

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİBRİT YAPAY ARI KOLONİSİ - ATEŞ BÖCEĞİ
OPTİMİZASYON YÖNTEMİ İLE GÖRÜNTÜLERDE
BELİRGİNLİK TESPİTİ

DOKTORA TEZİ

Elif Deniz YELMENOĞLU

Enstitü Anabilim Dalı : BİLGİSAYAR ve BİLİŞİM
MÜHENDİSLİĞİ
Tez Danışmanı : Doç. Dr. Numan ÇELEBİ

Temmuz 2022

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**HİBRİT YAPAY ARI KOLONİSİ - ATEŞ BÖCEĞİ
OPTİMİZASYON YÖNTEMİ ile GÖRÜNTÜLERDE
BELİRGİNLİK TESPİTİ**

DOKTORA TEZİ

Elif Deniz YELMENOĞLU

Enstitü Anabilim Dalı : **BİLGİSAYAR ve BİLİŞİM
MÜHENDİSLİĞİ**

**Bu tez / / 2022 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile
kabul edilmiştir.**

Jüri Başkanı

Üye

Üye

Üye

Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Elif Deniz YELMENOĞLU

.../.../...

ÖNSÖZ

Doktora eğitimim boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Doç. Dr. Numan ÇELEBİ'ye ve deneyimlerinden yararlandığım, yardımlarını esirgemeyen sayın hocam Dr. Tuğrul TAŞÇI'ya teşekkürlerimi sunarım.

Ayrıca yetişmemde haklarını hiçbir zaman ödeyemeyeceğim sevgili aileme ve her zaman destek olan sevgili eşime gösterdikleri anlayıştan dolayı sonsuz teşekkür ederim.

İÇİNDEKİLER

ÖNSÖZ	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	v
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	vii
ÖZET	viii
SUMMARY	ix
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
KAYNAK ARAŞTIRMASI	4
2.1. Yukarıdan-Aşağıya (Top-Down) Yaklaşım İçeren Çalışmalar	4
2.2. Aşağıdan-Yukarıya (Bottom-Up) Yaklaşım İçeren Çalışmalar.....	8
2.3. Hem Aşağıdan-Yukarıya (Bottom-Up) Hem Yukarıdan-Aşağıya (Top-Down) Yaklaşım İçeren Çalışmalar	12
2.4. Belirginlik Tespitinde Optimizasyon Algoritmalarını Kullanan Çalışmalar	14
BÖLÜM 3.	
MATERYAL VE YÖNTEM	17
3.1. Sayısal Görüntü İşleme	17
3.1.1. Temel kavramlar	17
3.1.2. Görüntü türleri	18
3.1.3. Görüntü işleme teknikleri	18

3.2. Sayısal Görüntülerde Belirginlik Tespiti	21
3.3. Optimizasyon ve Optimizasyon Teknikleri	22
3.3.1. Yapay arı kolonisi optimizasyonu	27
3.3.2. Ateş böceği optimizasyonu	33
BÖLÜM 4.	
GELİŞTİRİLEN HİBRİT YAPAY ARI KOLONİSİ - ATEŞ BÖCEĞİ	
OPTİMİZASYON MODELİ ve PERFORMANS ANALİZİ	37
4.1. HABCFA Optimizasyonu	37
4.2.HABCFA, ABC ve FA Optimizasyon Yöntemlerinin	
Karşılaştırılması.....	41
BÖLÜM 5.	
GELİŞTİRİLEN HABCFA YÖNTEMİNİN GÖRÜNTÜLERDE	
BELİRGİNLİK TESPİTİ PROBLEMİNDE KULLANILMASI	45
BÖLÜM 6.	
DENEYSEL BULGULAR.....	49
6.1. Kullanılan Veri Setleri.....	49
6.1.1.MSRA1000 veri seti.....	49
6.1.2. ECSSD veri seti	50
6.1.3. ICOSEG veri seti.....	50
6.1.4. DUTOMRON veri seti	50
6.2. Kullanılan Değerlendirme Yöntemleri.....	50
6.2.1. Precision-recall (Kesinlik-duyarlılık).....	50
6.2.2. F-measure (F-ölçütü).....	51
6.2.3. MAE (Ortalama mutlak hata).....	52
6.3. Başlangıç Parametre Değerlerinin Belirlenmesi.....	52
6.4. Diğer Metotlar ile HABCFA'nın Karşılaştırma Sonuçları.....	53
6.4.1. Precision-recall sonuçları.....	53
6.4.2. Ortalama f-measure sonuçları.....	55
6.4.3. Elde edilen sonuç görüntüleri.....	55

6.4.4. MAE sonuçları.....	57
6.4.5. Çalışma süreleri.....	58
BÖLÜM 7.	
SONUÇ.....	65
KAYNAKLAR	67
ÖZGEÇMİŞ	73

SİMGELER VE KISALTMALAR LİSTESİ

AAMLN	: Auto-associative multilayer perceptron (otomatik ilişkişel çok katmanlı algılayıcı)
ABC	: Artificial bee colony (yapay arı kolonisi) optimizasyon algoritması
ATDF	: Automatic Top-Down Fusion (otomatik yukarıdan-aşağıya füzyon)
CRF	: Conditional random field (koşullu rastgele alan)
DCT	: Discrete cosine transform (ayrık kosinüs dönüşümü)
DFT	: Discrete fourier transform (ayrık fourier dönüşümünü)
DNN	: Deep neural networks (derin sinir ağları)
FA	: Firefly (ateş böceği) optimizasyon algoritması
FCN	: Fully convolutional network (evrişimsel sinir ağları)
FFD	: Fast fourier transform (hızlı fourier dönüşümü)
FIN	: Foreground interface network (ön plan arayüz ağları)
HABCFA	: Hybrid artificial bee colony firefly optimization algorithm (hibrit yapay arı kolonisi - ateş böceği optimizasyon algoritması)
LSM	: Level set method (düzey kümesi yöntemi)
MAE	: Mean absolute error (ortalama mutlak hata)
PCA	: Principal component analysis (temel bileşen analizi)
PFT	: Phase spectrum of quaternion fourier transform (fourier dönüşümünün faz spektrumu)
SDREL	: Saliency driven region-edge based level set model (belirginlik odaklı bölge-kenar tabanlı düzey kümesi modeli)
SLIC	: Simple linear iterative clustering (basit doğrusal yinelemeli kümeleme)
SOD	: Salient object detection (belirgin alan tespiti)

ŞEKİLLER LİSTESİ

Şekil 3.1. Dijital görüntü ve piksel değerleri.....	19
Şekil 3.2. Görüntü işleme teknikleri şeması.....	19
Şekil 3.3. Optimizasyon algoritmaları grupları.....	23
Şekil 3.4. Sezgisel yöntemler.....	26
Şekil 3.5. Arı dansı ve gözcü arılar ile bilgi paylaşımı.....	28
Şekil 3.6. Arıların yiyecek arama döngüsü.....	29
Şekil 3.7. ABC akış diyagramı.....	30
Şekil 3.8. FA akış diyagramı.....	35
Şekil 4.1. HABCFA optimizasyonu akış diyagramı.....	38
Şekil 4.2. Kalite testi problemleri üzerinde performans karşılaştırması.....	43
Şekil 5.1. Önerilen yaklaşımın çalışma mekanizması.....	45
Şekil 5.2. Belirginlik tespitinde HABCFA'daki görevli bireylerin rolü.....	47
Şekil 5.3. Belirginlik tespitinde HABCFA'daki gözcü bireylerin rolü.....	48
Şekil 6.1. Precision recall eğrileri.....	54
Şekil 6.2. Ortalama F-measure karşılaştırmaları.....	55
Şekil 6.3. MSRA1000 veri seti için belirginlik haritalarının karşılaştırması.....	56
Şekil 6.4. ECSSD veri seti için belirginlik haritalarının karşılaştırması.....	56
Şekil 6.5. ICOSEG veri seti için belirginlik haritalarının karşılaştırması.....	57
Şekil 6.6. DUT-OMRON veri seti için belirginlik haritalarının karşılaştırması...	57
Şekil 6.7. Tüm veri kümeleri ve yöntemler için çalışma sürelerinin karşılaştırılması.....	59
Şekil 6.8. Görüntülerdeki renk farklılıklarına göre ortalama çalışma süreleri.....	60

TABLULAR LİSTESİ

Tablo 4.1. Kullanılan test fonksiyonlarının özellikleri	42
Tablo 4.2. Kullanılan test fonksiyonlarının formülleri	42
Tablo 4.3. HABCFA, FA ve ABC algoritmalarının çalışma süreleri	44
Tablo 6.1. Görüntülerde belirgin alanların tespiti için hata matrisi	51
Tablo 6.2. MAE değerlerinin karşılaştırması	58
Tablo 6.3. Görüntü başına ortalama çalışma süreleri	58
Tablo 6.4. Standart sapma değerlerinin karşılaştırması	60
Tablo 6.5. Literatürdeki 11 state-of-the-art yöntemin özellikleri ve HABCFA ile karşılaştırmaları	61

ÖZET

Anahtar kelimeler: Yapay arı kolonisi algoritması, ateş böceği algoritması, belirginlik tespiti, meta-sezgisel optimizasyon, görüntü işleme.

Görüntülerde belirginlik tespiti (saliency detection) son yıllarda popüler olan bir görüntü işleme dalıdır. Belirginlik tespitinde, insan gözünün çalışması taklit edilir ve görüntülerde ilk odaklanılan alanın bulunması amaçlanır. Göze çarpan alanların tespit edilmesi, nesne tanıma, görüntü bölütleme ve video izleme gibi problemleri çözmek için geliştirilen modellere alternatif olarak kullanılacak bir yöntemdir. Bu durum, belirginlik tespitini görüntü işlemede önemli bir yere sahip kılmaktadır.

Optimizasyon algoritmalarının görüntü işleme problemlerine uygulanması oldukça yaygın bir araştırma alanıdır. Bu çalışmada, görüntülerde belirginlik tespiti probleminin çözümünde, yapay arı kolonisi (artificial bee colony - ABC) ve ateş böceği (firefly - FA) optimizasyon yöntemlerinden yararlanılarak geliştirilen hibrit yöntem (hybrid artificial bee colony firefly algorithm – HABCFA) kullanılmıştır.

Bir görüntüdeki göze çarpan alanı veya nesneyi tespit etmek için geliştirilen algoritmalar genel olarak aşağıdan - yukarıya ve yukarıdan - aşağıya yöntemler olarak iki grupta ele alınmaktadır. Aşağıdan – yukarıya olan yöntemler görüntülerden elde edilebilen verileri kullanırken, yukarıdan – aşağıya olan yöntemler öğrenme tabanlı sistemlere ihtiyaç duymaktadır. Bu çalışmadaki yaklaşım görüntünün renk bilgisinden yararlandığından dolayı aşağıdan – yukarıya sınıfına dahil olmaktadır. Belirginlik tespiti sürecinde, göze çarpan bölgelerin daha hassas bir şekilde çıkarılmasını sağlamak ve daha optimum bir arka plan değeri elde etmek için süper-piksel tabanlı bir sınıflandırma yöntemi olan SLIC yöntemi ön işlem aşamasında kullanılmıştır. Ön işlem aşamasından sonra görüntünün kenar bölgelerinden elde edilen arka plan değeri, HABCFA yöntemi ile optimize edilmekte ve görüntüye en uygun arka plan değeri bulunmaktadır. Optimum arka plan değerinin mevcut görüntüden çıkarılması ile belirginlik haritası (saliency map) elde edilmektedir.

Yapılan deneylerde, HABCFA belirginlik tespiti yöntemi, yaygın olarak kullanılan MSRA-1000, ECSSD, ICOSEG ve DUTOMRON veri kümeleri kullanılarak, literatürdeki 11 state-of-the art yöntem ile karşılaştırılmıştır. HABCFA'nın herhangi bir ekstra maske veya eğitim aşaması gerektirmeden elde ettiği sonuç görüntüleri, diğer yöntemlerin sonuçları ile karşılaştırıldığında, HABCFA'nın etkili olduğu görülmüştür. Ayrıca ABC, FA ve HABCFA yöntemleri, yakınsama oranı ve çalışma süreleri açısından bilinen dört kıyaslama problemi ile karşılaştırılmış ve HABCFA diğer iki optimizasyon yönteminden daha iyi bir performans üretmiştir.

SALIENCY DETECTION BASED ON HYBRID ARTIFICIAL BEE COLONY AND FIREFLY OPTIMIZATION

SUMMARY

Keywords: Artificial bee colony algorithm, firefly algorithm, saliency detection, meta-heuristic optimization, image processing.

In recent years, saliency detection in images has become a major image processing field. The human eye's focusing function is emulated in saliency detection, which aims to discover the first focused area in images. The method of detecting salient areas can be utilized instead of the models established to handle problems like object recognition, image segmentation, and video surveillance. As a result, saliency detection is a significant aspect of image processing.

The use of optimization techniques to solve image processing difficulties is a popular research topic. In this study, a hybrid approach (hybrid artificial bee colony firefly algorithm – HABCFA) was developed by combining artificial bee colony (ABC) and firefly (FA) optimization methods to answer the problem of saliency detection in images.

Bottom-up and top-down approaches are two types of algorithms created to find the most important area or object in an image. Top-down methods require learning-based systems, whereas bottom-up methods rely on data received from images. This study's approach is classified as bottom-up because it makes use of the image's color information. During the preprocessing stage, the SLIC approach, which is a super-pixel-based classification method, was utilized to extract salient regions more precisely and obtain a more ideal background value for the saliency detection process. Following the preprocessing stage, the HABCFA method is used to optimize the background value obtained from the image's edge regions, resulting in the best acceptable background value for the image. The ideal background value is subtracted from the current image to produce a saliency map.

In the experiments, using the popular MSRA-1000, ECSSD, ICOSEG, and DUTOMRON datasets, the HABCFA saliency detection approach was compared to 11 state-of-the-art methods in the literature. When the results of HABCFA without any additional masking or training steps were compared to the results of other approaches, it was discovered that HABCFA was effective. In addition, in terms of convergence rate and running times, the ABC, FA, and HABCFA methods were compared to four known comparison problems, with HABCFA outperforming the other two optimization methods.

BÖLÜM 1. GİRİŞ

Görüntü işleme insanların görme sisteminden esinlenilerek ortaya çıkan bir araştırma alanıdır. Göz gibi davranma yeteneğine sahip olan donanımların gelişmesi ile birlikte görüntüler yakalanabilmiş ve incelenmek üzere işlenebilir hale gelmişlerdir. İlk zamanlarda bu süreç, analog olarak görüntülerin elde edilmesi ile başlamış, daha sonra ise dijital görüntülerin elde edilmesi ve işlenmesi ile birlikte devam etmiştir. Günümüzde dijital görüntülerin bilgisayarlar aracılığıyla işlenmesi ve analiz edilmesi son yılların popüler bilimsel çalışma alanlarından biri olmuştur. Dijital görüntü işleme, matematiksel ve olasılıksal formülasyonlar üzerine kurulmuş olsa da, insan sezgisi ve analizi, bir tekniği diğerine tercih etmede önemli bir rol oynar ve bu seçim genellikle kişisel ve görsel yargı yoluyla yapılır [1]. İnsanların görme duyusundan esinlenilerek, uzay uygulamaları, tıbbi görüntüleme teknikleri, bilgisayarlı endüstri, biyoloji bilimi, coğrafi analiz sistemleri, arkeoloji, savunma teknolojileri ve sanayi gibi pek çok alanda yapılmış olan çalışmalar görüntü işlemenin önemini göstermektedir.

Görüntülerde belirginlik tespiti alanında yapılan çalışmalar, insan gözünün bir görüntüdeki farklı olan alanlara odaklanmasını simule eder. İnsan görme sistemi, bir görüntüye odaklandığında aslında tüm alanın sadece dikkat çeken bir parçasına odaklanır. Bu parça görüntüdeki genel dağılımdan farklı olduğu için belirgin alan veya dikkat çeken alan olarak tanımlanır. Nesne tanıma problemlerinde tanınması gereken nesnenin belirgin alanda bulunması, video izleme (tracking) problemlerinde bir video içindeki nesnenin takip edilebilmesi için nesnenin farklı özelliklerinin belirlenebilmesi ve sınıflandırma uygulamaları için görüntüdeki piksellerin belirli özelliklerine göre gruplandırılması gerekir. Belirginlik tespiti yöntemleri, nesne tanıma, video izleme ve sınıflandırma gibi pek çok farklı görüntü işleme problemlerine alternatif çözümler üretebilir. Bir nesnenin arka planından ayırt edilmesini göstermek için nesnenin arka plandan ayırt edilebilmesini sağlayan niteliklerine göre belirginlik haritaları oluşturulur. Bu haritalar sayesinde insan görme

sistemi taklit edilir. Belirginlik haritalarının oluşturulmasını sağlayan bu nitelikler belirginlik ölçütleri olarak tanımlanır.

Belirgin alanları bulma yaklaşımları temelde iki ana kategoriye ayrılır [2]: belirli bir objenin görsel bilgisinin öğrenilmesine ihtiyaç duyulan (supervised manner) yukarıdan-aşağıya yaklaşım [6-18] ve renk, parlaklık, desen, konum gibi veriye göre (low-level) olan niteliklerin önem kazandığı aşağıdan-yukarıya yaklaşım [19-35]. Öğrenmeye/eğitime dayanan yukarıdan-aşağıya yaklaşımda, görüntünün içeriği ile ilgili öncül bilgiye ihtiyaç vardır. Ancak aşağıdan-yukarıya yaklaşımlar görüntünün kendi bilgilerinden direkt olarak belirgin alanı çıkarımı yapabilirler. Bu nedenle literatürde, aşağıdan-yukarı yaklaşıma dayalı çalışmalar daha yaygın olarak görülmektedir. Bu tez çalışmasında, aşağıdan-yukarıya yaklaşıma sahip bir belirginlik tespiti uygulaması gerçekleştirilmiştir.

Görüntülerde belirgin alanların tespitini zorlaştıran bazı durumlar mevcuttur. Görüntünün arka planının karmaşık olması, belirgin nesnenin görüntünün kenar bölgelerinde bulunabilmesi ve belirgin nesne ile arka plan arasında düşük renk kontrastı olması gibi sorunlar zorlaştırıcı durumlardır. İstenmeyen bu gibi durumlar, belirgin nesneye/alana ait bölgelerin de arka plan gibi nitelendirilmesine neden olabilmektedir. Bu tez çalışmasında bu gibi problemleri çözebilmek için aşağıdan-yukarı yaklaşım benimsenerek sezgisel optimizasyon algoritmalarından yararlanılmaktadır. Sezgisel optimizasyon algoritmaları, akıllı tahminlere dayalı buluş yöntemi veya yeni çözümlerin keşfine götüren bulgulara dayalı aramalar yapan algoritmalarıdır. Bu algoritmalarından Yapay Arı Kolonisi (ABC) [3] ve ateş böceği (FA) [4] optimizasyon algoritmaları, optimizasyon problemlerinde çalışma süreleri ve optimum çözümü elde edebilme başarıları ile öne çıkan algoritmalarındandır. Bu çalışmada bu iki algoritmanın birleştirilmesi ile hibrit bir optimizasyon algoritması geliştirilmiştir. Geliştirilen hibrit yöntem ile renkli görüntülerden belirginlik haritası çıkarımı gerçekleştirilmiştir. Giriş görüntülerine ilk olarak SLIC (Simple Linear Iterative Clustering) süper-piksel yöntemi [5] uygulandı ve daha sonra önerilen HABCFA (Hybrid Artificial Bee Colony Firefly Algorithm) algoritması ile belirginlik alan tespit edilmiştir. SLIC süper-piksel yöntemi Achanta vd., (2012)

tarafından geliştirilmiş ve bölütlemeye önileme, nesne yer tayini vb. problemlerin çözümünde kullanılmaktadır [5].

Geliştirilen HABCFA optimizasyonu ile belirginlik tespiti yaklaşımının iki ana avantajı: Birincisi, hiçbir öncül bilgiye, maskeye veya eğitim aşamasına ihtiyaç duymamaktadır. İkincisi, iki optimizasyon metodunun birleştirilmesi ile birlikte, daha iyi olan çözüme daha çok yakınsama hedeflenerek optimum sonuca daha iyi bir yakınsama sağlanmıştır. Önerilen model belirginlik tespiti probleminde yaygın olarak kullanılan veri setleri üzerinde test edilmiştir. Bu veri setlerinden elde edilen belirginlik haritaları literatürde en yaygın kullanılan belirginlik tespiti metotları ile karşılaştırılmıştır.

Bu tez çalışması 5 bölümden oluşmaktadır. Birinci bölüm, tez çalışmasının amacını, incelenen problemin ne olduğunu ve önemini içermektedir. İkinci bölüm, belirginlik tespiti alanındaki ilgili çalışmalara genel bir bakış sunmaktadır. Üçüncü bölümde, tez çalışmasının amacına ulaşabilmek için kullanılan metotlar ve materyaller açıklanmaktadır. Dördüncü bölümde, geliştirilen hibrit optimizasyon algoritmasının, görüntülerde belirginlik tespiti problemlerine uygulanması deneylerinden elde edilen sonuçlar belirtilmiştir. Son olarak beşinci bölümde, çalışmanın sonucunda elde edilen bilgiler özet olarak verilmiş ve gelecek çalışmalar için hangi açılardan temel olabileceği konusunda bilgi verilmiştir.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

Bu bölümde, belirginlik tespitinde literatürde var olan çalışmalar incelenmiştir. Her bir çalışmanın içeriği kısaca açıklanmıştır.

2.1. Yukarıdan-Aşağıya (Top-Down) Yaklaşım İçeren Çalışmalar

Göze çarpan alanların tespiti için yukarıdan-aşağıya yaklaşımı temel alarak geliştirilen çalışmalarda öğrenme algoritmaları kullanılabilir. Sistemin eğitilmesine ihtiyaç duyan bu metotlar, görüntülerdeki nesnelerin belirginliğini modellemek için önceden belirlenmiş bilgileri kullanır. Bu yaklaşımlar hafıza tabanlı olduklarından tüm verileri işlemek için daha fazla hafızaya ihtiyaç duyarlar.

Yukarıdan-aşağıya yaklaşımını benimseyen Zhao ve ark.'nın çalışmalarında [6], daha iyi bir başlangıç değeri sağlamak amacıyla derin sinir ağları (Deep Neural Networks - DNN) kullandılar. Bu ağı eğitmek için, farklı ön eğitim stratejileri araştırılmış ve bu araştırmaların sonucunda bir ön eğitim şeması tasarlanmıştır.

Belirginlik tespitinde DNN yönteminin kullanıldığı bir diğer çalışmada ise DNN'lerin eğitim maliyeti üzerine bir araştırma yapılmıştır [7]. Bu çalışmada, görüntü düzeyinde zayıf denetim ile belirginlik tespiti için iki aşamalı bir eğitim yöntemi önerilmiştir. Eğitimin ilk aşamasında, FIN (Foreground Inference Network), görüntü düzeyinde etiket tahmini için FCN (Fully Convolutional Network) ile birlikte eğitilmiştir. İkinci aşamada, FIN ile tahmini belirginlik haritaları kullanılarak daha da hassas bir şekilde belirginlik tespitinin yapılması amaçlanmıştır. Ayrıca, tahmini sonuçları iyileştirmek ve performansı daha da arttırmak için yinelemeli bir CRF (Conditional Random Field - Koşullu Rastgele Alan) geliştirdiler.

J. Yang ve M. Yang'ın 2017 yılındaki çalışmalarında [8], CRF ve ayırt edici bir sözlük ile birlikte öğrenen bir model önerdiler. Model için hızlı çıkarım algoritmaları, eğitmek için ise bir maksimum tolerans yaklaşımını kullandılar. Bu şekilde hem hedef nesnelerin belirginlik haritalarını sundular hem de arama alanının azaltılması için bir olasılık haritası sağladılar.

Belirginlik tespiti alanındaki diğer bir çalışma olan Liu ve ark.'nın çalışmalarında belirgin nesnenin hem yerel hem bölgesel hem de küresel olarak tanınması amaçlanmıştır. Tespit için çoklu ölçek kontrastı, merkez çevre histogramı ve mekânsal renk dağılımı özelliklerinden yararlanılmıştır. Ayrıca belirgin nesne tespiti için ikili etiketleme (binary labeling) yaklaşımı uygulanmış ve farklı olan özellikleri etkili bir şekilde birleştiren bir CRF ile öğrenme tabanlı bir sistem kullanılmıştır. Önerilen yaklaşımın etkinliğini göstermek için yapılan deneylerde hem görüntü veri tabanı hem de bir video veri tabanı kullanılmıştır [9].

