

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ DOKTORA
PROGRAMI**

**GEZGİN SATICI PROBLEMİNDE GENETİK ALGORİTMALAR
İÇİN YENİ SEÇİLİM OPERATÖRLERİNİN GELİŞTİRİLMESİ**

HAZIRLAYAN

ŞAHİN BURAK DALKILIÇ

DOKTORA TEZİ

ANKARA- 2025

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ DOKTORA
PROGRAMI**

**GEZGİN SATICI PROBLEMİNDE GENETİK ALGORİTMALAR
İÇİN YENİ SEÇİLİM OPERATÖRLERİNİN GELİŞTİRİLMESİ**

HAZIRLAYAN

ŞAHİN BURAK DALKILIÇ

DOKTORA TEZİ

TEZ DANIŞMANI

PROF. DR. HAMİT ERDEM

ANKARA- 2025

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik-Elektronik Mühendisliği Anabilim Dalı Doktora Programı çerçevesinde Şahin Burak DALKILIÇ tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Doktora Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 08 / 08 / 2025

Tez Adı: Gezgin Satıcı Probleminde Genetik Algoritmalar İçin Yeni Seçilim Operatörlerinin Geliştirilmesi

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)		İmza
Prof. Dr. Hamit ERDEM	Başkent Üniversitesi	
Doç. Dr. Fatih NAR	Yıldırım Beyazıt Üniversitesi	
Doç. Dr. Emre SÜMER	Başkent Üniversitesi	
Doç. Dr. Selda GÜNEY	Başkent Üniversitesi	
Dr. Atilla ÖZGÜR	Constructor Üniversitesi	

ONAY

Prof. Dr. Dilek ÇÖKELİLER SERDAROĞLU

Fen Bilimleri Enstitüsü Müdürü

Tarih: ... / ... / 2025

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 08 / 08 / 2025

Öğrencinin Adı, Soyadı: Şahin Burak DALKILIÇ

Öğrencinin Numarası: 21920146

Anabilim Dalı: Elektrik-Elektronik Mühendisliği Anabilim Dalı

Programı: Elektrik-Elektronik Mühendisliği Doktora Programı

Danışmanın Unvanı/Adı, Soyadı: Prof. Dr. Hamit Erdem

Tez Başlığı: Gezgin Satıcı Probleminde Genetik Algoritmalar İçin Yeni Seçilim Operatörlerinin Geliştirilmesi

Yukarıda başlığı belirtilen Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 96 sayfalık kısmına ilişkin, 08 / 08 / 2025 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 6'dır. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına 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.

Öğrenci İmzası:

ONAY

Tarih: 08 / 08 / 2025

Öğrenci Danışmanı:

Prof. Dr. Hamit ERDEM

TEŞEKKÜR

Tez çalışmalarımın yürütülmesi sırasında sonsuz desteklerini esirgemeyen danışman hocam Prof. Dr. Hamit Erdem'e, konu seçiminden araştırmaların yürütülmesine dek değerli katkılarını esirgemeyen ikinci danışman hocam Dr. Atilla Özgür'e, tez izleme komitemde yer alarak görüşleri ile araştırmanın şekillenmesini sağlayan Doç. Dr. Selda Güney hocama sonsuz teşekkür ederim.

Tez çalışmam süresince yanımda olan aileme özellikle de sevgili anneme ve babama teşekkürü bir borç bilirim. Hayatımın her alanında olduğu gibi, tez çalışmamı hazırlarken de her aşamada bana yardımcı olan sevgili eşim Arş. Gör. Hande Nur Dalkılıç'a sonsuz teşekkür ederim.

Ayrıca, tez sürecim boyunca çalışma ortamını anlayışla karşılayan, mesleki gelişimime katkı sağlayan ve zaman zaman tez çalışmalarına destek sunan HAVELSAN'daki değerli yöneticilerime ve kıymetli ekip arkadaşlarıma da teşekkür etmek isterim.

ÖZET

Şahin Burak DALKILIÇ

GEZGİN SATICI PROBLEMİNDE GENETİK ALGORİTMALAR İÇİN YENİ SEÇİLİM OPERATÖRLERİNİN GELİŞTİRİLMESİ

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

2025

Gezgin satıcı problemi (GSP) rota planlama, baskı devre kart tasarımı, bilgisayar kablolama, üretim planlama gibi birçok gerçek hayat problemlerinde kullanılmaktadır. GSP'nin çözümü için meta-sezgisel algoritmalar yani, Tavlama benzetimi, karınca kolonisi, sinir ağı, tabu arama, parçacık sürüşü optimizasyonu ve genetik algoritma kullanılmaktadır. Son yıllarda, araştırmacılar genetik algoritması üzerinde keşif ve sömürü arasındaki dengenin iyileştirilmesi amacıyla, seçim, mutasyon ve çaprazlama operatörleri önermişlerdir. Literatürde yer alan 6 seçim operatörü, 6 mutasyon operatörü ve 11 çaprazlama operatörü uygulanmış ve yöntemlerin performansları yakınsama oranları ve hesaplama süreleri açısından değerlendirilmiştir. Ayrıca keşif ve sömürü dengesini iyileştirmek amacıyla, Keşif-Sömürü Denge Seçim (KSDS) ve Hibrit Seçim operatörleri (HS) önerilmiştir. Yöntemler, 30 farklı TSPLIB veri setinde ve çelik üretim verilerinde test edilmiş ve kritik fark diyagramları kullanılarak yöntemler arasındaki istatistiksel farklar görselleştirilmiştir. Ayrıca yöntemlerin birbirinden ne derece iyileştirilmiş olduğunu gözlemlemek için t-test istatistiksel testleri yapılmıştır. Sonuçlar önerilen seçim operatörlerinin literatürdeki diğer yöntemlere kıyasla daha etkili performans gösterdiği görülmüştür. Mutasyon yöntemlerinde Değişim Mutasyon (DM) operatörü en etkili sonuçları verirken, çaprazlama yöntemlerinde ise Geliştirilmiş Açgözlü Çaprazlama (GAÇ) yöntemi en iyi sonuçları vermiştir.

ANAHTAR KELİMELER: Gezgin satıcı problemi, seçim operatörleri, mutasyon operatörleri, çaprazlama operatörleri, çelik üretim planlama.

ABSTRACT

Şahin Burak DALKILIÇ

DEVELOPMENT OF NEW SELECTION OPERATORS FOR GENETIC ALGORITHMS IN THE TRAVELLING SALESMAN PROBLEM

Başkent University Institute of Science

Department of Electrical and Electronics Engineering

2025

Traveling salesman problem (TSP) is used in many real-world problems such as route planning, printed circuit board design, computer wiring, production planning. Meta-heuristic algorithms such as simulated annealing, ant colony, neural networks, tabu search, particle swarm optimization and genetic algorithm are used to solve TSP. In recent years, researchers have proposed selection, mutation and crossover operators in order to improve the balance between exploration and exploitation on genetic algorithm. 6 selection operators, 6 mutation operators and 11 crossover operators in the literature were applied and the performances of the methods were evaluated in terms of convergence rates and computation times. In addition, Exploration-Exploitation Balance Selection (EEBS) and Hybrid Selection (HS) operators were proposed to improve the balance between exploration and exploitation. The methods were tested on 30 different TSPLIB data sets and steel production data and statistical differences between the methods were visualized using critical difference diagrams. In addition, t-test statistical tests were performed to observe to what extent the methods were improved from each other. The results show that the proposed selection operators perform better than other methods in the literature. In mutation methods, the Swap Mutation (SWPM) operator gives the most effective results, while in crossover methods, the Improved Greedy Crossover (IGX) method gives the best results.

KEYWORDS: Traveling salesman problem, selection operators, mutation operators, crossover operators, steel production planning.

İÇİNDEKİLER

TEŞEKKÜR.....	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ	vii
ŞEKİLLER LİSTESİ	ix
SİMGELER VE KISALTMALAR LİSTESİ	xiii
1. GİRİŞ.....	1
1.1. Gezin Satıcı Problemi	4
1.2. Genetik Algoritma	4
1.2.1. Genetik operatörler üzerinde yapılan çalışmalar	7
1.2.1.1. Seçim yöntemleri literatür taraması	7
1.2.1.2. Çaprazlama yöntemleri literatür taraması	9
1.3. Çelik Üretim Planlama	11
1.3.1. Çelik üretimi alanında yapılan çalışmalar	15
2. MATERYAL VE METOT	17
2.1. Seçim Operatörleri	17
2.1.1. Uygunluk orantılı seçim.....	17
2.1.2. Turnuva seçimi	18
2.1.3. Lineer sıralama seçimi	19
2.1.4. Üstel sıralama seçimi.....	19
2.1.5. Bölünmüş sıralama seçimi	20
2.1.6. Yeni turnuva seçimi	21
2.2. Yeni Seçim Operatör Önerileri	21
2.2.1. Keşif-sömürü denge seçimi.....	21
2.2.1.1. Motivasyon	21
2.2.1.2. Zaman karmaşıklığı analizi	23
2.2.2. Hibrit seçim.....	24
2.2.2.1. Deterministik hibrit seçimi	25
2.2.2.2. Bulanık mantık hibrit seçimi	26
2.2.2.3. Entropi tabanlı hibrit seçimi	30
2.2.2.4. Adaptif hibrit seçimi.....	31
2.2.2.5. Öz uyarlamalı hibrit seçimi	31

