

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAPAY ZEKA VE ROBOTİK ANABİLİM DALI

**AFRİKA AKBABALARI OPTİMİZASYONU KULLANILARAK GEZGİN
SATICI PROBLEMİNİN ÇÖZÜMÜ İÇİN VERİMLİ BİR BAŞLANGIÇ
POPÜLASYONU OLUŞTURMA**

YÜKSEK LİSANS TEZİ

Veli AKAY
Danışman: Prof. Dr. Rıdvan SARAÇOĞLU

VAN – 2025

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAPAY ZEKA VE ROBOTİK ANABİLİM DALI

**AFRİKA AKBABALARI OPTİMİZASYONU KULLANILARAK GEZGİN
SATICI PROBLEMİNİN ÇÖZÜMÜ İÇİN VERİMLİ BİR BAŞLANGIÇ
POPÜLASYONU OLUŞTURMA**

YÜKSEK LİSANS TEZİ

Veli AKAY

Tez Savunma Sınavı Jüri Üyeleri

Prof. Dr. Rıdvan SARAÇOĞLU (Başkan)

Dr. Öğr. Üyesi Fikriye Ataman (Üye)

Dr. Öğr. Üyesi Yavuz Ünal (Üye)

KABUL VE ONAY SAYFASI

Van Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü, Yapay Zeka ve Robotik Anabilim Dalı'nda Prof. Dr. Rıdvan SARAÇOĞLU danışmanlığında, Veli AKAY tarafından sunulan “Afrika Akbabaları Optimizasyonu kullanılarak Gezgin Satıcı Probleminin çözümü için verimli bir başlangıç popülasyonu oluşturma” başlıklı bu çalışma Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili hükümleri gereğince 22/05/2025 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile başarılı bulunmuş ve Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan: Prof. Dr. Rıdvan SARAÇOĞLU

İmza:

Üye: Dr. Öğr. Üyesi Fikriye ATAMAN

İmza:

Üye: Dr. Öğr. Üyesi Yavuz ÜNAL

İmza:

Üye:

İmza:

Üye:

İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun / / tarih ve sayılı kararı ile onaylanmıştır.

İmza

.....

Enstitü Müdürü

ETİK BEYAN

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Veli AKAY



ÖZET

AFRİKA AKBABALARI OPTİMİZASYONU KULLANILARAK GEZGİN SATICI PROBLEMİNİN ÇÖZÜMÜ İÇİN VERİMLİ BİR BAŞLANGIÇ POPÜLASYONU OLUŞTURMA

AKAY, Veli

Yüksek Lisans Tezi, Yapay Zeka ve Robotik Anabilim Dalı

Danışman: Prof. Dr. Rıdvan SARAÇOĞLU

Haziran 2025, 61 sayfa

Günümüzde teknolojinin ve bilimin hızla ilerlemesi, optimizasyon problemlerinin çözümüne yönelik yeni yaklaşımların geliştirilmesine olanak sağlamaktadır. Optimizasyon, yaşamın çeşitli alanlarında karşılaşılan karmaşık problemlerin doğru ve etkin bir şekilde çözülmesine olanak tanıyarak karar süreçlerinin hızlanmasına katkıda bulunmada ve sonuçların doğruluğunu artırmaktadır. Bu çalışmada, AVOA(Afrika Akbabaları Optimizasyonu) algoritması, birçok gerçek dünya probleminde olduğu gibi GSP(Gezgin Satıcı Problemi) için uyarlanmıştır. GSP, bir satıcının tüm şehirleri yalnızca bir defa ziyaret edip başlangıç konumuna geri dönerek toplam yolculuk maliyetini en aza indirmeyi amaçlayan klasik bir kombinatoriyal optimizasyon problemidir. Algoritmanın performansını artırmak için başlangıç popülasyonunun oluşturulmasında Sobol dizileri kullanılmış, ayrıca başlangıç popülasyonunun iyileştirilmesi amacıyla DBSCAN ve En Yakın Komşu (EYK) algoritmaları entegre edilmiştir. Sobol dizilerinin düşük sapma özelliği, çözüm uzayını homojen biçimde tarayarak algoritmanın çözüm kalitesine katkı sağlamıştır. Çalışma kapsamında, TSPLIB'den alınan 51 şehirlik(eil51) ve 280 şehirlik(a280) veri setleri kullanılarak Sobol tabanlı AVOA algoritmasının çeşitli varyantlarının performansı değerlendirilmiştir. Elde edilen bulgular, Sobol dizileriyle oluşturulan başlangıç popülasyonunun, rastgele yaklaşımlara kıyasla daha yüksek çözüm kalitesi ve daha tutarlı sonuçlar sağladığını ortaya koymuştur. Özellikle AVOA+EYK+SOBOL yaklaşımı, her iki veri setinde de en uygun çözümlerden bazılarını sunmuş ve düşük sapma ile standart sapma değerleri sayesinde istikrarlı sonuçlar elde edilmiştir. Ancak, MAGA algoritmasının en düşük ortalama çözüm değeri ile genel anlamda en başarılı sonucu verdiği gözlemlenmiştir. Bu bulgular, sezgisel ve meta-sezgisel algoritmaların optimizasyon problemlerindeki etkinliğini bir kez daha teyit etmektedir. Çalışma kapsamında, Sobol dizilerinin başlangıç popülasyonu oluşturmada sağladığı avantajlar ortaya konmuş ve AVOA algoritmasının, GSP gibi karmaşık optimizasyon problemlerine başarılı biçimde uyarlanabileceği gösterilmiştir. Bununla birlikte, başlangıç popülasyonunda yerel iyileştirme algoritmalarının entegrasyonu sayesinde AVOA'nın performansında belirgin bir artış sağlanmış, çözüm kalitesinde de anlamlı iyileşmeler elde edilmiştir. Gelecekte gerçekleştirilecek çalışmalarda, farklı hibrit optimizasyon yöntemlerinin değerlendirilmesi önerilmektedir.

Anahtar kelimeler: Afrika akbabaları optimizasyonu, Başlangıç popülasyonu, Düşük sapma, Gezgin satıcı problemi, Optimizasyon, Sobol dizileri



ABSTRACT

CREATING AN EFFICIENT INITIAL POPULATION TO SOLVE THE TRAVELING SALESMAN PROBLEM USING AFRICAN VULTURE OPTIMIZATION

AKAY, Veli

M.Sc. Thesis, Department of Artificial Intelligence and Robotics

Supervisor: Prof. Dr. Rıdvan SARAÇOĞLU

June 2025, 61 pages

In recent years, the rapid advancement of science and technology has facilitated the development of novel approaches for addressing optimization problems. Optimization plays a critical role in solving complex problems across various domains by enhancing both the efficiency of decision-making processes and the accuracy of results. This study investigates the application of the African Vultures Optimization Algorithm (AVOA) to the Traveling Salesman Problem (TSP), a classical combinatorial optimization problem that seeks to minimize the total travel cost by requiring a salesman to visit each city exactly once and return to the point of origin. To improve the algorithm's performance, Sobol sequences were employed for generating the initial population, to improve the initial population, the DBSCAN and Nearest Neighbor (NN) algorithms were integrated.. The low-discrepancy property of Sobol sequences contributed to a more uniform exploration of the solution space, thereby enhancing solution quality. The empirical evaluation utilized two benchmark datasets from TSPLIB, namely eil51 (51 cities) and a280 (280 cities), to assess the performance of various Sobol-based AVOA variants. The results demonstrated that the initial population generated via Sobol sequences yielded superior solution quality and more stable outcomes compared to random initialization methods. Notably, the AVOA+NN+SOBOL variant produced some of the best solutions across both datasets, achieving robust performance characterized by low deviation and standard deviation values. However, the MAGA algorithm was found to deliver the overall best performance with the lowest mean solution value. Overall, the findings reaffirm the effectiveness of metaheuristic algorithms in addressing complex optimization problems. This study highlights the potential of Sobol sequences in enhancing initial population diversity and confirms the adaptability of the AVOA algorithm to challenging problems such as the TSP. Furthermore, the integration of local improvement techniques was shown to substantially improve the algorithm's performance and solution quality. Future research is encouraged to explore alternative hybrid optimization strategies to further advance the state of the art in this field.

Keywords: African vulture optimization Algorithm, Initial population, Low-discrepancy, Optimization, Sobol sequences, Traveling salesman problem



TEŞEKKÜR

Bu tez çalışmasında, her türlü ilgi ve yardımlarını esirgemeyen, değerli bilgi ve deneyimleriyle bana rehberlik eden danışmanım Prof. Dr. Rıdvan Saraçođlu'na en içten teşekkürlerimi sunarım. Tez sürecimde yol gösterici katkıları, sabrı ve desteđi benim için çok kıymetli olmuştur. Ayrıca, eğitim hayatım boyunca bilgi ve tecrübeleriyle bana ışık tutan, derslerime girerek akademik gelişimime katkı sağlayan Yapay Zeka ve Robotik bölümü hocalarına teşekkür ederim. Verdikleri kıymetli bilgiler, teşvik edici yaklaşımları ve akademik destekleri sayesinde bu çalışmayı tamamlayabildim. Desteklerini her zaman hissettiđim sevgili eşim Aysel AKAY ve arkadaşlarıma da teşekkürü bir borç bilirim. Onların manevi desteđi, bu süreci daha kolay ve anlamlı kılmıştır.

Teşekkürlerimle...

2025
Veli AKAY



İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER.....	vii
ÇİZELGELER LİSTESİ	ix
ŞEKİLLER LİSTESİ.....	xi
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ.....	1
2. KAYNAK BİLDİRİŞLERİ	3
2.1 Başlangıç Popülasyonu Üzerine Yapılmış Çalışmalar	3
2.2 Gezgin Satıcı Problemi ile İlgili Çalışmalar.....	11
3. MATERYAL VE YÖNTEM.....	21
3.1 Gezgin Satıcı Problemi(GSP).....	21
3.2 Afrika Akbabaları Optimizasyon Algoritması(AVOA)	22
3.2.1 Algoritmanın Temel Bileşenleri	22
3.3 Başlangıç Popülasyonu Oluşturma.....	27
3.3.1 Sobol Dizileri	30
3.3.2 Dbscan Algoritması.....	32
3.3.3 En Yakın Komşu Sezgiseli(EYK).....	34
3.4 Önerilen Yöntem	34
4. BULGULAR.....	37
4.1 Kullanılan Veri Seti.....	37
4.2 Kullanılan Parametreler.....	37
4.3 Değerlendirme Kriterleri	38
4.4 Sobol ve Rastgele Yöntem Karşılaştırma.....	40
4.5 DBSCAN Kümeleme Algoritması Karşılaştırma.....	42
4.6 EYK Sezgiseli Karşılaştırma	43
4.7 Genel Karşılaştırma	45
4.7.1 Klasik AVOA (Çizelge 4.4) ve DBSCAN ile Başlatılmış AVOA (Çizelge 4.5)	47
4.7.2 Klasik AVOA (Çizelge 4.4) ve EYK ile Başlatılmış AVOA (Çizelge 4.6)	48
4.7.3 DBSCAN ve EYK (Çizelge 4.5 ve Çizelge 4.6).....	49
4.7.4 Genel Değerlendirme	49
4.8 Literatür ile Karşılaştırma	50

5. TARTIŞMA VE SONUÇ	53
KAYNAKLAR.....	55
ÖZ GEÇMİŞ.....	61



ÇİZELGELER LİSTESİ

	Sayfa
Çizelge 4.1 Genel parametreler	37
Çizelge 4.2 DBSCAN için kullanılan parametreler.....	37
Çizelge 4.3 AVOA için kullanılan parametreler	37
Çizelge 4.4 Sobol ve rastgele başlangıç ile oluşturulan yöntem sonuçları.....	40
Çizelge 4.5 DBSCAN ile başlatılan yöntem sonuçları.....	42
Çizelge 4.6. EYK ile başlatma sonuçları	44
Çizelge 4.7. Literatür İle Karşılaştırma	51



ŞEKİLLER LİSTESİ

	Sayfa
Şekil 3.1 AVOA akış diyagramı.....	27
Şekil 3.2 Metasezgisel optimizasyon süreci.....	28
Şekil 3.3 Başlangıç popülasyonu oluşturma yöntemleri	29
Şekil 3.4 Sobol dizisi oluşturma adımları.....	32
Şekil 4.1 (a) eil 51 yakınsama eğrisi, (b) eil51 en iyi rota, (c) a280 yakınsama eğrisi, (d) a280 en iyi rota.....	41
Şekil 4.2 (a) eil 51 yakınsama eğrisi, (b) eil51 en iyi rota, (c) a280 yakınsama eğrisi, (d) a280 en iyi rota.....	43
Şekil 4.3 (a) eil 51 yakınsama eğrisi, (b) eil51 en iyi rota, (c) a280 yakınsama eğrisi, (d) a280 en iyi rota.....	45
Şekil 4.4 Ortalama çalışma süreleri (a) eil51 (b) a280.....	46
Şekil 4.5 Ortalama çözümler (a) eil51 (b) a280	46
Şekil 4.6 Standart sapmalar (a) eil51 (b) a280	46



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış olan bazı simgeler ve kısaltmalar, açıklamalarıyla birlikte aşağıda verilmiştir.

Simgeler

Açıklama

E(i)	Konum vektörü
F	Açlık oranı
K₁, K₂, K₃	Rastgele parametreler
k_i	En iyi akbaba
M_i	Mevcut iterasyon
MinPts	Minimum eleman sayısı
P	Popülasyon boyutu
TB	Tavlama benzetimi
TA	Tabu arama
λ₁, λ₂	Ağırlık katsayıları
ε	Epsilon

Kısaltmalar

Açıklama

AFOA	Ağaç Fizyolojisi Optimizasyon Algoritması
AVOA	Afrika Akbabaları Optimizasyon Algoritması
DBSCAN	Yoğunluk Tabanlı Kümeleme Algoritması
EYK	En Yakın Komşu
GA	Genetik Algoritma
GSP	Gezgin Satıcı Problemi
KKO	Karınca Kolonisi Algoritması
MAGA	Melez Akışkan Genetik Algoritma
PSO	Parçacık Sürü Optimizasyonu
TA	Tabu Arama



1. GİRİŞ

Gelişen teknoloji ve bilim ile birlikte, hayatımızda bilgisayar ve internet tabanlı uygulamaların rolü her geçen gün artmaktadır. Özellikle optimizasyon problemleri, çeşitli alanlarda etkili çözümler üretmek için giderek daha önemli hale gelmektedir. Optimizasyon, kısıtlı kaynakları en verimli şekilde kullanarak, belirli bir hedefe yönelik en uygun çözümü bulmayı amaçlayan bir tekniktir. Günümüzün karmaşık problemlere yönelik çözümleri hızlandırmak ve doğruluğu artırmak için optimizasyon algoritmalarına olan ihtiyaç giderek büyümektedir (Li vd., 2017).

Optimizasyon problemleri, genellikle çözüm uzayındaki alternatifleri değerlendirme ve en iyi çözümü bulma çabasıyla çözülür. Ancak, klasik yöntemler çoğu zaman büyük çözüm uzaylarıyla karşılaştığında yetersiz kalmaktadır. Bu noktada, meta-sezgisel algoritmalar devreye girer ve çözüm uzayında daha verimli aramalar yaparak, iyi çözümler elde edilmesini sağlar. Bu tür algoritmalar, gerçek dünyadaki problemleri çözmeye sıklıkla kullanılır (Elmas, 2024)

GSP, optimizasyon alanında yaygın olarak araştırılan ve çözülmesi zor olan klasik bir problemdir. GSP, belirli bir dizi şehirdeki noktaların her birini yalnızca bir kez ziyaret ederek başlangıç noktasına dönerek, toplam mesafeyi minimize etmeyi amaçlar. Problem, şehirlere ait sayılar arttıkça çözüm kümesinin büyümesi nedeniyle klasik yöntemlerle çözülmesi oldukça zorlaşır. Bu nedenle, meta-sezgisel algoritmalar, çözüm alanında hızlı bir şekilde iyi sonuçlar elde etmek için sıklıkla tercih edilir (Önay vd., 2014).

1.1 Tezin Amacı

Bu çalışmanın amacı, GSP'yi çözmek için Afrika Akbabaları Optimizasyonu (African vultures optimization algorithm, AVOA) yöntemini kullanarak, başlangıçta üretilen popülasyonların etkisini incelemektir. AVOA, doğada yaşayan akbabaların sosyal davranışlarını taklit ederek çözüm arayışında bulunan bir algoritmadır (Abdollahzadeh vd., 2021). Ancak, AVOA gibi meta-sezgisel algoritmaların etkinliği, kullanılan başlangıç popülasyonunun kalitesine doğrudan bağlıdır (Pulat vd., 2017). Bu bağlamda, Sobol dizileri kullanarak, başlangıç popülasyonunun daha homojen ve etkili bir şekilde oluşturulması sağlanmıştır. Sobol dizileri, düşük sapma özelliği sayesinde

özüm uzayını daha kapsamlı bir şekilde araştırarak, daha kaliteli çözümler elde edilmesine olanak tanır (Vesel, 2019).

Bu çalışmada, Sobol dizileri kullanılarak elde edilen başlangıç popülasyonları ile AVOA algoritmasının başarı düzeyi test edilmiştir. eil51 ve a280 veri setleri üzerinde gerçekleştirilen deneylerde, Sobol dizilerinin kullanımı ile elde edilen sonuçlar, rastgele başlangıç popülasyonu yöntemlerine kıyasla daha iyi performans göstermiştir. Bu doğrultuda, Sobol dizileri, başlangıç popülasyonunun kalitesini artırmak suretiyle çözümlerinin hem hızını hem de doğruluğunu olumlu yönde etkilemiştir.

Çalışmanın sonuçları, Sobol dizilerinin AVOA algoritmasının etkinliğini artırmak ve GSP gibi karmaşık problemlerde daha verimli sonuçlar almak için anlamlı bir yöntem olduğunu ortaya koymaktadır.

2. KAYNAK BİLDİRİŞLERİ

2.1 Başlangıç Popülasyonu Üzerine Yapılmış Çalışmalar

Gürsu ve İnce (2005), evrimsel algoritmalarda başlangıç popülasyonunun çözüm uzayındaki rolünü değerlendirmek amacıyla Halton, Hammersley ve Ortogonal dizilerle oluşturulan popülasyonları karşılaştırmıştır. Araştırmada, Rastrigin ve Rosenbrock fonksiyonlarının optimizasyon süreçlerinde bu farklı başlangıç yöntemlerinin global çözüme ulaşmadaki başarımı incelenmiştir. Elde edilen bulgular, Ortogonal dizilerle başlatılan popülasyonların daha az iterasyon ve kromozom kullanarak daha hızlı şekilde global optimuma ulaşabildiğini göstermiştir. Ayrıca, Halton ve Hammersley yöntemlerinin rastgele oluşturulan popülasyonlara kıyasla daha etkili olduğu, rastgele yöntemlerin ise zaman zaman lokal minimumlarda takılma eğilimi gösterdiği tespit edilmiştir.

Sanaç ve Karcı (2004), genetik algoritmalar kapsamında sözde rastgele oluşturulan başlangıç popülasyonlarının algoritmanın verimliliği üzerindeki etkilerini incelemiş ve bu popülasyonların genetik operatörlerle birlikte algoritmanın performansını nasıl etkilediğini araştırmıştır. Çalışmada, Halton dizileri kullanılarak oluşturulan sözde rastgele popülasyonlar ile n noktalı çaprazlama yöntemlerinin karşılıklı etkileri incelenmiştir. Sonuçlar, sözde rastgele popülasyonların çözüm uzayında daha dengeli bir dağılım sağladığını ve çaprazlama işlemlerinde şema bozulma olasılığını azalttığını göstermiştir. Bu durum, algoritmanın kaliteli çözümlere daha hızlı yakınsamasını sağlamıştır.

Rahnamayan vd. (2007), karşıt-temelli öğrenme (OBL) yöntemiyle geliştirilen evrimsel algoritmaların nüfus başlatma aşamasını hızlandıran bir yöntem geliştirmiş ve önerilen yöntemin, 34 farklı optimizasyon problemi üzerinde gerçekleştirilen deneylerde, rastgele başlatmaya kıyasla yaklaşık %10 oranında daha hızlı yakınsama sağladığını göstermiştir.

Çolak ve Güler (2009) çalışmasında, Genetik Algoritmalar (GA) kullanılarak Gezin Satıcı Problemi'ne çözüm üretilmiştir. Başlangıç popülasyonu oluşturulurken, yalnızca rastgele kromozomlardan oluşan bir popülasyon yerine, en yakın komşuluk yöntemi gibi sezgisel yöntemler ile bulunan çözümler de popülasyona dahil edilmiştir.

Bu yaklaşımın, rastgele başlangıç popülasyonu ile karşılaştırıldığında daha iyi sonuçlar ürettiği belirtilmiştir. Adana'da bir gıda lojistiği firması üzerinde yapılan testlerde, firmanın mevcut rotaları ile GA tarafından üretilen rotalar karşılaştırılmış ve toplam yol uzunluğunda ortalama %20 oranında iyileşme sağlandığı gösterilmiştir.

Kaya ve İnce (2010) çalışmalarında, Genetik Algoritmalar (GA) için başlangıç popülasyonunun arama uzayında eşit dağılımını sağlamak amacıyla Halton ve Hammersley gibi düzgün dağılımlı yöntemler kullanılarak, FIR filtre tasarımında pencere fonksiyonu performansına etkileri incelenmiştir. Bu yöntemlerin rastgele oluşturulan popülasyona kıyasla daha başarılı olduğu, daha küçük yan lob azaltma oranı ve dalgalanma oranı gibi yüksek performanslı sonuçlara ulaşıldığı görülmüştür. Kaiser penceresi ile yapılan karşılaştırmalarda, geliştirilen yaklaşımın genlik tepkisi yönünden daha iyi bir performans ortaya koyduğu belirtilmiştir.

Tometzki ve Engell (2011), iki aşamalı stokastik karışık tamsayı optimizasyon problemlerini çözmek amacıyla önerdikleri hibrit evrimsel algoritmalarda, tam sayılı programlamanın gevşetilmiş hali (LP), iki aşamalı gevşetme yaklaşımı (2SLP) ve beklenen değer modeline (EV) gibi yeni başlatma yöntemleriyle rastgele başlatma yöntemine kıyasla daha kısa sürede yüksek kaliteli çözümler elde edildiğini göstermiştir.