Belirginlik tespiti, sabit görüntülerde kullanıldığı gibi videolar üzerinde de kullanılan bir yöntemdir. Rahtu ve ark.'nın çalışmasında bir CRF modeli ve bir belirginlik ölçüsü kullanarak belirgin nesne bölütleme yöntemi önerilmiştir [10]. Önerilen belirginlik ölçüsü, aydınlatma, renk ve hareket bilgisinde istatistiksel bir çerçeve ve yerel özellik kontrastı kullanılarak formüle edilmiştir. Ortaya çıkan belirginlik haritası daha sonra, iyi tanımlanmış göze çarpan nesnelere ayırabilmeyi amaçlayan bir enerji minimizasyonuna dayalı bir CRF modelinde kullanılmıştır. Bu yöntem, hem sabit görüntülere hem de videolara uygulanabilen birkaç yöntemden birisi olarak nitelendirilmektedir.

Görüntülerdeki belirgin alanların tespit edilmesi sürecinde, etiketlenmiş veya sınıflandırılmış verilerle çalışmak daha iyi veya daha hızlı sonuçlar alınmasını sağlayabilir. Bu nedenle belirginlik tespitinde, belirginlik kriterine göre sınıflandırma alanında da eğitici sistemler kullanan yukarıdan-aşağıya yaklaşımlı çalışmalar yapılmıştır. 2003'te Fergus ve ark. [11], bölümlenmemiş karmaşık görüntülerde, nesne sınıfı modellerini öğrenmek ve tanımlamak için bir yukarıdan-aşağıya yöntem önerdiler ve nesnenin şekil gibi özellikleri için olasılıksal bir gösterim kullandılar.

Konvolüsyonel sinir ağlarını (Convolutional Neural Networks-CNN'ler) belirginlik tespitinde kullanan Qiu ve ark. çalışmalarında [12], ağ mimarilerinin gittikçe daha karmaşık hale geleceği ve bu durumun gelecekteki iyileştirmeyi zorlaştıracağı ayrıca manuel olarak tasarlanmış füzyon stratejilerinin, olası çözümlerin geniş arama alanı nedeniyle yetersiz olacağını belirttiler. Alt katmanların öğrenilmesine rehberlik etmek için üst katmanlardaki global bilgilerin alt katmanlara aktığı bir Otomatik Yukarıdan-Aşağıya Füzyon (Automatic Top-Down Fusion- ATDF) yöntemi geliştirilerek bu sorunların giderilmesi amaçlanmıştır. Yeni bir valf modülü (valve module) tasarlanmış ve belirginlik tespiti için birleştirilmiş derin özelliklerin tahmin kabiliyetini geliştirmek için bir yapı tasarlanmıştır. ATDF'nin basit ve etkili olduğunu göstermek için kapsamlı deneyler yapılmıştır.

CNN'in belirginlik tespiti alanında kullanıldığı diğer bir çalışma ise Cao ve ark.'nın çalışmasıdır [13]. Bu çalışmada, genellikle büyük miktarlarda model parametresinin kullanıldığına ve bu durumun belirginlik tespiti problemlerinde uzun çalışma sürelerine yol açtığına değinilmiştir. Belirginlik haritası çıkarımı için en kullanışlı haritaları seçmek ve kalanı atmak için bir özellik haritası seçim yöntemi önerilmiştir. Bu yöntemde 18 özellik haritasından eşleşme oranlarına göre 6 tanesi seçilmiş ve bu seçilen özellik haritaları kullanılarak çalışma süresinde azalma sağlanmıştır.

Zhao ve ark. da çalışmalarında CNN'den yararlanmışlardır [14]. Bu makalede, derin öğrenme temelli SOD (Salient Object Detection) yaklaşımı uygulanmıştır. Önerilen ağ ile önceden kontrasta dayalı olarak geliştirilmiş olan derinlik haritalarının geliştirilmesi amaçlanmıştır. Belirgin ve belirgin olmayan bölgeler arasındaki kontrastı artırmak ve bu bölgelerdeki tutarlılığı garanti etmek için RGB özellikleriyle çalışılmıştır. Ayrıca, özelliklerden daha iyi yararlanmak için bir akışkan piramit entegrasyon yöntemi (Fluid Pyramid Integration) önerilmektedir. Zorlu durumlarda göze çarpan bölgeleri yakalama yeteneğine sahip bir yöntem geliştirilmiştir ve bu yöntem, yaygın olarak kullanılan veri kümeleri üzerinde test edilmiştir.

Zhi ve Shen çalışmalarında, belirgin alanları tespit edebilmek için segmentasyon problemlerinde sıkça kullanılan LSM (Level Set Method) ve SDREL (Saliency

Driven Region-Edge based Level set model) modelinden yararlanmışlardır [15]. Ancak LSM yöntemlerinin bazı durumlarda yetersiz kaldığı belirtilmiştir. LSM, tespit edilmesi gereken nesnelere arka plandaki renk yoğunluğuna benzer renk yoğunluğuna sahip olması durumunda yetersiz olabilmektedir. Bu çalışmada, problemlerin üstesinden gelmek için SDREL metodunda yeni bir enerji fonksiyonu tanımlanmış ve bu fonksiyonda hem belirginlik haritası bilgisi hem de renk yoğunluğu bilgisi kullanılmıştır.

Li ve ark., belirginlik tespiti problemleri için bir öğrenme modeli geliştirmişlerdir [16]. Bu modelde, her bir belirginlik değeri için ikili bir karar kullanmak yerine, verilen tahmini belirginlikle olan ilişki düzeyine göre belirginlik değerleri azalan bir şekilde sıralanmaktadır. Ayrıca farklı belirginlik etiketleri için tahmin modelleri bir matriste toplanmıştır. Belirginlik sıralaması düşük sıralı bir matris kurtarma problemi (Low-Rank Matrix Recovery Problem) ile çözülmüştür.

Shen ve Wu'nun çalışmalarında da, düşük seviyeli görsel özellikleri ve belirginlik tespiti için daha yüksek seviyeli öncelikleri entegre etmek için düşük sıralı matris kurtarma (Low-Rank Matrix Recovery Problem) tabanlı yeni ve birleşik bir model önerilmiştir [17]. Bu modelde bir görüntü, arka planı temsil eden düşük sıralı bir matrise ve belirgin bölgeleri gösteren seyrek bir görüntü matrisine ayrıştırılmaktadır.

2014'te yapılmış olan bir çalışmada, belirginlik tespiti için, göz sabitleme ve dokunma belirginliği haritası adı verilen alternatif bir kavram sunulmuştur [18]. Dokunmatik ekranlı akıllı telefonlarda, kullanıcıların günlük tarama davranışlarından elde edilen verilerin toplanmasıyla dokunmaya dayalı belirginlik verilerinin elde edilebileceği vurgulanmıştır. Bu çalışmada ilk olarak, dokunmatik ekran sabitleme haritalarının özellikleri (touch saliency), muadili olan göz sabitleme haritalarının (visual saliency) özellikleri ile karşılaştırılmıştır. Karşılaştırmalar sonucunda bu iki kavramın ilişkili olduğu ve dokunma haritalarının görsel dikkat çalışması için veri toplamadaki faydası belirtilmiştir. Hem dokunma belirginliği hem de görsel belirginlik arasındaki tutarlılığa dayanan birleşik bir belirginlik tahmin modeli önerilmiştir.

2.2. Aşağıdan-Yukarıya (Bottom-Up) Yaklaşım İçeren Çalışmalar

Belirgin alanların tespitindeki yöntemler arasında aşağıdan-yukarıya yaklaşımı benimseyen yöntemler daha popülerdir. Mevcut aşağıda -yukarıya yöntemler, bir pikselin veya bölgenin ön plandaki belirginliğini yerel bir bağlamdaki veya tüm görüntüdeki zıtlığına dayalı olarak ölçer ve dikkat çekici nesnelere ayırmaya odaklanır. Bu yöntemler, önceden tanımlanmış herhangi bir bilgiye ihtiyaç duymadan renk, doku ve parlaklık gibi görüntü özelliklerini kullanarak göze çarpan bölge tespiti sağlar.

Itti, Koch ve Niebur [19], dinamik bir sinir ağı olarak tanımladıkları belirginlik haritasına aşağıdan-yukarıya yaklaşımla girdi sağlamaktadır. Renk, yoğunluk ve yönlenmeye göre üç özellik haritası oluşturulmuştur ve bu üç harita da normalleştirilerek kullanılmıştır.

Hou ve Zhang [20] çalışmalarında, önceden tanımlanmış nesneye ait bir bilgi, kategori veya özellikten bağımsız bir model sunmuştur. Giriş görüntüsünün Log-spektrumu analiz edilmekte ve görüntünün spektral alandaki izi çıkarılmaktadır. Görüntülerden belirginlik haritasının çıkarılmasında hızlı bir yöntem olarak sunulmuştur.

Gu, Ma ve Zhang [21], belirginlik haritasını elde etmek için PFT (Phase Spectrum Of Quaternion Fourier Transform) kullandılar. PFT, her pikselin yoğunluk, renk ve hareket özelliğinden oluşan bir yapı olarak gösterilmiştir. Zamansal hareket boyutu eklenmesi ve faz spektrumu uygulanması ile görüntülerde belirgin olan alanların hem uzaysal hem de zamansal belirginlik göstermesi sağlanmıştır.

Ma ve Zhang [22], kontrast analizi temelli belirginlik tespiti için uygulanabilir ve hızlı bir yaklaşım önerdiler. Yaklaşımları, lokal kontrast analizine dayanan yeni bir belirti haritası oluşturulmasını içermektedir. İnsan algısı taklit edilerek, belirginlik haritasına girecek veya haritadan çıkarılacak alanların tespiti bulanık gelişen (Fuzzy Growing) bir yöntem ile sağlanmıştır.

Yang ve ark. çalışmalarında hem ön hem de arka plan ipuçlarını ele almışlardır [23]. GMR (Graph-Based Manifold Ranking) aracılığıyla görüntü öğelerinin benzerliği ön plan veya arka plan bilgileri ile sıralanmıştır. Görüntü öğelerinin belirginliği, verilen sorgularla olan ilgilerine göre tanımlanmaktadır. Görüntü, düğümler olarak süper-piksellere sahip bir kapalı döngü grafiği (close-loop graph) olarak temsil edilmektedir. Bu düğümler, arka plan ve ön plan sorgularına olan benzerliğe göre sıralanmaktadır. Ayrıca, önerilen belirginlik modelini test etmek için 5.172 görüntü içeren bir veritabanı oluşturulmuştur.

Wei ve ark. çalışmalarında, belirgin nesne yerine arka plana daha çok odaklandılar [24]. Probleme ait daha fazla ipucu elde etmek için doğal görüntülerdeki arka planlarla ilgili iki yaygın öncelik; yani sınır ve bağlantı öncelikleri kullanılmıştır. Buna göre, jeodezik belirginlik adı verilen yeni bir belirginlik ölçüsü önerilmiştir.

Lu ve ark., görüntü sınırlarını, arka plan şablonları için olası ipuçları olarak süper-pikseller aracılığıyla elde etmektedir [25]. İlk olarak, her bir görüntü bölgesi için arka plan şablonlarında yoğun ve seyrek yeniden yapılandırma hataları (reconstruction error) hesaplanmaktadır. İkinci olarak, yeniden yapılandırma hataları, elde edilen bağlamlara dayalı olarak K-means yöntemi kullanılarak kümelenebilir. Daha sonra, piksel düzeyinde yeniden yapılandırma hatası, çoklu ölçekli yeniden yapılandırma hatalarının (multi-scale reconstruction errors) entegrasyonu ile hesaplanmaktadır. Bu çalışmalar temel alınarak, yoğun ve seyrek olmak üzere yeniden yapılandırma hatalarına dayalı iki belirginlik ölçüsü ile elde edilen belirginlik haritalarını birleştirmek için yeni bir Bayes entegrasyon yöntemi sunulmuştur.

Görüntülerde belirgin alan tespiti için bazı çalışmalarda Markov zinciri yönteminden yararlanılmıştır. Bu çalışmalardan birine sahip olan Jiang ve ark., Markov zincirini bir görüntü grafik modelinde uyarlayarak belirginlik tespitini formüle etmişlerdir [26]. Öne çıkan nesnelere ve arka planın görünüş farklılığı ve uzamsal dağılımı birlikte ele alınmıştır. Sanal sınır düğümleri, bir Markov zincirinde kaydedici düğümler olarak seçilmektedir ve her geçici düğümden sınır düğümlere kadar kayıt

edilen zaman hesaplanmaktadır. Geçici düğümün kayıt süresi, tüm kaydedici düğümler ile küresel benzerliğini ölçmektedir ve bu nedenle, kaydedilen zaman bir ölçü olarak kullanıldığında dikkat çekici nesnelere arka plandan tutarlı bir şekilde ayrılabilir. Geçici düğümden sanal sınır düğümlere kadar geçen süre, yol üzerindeki ağırlıklara ve bunların uzaysal mesafesine bağlı olduğundan, görüntünün merkezi ile arka plan bölgesi farkı belirgin olmaktadır.

Imamoglu ve ark. çalışmalarında, dalgacık dönüşüm (wavelet transform) alanından elde edilen düşük seviyeli özellikler kullanılarak yeni bir belirginlik algılama modeli tanıtmıştır [27]. İlk olarak, dalgacık dönüşümü, farklı özellikleri temsil edebilen çok ölçekli özellik haritalarını oluşturmak için kullanılmıştır. Ardından, bu özelliklerden belirginlik haritası elde etmek için hesaplamalı bir model önerilmektedir. Önerilen model, belirginlik haritasını çıkarmak için yerel farklılıkları ve küresel kontrastı dikkate almaktadır.

Cheng ve ark. çalışmalarında, küresel kontrastı ve mekansal tutarlılığı eşzamanlı olarak değerlendiren, bölgesel kontrast tabanlı belirginlik çıkarma algoritması önermiştir [28]. Ayrıca çıkarılan belirginlik haritasının, sonraki görüntü işleme problemlerinde kullanılmak üzere yüksek kaliteli segmentasyon maskeleri oluşturmak için nasıl kullanılacağı da sunulmuştur.

Perazzi ve ark.'nın 2012 yılındaki çalışmasında, önceki yöntemlerin bazı tasarım seçimleri gözden geçirilmiştir ve kontrast temelli belirginlik tahmini için kavramsal olarak açık ve sezgisel bir algoritma önerilmiştir [29]. Bu algoritma dört temel adımdan oluşmaktadır. İlk olarak, görüntü gereksiz ayrıntılardan soyutlanarak kompakt, algısal olarak homojen unsurlara ayrılmaktadır. İkinci adımda, bu soyutlamaya dayanarak, öğelerin benzersizliğini ve mekansal dağılımını derecelendiren iki kontrast ölçüsü hesaplanmaktadır. Daha sonra, ilgili nesnelere ön ve arka planlarını tutarlı bir şekilde ayıran bir belirginlik haritası üreten bir belirginlik ölçüsü türetilmektedir. Tam kontrast bilgisinin ve belirginlik tahmininin yüksek boyutlu Gauss filtreleri kullanılarak, birleşik bir şekilde formüle edilebileceği gösterilmiştir.

Duan ve ark.'nın çalışmalarında, mekansal ağırlıklı farklılığa dayalı yeni bir görsel belirginlik algılama yöntemi önerilmiştir [30]. Belirginlik, üç öge entegre edilerek ölçülmüştür. Bu öğeler, azaltılmış boyutsal alanda değerlendirilen görüntü alanları arasındaki farklılıklar, görüntü alanları arasındaki uzamsal mesafe ve merkezi sapma olarak belirlenmiştir. Boyut azaltma yöntemi olarak temel bileşen analizinden (Principal Component Analysis - PCA) yararlanılmıştır.

Görüntülerde belirgin alanın tespit edilmesinde çoğu çalışma benzer bir merkeze olan komşuluk bilgisini kullanmaktadır. Buradaki en önemli nokta bu komşuluğun büyüklüğünün belirlenmesidir. Achanta ve ark.'nın çalışmasında [31], tüm görüntü komşuluk içerisinde ele alınmıştır. Kenar veya sınır olarak tanımlanan bölgeleri iyi tanımlamak için uzamsal frekanstan yararlanılmıştır. Bu çalışmadaki yöntemde, renk ve parlaklık özelliklerinden yararlanılmış ve geliştirilen algoritmanın frekans etki alanı analizi, temel doğruluk ve göze çarpan nesne segmentasyonu açısından sonuçları sunulmuştur.

Goferman ve ark. belirginlik problemlerinin çözümü için bazı kurallar tanımlamış ve bu kurallar çerçevesinde geliştirdikleri algoritma ile görüntülerde belirgin alanları tespit edebilmişlerdir [32]. Bu kurallar, farklı renklere veya desenlere sahip alanlar yüksek, homojen veya bulanık alanlar ve sıklıkla ortaya çıkan özellikler düşük belirginlik değerine sahip olmalı şeklinde sıralanmıştır. Ayrıca belirgin piksellerin birlikte gruplanması ve görüntünün tamamına yayılmaması gerektiği de vurgulanmıştır.

İyi bilinen bir belirgin alan tespiti yöntemi ise merkez-çevre (center-surround) tekniğidir. Bu yaklaşımda, bir merkez ve bir çevreye bölünmüş yerel bir pencere vardır. Merkez bir nesne içermektedir. Tavakoli ve ark., bu tekniğe dayalı ve bayesci (bayesian) bir çerçevede yerel özellik kontrastının belirginliğini tahmin etmeye çalışan bir yöntem geliştirmiştir [33].

Seo ve Milanfar'ın çalışmalarında, bir pikselin çevresine benzerliğini ölçen, verilen görüntüden (veya bir videodan) yerel tanımlayıcıları hesaplayan bir çerçeve

önermiştir [34]. Görsel belirginlik, "kendine benzerlik (self-resemblance)" ölçüsü kullanılarak hesaplanmaktadır. Çerçeve, her pikseli çevreleyen özellik matrisleri göz önüne alındığında, bir özellik matrisinin belirgin olma olasılığının istatistiksel olasılığını gösterdiği bir belirginlik haritası ile sonuçlanmaktadır. Bir benzerlik ölçüsü olarak, matris kosinüs benzerliği (kosinüs benzerliğinin bir genellemesi) kullanılmaktadır.

Doğal görüntülerde belirgin alanların tespit edilmesindeki zorlukların üstesinden gelebilmek için Yan ve ark. hiyerarşik bir model önermiştir [35]. Bu modelde ölçekli bir yol izlenmiş ve belirginlik ipuçlarını analiz etmek için çok katmanlı bir yaklaşım sunulmuştur. Nihai belirginlik haritası, hiyerarşik bir modelde üretilmektedir ve ölçek tabanlı bölge işleme yönteminde, bir ağaç modeli kullanılarak belirginlik değerleri bulunmaktadır. Ayrıca bu çalışmada yeni bir veri kümesi de oluşturulmuştur.

2.3. Hem Aşağıdan-Yukarıya (Bottom-Up) Hem Yukarıdan-Aşağıya (Top-Down) Yaklaşım İçeren Çalışmalar

Görüntülerde dikkat çeken alanların tespit edilmesinde her iki yaklaşımın da kullanıldığı çalışmalar mevcuttur. Murabito ve ark., yukarıdan-aşağıya ve aşağıdan-yukarıya süreçlerin entegrasyonunu taklit edebilen bir belirginlik tespiti yaklaşımı sunmuştur [36]. Özellikle, belirli bir görsel görevin yerine getirilmesi gerektiğinde ilk önce nasıl belirginlik yaratılacağı öğrenilmektedir. Daha sonra, öğrenilen belirginlik haritalarının önemsiz durumlarda görsel sınıflandırmayı destekleyip desteklemediği ve ne ölçüde destekleyebileceği araştırılmıştır. Bunun için, ortak olarak eğitilmiş iki ağdan oluşan bir CNN çerçevesi olan SalClassNet önerilmiştir. Sınıflandırma görevi için öğrenilen haritalar girdi olarak kullanılmış ve göreve dayalı belirginlik haritalarının sınıflandırma performansını arttırdığı gözlemlenmiştir.

Ban, Lee ve Yang çalışmalarında hem yukarıdan-aşağıya hem de aşağıdan-yukarıya yaklaşıma sahip bir yüz algılama modeli önermiştir [37]. Önerilen model, aşağıdan-yukarıya yaklaşımla ve yukarıdan-aşağıya yaklaşımla elde edilen göze çarpan

bilgileri birleştirmektedir. Sonuç olarak, giriş görüntüsündeki her alan için bir yüz olma derecesini temsil eden değer belirlenmekte ve yüz belirginlik haritası oluşturulmaktadır. Yukarıdan-aşağıya model aşamasında, yüz şekil ve renginin tespit edilmesinde AAMLN (Auto-Associative Multilayer Perceptron) yönteminden yararlanılmıştır.

İki akışlı UNet tabanlı mimariler, SOD (Salient Object Detection) modellerinde yaygın olarak kullanılmaktadır. Zhang ve ark. çalışmalarında, Unet'in, yüksek seviyeli özellikleri düşük seviyeli olanlarla aşamalı olarak bir araya getirmek için yalnızca yukarıdan-aşağıya bir kod çözücü ağı olarak kullanıldığını vurgulamıştır [38]. Bu çalışmada, bütünsel birleştirme yolları ve aşağıdan-yukarıya yaklaşıma sahip ekstra bir kod çözücü ağı aracılığıyla elde edilen farklı belirginlik özelliklerinin kullanılması önerilmiştir. İlki, çoklu özellik etkileşimlerini öğrenmek için özellikleri bütünsel olarak bir araya getirirken, ikincisi, yüksek seviyeli özelliklerle düşük seviyeli özellikleri bir araya getirerek düşük seviyeli özelliklerin yeteneklerini geliştirmektedir. Deneysel sonuçlar, önerilen tüm bileşenlerin RGB-D (RGB and depth features) görüntüler için SOD sonuçlarının kademeli olarak iyileştirebileceğini göstermiştir.

Wang ve ark., gelişmiş yüksek düzeyde belirginlik tahmini sağlamak için yukarıdan-aşağıya işlemde elde edilen belirginliği aşağıdan-yukarıya işlemde kullanmıştır [39]. Geliştirilen modelde yinelemeli olarak yukarıdan-aşağıya ve aşağıdan-yukarıya çıkarım gerçekleştirilmekte ve böylece iki süreç birbirine fayda sağlayabilmektedir. VGGNet veya ResNet'in konvolüsyonel katmanlarından alınan bir konvolüsyonel sinir ağı (CNN), ilk olarak bir belirginlik özelliği çıkarıcı olarak kullanılmaktadır. Alt katmanlardan gelen özellikler daha zengin, düşük düzeyli bilgileri kodlarken, üst katman etkinleştirmeleri daha az uzamsal ayrıntıyla daha yüksek düzeyde anlam taşımaktadır.

Göz izleme teknolojisi, göze çarpan nesnelerin tespiti için etkili bir araçtır. Xiao ve ark., süper-piksel segmentasyonu ve göz izleme verilerinin bir kombinasyonunu içeren yeni bir belirginlik algılama modeli önermiştir [40]. Göz izleme verileri ilk

olarak süper-piksel sayısını azaltmak ve hesaplamayı hızlandırmak için tanıtılmıştır. Daha sonra bu yaklaşım temel alınarak göze çarpan nesneyi tespit etmek için bir öğrenme modeli oluşturulmuştur. Son olarak, özellik kontrastı ve çok ölçekli strateji, entegre bir model olarak önerilmekte ve ayrıntılandırma belirginlik haritasını elde etmek için birleştirilmektedir.

Luo ve ark.'larının yaptıkları çalışmada CNN tabanlı modellerin uçtan-uca eğitiminin, genellikle pahalı ve zaman alıcı olan piksel seviyesinde açıklamalar içerdiği ve çok sayıda eğitim örneği gerektirdiği vurgulanmıştır [41]. Bu çalışmada öğrenme aşaması için büyük miktarda web verileri kullanılmıştır. Web'ten toplanan çok sayıda görüntü ile birlikte göze çarpan nesne maskelerini oluşturmak için önce birkaç aşağıdan-yukarıya belirginlik algılama tekniği kullanılmıştır ve ardından eğitim için güvenilir maskeler içeren bir görüntü alt kümesini seçmek için yeni bir kalite değerlendirme yöntemi kullanılmıştır. Bu işlemlerin ardından, ağ eğitim süreci ile eğitim seti güncelleme süreci arasında yinelenen ilk ağın performansını artırmak için kendi kendine eğitim yaklaşımı geliştirilmiştir.

2.4. Belirginlik Tespitinde Optimizasyon Algoritmalarını Kullanan Çalışmalar

Optimizasyon algoritmalarının, görüntü işleme problemlerinde en iyiye en yakın sonucu elde etmek için kullanımı son zamanlarda oldukça artmıştır. Bu durum, optimizasyon algoritmalarının, görüntülerde göze çarpan alanların tespiti problemi için de kullanılabilirliğini göstermektedir [42-49].