2.2.2.6. Q-öğrenme tabanlı hibrit seçimi	32
2.2.2.7. Çok kollu haydut hibrit seçimi	33
2.3. Çaprazlama Operatörleri.....	34
2.3.1. Kısmi eşleştirmeli çaprazlama	35
2.3.2. Dairesel çaprazlama	36
2.3.3. Sıralı çaprazlama.....	36
2.3.4. Sıraya dayalı çaprazlama	37
2.3.5. Pozisyona dayalı çaprazlama	38
2.3.6. Kenar birleştirme çaprazlama	38
2.3.7. Maksimum korumacı çaprazlama	39
2.3.8. Genişletilmiş kısmi eşleşmeli çaprazlama	40
2.3.9. Açgözlü çaprazlama	41
2.3.10. Gelişmiş açgözlü çaprazlama	42
2.3.11. Sıralı yapıcı çaprazlama	44
2.4. Mutasyon Operatörleri.....	45
2.4.1. Yer değiştirme mutasyon operatörü.....	45
2.4.2. Değişim mutasyonu operatörü	46
2.4.3. Ekleme mutasyon operatörü	47
2.4.4. Basit ters çevirme mutasyon operatörü	47
2.4.5. Ters çevirme mutasyon operatörü.....	48
2.4.6. Karıştırma mutasyon operatörü	48
2.5. Değerlendirme Kriterleri	49
2.5.1. Yüzdesel hata	49
2.5.2. İki kuyruklu t-testi	49
2.5.3. Kritik fark diyagramı	50
2.5.4. Çeşitlilik analizi	51
2.6. Deney Ayarları	52
2.6.1. TSPLIB veri seti	52
2.6.2. Çelik üretim veri seti.....	53
2.6.3. Deney parametreleri ve bilgisayar özellikleri.....	53
3. DENEYSEL SONUÇLAR.....	56
3.1. Gezgin Satıcı Problemi Üzerinde Uygulamalar	56
3.1.2. Seçilim operatörlerinin karşılaştırılması	56
3.1.3. Mutasyon operatörlerinin karşılaştırılması.....	60
3.1.4. Çaprazlama operatörlerinin karşılaştırılması.....	62

3.1.5. Çeşitlilik analizi sonuçları	65
3.2. Endüstri Problemi Üzerinde Uygulamalar	69
4. TARTIŞMA VE YORUM	75
5. SONUÇ	82
KAYNAKLAR	83
EKLER	97
EK 1: Seçilim Operatörlerinin Jenerasyon-Uygunluk Performansları	97
EK 2: Seçilim Operatörlerinin Karşılaştırılması	101
EK 3: Seçilim Operatörleri İçin Hesaplama Süreleri Karşılaştırılması	109
EK 4: Mutasyon Operatörlerinin Jenerasyon-Uygunluk Performansları	114
EK 5: Mutasyon Operatörlerinin Karşılaştırılması	118
EK 6: Mutasyon Operatörleri İçin Hesaplama Sürelerinin Karşılaştırılması	126
EK 7: Çaprazlama Operatörlerinin Jenerasyon-Uygunluk Performansları	130
EK 8: Çaprazlama Operatörlerinin Karşılaştırılması	134
EK 9: Çaprazlama Operatörleri İçin Hesaplama Sürelerinin Karşılaştırılması ...	149

TABLÖLER LİSTESİ

	Sayfa
Tablo 1.1. Seçim yöntemleri geçmiş çalışmalar	7
Tablo 1.2. Literatürde yer alan ilgili çalışmalar	9
Tablo 1.3. En yaygın kullanılan çaprazlama operatörleri	10
Tablo 1.4. Çelik üretim planlamada kullanılan optimizasyon teknikleri	14
Tablo 2.1. Uygunluk orantılı seçim olasılık dağılımı	17
Tablo 2.2. Keşif-sömürü dengesini sağlayan parametre bazlı yöntemler	25
Tablo 2.3. Alfa parametre değerinin kontrolü için bulanık kurallar	28
Tablo 2.4. Şehirlerin bağlantılı olduğu kenar haritası	39
Tablo 2.5. Kenar birleştirme çaprazlama operatörü adımları	39
Tablo 2.6. Şehirlerarası uzaklık matrisi	41
Tablo 2.7. Açgözlü çaprazlama operatörü çalışma adımları	41
Tablo 2.8. Gelişmiş açgözlü çaprazlama çalışma adımları	43
Tablo 2.9. Şehirlerarası maliyet matrisi	44
Tablo 2.10. Sıralı yapıcı çaprazlama operatörü çalışma adımları	44
Tablo 2.11. TSPLIB veri setleri	52
Tablo 2.12. Seçim operatör deneyleri için kullanılan parametreler	54
Tablo 2.13. Mutasyon operatör deneyleri için kullanılan parametreler	54
Tablo 2.14. Çaprazlama operatör deneyleri için kullanılan parametreler	54
Tablo 3.1. Friedman testi ile elde edilen ortalama sıralamalar, istatistikler ve karşılık gelen p-değerleri	57
Tablo 3.2. Friedman testi ile elde edilen ortalama sıralamalar, istatistikler ve karşılık gelen p-değerleri	61
Tablo 3.3. Friedman testi ile elde edilen ortalama sıralamalar, istatistikler ve karşılık gelen p-değerleri	63

Tablo 3.4. Seçim operatörlerin çelik verisi üzerinde karşılaştırılması.....	70
Tablo 3.5. Çaprazlama operatörlerinin çelik verisi üzerinde karşılaştırılması	72
Tablo 4.1. Literatürde elde edilen sonuçlar ile deneysel sonuçlarımız ile karşılaştırılması.....	76
Tablo 4.2. Seçim operatörleri avantaj ve dezavantajları.....	77
Tablo 4.3. Hibrit seçim operatörleri avantaj ve dezavantajları	78
Tablo 4.4. Mutasyon operatörleri avantaj ve dezavantajları.....	79
Tablo 4.5. Çaprazlama operatörleri avantaj ve dezavantajları.....	81

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Gezgin satıcı probleminin çözümü için algoritmalar	1
Şekil 1.2. Minimum maliyetli tur: $A \Rightarrow B \Rightarrow C \Rightarrow E \Rightarrow D \Rightarrow A$	4
Şekil 1.3. Genetik algoritma akış diyagramı.....	5
Şekil 1.4. Kromozom yapısı.....	6
Şekil 1.5. Genetik algoritmasının performansına etki eden faktörler	6
Şekil 1.6. Çelik üretim aşamaları.....	13
Şekil 1.7. Sıcak haddeleme ünitesinin yapısı.....	13
Şekil 2.1. Rulet çarkı olasılık dağılımı	18
Şekil 2.2. Turnuva seçimi tekniği çalışma prensibi	19
Şekil 2.3. Keşif-sömür dengesi	22
Şekil 2.4. Keşif ve sömürü aday listelerinin belirlenmesi	22
Şekil 2.5. Bulanık mantık giriş popülasyon çeşitliliği ve jenerasyon oranı çıkış alfa değeri	26
Şekil 2.6. Giriş dilsel değeri popülasyon çeşitliliğini temsil eden bulanık kümelerin grafiksel gösterimi	27
Şekil 2.7. Giriş dilsel değeri jenerasyon oranını temsil eden bulanık kümelerin grafiksel gösterimi	27
Şekil 2.8. Çıkış dilsel değeri alfa değerini temsil eden bulanık kümelerin grafiksel gösterimi	28
Şekil 2.9. Popülasyon çeşitliliği ve jenerasyon oranı girişlerine karşılık çıkış alfa değer yüzey grafiği	29
Şekil 2.10. Kısmi eşleşmeli çaprazlama öncesi ebeveyn kromozomlar	35
Şekil 2.11. Ebeveyn kromozomların kesim noktalarının belirlenmesi	35
Şekil 2.12. Ebeveyn kromozomlarda eşleşen dizilerin çocuk kromozomlara yerleştirilmesi	35
Şekil 2.13. Kısmi eşleşmeli çaprazlama sonrası oluşan çocuk kromozomlar.....	36

Şekil 2.14. Dairesel çaprazlama öncesi ebeveyn kromozomlar.....	36
Şekil 2.15. Dairesel çaprazlama alt küme oluşturma işlemi	36
Şekil 2.16. Dairesel çaprazlama sonrası oluşan çocuk kromozomlar	36
Şekil 2.17. Sıralı çaprazlama öncesi ebeveyn kromozomlar	37
Şekil 2.18. Kesim noktaları arasındaki bölgelerin çocuk kromozomlara kopyalanması.....	37
Şekil 2.19. Sıralı çaprazlama sonrası oluşan çocuk kromozomlar	37
Şekil 2.20. Sıraya dayalı çaprazlama sonrası çocuk kromozomlar	37
Şekil 2.21. Pozisyona dayalı çaprazlama öncesi ebeveyn kromozomlar.....	38
Şekil 2.22. Pozisyona dayalı çaprazlama sonrası çocuk kromozomlar	38
Şekil 2.23. Maksimum korumacı çaprazlama öncesi ebeveyn kromozomlar.....	39
Şekil 2.24. Maksimum korumacı çaprazlama sonrası çocuk kromozomlar	40
Şekil 2.25. Genişletilmiş kısmi eşleşmeli çaprazlama öncesi ebeveyn kromozomlar	40
Şekil 2.26. Genişletilmiş kısmi eşleşmeli çaprazlama için tekrarlamayan şehirler	40
Şekil 2.27. Genişletilmiş kısmi eşleşmeli çaprazlama için şehirlerin transferi.....	41
Şekil 2.28. Genişletilmiş kısmi eşleşmeli çaprazlama sonrası çocuk kromozomlar.....	41
Şekil 2.29. Gelişmiş açgözlü çaprazlama sonrası çocuk kromozomlar	43
Şekil 2.30. Yer değiştirme mutasyonu öncesi gen dizilimi	45
Şekil 2.31. Yer değiştirme mutasyonu alt tur çıkarıldıktan sonraki gen dizilimi	46
Şekil 2.32. Yer değiştirme mutasyonu operatörü sonrası gen dizilimi	46
Şekil 2.33. Değişim mutasyon operatörü öncesi gen dizilimi	46
Şekil 2.34. Değişim mutasyon operatörü sonrası gen dizilimi	46
Şekil 2.35. Ekleme mutasyon operatörü öncesi gen dizilimi.....	47
Şekil 2.36. Ekleme mutasyon operatörü sonrası gen dizilimi.....	47
Şekil 2.37. Basit ters çevirme mutasyon operatörü öncesi gen dizilimi	47
Şekil 2.38. Basit ters çevirme mutasyon operatörü sonrası gen dizilimi	48