Zhang vd. (2011), esnek iş atölyesi çizelgeleme problemi (Flexible Job-Shop Scheduling Problem - FJSP) için etkili bir genetik algoritma geliştirmiştir. Bu algortmada başlangıç popülasyonunu oluşturmak için iki yenilikçi yöntem kullanılmıştır: Küresel Seçim (Global Selection - GS) ve Yerel Seçim (Local Selection - LS). Bu yöntemler, makineler arasındaki iş yükünü dengelemek ve işlem sürelerini optimize etmek amacıyla tasarlanmıştır. Yapılan hesaplamalı deneyler, GS ve LS yöntemlerinin bir arada kullanılmasının algoritmanın yakınsama hızını artırdığını ve çözüm kalitesini önemli ölçüde iyileştirdiğini göstermiştir. Örneğin, Mk04 veri setiyle yapılan deneylerde, GS ve LS yöntemlerinin kullanımıyla algoritma, optimum çözümü 40. nesilde elde ederken, yalnızca rastgele seçim yöntemi kullanıldığında bu sonuç 84. nesilde elde bulunmuştur.

Gören (2011) doktora çalışmasında, Kapasite Sınırlı Parti Büyüklüğü Problemi (KKPBP) için GA(Genetik Algoritma) temelli melez yaklaşımlar geliştirmiştir. Çalışmada, hazırlık işlemlerine ayrılan zaman, taşıma faaliyetleri ve yığılan sipariş özellikleriyle genişletilmiş KKPBP ele alınmış ve problem iki seviyede çözülmüştür. İlk seviyede, genetik algoritmaların "Fix-and-Optimize" sezgiseli ile ardışık ve iç içe

melezleme yöntemleri kullanılarak, hazırlık sürelerini ve hazırlık taşımasını içeren problemler çözülmüştür. İkinci seviyede ise bu modele birikmiş sipariş özelliği eklenmiş ve sekiz farklı GA tabanlı yaklaşım önerilmiştir. Gören'in çalışması, başlangıç popülasyonunun oluşturulması için probleme özgü bilgi ve rastgelelik içeren özgün bir yöntem önermiş ve bu yöntemlerin etkinliği çeşitli deneysel koşullar altında test edilmiştir.

Dong vd. (2012) çalışması, kaotik bir GA/PSO hibrit algoritması (CHA) sunarak, kaotik dinamikler ve genetik algoritmalarından türetilen seçim, çaprazlama ve mutasyon işlemlerini parçaçık sürü optimizasyonu (PSO) kurallarıyla birleştirmiş; kaotik başlangıç ve karşıt-temelli öğrenme (OBL) yöntemiyle nüfus başlatmasını hızlandırmış, multimodal optimizasyon problemlerini çözmek için tür-temelli CHA (SCHA) ile başarılı sonuçlar elde etmiş ve algoritmayı dairesel nesne algılamada yüksek doğrulukla uygulamıştır.

Ali vd. (2013) çalışmasında, başlangıç popülasyonu oluşturma yöntemleri olarak Karesel Yaklaşım Yöntemi ve Doğrusal Olmayan Simpleks Yöntemi kullanılarak, başlangıç popülasyonunun optimizasyon sürecindeki etkisinin artırılması hedeflenmiştir. Bu yöntemlerin, differential evolution algoritmasının performansını önemli ölçüde iyileştirdiği ve klasik yöntemlere göre daha yüksek hızlı bir yakınsama sağladığı gösterilmiştir. Çalışma, başlangıç popülasyonunun optimizasyon algoritmalarındaki kritik rolünü vurgulayarak, QI ve NSM yöntemlerinin, popülasyonu optimum çözüme daha yakın başlatma yeteneğinin algoritmanın genel başarısını artırdığını ortaya koymaktadır.

Pan vd. (2014), evrimsel algoritmaların yakınsama hızını ve çözüm kalitesini artırmayı amaçlayan Uyarlamalı Rastgelelik (Adaptive Randomness, AR) adlı yeni bir popülasyon başlatma yöntemi önermiştir. AR yöntemi, başlangıç popülasyonunu arama alanında daha dengeli bir şekilde dağıtarak, yeni adayların mevcut popülasyondaki bireylerden mümkün olduğunca uzak olmasını sağlamaktadır. Yapılan deneysel çalışmalar, AR yönteminin geleneksel rastgele başlatma, karşıt temelli başlatma ve genelleştirilmiş karşıt temelli başlatma yöntemlerine göre daha iyi performans gösterdiğini ortaya koymuştur.

Kazimipour vd. (2014) yaptıkları çalışmada, evrimsel algoritmalar için başlangıç popülasyonu oluşturma tekniklerini sistematik bir şekilde inceleyerek, Pseudo-Rastgele

Sayı Üreteçleri (PRNG) ve Kaotik Sayı Üreteçleri (CNG) gibi yöntemlerin performansını artırma potansiyelini ortaya koymuşlar; ayrıca bu gelişmiş tekniklerin, global optimum bulma olasılığını artırdığı, sonuçların varyansını azalttığı ve çözüm kalitesini iyileştirdiği sonucuna varmışlardır.

Gürsu ve İnce (2014) transformatör merkezi topraklama sisteminin güvenliğini sağlamak amacıyla, mevsimsel faktörlerin etkilerini dikkate alan bir topraklama ağı tasarımı gerçekleştirmiştir. Çalışmada, genetik algoritmaların başlangıç popülasyonu olarak Faure dizileri kullanılarak, çözüm uzayına düzgün bir dağılım sağlanmış ve algoritmanın global çözüme hızlı yakınsama yeteneği artırılmıştır. Bu yöntemle, toprak özdirencinin mevsimsel değişimleri analiz edilmiş ve güvenlik ile maliyet optimizasyonu başarıyla gerçekleştirilmiştir. Faure dizisi tabanlı başlangıç popülasyonunun, rastgele başlangıç popülasyonlarına kıyasla daha üstün performans gösterdiği saptanmıştır.

Şahin ve Eroğlu (2015) yaptıkları çalışmada, başlangıç popülasyonunun oluşturulması için iki ayrı yöntem önermişlerdir. Bu yöntemlerden biri, başlangıç popülasyonunun %25'lik kısmını Rota Benzerlik Yöntemi (RB) ile oluştururken kalan %75'lik kısmını rastgele oluşturan GARB yöntemi, diğeri ise başlangıç popülasyonunun tamamını rastgele oluşturmayı temel alan GAS yöntemidir. Çalışmada bu yöntemlerin genetik algoritma performansına etkileri değerlendirilmiş ve literatürde başlangıç popülasyonu seçiminin genetik algoritmaların çözüm kalitesi üzerindeki önemi vurgulanmıştır.

Cruz-Chávez ve Martínez-Oropeza (2016), Zaman Pencereci Araç Rotalama Problemi (VRPTW) için uygulanabilir başlangıç popülasyonları üretmek amacıyla genetik çeşitlilik sağlayan bir yöntem geliştirmiştir. Çalışmada, klasik k-means algoritmasını araç rotalama problemine uygun hale getiren bir kümeleme algoritması ve ardından iki adımlı bir algoritma önerilmiştir. İlk adımda, müşterilerin talep ve mesafe bilgilerine dayanarak kısmen uygulanabilir çözümler oluşturulmuş, ikinci adımda ise bu çözümler zaman penceresi kısıtlarını karşılayacak şekilde optimize edilmiştir. Çeşitliliği artırmak için hibrit bir ekleme yöntemi önerilmiş ve bu yöntem değişik ekleme algoritmalarının rastgele uygulanmasıyla elde edilmiştir. Bulgular, önerilen yöntemin başlangıç popülasyonlarında yüksek genetik çeşitlilik sağladığını ve bu çeşitliliğin algoritmanın performansını artırdığını göstermektedir.

Kuram (2016) yaptığı çalışmada, başlangıç popülasyonunun oluşturulması için rastgele oluşturma ve belirli örüntülere dayalı başlangıç popülasyonu stratejileri gibi yöntemler kullanmıştır. Bu yöntemlerle Zaman Pencere Araç Rotalama Problemi için genetik algoritmaların etkinliği artırılmış ve toplam maliyetlerin minimize edilmesi sağlanmıştır. Literatürde bu tür popülasyon tabanlı sezgisel yöntemlerin özellikle hızlı ve yakın-optimum çözümler sunma yeteneği vurgulanmıştır.

Yücel (2016) çalışmasında, Mesafe Sınırlı Esnek Kümeli Açık Araç Rotalama Problemi (M-ÇYK-A-ARP) için Genetik Algoritma (GA) yöntemi kullanılarak başlangıç popülasyonu oluşturulmuştur. Problemin çözümünde rastgele ve sezgisel yöntemlerin beraber kullanıldığı bu yaklaşım, popülasyonun çeşitliliğini koruyarak çözüm uzayının geniş bölgelerini taramış ve optimum çözüme ulaşılmasını hızlandırmıştır.

Külahlı (2016) yaptığı çalışmada, başlangıç popülasyonu oluşturmak için Genel Arama Metodu (%60), Yerel Arama Metodu (%30) ve Rastgele Metot (%10) kullanılmıştır. Bu yöntemlerin performansı üzerinde yapılan optimizasyon sonuçları, başlangıç popülasyonunun kaliteli bireylerden oluşmasının çözüm performansını artırdığını ve toplam tamamlanma süresini (C_{max}) minimize ettiğini göstermektedir.

Kaya ve Fırlı, (2016), esnek iş atölyesi çizelgeleme problemlerinin çözümünde başlangıç popülasyonunu oluşturmak için genetik algoritmalarla Monte Carlo yöntemlerini birleştiren bir yaklaşım kullanmış; bu yöntemle rastgele üretilen başlangıç çözümleri üzerinde farklı stratejiler uygulayarak çözüm kalitesini artırmış ve kısa sürede daha kaliteli sonuçlar elde edilmesine olanak sağlamışlardır.

Pulat ve Kocakoç (2017) yaptıkları çalışmada, gezgin satıcı problemi için başlangıç popülasyonlarını rasgele seçim ve en yakın komşuluk sezgiseli yöntemleri kullanarak oluşturmuşlar; bu yöntemlerin çözüm performansı üzerindeki etkilerini sistematik bir şekilde analiz etmişlerdir. Araştırma bulguları, rasgele oluşturulan popülasyonların genellikle daha iyi sonuçlar verdiğini, ancak en yakın komşuluk sezgiseli yönteminin de etkili bir başlangıç sağladığını ortaya koymuştur. Ayrıca, OX çaprazlama operatörünün, elde edilen çözümlerin kalitesini artırmada en başarılı yöntem olduğunu göstermişlerdir.

Tezer (2017), Pareto optimum yaklaşımıyla tasarladığı yenilenebilir enerji sistemleri optimizasyonunda NSGA-II tabanlı SAHRESOpt algoritması için başlangıç popülasyonunu, sistemin hibrit yapısını garanti altına alacak şekilde reformer boyutu ve

operasyon stratejisini düzenleyerek oluşturmuş; bu yöntem, sistem güvenilirliği ve maliyet minimizasyonu arasında dengeli çözümler sunarak hibrit enerji sistemleri için önemli bir optimizasyon aracı olarak öne çıkmıştır.

Pian vd. (2018), klasik yapay arı kolonisi (ABC) algoritmasındaki başlangıç popülasyonu oluşturma yöntemini geliştirerek çeşitliliği artırmak amacıyla "unlearning initialization" yöntemini önermiştir. Bu yöntem, başlangıç popülasyonundaki her çözümün ters çözümünü (inverse solution) bularak popülasyonu iki katına çıkarmış ve bu çözümlerin uygunluklarına göre seçilerek popülasyonun daha geniş bir arama alanında dağılımını sağlamıştır. Bu yaklaşım, lokal optimallere sapma riskini azaltmış ve algoritmanın çözüm kalitesini iyileştirmiştir.

Kazemzadeh Azad (2018) çalışmasında, çelik kirişlerin metaheuristik optimizasyonunda başlangıç popülasyonuna uygun (feasible) çözümler eklenmiştir. Bu amaçla, boyut uyarlamalı arama yöntemi (ADS), geliştirilmiş BB-BC algoritması (MBB-BC) ve üstel genişleme temelli BB-BC yaklaşımı (EBB-BC) algoritmaları kullanılmıştır. Araştırma, başlangıç popülasyonuna uygun çözümler eklemenin, özellikle optimizasyon sürecinin erken aşamalarında, metaheuristik algoritmaların hesaplama verimliliğini artırabileceğini göstermektedir. Bu çalışma, büyük ölçekli yapısal sistemlerin daha etkili biçimde optimize edilmesine katkı sağlayan sonuçlar ortaya koymaktadır.

Göçken vd. (2018), zaman penceresi kısıtlamalı araç yönlendirme problemi için geliştirdikleri genetik algoritma yaklaşımında, başlangıç popülasyonunun oluşturulmasında üç farklı yöntemi karşılaştırmalı olarak değerlendirmiştir. Bu kapsamda rastgele popülasyon, en yakın komşu algoritması ve süpürme algoritması tabanlı popülasyonlar oluşturularak çözüm kalitesi üzerinde etkileri incelenmiştir. Elde edilen sonuçlar, rastgele oluşturulan başlangıç popülasyonunun, en yakın komşu algoritmasına dayalı popülasyona kıyasla daha düşük performans sergilediğini göstermiştir. Buna karşılık, süpürme algoritması ile oluşturulan başlangıç popülasyonu, toplam mesafe açısından en iyi sonuçları üretmiş ve yöntemin etkinliğini ortaya koymuştur. Nitekim süpürme algoritması ile elde edilen çözümler, C1 veri setinde %33, R1 setinde %18 ve RC1 setinde %14 oranında iyileştirme sağlayarak algoritmanın başlangıç aşamasında güçlü bir performans sunduğunu göstermiştir.

Demir vd. (2019), lojistik ve Singer haritalarını birleştirerek yeni bir hibrit kaotik sürü optimizasyon yöntemi geliştirmiş ve başlangıç popülasyonunun oluşturulması ile parçacık güncellemelerinde bu hibrit haritayı kullanmışlardır. Çalışmalarında, önerilen yöntemin meta-sezgisel optimizasyon süreçlerinde lokal minimumlara takılmayı önlediği ve tüm kıyaslama fonksiyonlarında global optimuma ulaştığı sonucuna varılmıştır.

Deniz ve Kiziloğ (2019), evrimsel algoritmalarda başlangıç popülasyonunun etkilerini inceleyerek, rastgele (Rnd), ayırık rastgele (DR), bilgi kazancı sıralaması (IGR), açgözlü yaklaşım (Gr) ve küçük rastgele (SR) gibi farklı popülasyon oluşturma yöntemlerini karşılaştırmış ve özellikle bilgi kazancı sıralaması (IGR) yönteminin orta ve büyük boyutlu veri setlerinde hem doğruluk hem de hesaplama süresi açısından üstün performans gösterdiğini rapor etmişlerdir.

Kaya vd. (2020) yaptıkları çalışmalarla, başlangıç popülasyonlarının kalitesinin akış tipi çizelgeleme problemlerinin çözümünde önemli bir rol oynadığı belirlenmiş; NEH, SKNEH10 ve SKNEH1 yöntemleri ile oluşturulan başlangıç popülasyonlarının, rastgele başlangıç yöntemlerine göre daha düşük ortalama görel sapma (OGS) değerleri sağladığı ve çözüm kalitesini belirgin şekilde artırdığı gözlemlenmiştir.

Madenoglu (2020), araştırmasında, hibrit akış tipi çizelgeleme problemi için parçacık sürü optimizasyonu (PSO) algoritması kullanılarak, başlangıç popülasyonlarının oluşturulmasında NEH (Nawaz, Enscore, Ham) yönteminin, diğer yöntemlere kıyasla daha etkili olduğu ve en düşük ortalama bağıl yüzde sapma (BYS) değerlerine ulaştığı tespit edilmiştir.

Digehsara vd. (2020), iyileştirilmiş bir parçacık sürü optimizasyonu (PSO) algoritması olan Halton-PSO'yu önermiştir. Bu yöntem, popülasyonun başlangıç aşamasını rastgele başlatmak yerine, karıştırılmış Halton dizisi kullanarak güçlendirmektedir. Yöntem, geleneksel PSO'nun erken yakınsama (convergence) ve yerel minimumlara takılma gibi sınırlamalarını ele almayı amaçlamaktadır. Halton-PSO'nun performansı, 11 karşılaştırma (benchmark) fonksiyonu ve 7 doğrusal olmayan mühendislik problemi üzerinde test edilmiştir. Sonuçlar, yöntemin diğer PSO varyantları ve optimizasyon yöntemlerine kıyasla üstün bir performans sergilediğini göstermektedir.

Seyyarer (2021) doktora tezinde, optimizasyon algoritmalarının başlangıç popülasyonu oluşturma aşamasına odaklanarak deterministik bir yöntem geliştirmiştir. Tezde, stokastik ve deterministik başlatma yöntemleri karşılaştırılmış, yeni yöntemin

daha dengeli ve homojen bir dağılım sağladığı gösterilmiştir. Önerilen deterministik başlatma yöntemi, çok değişkenli lineer regresyon (MLR) modeli ve SGD, Momentum, Adagrad, RMSProp, Adadelata, Adam gibi optimizasyon algoritmaları ile test edilmiştir. Çalışma sonucunda, Adadelata algoritması ve MSE hata fonksiyonunun en iyi performansı sergilediği tespit edilmiştir.

Başar (2021) çalışmasında, Beklemez Akış Tipi Çizelgeleme problemlerinin çözülmesinde kullanılan Dağılık Arama yaklaşımında, başlangıç popülasyonunun oluşturulmasında, yerel arama algoritması kullanılarak daha çeşitli çözümler sağlamak amacıyla optimize edilmiş ve bu değişiklik, algoritmanın performansını artırarak daha kaliteli çözümler elde edilmesini sağlamış; elde edilen sonuçlar, diğer sezgisel yöntemlerle karşılaştırıldığında %0,0136 gibi düşük bir ortalama sapma ile oldukça başarılı bulunmuştur.

Özkök (2021) yaptığı çalışmada, Zaman Pencereli Araç Rotası Problemi (ZPARP) için geliştirilen hibrit ABC-OX1 yönteminde, başlangıç popülasyonu oluşturulurken, rastgele üretilen veriler, tur geliştirici 3-opt yöntemi ile iyileştirilmiş; bu sayede daha kaliteli ve çeşitli başlangıç sonuçları elde edilmiştir. Elde edilen sonuçlar, bu yaklaşımın, klasik ABC algoritmasına göre daha yüksek bir performans sergilediğini ve test edilen 56 örnekten 14'ü için bilinen en iyi çözüme ulaşmayı başardığını göstermiştir.

Başar ve Engin (2022), beklemez akış tipi çizelgeleme (BATÇ) problemlerinin çözümünde hibrit dağılık arama (HDA) yöntemini önererek, başlangıç popülasyonunun oluşturulmasında NEH algoritması ve rastgele yöntemlerin birleştirildiğini ifade etmişlerdir. Bu yaklaşım, çözüm kalitesini artırmak amacıyla başlangıç popülasyonunun daha çeşitlendirilmiş ve etkili bir şekilde oluşturulmasını sağlamaktadır. HDA algoritmasının, diğer sezgisel ve meta-sezgisel yöntemlere kıyasla daha yüksek doğrulukla optimum çözüme yakın sonuçlar verdiği vurgulanmıştır.

Dedetürk vd., (2023), zaman pencereli araç rota belirleme problemleri (ZP-ARP) için kümeleme tabanlı bir Klonal Seçim Algoritması (KSA) geliştirerek, afet yardımı gibi olağanüstü durumlarda etkili ve optimize edilmiş rotalama çözümleri sunma potansiyelini göstermiştir. Araştırmada, başlangıç popülasyonlarının k-ortalama ve k-ortalama++ algoritmalarıyla iyileştirilmesiyle KSA'nın performansının artırıldığı, yerel optimuma takılma olasılığının azaltıldığı ve daha kısa mesafeler ile daha az araç kullanımını

sağladığı belirtilmiştir. Bu yaklaşımın, özellikle doğal felaketlerin etkilerini hafifletmek amacıyla afet yardımı uygulamalarında pratik fayda sağlayabileceği vurgulanmaktadır.

Elmas (2024), kümeleme algoritmasında başlangıç popülasyonunu oluştururken, popülasyon büyüklüğüne göre arama ajanlarını kodlama yapısına uygun şekilde üretmiş ve her bir ajan için $K \times M$ boyutunda vektörler elde etmiştir. Bu vektörler, balinaların konumlarını temsil eder ve başlangıç popülasyonu bu şekilde şekillendirilmiştir. Geliştirilen KWOA (Balina Optimizasyon Algoritması Tabanlı) algoritması, UCI veri setleri kullanılarak yapılan testlerde en yüksek Rand İndeks (RI) ve Siluet İndeks (SI) değerleriyle başarı elde etmiştir.

2.2 Gezgin Satıcı Problemi ile İlgili Çalışmalar

Terzi (2009), Diferansiyel Gelişim Algoritması'nın (DGA), her ne kadar kombinatoriyel problemler üzerinde yaygın olarak kullanılsa da, sürekli çözüm uzaylarında ve belirli ayırık problemlerde etkili sonuçlar üreten popülasyon temelli bir meta-sezgisel algoritma olduğunu ifade etmektedir. Bu bağlamda yürütülen söz konusu çalışmada, DGA'nın kombinatoriyel optimizasyon problemlerinde daha etkin biçimde kullanılabilmesine olanak tanıyacak özgün bir yöntem önerilmiştir. Geliştirilen yaklaşım, sıralama uzayı ile sürekli çözüm uzayı arasında uygun bir dönüşüm sağlayarak, DGA'nın yalnızca kayan noktalı vektörler üzerinde işlem yapabilme sınırlılığını aşmayı hedeflemektedir. Yöntemin geçerliliği, çözüm zorluğu literatürde yüksek kabul edilen Gezgin Satıcı Problemi (GSP) ile yapılan deneylerle test edilmiştir. Ayrıca çalışmada, GSP'ye yönelik kesin, sezgisel ve metasezgisel çözüm yöntemlerine ilişkin kapsamlı bir değerlendirme sunulmuş; önerilen yaklaşımın DGA'ya permütasyon tabanlı problemlerde uygulanabilirlik kazandırdığı ortaya konmuştur. Elde edilen bulgular, DGA'nın performansının Karınca Kolonisi Optimizasyonu ve Genetik Algoritma benzeri diğer popülasyon tabanlı algoritmalarla karşılaştırılabilir düzeye ulaştığını ve bazı durumlarda Parçacık Sürü Optimizasyonu'na kıyasla üstün sonuçlar verdiğini göstermektedir.