Chen ve Leou, görsel dikkat modeli ile blok tabanlı bir belirginlik haritası oluşturmuştur ve bu haritaya bağlı olarak, belirgin olan ve olmayan bloklardaki pikseller için çift yönlü doğrusal interpolasyon (bilinear interpolation) ve parçacık sürü optimizasyonu belirginliğine dayalı görüntü elde etme yaklaşımını önerilmiştir [42].

Singh, Arya ve Agrawal [43] çalışmalarında iki aşamalı bir belirgin nesne tespiti yaklaşımını önermektedir. Birinci aşamada, çok ölçekli kontrast, merkez çevre

histogramı ve mekansal renk dağılımı özellikleri kullanılmaktadır. Parçacık sürü optimizasyonu, belirgin nesneyi arka plandan ayırt etmek için optimum bir ağırlık vektörünü belirlemede yani ikinci aşamada kullanılmaktadır. Bu durum için, arka plan bölgelerini etkili bir şekilde ayıran basit bir uygunluk fonksiyonu tanımlanmıştır.

Chang, Liu, Chen ve Lai [44], görsel dikkat çekicilik konusunda önemli iki kavram olan nesnellik ve belirginlik arasındaki ilişki için yeni bir hesaplama modeli sunmuştur. Önerilen bu yaklaşım, nesnellik ve belirginlik kavramları ile bir grafik model oluşturularak kavramsal olarak bütünleştirilmekte ve aynı zamanda modeli gerçekleştiren enerji fonksiyonu tekrar tekrar optimize edilerek tahminler geliştirilmektedir.

Zhu ve ark. [45], sınır bağlantısı olarak adlandırılan bir arka plan ölçütü önermektedir. Görüntü bölgelerinin, görüntü sınırlarına göre uzamsal düzenini bu ölçüt karakterize etmektedir. Bu çalışmada, düzgün bir belirginlik haritası oluşumu için, arka plan ölçütü ve düşük seviyeli niteliklerin entegre edildiği bir optimizasyon çerçevesi önerilmiştir.

Lei ve ark. [46] RGBD görüntülerde optimizasyona dayalı bir belirginlik tespiti algoritması önermiştir. Bu çalışmada, RGBD görüntülerde, arka ve ön plan kavramlarının geliştirilmesinde “Derinlik kanalı (depth channel)” kullanılarak, doğrusal olmayan dönüşüm kullanılarak yeni bir derinlik imgesi üretilmekte ve sonuç belirginlik haritasını elde etmek için “derinlik bilgisi (depth cue)” ve “düşük seviyeli bilgiler (low-level cues)” kavramları entegre edilerek belirginlik optimizasyon çerçevesi oluşturulmuştur.

Ma, Tian ve Yu [47] tarafından sunulan çalışmalarında, görüntü üzerinde karınca hareketlerinin aracılığıyla feromon yaratarak, resmin belirginliğini ölçmede karınca kolonisi optimizasyonu kullanılmıştır. Ayrıca karıncaların hareketleri lokal aşamaların durumuna göre belirlenmektedir.

Lee, Leou ve Hsiao [48], belirginlik tabanlı segmentasyon için (Simple Modified) basit modifiye edilmiş parçacık sürü optimizasyonu yaklaşımını önermiştir. Bu çalışmada, belirginlik haritası üç özelliğe göre oluşturulmaktadır: renk, yoğunluk ve yönlenme. Önerilen metotta bir uygunluk fonksiyonu ile renkli görüntülerde segmentasyon sağlanmıştır.

Owechko ve ark. [49], bir görüntüdeki nesnelere görsel tanınması için, özellik tabanlı nesne sınıflandırmasını, sürü tabanlı arama mekanizmasıyla birleştiren bir yöntem sunmuştur. Parçacık sürü optimizasyonundaki her bir parçacık, “nesne benzeri” olan bölgeleri arayarak sınıflandırmada kullanılmıştır.

Yapılan literatür araştırması sonucunda, görüntülerde belirginlik tespiti problemlerinde, optimizasyon algoritmalarından yararlanıldığı ve genellikle önerilen yöntemlerin bir ön eğitime veya ön bilgiye ihtiyaç duyduğu görülmüştür. Performans olarak çoğu problemde iyi sonuçlar veren ABC (Yapay Arı Kolonisi) ve FA (Ateş böceği) optimizasyon algoritmalarından, görüntü işlemede belirginlik tespiti problemlerinde yararlanılmadığı tespit edilmiştir. ABC ve FA algoritmalarının, Segmentasyon [50] ve (multilevel thresholding) çoklu eşikleme [51] gibi problemlerin çözümünde kullanılmış olması, belirginlik tespitinde de kullanılabileceğini göstermektedir. Bu çalışmada, ABC ve FA sürü tabanlı metasezgisel optimizasyon algoritmalarının hibrit bir kombinasyonu olan HABCFA optimizasyonu geliştirilmiştir. Geliştirilen yöntem ile olabilecek en iyi arka plan (belirgin olmayan alan) değerinin, görüntüdeki tüm pikseller ziyaret edilmeden, en verimli şekilde bulunması amaçlanmıştır. HABCFA ile bulunan belirgin olmayan değerlerin mevcut görüntüden çıkarılması ile belirgin olan alanın öne çıkarılması sağlanmıştır. HABCFA yöntemi ile belirginlik tespitinin en önemli farkı, herhangi bir ön bilgi veya eğitim aşaması olmaksızın göze çarpan nesnelere bulunabilmesidir.

BÖLÜM 3. MATERYAL VE YÖNTEM

Bu bölümde tez konusuna ait temel kavramlar ve kullanılan yöntemler kısaca açıklanacaktır.

3.1. Sayısal Görüntü İşleme

Görüntü, gerçek yaşamdaki üç boyutlu nesnelere oluşan bir sahnenin basit iki değişkenli bir fonksiyon olarak tanıtılmasıdır [52]. Bu fonksiyondaki iki değişken görüntüdeki bir noktanın konum bilgisini içerir ve renk bilgisi bu fonksiyonun sonucu olan noktanın değeri olarak tanımlanır. Sayısal görüntü işleme, görüntülerin dijital formatları ile ilgili teknik konuları kapsamaktadır. Sayısal görüntü işleme yöntemlerinin amacı, görüntülerden anlamlı bilginin çıkarılabilmesi için, görüntünün iyileştirilmesi ve analizinin yapılmasıdır. Sayısal görüntüler, uygulama ve araştırma sahalarında yaygın olarak kullanılan önemli veri kaynaklarıdır [53].

3.1.1. Temel kavramlar

Sayısallaştırılmış görüntüler, bilgisayar ortamında piksel tabanlı ve vektör tabanlı görüntüler olmak üzere iki farklı şekilde depolanmaktadır. Matematiksel ifadelerle bağlı eğriler, alanlar ve renkler olarak depolama söz konusu ise bu tür görüntü dosyaları vektörel veya vektör tabanlı olarak adlandırılmaktadır. Piksel tabanlı görüntüler, noktalar topluluğu olarak oluşturulan görüntülerdir. Piksel, dijital ekranlarda bir ölçü birimi olarak kullanılmaktadır ve görüntülerde insan gözünün ayırt edebileceği en küçük birimdir. Eğer bir piksel tabanlı görüntünün büyütme oranı arttırılırsa, piksel olarak adlandırılan nokta sayısı da artacağından, dosyanın hafızada kapladığı alan da artmaktadır. Bu nedenle vektör tabanlı görüntülerden farklı olarak piksel tabanlı görüntüler için sahip olunan piksel sayısı ve çözünürlük oldukça önemlidir. Çözünürlük, yatay ve dikey eksenlerdeki sahip olunan piksel


sayısını ifade etmektedir ve görüntünün netliğinin tanımlanmasında kullanılan bir ölçüttür.

3.1.2. Görüntü türleri

Görüntü türleri; ikili (binary), gri seviyeli ve renkli görüntüler olmak üzere üç ana sınıfa ayrılır. İkili görüntülerde piksel değerleri 0 ve 1 ile ifade edilmektedir ve bu görüntüler siyah-beyaz görüntüler olarak da tanımlanmaktadır. Gri seviyeli görüntülerde her bir pikselin değeri [0-255] aralığındadır. Bu tip görüntülerde siyah ve beyaz renkler arasındaki gri geçiş değerleri de bu şekilde insan gözü ile algılanabilir olmaktadır. Gri seviyeli görüntüler, bilgisayar dilinde 8 bit olarak da bilinmektedir. Çünkü bir piksel 256 farklı renk bilgisine sahip olabilmektedir. Bu aralıktaki alt sınır olan 0 siyah, üst sınır olan 255 ise beyaz rengi temsil etmektedir. Renkli görüntüler ise mavi, yeşil ve kırmızı olmak üzere üç renk katmanının birleşmesi sonucu oluşan görüntülerdir. Bu üç farklı renk katmanı ile tüm renkler elde edilebilmektedir. Gri seviyeli görüntülerdeki gibi her bileşen 8 bit ile ifade edilmektedir ve böylece bir renkli görüntü 24 bitlik alan kaplamaktadır. Elektromanyetik spektrumda mavi renk 0.4- 0.5 mm, yeşil renk 0.5-0.6 mm, kırmızı renk ise 0.6-0.7 mm dalga boylarına karşılık gelmektedir. Bu dalga boylarında elde edilmiş üç gri seviyeli görüntü birleştirildiğinde renkli görüntü elde edilmektedir.

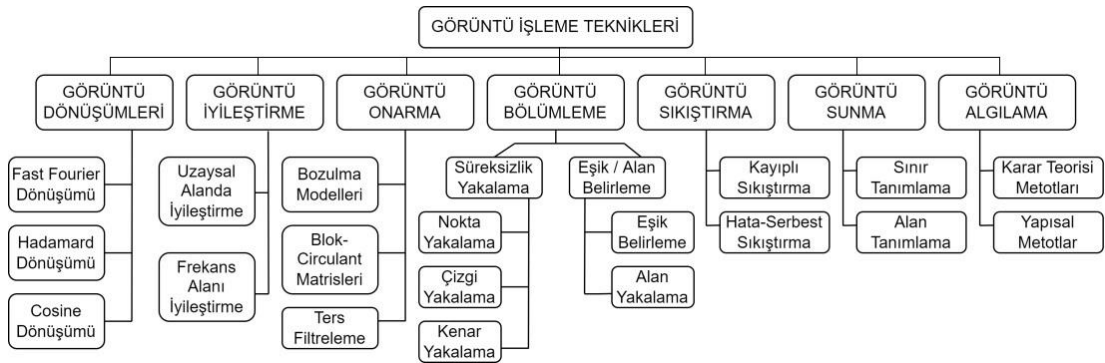
3.1.3. Görüntü işleme teknikleri

Dijital görüntülerden anlamlı bilgi çıkarımı yapabilmek için, sayısal görüntü işleme tekniklerinden yararlanılmaktadır. Sayısal bir görüntü, iki boyutlu bir $f(x,y)$ fonksiyonu olarak tanımlanmaktadır. f fonksiyonunun (x,y) koordinatlarındaki değeri, görüntünün o noktadaki gri seviye veya kontrast (ışık yeğinlik farkı) değeri olarak ifade edilmektedir (Şekil 3.1.).



Şekil 3.1. Dijital görüntü ve piksel değerleri

Sayısal görüntü işleme teknikleri yedi ana başlık altında incelenmektedir (Şekil 3.2.).



Şekil 3.2. Görüntü işleme teknikleri şeması [52]

Analog görüntülerin bilgisayar ile işlenebilmesi için dijital yani sayısal görüntüye dönüştürülmesi gerekmektedir. Sayısallaştırma için, görüntüde konumsal örnekleme (sampling) ve renk için ise nicemleme (kuantalama- quantization) yapılmaktadır. Temeli bu dönüşümlere dayanan görüntü dönüşümleri Şekil 3.2.'de görüldüğü gibi üç alt alanda incelenmektedir. Fast Fourier dönüşümünün temelinde de Fourier analizi bulunmaktadır. Fourier analizi, periyodik olayların incelenmesinde kullanılan periyodik bir fonksiyondur ve pek çok alanda yaygın olarak kullanılmaktadır. Fourier dönüşümü, bir sinyalin içindeki bilgilerin çıkarılması için kullanılan önemli bir yöntemdir. Bir sinyal Fourier dönüşümü ile birlikte farklı genlik, frekans ve fazlarda kosinüs ve sinüs bileşenlerinin toplamı olarak ifade edilebilir. Böylece her bir bileşenin bilgisayarla işlenmesi kolaylaşır. Sinyaller ayrık zamanlı (dijital) veya sürekli (analog) olmak üzere iki farklı türde bulunabilirler. Ayrık Fourier dönüşümünü (Discrete Fourier Transform - DFT) hızlı bir şekilde kullanmak için geliştirilen yöntem Fast Fourier Dönüşümü (FFD) olarak adlandırılmaktadır. Hadamard dönüşüm FFD ile benzerdir. Ancak hız açısından daha avantajlıdır. Hadamard dönüşümünde sadece reel sayılarla toplama ve çıkarma işlemleri

gerçekleştirilmektedir. Görüntünün uzamsal temsilinden ziyade, görüntünün Hadamard dönüşümünü iletmek, kanal hatalarına potansiyel bir tolerans ve azaltılmış bant genişliği iletimi olasılığı sağlamaktadır [54]. Ayrık kosinüs dönüşümü (Discrete Cosine Transform – DCT), farklı frekanslardaki kosinüs fonksiyonlarının toplamı cinsinden sonlu bir veri noktaları dizisini ifade etmektedir. DCT ve DFT arasındaki fark, DCT'nin sadece kosinüs fonksiyonlarını kullanması, DFT'nin ise hem kosinüs hem de sinüs fonksiyonlarını kullanmasıdır.

Görüntü iyileştirme teknikleri, görüntünün görsel olarak daha iyi algılanmasını sağlayan işlemlerdir. Bu teknikler, kontrast ve parlaklık ayarlamaları, kenar iyileştirme, histogram eşitleme gibi teknikleri kapsamaktadır ve görüntülerin niteliğini optimum bir şekilde iyileştirmeyi amaçlamaktadır. Doğrudan pikseller üzerinde çalışan teknikler uzaysal alan (domain) iyileştirme teknikleri olarak adlandırılmaktadır. Basit anlaşılır ve karmaşıklığı düşük olan tekniklerdir. Ancak frekans alanı iyileştirme yöntemlerinin kullanılabilmesi için görüntü öncelikle frekans alanına aktarılmalıdır. Bu aktarılma işlemi Fourier dönüşümü ile gerçekleştirilir ve dönüşüm ile iyileştirme tamamlandıktan sonra ters Fourier dönüşümü ile sonuç görüntü elde edilir. Bu dönüşüm sonucunda, görüntüyü oluşturan frekans bileşenleri birbirinden daha iyi ayırt edilebildiği için uzaysal alanda yapılması zor işlemler, frekans alanında daha kolay yapılabilir hale gelmektedir.

Görüntü onarma tekniklerinin amacı, gürültüden etkilenmiş veya bozulmuş görüntülerin, orjinal-bozulmamış durumlarını yeniden elde edebilmektir.

Bir görüntüdeki öğelerin veya nesnelerin gruplandırılması ve sınıflandırılması amacı ile görüntü bölümlenme teknikleri kullanılmaktadır. Bu gruplamalar sayesinde, görüntüdeki nesne tanıma, kenar bulma gibi işlemler oldukça kolaylaşmaktadır.

Sayısal görüntülerin çözünürlüğü ve kalitesi, teknolojinin ilerlemesi ile birlikte günümüzde oldukça artmıştır. Bu kavramların gelişmesi daha nitelikli bilgi çıkarımı için olumlu bir gelişme olsa da bilgisayar ortamındaki depolama alanları için daha

fazla hafızaya ihtiyaç duyulmasına sebep olmuştur. Görüntü sıkıştırma teknikleri ile birlikte ihtiyaç duyulan bellek miktarının azaltılması amaçlanmaktadır.

Görüntü sunma teknikleri, görüntülerin içerdiği nesne veya elemanların belirginleştirilmesini amaçlamaktadır. Bu teknikler sınır tanımlama ve alan tanımlama olarak iki ana grupta incelenmektedir.

Görüntü algılama teknikleri, yüksek seviyeli görüntü işleme teknikleri arasında bulunmaktadır. Bu tekniklerde, çeşitli karar verme yöntemleri (yapay zeka algoritmaları gibi) kullanılmaktadır. Böylece görüntülerde tespit edilen nesnelere (plaka, yüz, insan, harf vb.) ile ilgili detaylı bilgilerin algılanması sağlanabilmektedir.

3.2. Sayısal Görüntülerde Belirginlik Tespiti

İnsan görme sistemi, dikkat çeken veya genele göre farklılık gösteren alanlara yönelme ve odaklanma eğilimindedir. Bu görsel dikkat çekme olgusundan ilham alarak, göz sabitlemesini benzetmeye çalışan görsel belirginlik modelleri geliştirilmiştir. Ancak insanın sahip olduğu görsel dikkat mekanizması, psikolojik ve nörolojik etkenler de dikkate alındığında, modellenmesi oldukça zor olan bir kavram ortaya çıkmaktadır. Bu kavram belirginlik tespiti (saliency detection) olarak tanımlanmaktadır. Amaç, insan görme sisteminin nasıl çalıştığını ve bir görüntünün dikkat çeken en önemli ve ilginç kısmını bulmaktır.

Görüntülerdeki belirgin bölgelerin tespit edilmesinde, arka planın desenli veya karmaşık olması, dikkat çeken nesneye veya alana ait bazı kısımların görüntünün kenar bölgelerinde de konumlanabilmesi, belirgin nesne ile arka plan arasında düşük renk kontrastının bulunması gibi sorunlar ile karşılaşılabilir. Son yıllarda belirgin alanları tespit edebilmek için bu gibi sorunların çözülmesini amaçlayan çeşitli çalışmalar yapılmaktadır. Göze çarpan yani belirgin olan bir alan genellikle aşağıdaki özellikleri içermektedir:

- Belirgin nesnenin çevresindeki arka plana kıyasla yüksek karşıtlık özelliği vardır. Özellikle görüntüdeki renk dağılımı nadirdir.
- Belirgin nesne, kontrast değeri için daha uzak olan bölgelere değil, daha yakın bölgelere göre üstünlük sağlamaktadır.
- Belirgin nesne genellikle görüntünün merkezinde bulunur. İnsan dikkati öncelikle merkez odaklıdır.
- Belirgin nesne, arka plan nesnelere kıyasla, daha küçük bir alanda görülür ve daha kompakt bir yer işgal eder.
- Belirgin nesne, düzgün bir renk dağılımı sergiler.

Belirgin alanların bu özelliklerine ve karşılaşılabilecek problemlere göre belirginlik tespiti yöntemleri geliştirilmektedir. Görüntülerde belirginlik tespiti probleminin daha efektif bir şekilde çözülmesi ile birlikte, bilgisayarlı görme alanındaki pek çok teknolojik gelişme olumlu yönde etkilenecektir. Çünkü belirginlik tespitinde, insan gözünün en iyi şekilde taklit edilmesi ana amaçtır. Görüntü işleme problemlerinde, en iyi çözümün arandığı arama uzayının büyük olması verimliliği düşürebilmekte ve arama sürelerini uzatabilmektedir. İnsan görme sisteminin en önemli özelliklerinden birisi olan belirli bir noktaya odaklanma yeteneğinin modellenmesi ile birlikte, dikkat çekmeyen alanlar problemlerin çözüm uzayından çıkarılabilir ve çözüme ulaşma verimliliği artırılabilir.

3.3. Optimizasyon ve Optimizasyon Teknikleri

Optimizasyon, hedeflenen amacın maksimum ya da minimum olabilmesi için gereken en iyi çözümün bulunması işlemidir. Deterministik yöntemlerle çözümü zor olan problemlerin optimizasyon yöntemleri ile çözülebilmesi, bu tekniklerin hemen hemen tüm bilim dallarında kullanılabilir olmasını sağlamıştır.

Bir optimizasyon probleminin temel bileşenleri, en az bir amaç fonksiyonunun optimize edilmesi, eşitlik kısıtları ve eşitsizlik kısıtlarıdır. Amaç fonksiyonu, optimize edilecek olan bir fonksiyondur. Bu fonksiyon için bulunacak olan optimum değer, değerleri güncellenen parametrelere yani tasarım değişkenlerine bağlıdır. Bu

parametrelerin hangi aralıkta değer alacağı tanımlı olmalıdır. Bu aralıklar yani sınırlamalar, kısıtlayıcılar olarak tanımlanmaktadır.

Bir optimizasyon probleminin çözülmesi için aşağıdaki adımlar takip edilmelidir:

Adım 1: Temel konfigürasyon oluşturulmalı.


Adım 2: Tasarım değişkenleri yani parametreler tanımlanmalı.

Adım 3: Amaç fonksiyonu tanımlanmalı.

Adım 4: Kısıtlayıcılar tanımlanmalı.

Adım 5: Uygun optimizasyon metodu seçilmeli ve uygulanmalı.

Bütün optimizasyon problemlerinin çözümü için tek bir yöntem yoktur. Bu nedenle farklı türdeki optimizasyon problemleri için farklı optimizasyon metotları geliştirilmiştir (Şekil 3.3.).



Şekil 3.3. Optimizasyon algoritmaları grupları

Eğer problemde sadece bir parametre bulunuyorsa, optimizasyon problemi bir parametrelidir. Birden çok parametre bulunması durumunda ise problem çok parametrelili optimizasyon problemi olarak tanımlanmaktadır. Statik optimizasyon problemlerinde, optimizasyon zamandan bağımsızdır. Dinamik optimizasyon problemlerinde ise zamana göre çıkış üretilmektedir. Süreklilik ve ayrıklık açısından optimizasyon problemlerinde, sürekli parametrelerin sonsuz, ayrık parametrelerin sınırlı değerler olması söz konusudur. Örneğin; bir $f(x)$ fonksiyonunda minimum değeri bulmaya çalışmak, sürekli bir optimizasyon problemidir. Sınırsız (kısıtsız) optimizasyon problemlerinde parametreler herhangi bir değerde olabilmektedir. Ancak sınırlı (kısıtlı) optimizasyon problemlerinde parametrelere sadece belirli

değerler verilebilmektedir. Rastgele optimizasyon yaklaşımında, parametrelerin optimum değerini bulmak için olasılık hesaplamalarından yararlanılmaktadır. Rastgele araştırma, minimum araştırma yaklaşımına göre global minimumu bulmada daha başarılıdır ancak daha yavaştır. Çünkü minimum araştırma optimizasyon problemlerinde, parametrelere başlangıç değerleri verilir ve bu değerlere göre minimum uygunluk değeri araştırılır.

Optimizasyon problemlerinin sınıflandırılmasında amaç fonksiyonlarının yapısı da önemlidir. Problem tek amaç için en iyi sonucu bulma çabasını içeriyorsa tek amaçlı, birden fazla amaç için aynı anda en iyi sonucu elde etmeyi amaçlıyorsa çok amaçlı problem olarak tanımlanır. Amaç fonksiyonuna göre tek-çok amaçlı problem ve fonksiyonun derecesine göre doğrusal (linear) – doğrusal olmayan (nonlinear) problem olarak sınıflandırmalar söz konusudur.

Optimizasyon metotları genel olarak deterministik veya istatistiksel olma durumuna göre sınıflandırılabilir. Deterministik metotlar, yerel minimum veya maksimuma yakınsayan metotlardır. Türevsel yaklaşımlar deterministik metotlara örnek olarak verilebilir. İstatistiksel metotlar ise, global minimum veya maksimumu bulabilmek için rastgele sayılar ve bazı yöntemler kullanmaktadır.

Çözümüne ulaşmak için kullanılan bilgi dikkate alındığında, optimizasyon metotları zero order, 1st order ve 2nd order olmak üzere üç sınıfta incelenmektedir. Zero order metotlarda fonksiyonun değeri, 1st order metotlarda fonksiyonun birinci türevi (gradyenti) ve 2nd order metotlarda ise fonksiyonun ikinci türevi kullanılmaktadır. Golden section, bisection, polynomial, sezgisel-heuristic algoritmalar zero order sınıfına, steepest descent ve gradient projection 1st order sınıfına, newton metotları ise 2nd order sınıfına giren optimizasyon yöntemlerinden bazılarıdır.

Çözüm mantığı açısından optimizasyon algoritmaları incelendiğinde, direkt (steepest descent, newton, gradient projection), yaklaşık (sequential linear programming, sequential quadratic programming) ve sezgisel-heuristic (simulated annealing, genetik algoritma vb.) olmak üzere üç sınıf bulunmaktadır.