Şekil 2.39. Ters çevirme mutasyon operatörü öncesi gen dizilimi	48
Şekil 2.40. Ters çevirme mutasyon operatörü sonrası gen dizilimi	48
Şekil 2.41. Karıştırma mutasyon operatörü öncesi gen dizilimi	48
Şekil 2.42. Karıştırma mutasyon operatörü sonrası gen dizilimi	49
Şekil 3.1. Seçim operatörlerinde simetrik veri kümeleri için kritik fark diyagramı	57
Şekil 3.2. Seçim operatörlerinde asimetrik veri kümeleri için kritik fark diyagramı	58
Şekil 3.3. Seçim operatörlerinde matris tipi veri kümeleri için kritik fark diyagramı	58
Şekil 3.4. Seçim operatörlerinde öklid uzaklık tipi veri kümeleri için kritik fark diyagramı	58
Şekil 3.5. Hibrit seçim operatörlerinde simetrik veri kümeleri için kritik fark diyagramı	59
Şekil 3.6. Hibrit seçim operatörlerinde simetrik veri kümeleri için kritik fark diyagramı	59
Şekil 3.7. Mutasyon operatörlerinde simetrik veri kümeleri için kritik fark diyagramı	61
Şekil 3.8. Mutasyon operatörlerinde asimetrik veri kümeleri için kritik fark diyagramı	61
Şekil 3.9. Mutasyon operatörlerinde matris tipi veri kümeleri için kritik fark diyagramı	62
Şekil 3.10. Mutasyon operatörlerinde öklid uzaklık tipi veri kümeleri için kritik fark diyagramı	62
Şekil 3.11. Çaprazlama operatörlerinde simetrik veri kümeleri için kritik fark diyagramı	64
Şekil 3.12. Çaprazlama operatörlerinde asimetrik veri kümeleri için kritik fark diyagramı	64
Şekil 3.13. Çaprazlama operatörlerinde matris tipi veri kümeleri için kritik fark diyagramı	64
Şekil 3.14. Çaprazlama operatörlerinde öklid uzaklık tipi veri kümeleri için kritik fark diyagramı	65
Şekil 3.15. Seçim operatörleri için keşif-sömürü dengesi	65

Şekil 3.16. Hibrit seçim yöntemlerinde α parametresinin dinamik davranışı	66
Şekil 3.17. Hibrit seçim operatörleri için keşif-sömürü dengesi	67
Şekil 3.18. Mutasyon operatörleri için keşif-sömürü dengesi	68
Şekil 3.19. Çaprazlama operatörleri için keşif-sömürü dengesi	68
Şekil 3.20. Seçilim operatörlerinin çelik veri setindeki performansları	71
Şekil 3.21. Çaprazlama operatörlerinin çelik veri setindeki performansları	74

SİMGELER VE KISALTMALAR LİSTESİ

AÇ	Açgözlü Çaprazlama
AÇSYÇ	Aç Gözlü Sıralı Yapıcı Çaprazlama
ADÇ	Alt Tur Değişim Çaprazlama
AGA-2	Aç Gözlü Alt Tur Çaprazlama
AHS	Adaptif Hibrit Seçimi
AKÇ	Alternatif Kenar Çaprazlama
APÇ	Alternatif Pozisyon Çaprazlama
ARP	Araç Rotalama Problemi
ATBÇ	Alt Tur Birleştirme Çaprazlama
BÇ	Bölgeleme Çaprazlama
BMHS	Bulanık Mantık Hibrit Seçimi
BNÇ	Bir nokta Çaprazlama
BS	Boltzmann Seçimi
BSS	Bölünmüş Sıralama Seçimi
BTÇM	Basit Ters Çevirme Mutasyonu
ÇAÇ	Çok Aç Gözlü Çaprazlama
ÇGSP	Çoklu Gezgin Satıcı Problemi
ÇKHHS	Çok Kollu Haydut Hibrit Seçimi
ÇYDSYÇ	Çift Yönlü Dairesel Sıralı Yapıcı Çaprazlama
ÇYGA	Çok Yavrulu Genetik Algoritma
ÇYKEÇ	Çok Yavrulu Kısmi Eşleştirmeli Çaprazlama
DÇ	Dairesel Çaprazlama
DÇ2	Değiştirilmiş Dairesel Çaprazlama
DHS	Deterministik Hibrit Seçimi
DKTÇ	Dairesel Kaydırmalı Ters Çaprazlama
DM	Değişim Mutasyonu
DŞÇ	Değiştirilmiş Sezgisel Çaprazlama
EİŞÇ	En İyi Sıra Çaprazlama
EM	Ekleme Mutasyonu
ES	Elitizm Seçimi
ETHS	Entropi Tabanlı Hibrit Seçimi
GA	Genetik Algoritma
GAA-2	Geliştirilmiş Aç Gözlü Alt Tur Çaprazlama
GAÇ	Gelişmiş Açgözlü Çaprazlama
GDC	Geliştirilmiş Dairesel Çaprazlama
GKEÇ	Genişletilmiş Kısmi Eşleştirmeli Çaprazlama
GKS	Geri Kontrollü Seçim
GNÇ	Genelleştirilmiş N-nokta Çaprazlama
GRTS	Geliştirilmiş Rulet Tekerleği Seçimi
GSYÇ	Gelişmiş Sıralı Yapıcı Çaprazlama
HMDS	Hamming Mesafesine Dayalı Seçim
İNÇ	İki nokta Çaprazlama
İŞÇ	İsimsiz Sezgisel Çaprazlama
İTS	İkili Turnuva Seçimi
KAS	Kraliçe Arı Seçimi
KBÇ	Kenar Birleştirme Çaprazlama

KBÇ6	Kenar Birleştirme Çaprazlama Varyantı
KÇ	Karıştırma Çaprazlama
KEÇ	Kısmi Eşleştirmeli Çaprazlama
KEÇ2	Değiştirilmiş Kısmi Eşleştirmeli Çaprazlama
KFD	Kritik Fark Diyagramı
KKMDS	Kosinüs Katsayısı Mesafeye Dayalı Seçim
KM	Karıştırma Mutasyonu
KOMS	Kombine Seçim
KS	Kesme Seçimi
KSDS	Keşif-Sömürü Denge Seçimi
KSYÇ	Kapsamlı Sıralı Yapıcı Çaprazlama
LSS	Lineer Sıralama Seçimi
MKÇ	Maksimum Korumacı Çaprazlama
MKÇ3	Maksimum Korumacı Çaprazlama Varyantı
MKO	Mesafe Koruma Operatörü
MS	Merdiven Seçimi
MSC	Modifiyeli Sıralı Çaprazlama
OİTS	Olasılıklı iki-turnuva seçimi
ORTS	Orantılı Rulet Tekerleği Seçimi
ÖGSP	Ödüllü Gezgini Satıcı Problemi
ÖUHS	Öz-Uyarlamalı Hibrit Seçimi
PBA	Paralel Bağışıklık Algoritması
PDÇ	Pozisyona Dayalı Çaprazlama
PKMDS	Pearson Katsayısı Mesafeye Dayalı Seçim
QÖHS	Q-Öğrenme Hibrit Seçimi
RKS	Rastgele Kombinasyonel Seçim
RRTS	Round-Robin Tabanlı Turnuva Seçimi
RTS	Rulet-Turnuva Seçimi
SÇ	Sıralı Çaprazlama
SDÇ	Sıraya Dayalı Çaprazlama
SDS	Sabit Durum Seçimi
SEÖ	Stokastik Evrensel Örnekleme
SKS	Sıralı Kombinasyonel Seçim
SSÇ	Sarılmayan Sıralı Çaprazlama
STRTS	Sıralama Tabanlı Rulet Tekerleği Seçimi
SYÇ	Sıralı Yapıcı Çaprazlama
TASYÇ	Ters Aç Gözlü Sıralı Yapıcı Çaprazlama
TÇ	Tekdüze Çaprazlama
TÇM	Ters Çevirme Mutasyonu
TDSTÇ	Tek Düze Sıra Tabanlı Çaprazlama
TKEÇ	Tekdüze Kısmi Eşleştirmeli Çaprazlama
TS	Turnuva Seçimi
USYÇ	Uyarlanabilir Sıralı Yapıcı Çaprazlama
UOS	Uygunluk Orantılı Seçimi
ÜÇ	Üçlü Çaprazlama
ÜGS	Üst Güven Sınırı
ÜSS	Üstel Sıralama Seçimi
YDM	Yer Değiştirme Mutasyonu
YEDSZTS	Yedeksiz Turnuva Seçimi
YEDTS	Yedekli Turnuva Seçimi


YTS

Yeni Turnuva Seçimi

1. GİRİŞ

30 yılı aşkın bir süredir optimizasyon alanındaki çeşitli algoritmalar, karmaşık problemlere optimal bir çözüm sağlamak amacıyla araştırma alanları açısından yaygınlaşmaya devam etmektedir. Optimizasyon optimum çıktıyı bulmak için bir sistemin girişlerini matematiksel olarak ayarlayan süreçtir. Endüstri, işletme ve bilgi sistemlerindeki modern uygulamalar optimizasyona ihtiyaç duyar ve karmaşık fiziksel sistemleri, iş süreçlerini ve özellikle yapay zekâ uygulamalarından kaynaklanan çeşitli ciddi sorunları ele alır. Üretim hızı, parça kalitesi veya enerji verimliliği ile ilgili makineler, üretim planlama, satın alma, satış sonrası gibi endüstride zorlu sorunlar ortaya çıkar. Bu tür optimizasyon problemlerini çözmek için, simülasyonlar ve gerçek dünya deneyleri gibi maliyet hesaplamalarının yapılması gerekir [1]. Tüm optimizasyon problemleri, kombinatoriyal optimizasyon, doğrusal programlama, tam sayı programlama gibi çeşitli kategorilerde sınıflandırılır ve bir dizi değişkenden en iyisini aramayı amaçlar.