Kuzu vd. (2014), Gezgin Satıcı Problemi'nin (GSP) çözümüne yönelik gerçekleştirdikleri çalışmalarında, sekiz farklı meta-sezgisel algoritmanın performansını incelemiş ve bu algoritmaların sonuçlarını literatürde yer alan 18 farklı GSP örneği

üzerinden karşılaştırmalı olarak değerlendirmiştir. Elde edilen sonuçlar, çoklu başlangıç noktasıyla arama gerçekleştiren meta-sezgisel yöntemlerin, tekil çözüm arama yaklaşımına sahip algoritmalara oranla daha üstün performans sergilediğini ortaya koymaktadır. Özellikle Karınca Kolonisi Algoritması'nın (KKA), GSP üzerinde tatmin edici ve rekabetçi çözümler üretebildiği gözlemlenmiştir.

Topcu (2014) tarafından hazırlanan doktora tezinde, elektromanyetizma temelli sezgisel algoritmanın Gezgin Satıcı Problemi (GSP) üzerindeki uygulanabilirliği incelenmiştir. Global optimizasyon problemleri için tasarlanan bu algoritma, Coulomb Yasası'na dayalı olarak parçacıklar arasındaki elektrostatik kuvvetlerini modelleyen bir meta-sezgisel yaklaşım sunmaktadır. Tez çalışmasında, yönetsel karar problemlerine uyarlanabilirliğini artırmak amacıyla elektromanyetizma algoritması, rastgele anahtar yöntemi ile entegre edilerek, kesikli ve kısıtlı optimizasyon problemleri için uygun bir arama mekanizması geliştirilmiştir. Farklı boyutlardaki GSP örnekleri üzerinde gerçekleştirilen deneysel analizlerde, söz konusu algoritmanın çözüm kalitesi ve işlem süresi bakımından performansı değerlendirilmiştir. Elde edilen bulgular, elektromanyetizma algoritmasının çeşitli problem boyutlarında etkili çözümler üretebildiğini, ancak Tavlama Benzetimi algoritmasına kıyasla daha uzun çalışma sürelerine ihtiyaç duyduğunu göstermiştir. Performansın artırılması amacıyla, alternatif arama stratejilerinin entegrasyonu ve daha etkili başlangıç çözümleri üretmeye yönelik prosedürlerin eklenmesi önerilmiştir. Ayrıca, algoritma parametrelerinin sonuçlar üzerindeki etkisi detaylı şekilde incelenerek, optimum parametre kombinasyonlarının belirlenip algoritmaya entegre edilmesi gerektiği vurgulanmıştır.

Dikmen vd. (2014), Gezgin Satıcı Problemi'nin (GSP) çözümüne yönelik olarak yapay zekâ tabanlı iki farklı metasezgisel yöntem olan Karınca Kolonisi Optimizasyon Algoritması (KKA) ile Genetik Algoritma'nın (GA) performanslarını karşılaştırmalı olarak değerlendirmiştir. Türkiye haritası üzerinde gerçekleştirilen uygulamada, en uygun rotanın oluşturulması hedeflenmiş ve her iki algoritma; toplam rota uzunluğu ve hesaplama süresi bakımından analiz edilmiştir. C# tabanlı bir kullanıcı arayüzü aracılığıyla gerçekleştirilen deneysel çalışmanın bulguları, KKA'nın, GA'ya kıyasla hem daha kısa rota üretme hem de daha hızlı çözüm süresi sağlama yönünden üstün performans sergilediğini ortaya koymuştur.

Öztürk ve Uysal (t.y.), Gezgin Satıcı Problemi'nin (GSP) çözümüne yönelik olarak Genetik Algoritma (GA) temelli bir yaklaşımı ele aldıkları çalışmalarında, bu klasik kombinatoriyel optimizasyon problemini, bir satıcının belirli şehirler arasında en kısa turu tamamlamasını hedefleyen yapısıyla incelemişlerdir. Uygulama kapsamında, Sırbistan'ın Nis kentinde faaliyet gösteren ve 20 atık imha sahasını kapsayan bir atık toplama firmasının güzergâh planlaması problemi ele alınmıştır. Bu problem özelinde geliştirilen GA yaklaşımı, daha önce Markovic ve arkadaşları (2012) tarafından Kohonen'in Öz-Örgütleyen Haritası (Self-Organizing Map - SOM) yöntemiyle çözülmüş olan aynı problem senaryosu üzerinden test edilmiştir. Çalışmanın temel amacı, alternatif bir teknik kullanılarak bulunan sonuçların daha önceki yöntemle karşılaştırılması yoluyla farklı bir çözüm perspektifi sunmak ve Genetik Algoritma'nın problem üzerindeki etkinliğini değerlendirmektir.

Kayman (2015), Gezgin Satıcı Problemi'nin (GSP) çözümünde Parçacık Sürü Optimizasyonu (PSO) algoritmasının, literatürde hızlı ve etkili sonuçlar sunmasıyla öne çıktığını belirtmekte; ancak klasik PSO'nun yalnızca küçük boyutlu problem örneklerinde yeterli performans gösterdiğini ifade etmektedir. Bu bağlamda yürütülen çalışmada, klasik PSO algoritması ile Bulanık C-Ortalamlar (BCO) yöntemlerinin entegrasyonu yoluyla FCM-PSO-M, FCM-PSO-M2 ve FCM-PSO-U adını taşıyan yeni algoritmalar geliştirilmiş ve bu algoritmalar farklı ölçeklerdeki GSP örnekleri kullanılarak test edilmiştir. Ortaya çıkan bulgular, geliştirilen yöntemlerin küçük boyutlu problemler için klasik PSO'ya kıyasla daha yüksek çözüm kalitesi sağladığını; ancak bu durumun işlem süresinde artışa neden olduğunu ortaya koymaktadır. Orta ve büyük ölçekli problemlerde ise önerilen yaklaşımların, işlem süresi ve elde edilen çözümün kalitesi bakımından klasik PSO'ya üstünlük sağladığı belirlenmiştir. Özellikle 18.512 düğüm noktasına sahip D18512 örneği üzerinde yapılan uygulamada, FCM-PSO-M2 (9x9) algoritmasının klasik PSO'ya göre %5 daha kısa sürede çalıştığı ve yaklaşık 9,89 kat daha kaliteli çözüm sunduğu tespit edilmiştir. Çalışmanın genel sonucunda, geliştirilen hibrit yöntemlerin problem boyutundan bağımsız olarak çözüm kalitesi açısından klasik PSO'nun üzerinde performans sergilediği ve özellikle orta ve büyük ölçekli problemlerde daha etkili olduğu ortaya konmuştur.

Yıldırım vd. (2016), Gezgin Satıcı Problemi'nin (GSP) çözümüne yönelik olarak doğadaki hayvan davranışlarından esinlenerek geliştirdikleri yeni bir meta-sezgisel

yaklaşımı tanıtmaktadır. Kör Fare Algoritması (KFA) olarak adlandırılan bu yöntem, yer altında yaşayan kör farelerin engelleri aşarak tünel sistemlerinde yön bulma stratejilerinden ilham alınarak tasarlanmıştır. Çalışmada, algoritmanın etkinliği farklı büyüklüklerdeki simetrik GSP test veri kümeleri üzerinde deneysel olarak test edilmiş; elde edilen çözümler literatürde bilinen en iyi sonuçlarla karşılaştırılmıştır. Analizler sonucunda, Kör Fare Algoritması'nın henüz mevcut güçlü meta-sezgisel yöntemlerle tam anlamıyla rekabet edemediği; ancak başlangıç düzeyindeki test bulgularının algoritmanın gelişime açık ve umut vadeden bir yapıya sahip olduğunu gösterdiği ifade edilmektedir.

Halim ve Ismail (2017), Gezgin Satıcı Problemi'ne yönelik çalışmada En yakın komşuluk, Genetik Algoritma(GA), Tavlama Benzetimi(TB), Tabu Arama(TA), Karınca Koloni Optimizasyon(KKO) ve Ağaç Fizyolojisi Optimizasyon(AFOA) algoritmalarını karşılaştırarak, özellikle küçük boyutlu problemlerde AFOA algoritmasının yüksek doğruluk ve düşük hesaplama süresiyle öne çıktığını göstermiştir.

Şahin ve Karagül (2019) tarafından gerçekleştirilen çalışmada, Gezgin Satıcı Problemi'nin (GSP) çözümüne yönelik olarak Melez Akışkan Genetik Algoritma (MAGA) temelli bir yaklaşım geliştirilmiştir. Önerilen yaklaşım, En Yakın Komşu ve 2-Opt sezgisel algoritmalarının entegrasyonu üzerine kurgulanmış olup, bu yapıyla klasik genetik algoritmanın arama yeteneklerini geliştirmeyi amaçlamaktadır. Yeni algoritmanın performans düzeyi; En Yakın Komşu, Genetik Algoritma, Tabu Arama, Karınca Kolonisi Optimizasyonu ve Ağaç Fizyolojisi Optimizasyonu gibi farklı sezgisel ve metasezgisel yöntemlerle elde edilen çözümlerle karşılaştırmalı olarak değerlendirilmiştir. Elde edilen deneysel bulgular, MAGA'nın elde edilen çözüm kalitesi açısından rakip algoritmalara kıyasla üstün performans sergilediğini ortaya koymaktadır.

Gülcü (2019), Çoklu Gezgin Satıcı Problemi'nin (ÇGSP) çözümüne yönelik olarak Parçacık Sürü Optimizasyonu (PSO) tabanlı iki farklı algoritma olan APSO ve HAPSO'yu tanımlamış ve bu algoritmaların performanslarını karşılaştırmalı olarak incelemiştir. Çalışma kapsamında yürütülen deneysel analizler, HAPSO algoritmasının yalnızca daha yüksek çözüm kalitesi sağlamakla kalmayıp, aynı zamanda daha istikrarlı sonuçlar ürettiğini de ortaya koymuştur.

Yıldız (2020), yüksek lisans tezinde genetik algoritmaların küresel optimizasyon yeteneği ile Apriori algoritmasının birliktelik analizi yapabilme özelliğini bir araya

getirerek, turizm sektöründe rota planlamasına yönelik maliyet etkin bir yaklaşım geliştirmiştir. Geliştirilen yöntem, şehir seçimi mekanizmasıyla iyileştirilmiş ve performans değerlendirmesi TSPLIB veri setleri üzerinden gerçekleştirilmiştir.

Aslan vd. (2020), çalışmasında, Rao (2016) tarafından geliştirilen popülasyon tabanlı Jaya algoritmasını temel alarak, ayrık ve ikili optimizasyon problemleri için yeni çözüm yaklaşımları önermiştir. Geliştirilen algoritmalar; Kapasitesiz Tesis Yerleştirme Problemi (KTYP), rüzgar türbini yerleştirme problemi ve Gezgin Satıcı Problemi (GSP) gibi farklı test senaryoları üzerinde uygulanmış ve modern metasezgisel algoritmalarla karşılaştırıldığında rekabetçi ve üstün performans sergilemiştir.

Çınar (2020) tarafından yürütülen çalışmada, 2015 yılında literatüre kazandırılan Ağaç-Tohum Algoritması (TSA), sürekli ve kısıtsız optimizasyon problemleri dışında, kısıtlı ve ayrık problemlere uygulanabilecek şekilde uyarlanmıştır. Bu kapsamda algoritmanın; kural tabanlı versiyonu (CTSA), benzerlik odaklı ikili varyantı (SimTSA), mantıksal kapı tabanlı ikili biçimi (LogicTSA) ve hibrit versiyonu olan SimLogicTSA türevleri geliştirilmiştir. Elde edilen sonuçlar, mühendislik uygulamaları ve Gezgin Satıcı Problemi gibi örnekler üzerinde test edilmiş ve literatürdeki alternatif yöntemlerle karşılaştırıldığında rekabetçi çözümler üretebildiği gözlemlenmiştir.

Berkaya (2021), Gezgin Satıcı Problemi'nin (GSP) çözümüne yönelik olarak Guguk Kuşu Arama (GKA) algoritması ile 3-Opt yerel arama tekniğini birleştirerek yeni bir hibrit metasezgisel yaklaşım geliştirmiştir. Önerilen algoritmanın etkinliği, TSPLIB veri tabanından seçilen 41 farklı test problemi üzerinde değerlendirilmiştir. Elde edilen bulgular, özellikle 150 şehirden daha az içeren problemler için algoritmanın optimum çözümler üretebildiğini ortaya koymaktadır. Ayrıca, problem boyutu büyüdükçe yöntemin diğer benzer yöntemlere göre optimum değere daha yakın sonuçlar bulduğu tespit edilmiştir. Bu kapsamda, geliştirilen yaklaşımın literatürdeki mevcut metasezgisel yöntemlerle karşılaştırıldığında hem rekabetçi hem de daha iyi bir başarı ortaya koyduğu belirtilmiştir.

Uzun (2021) çalışmasında, Zaman Pencereli Tamirci Problemi (ZPTP) ve bu problemin çeşitli uzantıları üzerine odaklanarak, toplamda dört farklı matematiksel model tasarlamıştır. Araştırma kapsamında, Çok Gezginli Zaman Pencereli Tamirci Problemi (ÇZPTP) ile Çok Depolu Zaman Pencereli Tamirci Problemi (DZPTP) gibi daha karmaşık problem türleri de ele alınmıştır. ZPTP ve ÇZPTP için hem düğüm tabanlı hem

de ayırıt tabanlı modelleme yaklaşımları geliştirilmiş; DZPTP için ise gerçek yaşam uygulamalarında karşılaşılabilecek farklı senaryoları temsil eden özel matematiksel modeller önerilmiştir. Ayrıca, büyük ölçekli DZPTP örnekleri için Biyocoğrafya Tabanlı Eniyileme (BTE) algoritması temelinde bir sezgisel çözüm yaklaşımı geliştirilmiştir. Yapılan sayısal deneyler sonucunda, sunulan modellerin ve algoritmanın işlem süresi, sapma oranı ve çözüm kalitesi bakımından yüksek başarı sağladığı ortaya konmuştur..

Toksoy (2021) tarafından yürütülen çalışmada, Kapasite Kısıtlı Yer Seçimi ve Araç Rotalama Problemi (YSARP) için Dağıtık Arama (DA) ve Genetik Algoritma (GA) yaklaşımlarının entegrasyonu ile Hibrit Dağıtık Genetik Arama (HDGA) yöntemi geliştirilmiştir. Başlangıç popülasyonunun oluşturulmasında Bulanık K-Ortalamlar (Fuzzy C-Means) algoritmasından, algoritma parametrelerinin ayarlanmasında ise Taguchi deneysel tasarım yönteminden yararlanılmıştır. Geliştirilen yöntem, Prodhon, Barreto ve Tuzun-Burke veri kümeleri üzerinde test edilerek, literatürdeki mevcut çözüm teknikleriyle karşılaştırılmış ve rekabetçi performans sergilemiştir. Bu kapsamda, önerilen HDGA algoritması, YSARP için etkili ve uygulanabilir bir çözüm alternatifi olarak değerlendirilmektedir.

Bozdemir (2021), Servis Rotalama Problemi kapsamında, bir bankanın genel merkezinde görev yapan çalışanların sabah ve akşam saatlerinde belirli duraklardan alınıp bırakılmasını kapsayan Açık Uçlu Araç Rotalama Problemi'ne (AUARP) odaklanan bir çalışma gerçekleştirmiştir. Çalışmada, farklı kapasitelere sahip araçlardan oluşan heterojen bir filo göz önünde bulundurularak 2-indsli bir matematiksel model geliştirilmiştir. Önerilen modelin, problemin yapısını yalınlaştırmakla kalmayıp, aynı zamanda düğüm sayısının artırılması ve çeşitli operasyonel kısıtların entegre edilmesi durumlarında da uygulanabilirliğini koruduğu gösterilmiştir. İstanbul'un Avrupa ve Anadolu yakalarını kapsayan ve 171 düğüm içeren gerçek veri seti üzerinden gerçekleştirilen testler sonucunda, modelin mevcut çözüm yaklaşımlarına kıyasla hem maliyet hem de operasyonel başarı açısından üstün sonuçlar sunduğu tespit edilmiştir.

Belgin vd. (2021), Eş Zamanlı Toplama ve Dağıtım faaliyetlerini içeren İki Aşamalı Araç Rotalama Problemi'ne (2E-VRPSPD) yönelik olarak iki indsli, düğüm tabanlı bir Karma Tamsayı Programlama (MIP) modeli geliştirmiştir. Problem çözümünde, Değişken Komşu İniş (VND) algoritması ile Yerel Arama (LS) stratejilerini matematiksel programlama teknikleriyle entegre eden yenilikçi bir metasezgisel yaklaşım

önerilmiştir. Geliştirilen yöntemin başarısı, literatürde yaygın olarak kullanılan 564 test problemi üzerinde değerlendirilmiş ve bu problemlerin 390'ında optimal çözüme ulaşarak yüksek başarı performansı sergilediği gösterilmiştir. Çalışma, lojistik yönetimi ve araç rotalama problemlerine yönelik etkili ve uygulanabilir bir çözüm yöntemi sunması açısından önemli katkılar sağlamaktadır.

Dengiz (2021), çalışmasında Evde Sağlık Hizmetleri Çizelgeleme ve Rotalama Problemi'ni (ESHÇRP) ele alarak, bu problemin çözümüne yönelik dört farklı meta-sezgisel algoritma geliştirmiştir. Söz konusu algoritmalar; Yerel Arama (YA), Tavlama Benzetimi (TB), Açgözlü Rastgeleleştirilmiş Uyarlamalı Arama Prosedürü ile entegre edilmiş Tavlama Benzetimi (ARUAP-TB) ve ısıtma mekanizması eklenmiş ARUAP-TB-Isıtma yöntemidir. Geliştirilen yöntemlerin performansı, Ankara Gölbaşı Devlet Hastanesi'nden alınan gerçek verilerle test edilmiş ve karşılaştırmalı analizler gerçekleştirilmiştir. Sayısal sonuçlar, matematiksel modellerin küçük ölçekli problemler için uygun olduğunu; ancak hasta sayısının 40 ve üzerine çıktığı senaryolarda meta-sezgisel algoritmaların daha verimli ve kaliteli çözümler sunduğunu ortaya koymuştur. Özellikle ARUAP-TB algoritması, çözüm kalitesi yönünden en yüksek performansı sergilerken; YA algoritması işlem süresi bakımından avantaj sağlamıştır. Bu çalışma, Türkiye bağlamında ESHÇRP üzerine gerçekleştirilen ilk kapsamlı matematiksel modelleme ve meta-sezgisel algoritma geliştirme çalışması olarak literatüre kayda değer bir katkı sunmaktadır.

Cengiz (2022) tezinde Konya ili Selçuklu ilçesi Kosova Mahallesi'nde katı atık toplama sisteminin rotalama problemini ele alarak, bu problemin çözümünde Benzetilmiş Tavlama (Simulated Annealing, SA) algoritmasını kullanmıştır. Çalışmada, katı atık toplama araçlarının güzergâhlarının optimize edilmesiyle yakıt tüketiminin azaltılması, böylece hem operasyonel maliyetlerin düşürülmesi hem de karbon emisyonlarının azaltılması hedeflenmiştir. SA algoritması, konteynerlerin coğrafi koordinatlarına dayalı olarak en uygun toplama rotalarını oluşturacak şekilde uyarlanmış ve performansı Açgözlü Algoritma ile karşılaştırmalı olarak değerlendirilmiştir. Ayrıca, SA algoritmasının parametrelerinin çözüm kalitesi üzerindeki etkisi incelenmiş ve uygun parametre kombinasyonlarıyla global düzeyde daha iyi sonuçlara ulaşılmıştır. Elde edilen bulgular, önerilen yaklaşımın atık toplama sistemlerinin etkinliğini artırarak akıllı şehir uygulamalarına katkı sunabileceğini göstermektedir.

Karacan (2023) tezinde, endüstri mühendisliği kapsamında ele alınan kombinatoriyal optimizasyon problemlerine yönelik çoklu iş parçacıklı metasezgisel algoritmalar geliştirmiştir. Bu doğrultuda, klasik Benzetilmiş Tavlama (Simulated Annealing, SA) algoritmasından yola çıkarak, çok iş parçacıklı bir yapı sunan Simulated Annealing MultiThread (SAMT) algoritmasını önermiştir. SAMT algoritması, iki iş parçacığı ile eş zamanlı çalışarak hem çözüm kalitesini artırmayı hem de algoritmanın çalışma süresini azaltmayı hedeflemiştir. Geliştirilen yöntem, Beklemesiz Akış Tipi Çizelgeleme Problemi (NWFSSP) üzerinde test edilmiş ve klasik SA, Tabu Arama (TA) ile Parçacık Sürü Optimizasyonu (PSO) algoritmalarına oranla daha iyi bir performans sergilemiştir. Elde edilen bulgular, SAMT algoritmasının sadece NWFSSP değil, diğer kombinatoriyal optimizasyon problemleri için de kolaylıkla uyarlanabilecek esnek ve güçlü bir yaklaşım sunduğunu ortaya koymuştur.

Altın ve Sipahioğlu (2023), kombinatoriyal optimizasyon problemleri için parametresiz ve metaforsuz yeni bir metasezgisel algoritma olan Kesikli Rao Algoritması'nı (KRA) geliştirmiştir. Çalışmada, klasik Rao algoritmasının bileşenleri değiştirilerek özellikle Gezgin Satıcı Problemi (GSP) üzerindeki performansı değerlendirilmiştir. KRA algoritması, çözüm kalitesi ve hesaplama zamanı açısından literatürdeki diğer metasezgisel algoritmalarla karşılaştırıldığında rekabetçi sonuçlar elde etmiş; test edilen problem örneklerinde yüksek kaliteli çözümler üretmiştir. Parametre ayarlama ihtiyacını ortadan kaldırması, algoritmayı araştırmacılar için sade, uygulanabilir ve etkili bir çözüm haline getirmiştir. Bu yönüyle KRA algoritması, kombinatoriyal optimizasyon problemlerinde gelecek çalışmalara önemli bir katkı sunma potansiyeline sahiptir.

Sezer (2023) tezinde, insansız hava aracı (İHA) teknolojisinin gelişimiyle ortaya çıkan İnsansız Hava Araçlı Gezgin Satıcı Problemi'ni (GSP-D) ele almıştır. Bu doğrultuda, klasik Genetik Algoritma (GA) ile Karınca Arama Algoritması'nı (Ant Search, AS) birleştirerek GA-AS adlı hibrit bir metasezgisel yöntem geliştirilmiştir. Geliştirilen yöntem, kamyon ve drone rotalarını eş zamanlı olarak optimize etmeyi hedefleyen ikili bir feromon yapısı kullanarak rota optimizasyonunu tek bir aşamada gerçekleştirmektedir. Yapılan sayısal analizler, GA-AS algoritmasının rakip algoritmalara kıyasla daha iyi performans sergilediğini göstermiş ve GSP-D probleminin çözümünde etkili bir yaklaşım sunduğunu ortaya koymuştur.