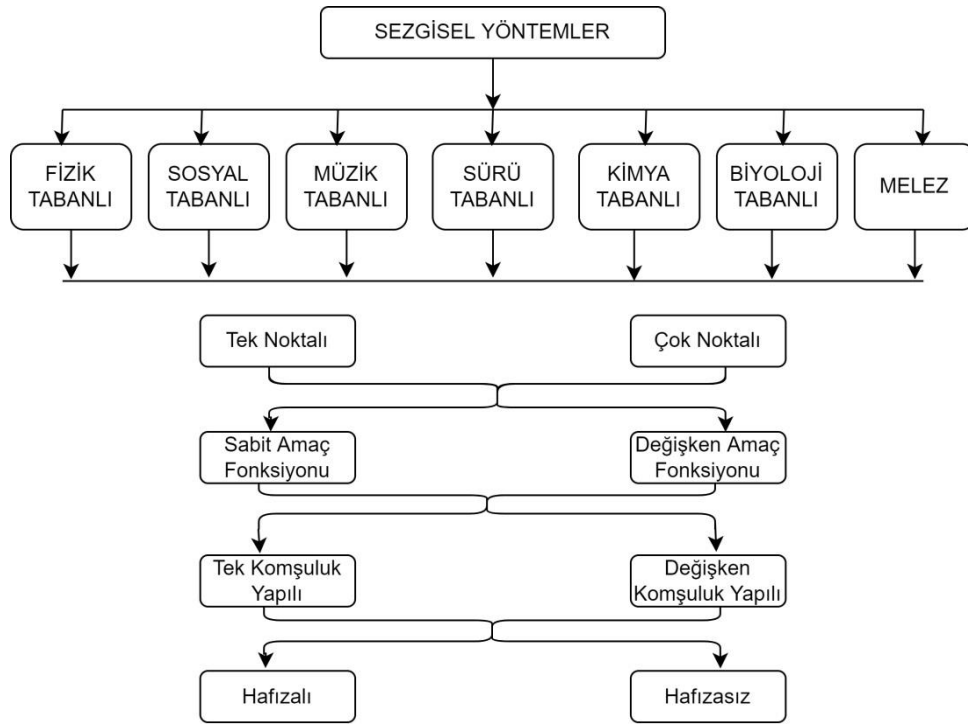
Optimizasyon algoritmalarında, optimum sonuca ulaşmak için aşağıdaki arama yaklaşımları yaygın olarak kullanılır:

- Yorucu (exhaustive)
- Rastgele (random)
- Açgözlü (greedy)
- Tepe tırmanma (hill climbing)
- Sezgisel (heuristic)
- Belirleyici (deterministic)
- İhtimalci (stochastic)

Yorucu aramada başlangıç veri kümesindeki tüm kombinasyonlar test edilir ve bu şekilde optimum çözüm arayışı yapılır. Rastgele aramada veri kümesinde rastgele üretilen kombinasyonlar test edilir ve kabul edilebilir bir çözüm bulunana kadar arama devam eder. Açgözlü arama ile rastgele arama benzer yaklaşımlardır. Rastgele aramadan farklı olarak bulunan iyi çözüm saklanır ve daha iyi bir çözüm arayışı saklanan çözüm etrafında devam eder. Bu durum global optimumu bulmak için dezavantajlıdır çünkü bazı durumlarda global optimum çözüm kötü olarak nitelendirilebilecek çözümlerin yakınında da bulunabilmektedir. Tepe tırmanma arama yaklaşımı bu dezavantaja çözüm üretir. Arayış sırasında bulunan çözümler, iyiye giderken daha sonra kötüye gitmeye başlarsa, bu noktalar sırt noktası olarak adlandırılır. Kötüden iyiye bir gidiş söz konusu ise bu noktalar da dip noktası olarak tanımlanır. Kısacası türev alınarak bulunan sonuçlar, bu şekilde aranarak ve denenerek bulunmaktadır. Deterministik yaklaşımda, elde edilen çözümlere göre bir sonraki adımda elde edilecek çözümler belirlenir. İhtimalci stratejide ise arama aşamasında iken bir sonraki adım olasılık tabanlı seçimlere dayalı bir şekilde önceden tahmin edilir.

Sezgisel yaklaşımlar, akıllı tahminlere dayalı bir şekilde optimum çözümü arayan yöntemlerdir (Şekil 3.4.). Arama uzayı çok geniş olan problemlerde tercih edilen yaklaşımlardır. Çözümün aranmasını sınırlayan bir bulguya dayalı bir arayış gerçekleşmektedir. Karınca Kolonisi optimizasyon algoritmasındaki feromon, Ateş

böceği optimizasyonundaki parlaklık kavramları bu tip bir bulguya örnek olarak verilebilir.



Şekil 3.4. Sezgisel yöntemler [55]

Modern sezgisel optimizasyon algoritmalarının avantajı, matematiksel ön hesaplama gerektirmemelerinden dolayı kolaylıkla uygulanabilmeleridir. Sezgisel algoritmalar sürü esaslı olan yaklaşımlarda, genel olarak doğadaki canlıların davranışlarını modelleyen yaklaşımlardır. Optimum çözümün aranması süreci bir sürüye bağlı olarak gerçekleştirilmektedir. Sürüden edinilen bilgilere göre en iyi ve kaliteli çözümün bulunması amaçlanmaktadır. Sürü, birbirleriyle etkileşim veya iletişim içerisinde olan bireyler anlamına gelmektedir. Sürü içerisinde N adet temsilci birey, bir amacı gerçekleştirmek ve hedefe ulaşmak için birlikte çalışmaktadır. Bu davranış biçimi ise karşımıza sürü zekâsı kavramı olarak çıkmaktadır [55]. Millonas bir sürüde sürü zekâsı kavramından bahsedebilmek için sürünün sağlaması gereken beş temel özelliğin sağlanması gerektiğini vurgulamaktadır [56]:

- Sürü, temel uzay ve zaman hesaplamalarını yapabilmelidir (yakınlık prensibi).
- Yiyeceklerin kalitesi veya yerin güvenliği gibi çevresel etkenleri değerlendirebilmeli ve tepki verebilmelidir (kalite prensibi).

- Tüm kaynaklarını dar boğazlarda kullanmamalı ve kaynakları birden fazla noktaya dağıtabilmelidir (dağılım prensibi).
- Çevrede oluşan her bir değişimde veya dalgalanmada çalışma şeklini değiştirmemeli ve kararlılığını koruyabilmelidir (kararlılık prensibi).
- Enerji tüketimine degecek maliyette ise çalışma şeklini değiştirebilmelidir (uyarlanabilirlik prensibi).

Bu çalışmada, doğadaki canlıların davranışlarından esinlenilerek sürü zekasına dayalı optimizasyon algoritmalarından olan ABC ve FA optimizasyon algoritmaları kullanılarak hibrit bir yaklaşım geliştirilmiştir.


3.3.1. Yapay arı kolonisi optimizasyonu

Sürü zekasına dayalı olan optimizasyon algoritmalarından olan Yapay Arı Kolonisi optimizasyon algoritması, 2005 yılında Derviş Karaboğa tarafından arıların doğadaki yiyecek arama davranışlarından esinlenilerek modellenmiştir [3].

Bir arı kolonisinde arılar arasında görev paylaşımı bulunmaktadır. Görev paylaşımı ve kendi kendine organize olabilme yeteneği sürü zekasının en önemli özelliklerindedir. Yapay arı kolonisi algoritmasındaki görev paylaşımına göre koloni üç gruptan oluşmaktadır:

- Çalışan (işçi- görevli) arılar
- Gözcü arılar
- Kaşif arılar

Görevli arılar, önceden edinilen kaynak bilgisine göre kaynaklardan kovana bilgi getirmekten sorumlu olan arılardır. Getirilen bu bilgi arı dansı (bee dance) olarak adlandırılan davranış biçimi ile birlikte kovandaki gözcü arılara aktarılmaktadır. Bu dans sayesinde, yiyecek kaynağına ait kovana göre uzaklık ve güneşe göre konum bilgileri iletilebilmektedir (Şekil 3.5.).



Şekil 3.5. Arı dansı ve gözcü arılar ile bilgi paylaşımı [56]

Görevli arılardan gelen bilgilere göre, gözcü arılar gözlem yapar ve yiyecek kaynaklarına yönelirler. Kaynakların uygunluk değeri ise nektar miktarı kavramına göre belirlenir. Bir yiyecek kaynağının görevli arı tarafından seçilme olasılığı rulet tekerleği yöntemine göre belirlenmektedir. Bu yöntemde daha iyi uygunluk değerine sahip olan kaynağın seçilme olasılığı daha yüksek olmaktadır.

Görevli arılar konumlandıkları kaynakları geliştirme çabası içerisindedir. Eğer mevcut kaynağın etrafında daha iyi bir kaynak varsa, mevcut kaynak terk edilir ve yeni kaynaktaki konumlanma gerçekleşir. Bu durum terk edilen kaynağın geliştirilebilir olduğunu göstermektedir. Bir kaynağın geliştirilememesi durumunda, daha iyi bir kaynak arayışı aşamasının tekrar sayısını sınırlandırmak için bir limit değeri tanımlanmaktadır. Aksi takdirde bu arayış sonsuza kadar devam edecektir ve çözüme ulaşma süresinde uzamaya neden olacaktır. Eğer bir kaynak için daha iyi bir kaynak arama sayısı, limit değerine ulaşmış ise o kaynağın terk edilmesi ve tekrar üzerine konumlanılmaması gerekmektedir. Çünkü bu kaynak iyileştirilememiş bir kaynaktır ve çevresinde de iyi bir kaynak bulunmamaktadır. Kaynağı terk etmek durumunda kalan görevli arının rolü kaşif arı olarak değişir. Kaşif arılar çözüm uzayında rastgele bir kaynağa konumlanan arılardır. Bu optimizasyon algoritmasında sonlandırma kriteri maksimum çevrim sayısı olabileceği gibi kaşif arı sayısının da maksimum ulaşabileceği değer sonlandırma kriteri olarak kullanılabilir.


A ve B kaynakları iki ziyaret edilen kaynak olarak düşünüldüğünde, kaynak araştırmasının başlangıcında bir görevli arı için kaynakların yerleri bilinmemektedir.

Bu arı için iki durum vardır (Şekil 3.6.) [58]:

1. Kaşif arı olmak. Şekil 3.6.'da S olarak gösterilmektedir.
2. Gözcü arı olmak, kuyruk dansı izlemek ve izlediği kaynağa yönelmek. Şekil 3.6.'da R ile gösterilmektedir.

İşçi arı kaynaktan döndükten sonra üç seçenek vardır (Şekil 3.6.) [58]:

1. Gittiği kaynağı terk eder ve bağımsız işçi arı olur. Şekil 3.6.'da UF ile gösterilmektedir.
2. Gittiği kaynağa dönmeden önce dans eder ve diğer arılara bilgi aktarımında bulunur. Şekil 3.6.'da EF1 ile gösterilmektedir.
3. Diğer arılara herhangi bir bilgi aktarımında bulunmaz ve aynı kaynağa yönelir. Şekil 3.6.'da EF2 olarak gösterilmektedir.



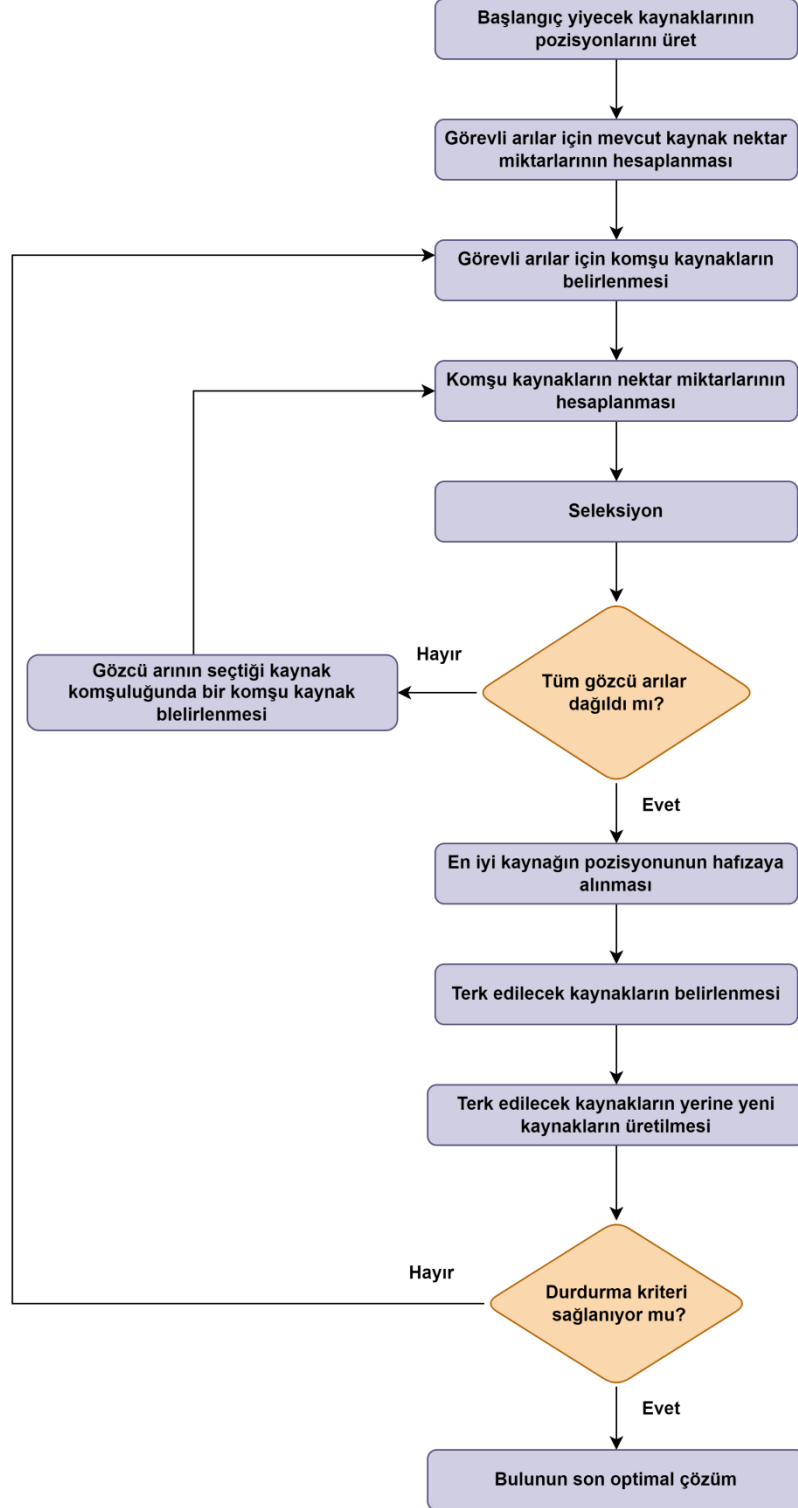
Şekil 3.6. Arıların yiyecek arama döngüsü [58]

Temel yapay arı kolonisi oldukça az kontrol parametresine sahiptir. Bu parametreler:

1. Maksimum çevrim sayısı,
2. Koloni büyüklüğü,

3. Limit

Yapay arı kolonisi optimizasyon algoritması için temel adımların akış diyagramı Şekil 3.7.'de verilmiştir.



Şekil 3.7. ABC akış Diyagramı

Yapay arı kolonisi algoritmasının ayrıntılı olarak çalışma adımları aşağıda verilmiştir:

Adım 1. Çözümlere başlangıç değeri atanması

Denklem 3.1 ile X_{ij} , $i=1, \dots, N$, $j=1, \dots, M$ olarak tanımlanan çözümlere başlangıç değeri atanır, geliştirilemeye sayacı ($hata_i$) sıfırlanır ve uygunluk değeri hesaplanır. X_{ij} arının konumlanmış olduğu ilk kaynaktır. N , yiyecek kaynağı sayısı ve M ise optimize edilecek parametre sayısıdır. Arama uzayı içerisindeki rastgele bir kaynağa konumlanma Denklem 3.1 ile sağlanmaktadır.

$$X_{ij} = X_j^{min} + rand(0,1)(X_j^{maks} - X_j^{min}) \quad (3.1)$$

Adım 2. Görevli arılar için yeni bir komşu kaynak üretilmesi ve uygunluk değerlerinin hesaplanması

$i=1$ den N 'ye kadar Denklem 3.2 ile X_i çözümünün görevli arısı için yeni bir kaynak üretilmesi sağlanır. V_{ij} X_{ij} 'nin komşuluğundaki yeni kaynaktır. Φ $[-1,1]$ aralığında rastgele bir değerdir ve komşuluktaki yeni kaynak bulunması işleminin rastgele yapılmasını sağlamaktadır.

$$V_{ij} = X_{ij} + \varphi_{ij}(X_{ij} - X_{kj}) \quad (3.2)$$

V_{ij} komşu kaynağının daha önceden belirlenen alt ve üst sınırları aşmaması gerekmektedir. Bu sınırların aşılması durumunda Denklem 3.3 ile j . parametreye ait alt veya üst sınır değerleri atanmaktadır. Böylece komşu kaynak çözümünün, mevcut kaynağın komşuluk sınırları içerisinde kalması sağlanmaktadır.

$$V_{ij} = \begin{cases} X_j^{min}, & V_{ij} < X_j^{min} \\ V_{ij}, & X_j^{min} \leq V_{ij} \leq X_j^{maks} \\ X_j^{maks}, & V_{ij} > X_j^{maks} \end{cases} \quad (3.3)$$

f_i , i . kaynağın maliyet değeridir ve bir maliyet fonksiyonu ile elde edilir. Maliyet fonksiyonu, probleme ait çözüm adayının çözüm değerini üretmek için kullanılan bir fonksiyondur. Elde edilen maliyet değerine göre çözümün uygun olup olmadığı F (fitness- uygunluk) değerine göre belirlenmektedir (Denklem 3.4). Uygunluk değeri, hem mevcut kaynak (X_i) hem de o kaynağın komşuları (V_i) için, kaynakların kıyaslanması amacıyla hesaplanmaktadır. Kaynaklar ve komşuları arasında bir seçim işlemi uygulanır ve daha iyi olan kaynak seçilir. Eğer X_i geliştirilemeyen bir kaynak ise yani V_i , X_i 'den daha kötü bir kaynak ise X_i için geliştirememeye sayacı yani $hata_i$ bir artırılmaktadır.

$$F = \begin{cases} \frac{1}{1+f_i}, & f_i \geq 0 \\ 1 + abs(f_i), & f_i < 0 \end{cases} \quad (3.4)$$

Adım 3. Kaynakların uygunluk değerlerine bağlı olasılık değerlerinin hesaplanması Denklem 3.5 kullanılarak, gözcü arıların seçim davranışını başlatabilmesi için gerekli olan uygunluk değerlerine bağlı olasılık değerleri hesaplanmaktadır.

$$P_i = \frac{F}{\sum_{j=1}^N F_j} \quad (3.5)$$

Adım 4. Rulet tekerleği (çemberi) yöntemine göre seçim

Rulet tekerleği yönteminde bir çember alt alanlara (dilimlere) ayrılmaktadır. Bu alanlar, popülasyondaki (sürüdeki) bireylerin konumlandığı kaynakları temsil etmektedir. Denklem 3.5 ile bulunan olasılık değerleri, çember üzerinde yüzde olarak gösterilmektedir. Rulet tekerleğinin her çevrilmesinde, olasılık değeri yüksek olan yani yüzdelik dilimi fazla olan kaynağın seçilme ihtimali de daha yüksek olmaktadır. Rulet tekerleğine göre seçim aşamasında her bir kaynak için, $[0,1]$ aralığında üretilen P_i değeri, rastgele üretilen bir değerden büyükse, gözcü arı için Denklem 3.3 ile yeni bir kaynak üretilir. Üretilen V_i ile X_i arasındaki seçim işlemi ardından daha iyi olan kaynak seçilir. X_i çözümü geliştirilememiş ise $hata_i = hata_i + 1$, geliştirilebilmiş ise $hata_i = 0$ olarak belirlenir. Bu adım, tüm gözcü arılar yiyecek kaynaklarında konumlandırılıncaya kadar tekrar etmektedir.

Adım 5. Mevcut kaynak tükendiğinde yeni kaynak belirleme

Konumlanılan mevcut kaynağın tükenip tükenmediği kontrol edilir. Eğer tükenmişse Denklem 3.2 ile rastgele yeni bir çözümle değiştirilir.

Adım 6. Yerel en iyi çözümün kaydedilmesi

Bulunan en iyi çözüm hafızada tutulur.

Adım 7. Arama süreci durdurma şartının kontrolü

Sonlandırma koşulları sağlanmadığı sürece Adım 2'den Adım 6'ya kadar devam edilir.

3.3.2. Ateş böceği optimizasyonu

Sürü zekasına dayalı bir optimizasyon algoritması olan Ateş böceği optimizasyon algoritması (Firefly Algorithm - FA), 2009'da Yang tarafından ateş böceklerinin parlaklık değerlerine göre birbirlerine yönelme hareketlerinden esinlenilerek geliştirilmiştir [4].

Ateş böcekleri tek cins (unisex) yapıdadır ve parlaklıklarına göre birbirlerini cezbederek hareket ederler. Kolonideki bireylerin çekicilikleri parlaklıkları ile doğru orantılıdır ancak mesafe kavramı ile ters orantılıdır. Çünkü iki birey arasındaki mesafe arttıkça, parlaklık kavramının gücü ve hissedilebilirliği azalmaktadır. Bu durum mesafe arttıkça çekiciliğin azalmasına neden olmaktadır. Bir ateş böceği kendisinden daha parlak bir ateş böceği gördüğünde ona doğru hareket etmektedir. Daha parlak bir ateş böceğinin görülmemesi durumunda ise, bireyler resgele hareket etmektedirler.

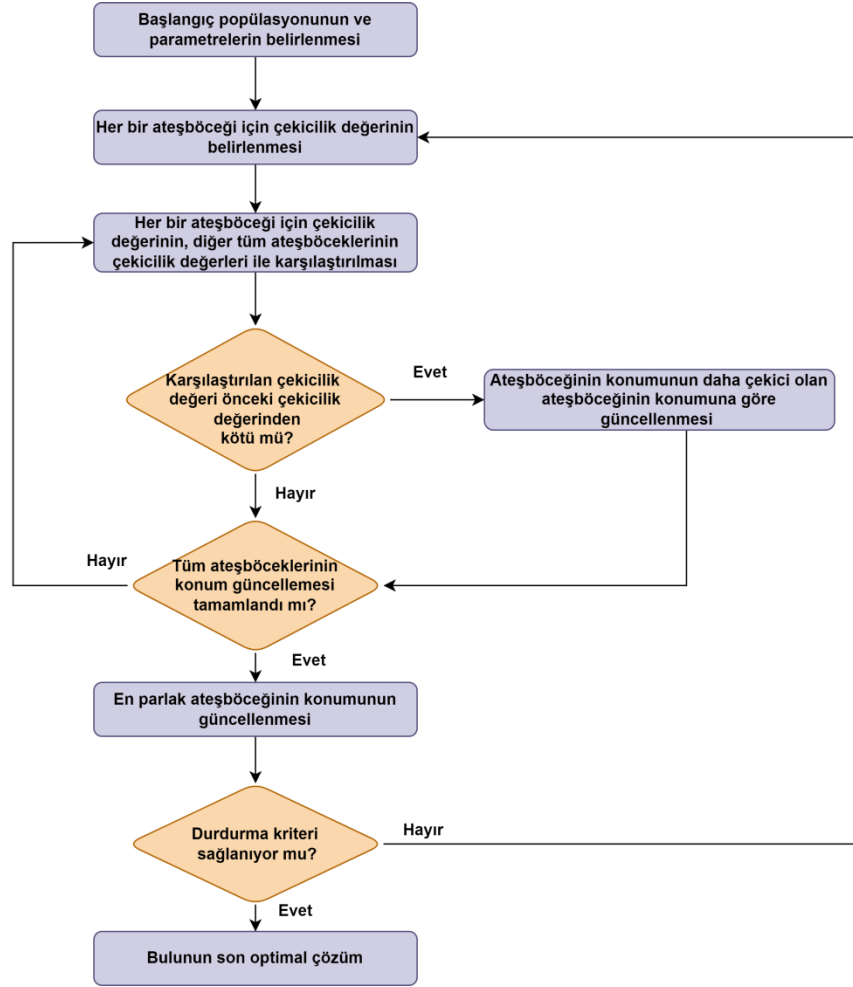
Sürüdeki bireylerin parlaklıkları ve parlaklık dereceleri uygunluk fonksiyonu ile ilişkilidir. Işık yoğunluğu ve çekiciliğin formülasyonunun yapılması ateş böceği algoritmasının sahip olduğu iki önemli durumdur. Şekil 3.8.'de, ateş böceği optimizasyon algoritmasına ait temel adımların akış diyagramı verilmiştir.