Gezgin Satıcı Problemi (GSP), 1759'da Leonhard Euler tarafından önerildiğinden ve 1930'ların başında Karl Menger tarafından matematiksel olarak tanımlandığından beri en çok çalışılan kombinatoriyal optimizasyon problemi olmuştur. GSP, tanımlanması kolay ancak çözülmesi zor bir problemdir ve polinomsal olmayan zor optimizasyon problemleri sınıfına aittir. Rota planlama, baskı devre kartlarının delinmesi, zamanlama, bilgisayar kablolaması, X-ışını kristalografisi, depolara ürün yerleştirme gibi gerçek dünya problemlerinde önemli uygulamalara sahiptir [2].



Şekil 1.1. Gezgin satıcı probleminin çözümü için algoritmalar

Son 50 yılda, araştırmacılar tarafından GSP problemini çözmek için "kesin" ve "yaklaşık" olmak üzere birçok algoritma önerilmiştir ve Şekil 1.1’de verilmiştir. Kesin algoritmalara örnek olarak dal ve sınır ve kesme düzlemi verilebilir. Ancak, kesin algoritmalar büyük ölçekli problemler için son derece zaman alıcıdır. Yaklaşık algoritmalar, sezgisel ve meta sezgisel olmak üzere iki gruba ayrılabilir. Yapıcı yöntemlerde başlangıçta boş bir çözümle başlanır ve ardından adım adım çözüm oluşturulur ve en yaygın kullanılan yöntem, en yakın komşu algoritmasıdır. İyileştirme yöntemlerinde, başlangıç çözümünü yapıcı bir yöntemle oluşturup, daha sonra, küçük değişiklikler yaparak çözümleri kademeli olarak iyileştir ve en yaygın olarak K-opt ve Lin-Kernigan-Helsgaun yöntemleri kullanılır. Meta-sezgisel algoritmaların ortaya çıkmasıyla, GSP problemlerine uygulanmıştır. Bu yöntemler, sezgisel yöntemlerden daha iyi performanslar sağlar ve daha karmaşık GSP problemlerinde optimum çözüme ulaşabilir. Simüle edilmiş tavlama, karınca kolonisi, parçacık sürü optimizasyonu ve genetik algoritma (GA), meta-sezgisel algoritmaların örnekleridir [3].

En yaygın kullanılan meta-sezgisel algoritmalarından genetik algoritma (GA) 1970'lerden 1980'lere kadar popüler olmaya başlamıştır ve doğadan ilham alınarak uygulamaya geçirilmiştir. Güçlü olan bireyler hayatta kalırken, zayıf olan bireylerin yok olması fikrine dayanmaktadır. GA'nın diğer meta-sezgisel yöntemlerden bazı avantajları olarak, yerel optimum noktasından kaçınmak için stokastik operatörler kullanması, büyük parametre uzaylarında arama yapması, uygulanması kolay ve tek seferde birçok çözüm bulunması olarak sıralanabilir [4].

GA'lar çeşitli optimizasyon problemlerini çözmek için güçlü araçlar olsa da bazı yaygın problemlerle karşılaşabilirler. En önemli sorun erken yakınsamadır. Erken yakınsama, algoritmanın popülasyonun genetik çeşitliliğini kaybettiği ve böylece arama alanının yalnızca sınırlı bir kısmına odaklandığı bir durumu ifade eder. Bu, algoritmanın yerel bir optimumda takılıp kalmasına ve küresel optimumu kaçırmasına neden olabilir. Ancak, yüksek genetik çeşitlilik, popülasyonun geniş bir alana dağılması ve optimum çözüm bölgelerinin yetersiz kullanımı nedeniyle optimum çözümlere daha yavaş, daha fazla zaman ve kaynak harcanarak ulaşılmasına neden olabilir. Bu sorunun üstesinden gelmek için, birincil hedef olarak popülasyon çeşitliliği ile seçim baskısı arasında bir denge sağlamak esastır.

Pandey ve ark. [5], erken yakınsamayı önleme yaklaşımlarının kapsamlı karşılaştırması üzerinde çalışma yürütmüştür. Bulguları, bu tür yaklaşımların başarısı için seçim baskısı ile genetik çeşitlilik arasında bir denge sağlamanın önemli olduğunu gösterdi. Back [6], GA seçim operatörlerinin performanslarını seçici baskılarına göre nicel olarak karşılaştırdı. Çeşitliliğin, yüksek seçim baskıları tarafından yok edilmesi nedeniyle seçim baskılarını dengelemenin önemli bir adım olduğunu belirtti. Gupta ve ark. [7], genetik çeşitliliği koruma yöntemleri üzerine araştırmalar yürüttü. Makul bir zaman diliminde en uygun çözümü belirlemek için popülasyon çeşitliliği ile seçici baskı arasında bir denge sağlanması gerektiğini önerdiler. Yang ve ark. [8], kısıtlı çok amaçlı optimizasyon problemini ele alarak, ikili popülasyon kooperatif algoritmasını (İPKA) önermişlerdir. Önerilen yöntem, optimizasyon sürecinin başlangıç aşamalarında, popülasyonların hızlı bir şekilde yakınsamasını kolaylaştırmak, orta aşamalarda popülasyonların çeşitliliği ve yakınsamasına göre bir dizi yerel arama stratejisi kullanmak ve son aşamalarda yerel optimumları aşmak için popülasyon çeşitliliğini artırma stratejisi uygulamak üzere tasarlanmıştır. Deneysel kanıtlar, bu yaklaşımın seçim baskısı ve popülasyon çeşitliliği arasında bir denge sağlamada etkili olduğunu göstermiştir.

Bu çalışmada, GA'nın performansını etkileyen seçim, çaprazlama ve mutasyon operatörleri üzerinde kapsamlı karşılaştırma deneyleri yapılmıştır. Ayrıca, keşif ve sömürü arasındaki dengeyi iyileştirmek için keşif-sömürü denge seçimi (KSDS) ve hibrit seçimi (HS) seçim yöntemleri önerilmiştir ve bu çalışma aşağıdaki katkılarda bulunmaktadır.


1. Erken yakınsamayı önleyen, popülasyon içindeki çeşitliliği artıran ve dinamik seçim baskısı kullanarak küresel optimumu bulma olasılığını artıran yeni seçim yöntemleri önerilmektedir.

2. Literatürde kullanılan istatistiksel yöntemlerin (ANOVA ve t-testi) aksine, Friedman testi sıfır hipotezini reddetmek ve algoritmaları sıralamak için kullanılmış ve daha sonra post-hoc testi olan Holm'un alfa (%5) düzeltilmesi ile Wilcoxon işaretli sıra testi, kritik farkları hesaplamak için gerçekleştirilmiştir. Daha sonra istatistiksel anlamlılıktaki farklar görselleştirilmiş ve kritik fark diyagramlar oluşturulmuştur.

3. GA'nın endüstriyel problemler üzerinde uygulanması ve performansına etki eden seçim, mutasyon ve çaprazlama operatörlerinin hem çelik üretim planlama veri seti hem de TSPLIB veri setleri üzerinde test edilmiştir.

1.1. Gezgin Satıcı Problemi

Gezgin Satıcı problemi (GSP), bilgisayar biliminde ve yöneylem araştırmalarında kullanılan kombinatorik optimizasyon problemi olarak bilinir. Amaç, belirli sayıda şehirde tur bulmak, her şehri bir kez ziyaret etmek ve turun uzunluğu için en kısa mesafeyi bulup, minimum maliyet ve zaman tüketimi ile başlangıç şehre geri dönmektir. Örneğin, Şekil 1.2'de gösterilen harita verildiğinde, en düşük maliyetli rota, (A, B, C, E, D, A) şeklinde takip eden rota olacaktır.



Şekil 1.2. Minimum maliyetli tur: A=>B =>C =>E =>D => A


Genel olarak, GSP iki farklı türü içerir, simetrik GSP ve asimetrik GSP. Simetrik formda, iki bitişik şehir arasında yalnızca bir yol vardır, yani A ve B şehirleri arasındaki mesafe B ve A şehirleri arasındaki mesafeye eşittir (Şekil 1.2). Ancak asimetrik GSP’de böyle bir simetri yoktur ve iki şehir arasında iki farklı maliyet veya mesafe olması mümkündür. Şehir sayısı n olan simetrik GSP için $\frac{(n-1)!}{2}$ olası çözüm, şehir sayısı n olan asimetrik GSP için $(n - 1)!$ olası çözüm vardır [9].

GSP problemlerini çözmek için, kesin ve meta-sezgisel algoritmalar kullanılabilir. Fakat kesin algoritma ile hesaplama karmaşıklığı şehirlere bağlı olarak ile üstel olarak artmaktadır. Sonuç olarak problemin çözümü için meta-sezgisel yöntemlerin kullanılması daha uygun olmaktadır. Meta-sezgisel yöntemler arasında tabu arama, benzetilmiş tavlama, genetik algoritması, karınca kolonisi algoritması bulunur.

1.2. Genetik Algoritma

Genetik algoritma (GA), Darwin evrim teorisinden esinlenerek, 1975 yılında J. Holland tarafından ortaya atılmıştır. Popülasyon evriminde, çevrelerine daha iyi uyum

sağlayan en iyi bireyler uzun süre hayatta kalabilirken, çevresine uymayan bireyler nesiller yok olurlar. Böylece her birey kendi kromozomu ve bireyleri değerlendirmek için tanımlanacak bir uygunluk fonksiyonu ile ifade edilir. İlk olarak, rastgele bir başlangıç popülasyonu oluşturulur. Daha sonra genetik operatörleri (seçim, çaprazlama, mutasyon), belirtilen olasılıklar dâhilinde, öncekinden daha iyi bir nesil üretmek için uygulanır. Bu işlem, Şekil 1.3'deki algorithmada gösterildiği gibi çok sayıda nesil için yinelemeli olarak tekrarlanmalıdır [10, 9].