Yetkin (2024) tezinde, Şanlıurfa ilindeki tarihi ve kültürel gezi rotalarının optimizasyonu amacıyla metasezgisel algoritmalar kullanılmıştır. Bu kapsamda, Gezgin Satıcı Problemi (GSP) için Genetik Algoritma (GA) ve Karınca Koloni Algoritması (KKA) uygulanmış; algoritmalar Microsoft Visual Studio platformunda C# dili ile kodlanarak süre, mesafe ve en iyi çözüm iterasyonu yönünden karşılaştırılmıştır. Elde edilen sonuçlara göre, KKA'nın GA'ya göre daha başarılı olduğu görülmüştür. Çalışmanın ikinci bölümünde ise, KKA algoritması Dart-Flutter platformunda yeniden kodlanarak Google Maps entegrasyonu ile yapay zekâ destekli bir mobil turizm rehberi uygulaması geliştirilmiştir. Uygulama, iOS ve Android cihazlarda minimum rota planlaması yapmayı hedeflemiş ve kullanıcı deneyimini artıracak biçimde tasarlanmıştır. Bu çalışma, KKA'nın rota optimizasyonundaki üstünlüğünü ve pratik uygulamalardaki etkinliğini ortaya koymuştur.



3. MATERYAL VE YÖNTEM

3.1 Gezgin Satıcı Problemi (GSP)

Gezgin satıcı problemi (GSP), kombinatorial optimizasyon alanında önemli bir problemdir. Bu problem, bir satıcının belirli bir dizi şehirdeki tüm şehirleri ziyaret edip, başlangıç noktasına geri dönerek en kısa yolu bulmasını amaçlar (Applegate et al., 2003). GSP, birçok gerçek dünya uygulamasına sahiptir; özellikle lojistik, ulaşım ve üretim alanlarında (Laporte, 2009). Problemin karmaşıklığı, şehir sayısı arttıkça hızla büyür ve çözümü zor bir problem olarak kabul edilir (Garey ve Johnson, 1979). GSP'nin birçok çözüm yöntemi bulunmaktadır. Bunlar arasında tam sayılı programlama, dinamik programlama ve sezgisel yöntemler yer alır (Miller ve Tucker, 1965). Tam sayılı programlama ile çözüm, her bir şehrin ziyaret edilme sırasını belirleyerek en kısa yolu bulmayı hedefler. Ancak bu yöntem, büyük şehir setleri için hesaplama açısından zorlu olabilir (Baker ve Ayechev, 2003). Dinamik programlama yaklaşımı, Bellman'ın Eşitlikleri kullanarak problemi daha verimli bir şekilde çözmeyi amaçlar (Bellman, 1957). Sezgisel yöntemler ise, genellikle daha hızlı bulgular elde etmek için kullanılır. Bu yöntemler arasında genetik algoritmalar, yerel arama ve simüle edilmiş tavlama gibi teknikler bulunmaktadır (Holland, 1975; Kirkpatrick vd., 1983). GSP'nin çeşitli varyasyonları da mevcuttur. Örneğin, araç rotalama problemleri, birden fazla satıcının olduğu durumları ele alır (Golden vd., 1987). Ayrıca, bazı uygulamalarda şehirler arasında farklı mesafe veya maliyetler göz önünde bulundurulabilir (Toth ve Vigo, 2002). GSP'nin çözümü, sadece teorik değil, aynı zamanda pratikte de büyük önem taşır.

Sonuç olarak, gezgin satıcı problemi, akademik araştırmalar ve endüstriyel uygulamalar için önemli bir konudur. Gelecekte, yapay zeka ve makine öğrenimi tekniklerinin GSP'ye uygulanması, bu problemin çözümünde yeni ufuklar açabilir (Wang vd., 2020). Bu nedenle, gezgin satıcı problemi üzerine yapılan çalışmalar, optimizasyon alanında devam eden bir ilgi kaynağı olmaya devam edecektir. Buna ek olarak, GSP'nin gerçek dünya uygulamaları, bu probleme olan akademik ve endüstriyel ilgiyi canlı tutmaktadır.

3.2 Afrika Akbabaları Optimizasyon Algoritması (AVOA)

Afrika Akbabaları Optimizasyon Algoritması (African Vulture Optimization Algorithm, AVOA), doğadaki Afrika akbabalarının avlanma ve beslenme davranışlarından ilham alınarak tasarlanmış bir sezgisel optimizasyon yöntemidir. Bu algoritma, karmaşık problemlerin çözümünde kullanılmak üzere tasarlanmıştır.

AVOA, 2021 yılında Abdullahzadeh ve arkadaşları tarafından önerilmiştir (Abdullahzadeh vd., 2021). Bu çalışma, doğadan ilham alan optimizasyon tekniklerinin artan popülaritesini yansıtmaktadır. Afrika akbabalarının avlanma ve beslenme davranışları, algoritmanın temelini oluşturur. Akbabalar, yiyecek bulmak için belirli stratejiler kullanarak hareket ederler. Bu stratejiler, algoritmanın çözüm uzayındaki arama işlemlerine yansıtılmıştır. Büyük ölçekli optimizasyon problemlerini etkili bir şekilde çözebilme kapasitesine sahiptir ve hesaplama karmaşıklığı $O(P \times (M + Mb))$ gibi düşük bir düzeydedir. Burada:

P , popülasyon büyüklüğünü ifade eder.

M , azami iterasyon sayısını ifade eder.

b , problemin boyutlarını gösterir.

Bu yapı, yöntemin verimli bir şekilde çalışmasını ve büyük ölçekli problemlerde hesaplama maliyetinin kontrol altında tutulmasını sağlar.

3.2.1 Algoritmanın Temel Bileşenleri

AVOA'da her akbaba, problem uzayındaki bir çözüm noktası olarak temsil edilir. Algoritma, popülasyon içindeki iki en iyi akbabayı ($K_{LiderAkbaba1}$ ve $K_{LiderAkbaba2}$) belirleyerek diğer bireylerin bu iki noktaya doğru hareket etmesini sağlar.

Afrika akbabaları optimizasyon algoritmasında, başlangıç popülasyonu belirlendikten sonra tüm bireylerin uygunluk değerleri bulunur. Uygunluk değeri en yüksek olan birey, ilk grubun lider akbabası olarak seçilirken, ikinci en iyi birey ikinci grubun lider akbabası olarak atanır. Eşitlik (3.1) ve Eşitlik (3.2) kullanılarak, diğer akbabalar sırasıyla her iki grubun en iyi bireyelerine doğru yönlendirilir. Her iterasyon sonunda, tüm bireyelerin uygunluk değerleri yeniden değerlendirilir.

Geçerli iterasyonda seçilmiş olan en iyi iki akbabadan birinin konum vektörü $E(i)$ ile ifade edilir. İlk grubun lider akbabasının konum vektörü $K_{LiderAkbaba1}$, ikinci grubun lider akbabasının konum vektörü ise $K_{LiderAkbaba2}$ olarak gösterilir. λ_1 ve λ_2 parametreleri, toplamları 1 olacak şekilde 0 ile 1 arasında farklı değerler alır.

$$E(i) = \begin{cases} K_{LiderAkbaba1}, k_i = \lambda_1 \\ K_{LiderAkbaba2}, k_i = \lambda_2 \end{cases} \quad (3.1)$$

$$k_i = \frac{F_i}{\sum_{i=1}^n F_i} \quad (3.2)$$

Tok olan akbabalar yüksek enerji seviyelerine sahip olduklarından, geniş alanlara yayılarak yiyecek arayabilirler. Ancak, aç olduklarında enerji seviyeleri düşer ve güçlü bir akbabanın yakınında daha uzun süre kalarak hareket kabiliyetleri kısıtlanır. Bu doğal davranış, matematiksel olarak Eşitlik (3.3) ve Eşitlik (3.4) ile modellenir. mi , mevcut iterasyon sayısını belirtirken, M ise algoritmanın toplam iterasyon sınırını ifade eder. $rast_1$, ρ_1 ve ρ_2 parametreleri sırası ile $[0,1]$, $[-1,1]$ ve $[-2,2]$ aralıklarında rastgele değerler alır. ρ_3 sabit bir katsayıdır ve bu değer artırılması, optimizasyon sürecinin ilerleyen aşamalarında keşif (exploration) sürecinin devreye girme ihtimalini yükseltir.

$$F = (2 \times rast_1 + 1) \times p_1 \times \left(1 - \frac{mi}{M}\right) \quad (3.3)$$

$$+ t$$

$$t = p_2 \times \left(\sin^{\rho_3} \left(\frac{\pi}{2} \times \frac{mi}{M} \right) + \cos \left(\frac{\pi}{2} \times \frac{mi}{M} \right) - 1 \right) \quad (3.4)$$

Eğer $|F|$ değeri 1 veya daha büyükse, algoritma keşif aşamasına geçer ve akbabalar, en iyi çözümlerden birine belirli mesafelerde rastgele yönlenerak yiyecek aramaya başlar. Keşif sürecinde farklı stratejilerden yararlanmak amacıyla, $[0,1]$ aralığında rastgele değerler alan K_1 ile $rastK_1$ parametreleri karşılaştırılır. Eğer K_1 , $rastK_1$ değerine eşit veya büyükse, Eşitlik (3.5) ve Eşitlik (3.6) devreye girer. Ancak, K_1

değeri $rast_{K1}$ 'den küçükse, Eşitlik (3.7) kullanılarak akbabanın yeni konumu belirlenir. Burada $K(i + 1)$, bir sonraki iterasyonda akbabanın güncellenmiş konum vektörünü temsil eder. F , mevcut iterasyonda akbabanın doyma seviyesini gösterirken, $K(i)$ ise o anki konum vektörünü ifade eder. s_1 ve s_2 , değişken değerleri için belirlenen alt ve üst sınırları tanımlar. Ek olarak, $rast$, $rast_2$ ve $rast_3$ parametreleri, 0 ile 1 aralığında rastgele değerler olarak keşif sürecinin dinamikliğini artırır.

$$K(i + 1) = E(i) - D(i) \times F \quad (3.5)$$

$$D(i) = |2 \times rast \times E(i) - K(i)| \quad (3.6)$$

$$K(i + 1) = E(i) - F + rast_2 \times ((s_2 - s_1) \times rast + s_1) \quad (3.7)$$

Eğer $|F|$ değeri 1'den küçükse, algoritma sömürü aşamasına geçer ve akbabalar, en iyi çözümlerden birinin çevresinde yoğunlaşarak yiyecek aramaya devam eder. Bu aşamada, farklı sömürü stratejilerinden yararlanmak amacıyla $[0,1]$ aralığında rastgele değerler alan $K2$ ile $rastK2$ ve $K3$ ile $rastK3$ parametreleri karşılaştırılır. Eğer $|F|$ değeri 0,5 ile 1 arasında ise, $K2$, $rastK2$ 'ye eşit veya büyükse Eşitlik (3.8) ve Eşitlik (3.9) kullanılarak akbabaların hareketi belirlenir. Ancak, $K2$, $rastK2$ 'den küçükse, Eşitlik (3.10) ve Eşitlik (3.11) devreye girer. Bu sayede, akbabaların yiyecek kaynağı etrafında dönen hareketleri ve avlarını kuşatma stratejileri modellenir. Ayrıca, $rast4$, $rast5$ ve $rast6$ parametreleri $[0,1]$ aralığında rastgele değerler olarak, sömürü sürecinin dinamikliğini artırır.

$$K(i + 1) = D(i) \times (F + rast_4) - d(t) \quad (3.8)$$

$$d(t) = E(i) - K(i) \quad (3.9)$$

$$K(i + 1) = E(i) - (U_1 + U_2) \quad (3.10)$$

$$\begin{aligned}
U_1 &= E(i) \times \left(\frac{rast_5 \times K(i)}{2\pi} \right) \times \cos(K(i)) \\
U_2 &= E(i) \times \left(\frac{rast_6 \times K(i)}{2\pi} \right) \times \sin(K(i))
\end{aligned} \tag{3.11}$$

Eğer $|F|$ değeri 0,5'ten küçükse, akbabalar yiyecek kaynağı etrafında daha agresif bir şekilde yoğunlaşır ve rekabet artar. Bu aşamada, K_3 ile $rast_{K_3}$ parametreleri karşılaştırılarak uygun hareket stratejisi belirlenir. Eğer K_3 , $rast_{K_3}$ 'e eşit veya büyükse, Eşitlik (3.12) ve Eşitlik (3.13) kullanılarak akbabaların yiyecek kaynağı çevresinde konumlarını daha etkin bir şekilde ayarlamaları sağlanır. Eğer K_3 , $rast_{K_3}$ 'den küçükse, Eşitlik (3.14) ve Eşitlik (3.15) devreye girerek agresif rekabet ve av kaynağını ele geçirme süreci modellenir. Bu süreçte: λ sabit bir katsayıdır. b , problemin boyutlarını ifade eder. ρ_4 ve ρ_5 , $[0,1]$ aralığında rastgele değerler olarak sürecin rastlantısallığını artırır. $\Gamma(z) = (z-1)!$ ifadesi, özel bir faktöriyel fonksiyonunu tanımlar. Bu çalışmada kullanılan belirli parametre değerleri şunlardır:

$$\lambda_1 = 0,8, \lambda_2 = 0,2, \rho_3 = 2,5, K_1 = 0,6, K_2 = 0,4, K_3 = 0,6$$

Afrika Akbabaları Optimizasyon Algoritması'nın sözde kodu Algoritma 1'de verilmişken akış diyagramı da, Şekil 3.1'de görüldüğü gibidir (Abdollahzadeh vd., 2021; Yeşilbudak, 2021).

$$K(i+1) = \frac{B_1 + B_2}{2} \tag{3.12}$$

$$\begin{aligned}
B_{1,2} &= K_{EniyiAkbaba_{1,2}}(i) \\
&- \frac{K_{EniyiAkbaba_{1,2}}(i) \times K(i)}{K_{EniyiAkbaba_{1,2}}(i) - K(i)^2} \times F
\end{aligned} \tag{3.13}$$

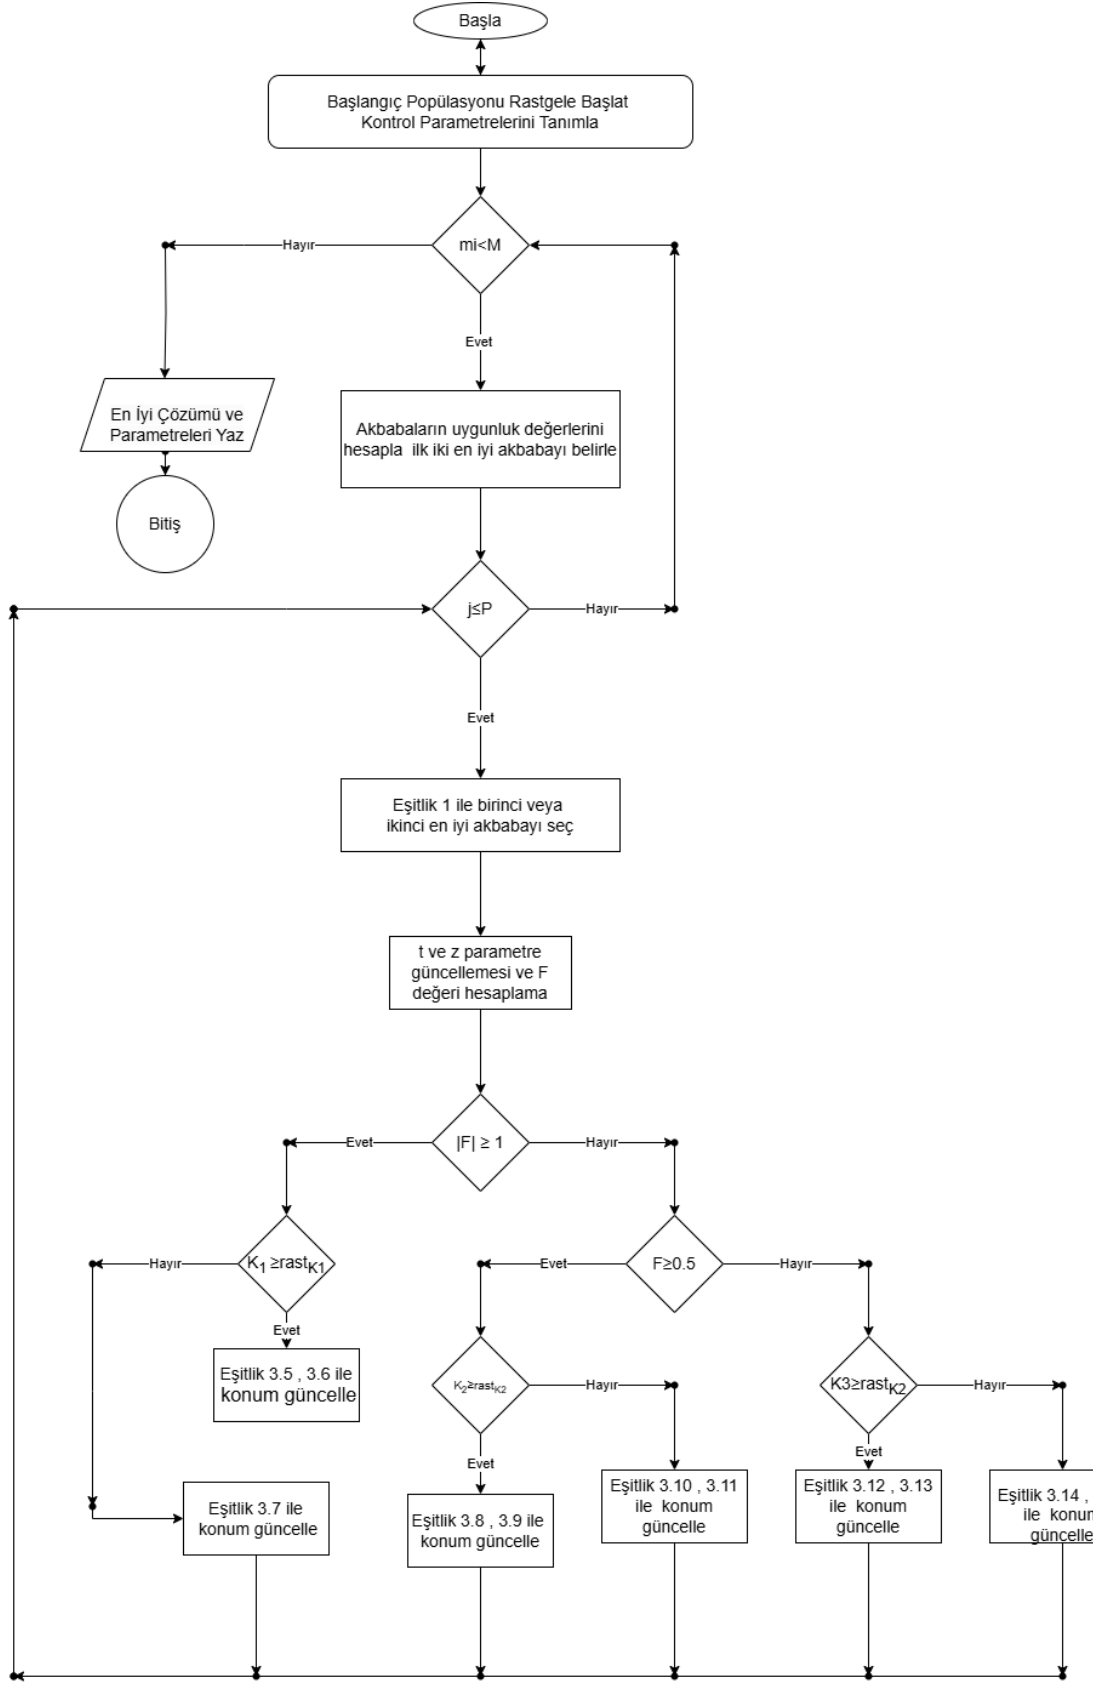
$$K(i+1) = E(i) - |d(t)| \times F \times L(b) \tag{3.14}$$

$$L(z) = 0,01 \times \frac{(p_4 \times \sigma)}{|p_5|^{\frac{1}{\lambda}}} \tag{3.15}$$

$$\sigma = \left(\frac{\Gamma(1 + \lambda) x \sin\left(\frac{\pi\lambda}{2}\right)}{\Gamma\left(\frac{1 + \lambda}{2}\right) x \lambda x 2^{\frac{\lambda-1}{2}}}\right)^{\frac{1}{\lambda}} \quad (3.15)$$

Algoritma 1. Avoa algoritmasının sözde kodu

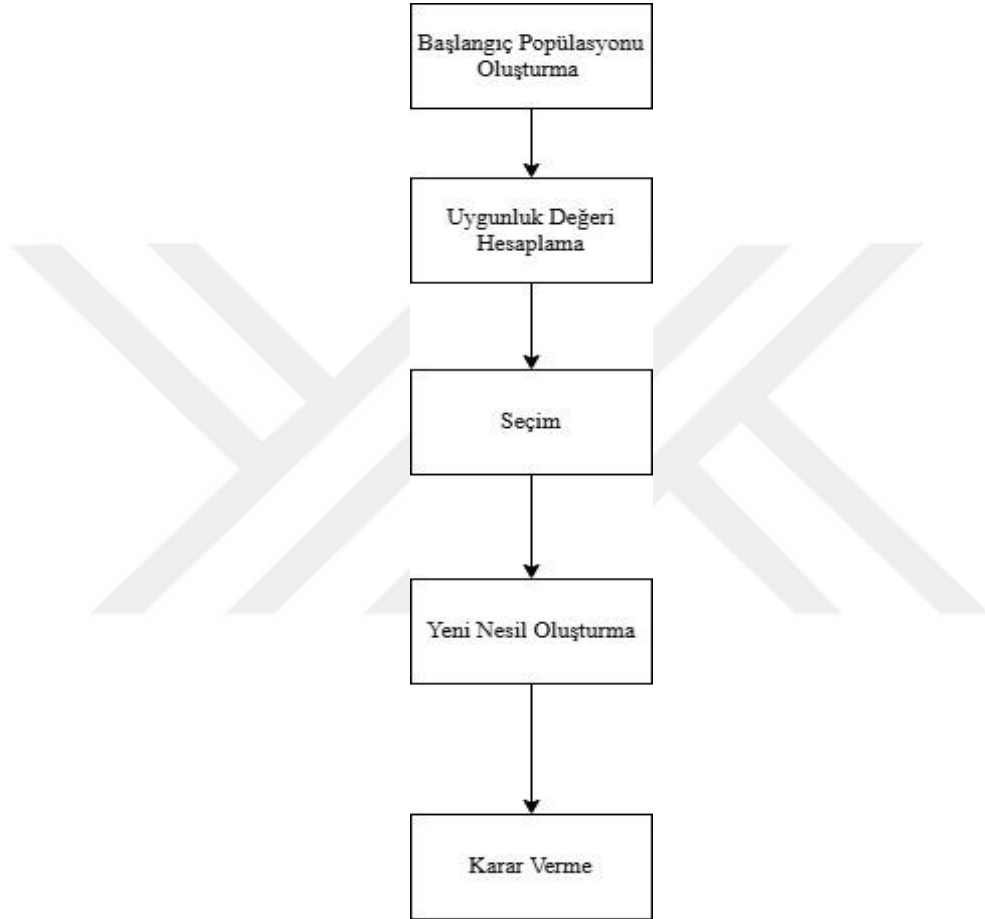
1. Rastgele bir akbaba popülasyonu oluştur.
 2. while (sonlandırma şartı) do
 - a. Akbabaların uygunluk değerlerini hesapla
 - b. $K_{LiderAkbaba1}$ ve $K_{LiderAkbaba2}$ 'yi ayarla
 - c. for (her bir akbaba) do
 - Eşitlik (3.1)'i kullanarak $E(i)$ 'yi seç
 - Eşitlik (3.3)'ü kullanarak F 'yi güncelle
 3. if ($|F| \geq 1$) then
 - a. if ($K1 \geq rastK1$) then
 - Eşitlik (3.5) ve (3.6)'yı kullanarak akbaba konumunu güncelle
 - b. else
 - Eşitlik (3.7)'yi kullanarak akbaba konumunu güncelle
 4. else
 5. if ($|F| \geq 0.5$) then
 - a. if ($K2 \geq rastK2$) then
 - Eşitlik (3.8) ve (3.9)'u kullanarak akbaba konumunu güncelle
 - b. else
 - Eşitlik (3.10) ve (3.11)'i kullanarak akbaba konumunu güncelle
 6. else
 - a. if ($K3 \geq rastK3$) then
 - Eşitlik (3.12) ve (3.13)'ü kullanarak akbaba konumunu güncelle
 - b. else
 - Eşitlik (3.14) ve (3.15)'i kullanarak akbaba konumunu güncelle
 7. return $K_{LiderAkbaba}$
-