Ateş böceği optimizasyon algoritmasında I , ışık yoğunluğu ve r iki birey arasındaki uzaklığı ifade etmektedir. Mesafe arttıkça, I_s ile tanımlanan ışık kaynağının yoğunluğu da azalmaktadır. Denklem 3.6, ışık yoğunluk formülünü göstermektedir.

$$I = \frac{I_s}{r^2} \quad (3.6)$$

Işık yoğunluğu kriterinde, iki birey arasındaki uzaklık kavramının yanı sıra havanın ışık emilimi de bir etken olmaktadır. Denklem 3.7'de y , havanın ışık emilim katsayısını ifade etmektedir. Ayrıca $r=0$ olduğu durumlarda Denklem 3.6'a alternatif bir formül olan Denklem 3.7'yi tercih etmek gerekmektedir. Hava ışık emilim katsayısı teorik olarak $[0, +\infty]$ aralığında herhangi bir değer olabilmektedir. Ancak genel olarak bu değer 1 olarak ele alınmaktadır. Bu denklemde I_0 başlangıç ışık yoğunluğunu temsil etmektedir.

$$I = I_0 \times e^{-yr} \quad (3.7)$$



Şekil 3.8. FA Akış Diyagramı

Ateş böceği algoritmasında ışık yoğunluğu kavramı ile çekicilik kavramları doğru orantılı kavramlardır. Kolonideki bir bireyin çekiciliği Denklem 3.8’de β ile ifade edilmektedir. β_0 , $r=0$ iken bir ateş böceğinin parlaklığıdır ve üstel işlemler karmaşıklığa neden olabileceğinden alternatif olarak Denklem 3.9 da kullanılabilir.

$$\beta = \beta_0 \times e^{-yr^2} \quad (3.8)$$

$$\beta = \frac{\beta_0}{1+y \times r^2} \quad (3.9)$$

Kolonideki x_i bireyinin daha çekici olan x_j bireyine doğru yönelme hareketi Denklem 3.10 ile hesaplanmaktadır. Bu denklemde α , rastlantısallık parametresi ve $[0,1]$ aralığında değer alabilen ε değişkeni rastgele bir vektör olarak kullanılmaktadır.

$$x_i(t+1) = x_i(t) + \beta_0 \times e^{-\gamma r_{ij}^2} \times (x_j(t) - x_i(t)) + \alpha \times \varepsilon_i(t) \quad (3.10)$$

İki birey arasındaki mesafe ise Denklem 3.11'e göre hesaplanmaktadır. Bu denklemde k değişkeni i . veya j . bireylerin içerisinde bulunduğu boyutu ve D değişkeni kaç boyuta sahip olduğunu göstermektedir.

$$r_{ij} = \sqrt{\sum_{k=1}^D (x_{ik} - x_{jk})^2} \quad (3.11)$$

BÖLÜM 4. GELİŞTİRİLEN HİBRİT YAPAY ARI KOLONİSİ - ATEŞ BÖCEĞİ OPTİMİZASYON MODELİ ve PERFORMANS ANALİZİ

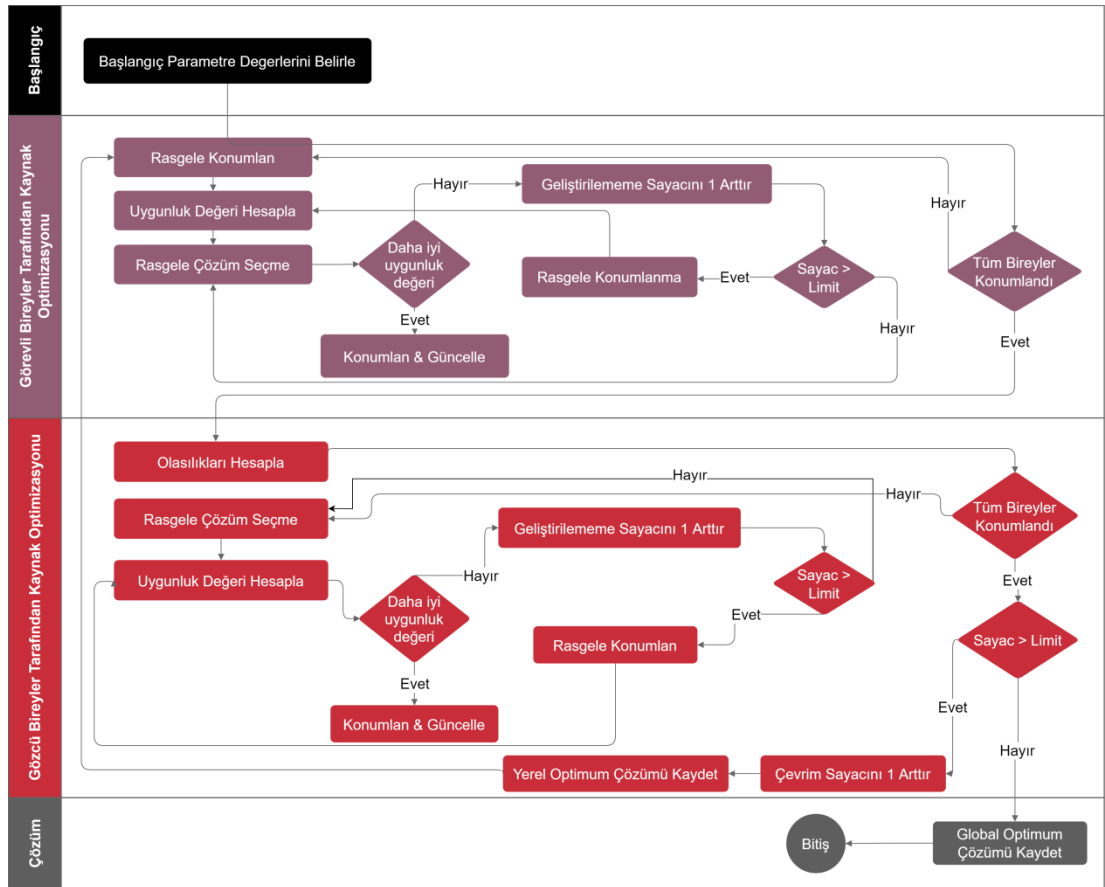
Optimizasyon metotları, verimli arama yöntemleri kullanarak en doğru sonuca en verimli şekilde ulaşmayı amaçlamaktadır. Bu bölümde, arama aşamasının verimliliğini arttırmak için ABC ve FA optimizasyon algoritmalarından yararlanılarak geliştirilen hibrit HABCFA yönteminin çalışması/aşamaları açıklanmıştır.

4.1. HABCFA Optimizasyonu

Meta-sezgisel ABC ve FA optimizasyon algoritmalarında, arama uzayındaki olası çözümler, popülasyonda/sürüde bulunan bireyler tarafından değerlendirilmektedir. ABC algoritması, popülasyondaki arıların yiyecek kaynaklarının kalitesine/nektar miktarına göre kaynaklara yönelmesi ve böylece en iyi yiyecek kaynağının bulunması davranışını modellemektedir. FA algoritması ise ateş böceklerinin, popülasyon içerisinde kendilerine göre daha çekici/parlak ateş böceğine doğru hareket etmesini ve böylece en parlak ateş böceğinin bulunması davranışını simule edilmektedir.

Geliştirilen hibrit yöntemde, ABC algoritmasındaki yiyecek kaynaklarının kalite özelliği ve FA algoritmasındaki ateş böceklerinin çekicilik özelliği, olası bir çözümün yeterliliğini nitelediğinden eşdeğer kavramlar olarak ele alınmaktadır. HABCFA yönteminde, popülasyondaki bireyler, önce ateş böcekleri gibi davranarak daha parlak olan bireye yönelmektedir. Daha sonra arı davranışı sergileyerek, çevrelerinde daha kaliteli olan bir kaynak olup olmadığını arayışını gerçekleştirmektedir. Eğer daha iyi bir kaynak varsa, bireyler o kaynağa doğru hareket etmektedir ve bu şekilde her iki optimizasyon algoritmasının da avantajlarından yararlanılmaktadır.

HABCFA yönteminde, FA'dan elde edilen en iyi çözüm bilgisi, ABC yönteminde kullanılarak lokal en iyi çözümün iyileştirilmesi amaçlanmıştır. HABCFA'da, popülasyondaki bireyler, aynı ABC optimizasyonundaki gibi görevli (employee), gözcü (onlooker) ve kaşif (scout) rollerine sahiptir. Bu rollerin davranış şekilleri ABC optimizasyon algoritmasındaki roller ile aynı olacak şekilde modellenmiştir. Geliştirilen HABCFA optimizasyonu akış diyagramı Şekil 4.1.'deki gibidir.



Şekil 4.1. HABCFA optimizasyonu akış diyagramı

HABCFA algoritmasının ayrıntılı olarak çalışma adımları aşağıdaki gibidir:

Adım 1. Başlangıç çözüm değerlerinin atanması

Popülasyondaki her bir görevli birey, başlangıç parametrelerin değerlerinin belirlenmesinin ardından arama uzayında rastgele konumlandırılır (Denklem 4.1). Burada L ve U sırasıyla arama uzayının alt ve üst sınır değerleridir. x_i ise i. bireyin arama uzayındaki konumunu temsil etmektedir.

$$x_i = L + rand * (U - L) \quad (4.1)$$

Adım 2. Kaynaklar için uygunluk değerlerinin hesaplanması

Her bir kaynak için F (uygunluk değeri - fitness value) Denklem 4.2'ye göre hesaplanmaktadır. Burada f_i , i. kaynağın maliyet fonksiyonu ile elde edilen maliyet değeridir.

$$F = \begin{cases} \frac{1}{1+f_i}, & f_i \geq 0 \\ 1 + abs(f_i), & f_i < 0 \end{cases} \quad (4.2)$$

Adım 3. Komşulukta daha iyi bir kaynak arama

Uygunluk değerleri hesaplanmış olan görevli bireyler, diğer görevli bireylerin kaynaklarından birine rastgele yönelir. Eğer bulunan komşu kaynağın uygunluk değeri, mevcut kaynağın uygunluk değerinden daha iyi ise görevli birey komşu kaynağa doğru yönelir ve önceki kaynağın geliştirilememe sayacı sıfırlanır. Bu yönelme davranışı, yani mevcut konumun güncellenmesi aşaması iki adımda gerçekleşir. İlk adımda FA optimizasyon algoritmasındaki konum güncelleme denkleminde göre yeni konum belirlenir (Denklem 4.3). Eşitlikteki $x_{i_fa}^{t+1}$, FA'ya göre güncellenmiş yeni konum, β çekicilik (attractiveness) miktarı, $\alpha \in [0, 1]$ aralığında sabit bir değer alan katsayı, rand ise $[0, 1]$ aralığında rastgele bir değerdir. Denklem 3.10'da i. ateşböceği için t zamanındaki rastgele bir vektör olarak tanımlanan $\varepsilon_i(t)$ parametresi $[4]$ 'te, $[-0.5, 0.5]$ arasında bir değer olarak alındığından, ε değeri, $(rand - 0.5)$ ile hesaplanmıştır.

$$x_{i_fa}^{t+1} = x_i^t + \beta * (x_j^t - x_i^t) + \alpha(rand - 0.5) \quad (4.3)$$

Bireylerin çekicilik miktarları FA optimizasyonundaki Denklem 3.8'e göre hesaplanmaktadır. D-boyutlu bir arama uzayında iki kaynak arasındaki mesafe Euclidean mesafesi ile ölçülür (Denklem 3.11).

Görevli bireylerin konum güncelleme aşamasının ikinci adımında, Denklem 4.3 ile elde edilen konum bilgisi, ABC optimizasyonunun konum güncelleme denkleminde kullanılmaktadır (Denklem 4.4).

$$x_i^{t+1} = x_{i_fa}^{t+1} + rand(0,1)(x_{i_fa}^{t+1} - x_i^t) \quad (4.4)$$

Adım 4. Mevcut kaynakların olasılık bilgilerine göre gözcü bireylerin kaynaklar üzerinde rastgele konumlanması

Görevli bireylerin daha iyi çözümlere yönelmesinin ardından, gözcü bireylerin rolü başlamaktadır. Gözcü bireyler, görevli bireylerin sürecinden elde ettikleri kaynakların olasılık bilgilerine göre kaynaklar üzerinde rastgele konumlanırlar. Çözümlerin olasılık değerleri Denklem 4.5'e göre hesaplanır. Burada N popülasyondaki birey sayısıdır.

$$P_i = \frac{F_i}{\sum_{j=1}^{N/2} F_j} \quad (4.5)$$

Gözcü bireylerin mevcut kaynaklardan birini seçmesi, bir doğal seçim yöntemi olan rulet tekerleği yöntemine göre yapılmaktadır. Her bir kaynak için [0, 1] aralığında elde edilmiş P_i olasılık değerleri, seçme aşamasında kullanılmaktadır.

Adım 5. Kaşif birey üretme

Gözcü bireyler de aynı görevli bireyler gibi konumlandıkları kaynakları iyileştirme aşamasını içerirler. Konumlanılan kaynak yeterli değilse ve komşuluğunda daha iyi bir kaynak bulunmuyorsa (eğer kaynağın geliştirilememe sayacı limit değerine ulaşmış ise), arama uzayında rastgele bir kaynak üzerinde konumlanırlar. Bu durumda birey, kâşif (scout) rolüne dönüşerek başka bir kaynak arama sürecine başlamaktadır ve kaşif birey sayısı 1 arttırılmaktadır. Kâşif bireylerin sayısı arama süreci başında 0 olarak belirlenir ve bazı yaklaşımlarda maksimum kâşif birey sayısı bir durdurma kriteri olarak da kullanılmaktadır. Ancak bu çalışmada durdurma şartı, maksimum çevrim sayısı olarak belirlenmiştir.

Adım 6. Yerel en iyi çöümün kaydedilmesi
Bulunan en iyi çöüm hafızada tutulur.

Adım 7. Arama süreci durdurma şartının kontrolü
Sonlandırma koşulları sağlanmadığı sürece Adım 2'den Adım 6'ya kadar devam edilir.

Tüm bireylerin görevini tamamlaması bir iterasyondur ve bir sonraki iterasyon rastgele bir çöüm üzerinden değil, bir önceki iterasyonun bulduğu yerel en iyi çöüm değeri üzerinden çalışmaya başlamaktadır. Bu durum, nesiller arasındaki bilgi veya deneyim akışı olarak da düşünülmektedir. Böylece yerel sonuçların kullanılması ile global en iyi sonuca minimum maliyetle ulaşılabilmesi amaçlanmıştır.

4.2. HABCFA, ABC ve FA Optimizasyon Yöntemlerinin Karşılaştırılması

Test (benchmark) fonksiyonları, bir optimizasyon yönteminin verimliliğini ölçmek için kullanılan fonksiyonlardır. Literatüre göre bu fonksiyonlar, sürekli-kesikli, doğrusal-doğrusal olmayan, dışbükey- dışbükey olmayan, tek modlu- çok modlu ve ayrıştırılabilir-ayrıştırılmaz(veya kısmen ayrıştırılabilir) olarak sınıflandırılmaktadır [61, 62].

Bu çalışmada Sphere [63], Ackley [64], Powell [65] ve Schwefel (Schwefel 2.26) [66] olmak üzere dört farklı popüler test fonksiyonu kullanılmıştır. Bu yöntemler tek modlu- çok modlu ve ayrıştırılabilir-ayrıştırılmaz (veya kısmen ayrıştırılabilir) özellikleri dikkate alınarak belirlenmiştir. Tek modlu test fonksiyonları, sadece bir global optimuma sahiptir ve yerel optimum içermezler. Bu durum, yakınsama hızının tespit edilmesi açısından, bu fonksiyonları tercih edilebilir hale getirmektedir [67]. Eğer bir fonksiyon birden fazla optimum değere sahip ise (bu değerlerden biri global optimum, diğerleri yerel optimum değerleridir), bu fonksiyon çok modlu bir test fonksiyonudur. Çok modlu test fonksiyonları kullanılarak, bir optimizasyon yönteminin yerel optimum değerlere takılıp takılmama başarısı test edilebilmektedir.

Ayrıştırılabilirlik özelliğine sahip test fonksiyonlarındaki her bir değişken, diğer değişkenlerden bağımsızdır. Bu durum ayrıştırılabilir fonksiyonların, ayrıştırılamaz olan fonksiyonlardan daha kolay çözülebilir olduğunu göstermektedir. Bu çalışmada önerilen HABCFA yönteminin performansı, ABC ve FA algoritmaları ile seçilen dört popüler test fonksiyonu kullanılarak karşılaştırılmıştır. Seçilen test fonksiyonlarının özellikleri Tablo 4.1’de, formülleri de Tablo 4.2’de gösterilmiştir.

Tablo 4.1. Kullanılan test fonksiyonlarının özellikleri [61, 62]

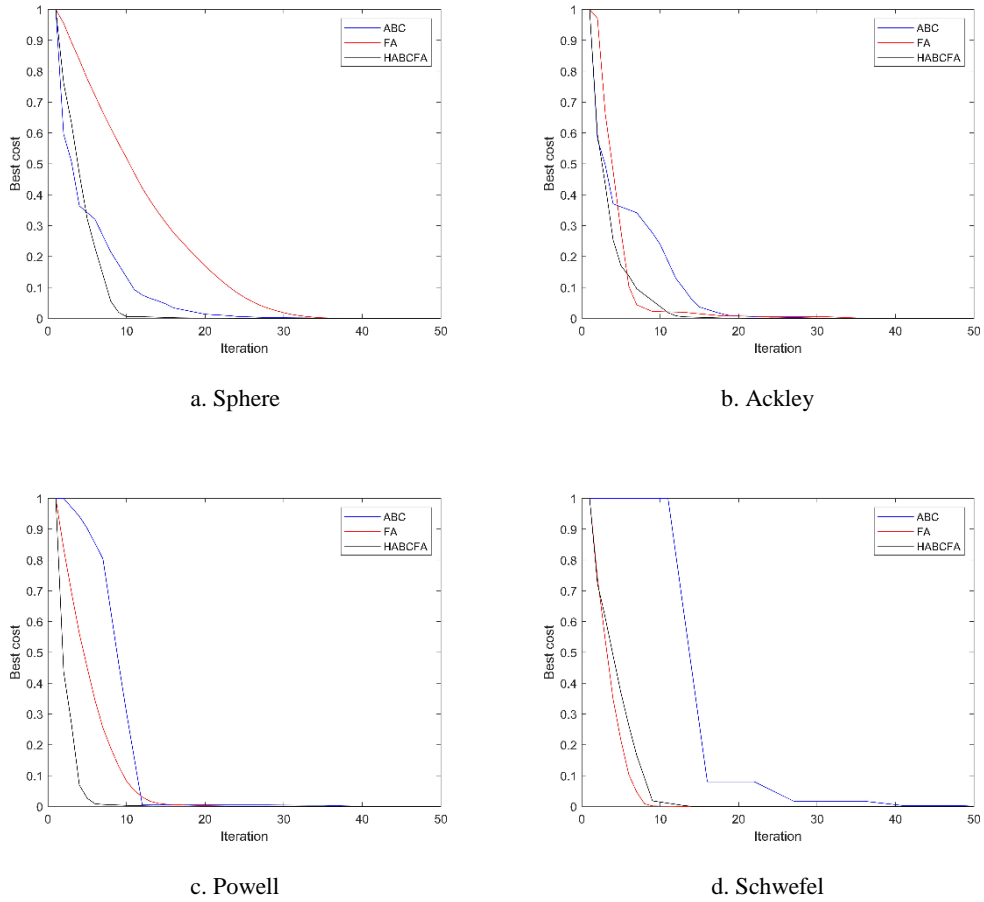
	En küçük değer	Arama Aralığı	Çok Modlu (multimodal)	Ayrıştırılabilir (Separable)
Sphere	0	[-5.12,5.12]	Hayır	Evet
Ackley	0	[-32,32]	Evet	Hayır
Powell	0	[-4,5]	Hayır	Hayır
Schwefel	0	[-512,512]	Evet	Kısmen Ayrıştırılabilir

Tablo 4.2. Kullanılan test fonksiyonlarının formülleri [61, 62]

	Formül
Sphere	$f(x) = \sum_{i=1}^n x_i^2$
Ackley	$f(x) = -20 \exp \left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right) - \exp \left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i) \right) + 20 + e$
Powell	$f(x) = \sum_{i=1}^{D-2} (x_{i-1} + 10x_i)^2 + 5(x_{i+1} - x_{i+2})^2 + (x_i - 2x_{i+1})^4 + 10(x_{i-1} - x_{i+2})^4$
Schwefel	$f(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$

Yakınsama oranı/ hızı, yeni bir optimizasyon algoritmasının değerlendirilebilmesi için tipik bir karşılaştırma kriteridir ve genel olarak performans değerlendirme için kullanılmaktadır. HABCFA, ABC ve FA algoritmalarının her biri için maksimum iterasyon sayısı 50 ve popülasyon limiti 100 olarak belirlenmiştir. Ayrıca maksimum iterasyon sayısının 500 olması durumunda çıktı değerleri Tablo 4.3’te verilmiştir. Hem Şekil 4.2. hem de Tablo 4.3., önerilen hibrit yaklaşımın, maliyet ve zaman verimliliği açısından her iki temel algoritmadan daha iyi sonuçlar ürettiğini göstermektedir.

Şekil 4.2.a.'da önerilen HABCFA yönteminin global minimuma en yakın sonuca ulaştığı görülmektedir. Şekil 4.2.b.'de önerilen yöntem ve ABC algoritması, önerilen yöntemin daha hızlı yakınsama oranına sahip olması dışında yakın sonuçlar vermektedir. Her üç yöntem de Şekil 4.2.c.'de görüldüğü gibi aşağı-yukarı aynı sonuçlara sahiptir, ancak yine en hızlı yakınsama HABCFA yöntemine aittir. Şekil 4.2.d.'de görüldüğü gibi tüm yöntemlerle yaklaşık olarak aynı global minimum değere ulaşılmaktadır. Ek olarak HABCFA ve FA yöntemlerinin yakınsama oranları birbirine yakındır.



Şekil 4.2. Kalite testi problemleri üzerinde performans karşılaştırması

Algoritmaların çalışma süreleri açısından karşılaştırılması Tablo 4.3.'te verilmiştir. FA algoritmasının diğer algoritmalara göre nispeten uzun bir çalışma süresine sahip olduğu açıkça görülmektedir. ABC ve HABCFA yöntemlerinin çalışma sürelerinin ABC yöntemi lehine olan küçük bir fark ile birbirine oldukça yakın olduğu sonucu

elde edilmiştir. Tablo 4.3.'te aynı iterasyon sayıları için, ABC yönteminin geliştirilen hibrit yöntemden çok az bir farkla daha hızlı çalıştığı görünüyor ancak Şekil 4.2.'de HABCFA, ABC'den daha hızlı bir şekilde (daha küçük iterasyon sayılarında) en iyi sonuca yakınsamıştır.

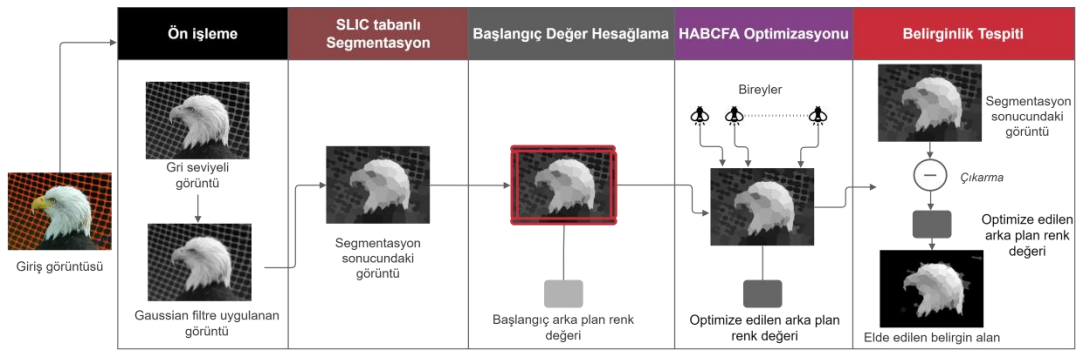
Tablo 4.3. HABCFA, FA ve ABC algoritmalarının çalışma süreleri (maksimum iterasyon sayısı=500)

	Sphere	Ackley	Powell	Schwefel
	Çalışma süresi	Çalışma süresi	Çalışma süresi	Çalışma süresi
FA	120.55 sn.	204.24 sn.	138.96 sn.	170.39 sn.
ABC	1.83 sn.	3.07 sn.	2.15 sn.	3.25 sn.
<i>HABCFA</i>	<i>2.97 sn.</i>	<i>4.2 sn.</i>	<i>3.24 sn.</i>	<i>3.85 sn.</i>

BÖLÜM 5. GELİŞTİRİLEN HABCFA YÖNTEMİNİN GÖRÜNTÜLERDE BELİRGİNLİK TESPİTİ PROBLEMİNDE KULLANILMASI

Bu bölümde, ABC ve FA yöntemlerinin birleştirilmesi ile geliştirilen HABCFA optimizasyon algoritması, görüntülerde dikkat çeken alanların belirlenmesi problemine uygulanmıştır. Böylece literatürde sıkça görülen ön bilgi gerektiren çalışmaların yerine hiçbir ön eğitim ve ön bilgi gerektirmeyen bu yöntemin çalışması gösterilmiştir.