Şekil 1.3. Genetik algoritma akış diyagramı


GSP problemini Genetik Algoritmalar kullanarak çözmek için birçok farklı gösterim kullanılmıştır. Bunlar, ikili (binary), yol (path), komşuluk (adjacency), sıralı (ordinal) ve matris gösterimidir. Başlangıçta kullanılan ikili ve matris gösterimleri, klasik çaprazlama ve mutasyon operatörleriyle geçerli turlar üretememeleri nedeniyle sınırlı bir başarıya sahipti. Onarım operatörlerinin tasarlanmasının nedeni budur. Literatürde en yaygın ve etkili şekilde kullanılan yol gösterimi, şehirlerin ziyaret edilme sırasını doğrudan ifade etmesi nedeniyle sezgisel olarak anlaşılabilir ve çok sayıda operatörün geliştirilmesini sağlamıştır. Şema analizini etkinleştirmek için önerilen komşuluk ve sıralı gösterimler, teorik katkılarına rağmen deneysel sonuçlar açısından yetersiz kalmıştır. Bu bağlamda, yol gösterimi şu anda

Genetik Algoritmalarla GSP'yi çözmek için en çok tercih edilen yaklaşımdır. Örneğin 8 şehrimiz olduğunu varsayarsak kromozom yapısı Şekil 1.4'deki gibi gösterilir:

(1 2 3 4 5 6 7 8)

Şekil 1.4. Kromozom yapısı

GSP için yol gösteriminde, her şehir tam olarak bir kez ziyaret edilmeli ve kromozomlarda şehir tekrarı olmamalıdır. Bu sorunu ele almak için, yol gösterimi kullanılarak GSP için özel olarak seçim, çaprazlama ve mutasyon operatörleri geliştirilmiştir. GA'nın performansını etkileyen faktörler Şekil 1.5'de verilmiştir.



Şekil 1.5. Genetik algoritmasının performansına etki eden faktörler

GA performansını etkileyen faktörler arasında popülasyon büyüklüğü, mutasyon oranı, çaprazlama oranı, seçim yöntemi ve çaprazlama yöntemi bulunur. Popülasyon büyüklüğü, her nesilde mevcut aday çözümlerin (kromozomların) sayısıdır. Daha büyük popülasyonlar çeşitliliği artırabilir ancak daha fazla hesaplama kaynağı gerektirir. Mutasyon oranı, bir genin (kromozomun bir parçası) mutasyona uğrama olasılığını belirler. Çaprazlama oranı, yavru üretmek için bir çift ebeveyn kromozomuna çaprazlama (rekombinasyon) uygulama olasılığıdır. Seçim yöntemi, uygunluklarına göre bir sonraki nesil için hangi kromozomların ebeveyn olarak seçileceğini belirler. İyi seçim yöntemleri, çeşitliliği korumaya ve daha iyi performans gösteren bireyleri tercih etmeye yardımcı olur. Mutasyon, popülasyona rastgele değişiklikler getirerek keşif yapılmasına yardımcı olur. Çaprazlama, genetik bilgiyi ebeveynlerden yavruya aktarır ve popülasyonun daha iyi çözümlere doğru yakınsamasını etkiler.

Standart GA operatörleri, GSP problemlerinin yapısal gereksinimlerini dikkate almadığından, bu problemlerin doğasına uygun değildir. Bu tür operatörler, her şehrin yalnızca bir kez ziyaret edilmesi kuralını ihlal eden geçersiz turlar oluşturabilir. Ayrıca, GSP çözümlerinde kritik öneme sahip olan şehirlerin sıralamasını ve aralarındaki bağlantıları da bozarak çözüm kalitesini düşürürler. Bu nedenle, literatürde GSP'ye özgü, geçerli turlar üreten ve problem yapısını koruyan özel seçim, çaprazlama ve mutasyon operatörleri geliştirilmesine yönelik birçok çalışma yapılmıştır. Araştırmacılar, bu tür problemlere özel genetik yapıların ve operatörlerin tasarımı üzerinde çalışmalarını sürdürmektedir.

1.2.1. Genetik operatörler üzerinde yapılan çalışmalar

Literatürde GSP çözümü için birçok genetik operatör önerilmiştir. Bu bölümde seçim ve çaprazlama yöntemleri için daha önce önerilmiş çalışmalar üzerinde durulacaktır.

1.2.1.1. Seçim yöntemleri literatür taraması

Birçok araştırmacı, farklı seçim stratejileri kullanarak GA'nın performansına nasıl etki ettiklerini incelemişlerdir. GA'nın performansı genellikle yakınsama oranı, optimum çözüme ulaşmak için gereken yinleme sayısı ve hesaplama süreleri açısından değerlendirilir. 1975'ten 2024 yıllarına kadar olan çalışmaların özeti Tablo 1.1'de verilmiştir.

Tablo 1.1. Seçim yöntemleri geçmiş çalışmalar

Seçim Yöntemi	Yıl	Referanslar
Orantılı Rulet Tekerleği Seçimi (ORTS)	1975	[11, 12, 13, 14, 15]
Sıralama Tabanlı Rulet Tekerleği Seçimi (STRTS)	2008	[11]
İkili Turnuva Seçimi (İTS)	1996	[16, 17, 18, 19]
Olasılıklı iki-turnuva seçimi (OİTS)	1999	[16, 17, 18, 20]
Yedekli Turnuva Seçimi (YEDTS)	2020	[21]
Yedeksiz Turnuva Seçimi (YEDSZTS)	2020	[21]
Stokastik Evrensel Örnekleme (SEÖ)	1987	[22, 23]
Kesme Seçimi (KS)	1993	[23, 24, 25]
Doğrusal Sıralama Seçimi (LSS)	1985	[16, 17, 18, 12, 26]
Üstel Sıralama Seçimi (ÜSS)	1992	[16, 17, 18, 27]
Bölünmüş Sıralama Seçimi (BSS)	2020	[16, 17, 18]
Round-robin tabanlı turnuva seçimi (RRTS)	2022	[18]
Yeni Turnuva Seçimi (YTS)	2023	[17]
Hamming mesafesine dayalı seçim (HMDS)	2022	[28]
Kosinüs katsayısı mesafeye dayalı seçim (KKMDS)	2022	[28]
Pearson katsayısı mesafeye dayalı seçim (PKMDS)	2022	[28]
Boltzmann Seçimi (BS)	1983	[29, 30, 31]
Sabit Durum Seçimi (SDS)	-	[31]

Tablo 1.1. Devam ediyor

Elitizm Seçimi (ES)	1975	[31, 32, 33]
Geliştirilmiş Rulet Tekerleği Seçimi (GRTS)	2016	[34]
Merdiven Seçimi (MS)	2019	[35]
Kraliçe Arı Seçimi (KAS)	2003	[36, 37]
Geri Kontrollü Seçim (GKS)	2011	[38]
Kombine Seçim (KOMS)	2013	[23]
Rulet-Turnuva Seçimi (RTS)	2016	[37, 39]
Rastgele Kombinasyonel Seçim (RKS)	2011	[40]
Sıralı Kombinasyonel Seçim (SKS)	2012	[41]

Jadaan ve ark., [11] ORTS ve STRTS yöntemlerini çeşitli matematiksel uygunluk fonksiyonları üzerinde karşılaştırdılar ve STRTS yönteminin nesil sayısı açısından daha iyi performans gösterdiğini buldular. Ayrıca, STRTS yöntemin popülasyon içindeki çeşitliliği artırarak daha kararlı ve daha optimum çözümlere yakınsadığını gözlemlediler.

2020 yılında, Hussain ve ark., [16] BSS yöntemini önerdi ve ORTS, İTS, OİTS, LSS ve ÜSS yöntemleriyle ile karşılaştırdı. Üç farklı çaprazlama operatörüyle seçim yöntemlerini birleştirerek deneysel çalışmalar yürüttüler. ORTS yönteminin sömürüye, LSS yönteminin ise keşif yapmaya meyilli olduğunu gösterdiler ve önerdikleri yöntemin, keşif ve sömürü arasında denge sağlayarak daha iyi performans gösterdiğini ortaya koydu.

Prayudani ve ark., [21] turnuva seçim yönteminin bir yarışta yarışan bireylerin bir sonraki yarış için seçildiği YEDTS ve seçilmediği YEDSZTS versiyonları karşılaştırmıştır. Deneysel sonuçları, YEDTS 'nin en yüksek en iyi uygunluk değerini elde ettiğini, YEDSZTS'un ise en iyi uygunluk değerine ulaşmak için daha hızlı olduğunu göstermektedir.

2022'de Hussain ve ark., [18] popülasyonu iki eşit gruba ayırarak bir gruptaki her birey, diğer gruptaki tüm bireylerle rekabet etmesi fikrine dayanan bir RRTS yöntemi önerdi. Deneysel çalışmalar, önerilen yöntemin, LSS, ÜSS, İTS, OİTS, BSS yöntemleriyle karşılaştırıldığında popülasyon çeşitliliğinde minimum kayba sahip olduğunu ve GSP problemlerinde daha iyi bir seçim baskısına sahip olduğunu göstermiştir.

Son zamanlarda, araştırmalar her yöntemin doğasında bulunan güçlü yönleri birleştirmek amacıyla hibrit seçim yöntemleri geliştirmeye odaklanmıştır. Jebari ve ark., [23] ORTS, SEÖ, LSS, ÜSS, TS ve KS yöntemlerini çeşitli test fonksiyonlarında test etmiş ve her nesilde benimsenecek en iyi seçim yönteminin seçilmesine olanak tanıyan KOMS yöntemini önermiştir. Deneysel çalışmalar, orantılı yöntemlerin genetik çeşitliliği elitist

yöntemlere göre daha fazla koruduğunu ve önerilen yöntemin hata oranları açısından daha iyi performans sağladığını göstermiştir.