Şekil 3.1 AVOA akış diyagramı

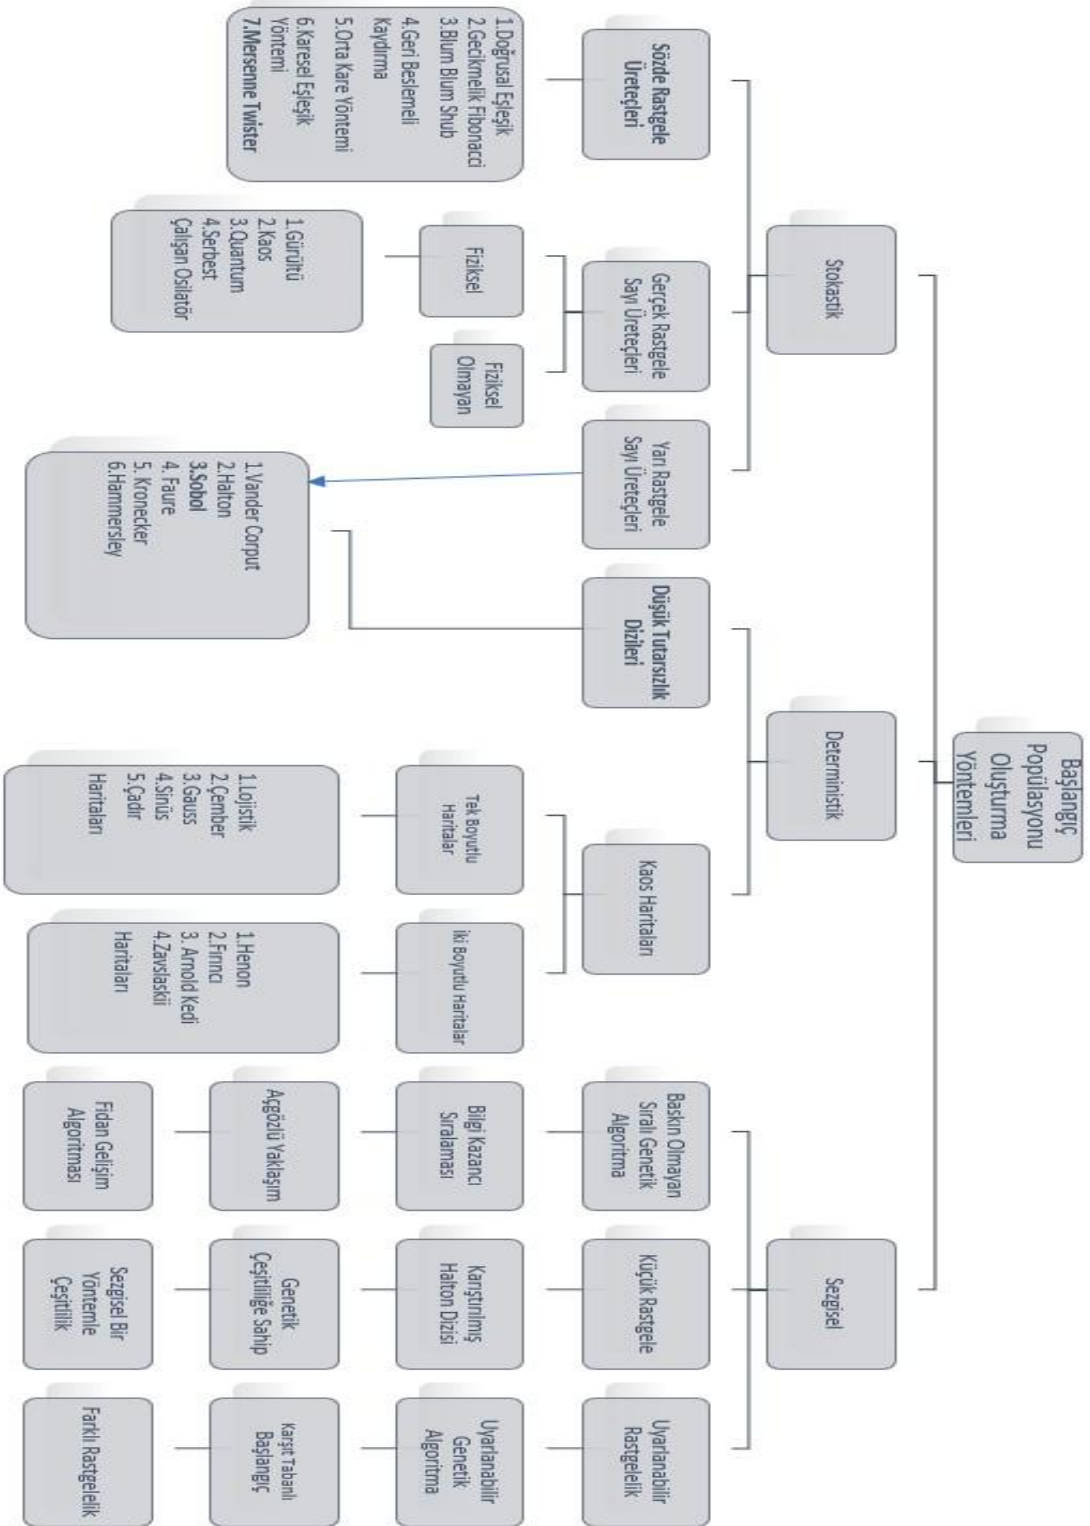
3.3 Bařlangıç Popülasyonu Oluřturma

Metasezgisel optimizasyon süreci Őekil 3.2’de belirtilmiřtir. Bu ařamalardan ilki bařlangıç popülasyonu oluřturmadır literatürde en az alıřma bu alanda yapılmıřtır. En ok alıřmada yeni nesil oluřturma ařaması ile ilgili yapılmıřtır.



Őekil 3.2 Metasezgisel optimizasyon süreci

Kullanımı kolay ve pratik olduęundan bařlangıç popülasyonu genelde rastgele oluřturulmaktadır. Ancak iyi oluřturulmuř bir bařlangıç popülasyonu optimizasyon sürecinin dięer ařamalarını önemli Őekilde etkileyecektir. Bu nedenle bařlangıç popülasyonu üzerine bazı alıřmalar yapılmıřtır. Seyyarer (2021), doktora tezinde bařlangıç popülasyonu oluřturma yöntemlerini Őekil 3.3’te görüldüęü gibi Stokastik, Deterministik ve Sezgisel olarak 3 ana bařlık altında ele almıřtır.



Şekil 3.3 Başlangıç popülasyonu oluşturma yöntemleri

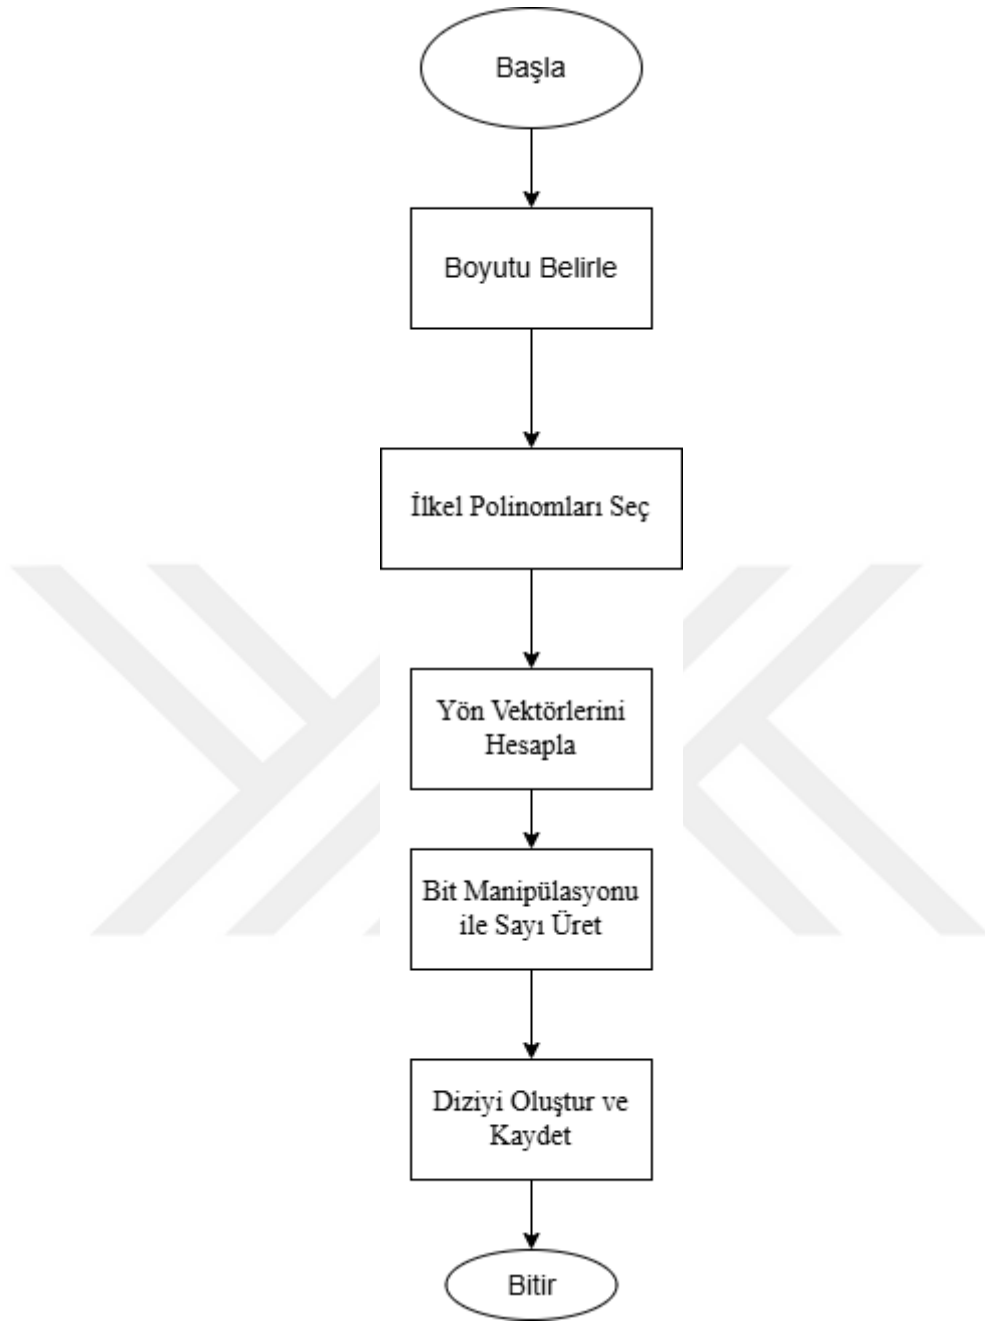
Bu tez kapsamında, düşük tutarsızlık özelliği ile bilinen Sobol dizileri; sezgisel yöntemlerden DBSCAN kümeleme algoritması ve En Yakın Komşu (EYK) algoritması ile birlikte başlangıç popülasyonunun oluşturulmasında kullanılacaktır.

3.3.1 Sobol Dizileri

Sobol dizileri, düşük sapmalı (low-discrepancy) sayılar üreten bir Quasi-Monte Carlo (QMC) tekniğidir. Sobol dizileri, rastgele sayı üreticilerine kıyasla daha iyi bir dağılıma sahiptir ve özellikle yüksek boyutlu integral hesaplamalarında ve optimizasyon problemlerinde kullanılır. Rus matematikçi Ilya M. Sobol tarafından 1967 yılında geliştirilmiştir (Sobol, 1967). Sobol dizileri, ikili tabanda çalışan, ardışık vektörler üreten bir yöntemdir. Bu diziler, özel vektörler kullanarak her yeni sayıyı bir öncekine bağlı şekilde hesaplar. Sayılar, ikili sistemde oluşturulur ve ardından ondalık sisteme çevrilerek kullanılır. Vektör tabanlı bir dönüşüm mekanizmasıyla üretilen sayılar, standart rastgele dizilere kıyasla daha düzenli bir dağılıma sahiptir (Antonov ve Saleev, 1979). Sobol dizileri, birçok farklı alanda kullanılan düşük sapmalı dizilerdir. Finans alanında, opsiyon fiyatlandırma gibi Monte Carlo simülasyonları gerektiren işlemlerde ve portföy optimizasyonu gibi risk analizlerinde kullanılır. Mühendislik ve simülasyon çalışmalarında ise hassasiyet analizi ve belirsizlik propagasyonu için tercih edilir. Ayrıca, Hesaplamalı Akışkanlar Dinamiği ve Sonlu Elemanlar Tekniği gibi mühendislik simülasyonlarında önemli bir rol oynar (Caflisch, 1998). Makine öğrenmesi ve optimizasyon süreçlerinde de yaygın olarak kullanılan Sobol dizileri, hiperparametre optimizasyonunda rastgele arama yerine daha düzenli bir örnekleme sağlamak amacıyla tercih edilir. Ayrıca, Bayes optimizasyonu ve genetik algoritmalarda başlangıç popülasyonu oluşturulma aşamasında kullanılır. Fiziksel bilimler ve hesaplamalı biyoloji alanında ise istatistiksel mekanik ve kuantum hesaplamalarda daha etkili numune üretmek için uygulanırken, biyolojik sistemlerin modellenmesi ve simülasyonu için de kullanılmaktadır (Emec ve Özcanhan, 2023).

Sobol dizileri, rastgele sayılardan farklı olarak belirli bir alanda daha homojen bir dağılım sağlayarak daha düzenli bir kapsama sahiptir. Düşük sapma özelliği sayesinde Monte Carlo simülasyonlarında daha hızlı yakınsama elde edilir. Ayrıca, yüksek boyutlu problemlerde de etkili bir şekilde çalışarak ölçeklenebilirlik avantajı sunar. Deterministik

ancak rastgele sayıların avantajlarını da içeren yapısıyla Sobol dizileri, özellikle bu tür uygulamalarda tercih edilir. Monte Carlo yöntemlerine kıyasla daha iyi bir yakınsama oranı sunduğundan, bilimsel hesaplamalar ve mühendislik uygulamalarında etkin olarak kullanılır (Liu ve Han, 2017.). Şekil 3.4'te görüldüğü gibi, Sobol dizisinin oluşturulma süreci belirli adımlar halinde ilerlemektedir. İlk olarak dizinin boyutu belirlenir; bu, üretilecek nokta sayısının hangi uzayda (örneğin 2D, 3D) yer alacağını tanımlar. Ardından her boyut için uygun ilkel polinomlar seçilir. Bu polinomlar, yön vektörlerinin hesaplanmasında temel rol oynar. Üçüncü adımda, bu ilkel polinomlara bağlı olarak her boyut için yön vektörleri hesaplanır. Daha sonra bit manipülasyonu teknikleri kullanılarak Sobol dizisinin her bir bileşeni oluşturulur; bu adımda genellikle XOR gibi işlemlerle sayılar türetilir. Son olarak, elde edilen sayılar bir dizi şeklinde oluşturulup kaydedilir. Tüm bu adımlar tamamlandıktan sonra süreç sona erer (Gürsu ve Kent, 2012). Sobol dizilerini oluşturmak için çeşitli karmaşık matematik işlemler kullanılmaktadır. Bu dizileri oluşturmak için tezimizde daha doğru sonuçlar almak için Python programlama dilinde yer alan hazır kütüphaneler kullanılmıştır. Python'daki `scipy.stats.qmc.Sobol` kütüphanesini veya R'deki `sobolgen` paketini kullanarak Sobol dizileri oluşturulabilir (The SciPy community, t.y.).



Şekil 3.4 Sobol dizisi oluşturma adımları

3.3.2 Dbscan Algoritması

DBSCAN (Density-Based Spatial Clustering of Applications with Noise), yoğunluğa dayalı bir kümeleme yöntemidir. Veri noktalarını yoğunluklarına göre gruplandırarak çalışır ve geleneksel kümeleme yöntemlerinden farklı olarak küme

sayısının önceden belirlenmesini gerektirmez. Algoritma, belirli bir yarıçap içindeki veri noktalarının sayısına bağlı olarak yoğun bölgeleri tespit eder ve kümeler oluşturur (Deng, 2020). DBSCAN, iki temel parametreye dayanır: Epsilon (ϵ) ve MinPts (minimum nokta sayısı). Epsilon, bir noktanın komşularını belirlemek için kullanılan mesafe eşik değeri iken, MinPts belirli bir bölgenin yoğun olarak kabul edilmesi için ihtiyaç duyulan minimum nokta sayısını ifade eder. Algoritma, bir noktayı çekirdek nokta, sınır noktası veya gürültü noktası olarak sınıflandırır. Çekirdek noktalar, belirlenen yarıçap içinde yeterli sayıda komşuya sahip olan noktalardır ve kümelerin oluşmasını sağlar. Sınır noktaları, yoğun bölgelerde bulunan ancak çekirdek nokta olamayacak kadar az komşusu olan noktalardır. Gürültü noktaları ise hiçbir kümeye dahil edilemeyen noktalardır (Deng, 2020).

DBSCAN'ın en büyük avantajlarından biri, farklı yoğunluklara sahip verilerde başarılı bir şekilde çalışabilmesi ve gürültülü verileri dışarıda bırakabilmesidir. Özellikle küresel olmayan şekillere sahip kümeleri tespit etmekte iyi performans gösterir. Ancak, optimum parametre değerlerini belirlemek zorluk yaratabilir ve değişken yoğunluklu kümelerde performansı düşebilir. Yüksek boyutlu verilerde de hesaplama maliyeti arttığı için uygulanması zorlaşabilir (Tekbir ve Albayrak, 2010). DBSCAN, coğrafi veri analizi, anomali tespiti, görüntü işleme ve biyoinformatik gibi birçok alanda etkin olarak kullanılmaktadır. Özellikle yoğunluk tabanlı analizlerin önemli olduğu veri kümelerinde etkili bir kümeleme yöntemi olarak öne çıkar. DBSCAN algoritması, yoğunluk tabanlı bir kümeleme yöntemi olarak belirli kurallar ve adımlarla oluşturulur (Deng, 2020; Tekbir ve Albayrak, 2010).

DBSCAN algoritması, veri kümesindeki noktaların yoğunluklarına göre kümeler oluşturmayı amaçlayan bir kümeleme yöntemidir. Algoritma, her bir veri noktasının daha önce ziyaret edilip edilmediğine göre işlem yaparak başlar ve tüm noktaları tek tek inceler. Her nokta için, belirlenen ϵ (epsilon) yarıçapı içindeki komşular hesaplanır. Eğer bu komşu sayısı belirli bir eşik değeri olan MinPts'ten fazlaysa, bu nokta çekirdek nokta olarak ele alınır. Çekirdek nokta olan bir noktadan başlanarak, kendisine bağlı komşu noktalar kümeye dahil edilir ve bu işlem, kümeye yeni katılan diğer çekirdek noktalar için de tekrarlanarak küme genişletilir. Bu süreçte, çekirdek noktalara bağlı olmayan ancak küme içinde yer alan noktalar sınır noktası olarak değerlendirilir; bu noktalar kümeye eklenir ancak başka noktaları kümeye dahil edemez. Eğer bir nokta, hiçbir kümenin

parçası olamazsa, bu nokta gürültü olarak işaretlenir. Algoritma, tüm noktalar işlenene kadar devam eder. Sonuç olarak, DBSCAN algoritması farklı yoğunluklara sahip veri bölgelerine dayalı olarak kümeler oluşturur ve bu kümelerin dışında kalan noktaları gürültü olarak tanımlar. Bu çalışma kapsamında gürültüleri de küme olarak ele alacağımız için MinPts değeri 1 olarak alınmıştır.

3.3.3 En Yakın Komşu Sezgiseli (EYK)

EYK, bir noktadan başlayarak en yakın komşuya gitme prensibine dayalı bir yol belirleme yöntemidir. Algoritma, seçilen başlangıç noktasından itibaren her adımda henüz ziyaret edilmemiş en yakın noktayı seçerek ilerler. Bu süreç tüm noktalar ziyaret edilinceye kadar sürdürülür (Aburomman, ve Reaz, 2016) .

EYK, GSP için başlangıç çözümü oluşturmak nedeniyle kullanılan basit ve etkili bir yöntemdir. Bu yöntemde öncelikle bir başlangıç noktası belirlenir. Ardından, mevcut konuma en yakın şehir seçilerek ziyaret edilir ve her bir şehir yalnızca bir kez ziyaret edilir. Bu işlem, tüm şehirler ziyaret edilene kadar tekrarlanır. Tüm şehirler ziyaret edildikten sonra, son şehirden başlangıç noktasına geri dönülerek tur tamamlanır. Böylece, şehirler arası en kısa mesafeye dayalı, döngüsel bir gezi rotası elde edilir (Karagül, 2019).