HABCFA optimizasyonu ile belirlenlik tespiti, arka plan temellidir ve aşağıdan-yukarıya yaklaşım özelliği taşımaktadır. Belirgin alanların, görüntülerin çoğunlukla merkezinde bulunmasından ve görüntünün genelinde görülen renk dağılımından daha farklı bir renk bilgisine sahip olmasından dolayı, renk ve konum bilgileri kullanılarak göze çarpan alanların çıkarımı amaçlanmaktadır. Şekil 5.1.'de görüldüğü gibi ön işlem ve sınıflandırma aşamalarının ardından, görüntünün kenar bölgelerinde en sık görülen gri seviye değeri bilgisi, optimize edilecek değer olarak ele alınmaktadır.



Ön işlem aşamasında, öncelikle RGB renk uzayındaki renkli giriş görüntüsü gri seviyeli görüntüye çevrilmektedir. Böylece optimizasyon metodunun arama aşaması

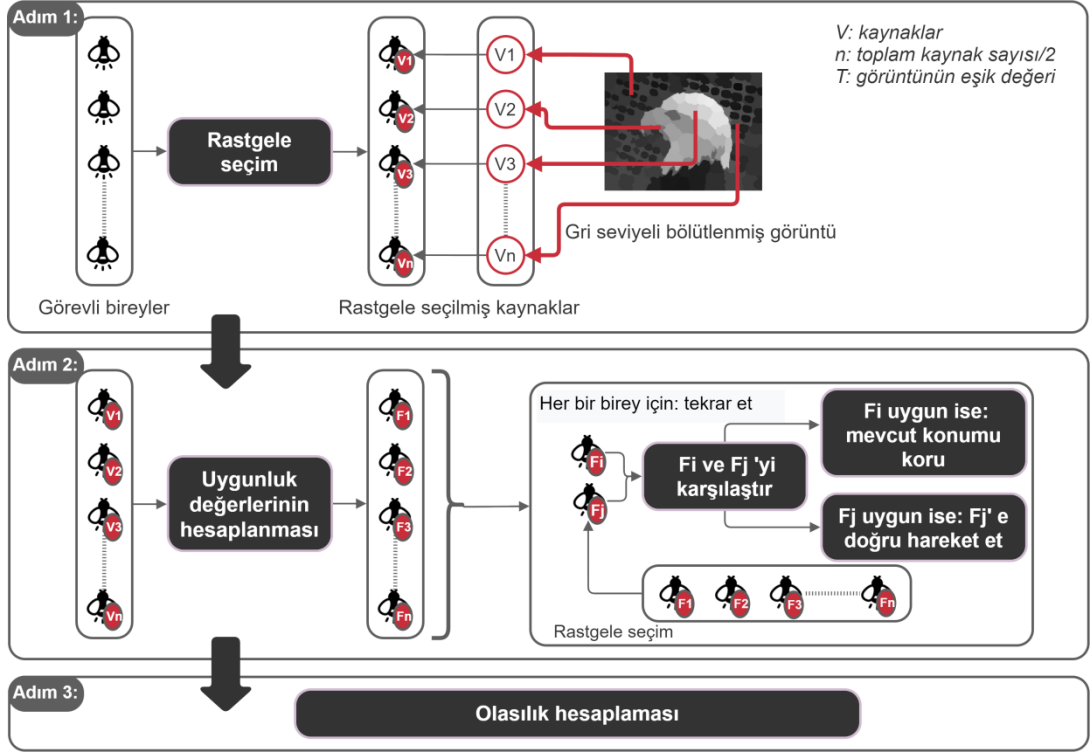
için arama uzayının küçültülmesi sağlanmıştır. Daha sonra, olası gürültüden kurtulmak için blurlaştırma etkisi olan Gaussian filtreden yararlanılmıştır.

İkinci aşama olarak SLIC super piksel sınıflandırma yöntemi uygulanarak benzer gri seviye değerlerine sahip pikseller gruplandırılmıştır.

Görüntülerde dikkat çeken alanlar genellikle görüntünün merkezinde olduğundan üçüncü aşamada, sınıflandırılmış gri seviyeli görüntünün kenar bölgelerinden optimize edilecek olan başlangıç arka plan değeri bulunmaktadır.

Bir görüntüde en yaygın görülen gri seviye renk değeri ile herhangi bir piksel grubunun gri seviye değerinin farkı uygunluk fonksiyonu olarak tanımlanmaktadır. Belirgin alanların tespiti açısından, eğer gidilen kaynağın uygunluk değeri görüntüde yaygın görülen yakın bir değer ise o kaynağın arka plan olma olasılığı yüksektir. Son aşamada, optimizasyon aşaması sonucunda elde edilen minimum uygunluk değerine sahip gri seviye değeri, arka plan değeri olarak tanımlanmaktadır. Bulunan arka plan değeri ile görüntünün farkının alınması sonucunda belirginlik haritası elde edilmektedir.

Optimizasyon aşamasının uygulanmasında popülasyon/sürü büyüklüğü önemli bir faktördür. Popülasyondaki birey sayısı çok az veya çok fazla olursa en iyi çözümün bulunmasındaki arama verimliliği düşmektedir. HABCFA'da popülasyondaki birey sayısı sabit değil, görüntünün en, boy oranına göre dinamik olarak belirlenmektedir. HABCFA optimizasyonunun, görüntülerde belirgin alan tespiti problemlerine uygulanma aşamaları Şekil 5.2.'de görevli bireyler ve Şekil 5.3.'te gözcü bireyler için gösterilmektedir.



Şekil 5.2. Belirginlik tespitinde HABCFA'daki görevli bireylerin rolü

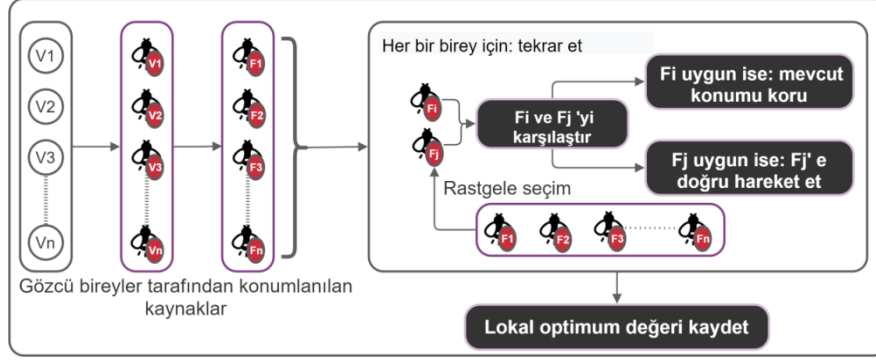
İlk adımda görevli bireyler rastgele piksel grupları üzerinde konumlandırılmaktadır. Konumlanılan piksel gruplarının gri seviye değerleri HABCFA optimizasyonu için çözüm adaylarını/kaynakları temsil etmektedir. Bu kaynaklara ait koordinat, gri seviye değeri, uygunluk değeri, geliştirilememe sayacı, olasılık ve yasaklı kaynak olup olmadıkları bilgileri tutulmaktadır.

Uygunluk fonksiyonu, popülasyondaki bireylerin konumlandığı her kaynak/piksel grubu için Denklem 5.1'e göre hesaplanmaktadır. Burada F_i uygunluk değeri, T görüntüde en yaygın görülen gri seviye değeri ve G_{X_i} , X_i 'nci piksel grubuna ait gri seviye değeridir.

$$F_i = \sqrt{(T - G_{X_i})^2} \quad (5.1)$$

Konumlanılan kaynak arka plan değeri olma özelliği taşıyorsa ve geliştirilememe sayacı, limit değerine ulaşmış ise o kaynak birey tarafından terk edilir.

Geliştirilememe sayacı limit değerine ulaşmadan, arka plan olmaya daha uygun bir kaynak bulunursa, mevcut kaynağın geliştirilememe sayacı sıfırlanır çünkü bu kaynak ve çevresi arka plana dâhil olabilme ihtimali taşır ve bu bölgede arama sürecine devam edilebilir (Şekil 5.2. ve Şekil 5.3.).



Şekil 5.3. Belirginlik tespitinde HABCFA'daki gözcü bireylerin rolü

Arka plan değeri olabilme olasılık değerleri, görevli bireylerden gelen uygunluk değerlerine göre hesaplanır. Gözcü bireyler, bu olasılık değerini kullanarak yasaklı olmayan piksel gruplarına, rulet tekerleği doğal seçim yöntemine göre yönelir. Daha sonra, aynı görevli bireyler gibi daha iyi bir arka plan değeri olabilecek kaynak arayışına girerler. Gözcü bireyler, görevlilerden edindikleri çözüm değerlerini iyileştirme çabasında olduklarından, daha doğru bir arka plan değeri elde etmemizi sağlamaktadırlar (Şekil 5.3.).

BÖLÜM 6. DENEYSEL BULGULAR

Bu bölümde, geliştirilen HABCFA optimizasyon algoritmasının, görüntülerdeki belirgin alanları tespit edebilme yetenekleri incelenmiştir. Literatürde pek çok state-of-the-art belirginlik tespiti yöntemi bulunmaktadır. Bu yöntemler arasından literatürdeki popülerliklerine göre 11 yöntem HABCFA ile karşılaştırmak üzere seçilmiştir: IT [19], FT [31], SR [20], MC [26], CA [32], SEG [10], GMR [23], FES [33], DSR [25], SeR [34] and HS [35]. Tüm deneyler Intel i5-7300HQ CPU (2.5 GHz) ve 8GB RAM ile MATLAB R2019b platformu kullanılarak gerçekleştirilmiştir.

6.1. Kullanılan Veri Setleri

Bu çalışmada, belirginlik tespiti alanında literatürde oldukça popüler olan MSRA1000 [31], ECSSD [35], ICOSEG [68] ve DUTOMRON [23] veri setleri üzerinde deneyler yapılmıştır. Farklı zorluk seviyelerinde veri setlerinin deneylerde kullanılmasındaki amaç, geliştirilen HABCFA optimizasyon algoritmasının zorluk derecelerinden etkilenip etkilenmediğini tespit edebilmektir.

6.1.1. MSRA1000 veri seti

MSRA1000 veri setinde, göze çarpan alanlar genellikle görüntülerin merkezinde konumlanmaktadır ve bu alanlar arka plandan daha kolay ayırt edilebilmektedir. 1000 adet görüntü içeren bu veri seti, literatürde diğer veri setlerine göre nispeten daha kolay olarak nitelendirilmektedir.

6.1.2. ECSSD veri seti

ECSSD veri seti, belirgin nesnelere tespitinin nispeten daha zor olduğu, farklı boyutlardaki 1000 adet doğal yaşamdan görüntüyü içermektedir. Görüntüler genellikle çoklu belirgin nesnelere sahiptir.

6.1.3. ICOSEG veri seti

ICOSEG, 38 gruba ayrılmış 643 doğal görüntü içerir. Her grup ortalama 17 resim içerir. Bir grup içinde, görüntüler aynı ön plana ve arka plana sahiptir ancak farklı bakış açılarından görülür. Her gruptaki arka planlar tutarlı doğal sahnelerdir ancak günlük yaşamdan görüntüler içerdiğinden belirgin alan tespitinin zor olduğu veri setlerindedir.

6.1.4. DUTOMRON veri seti

DUTOMRON, 5.168 yüksek kaliteli karmaşık doğa görüntüsü içermektedir, daha uygulanabilir ve sağlam belirginlik yöntemlerinin araştırılması için kullanılır. Bu veri seti literatürde en zorlu belirgin nesne algılama veri seti olarak nitelendirilmektedir.

6.2. Kullanılan Değerlendirme Yöntemleri

Yapılan deneylerin sonucunda elde edilmiş olan sonuçların karşılaştırılması için, precision-recall (kesinlik-duyarlılık), F_β (F-measure – F-ölçütü) ve MAE (Mean Absolute Error - Ortalama Mutlak Hata) olmak üzere evrensel olarak kabul edilmiş olan dört sayısal değerlendirme yöntemi kullanılmıştır.

6.2.1. Precision-recall (Kesinlik-duyarlılık)

Bir sınıflandırma işleminin ne derecede başarılı sonuç verdiğinin ölçülebilmesi için pozitif ve negatif olarak nitelendirilen sonuçların incelenmesi gerekmektedir. Bu çalışmada, sonuç inceleme yöntemlerinden biri olan precision-recall analizi

kullanılmıştır. Tablo 6.1.'de, görüntülerde belirgin alanların tespiti için özelleştirilmiş bir hata matrisi (confusion matrix) verilmiştir. Bu tabloda, gerçekte pozitif olan ve pozitif olarak tahmin edilen sonuçların sayısı GP, gerçekte negatif olan ve negatif olarak tahmin edilen sonuçların sayısı GN, gerçekte pozitif olan ama negatif olarak tahmin edilen sonuçların sayısı YN ve gerçekte negatif olan ama pozitif olarak tahmin edilen sonuçların sayısı YP ile gösterilmiştir.

Tablo 6.1. Görüntülerde belirgin alanların tespiti için hata matrisi

	BELİRGİN(+)	BELİRGİN(-)
TEST(+)	Gerçek Pozitif(GP)	Yanlış Pozitif(YP)
TEST(-)	Yanlış Negatif(YN)	Gerçek Negatif(GN)

Precision (kesinlik) değeri, pozitif olarak elde edilen sonuçların, test sonucunda elde edilen tüm pozitif sonuçlara oranıdır. Recall (duyarlılık) değeri ise pozitif olarak elde edilen sonuçların, gerçekte olan tüm pozitif sonuçlara oranıdır [27].

$$Precision = \frac{GP}{GP+YP} \quad (6.1)$$

$$Recall = \frac{GP}{GP+YN} \quad (6.2)$$

6.2.2. F-measure (F-ölçütü)

Belirginlik haritaları, precision ve recall değerlerini elde etmek ve ayrıca precision-recall eğrilerini oluşturmak için 0 ve 255 kapalı aralığında eşikler kullanılarak ikili (binary) hale getirilmiştir. F_β , precision ve recall değerlerinin kullanılması ile birlikte bütünlük bir performans kriteri olarak kabul edilmektedir. Deneysel sonuçlar için precision, geliştirilen modelin belirginlik tespit performansı ile ilgilidir. Recall ise doğru tespit edilen ve gerçekte belirgin olan alanların birbirine oranıdır. F-measure, precision ve recall değerlerinin harmonik ortalaması ile hesaplanan bir performans ölçütüdür [27]. [31]'de önerildiği gibi β^2 değeri 0.3 iken, Denklem 6.3 ile hesaplanmaktadır:

$$F_{\beta} = \frac{(1 + \beta^2) \times Precision \times Recall}{\beta^2 \times Precision + Recall} \quad (6.3)$$

6.2.3. MAE (Ortalama mutlak hata)

MAE, elde edilmiş olan belirginlik haritasını içeren sonuç görüntüler ile gerçek referans değer (ground truth) görüntüler arasındaki ortalama fark olarak kullanılarak Denklem 6.4 ile hesaplanmaktadır [28]. Denklem 6.4'te, H ve W görüntünün yüksekliğini ve genişliğini belirtirken, M(i) ve GT(i) sırasıyla piksel düzeyinde belirginlik değeri ve gerçek referans değeridir.

$$MAE = \frac{1}{H \times W} \sum_{i=1}^{H \times W} |M(i) - GT(i)| \quad (6.4)$$

6.3. Başlangıç Parametre Değerlerinin Belirlenmesi

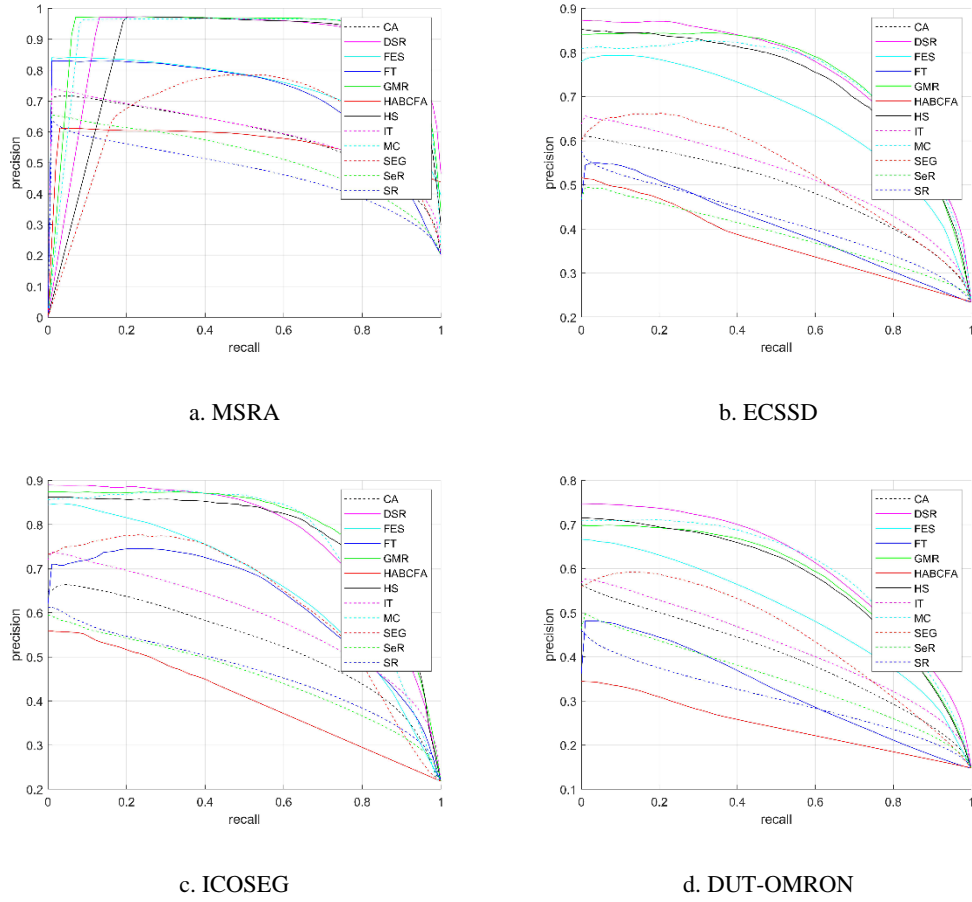
HABCFA ile belirgin alanların tespiti çalışması bazı başlangıç parametrelerine sahiptir ve bu parametrelere çalışma öncesinde başlangıç değeri ataması yapılması gerekmektedir. Bölütleme adımında SLIC tabanlı süper-piksel sınıflandırma yönteminde kullanılan süper-piksel sayısı, popülasyondaki birey sayısı ve optimizasyon sürecindeki kaynak sayısı, [59]'deki toplam birey sayısı hesaplamasında kullanılan denklem kullanılarak, görüntünün genişliğine ve yüksekliğine göre dinamik olarak belirlenmektedir. Popülasyondaki birey sayısı, Süper-piksel sayısı ve kaynak sayısı da yine aynı denklem kullanılarak belirlenmektedir. HABCFA yönteminin, ABC kısmında kullanılan bir diğer parametre olan limit değeri, popülasyonda bulunan toplam birey sayısının karekökü olarak ayarlanmaktadır. Ayrıca popülasyondaki birey sayısı, işçi ve gözcü rollerinde olmak üzere eşit iki gruba ayrılmaktadır. Temel FA algoritmalarında kullanılan γ , β_0 ve α parametreleri, [60]'daki gibi sırasıyla 1, 1 ve 0.2 olarak belirlenmiştir. Farklı maksimum iterasyon sayıları kullanılarak sistem çalıştırılmıştır ve daha iyi bir performans için maksimum iterasyon sayısı 100 olarak belirlenmiştir.

6.4. Diğer Metotlar ile HABCFA'nın Karşılaştırma Sonuçları

Elde edilen sonuç görüntüleri, 11 state-of-the-art belirginlik tespiti yönteminin sonuç görüntüleri ile karşılaştırılmıştır. Elde edilen sonuçlar Şekil 6.1., Şekil 6.2. ve Tablo 6.2.'de ayrıntılı bir şekilde gösterilmiştir. Şekil 6.3., Şekil 6.4. , Şekil 6.5. ve Şekil 6.6., her bir veri setinden rastgele seçilen 5 görüntü için tüm yöntemlerin sonuç görüntülerini içermektedir. Ayrıca tüm yöntemler çalışma süreleri açısından da karşılaştırılmıştır (Tablo 6.3., Şekil 6.7.). Ek olarak, görüntülerdeki zorluk derecesinin, HABCFA'nın ve diğer metotların çalışma süresindeki performansı etkileyip etkilemediği de incelenmiştir (Tablo 6.4., Şekil 6.8.).

6.4.1. Precision-recall sonuçları

Belirlenen 4 veri seti üzerinde tüm yöntemler çalıştırılmış ve sonuç görüntüleri elde edilmiştir. Tüm sonuç görüntüleri, veri setlerinde bulunan gerçek referans değer (ground truth) görüntüler ile [31]'da belirtilen sabit eşikleme (fixed thresholding) yöntemi kullanılarak karşılaştırılmıştır. Bu karşılaştırmalar için, elde edilen her bir sonuç belirginlik haritası görüntüsü, [0-255] aralığındaki her bir değer için eşik değeri olarak kullanılması ile ikili (binary) görüntü haline çevrilmiştir. Her bir eşik değeri için elde edilen ikili görüntü, gerçek referans değer görüntü ile karşılaştırılarak precision-recall değerleri hesaplanmıştır. Şekil 6.1'de de görüldüğü gibi, maksimum recall noktasında, tüm yöntemler aynı precision değerine sahiptir. Bu, tüm yöntemlerin belirginlik haritalarındaki tüm piksellerin pozitif (belirgin) olarak tutulduğu anlamına gelmektedir.



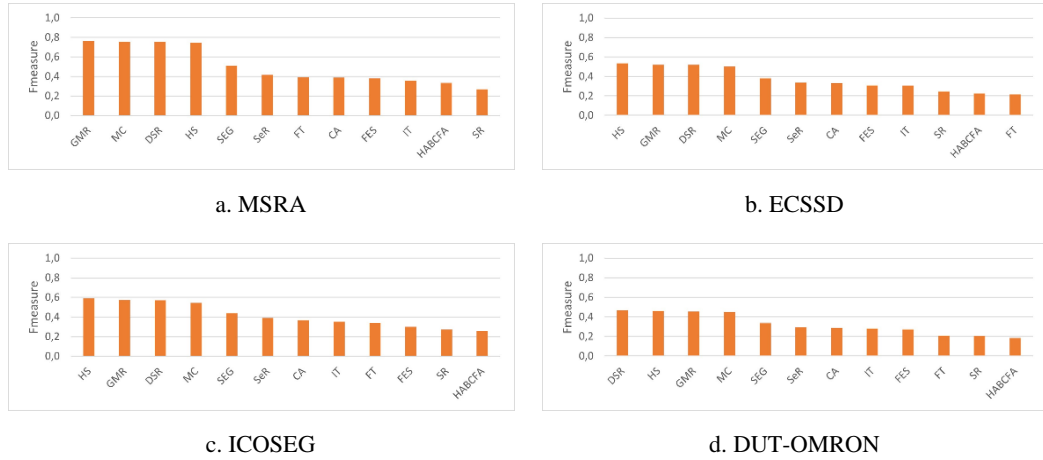
Şekil 6.1. Precision recall eğrileri

TP (gerçek pozitif), belirgin nesne olarak algılanan görüntü alanındaki göze çarpan piksel sayısını, FP (yanlış pozitif) arka plan piksellerinin sayısını ve FN (yanlış negatif) ise belirgin nesneye ait olduğu halde yanlışlıkla arka plana ait olarak belirtilen toplam piksel sayısını temsil etmektedir. Precision (kesinlik) değeri TP ve FP değerleri ile hesaplanmaktadır ve pozitif sınıfa ait olan pozitif sınıf tahminlerinin sayısını ölçmektedir. Recall (geri çağırma) değeri TP ve FN değerleri ile hesaplanmaktadır ve veri kümesindeki tüm olumlu örneklerden yapılan olumlu sınıf tahminlerinin sayısını göstermektedir. Tüm yöntemlerin, 4 veri seti üzerindeki sonuç görüntüleri bu şekilde eşiklenmiş ve precision recall değerleri ile hesaplanmıştır ve Şekil 6.1., precision-recall eğrilerini göstermektedir. Şekil 6.1.a.'da, önerilen HABCFA yönteminin SER ve SR'den daha iyi sonuçlar ürettiği açıkça görülmektedir. Şekil 6.1.b.'de, HABCFA, SER ile hemen hemen aynı performansı

göstermiştir. Öte yandan, Şekil 6.1.c. ve Şekil 6.1.d.'de ise HABCFA, bu karmaşık görüntülerin daha iyi anlaşılmasını sağlamaktadır.