Abd Rahman ve ark., [37] yeni bir hibrit RTS yöntemini önerdi ve önerilen seçim stratejisini, karides diyeti formül problemi üzerinde gerçek kodlama kullanarak ORTS ve KAS yöntemleriyle karşılaştırdı.

2011 yılında, Eskandari ve ark., [40] ORTS, TS ve GKS yöntemlerinin bir kombinasyonunu kullanan RKS operatörünü ortaya koydu. RKS, her operatör için bir seçim olasılığı üreterek her nesilde kullanılacak seçim operatörünü belirler. 2012 yılında, Eskandari ark., [41] RKS ile benzer SKS operatörü olarak adlandırılan bir seçim yöntemi önerdi. Rastgele üretilen sayının çift olması durumunda, TS tekniğini kullanır, tek sayı olması durumunda ise, ORTS tekniğini kullanır.

1.2.1.2. Çaprazlama yöntemleri literatür taraması

Çaprazlama yöntemleri üzerinde daha önce yapılan çalışma veri seti ve operatör sayıları ile birlikte Tablo 1.2’de verilmiştir. Ayrıca literatürde en yaygın kullanılan çaprazlama operatörlerinin özeti Tablo 1.3’de gösterilmiştir.

Tablo 1.2. Literatürde yer alan ilgili çalışmalar

Referanslar	Veri seti	Operatör sayısı
1. Abdoun ve ark. (2011) [42]	1	6
2. Hussain ve ark. (2017) [43]	12	3
3. Hussain ve ark. (2018) [44]	10	5
4. Hussain ve ark. (2019) [45]	18	6
5. Akter ve ark. (2019) [46]	15	3
6. Al-Ommer ve ark. (2019) [47]	15	6
7. Kuroda ve ark. (2010) [48]	10	4
8. Hussain ve ark. (2020) [49]	18	6
9. Ahmed (2020) [50]	12	8
10. Ahmed (2020) [51]	28	6
11. Bye ve ark. (2022) [52]	2	3
12. Dou ve ark. (2023) [53]	6	10
13. Bennaceur ve ark. (2017) [54]	23	2
14. Tao ve ark. (1998) [55]	12	2
15. Ucoluk ve ark. (2002) [56]	3	2
16. Wang ve ark. (2007) [57]	3	1
17. Ahmed (2010) [58]	26	3
18. Dalkilic ve ark. (2024) [59]	18	7
19. Su ve ark. (2009) [60]	8	3
20. Satyananda (2015) [61]	3	3
21. Zhang ve ark. (2022) [62]	13	5

Tablo 1.2. Devam ediyor

22. Thanh ve ark. (2015) [63]	12	4
23. Hassanat ve ark. (2017) [64]	11	6
24. Koohestani (2020) [65]	36	4

Abdoun ve ark. [42] berlin52 veri seti üzerinde, TÇ, DÇ, KEÇ, TKEÇ, SSÇ ve SÇ olmak üzere altı farklı çaprazlama operatörünü karşılaştırdı. Deneysel sonuçlara göre, SÇ operatörünün diğer yöntemlere göre daha iyi performans gösterdiği gözlemlenmiştir.

Hussain ve ark. [43] 2017'de DÇ'ten esinlenerek DÇ2 çaprazlama yöntemini önerdiler. Önerilen operatörü on iki simetrik ve asimetrik veri seti kullanarak KEÇ ve SÇ operatörleriyle karşılaştırarak test ettiler. Deneysel sonuçlar, DÇ2 yönteminin büyük boyutlu problemlerde bile daha yüksek doğruluğa sahip olduğunu göstermiştir.

Tablo 1.3. En yaygın kullanılan çaprazlama operatörleri

Çaprazlama Operatörü	Referans	Çaprazlama Operatörü	Referans
Tekdüze Çaprazlama (TÇ)	[42, 52]	Sıralı Yapıcı Çaprazlama (SYÇ)	[47, 50, 66, 46, 51, 53, 54, 58]
Kısmi Eşleştirmeli Çaprazlama (KEÇ)	[49, 42, 43, 44, 45, 47, 50, 52, 67, 66]	Uyarlanabilir Sıralı Yapıcı Çaprazlama (USYÇ)	[50, 51]
Tekdüze Kısmi Eşleştirmeli Çaprazlama (TKEÇ)	[42]	Çift Yönlü Dairesel Sıralı Yapıcı Çaprazlama (ÇYDSYÇ)	[50]
Genişletilmiş Kısmi Eşleştirmeli Çaprazlama (GKEÇ)	[67, 59]	Kapsamlı Sıralı Yapıcı Çaprazlama (KSYÇ)	[51]
Değiştirilmiş Kısmi Eşleştirmeli Çaprazlama (KEÇ2)	[49]	Aç Gözlü Sıralı Yapıcı Çaprazlama (AÇSYÇ)	[51]
Çok Yavrulu Kısmi Eşleştirmeli Çaprazlama (ÇYKEÇ)	[45]	Ters Aç Gözlü Sıralı Yapıcı Çaprazlama (TASYÇ)	[51]
Çok Yavrulu Genetik Algoritma (ÇYGA)	[45]	Değiştirilmiş Sezgisel Çaprazlama (DSC)	[51]
Sıralı Çaprazlama (SÇ)	[49, 42, 43, 44, 45, 47, 50, 52, 59]	Bölgeleme Çaprazlama (BÇ)	[53]
Sıraya Dayalı Çaprazlama (SDÇ)	[9, 53]	Gelişmiş Sıralı Yapıcı Çaprazlama (GSYÇ)	[54]
Sarılmayan Sıralı Çaprazlama (SSÇ)	[49, 42]	Üçlü Çaprazlama (ÜÇ)	[46]
Dairesel Çaprazlama (DÇ)	[49, 42, 44, 45, 47, 50, 66, 53, 59]	Alternatif Pozisyon Çaprazlama (APÇ)	[47]
Değiştirilmiş Dairesel Çaprazlama (DÇ2)	[49, 43, 44, 45, 46]	Alternatif Kenar Çaprazlama (AKÇ)	[50]
Geliştirilmiş Dairesel Çaprazlama (GDÇ)	[44]	Genelleştirilmiş N-nokta Çaprazlama (GNÇ)	[58]
Pozisyona Dayalı Çaprazlama (PDÇ)	[9, 59]	Bir nokta Çaprazlama (BNÇ)	[52]
Kenar Birleştirme Çaprazlama (KBÇ)	[47, 66, 53, 58]	İki nokta Çaprazlama (İNÇ)	[52, 66]
KBÇ varyantı (KBÇ6)	[48]	Karıştırma Çaprazlama (KÇ)	[66]
Maksimum Korumacı Çaprazlama (MKÇ)	[9, 59]	Tek Düzey Sıra Tabanlı Çaprazlama (TDSTÇ)	[66]
MKÇ varyantı (MKÇ3)	[48]	Alt Tur Değişim Çaprazlama (ADÇ)	[66]

Tablo 1.3. Devam ediyor

MKÇ varyantı (MKÇ3)	[48]	Alt Tur Değişim Çaprazlama (ADÇ)	[66]
Aç Gözlü Alt Tur Çaprazlama (AGA-2)	[48]	Geliştirilmiş Aç Gözlü Alt Tur Çaprazlama (GAA-2)	[67]
Alt Tur Birleştirme Çaprazlama (ATBÇ)	[48]	İsimsiz Sezgisel Çaprazlama (İSÇ)	[67]
Aç Gözlü Çaprazlama (AÇ)	[50, 9, 67]	Mesafe Koruma Operatörü (MKO)	[67]
Gelişmiş Aç Gözlü Çaprazlama (GAÇ)	[68]	Dairesel Kaydırmalı Ters Çaprazlama (DKTÇ)	[69]
Çok Aç Gözlü Çaprazlama (ÇAÇ)	[67, 51]	En İyi Sıra Çaprazlama (EİSÇ)	[69]

2018'de Hussain ve ark. [44] DÇ2 ve DÇ'ten esinlenerek GDÇ yöntemini önerdiler. Beş farklı operatör KEÇ, SÇ, DÇ, DÇ2 ve GDÇ, on simetrik ve asimetrik veri seti üzerinden karşılaştırıldı. Yapılan t-testi sonucunda istatistiksel sonuçlar GDÇ yönteminin en iyi çözüm kalitesini sunduğunu ve %95 güven seviyesine sahip olduğunu gösterdi.

Hussain ve ark. [45] 2019 yılında ÇYKEÇ yöntemini öneren karşılaştırmalı bir çalışma gerçekleştirdi. Hem simetrik hem de asimetrik veri setlerindeki verimliliği analiz etmek için önerilen operatörü SÇ, ÇYGA, DÇ, DÇ2 ve KEÇ operatörleriyle karşılaştırdılar. İstatistiksel analiz, ÇYKEÇ yönteminin t-testi, standart sapma ve yakınsama oranları açısından en iyi yöntem olduğunu gösterdi.

Akter ve ark. [46] 2019'da DÇ2 yönteminin bazı durumlarda çocuk kromozomlarında varyasyon bulamaması sorununu ortaya koydular. Sınırlamaların üstesinden gelmek için, gelecek nesli yaratma sürecinin şehirlerarasındaki minimum maliyete bağlı olduğu yeni bir çaprazlama tekniği önerdiler. Önerilen operatör, ÜÇ ve SYÇ ile karşılaştırıldığında en az zaman harcayan operatör olduğunu gösterdiler.