EYK, hızlı ve basit bir optimizasyon yöntemi olarak özellikle GSP gibi rota optimizasyonlarında kullanılır. Ancak, her zaman en iyi çözüm garantisi yoktur. Bu nedenle, Genetik Algoritma (GA), Tavlama Benzetimi (TB) veya Tabu Arama (TA) gibi daha gelişmiş optimizasyon algoritmalarında bir başlangıç çözümü olarak kullanılması önerilir (Yıldırım vd., 2016).

3.4 Önerilen Yöntem

Bu çalışmada, AVOA kullanılarak GSP çözülmüştür. AVOA'nın başlangıç popülasyonunun kalitesinin, algoritmanın genel başarımını doğrudan etkilediği göz önünde bulundurularak, bu aşamada farklı stratejiler uygulanmıştır. İlk olarak klasik rastgele sayı üretimi ve Sobol dizileri kullanılarak başlangıç popülasyonları oluşturulmuştur. Ardından, bu popülasyonlar yoğunluk tabanlı kümeleme algoritması

olan DBSCAN ile işlenmiş, böylece yakın konumda bulunan şehirlerin birlikte gruplanması sağlanmıştır. DBSCAN ile oluşturulan her bir küme içerisindeki şehirlerin sıralanması ise hem rastgele hem de Sobol dizileri kullanılarak gerçekleştirilmiştir. Böylece küme içi sıralamanın da optimizasyon sürecine etkisi değerlendirilmiştir. Daha sonra, En Yakın Komşuluk (EYK) sezgisel yöntemi, GSP'ye uygun başlangıç bireyleri üretmek amacıyla kullanılmıştır. Bu süreçte de EYK algoritmasının başlangıç noktaları hem rastgele hem de Sobol dizilerine dayalı olarak seçilmiştir. Böylece EYK'nın çözüm kalitesi üzerindeki etkisi başlangıç koşullarına göre incelenmiştir. Önerilen bütün yöntemler sonucunda bulunan bireyler, AVOA için daha dengeli, çeşitlilik içeren ve çözüm uzayını daha iyi temsil eden bir başlangıç popülasyonu oluşturulmuştur. Bu yaklaşım sayesinde, algoritmanın daha hızlı yakınsama göstermesi ve daha kaliteli çözümler üretmesi hedeflenmiştir. Çalışmanın temel amacı, farklı başlangıç popülasyonu oluşturma stratejilerinin AVOA algoritmasının performansı üzerindeki etkisini karşılaştırmak ve GSP gibi karmaşık kombinatoriyel problemlerde en verimli başlangıç yaklaşımını belirlemektir. Elde edilen sonuçlar, Sobol dizilerinin, kümeleme tabanlı sıralama yöntemlerinin ve sezgisel yaklaşımların optimizasyon sürecine katkılarını kapsamlı bir şekilde değerlendirmek üzere analiz edilmiştir.



4. BULGULAR

4.1 Kullanılan Veri Seti

Çalışmada gerçekleştirilen tüm deneylerde, GSP ile ilgili çeşitli veri setlerini içeren TSPLIB kütüphanesinden yararlanılmıştır (Reinelt,1991). TSPLIB, farklı şehir sayılarının olduğu veri setlerini ve her veri seti için bulunmuş optimal tur mesafelerini içeren bir referans kütüphanesidir. Bu çalışmada bulunan deneysel sonuçlar, TSPLIB' de yer alan optimum değerler ile karşılaştırılarak analiz edilip değerlendirilmiştir.

4.2 Kullanılan Parametreler

51 şehirlik ve 280 şehirlik koordinatların yer aldığı küçük ve büyük boyutlu iki veri setine ait parametreler, yapılan testler sonucunda belirlenmiş olup, en iyi sonuçları veren parametreler Çizelge 4.1–4.3'te sunulmuştur. Testler, Google Colab Pro+ ortamında v5e-1 TPU altyapısı kullanılarak, Python 3 programlama dili ile gerçekleştirilmiştir. Sonlandırma kriteri olarak maksimum iterasyon sayısı esas alınmış ve bu iterasyona ulaşıldığında algoritmanın çalışması sonlandırılmıştır.

Çizelge 4.1 Genel parametreler

Veri Seti	Çalıştırma Sayısı	Popülasyon Boyutu	İterasyon Sayısı
eil51	50	100	25000
a280	50	300	150000

Çizelge 4.2 DBSCAN için kullanılan parametreler

Veri Seti	Epsilon	Min_pts
eil51	7.5	1
a280	10	1

Çizelge 4.3 AVOA için kullanılan parametreler

$\lambda 1$	$\lambda 2$	$\rho 3$	$K1$	$K2$	$K3$
0.8	0.2	2.5	0.6	0.4	0.6

4.3 Değerlendirme Kriterleri

Bu tez çalışmasında, GSP üzerinde uygulanan algoritmaların performanslarını nicel olarak değerlendirmek amacıyla çeşitli istatistiksel ve hesaplama dayalı ölçütler kullanılmıştır. Kullanılan değerlendirme kriterleri aşağıda tanımlanmıştır:

Ortalama Çözüm Değeri:

Her bir algoritmanın belirli bir problem örneği üzerinde çoklu çalışmaları sonucunda elde edilen tur uzunluklarının aritmetik ortalamasıdır.

$$\mu = \frac{1}{N} \sum_{i=1}^N S_i \quad (4.1)$$

Burada S_i , i . çalışmada elde edilen çözüm değerini, N ise toplam tekrar sayısını ifade eder.

Standart Sapma:

Elde edilen çözüm değerlerinin ortalama etrafındaki varyasyonunu belirtir. Kararlılık ve tutarlılık analizi için kullanılır.

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (S_i - \mu)^2} \quad (4.2)$$

En İyi Çözüm:

Algoritmanın tüm çalışmaları boyunca ulaştığı en düşük tur uzunluğudur ve algoritmanın en yüksek başarı kapasitesini temsil eder.

$$\begin{aligned} S_{best} \\ = \min\{S_1, S_2, \dots, S_N\} \end{aligned} \quad (4.3)$$

En Kötü Çözüm:

Tüm çalışmalar içinde elde edilen en yüksek tur uzunluğudur.

$$\begin{aligned}
& Sworst \\
& = \max\{S1, S2, \dots, SN\}
\end{aligned} \tag{4.4}$$

Optimal Çözümüne Göre Sapma Oranı:

Literatürde bilinen en iyi (optimal) çözüm değeriyle karşılaştırmalı olarak, algoritmanın ortalama çözümünün sapma yüzdesini ifade eder.

$$\begin{aligned}
& Sapma(\%) \\
& = \left(\frac{\mu - S_{opt}}{S_{opt}} \right) \times 100
\end{aligned} \tag{4.5}$$

Burada S_{opt} , TSPLIB gibi standart veri kümelerinde tanımlanmış olan optimal çözümdür (Reinelt, 1991).

Ortalama Çalışma Süresi:

Algoritmanın her bir çalıştırmasının tamamlanması için geçen sürenin ortalamasıdır ve hesaplama verimliliği hakkında bilgi sağlar.

$$t_{avg} = \frac{1}{N} \sum_{i=1}^N t_i \tag{4.6}$$

Burada t_i , i . çalıştırmanın çalışma süresidir.

Başlangıç Ortalama Çözüm Değeri:

Başlangıç popülasyonunda yer alan bireylerin ortalama çözüm kalitesini ifade eder. Başlangıç stratejisinin algoritmanın başarımı üzerindeki etkisini değerlendirmek için kullanılır.

$$\mu_{initial} = \frac{1}{M} \sum_{j=1}^M I_j \tag{4.7}$$

Burada I_j , başlangıç popülasyonundaki bireylerin tur uzunlukları, M ise popülasyon boyutudur.

Bu tezde tanımlanan değerlendirme ölçütleri, algoritmaların performanslarını çok boyutlu bir perspektiften analiz etme olanağı sunmaktadır. Performans değerlendirmesi kapsamında kullanılan kriterler; çözüm kalitesi, hesaplama verimliliği ve istikrar olmak üzere üç temel bileşen üzerinden nicel olarak ele alınmaktadır. Çözüm kalitesi, algoritmaların elde ettiği ortalama çözüm değeri (Eşitlik 4.1), standart sapma (Eşitlik 4.2), en iyi çözüm (Eşitlik 4.3), en kötü çözüm (Eşitlik 4.4) ve optimal çözümden sapma oranı (Eşitlik 4.5) gibi metriklerle değerlendirilmektedir. Ayrıca, algoritmaların başlangıç noktalarının genel başarımlar üzerindeki etkisini ortaya koymak amacıyla başlangıç ortalama çözüm değeri (Eşitlik 4.7) dikkate alınmaktadır. Hesaplama verimliliği ise algoritmanın çalışması sırasında harcadığı süre (Eşitlik 4.6) üzerinden analiz edilmektedir. Özellikle optimal çözüme yakınlık, elde edilen sonuçların tutarlılığı ve başlangıç çözüm stratejisinin etkisi, GSP gibi çözümü polinomsal zamanda bulunamayan zorlayıcı kombinatoriyal optimizasyon problemlerinde algoritmaların başarımlar üzerinde belirleyici unsurlar olarak öne çıkmaktadır (Talbi, 2009).

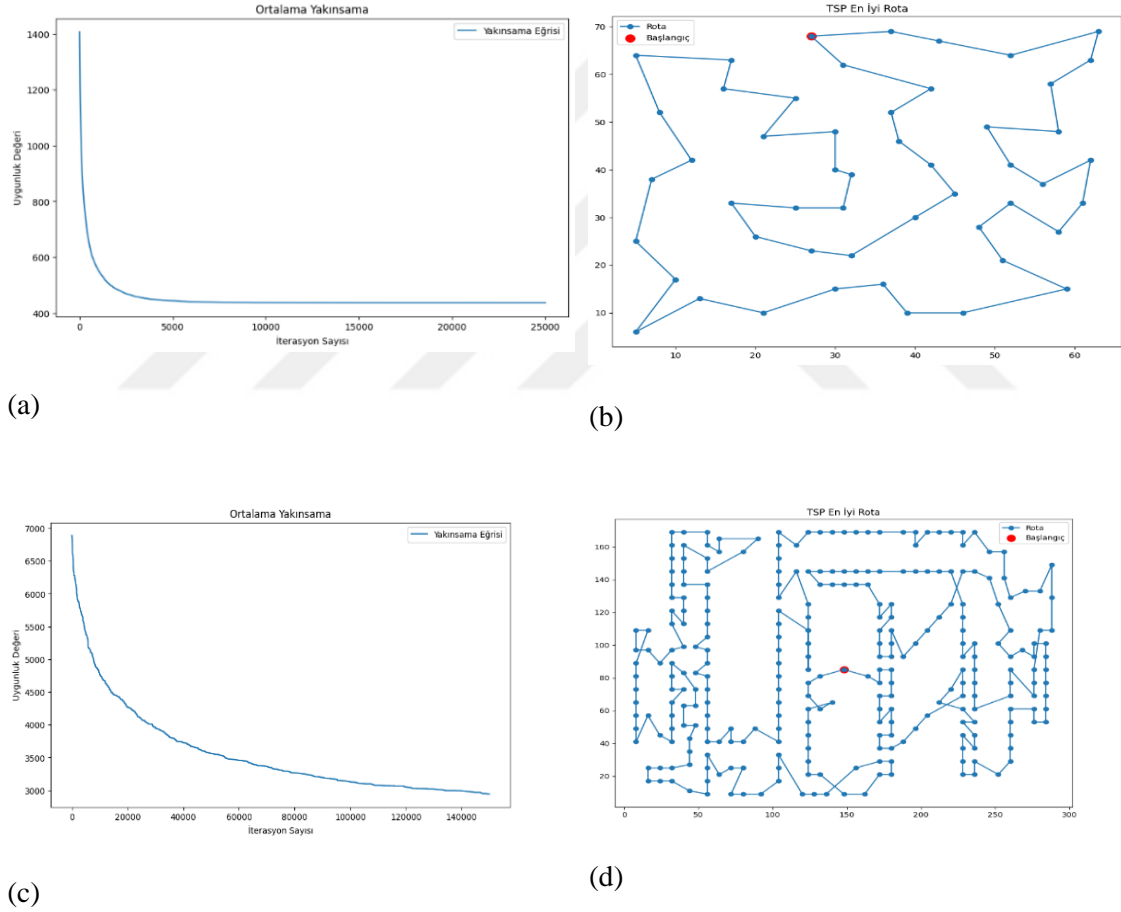
4.4 Sobol ve Rastgele Yöntem Karşılaştırma

İlk aşamada AVOA algoritması başlangıç popülasyonu rastgele ve sobol dizileri ile oluşturularak Çizelge 4.4'te görüldüğü gibi bulgular elde edilmiştir. Ayrıca ortalama yakınsama eğrisi ve en iyi rotalar Şekil 4.1'de görüldüğü gibi bulunmuştur.

Çizelge 4.4 Sobol ve rastgele başlangıç ile oluşturulan yöntem sonuçları

Veri Seti	Başlatma Yöntemi	Başlangıç Ortalama Çözüm	Optimal Çözüm	Ortalama Çözüm	En İyi		En İyi Çözüm	En Kötü Çözüm	Ortalama çözüm Süresi (sn)
					Çözüm	Standart Sapma			
eil51	Rastgele	1430.50	426	436.67	2.50	2.37	428.87	441.91	48.29
	Sobol	1313.47	426	436.43	2.45	2.82	430.44	441.92	48.65
a280	Rastgele	31627.33	2579	2967.38	15.05	36.98	2894.65	2996.1	978.91
	Sobol	6980.50	2579	2942.33	14.08	17.70	2922.90	2965.7	981.07

Çizelge 4.4' te görüldüğü gibi; Sobol dizileri ile oluşturulan başlangıç popülasyonu, genel olarak rastgele başlangıç popülasyonuna göre daha iyi sonuçlar vermektedir. Ortalama çözüm değerleri Sobol dizileri ile daha düşük çıkmış, en iyi çözümden sapma oranı daha az olmuş ve özellikle büyük veri setlerinde daha stabil sonuçlar elde edilmiştir. Ayrıca Sobol dizileri, çözüm süresi açısından da küçük bir avantaj sağlamaktadır. Küçük veri seti (ei151) için rastgele başlatma bazen daha iyi en iyi çözüm sunabilse de, büyük veri seti (a280) için Sobol dizileri belirgin şekilde daha başarılıdır. Bu nedenle, büyük ölçekli problemler için Sobol dizileri daha uygun bir başlangıç yöntemi olarak değerlendirilebilir.



Şekil 4.1 (a) ei151 yakınsama eğrisi, (b) ei151 en iyi rota, (c) a280 yakınsama eğrisi, (d) a280 en iyi rota

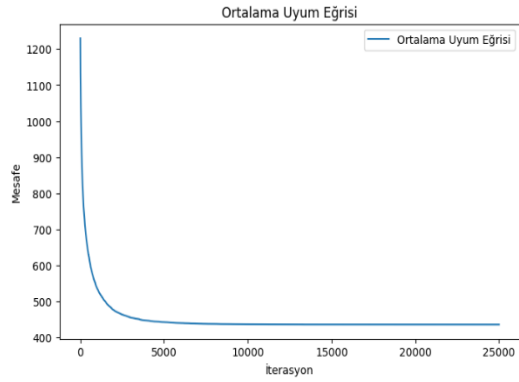
4.5 DBSCAN Kümeleme Algoritması Karşılaştırma

DBSCAN algoritması ile başlangıç popülasyonu oluşturulmuş ilk olarak kümeler oluşturulduktan sonra hem küme elemanları hem de kümeler rastgele ve sobol dizileri ile ayrı ayrı karıştırılarak başlangıç rotaları oluşturulmuş her iki yönteme ait Çizelge 4.5'te görünen sonuçlar bulunmuştur.

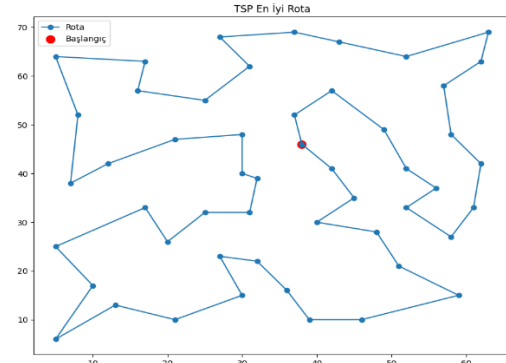
Çizelge 4.5 DBSCAN ile başlatılan yöntem sonuçları

Veri Seti	Başlatma Yöntemi	Başlangıç Ortalama Çözüm	Optimal Çözüm	Ortalama Çözüm	En İyi Çözümünden Sapma (%)	Standart Sapma	En İyi Çözüm	En Kötü Çözüm	Ortalama çözüm Süresi
eil51	Rastgele	1650.20	426	436.98	2.57	2.48	432.35	441.83	48.49
	Sobol	1174.95	426	436.56	2.47	2.51	430.86	442.36	49.26
a280	Rastgele	34104.80	2579	2994.20	16.09	11.54	2979.27	3011.8	975.19
	Sobol	15485.22	2579	2950.6	14.40	8.73	2940.73	2962	975.22

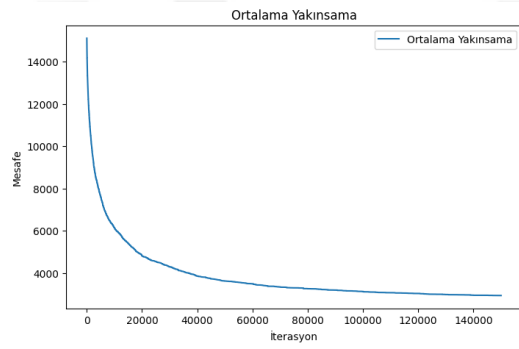
Çizelge 4.5' te görüldüğü gibi; Sobol dizileri ile oluşturulan başlangıç popülasyonu, ortalama, en iyi ve en kötü çözümler açısından daha iyi bir performans sağlıyor. Standart sapmanın daha düşük olması, sonuçların daha istikrarlı olduğunu gösteriyor. Ancak çözüm süresi açısından belirgin bir fark gözlenmiyor. Bu sonuçlar, Sobol dizilerinin başlangıç popülasyonunda kullanıldığında çözüm kalitesini artırabileceğini ve daha tutarlı sonuçlar sağlayabileceğini gösteriyor. Ayrıca ortalama yakınsama eğrisi ve en iyi rotalar Şekil 4.2'de görüldüğü gibidir.



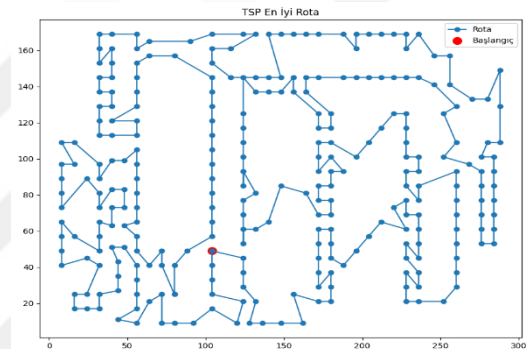
(a)



(b)



(c)



(d)

Şekil 4.2 (a) eil 51 yakınsama eğrisi, (b) eil51 en iyi rota, (c) a280 yakınsama eğrisi, (d) a280 en iyi rota

4.6 EYK Sezgiseli Karşılaştırma


EYK sezgiseli başlangıç popülasyonu oluşturmada kullanılmış, EYK algoritmasının başlangıç aşaması hem rastgele hem de sobol dizileri ile ayrı ayrı oluşturulup Çizelge 4.6'daki sonuçlar elde edilmiştir. Ayrıca ortalama yakınsama eğrisi ve en iyi rotalar Şekil 4.3'da verilmiştir.

Çizelge 4.6 EYK ile başlatma sonuçları

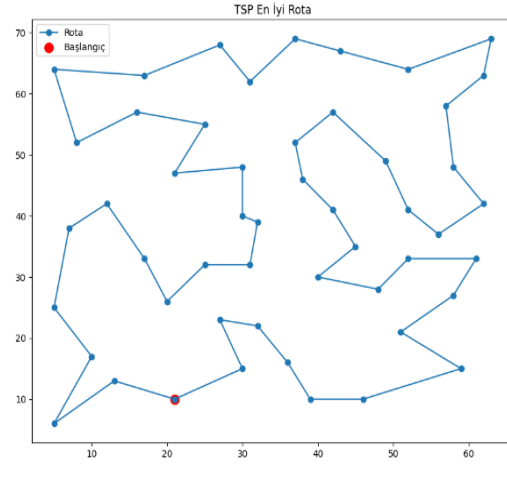
Veri Seti	Başlatma Yöntemi	Optimal Çözüm	Başlangıç Ortalama Çözüm	Ortalama Çözüm	En İyi Çözümünden Sapma (%)	Standart Sapma	En İyi Çözüm	En Kötü Çözüm	Ortalama Çözüm Süresi
eil51	Rastgele	426	565.28	432.74	1.58	2.0	430.60	435.66	49.36
	Sobol	426	563.22	432.00	1.40	1.07	431.10	434.04	49.04
a280	Rastgele	2579	3320.23	2744.08	6.40	13.16	2726.43	2758	1087.81
	Sobol	2579	3310.27	2732.40	5.94	3.94	2726.86	2735.7	1038.84

Çizelge 4.6’da görüldüğü gibi; Sobol yöntemi kullanıldığında hem eil51 hem de a280 veri setlerinde daha iyi sonuçlar elde edilmiştir. Özellikle ortalama çözüm değerleri Sobol yöntemiyle optimal çözüme daha yakın gerçekleşmiş, en iyi çözümden sapma oranı daha düşük olmuştur. Bu, Sobol dizileriyle başlatılan popülasyonun daha kaliteli çözümler ürettiğini göstermektedir. Ayrıca, standart sapma değerleri Sobol yöntemiyle daha düşük çıkmış, bu da sonuçların daha tutarlı ve istikrarlı olduğunu ortaya koymaktadır. En kötü çözüm açısından da Sobol yöntemi daha başarılı olmuş, yani çözüm kalitesi genel olarak daha iyi korunmuştur.


Çözüm süreleri açısından belirgin bir fark olmasa da Sobol dizileriyle başlatılan popülasyon, daha düşük sapmalar ve daha iyi ortalama çözümlerle algoritmanın performansını artırmıştır. Bu bulgular, EYK algoritmasını Sobol dizileriyle başlatmanın, AVOA’nın daha kararlı ve kaliteli sonuçlar üretmesine katkı sağladığını göstermektedir. Özellikle büyük ölçekli problemler için Sobol dizilerinin daha avantajlı olduğu söylenebilir. Şekil 4.3’te her iki veri seti için yakınsama eğrileri ve en iyi rotalar verilmiştir. Aynı şartlar altında değerlendirme yapılmıştır bu nedenle büyük veri setinde daha büyük iterasyon ve başlangıç popülasyonu verilerek daha iyi sonuçların elde edileceği Şekil 4.3(c)’teki yakınsama eğrisinde görülmektedir.