6.4.2. Ortalama f-measure sonuçları

Ortalama F-measure sonuçları Şekil 6.2.'deki grafiklerde, her bir veri seti için ve her bir yöntem için azalan bir sıralama ile gösterilmiştir. Önerilen yöntem, MSRA-1000 veri seti görüntülerinde SR yönteminden daha iyi sonuçlar verirken, CA, FES, FT, IT, SR yöntemler ile benzer sonuçlar elde edilmiştir (Şekil 6.2.a.). Şekil 6.2.b.'de, ECSSD veri setindeki görüntüler için HABCFA, FT ve SR yöntemlerinin daha yakın sonuçlar ürettiği görülmektedir. Şekil 6.2.c.'de HABCFA'nın ICOSEG üzerindeki SR ve FES yöntemleri ile benzer sonuçlar ortaya koyduğu, Şekil 6.2.d.'de ise DUT-OMRON veri seti üzerinde SR ve FT yöntemleri ile benzer çıktılara sahip olduğu görülmektedir.

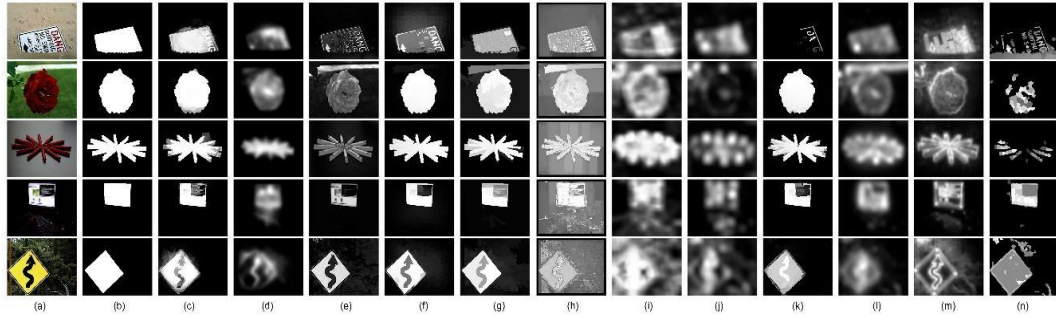


Şekil 6.2. Ortalama F-measure karşılaştırmaları

6.4.3. Elde edilen sonuç görüntüleri


Geliştirilen HABCFA yöntemi ve diğer 11 state-of-the-art yöntem, 4 veri seti için çalıştırılmış ve sonuç görüntüleri elde edilmiştir. Şekil 6.3. MSRA1000, Şekil 6.4. ECSSD, Şekil 6.5. ICOSEG ve Şekil 6.6. DUT-OMRON veri setindeki 5 örnek görüntü için, elde edilen sonuç görüntülerini, orijinal ve gerçek referans görüntülerini göstermektedir.

Şekil 6.3.'de, MSRA-1000 veri setinden alınan 5 örnek görüntü için elde edilen belirlenlik haritaları verilmiştir. Bu veri setindeki görüntülerde, belirgin alanlar genellikle görüntünün merkezinde yer almaktadır ve belirgin nesnelere daha kolay arka plandan ayırt edilebilmektedir. Tek tip bir arka plan özelliği yaygın biçimde bu veri setinde görülmektedir.



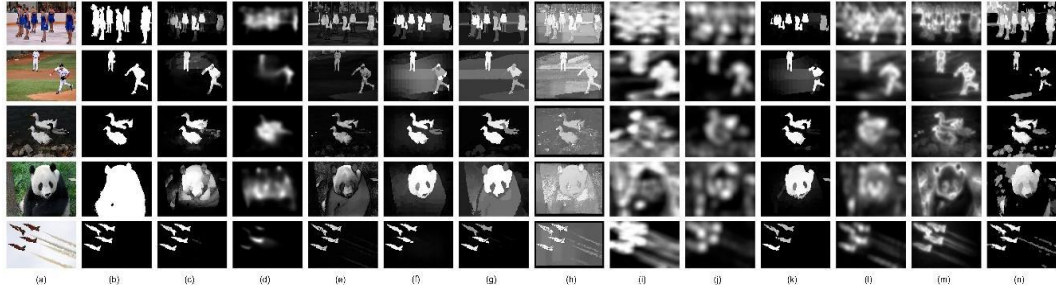
Şekil 6.3. MSRA1000 veri seti için belirlenlik haritalarının karşılaştırması: (a) orijinal görüntü, (b) gerçek referans görüntü, (c) DSR, (d) FES, (e) FT, (f) MC, (g) HS, (h) SEG, (i) SeR, (j) SR, (k) GMR, (l) IT, (m) CA, (n) HABCFA

ECSSD veri kümesine ait görüntüler, genel olarak birden çok dikkat çeken nesne ve dağınık arka planlar içermektedir. Şekil 6.4.'de, ECSSD veri setinden alınan 5 örnek görüntü için elde edilen belirlenlik haritaları görülmektedir.



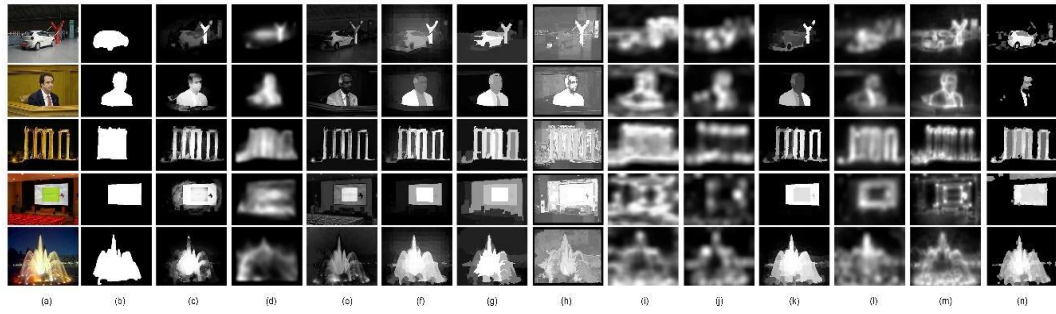
Şekil 6.4. ECSSD veri seti için belirlenlik haritalarının karşılaştırması: (a) orijinal görüntü, (b) gerçek referans görüntü, (c) DSR, (d) FES, (e) FT, (f) MC, (g) HS, (h) SEG, (i) SeR, (j) SR, (k) GMR, (l) IT, (m) CA, (n) HABCFA

ICOSEG veri setinde çoklu belirgin nesne içeren görüntüler bulunmaktadır. Bu özelliğinden dolayı dikkat çeken alanları tespit etmek oldukça zordur. Şekil 6.5., ICOSEG veri setinden alınan 5 örnek görüntü için elde edilen belirlenlik haritalarını içermektedir.



Şekil 6.5. ICOSSEG veri seti için belirginlik haritalarının karşılaştırması: (a) orijinal görüntü, (b) gerçek referans görüntü, (c) DSR, (d) FES, (e) FT, (f) MC, (g) HS, (h) SEG, (i) SeR, (j) SR, (k) GMR, (l) IT, (m) CA, (n) HABCFA

DUT-OMRON veri setini zorlu bir veri seti yapan etken, gerçek hayattaki görüntülere çok benzer görüntüler içermesidir. Ayrıca belirgin olan nesnelere karmaşık bir yapı göstermektedir. Şekil 6.6., DUT-OMRON veri setinden alınan 5 örnek görüntü için elde edilen belirginlik haritalarını göstermektedir.



Şekil 6.6. DUT-OMRON veri seti için belirginlik haritalarının karşılaştırması: (a) orijinal görüntü, (b) gerçek referans görüntü, (c) DSR, (d) FES, (e) FT, (f) MC, (g) HS, (h) SEG, (i) SeR, (j) SR, (k) GMR, (l) IT, (m) CA, (n) HABCFA

6.4.4. MAE sonuçları

Geliştirilen yöntemin sonuç görüntülerini, diğer yöntemlerden elde edilen sonuç görüntüleri ile karşılaştırmada kullanılan bir diğer ölçüt MAE değeridir. Tablo 6.1.'de görüldüğü gibi HABCFA'nın MAE değeri açısından performansı nispeten daha düşüktür ve bu karşılaştırılan diğer yöntemler için de geçerli bir durumdur. Tablo 6.2.'de görüldüğü gibi, HABCFA ve FES yöntemleri oldukça benzer MAE sonuçları üretmektedir.

Tablo 6.2. MAE değerlerinin karşılaştırması

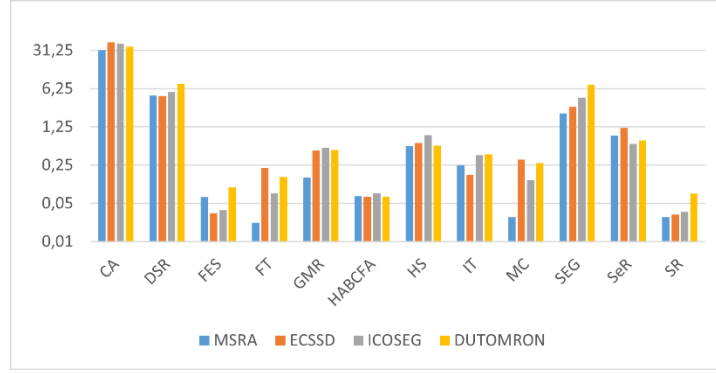
	<i>HABCFA</i>	IT	FT	SR	MC	CA	SEG	GMR	FES	DSR	SeR	HS
MSRA	<i>34.19</i>	28.84	29.48	35.27	10.33	27.57	13.09	14.41	34.63	14.34	20.05	10.81
ECSSD	<i>47.87</i>	37.46	45.35	41.87	28.51	34.94	27.23	29.47	45.51	33.27	28.38	24.32
ICOSEG	<i>43.19</i>	34.13	36.81	39.38	29.03	33.97	24.06	27.79	43.98	30.77	25.32	21.74
DUT-OMRON	<i>29.93</i>	22.31	26.77	27.29	16.11	22.84	15.05	16.41	28.53	18.96	17.04	13.33

6.4.5. Çalışma süreleri

Yapılan deneylerde geliştirilen HABCFA yönteminin, ABC ve FA yöntemlerinden daha hızlı bir şekilde en iyi sonuca yakınsadığı görülmüştür (Şekil 4.2.). Bu nedenle, HABCFA'nın optimizasyon metotları arasındaki hız avantajının, görüntülerde belirginlik tespiti problemlerinde de geçerli olup olmadığı test edilmiştir. 11 state-of-the-art metot ve geliştirilen HABCFA yöntemi, dört veri seti üzerinde çalıştırılmış ve çalışma süreleri karşılaştırılmıştır. Tüm metotlar için ilgili çalışmaların kodları kullanılmıştır ve kodlar Intel Core i5 2.5GHz 8GB RAM ortamında çalıştırılmıştır. Her bir veri seti için görüntü başına ortalama çalışma süreleri Tablo 6.3.'de ve Şekil 6.7.'de gösterilmektedir.

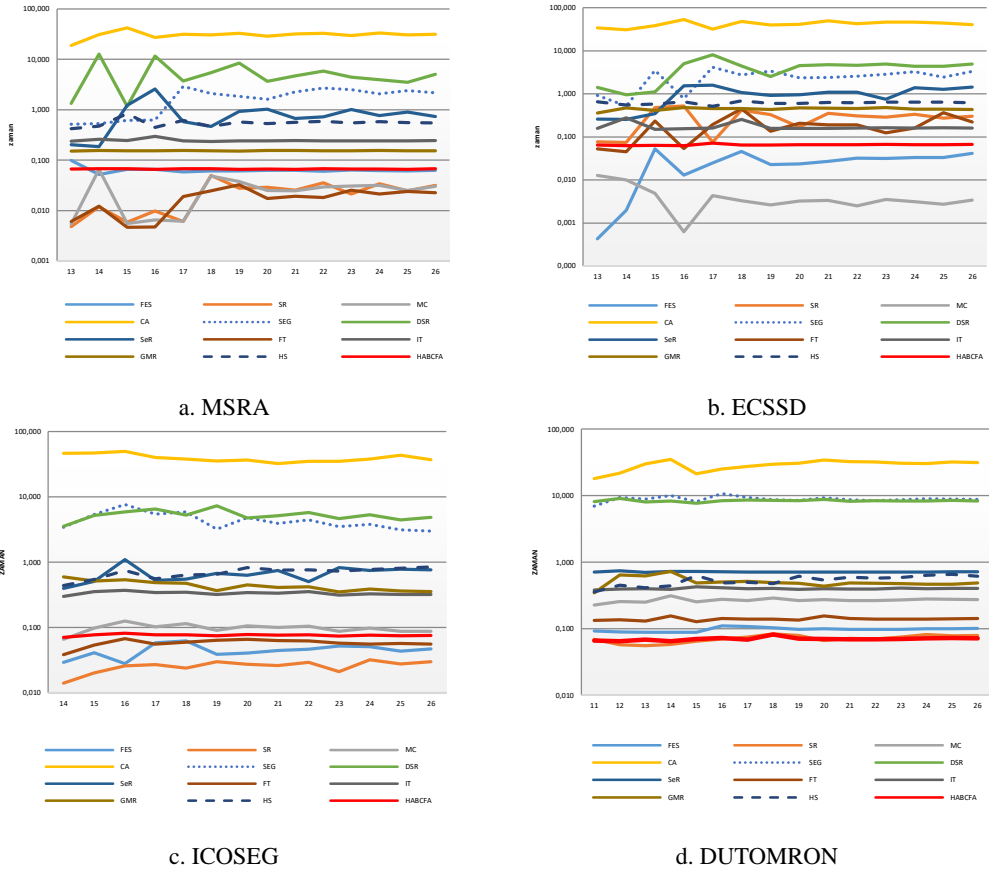
Tablo 6.3. Görüntü başına ortalama çalışma süreleri (sn)

	<i>HABCFA</i>	IT	FT	SR	MC	CA	SEG	GMR	FES	DSR	SeR	HS
MSRA	<i>0.067</i>	0.251	0.022	0.028	0.028	31.362	2.221	0.151	0.065	4.661	0.862	0.561
ECSSD	<i>0.066</i>	0.165	0.221	0.031	0.318	44.031	2.883	0.465	0.033	4.588	1.201	0.631
ICOSEG	<i>0.076</i>	0.379	0.077	0.035	0.132	41.881	4.272	0.514	0.037	5.454	0.612	0.887
DUT-OMRON	<i>0.066</i>	0.393	0.151	0.076	0.271	36.665	7.463	0.475	0.098	7.681	0.707	0.569



Şekil 6.7. Tüm veri kümeleri ve yöntemler için çalışma sürelerinin karşılaştırılması

Görüntülerde belirgin alanların tespitindeki zorluk derecesi, görüntülerin renk, desen bilgisi ve belirgin nesnenin bulunduğu konum kavramlarına göre değişmektedir. HABCFA ile belirgin alan tespiti, gri seviyeli görüntülerdeki renk bilgisine dayanan bir yöntemdir. Bu nedenle görüntülerin sahip olduğu gri seviye renklerde farklılıkların artması ile birlikte çalışma sürelerinin nasıl etkilendiği incelenmiştir. Bu durumun analizi için, veri setlerindeki her bir görüntü gri seviyeye dönüştürüldü ve gri seviye değerlerinin [0-255] aralığında eşit aralıklarla belirlenen 26 farklı sınıftan kaçında renk dağılımına sahip olup olmadığı incelenmiştir. Bu sınıf değerlerine göre çalışma sürelerinin değişimi Şekil 6.8.'de görülmektedir. MSRA ve ECSSD veri setlerindeki görüntüler minimum 13, ICOSEG veri setindeki görüntüler minimum 14 ve DUTOMRON veri setindeki görüntüler minimum 11 farklı sınıfta dağılım göstermiştir. Her bir sınıfa ait görüntüler için ortalama çalışma süreleri hesaplanmıştır. Bu grafiklere göre HABCFA yönteminin görüntülerdeki renk karmaşıklığından çok fazla etkilenmediği ve tüm görüntülerde benzer çalışma sürelerinde çalıştığı görülmektedir.



Şekil 6.8. Görüntülerdeki renk farklılıklarına göre ortalama çalışma süreleri

Tablo 6.4.'te, veri setlerindeki görüntüler için çalışma süreleri arasındaki değişimin ne boyutta olduğunu görülebilmesi amacı ile HABCF A ve diğer yöntemlerin sürelerinin standart sapmaları gösterilmektedir. HABCF A tüm veri setlerinde 0'a en yakın standart sapma değerlerine sahiptir. Bu da görüntülerdeki zorluk derecesinin, HABCF A'nın çalışma süresindeki performansı etkilemediğini göstermektedir.

Tablo 6.4. Standart sapma değerlerinin karşılaştırması

	HABCF A	IT	FT	SR	MC	CA	SEG	GMR	FES	DSR	SeR	HS
MSRA	0.009	0.041	0.037	0.066	0.057	18.681	4.856	0.021	0.077	10.1	2.175	0.181
ECSSD	0.008	0.059	1.067	0.772	0.051	26.952	5.982	0.326	0.037	8.579	2.079	0.175
ICOSEG	0.009	0.101	0.038	0.078	0.068	23.469	4.095	0.190	0.056	5.793	1.124	0.429
DUT-OMRON	0.014	0.101	0.384	0.118	0.092	21.804	2.226	0.176	0.144	1.001	0.124	0.175

Tablo 6.5, karşılaştırılan diğer yöntemlerin özelliklerini ve elde edilen analiz sonuçları açısından HABCFA ile karşılaştırmalarını göstermektedir.

Tablo 6.5. Literatürdeki 11 state-of-the-art yöntemin özellikleri ve HABCFA ile karşılaştırmaları

CA	<ul style="list-style-type: none"> • Yukarıdan aşağıya yaklaşıma sahip bir yöntemdir. • Bu yöntemde, belirginlik haritası oluşturmak için CNN kullanılarak elde edilen verilere ek olarak renk ve kontrast verileri de kullanılmıştır. • Bu üç açıdan oluşturulan belirginlik haritası birleştirilerek nihai belirginlik haritası oluşturulmaktadır. • CA yöntemi, CNN kullanarak belirginlik haritalarının çıkarılması için önceden eğitilmiş bir süreci içermektedir. • Bu çalışma, birden çok belirginlik haritasının birleşiminden yararlandığı için en yavaş çalışan yöntem olarak tespit edilmiştir. • <u>HABCFA-CA karşılaştırması:</u> Belirginlik tespiti için herhangi bir eğitim adımı bulunmamaktadır ve çok daha kısa bir çalışma süresine sahiptir.
DSR	<ul style="list-style-type: none"> • Yukarıdan aşağıya yaklaşıma sahip bir yöntemdir. • İlk olarak, her bir görüntü bölgesi için arka plan şablonlarında yoğun ve seyrek yeniden yapılandırma hataları (reconstruction error) hesaplanmaktadır. İkinci olarak, yeniden yapılandırma hataları, elde edilen bağlamlara dayalı olarak K-means yöntemi kullanılarak kümelenebilir. Daha sonra, piksel düzeyinde yeniden yapılandırma hatası, çoklu ölçekli yeniden yapılandırma hatalarının (multi-scale reconstruction errors) entegrasyonu ile hesaplanmaktadır. Bu çalışmalar temel alınarak, yoğun ve seyrek olmak üzere yeniden yapılandırma hatalarına dayalı iki belirginlik ölçüsü ile elde edilen belirginlik haritalarını birleştirmek için yeni bir Bayes entegrasyon yöntemi sunulmaktadır. • Belirgin alanın tespiti için süper-pikseller kullanılmakta ve birden çok aşama sırası ile uygulanmaktadır. • <u>HABCFA-DSR karşılaştırması:</u> DSR yöntemi HABCFA'ya göre F-measure ve MAE değerlerinde daha iyi görünmesinin nedeni pek çok alt aşamaya sahip olmasıdır. Ancak bu aşamaların çalışma süresine negative yansıdığı ve HABCFA'dan daha yavaş çalışan bir yöntem olduğu görülmektedir.
IT	<ul style="list-style-type: none"> • Aşağıdan yukarıya yaklaşıma sahip bir yöntemdir. • Renk, yoğunluk ve yönlenmeye göre üç özellik haritası oluşturulmuştur ve bu üç harita da normleştirilerek kullanılmıştır. • <u>HABCFA-IT karşılaştırması:</u> HABCFA ve IT yaklaşık aynı F-measure değerlerine sahiptir. IT'de üç farklı özellikten yararlanılarak belirginlik haritaları elde edilmektedir. Ancak HABCFA'da sadece arka plan gri seviye değeri optimize edilerek belirgin alan çıkarımı yapılabilmektedir. MAE değerleri açısından az bir farkla IT daha iyi görünse de HABCFA daha kısa çalışma sürelerinde benzer özelliklere sahip belirginlik haritalarını elde edebilmektedir.

Tablo 6.5. (Devamı)

SEG	<ul style="list-style-type: none"> • Yukarıdan aşağıya yaklaşıma sahip bir yöntemdir. • Bir CRF modeli ve bir belirginlik ölçüsü kullanarak bir belirgin nesne bölütleme yöntemidir. • Önerilen belirginlik ölçüsü, aydınlatma, renk ve hareket bilgisinde istatistiksel bir çerçeve ve yerel özellik kontrastı kullanılarak formüle edilmiştir. • Ortaya çıkan belirginlik haritası daha sonra, iyi tanımlanmış göze çarpan nesnelere ayırabilmeyi amaçlayan bir enerji minimizasyonuna dayalı bir CRF modelinde kullanılmıştır. • Birden çok yöntemin bir arada kullanılmasından dolayı yöntemin yavaş çalıştığı tespit edilmiştir. • HABCFA-SEG karşılaştırması: Optimize edilmiş başlangıç arka plan değeri dışında herhangi bir ekstra bilgi kullanmamıza gerek yoktur. SEG yönteminde bir pencerenin kaydırılması ile özellik çıkarımı yapılmaktadır ancak HABCFA'da herhangi bir pencere/maske işlemi uygulanmasına ihtiyaç yoktur ve daha kısa bir çalışma süresine sahiptir.
FES	<ul style="list-style-type: none"> • Yukarıdan aşağıya yaklaşıma sahip bir yöntemdir. • Bu yöntemde, bir merkez ve bir çevreye bölünmüş yerel bir pencere vardır. Merkez bir nesne içermektedir. Bu tekniğe ek olarak bayesci (bayesian) bir çerçevede yerel özellik kontrastının belirginliğini tahmin etmeye çalışan bir yöntem de uygulanmıştır. • Piksel düzeyinde belirginlik haritaları kullanarak daha iyi sonuçlar elde edilmeye çalışılmıştır. • HABCFA-FES karşılaştırması: HABCFA ve FES yaklaşık aynı çalışma sürelerine, F-measure ve MAE değerlerine sahiptir. Ancak HABCFA'da belirginlik tespiti için optimize edilmiş başlangıç arka plan değeri dışında herhangi bir ekstra bilgi kullanılmasına gerek yoktur.
FT	<ul style="list-style-type: none"> • Aşağıdan yukarıya yaklaşıma sahip bir yöntemdir. • Belirgin alan tespitinde “benzer bir merkeze olan komşuluk bilgisi” kullanılmıştır. Bu komşuluk değerinin büyüklüğü renk ve parlaklık özelliklerine göre belirlenmiştir. • Bu yöntemde elde edilen komşuluk büyüklükleri, nesne segmentasyonunda kullanılmıştır. • HABCFA-FT karşılaştırması: HABCFA ve FT yaklaşık aynı çalışma süreleri, F-measure ve MAE değerlerine sahiptir. Ancak HABCFA'da çalışma sürelerindeki standart sapma SR yönteminden daha az olarak karşımıza çıkmaktadır. Bu durum, FT yönteminin görüntülerdeki farklı zorluk derecelerinden (çalışma süresi açısından) daha çok etkilendiğini göstermektedir.