2019 yılında Al-Ommer ve ark. [47] tarafından karşılaştırmalı bir çalışma yürütülmüş, 6 farklı çaprazlama operatörü SÇ, KEÇ, KBÇ, DÇ, APÇ ve SYÇ test edilmiştir. Deneysel sonuçlara göre hata yüzdesi açısından KBÇ operatörü en düşük performansı (%90.86) gösterirken, en iyi performansı (%19.52) SYÇ operatörü gösterdi. Ayrıca KEÇ operatörünün hesaplama süresi açısından en iyi yöntem olduğu görülmüştür.


1.3. Çelik Üretim Planlama

Demir ve çelik endüstrisi, antik çağlardan beri çeşitli endüstrilerin gelişiminde önemli bir rol oynamıştır. Özellikle gelişmekte olan ülkelerde diğer endüstrilere öncülük etmiştir. Güney Kore, 1970'lerde ve 1980'lerde yeni sanayileşen ülkelere biriyken, son yıllarda

Çin'deki çelik üretim oranındaki artış, inşaat projelerinde ve imalat endüstrisinde üretimde hızlı bir büyüme sağlamıştır. Öte yandan, ülkeler çelik üretim oranlarını artırırken bu kaynakların kıtlığıyla başa çıkmak zorundadır. Bu nedenle, üretim planlama ve programlama sayesinde ülkelerin kaynaklarını en verimli şekilde kullanmak, üretim maliyetlerini düşürmek ve ürün kalitesini iyileştirmek mümkündür [70].


2017'deki çelik piyasası gelişmeleri raporu, çelik üretim şirketlerinin sürdürülebilir kâr seviyesinin altında kaldığını gösterdi. Endüstriyel üretim planlamasında, birbiriyle ilişkili ve çelişkili nitelikler arasında denge kurmak esastır. Örneğin, bir üretim programı, verim seviyeleri açısından en iyi şekilde tasarlanmış olabilirken, ürün kalite ölçütleri açısından yetersiz kalabilir. Bu sorun, GSP olarak formüle edilebilir ve çözülebilir. Bu yaklaşım, tesislerin üretim verimliliğini artırabilir, maliyeti düşürebilir ve daha kısa sürede daha fazla çelik üretimine olanak tanıyabilir. Bu hedef doğrultusunda, çelik üretiminde planlama sistemlerinin matematiksel optimizasyonuna ihtiyaç vardır [70, 59].

Çelik üretimi beş farklı kategoriye ayrılabilir. Birincil çelik üretimi, ikincil çelik üretimi, sürekli döküm, sıcak haddehane ve diğer işlemler olmak üzere üretim aşamaları Şekil 1.6'da verilmiştir. Birincil üretimi, hurda metalleri veya demir cevherleri sıvı demire dönüştürme aşamasıdır. Demir cevherler yüksek fırınlarda eritilirken, hurda metaller elektrik ark ocaklarında eritilmektedir. Birincil çelik üretiminden elde edilen sıvı çelik, ikincil çelik üretim tesisine gönderilir. İkincil çelik üretimi, çeliğin daha kaliteli üretilmesi amacıyla, ham çeliğin rafine edilmesi aşamasıdır. Çelik kalitesini belirleyen elementlerin eklenmesi veya çıkarılması gerektiğinden, ikincil çelik üretimi en önemli aşamadır. Bu işlemlerin çoğu pota fırınlarda gerçekleştirilir. Pota fırınlarda üretilen sıvı çelik, sürekli döküm tesislerine gönderilir. Sürekli döküm sıvı çeliğin levhalara dönüştürüldüğü aşamadır. Sürekli döküm sonucunda, kütük, slab, blum gibi yarı nihai ürünler ortaya çıkar. Sıcak haddehane işleminde plakalar uygun deformasyon sıcaklığına kadar ısıtılır ve daha sonra kangal (coil) haline getirilir. Diğer işlemler aşamasında ise, üretilen kangal ürünler, bir kısmı nakliye için ayrılırken, bir kısımda sürekli galvanizleme işlemi yapılmak üzere ayrılır. Sürekli galvanizleme işlemi, çeliğin korozyon direncini artırmak için çinko eklenmesi işlemidir [70].



Şekil 1.6. Çelik üretim aşamaları

Sıcak haddeleme üretim planı, üretim süreçlerinin ve üretim ekipmanlarının kısıtlamalarını ve ürün kalitesi gereksinimlerini hesaba katan sözleşme siparişlerine dayalı bir üretim planıdır. Tam bir haddeleme ünitesi planı, Şekil 1.7'de gösterildiği gibi, levha genişliğinin "tabut şekli" şeklinde değiştiği "ısıtma (warm-up) malzemesi bölümü" ve "zımba (staple) malzemesi bölümünden" oluşur. Isıtma malzemesi bölümü, levhaların sıcaklıklarını artırarak, şekillendirmeye uygun hale getirilme aşamasıdır. Zımba malzemesi bölümü ise levhaların şekillendirilip işleneceği malzeme kısmıdır, yani son ürünün şekli bu aşamada ortaya çıkar [71, 70].



Şekil 1.7. Sıcak haddeleme ünitesinin yapısı

Haddelme planlaması, üretim süreci kısıtlamalarına göre aday levhaları seçme ve haddeleme süreci olarak özetlenebilir. Genellikle üretim kapasitesini artırmak için teslim süresini ihlal etmeden birim planının kapasitesini maksimize etmek, rulolardaki levhanın aşınmasını en aza indirerek rulo değişim sayısını azaltmak ve enerji tüketimini azaltmak için

levha sıcak şarj oranını maksimize etmektir. Genellikle, bir haddeleme planı hazırlanırken aşağıdaki kısıtlamaların karşılanması gerekir:

1. Isıtma malzemesi bölümünde, levha genişliği genellikle dardan geniş doğru, zımba malzemesi bölümünde ise genellikle genişten dara doğru değişmelidir. Genişlik geçişlerinde yerel sıçramalara (küçük sapmalara) izin verilebilir.
2. Üretim planında; levha genişliği, kalınlığı, sertliği, döküm sıcaklığı, bitiş haddeleme sıcaklığı ve sarım sıcaklığı gibi işlem parametreleri, kademeli olarak değişmeli ve aralarındaki fark belirli sınırları aşmamalıdır.
3. Aynı genişlikteki veya aynı yüzey kalitesine sahip levhalarla yapılan ardışık haddeleme uzunluğu, belirli bir maksimum değeri geçmemelidir.
4. Isıtma ve zımba malzemelerine ait üretim planlarında, toplam haddeleme uzunluğu veya ağırlığı, ilgili kısıtlama ve gereksinimlere uygun olmalıdır.
5. Düşük kalite gereksinimine sahip levhalar, ısıtma malzemesi bölümünde; yüksek kalite gereksinimine sahip levhalar ise zımba malzemesi bölümünde haddelenmelidir.

Sıcak haddeleme modelinde çelişkili kısıtlamalar olduğundan, çok amaçlı bir optimizasyon problemidir. Çok amaçlı optimizasyon problemlerinin çözümü için iki yaklaşım kullanılabilir. Birinci yaklaşım olarak, çok amaçlı optimizasyon probleminin tek amaçlı optimizasyon problemine dönüştürüp, ardından tek amaçlı optimizasyon problemi için tasarlanmış genetik algoritmalar ve tabu arama gibi meta-sezgisel algoritmaların kullanılmasıdır. Genetik algoritmalar genom biyolojisinden gelen fikirleri kullanırken tabu araması yakın zamanda bulunan çözümler için bir tabu listesi kullanır. İkinci yaklaşım, NSGA-II gibi çok amaçlı optimizasyon problemleri için tasarlanmış algoritmaları kullanmaktır. NSGA-II, standart genetik algoritma yaklaşımını kullanarak birden fazla nesnel hedefi optimize eder [70]. Problemin çözümü için en yaygın kullanılan optimizasyon yöntemleri Tablo 1.4'te gösterilmiştir.

Tablo 1.4. Çelik üretim planlamada kullanılan optimizasyon teknikleri

Tabu Arama
Genetik Algoritma
Karınca Kolonisi

Tablo 1.4. Devam ediyor

External Optimizasyon
Parçacık Sürü Optimizasyonu
Benzetimli Tavlama
Bağışıklık Algoritması
Evrimsel Optimizasyon

Bu çalışmada, çelik üretiminde haddeleme levha parametreleri olan, levha genişliği, kalınlığı, sertliği, döküm sıcaklığı, bitiş haddeleme sıcaklığı ve sarım sıcaklığı gibi işlem parametreleri arasındaki nitelik farkını en aza indirmek amacıyla, GA tabanlı bir optimizasyon yaklaşımı uygulanmıştır. Problem, asimetrik GSP olarak modellendi ve GA'nın performansına etki eden seçim, çaprazlama ve mutasyon yöntemlerinin optimizasyon sonuçları üzerindeki performansları karşılaştırılmıştır.

1.3.1. Çelik üretimi alanında yapılan çalışmalar

Çelik üretim şirketlerinde uzun süredir araştırma konusu olan haddeleme planlaması probleminin çözümü için çeşitli optimizasyon algoritmaları önerilmiştir. 1989'da Balas, bir çelik haddehane probleminin planlamasını, ödüllü bir GSP'ye (ÖGSP) formüle etti. Siparişlere atanan levhaların envanterden seçilmesi ve levhaların sırasının belirlenmesi görevlerinin ortak çözümü için teorik bir çalışma yapılmıştır [72].

Kosiba ve ark. (1992), çakışan üretim hedeflerine ceza puanları atadı ve bunları tek bir performans ölçüsünde topladı. Problem, Miller ve ark. tarafından önerilen kesin çözüm yöntemi kullanılarak asimetrik bir GSP olarak modellenmiş ve çözülmüştür ve %78'e varan iyileşme sağladığı gösterilmiştir [73].