(a)



(b)



(c)



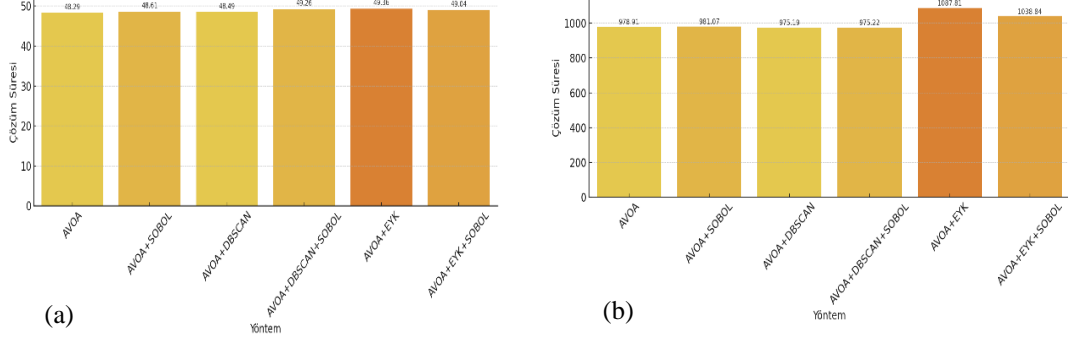
(d)

Şekil 4.3 (a) eil 51 yakınsama eğrisi, (b) eil51 en iyi rota, (c) a280 yakınsama eğrisi, (d) a280 en iyi rota

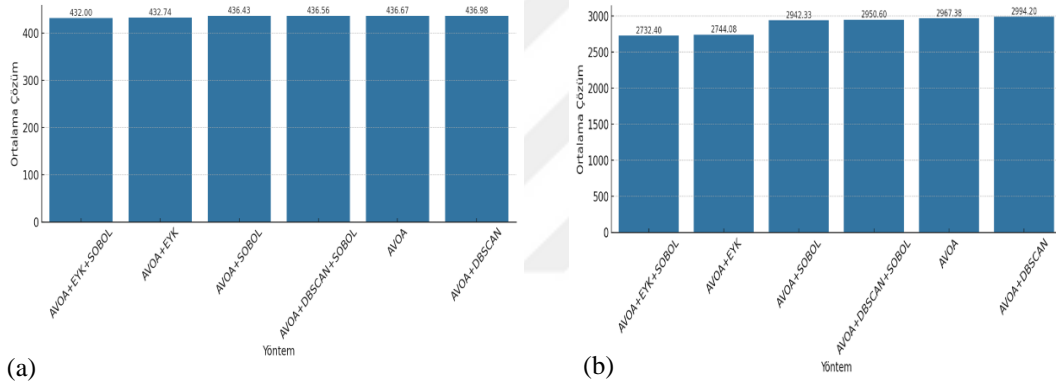
4.7 Genel Karşılaştırma

Çizelge 4.4: AVOA algoritmasının klasik hali, yani yalnızca rastgele ve Sobol başlatılması ile elde edilen sonuçları gösteriyor. Çizelge 4.5: AVOA algoritmasının DBSCAN ile başlatılmış hali, yani başlangıç popülasyonunun DBSCAN kümeleme yöntemiyle iyileştirilmiş halini gösteriyor. Çizelge 4.6: AVOA algoritmasının EYK ile başlatılmış hali, yani başlangıç popülasyonunun EYK yöntemiyle iyileştirilmiş hali. Şekil


4.4 - 4.6’da her iki veri seti için ortalama çalışma süreleri, ortalama çözümler ve standart sapmalar verilmiş olup bütün yöntemler birbiriyle karşılaştırılmıştır.



Şekil 4.4 Ortalama çalışma süreleri (a) eil51 (b) a280



Şekil 4.5 Ortalama çözümler (a) eil51 (b) a280



Şekil 4.6 Standart sapmalar (a) eil51 (b) a280

4.7.1 Klasik AVOA (Çizelge 4.4) ve DBSCAN ile Başlatılmış AVOA (Çizelge 4.5)

Çalışmada elde edilen bulgular, DBSCAN algoritmasının başlangıç popülasyonu oluşturma sürecine dahil edilmesinin, AVOA'nın performansını çeşitli açılardan olumlu yönde etkilediğini göstermektedir. Ortalama çözüm değeri açısından incelendiğinde, DBSCAN ile başlatılan yöntemlerin genellikle daha iyi sonuçlar ürettiği görülmektedir. Örneğin, eil51 veri setinde klasik Sobol yöntemiyle elde edilen ortalama çözüm 436.43 iken, DBSCAN destekli Sobol yöntemiyle bu değer 436.56'ya ulaşmıştır. Her ne kadar küçük bir fark olsa da bu durum yöntemlerin tutarlılığı açısından önemlidir. Ancak a280 gibi daha büyük veri setlerinde bu fark daha az belirgindir; klasik Sobol yöntemiyle 2942.33 olan ortalama çözüm, DBSCAN ile 2950.6'ya yükselmiştir. Bu da, DBSCAN'ın büyük veri setlerinde ortalama çözüm açısından çok belirgin bir avantaj sağlamadığını göstermektedir.

Sapma oranı açısından değerlendirildiğinde ise DBSCAN'ın daha olumlu etkiler yarattığı görülmektedir. eil51 veri setinde DBSCAN ile başlatılan Sobol yöntemi, klasik yöntemle göre daha iyi bir sapma oranına sahiptir (2.82% yerine 2.51%). Özellikle a280 veri setinde bu fark daha dikkat çekicidir; klasik Sobol yöntemiyle 17.70% olan sapma oranı, DBSCAN destekli yöntemde 8.73%'e düşmüştür. Bu da DBSCAN'ın başlangıç popülasyonunu homojenleştirerek çözüm çeşitliliğini azalttığını ve daha kararlı sonuçlara ulaşılmasını sağladığını göstermektedir.

Çözüm süresi açısından bakıldığında, klasik AVOA yöntemi ile DBSCAN ve Sobol tabanlı varyantlar arasında çok büyük farklar gözlemlenmemektedir; ancak a280 veri setinde, DBSCAN kullanımı (975,19 sn), klasik AVOA'ya (978,91 sn) ve AVOA+Sobol'a (981,07 sn) kıyasla çok sınırlı da olsa daha hızlı bir çözüm sunmuştur.

Genel olarak değerlendirildiğinde, DBSCAN algoritmasının AVOA'nın başlangıç popülasyonuna entegre edilmesi, özellikle çözümün kararlılığı (daha düşük sapma oranı) ve çözüm kalitesinin tutarlılığı açısından olumlu katkılar sunarken, çözüm süresi üzerinde kısıtlı bir etkisi olduğu görülmektedir. Bu da DBSCAN'ın büyük veri setlerinde hız açısından belirleyici bir avantaj sağlamasa da, daha dengeli ve güvenilir sonuçlara ulaşılmasında etkili bir strateji olduğunu göstermektedir.

4.7.2 Klasik AVOA (Çizelge 4.4) ve EYK ile Başlatılmış AVOA (Çizelge 4.6)

Yapılan analizler, EYK sezgiselinin Sobol dizileriyle birlikte kullanıldığında, AVOA algoritmasının başlangıç popülasyonunu önemli ölçüde iyileştirdiğini ortaya koymaktadır. Ortalama çözüm açısından değerlendirildiğinde, EYK ile başlatılan Sobol yöntemi, en iyi sonuçları üretmiştir. Örneğin, eil51 veri setinde klasik Sobol yöntemiyle elde edilen ortalama çözüm 436.43 iken, EYK-Sobol yöntemiyle bu değer 432.00'e düşmüştür. Bu etki, daha büyük veri setlerinde çok daha belirgin hale gelmiştir; a280 veri setinde klasik Sobol ile 2942.33 olan ortalama çözüm, EYK-Sobol yöntemiyle 2732.40'a kadar gerilemiştir. Bu sonuçlar, EYK yönteminin çözüme daha yakın bireylerle başlama avantajını açıkça ortaya koymaktadır.

Sapma oranı bakımından da EYK yöntemi en düşük değerleri sağlamıştır. eil51 veri setinde klasik Sobol'un sapma oranı %2.45 iken, EYK-Sobol yöntemiyle bu oran %1.40'a düşmüştür. a280 veri setinde ise bu fark çok daha dikkat çekicidir; klasik Sobol ile %14.08 olan sapma oranı, EYK ile %5.94'e kadar inmiştir. Bu durum, EYK'nın sadece daha iyi sonuçlar üretmekle kalmayıp, aynı zamanda daha istikrarlı ve tutarlı çözümler sağladığını göstermektedir.

Klasik yöntemler (AVOA ve AVOA+Sobol), hem eil51 hem de a280 veri setlerinde EYK tabanlı versiyonlara kıyasla daha kısa ortalama çalışma süresi göstermiştir. Özellikle a280 veri setinde, klasik AVOA yöntemi 978,91 saniyede sonuç verirken, EYK tabanlı yöntemler bu süreyi 1038,84 ila 1087,81 saniyeye kadar çıkarmıştır. Bu durum, EYK stratejisinin çözüm süresini artırdığını göstermektedir.

Genel olarak değerlendirildiğinde, EYK yöntemiyle oluşturulan başlangıç popülasyonları, AVOA algoritmasının performansını her açıdan geliştirmektedir. Hem ortalama hem de en iyi çözüm değerleri iyileşmekte, sapma oranları azalarak çözümler daha kararlı hale gelmekte ve çözüm süresinde de ciddi bir fark görülmemektedir. Bu da EYK'nın, başlangıç popülasyonlarını iyileştirmede son derece etkili bir yöntem olduğunu göstermektedir.

4.7.3 DBSCAN ve EYK (Çizelge 4.5 ve Çizelge 4.6)

Yapılan karşılaştırmalar, EYK sezgiselinin, DBSCAN algoritmasına kıyasla AVOA'nın başlangıç popülasyonunu oluşturma sürecinde kayda değer bir etkililik sunduğunu göstermektedir. Ortalama çözüm değerleri açısından bakıldığında, EYK ile başlatılan yöntemlerin DBSCAN'a göre daha üstün sonuçlar ürettiği görülmektedir. Örneğin, eil51 veri setinde DBSCAN-Sobol yöntemiyle 436.56 olan ortalama çözüm, EYK-Sobol yöntemiyle 432.00'ye düşmüştür; a280 veri setinde ise DBSCAN-Sobol ile 2950.6 olan değer, EYK-Sobol yöntemiyle 2732.40 olarak elde edilmiştir. Bu durum, özellikle büyük veri setlerinde EYK'nın ciddi bir performans farkı yarattığını göstermektedir.

Sapma oranları açısından da EYK çok daha istikrarlı çözümler sunmaktadır. eil51 veri setinde DBSCAN-Sobol yöntemi %2.47 sapma üretirken, EYK-Sobol yöntemi bu oranı %1.40'a kadar düşürmüştür. a280 veri setinde ise DBSCAN ile %14.40 olan sapma oranı, EYK ile %5.94'e inmiştir. Bu farklar, EYK'nın sadece ortalama çözümde değil, aynı zamanda çözüm kararlılığında da daha başarılı olduğunu göstermektedir.

DBSCAN tabanlı yöntemler (avoa+dbscan ve avoa+dbscan+sobol), özellikle a280 veri setinde, EYK tabanlı yöntemlere göre belirgin şekilde daha kısa çözüm süresi sunmuştur. Örneğin, a280 veri setinde avoa+dbscan+sobol yöntemi 975,22 saniyede tamamlanırken, avoa+eyk+sobol yöntemi 1038,84 saniyede sonuca ulaşmıştır. Buna karşılık, eil51 veri setinde ise yöntemler arasında çözüm süresi bakımından kayda değer bir fark gözlenmemektedir.

Genel olarak değerlendirildiğinde, EYK yöntemi DBSCAN'a göre daha iyi ortalama çözümler üretmekte, sapmaları azaltmaktadır. DBSCAN başlangıç popülasyonunun kalitesini belirli ölçüde artırsa da, en iyi başlangıç popülasyonunu oluşturma konusunda EYK'nın çok daha üstün bir yaklaşım sunduğu söylenebilir.

4.7.4 Genel Değerlendirme

Yöntemlerin karşılaştırmalı analizi sonucunda, AVOA algoritmasının başlangıç popülasyonunun oluşturulmasında kullanılan stratejilerin performans üzerinde doğrudan etkili olduğu açıkça görülmektedir. Klasik AVOA yöntemi (Çizelge 4.4), rastgele

başlatma stratejisine dayandığı için en düşük performansı sergilemiştir. Bu yöntemde hem ortalama çözüm değerleri daha yüksek kalmakta hem de sapma oranları artmaktadır; dolayısıyla çözüm kalitesi ve tutarlılığı zayıflamaktadır.

DBSCAN ile başlatılan AVOA yöntemi (Çizelge 4.5), klasik yaklaşıma kıyasla ortalama çözümleri bir miktar iyileştirmiş ve sapmaları azaltarak çözüm kararlılığını artırmıştır. Ancak çözüm süresi bakımından anlamlı bir fark oluşturmadığı gözlemlenmiştir. Yine de, başlangıç popülasyonunun yoğunluk temelli gruplarla şekillendirilmesi, çözüm uzayının daha verimli taranmasına katkı sağlamıştır.

En başarılı sonuçlar ise EYK yöntemiyle başlatılan AVOA algoritmasından (Çizelge 4.6) elde edilmiştir. Bu yöntemde hem ortalama çözüm değerleri önemli ölçüde düşmüş, hem sapma oranları en düşük seviyelere ulaşmıştır. Özellikle büyük ölçekli veri setlerinde, EYK-Sobol yöntemi klasik ve DBSCAN destekli AVOA'ya kıyasla belirgin performans artışları sağlamıştır.

Sonuç olarak, EYK ile başlatılan AVOA algoritması en iyi performansı sergilemektedir. Bu yöntem, yalnızca çözüm kalitesini artırmakla kalmamakta, aynı zamanda daha istikrarlı sonuçlar üreterek özellikle büyük boyutlu problemlerde önemli avantajlar sunmaktadır.

4.8 Literatür İle Karşılaştırma

Karşılaştırma için Şahin ve Karagül'ün (2019), GSP'nde MAGA(Melez Akışkan Genetik Algoritma) yöntemi ile ilgili yaptıkları çalışma ile, Halim ve İsmail (2017), yapmış oldukları EYK(En Yakın Komşuluk), GA(Genetik Algoritma), BT(Benzetimli Tavlama), TA(Tabu Arama), KKO(Karınca Kolonisi Optimizasyonu) ve AFOA(Ağaç Fizyolojisi Optimizasyon Algoritması) üzerine yapılan çalışmaları kullanılmıştır. Her iki çalışmada test veri setleri tsplib kütüphanesinden alınmış ve ortalama çözüm, standart sapma, en iyi çözümler ve en kötü çözümler açısından sonuçlar Çizelge 4.7' de görüldüğü gibidir. Geliştirdiğimiz yöntemler olan klasik AVOA, AVOA+SOBOL, AVOA+DBSCAN, AVOA+DBSCAN+SOBOL, AVOA+EYK, AVOA+EYK+SOBOL'a ait sonuçlar da Çizelge 4.7'ye işlenmiştir.

Çizelge 4.7 Literatür ile karşılaştırma

Veri Seti	Yöntem	Optimal Çözüm	Ortalama Çözüm	En İyi		En İyi Çözüm	En Kötü Çözüm
				Çözüm	Sapma		
eil51	EYK	426	505.08	18.56	1.17	503.17	505.99
	GA	426	454.10	6.60	1.35	452.90	455.90
	BT	426	439.13	3.08	2.29	437.42	443.04
	TA	426	439.10	3.08	4.00	434.01	443.58
	KKO	426	467.46	9.73	0.91	466.54	468.43
	AFOA	426	437.26	2.64	1.65	435.28	438.91
	MAGA	426	427.40	0.33	0.97	426.00	429.00
	AVOA	426	436.67	2.50	2.37	428.87	441.91
	AVOA+SOBOL	426	436.43	2.45	2.82	430.44	441.92
	AVOA+DBSCAN	426	436.98	2.57	2.48	432.35	441.83
	AVOA+DBSCAN+SOBOL	426	436.56	2.47	2.51	430.86	442.36
	AVOA+EYK	426	432.74	1.58	2.0	430.60	435.66
	AVOA+EYK+SOBOL	426	432.00	1.40	1.07	431.10	434.04
	a280	EYK	2579	3094.21	19.98	0.43	3093.78
GA		2579	2789.83	8.82	47.47	2787.75	2894.43
BT		2579	2830.18	9.74	87.54	2766.43	2976.77
TA		2579	2800.79	8.60	13.18	2786.31	2816.81
KKO		2579	2867.85	11.20	88.22	2733.74	2965.85
AFOA		2579	2790.54	7.89	13.63	2763.00	2795.04
MAGA		2579	2634	2.13	0.00	2634	2634
AVOA		2579	2967.38	15.05	36.98	2894.65	2996.1
AVOA+SOBOL		2579	2942.33	14.08	17.70	2922.90	2965.7
AVOA+DBSCAN		2579	2994.20	16.09	11.54	2979.27	3011.8
AVOA+DBSCAN+SOBOL		2579	2950.6	14.40	8.73	2940.73	2962
AVOA+EYK		2579	2744.08	6.40	13.16	2726.43	2758
AVOA+EYK+SOBOL		2579	2732.40	5.94	3.94	2726.86	2735.7

Çizelge 4.7’de görüldüğü gibi, geliştirilen AVOA algoritması ve bu algoritmaya entegre edilen farklı başlangıç stratejileri (SOBOL, DBSCAN, EYK), eil51 ve a280 veri setleri ile literatürde olan optimizasyon yöntemleri ile karşılaştırılmış ve her iki problem boyutunda da üstün performans sergilemiştir.

eil51 veri seti özelinde değerlendirildiğinde, AVOA algoritmasının klasik hali dahi 436.67 ortalama çözüm değeri ile GA, EYK, BT, TA gibi birçok geleneksel yöntemi geride bırakmıştır. Ancak, başlangıç popülasyonunun SOBOL örnekleme ve EYK sezgisel bilgisinin katkısıyla oluşturulduğu AVOA+EYK+SOBOL yöntemi, 432.00 ortalama çözüm değeri ile en iyi sonucu üretmiş, aynı zamanda 1.40 en iyi çözümden

sapma ve 1.07 standart sapma ile kararlılığını da kanıtlamıştır. Bu sonuç, çözüm kalitesi ile birlikte çözüm güvenilirliğinin de artırıldığını göstermektedir.

a280 veri seti üzerindeki karşılaştırmalar da benzer şekilde olumlu sonuçlar sunmuştur. Literatürdeki EYK, GA, BT gibi birçok yöntemin yüksek ortalama çözüm değerlerine ulaştığı görülmektedir. Buna karşılık, AVOA algoritmasına SOBOL ve EYK desteklerinin entegre edildiği AVOA+EYK+SOBOL yöntemi, 2732.40 ortalama çözüm değeri ile MAGA yönteminden sonra diğer yöntemleri geride bırakmıştır. Ayrıca 5.94 sapma ve 3.94 standart sapma değeri ile düşük varyanslı ve istikrarlı sonuçlar üretmiştir. Bu da yöntemlerin büyük ölçekli problemler üzerinde de etkili olduğunu göstermektedir.

Genel olarak değerlendirildiğinde, önerilen AVOA tabanlı hibrit yaklaşımlar hem küçük boyutlu (eil51) hem de büyük boyutlu (a280) TSP örneklerinde; ortalama çözüm kalitesi, en iyi-en kötü çözüm farkı ve standart sapma değerleri bakımından literatürdeki yöntemlere kıyasla daha başarılı ve istikrarlı sonuçlar vermiştir. Bu bulgular, uygun başlangıç popülasyonlarının ve örnekleme stratejilerinin AVOA algoritmasının keşif-sömürü dengesi üzerindeki olumlu etkisini ve genel başarıyı artırdığını ortaya koymaktadır.

5. TARTIŞMA VE SONUÇ

Bu çalışmada, AVOA algoritmasının Gezgin Satıcı Problemi (GSP) üzerindeki performansı, çeşitli başlangıç popülasyonu stratejileri (örneğin, rastgele dağılım ve Sobol dizileri) ile iyileştirme teknikleri (DBSCAN ve En Yakın Komşu - EYK) entegre edilerek geliştirilen varyantları aracılığıyla incelenmiştir. Elde edilen bulgular, önerilen yöntemlerin etkinliğinin değerlendirilmesine olanak tanımış ve bu yöntemlerin literatürde yer alan diğer yaklaşımlarla karşılaştırmalı analizini mümkün kılmıştır.

DeneySEL çalışmalar GSP'ye ait iki farklı veri seti olan eil51 ve a280 üzerinde gerçekleştirilmiş olup, her bir yöntemin optimal çözüme yakınsama başarısı, ortalama çözüm değerleri, optimal çözümden sapma oranları ve standart sapmalar gibi metriklerle karşılaştırılmıştır.

Ortaya çıkan bulgular ışığında, MAGA (Şahin ve Karagül, 2021) yönteminin her iki veri setinde de optimal çözüme daha yakın ortalama çözüm değerini sağladığı görülmüştür. Özellikle büyük bir veri seti olan a280'de, MAGA algoritması 2634 değerini bularak ile en düşük ortalama çözümü üretmiştir. Bu durum, MAGA algoritmasının optimizasyon problemlerinde başarılı bir şekilde uygulandığını ve yüksek performans gösterdiğini doğrulamaktadır. Ancak, önerilen AVOA tabanlı yöntemlerin de literatürde yaygın kullanılan diğer yöntemlere kıyasla üstün sonuçlar verdiği gözlemlenmiştir. Özellikle AVOA+EYK+SOBOL birleşimi, her iki veri setinde de en iyi çözümlerden biri olarak öne çıkmış ve klasik AVOA'ya kıyasla daha düşük sapma oranları üretmiştir. Bu sonuç, Sobol dizilerinin başlangıç popülasyonunun oluşturulmasında rastgele dağılıma kıyasla daha dengeli bir yapı sağladığını ve EYK algoritmasının yerel iyileştirmede etkin olduğunu göstermektedir. Önerilen AVOA tabanlı yöntemlerin, özellikle Geleneksel Evrimsel Algoritmalar (GA), En Yakın Komşuluk Sezgiseli (EYK), Karınca Kolonisi Optimizasyonu (KKO) ve Tabu Arama (TA) gibi yöntemlere kıyasla daha iyi performans elde ettiği tespit edilmiştir. Bu durum, AVOA'nın optimizasyon yeteneğini ve iyileştirme algoritmaları ile entegrasyonunun etkisini desteklemektedir.