Tablo 6.5.(Devamı)

SR	<ul style="list-style-type: none"> Aşağıdan yukarıya yaklaşıma sahip bir yöntemdir. Belirgin alan tespitinde “Log spektrumu analizi” kullanılmaktadır. Bu yöntem, belirginlik haritası çıkarımında hızlı bir yöntem olarak nitelendirilmektedir. HABCFA-SR karşılaştırması: HABCFA ve SR yaklaşık aynı çalışma süreleri, F-measure ve MAE değerlerine sahiptir. Ancak HABCFA’da çalışma sürelerindeki standart sapma SR yönteminden daha az olarak karşımıza çıkmaktadır. Bu durum, SR yönteminin görüntülerdeki farklı zorluk derecelerinden (çalışma süresi açısından) daha çok etkilendiğini göstermektedir.
MC	<ul style="list-style-type: none"> Aşağıdan yukarıya yaklaşıma sahip bir yöntemdir. Belirgin alan tespitinde “Markov zinciri” yönteminden yararlanılmıştır. Markov zinciri bir görüntü grafik modeline uyarlanarak belirginlik tespiti formüle edilmiştir. Öne çıkan nesnelere ve arka planın görünüş farklılığı birlikte ele alınmıştır. Sanal sınır düğümleri, bir Markov zincirinde kaydedici düğümler olarak seçilmektedir ve her geçici düğümden sınır düğümlere kadar kayıt edilen zaman hesaplanmaktadır. Geçici düğümün kayıt süresi, tüm kaydedici düğümler ile küresel benzerliğini ölçmektedir ve bu nedenle, kaydedilen zaman bir ölçü olarak kullanıldığında dikkat çekici nesnelere arka plandan tutarlı bir şekilde ayrılabilir. Geçici düğümden sanal sınır düğümlere kadar geçen süre, yol üzerindeki ağırlıklara ve bunların uzaysal mesafesine bağlı olduğundan, görüntünün merkezi ile arka plan bölgesi farkı belirgin olmaktadır. HABCFA-MC karşılaştırması: MC yöntemi, F-measure ve MAE değerleri açısından daha avantajlı görünmektedir. Ancak HABCFA farklı datasetler için hemen hemen aynı çalışma sürelerine sahiptir ve MC farklı datasetlerde farklı çalışma sürelerinde çalışmıştır. HABCFA MC yöntemine alternatif olarak kullanılabilir bir yöntemdir. Ancak çalışma süresi açısından, MC farklı görüntüler için farklı çalışma sürelerine sahip olacağından daha tutarsız bir yapı sergilemektedir.
GMR	<ul style="list-style-type: none"> Aşağıdan yukarıya yaklaşıma sahip bir yöntemdir. Belirgin alan tespitinde “GMR (Graph-Based Manifold Ranking)” yönteminden yararlanılmıştır. GMR ile aracılığıyla görüntü öğelerinin benzerliği ön plan veya arka plan bilgileri ile sıralanmıştır. Görüntü, düğümler olarak süper-piksellere sahip bir kapalı döngü grafiği (close-loop graph) olarak temsil edilmektedir. Bu düğümler, arka plan ve ön plan sorgularına olan benzerliğe göre sıralanmaktadır. HABCFA-GMR karşılaştırması: GMR yöntemi, F-measure ve MAE değerleri açısından daha avantajlı görünmektedir. Ancak HABCFA’da çalışma sürelerindeki standart sapma GMR yönteminden daha az olarak karşımıza çıkmaktadır. Bu durum, GMR yönteminin görüntülerdeki farklı zorluk derecelerinden (çalışma süresi açısından) daha çok etkilendiğini göstermektedir. Ayrıca HABCFA daha kısa çalışma sürelerinde benzer özelliklere sahip belirginlik haritalarını elde edebilmektedir.

Tablo 6.5. (Devamı)

SeR	<ul style="list-style-type: none"> • Aşağıdan yukarıya yaklaşıma sahip bir yöntemdir. • Belirgin alan tespitinde "kendine benzerlik (self-resemblance)" ölçüsü ve "matris kosinüs benzerliği (kosinüs benzerliğinin bir genellemesi)" yöntemlerinden yararlanılmıştır. • <u>HABCFA- SeR karşılaştırması:</u> SeR yöntemi, F-measure ve MAE değerleri açısından daha avantajlı görünmektedir. Ancak HABCFA'da çalışma sürelerindeki standart sapma SeR yönteminden daha az olarak karşımıza çıkmaktadır. Bu durum, SeR yönteminin görüntülerdeki farklı zorluk derecelerinden (çalışma süresi açısından) daha çok etkilendiğini göstermektedir. Ayrıca HABCFA daha kısa çalışma sürelerinde benzer özelliklere sahip belirginlik haritalarını elde edebilmektedir.
------------	---

HS	<ul style="list-style-type: none"> • Aşağıdan yukarıya yaklaşıma sahip bir yöntemdir. • Belirgin alan tespiti için hiyerarşik bir model önerilmiştir. • Bu modelde ölçekli bir yol izlenmiş ve belirginlik ipuçlarını analiz etmek için çok katmanlı bir yaklaşım sunulmuştur. Nihai belirginlik haritası, hiyerarşik bir modelde üretilmektedir ve ölçek tabanlı bölge işleme yönteminde, bir ağaç modeli kullanılarak belirginlik değerleri bulunmaktadır. • <u>HABCFA- HS karşılaştırması:</u> HS yöntemi, F-measure ve MAE değerleri açısından daha avantajlı görünmektedir. Ancak HABCFA'da çalışma sürelerindeki standart sapma HS yönteminden daha az olarak karşımıza çıkmaktadır. Bu durum, HS yönteminin görüntülerdeki farklı zorluk derecelerinden (çalışma süresi açısından) daha çok etkilendiğini göstermektedir. Ayrıca HABCFA daha kısa çalışma sürelerinde benzer özelliklere sahip belirginlik haritalarını elde edebilmektedir.
-----------	--

BÖLÜM 7. SONUÇ

Günümüzde görüntü işleme teknikleri tıp, eğitim, bilim, güvenlik, askeri teknoloji gibi pek çok alanda aktif bir şekilde kullanılmaktadır. Bu durum daha hızlı ve daha doğru çözümlere olan ihtiyacı da arttırmaktadır. Pek çok alanda kullanımı popüler olan optimizasyon algoritmaları, son yıllarda sıkça görüntü işleme problemlerinin çözümünde de kullanılmaktadır. Ancak popüler görüntü işleme problemlerinden biri olan, görüntülerde belirgin alan tespiti problemlerinde, ABC ve FA sürü tabanlı metasezgisel optimizasyon algoritmalarının kullanılmamış olduğu tespit edilmiştir.

Bu problemin çözümü için önerilen yöntemler genellikle ön eğitim aşaması gerektiren veya ön bilgi gerektiren yaklaşımlardır. Bu çalışmada, bu tür fazladan bilgiye ihtiyaç duymaksızın, görüntülerdeki dikkat çeken alanların yani belirginlik haritalarının çıkarılması amaçlanmıştır. Bunun için öncelikle ABC ve FA algoritmalarının hibrit birleşimi olan HABCFA optimizasyonu geliştirilmiştir. Geliştirilen hibrit yöntemde, sürüdeki bireyler hem arı hem de ateş böceği gibi davrandığından iki algoritmanın da avantajlarından yararlanılmıştır. ABC, FA ve HABCFA algoritmaları performans açısından karşılaştırılmış, HABCFA'nın her iki yöntemden de daha erken doğru sonuca yakınsadığı ayrıca FA'dan da çok daha hızlı yakınsama süresine sahip olduğu dört benchmark problem üzerinde analiz edilerek gösterilmiştir.

Bu çalışmada gerçekleştirilen HABCFA ile görüntülerde belirginlik tespiti, ön işlem, sınıflandırma, başlangıç arka plan değerini elde etme, bu değerini HABCFA ile optimize edilmesi ve bulunan optimum arka plan değerine göre belirginlik haritasının çıkarımı şeklinde beş temel adımı içermektedir. Ön işlem aşamasında, RGB renk uzayındaki renkli giriş görüntüsü gri seviyeli görüntüye çevrilmektedir ve gürültüden kurtulmak için Gaussian filtreden yararlanılmaktadır. İkinci aşama olarak SLIC super piksel sınıflandırma yöntemi uygulanarak arama uzayındaki karmaşıklığın

azaltılması amaçlanmıştır. Üçüncü aşamada sınıflandırılmış görüntünün kenar bölgelerinden optimize edilecek olan başlangıç arka plan değeri bulunmaktadır. Dördüncü aşamada, HABCFA optimizasyonunun uygulanması sonucu elde edilen optimum arka plan değeri bulunmaktadır. Son olarak, bulunan optimum arka plan değeri ile görüntünün farkının alınması sonucunda belirginlik haritası elde edilmektedir.

HABCFA ve diğer yöntemler çalışma süreleri açısından 4 veri seti üzerinde karşılaştırılmıştır. Elde edilen sonuçlara göre, HABCFA, MSRA veri seti üzerinde beşinci, ECSSD veri setinde üçüncü, ICOSEG veri setinde üçüncü ve DUTOMRON veri setinde birinci en hızlı çalışan yöntem olmuştur. Çalışma sürelerindeki standart sapma değerlerine göre görüntülerdeki zorluk derecesinin, HABCFA'nın çalışma süresi üzerinde bir etkisi olmadığı da görülmüştür. Belirginlik tespiti problemlerinde görüntü karmaşıklığının, doğru sonucu almayı zorlaştırdığı bir gerçektir. Görüntülerdeki karmaşıklığın artmasına rağmen, çalışma sürelerinin etkilenmemesi de HABCFA yönteminin sunmuş olduğu bir diğer avantajdır.

HABCFA yönteminin en önemli farkı herhangi bir ön bilgi veya eğitim aşaması içermeden dikkat çekici nesnelere bulabilmesidir. HABCFA ile ilk defa karşılaşılan bir giriş görüntüsü için optimum bir arka plan değeri belirlenebilmektedir. Bu durum hem bir ön eğitim aşaması olmadığından zamandan, hem de ön bilgi kullanılmadığından hafızadan tasarruf edilmesini sağlamaktadır.

4 ayrı veri seti üzerinde yapılan deneysel sonuçlar, HABCFA optimizasyon yönteminin, literatürdeki 11 state-of-the-art metota alternatif olarak kullanılabileceğini göstermiştir. Daha sonraki çalışmalarda karmaşık veya birden çok dikkat çekici nesne bulunduran görüntüler üzerindeki performansın, farklı metasezgisel optimizasyon algoritmalarının kullanılması ve desen, şekil gibi farklı kriterlerin de göz önüne alınması ile artırılması amaçlanmaktadır.

KAYNAKLAR

- [1] Rafael C. Gonzalez and Richard E. Woods. 2006. Digital Image Processing (3rd edition). Prentice-Hall, Inc., USA.
- [2] Wei Zhang, QM Jonathan Wu, Guanghui Wang, Haibing Yin, An adaptive computational model for salient object detection, *IEEE Trans. Multimed.* 12 (4) (2010) 300–316.
- [3] Karaboga, D., An idea based on honey bee swarm for numerical optimization, Tech. Rep. TR06, Erciyes University, Kayseri, Turkey, 2005.
- [4] Yang, XS.: Firefly Algorithms for Multimodal Optimization. In: Watanabe, O., Zeugmann, T. (eds) *Stochastic Algorithms: Foundations and Applications. SAGA 2009. LNCS*, vol 5792, pp. 169-178. Springer, Berlin, Heidelberg (2009).
- [5] Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., Süsstrunk, S., (2012), SLIC superpixels compared to state of-the-art superpixel methods, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11), 2274-2282
- [6] R. Zhao, W. Ouyang, H. Li, X. Wang, Saliency detection by multi-context deep learning, *International Conference on Computer Vision and Pattern Recognition (CVPR)*, syf. 1265-1274, 2015.
- [7] Learning to Detect Salient Objects With Image-Level Supervision, Lijun Wang ve ark., 2017.
- [8] J. Yang, M.H. Yang, Top-down visual saliency via joint CRF and dictionary learning, *IEEE Trans. Pattern Anal. Mach. Intell.* 39 (2017) 576–588. <https://doi.org/10.1109/TPAMI.2016.2547384>.
- [9] T. Liu, Z. Yuan, J. Sun, J. Wang, N. Zheng, X. Tang, H.Y. Shum, Learning to detect a salient object, *IEEE Trans. Pattern Anal. Mach. Intell.* 33 (2011) 353–367. <https://doi.org/10.1109/TPAMI.2010.70>.
- [10] Rahtu, E., Kannala, J., Salo, M., Heikkilä, J.: Segmenting salient objects from images and videos. In: Daniilidis, K., Maragos, P., Paragios, N. (eds.) *ECCV 2010. LNCS*, vol. 6315, pp. 366–379. Springer, Heidelberg (2010),

- [11] R. Fergus, P. Perona, A. Zisserman, Object class recognition by unsupervised scale-invariant learning, in: Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., 2003: pp. 264–271. <https://doi.org/10.1109/cvpr.2003.1211479>.
- [12] A simple saliency detection approach via automatic top-down feature fusion, Yu Qiu, Yu Liu vs, 2020.
- [13] Efficient saliency detection using convolutional neural networks with feature selection, F. Cao vs, 2018.
- [14] Contrast Prior and Fluid Pyramid Integration for RGBD Salient Object Detection, 2019.
- [15] Saliency driven region-edge-based top down level set evolution reveals the asynchronous focus in image segmentation, Xu-Hao Zhi, Hong-Bin Shen, 2018.
- [16] Saliency ranker: A new salient object detection method, Zun Li ve ark. , 2018.
- [17] A unified approach to salient object detection via low rank matrix recovery, 2012.
- [18] Touch Saliency: Characteristics and Prediction, 2014.
- [19] L. Itti, C. Koch, E. Niebur, A model of saliency-based visual attention for rapid scene analysis, IEEE Trans. Pattern Anal. Mach. Intell. 20 (1998) 1254–1259. <https://doi.org/10.1109/34.730558>.
- [20] X. Hou, L. Zhang, Saliency detection: A spectral residual approach, in: Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., 2007: pp. 1–8. <https://doi.org/10.1109/CVPR.2007.383267>.
- [21] Chenlei Guo, Qi Ma, Liming Zhang. Spatio-temporal saliency detection using phase spectrum of quaternion fourier transform, in: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2008, IEEE, syf. 1–8, 2008.
- [22] Y. Ma, H. Zhang, Contrast-based image attention analysis by using fuzzy growing, in: Proceedings of the Eleventh ACM International Conference on Multimedia, ACM, Berkeley, CA, USA, 2003, pp. 374–381.
- [23] C. Yang, L. Zhang, H. Lu, X. Ruan, M.H. Yang, Saliency detection via graph-based manifold ranking, in: Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., 2013: pp. 3166–3173. <https://doi.org/10.1109/CVPR.2013.407>.

- [24] Yichen Wei, Fang Wen, Wangjiang Zhu, Jian Sun Geodesic Saliency Using Background Priors, 2012
- [25] H. Lu, X. Li, L. Zhang, X. Ruan, M.H. Yang, Dense and Sparse Reconstruction Error Based Saliency Descriptor, *IEEE Trans. Image Process.* 25 (2016) 1592–1603. <https://doi.org/10.1109/TIP.2016.2524198>
- [26] B. Jiang, L. Zhang, H. Lu, C. Yang, M.H. Yang, Saliency detection via absorbing Markov Chain, in: *Proc. IEEE Int. Conf. Comput. Vis.*, Institute of Electrical and Electronics Engineers Inc., 2013: pp. 1665–1672. <https://doi.org/10.1109/ICCV.2013.209>.
- [27] A Saliency Detection Model Using Low-Level Features Based on Wavelet Transform, N. Imamoglu ve ark.
- [28] Ming-Ming Cheng; Niloy J. Mitra; Xiaolei Huang; Philip H. S. Torr; Shi-Min Hu Global Contrast Based Salient Region Detection, 2011
- [29] Saliency filters: Contrast based filtering for salient region detection, 2012, Federico Perazzi; Philipp Krähenbühl; Yael Pritch; Alexander Hornung
- [30] Visual saliency detection by spatially weighted dissimilarity, L. Duan, 2011
- [31] R. Achanta, S. Hemami, F. Estrada, S. Susstrunk, Frequency-tuned salient region detection, in: *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, Institute of Electrical and Electronics Engineers (IEEE), 2010: pp. 1597–1604. <https://doi.org/10.1109/cvpr.2009.5206596>.
- [32] S. Goferman, L. Zelnik-Manor, A. Tal, Context-aware saliency detection, *IEEE Trans. Pattern Anal. Mach. Intell.* 34 (2012) 1915–1926. <https://doi.org/10.1109/TPAMI.2011.272>.
- [33] H. Rezazadegan Tavakoli, E. Rahtu, J. Heikkilä, Fast and efficient saliency detection using sparse sampling and kernel density estimation, in: *Lect. Notes Comput. Sci. (Including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, Springer, Berlin, Heidelberg, 2011: pp. 666–675. https://doi.org/10.1007/978-3-642-21227-7_62.
- [34] H.J. Seo, P. Milanfar, Static and space-time visual saliency detection by self-resemblance, *J. Vis.* 9 (2009) 1–27. <https://doi.org/10.1167/9.12.15>.
- [35] Q. Yan, L. Xu, J. Shi, J. Jia, Hierarchical saliency detection, in: *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, 2013: pp. 1155–1162. <https://doi.org/10.1109/CVPR.2013.153>.
- [36] Top-down saliency detection driven by visual classification, Francesca Murabito ve ark, 2018

- [37] A face detection using biologically motivated bottom-up saliency map model and top-down perception model, Sang-Woo Ban *et al.*, 2004
- [38] Rethinking feature aggregation for deep RGB-D salient object detection, 2021, Yuan-fang Zhang, Jiangbin Zheng, Long Li, Nian Liu, Wenjing Jia, Xiaochen Fan, Chengpei Xu, Xiangjian He,
- [39] An Iterative and Cooperative Top-Down and Bottom-Up Inference Network for Salient Object Detection, 2019, Wenguan Wang 1, Jianbing Shen*1, Ming-Ming Cheng 2, Ling Shao 1
- [40] Salient object detection based on eye tracking data, 2018, Fen Xiao, Liangchan Peng, Lei Fu, Xieping Gao,
- [41] Webly-supervised learning for salient object detection, Ao Luo *et al.*, 2020
- [42] H.Y. Chen, J.J. Leou, Saliency-directed image interpolation using particle swarm optimization, *Signal Processing*. 90 (2010) 1676–1692. <https://doi.org/10.1016/j.sigpro.2009.11.019>.
- [43] N. Singh, R. Arya, R.K. Agrawal, A novel approach to combine features for salient object detection using constrained particle swarm optimization, *Pattern Recognit.* 47 (2014) 1731–1739. <https://doi.org/10.1016/j.patcog.2013.11.012>.
- [44] K.Y. Chang, T.L. Liu, H.T. Chen, S.H. Lai, Fusing generic objectness and visual saliency for salient object detection, in: *Proc. IEEE Int. Conf. Comput. Vis.*, 2011: pp. 914–921. <https://doi.org/10.1109/ICCV.2011.6126333>.
- [45] W. Zhu, S. Liang, Y. Wei, J. Sun, Saliency Optimization from Robust Background Detection, *IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, syf. 2814-2821, 2014.
- [46] Z. Lei, W. Chai, S. Zhao, H. Song, F. Li, “Saliency detection for RGBD image using Optimization”, *The 12th International Conference on Computer Science & Education (ICCSE 2017)* .
- [47] L. Ma, J. Tian and W. Yu, Visual saliency detection in image using ant colony optimisation and local phase coherence, *Electronics Letters* vol. 46 syf. 1066-1068 Jul. 2010.
- [48] Chi-Yu Lee, Jin-Jang Leou, Han-Hui Hsiao, Saliency-directed color image segmentation using modified particle swarm optimization, *Signal Processing*, Volume 92, Issue 1, syf. 1-18, 2012.
- [49] Yuri Owechko, Swamp Medasani, and Narayan Srinivasa, Classifier Swarms for Human Detection in Infrared Imagery, *Conference on Computer Vision and Pattern Recognition Workshop (CVPRW'04)* Vol. 8 syf. 121, 2004.

- [50] A.A. Varghese, J.E. Rajan, A Fire Fly Optimization Based Video Object Co-Segmentation, *Int. J. Eng. Res. Sci.* 2 (2016) 57–63.
- [51] M.H. Horng, Multilevel thresholding selection based on the artificial bee colony algorithm for image segmentation, *Expert Syst. Appl.* 38 (2011) 13785–13791. <https://doi.org/10.1016/j.eswa.2011.04.180>.
- [52] Karakoç M., *Görüntü İşleme, Teknolojiler ve uygulamaları*, Ege Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalı, 50, Uşak, Türkiye, Şubat, 2012.
- [53] Umbaugh, S. E. (1998) *Comp. Vision and Image Proc.*, Prentice-Hall, International Inc., Upper Saddle River, New Jersey.
- [54] W.K. Pratt, J. Kane and H. C. Andrews, Hadamard transform image coding, *Proceeding of IEEE*, vol.57, no.1, pp.58-68, Jan.1969.
- [55] Akyol S., Alataş B., 2012, Güncel Sürü Zekâsı Optimizasyon Algoritmaları, Nevşehir Üniversitesi Fen Bilimleri Enstitü Dergisi 1, syf. 36-50.
- [56] Millonas,M., 1994, *Artificial Life III, Chapter Swarms, Phase Transitions, And Collective Intelligence*, Reading, MA:Addison-Wesley.
- [57] Barth F. G. 1982, *Insects and Flowers: The Biology of a Partnership*, Princeton, N.J.: Princeton University Press.
- [58] Akay B., 2009 (a), Nümerik Optimizasyon Problemlerinde Yapay Arı Kolonisi Algoritmasının Performans Analizi, *Fen Bilimleri Enstitüsü, Erciyes Üniversitesi*,325 syf.
- [59] Nezamabadi-pour H., Saryazdi S., Rashedi E., 2006, Edge detection using ant algorithms, *Soft Comput* 10: 623–628 syf.
- [60] Yang, X.S. (2010). Firefly Algorithm, Levy Flights and Global Optimization. In: Bramer, M., Ellis, R., Petridis, M. (eds) *Research and Development in Intelligent Systems XXVI*.Springer, London.
- [61] Jamil, M., & Yang, X. S. (2013). A literature survey of Benchmark functions for global optimization problems. arXiv preprint arXiv:1308.4008.
- [62] Danacı, M., & Alızada, B., “An Improvement Of Hybrid Whale Optimization Algorithm,” *Euroasia Journal of Mathematics-Engineering Natural & Medical Sciences*, vol.2, 60-68, 2019. [37] Yao X, Liu Y, Lin G. “Evolutionary programming made faster,” *IEEE Trans Evol Comput*,3:82–102, 1999.

- [63] Schumer, M.A. and Steiglitz, K., Adaptive step size random search, IEEE Transactions on Automatic Control, Vol. 13, No. 3, pp.270–276, 1968.
- [64] T. Bäck, H. P. Schwefel, An Overview of Evolutionary Algorithm for Parameter Optimization, Evolutionary Computation, vol. 1, no. 1, pp. 1-23, 1993.
- [65] M. C. Fu, J. Hu, S. I. Marcus, Model-Based Randomized Methods for Global Optimization, Proc. 17th International Symp. Mathematical Theory Networks Systems, Kyoto, Japan, pp. 355-365, 2006.
- [66] H. P. Schwefel, Numerical Optimization for Computer Models, John Wiley Sons,1981.
- [67] Mirjalili, S. (2015). The ant lion optimizer. Advances in Engineering Software, 83, 80-98.
- [68] D. Batra, A. Kowdle, D. Parikh, J. Luo, T. Chen, Interactively co-segmentating topically related images with intelligent scribble guidance, Int. J. Comput. Vision 93 (3) (2011) 273–292.

ÖZGEÇMİŞ

Adı Soyadı : Elif Deniz YELMENOĞLU

ÖĞRENİM DURUMU

Derece	Eğitim Birimi	Mezuniyet Yılı
Doktora	Sakarya Üniversitesi / Fen Bilimleri Enstitüsü / Bilgisayar ve Bilişim Mühendisliği	Devam ediyor
Yüksek Lisans	Selçuk Üniversitesi / Fen Bilimleri Enstitüsü / Bilgisayar Mühendisliği	2015
Lisans	Selçuk Üniversitesi / Mühendislik ve Mimarlık Fakültesi / Bilgisayar Mühendisliği	2011
Lise	Muğla Anadolu Lisesi	2007

İŞ DENEYİMİ

Yıl	Yer	Görev
2012-2020	Işık Üniversitesi Bilgisayar Mühendisliği	Araştırma Görevlisi
2020- Devam ediyor	Işık Üniversitesi Enformasyon Teknolojileri Bölümü	Öğretim Görevlisi

YABANCI DİL

İngilizce

ESERLER (makale, bildiri, proje vb.)

1. E. D. YELMENOĞLU & N. BAYKAN, Edge Detection Using Artificial Bee Colony Algorithm(abc), 2013 4th International Conference On Software And Computing Technology (icsct 2013), 24 -25 October 2013, 2010-3719, 3, 6, 634 - 638.

2. E. D. YELMENOĞLU, N. ÇELEBİ & T. TAŞCI, A Novel Hybrid Edge Detection Technique: Abc-fa, Tam Metin Bildiri, International Conference On Technology, Engineering And Science, 26 October 2017, 29 October 2017, 2602-3199, 193 - 200.
3. E. D. YELMENOĞLU, N. ÇELEBİ & T. TAŞCI, Saliency Detection with Hybrid Artificial Bee Colony- Firefly Optimization Method, ICCESN-2018, 12 - 16 October 2018.
4. Yelmenoglu, E.D., Celebi, N. & Tasci, T. Saliency detection based on hybrid artificial bee colony and firefly optimization. *Pattern Analysis Application* (2022). <https://doi.org/10.1007/s10044-022-01063-6>