Sonuç olarak, bu çalışmada önerilen AVOA tabanlı yöntemlerin, özellikle Sobol dizileri ile oluşturulan başlangıç popülasyonlarının ve EYK tabanlı yerel iyileştirmelerin optimizasyon performansına olumlu katkı sağladığı ortaya konulmuştur. MAGA

algoritmasının en iyi sonuçları üretmesi, literatürde yeni geliştirilen algoritmaların optimizasyon problemlerinde önemli bir başarı yakalayabileceğini göstermektedir.

Gelecek çalışmalarda, farklı düşük sapmalı diziler (örneğin Halton, Faure) ile Sobol dizilerinin karşılaştırmalı analizleri yapılabilir. Ayrıca, AVOA algoritması; kapasite kısıtlı rotalama, çoklu gezgin satıcı veya zaman pencereli rotalama gibi daha karmaşık kombinatoriyal problemlere uyarlanarak uygulanabilirliği test edilebilir. Yerel iyileştirme sürecinde kullanılan DBSCAN ve En Yakın Komşu algoritmaları yerine daha gelişmiş yöntemlerden olan 2opt, 3opt, Lin-Kernighan entegrasyonu ile çözüm kalitesi daha da artırılabilir. Bunun yanı sıra, Latin hypercube sampling, karşıt-temelli öğrenme gibi farklı başlangıç örnekleme yöntemlerinin AVOA ile hibrit olarak kullanılması, algoritmanın keşif-sömürü dengesi açısından daha derinlemesine incelemeler yapılmasına olanak sağlayabilir. Son olarak, algoritmanın farklı parametre ayarları altında performans duyarlılığı analiz edilerek, daha sağlam ve genellenebilir bulgular elde etmek mümkündür.

KAYNAKLAR

- Abdollahzadeh, B., Gharehchopogh, F. S., Mirjalili, S. (2021). African vultures optimization algorithm: A new nature-inspired metaheuristic algorithm for global optimization problems. *Computers and Industrial Engineering*, 158, 1-37. doi:10.1016/j.cie.2021.107408
- Aburomman, A. A., Reaz, M. B. I. (2016). A novel SVM-kNN-PSO ensemble method for intrusion detection system. *Applied Soft Computing*, 38, 360–372.
- Ali, M., Pant, M., Abraham, A. (2013). Unconventional initialization methods for differential evolution. *Applied Mathematics and Computation*, 219(9), 4474–4494. doi:10.1016/j.amc.2012.10.053
- Altın, İ., Sipahioğlu, A. (2023). Parameter-less and metaphor-less metaheuristic algorithm suggestion for solving combinatorial optimization problems. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 31(1), 599-609. doi:10.31796/ogummf.1186895
- Antonov, I. A., Saleev, V. M. (1979). An economic method of computing LPr-sequences. *USSR Computational Mathematics and Mathematical Physics*, 19, 252–256.
- Applegate, D. L., Bixby, R. E., Chvátal, V., Cook, W. J. (2003) ***The traveling salesman problem: A computational study***. Princeton University Press: New Jersey, ABD.
- Aslan, M., Gündüz, M., Kıran, M. S. (2020). A Jaya-based approach to wind turbine placement problem. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 42(24), 3318–3337. doi:10.1080/15567036.2020.1805528.
- Baker, K. R., Ayechev, M. (2003). A genetic algorithm for the traveling salesman problem. *Computers and Operations Research*, 30(5), 705-719.
- Başar, R. (2021). *Beklemesiz akış tipi çizelgeleme problemlerinin bulanık ortamda dağınık arama yöntemi ile çözümü*, Yüksek lisans tezi, Konya Teknik Üniversitesi Fen Bilimleri Enstitüsü, Konya, Türkiye
- Başar, R., Engin, O. (2022). Beklemesiz akış tipi çizelgeleme problemlerinin analizi ve hibrit dağınık arama yöntemi ile çözümü. *Journal of Advanced Research in Natural and Applied Sciences*, 8(2), 293-308
- Belgin, Ö., Karaoğlu, İ., Altıparmak, F. (2021). Mathematical programming based heuristic approach for two-echelon vehicle routing problem with simultaneous pickup and delivery. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(3), 1565-1579. doi:10.17341/gazimmfd.687959
- Bellmann, R. (1957). ***Dynamic programming***. Princeton University Press: New Jersey, ABD
- Berkaya, M. F. (2021). *Gezgin satıcı probleminin çözümü için guguk kuşu arama algoritma tabanlı yeni bir hibrit metasezgisel yöntem*, Yüksek lisans tezi. Konya Teknik Üniversitesi, Konya, Türkiye.
- Bozdemir, M. (2021). *Servis rotalama problemi için matematiksel model önerisi: Bankacılık merkez üssü uygulaması*, Yüksek lisans tezi. Konya Teknik Üniversitesi Fen Bilimleri Enstitüsü, Konya, Türkiye.
- Caflich, R. E. (1998). Monte Carlo and quasi-Monte Carlo methods. *Acta Numerica*, 7, 1–49. doi:10.1017/S0962492900002804.
- Cengiz, S. (2022). *Konya ili katı atık toplama sisteminin benzetilmiş tavlama algoritması ile optimizasyonu*, Yüksek lisans tezi. Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü, Konya, Türkiye.

- Cruz-Chávez, M. A., Martínez-Oropeza, A. (2016). Feasible initial population with genetic diversity for a population-based algorithm applied to the vehicle routing problem with time windows. *Mathematical Problems in Engineering*, 1-11. doi:10.1155/2016/3851520
- Çınar, A. C. (2020). *Kısıtlı ve ayrık optimizasyon problemlerinin çözümü için ağaç-tohum algoritmasının uyarlanması ve analizi*, Yüksek lisans tezi. Konya Teknik Üniversitesi Fen Bilimleri Enstitüsü, Konya, Türkiye
- Çolak, S., Güler, H. (2009). Dağıtım rotaları optimizasyonu için meta sezgisel bir yaklaşım. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 11(2), 171-190.
- Dedetürk, B. K., Kolukisa, B., Özmen, M. (2023). Zaman pencereli araç rotalama problemleri için kümeleme temelli klonal seçim algoritması. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 10(21), 307-320. doi:10.54365/adyumbd.1381562
- Demir, F. B., Tuncer, T., Kocamaz, A. F. (2019). A new chaotic swarm optimization method based on the Logistic-Singer map. **2019 International Artificial Intelligence and Data Processing Symposium, IDAP**, Malatya, Türkiye..
- Deng, D. (2020, September). DBSCAN clustering algorithm based on density. **2020 7th International Forum on Electrical Engineering and Automation, IFEEA**, Hefei, China.
- Dengiz, A. Ö. (2021). *Evde sağlık hizmetleri çizelgeleme ve rotalama problemi: Matematiksel modeller ve meta-sezgisel algoritmalar*, Doktora tezi. Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara, Türkiye.
- Deniz, A., Kiziloz, H. E. (2019). On initial population generation in feature subset selection. *Expert Systems with Applications*, 137, 11-21. doi:10.1016/j.eswa.2019.06.063
- Dighe Sara, P. A., Chegini, S. N., Bagheri, A., Roknsaraei, M. P. (2020). An improved particle swarm optimization based on the reinforcement of the population initialization phase by scrambled Halton sequence. *Cogent Engineering*, 7(1). doi:10.1080/23311916.2020.1737383
- Dikmen, H., Dikmen, H., Elbir, A., Ekşi Z., Çelik, F. (2014). Gezgin satıcı probleminin karınca kolonisi ve genetik algoritmalarla en iyilemesi ve karşılaştırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 18(1), 8-13.
- Dong, N., Wu, C. H., Ip, W. H., Chen, Z. Q., Chan, C. Y., Yung, K. L. (2012). An opposition-based chaotic GA/PSO hybrid algorithm and its application in circle detection. *Computers and Mathematics with Applications*, 64(6), 1886-1902. doi:10.1016/j.camwa.2012.03.040
- Elmas, H. (2024). *Çekirdek fonksiyonu kullanan meta sezgisel tabanlı yeni bir kümeleme algoritması*, Yüksek lisans tezi. Necmettin Erbakan Üniversitesi, Konya, Türkiye.
- Emeç, M., Özcanhan, M. H. (2023). Makine öğrenmesi algoritmalarında hiper parametre belirleme. In E. Yiğit ve U. Özkaya (Ed.), **Mühendislikte Öncü ve Çağdaş Çalışmalar** (pp. 71–98). Duvar Yayınları: İzmir, Türkiye.
- Garey, M. R., Johnson, D. S. (1979). A guide to the theory of NP-completeness. **Computers and intractability: A guide to the theory of NP-completeness** (pp. 37–79). W. H. Freeman and Company: San Francisco, CA, ABD.
- Golden, B. L., Levy, L., Vohra, R. (1987). The vehicle routing problem. *Operations Research*, 35(5), 793-814.

- Göçken, T., Yaktubay, M., Kılıç, F. (2018). Zaman pencereyi araç rotalama problemi çözümü için çok amaçlı genetik algoritma yaklaşımı. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 6(4), 774-786. doi:10.29109/gujsc.397543
- Gören, H. G. (2011). *Genetik algoritma tabanlı melez yaklaşımlarla hazırlık süreli ve taşınabilir kapasite sınırlı parti büyüklüğü probleminin çözümü*, Doktora tezi. Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir, Türkiye.
- Gülcü, S. D. (2019). *Çoklu gezgin satıcı probleminin sezgisel algoritmalar ile çözümü*, Yüksek Lisans Tezi. Konya Teknik Üniversitesi, Konya, Türkiye.
- Gürsu, B., İnce, M. C. (2005). Evrimsel algoritmalarda farklı başlangıç popülasyonu oluşturma yöntemlerinin karşılaştırılması. **Bilimde Modern Yöntemler Sempozyumu**, Kocaeli, Türkiye.
- Gürsu, B., İnce, M. (2014). Faure dizili genetik algoritmalar ile toprak öz direncinin mevsimsel değişiminde transformatör merkezi topraklama sisteminin optimum tasarım stratejisi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 16(1), 61-76
- Gürsu, B., Kent, S. (2012). Az uyumsuz dizilerle geliştirilmiş genetik algoritmalar. **Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu**, Trabzon, Türkiye.
- Halim AH, Ismail I. "Combinatorial optimization: comparison of heuristic algorithms in travelling salesman problem". *Archives of Computational Methods in Engineering*, 2017. doi:10.1007/s11831-017-9247-y.
- Holland, J. H. (1975). *Adaptation in natural and artificial systems*. University of Michigan Press: Ann Arbor, MI, ABD.
- Karacan, İ. (2023). *Developing and applying multi-threaded metaheuristic policies to solve combinatorial industrial engineering problems*, M.Sc.thesis. Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
- Karagül, K. (2019). Gezin satıcı problemi için yeni bir çözüm yaklaşımı: tport. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 21(63), 819-832.
- Kaya, S., Fırlı, N. (2016). Esnek atölye tipi çizelgeleme problemlerinin meta sezgisel yöntemler ile çözümüne yönelik bir inceleme. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 20(2), 223-244.
- Kaya, S., Karaçizmeli, İ. H., Aydılek, İbrahim Berkan, Tenekeci, M. E., Gümüüşü, A. (2020). The effects of initial populations in the solution of flow shop scheduling problems by hybrid firefly and particle swarm optimization algorithms. *Pamukkale University Journal of Engineering Sciences*, 26(1), 140-149. doi:10.5505/pajes.2019.94763
- Kaya, T., C. İnce. The effect of uniform scattered Genetic Algorithms to window function performance. **18th Signal Processing and Communications Applications Conference , SIU**, Diyarbakır, Türkiye.
- Kayman, A. Y. (2015). *Gezin satıcı probleminin çözümünde parçacık sürü optimizasyonu algoritması performansının bulanık c-ortalama yöntemini ile iyileştirilmesi*, Doktora tezi. Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli, Türkiye.
- Külahlı, S. (2016). *Esnek atölye tipi çizelgeleme problemleri için bir dağıntık arama metodu*, Yüksek lisans tezi. Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya, Türkiye.

- Kazemzadeh Azad, S. (2018). Seeding the initial population with feasible solutions in metaheuristic optimization of steel trusses. *Engineering Optimization*, 50(1), 89-105. doi:10.1080/0305215X.2017.1284833
- Kazimipour, B., Li, X., Qin, A. K. (2014, July). A review of population initialization techniques for evolutionary algorithms. **IEEE congress on evolutionary computation, CEC**, Beijing, China.
- Kirkpatrick, S., Gelatt, C. D., Vecchi, M. P. (1983). Optimization by simulated annealing. *Science*, 220(4598), 671-680.
- Kuram, Ç. (2016). *Zaman pencereci araç rotalama problemlerinin popülasyon tabanlı sezgisel yöntemler ile optimize edilmesi*, Yüksek lisans tezi. İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
- Kuzu, S., Önay, O., Şen, U., Tunçer, M., Yıldırım, B., Keskinürk, T. (2014). Gezgin satıcı problemlerinin metasezgiseller ile çözümü. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 43(1), 1-27.
- Laporte, G. (2009). The traveling salesman problem: An overview of exact and approximate algorithms. *European Journal of Operational Research*, 159(2), 405-415.
- Li, Z., Kucukkoc, I., Tang, Q., Zhang, Z. (2023). Models and two-phase bee algorithms for multi-objective U-shaped disassembly line balancing problem. *Optimization and Engineering*, 24(1), 591-622.
- Liu, S., Han, J. (2017). Energy efficient stochastic computing with sobol sequences. **Design Automation and Test in Europe Conference and Exhibition**, Lausanne, Switzerland
- Madenoglu, F. S. (2020). Hibrit akış tipi çizelgeleme probleminin parçacık sürü optimizasyon algoritmasıyla çözümüne başlangıç çözümlerinin etkisi. *Journal of Research in Business*, 5(2), 160-173.
- Miller, A. I., Tucker, A. W. (1965). Integer programming formulation of traveling salesman problems. *Journal of the Society for Industrial and Applied Mathematics*, 13(1), 1-11.
- Özkök, Z. (2021). *Zaman pencereci araç rotalama probleminin çözümü için hibrit bir yöntemin geliştirilmesi*, Yüksek lisans tezi. Necmettin Erbakan Üniversitesi, Konya, Türkiye.
- Öztürk, N., Uysal, F. N.(t.y). Gezgin satıcı probleminin genetik algoritma ile çözümü, *Karabük Üniversitesi Endüstri Mühendisliği Dergisi*, 125-128.
- Pan, W., Li, K., Wang, M., Wang, J., Jiang, B. (2014). Adaptive randomness: A new population initialization method. *Mathematical Problems in Engineering*, 2014(1), 1-14. doi:10.1155/2014/975916
- Pian, J., Wang, G., Li, B. (2018). An improved ABC algorithm based on initial population and neighborhood search. *IFAC-PapersOnLine*, 51(18), 251-256.
- Pulat, M., Kocakoç, D. (2017). Gezgin Satıcı Probleminin Genetik Algoritmalarla Çözümünde Başlangıç Popülasyonunun Belirlenmesi. *Journal of Emerging Economies and Policy*, 2(1), 95-123.
- Rahnamayan, S., Tizhoosh, H. R., Salama, M. M. A. (2007). A novel population initialization method for accelerating evolutionary algorithms. *Computers and Mathematics with Applications*, 53(10), 1605-1614. doi:10.1016/j.camwa.2006.07.013
- Reinelt, G. (1991). TSPLIB – Gezgin Satıcı Problemi Kütüphanesi. *ORSA Journal on Computing*, 3(4), 376–384.

- Erişim tarihi: 23 Mayıs 2025. Erişim adresi: <http://comopt.ifi.uni-heidelberg.de/software/TSPLIB95>
- Sanaç, P., Karci , A. (2004). Genetik algoritmalarda tek ve çok noktalı çaprazlamanın sözde rassal popülasyonlara etkisi, **ELECO-2004: Elektrik ve Elektronik Konferansı** , Elazığ, Türkiye.
- Seyyarer, E. (2021). *Uniform popülasyon ve türe ve dayalı meta-sezgisel yeni yöntem geliştirme*. Doktora tezi. İnönü Üniversitesi Fen Bilimleri Enstitüsü, Malatya, Türkiye.
- Şahin, Y., Eroğlu, A. (2015). Sipariş toplama ve kapasite kısıtlı araç rotalama problemlerinin hiyerarşik çözümü. *Mühendislik Bilimleri ve Tasarım Dergisi*, 3(1), 15-28.
- Şahin, Y., Karagül, K. (2019). Gezin satıcı probleminin melez akışkan genetik algoritma (MAGA) kullanarak çözümü. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 25(1), 106-114.
- Sezer, N. S. (2023). *İha'li gezgin satıcı problemi için bir melez metasezgisel yöntem*, Doktora tezi. Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye
- Sobol, I. M. (1967). Distribution of points in a cube and approximate evaluation of integrals. *USSR Computational Mathematics and Mathematical Physics*, 7, 86–112.
- Talbi, E. G. (2009). **Metaheuristics: from design to implementation**. John Wiley and Sons: Hoboken: NJ, USA
- Tekbir, M., Albayrak, S. (2010). Recursive-partitioned DBSCAN. *18th Signal Processing and Communications Applications Conference, SIU*, Diyarbakır, Türkiye.
- Terzi, Ü. (2009). *Gezin satıcı problemi için diferansiyel gelişim algoritması tabanlı bir metasezgisel öneri*, Doktora Tezi. Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli, Türkiye.
- Tezer, T. (2017). *Şebekeden bağımsız hibrit yenilenebilir enerji sistemlerinin tasarımı ve yönetim stratejisi için pareto optimum yaklaşımı*, Doktora tezi. Balıkesir Üniversitesi Fen Bilimleri Enstitüsü, Balıkesir, Türkiye.
- Toksoy, M. S. (2021). *Kapasite kısıtlı yer seçimi ve araç rotalama problemi ve bir metasezgisel çözüm önerisi*, Doktora tezi. Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli, Türkiye.
- Tometzki, T., Engell, S. (2011). Systematic initialization techniques for hybrid evolutionary algorithms for solving two-stage stochastic mixed-integer programs. *IEEE Transactions on Evolutionary Computation*, 15(2), 196-214. doi:10.1109/TEVC.2010.2058121
- Topcu, B. (2014). *Gezin satıcı problemlerinin çözümü için elektromanyetizma sezgiselinin uyarlanması*, Doktora tezi. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
- Toth, P., Vigo, D. (2002). **The vehicle routing problem**. SIAM: Philadelphia, USA.
- The SciPy community. (t.y.). *SciPy documentation*. Erişim tarihi: 10.02.2025. Erişim adresi: <https://docs.scipy.org/doc/scipy/>
- Uzun, G. Ö. (2021). *Zaman pencereli tamirci problemi ve uzantılarının yeni matematiksel modelleri*, Doktora tezi. Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara, Türkiye.
- Wang, Y., Zhang, Y., Li, J. (2020). A survey of the traveling salesman problem and its applications. *Journal of Industrial and Management Optimization*, 16(2), 779-798.

- Vesel, T. (2019). Efficient computation of sobol' quasi-random generator. *International Journal of Students' Research in Technology Management*, 7(2), 01-04. doi:10.18510/ijstrtm.2019.721
- Yeşilbudak, M. (2021). Extraction of photovoltaic cell and photovoltaic module parameters using african vultures optimization algorithm. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 9(4), 708-725. doi:10.29109/gujsc.997972
- Yetkin, M. (2024). *Tarihi ve kültürel gezi rota planlamasının metasezgisel algoritmalarla oluşturulması: Şanlıurfa ili örneği*, Yüksek lisans tezi. Harran Üniversitesi Fen Bilimleri Enstitüsü, Şanlıurfa, Türkiye
- Yıldırım, T., Kalaycı, C. B., Mutlu, Ö. (2016). Gezgin satıcı problemi için yeni bir meta-sezgisel: kör fare algoritması. *Pamukkale University Journal of Engineering Sciences*, 22(1), 64-70.
- Yıldız, İ. (2020). *Metasezgiler ve birliktelik analizi kullanarak turizmde rota planlama*, Yüksek lisans tezi. İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye
- Yücel, A.(2016) *Mesafe kısıtlı çok yönlü kümeleneşmiş açık araç rotalama probleminin genetik algoritma ile çözümü ve bir uygulama*, Doktora tezi. İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, Türkiye.
- Zhang, G., Gao, L., Shi, Y. (2011). An effective genetic algorithm for the flexible job-shop scheduling problem. *Expert Systems with Applications*, 38(4), 3563-3573. doi:10.1016/j.eswa.2010.08.145

ÖZ GEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Veli Akay

Eğitim Bilgileri

Lisans

Üniversite : Mersin Üniversitesi

Fakülte : Tarsus Teknik Eğitim Fakültesi

Bölüm : Bilgisayar Öğretmenliği

Mezuniyet Yılı : 2007





VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ORJİNALLİK RAPORU

Tarih 16/06/2025

Tez Başlığı: AFRİKA AKBABALARI OPTİMİZASYONU KULLANILARAK GEZGİN SATICI PROBLEMİNİN ÇÖZÜMÜ İÇİN VERİMLİ BİR BAŞLANGIÇ POPÜLASYONU OLUŞTURMA

Yukarıda başlığı belirtilen tez çalışmamın, kapak sayfası, giriş, ana bölümler ve sonuç bölümlerinden oluşan toplam 48 (kırksekiz) sayfalık kısmına ilişkin, 16/06/2025 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre tezimin benzerlik oranı % 15 (on beş) tir.

Uygulanan filtreler aşağıda verilmiştir:

- Kabul ve onay sayfası hariç,
- Teşekkür hariç,
- İçindekiler hariç,
- Simge ve kısaltmalar hariç,
- Gereç ve yöntemler hariç,
- Kaynakça hariç,
- Alıntılar hariç,
- Tezden çıkan yayınlar hariç,
- 7 kelimedenden daha az örtüşme içeren metin kısımları hariç (Limit match size to 7 words)

Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim.

Tarih ve İmza
16/06/2025

Adı Soyadı: Veli AKAY
Öğrenci No: 22910001095
Anabilim Dalı: Yapay Zeka ve Robotik
Programı: Yapay Zeka ve Robotik
Statüsü: (x) Yüksek lisans () Doktora

DANIŞMAN
UYGUNDUR

ENSTİTÜ ONAYI
UYGUNDUR