Lopez ve ark. (1998), yeniden ısıtma fırınlarını dikkate alarak bir sıcak haddehane problemini bir ÖGSP olarak formüle etmiş ve problemi tabu aramasını kullanarak çözmüştür. Hesaplama sonuçları, önerilen yöntemin geleneksel üretim programlarından önemli ölçüde daha iyi performans gösterdiğini göstermiştir [74].

Tang ve ark. (2000), bir sıcak haddeleme programlama problemini çoklu GSP (ÇGSP) olarak modelledi ve aynı anda çoklu çalıştırmaları programlamak için değiştirilmiş bir GA kullandı. Bu makalede, paralel stratejinin teorik olarak seri stratejiden %20 daha iyi olduğu gösterilmiştir [75].

Zhang ve ark. (2009), araç rotalama problemi (ARP) ve ÖGSP'nin özelliklerini birleştiren ve hadde yığınlarının kalitesini korurken çelik şerit özelliklerindeki planlanmamış değişiklikleri en aza indirmeyi amaçlayan bir ödül toplama aracı yönlendirme problemi modeli önerdi. Çalışmada problemin çözümü için parçacık sürü optimizasyonu kullanılmış ve çözüm kalitesini büyük ölçüde iyileştiren tabu arama yöntemine yer verilmiştir [76].

Tang ve ark. (2009), aynı genişlikteki ardışık plakaların haddeleme uzunluğu ve bitişik plakalar arasındaki sıcaklık sıçraması gibi çelik yapımında yer alan özellikleri birleştirerek model geliştirdi. Problemin çözümü için Karınca kolonisi ve saçılma aramasına dayalı iki farklı hibrit yöntem önerilmiştir. Ek olarak, sıcak haddehane çizelgeleme sürecini iyileştirmek için iki hibrit yöntemin gömülü olduğu bir karar destek sistemi geliştirilmiştir [77].

Xue ve ark. (2010), sıcak haddeleme planlaması için sözde GSP modeli ile çelik üretimini modelledi. Bu model ile birim numarası olmadan optimum haddeleme problemini çözebileceklerini göstermişlerdir. Problemi çözmek için ters operatör ile geliştirilen ayrık parçacık sürüsü optimizasyonu kullandılar [78].

Zhao ve ark. (2011), GSP için tasarlanmış paralel genetik ve bağışıklık operatörlerinden oluşan GPU yapısına dayalı bir paralel bağışıklık algoritması (PBA) önermiştir. Önerilen yöntemi doğrulamak için çelik endüstrisine örnek olarak soğuk haddeleme üretim çizelgelemesi üzerinde pratik bir uygulama yapılmıştır. Deneysel sonuçları, önerilen yöntemin mevcut akıllı algoritmalarından daha iyi çözme verimliliği sağladığını göstermektedir [79].

Su ve ark. (2021), sıcak haddeleme üretim sürecini, donanım ve ürünlerin gerekliliklerini ve kısıtlamalarını kapsamlı bir şekilde değerlendirdi ve çizelgeleme problemini asimetrik GSP'ye indirdi. Modeli çözmek için tabu tabloları olan bir karınca kolonisi-GA tasarladılar [71].

Bu çalışma, GA operatörlerinin performansını GSP veri setlerinde gözlemlemeyi ve çelik sıcak haddehane planlama problemini asimetrik bir GSP'ye indirgemeyi ve çözmeyi amaçlamıştır. Çelik fabrikasından alınan üretim verileri kullanılarak, levha genişliği, kalınlığı, sertliği, döküm sıcaklığı, bitiş haddeleme sıcaklığı ve sarım sıcaklığı gibi çelişen parametreler arasındaki varyasyonu en aza indirmek için genetik operatörlerinin hem yakınsama oranları hem de hesaplama süreleri karşılaştırılmıştır.

2. MATERYAL VE METOT

2.1. Seçim Operatörleri

Seçim operatörleri, genetik algoritmada çiftleşme için seçilecek bireyleri belirleme sürecidir. Seçim stratejisi, zayıf bireylerin elenmesi ve böylece daha iyi bireylerin ebeveyn olma şansının artırılması ilkesine dayanır. GA'nın performansı, seçim baskısına bağlıdır. Literatürde en sık kullanılan seçim yöntemleri, turnuva seçimi (TS) [16, 17] , uygunluk orantılı seçim (UOS) [16, 17], doğrusal sıra seçimi (LSS) [16, 17], üstel sıra seçimi (ÜSS) [16, 17], bölünmüş sıra seçimi (BSS) [16, 17] ve yeni turnuva seçimi (YTS) [17] operatörleri uygulanmıştır. Ayrıca, keşif ve sömürü arasındaki dengeyi iyileştirmek için, keşif sömürü denge seçimi (KSDS) ve hibrit seçimi (HS) yöntemleri önerilmiş ve literatürdeki yöntemler ile istatistiksel olarak performansları karşılaştırılmıştır.

2.1.1. Uygunluk orantılı seçim

Holland tarafından önerilen uygunluk orantılı seçim veya rulet çarkı seçim yöntemi kromozomların uygunluk değerleri ile orantılı olasılıklarına göre seçildiği varsayılır [9]. Kromozomların seçilme olasılıkları yani, kromozomun uygunluk değerinin, toplam popülasyonun uygunluk değerlerine oranları bir rulet çarkına yerleştirilir. Olasılık dağılımları Denklem 2.1'e göre hesaplanır.


$$p_i = \frac{f_i}{\sum_{j=1}^K f_j} ; \quad i \in \{1, 2, \dots, K\} \quad (2.1)$$

Burada f_i kromozom i 'nin uygunluk değerini ifade ederken, K popülasyon büyüklüğünü ifade eder. Tablo 2.1'de örnek olarak uygunluk değerlerine göre olasılık dağılımı verilmiştir.

Tablo 2.1. Uygunluk orantılı seçim olasılık dağılımı

Kromozom	Uygunluk değeri	Olasılık
1	0.2	0.2/1.4 =0.143
2	0.5	0.5/1.4 =0.357
3	0.1	0.1/1.4 =0.071
4	0.6	0.6/1.4 =0.429


Rulet çarkı döndürülür ve durduğunda, merkez açısı yüksek olan yüksek olan kromozom dilimlerinden birine denk gelir. Avantajı, popülasyondaki tüm bireylere hiçbirini elemeyen seçilme şansı vermesi ve böylece popülasyonun çeşitliliğini sağlamasıdır [16]. Ancak, uygunluk değerlerinde belirgin bir tutarsızlık olduğunda, bir ölçekleme sorunu ortaya çıkar. Grefenstette, ölçekleme sorununu ilk tanımlayan kişiydi [17]. Bir popülasyon evrimleştikçe, varyans ile ortalama uygunluk değeri arasındaki tutarsızlık azalır ve bu da seçim baskısında bir azalmaya yol açar. Düşük seçim baskısı, popülasyonun yakınsamaya doğru ilerlemesini engelleyebilir. Sonuç olarak, popülasyon dengeye yaklaştıkça, seçim baskısı azalma eğilimindedir. Tersine, yüksek seçim baskısı seviyeleri, optimum olmayan bir çözüme doğru erken yakınsamayı hızlandırabilir. Operatörün çalışma prensibi Şekil 2.1’de verilmiştir.



Şekil 2.1. Rulet çarkı olasılık dağılımı

2.1.2. Turnuva seçimi

Turnuva seçimi, verimliliği ve uygulama kolaylığı nedeniyle genetik algoritmanın en popüler seçim tekniğidir [9]. Turnuva seçiminde, n tane kromozom tüm popülasyondan rastgele seçilir. Bu seçilen kromozomlar kendi aralarında yarışır ve en yüksek uygunluk değerine sahip kromozom kazanır ve bir sonraki işlem için seçilir. Turnuvaya katılan kromozom sayısı turnuva boyutu olarak adlandırılır. Seçim baskısı turnuva boyutuyla değiştirilebilir ve en yaygın kullanılan boyut ikidir (İkili turnuva seçimi (İTS)). Turnuva seçimini diğer tekniklerden avantajlı hale getiren uygunluk ölçeklemesi ve sıralama gerektirmemesidir. Turnuva seçimi tekniği Şekil 2.2’de verilmiştir.



Şekil 2.2. Turnuva seçimi tekniği çalışma prensibi

Turnuva boyutu ne kadar büyük olursa, çeşitlilik kaybı olasılığı yüksek olur. Bunun sebebi, kromozom rasgele seçim nedeniyle seçilme fırsatı bulamadığından ya da bazı turnuvaları kaybettiği için ara popülasyonda seçilememesidir [9].

2.1.3. Lineer sıralama seçimi

Lineer sıralama seçimi, orantılı seçimin dezavantajlarını ortadan kaldırmak için Baker [26] tarafından önerilmiştir. Kromozomlar, uygunluk değerlerine göre en kötüden en iyiye doğru sıralanır ve sıralarına göre hayatta kalma şansları atanır. Bu görevin ardından, bireyleri seçmek için rulet çarkı örnekleme kullanılır. LSS tarafından sağlanan tutarlı ölçekleme, örnekleme süreci boyunca tutarlı bir seçim baskısı sağlar. Uygunluk değerinden bağımsız olarak, en yüksek uygunluğa sahip bireye her zaman farklı bir seçim olasılığı atanır. LSS alternatif metodolojilere göre başarısızlığa karşı daha dayanıklıdır ve böylece daha kararlı bir yaklaşım sağlar [16]. Kromozomlar için seçim olasılıkları Denklem 2.2'ye göre atanır.

$$p_i = \frac{1}{K} (n^- + n^+) \frac{i-1}{K-1} ; i \in \{1, \dots, K\} \quad (2.2)$$

Burada; p_i i numaralı kromozomun seçim olasılığı, $\frac{n^-}{K}$ en kötü kromozomun seçim olasılığını, $\frac{n^+}{K}$ en iyi kromozomun seçim olasılığını temsil eder. Kromozomlar aynı uygunluk değerine sahip olsalar bile, farklı bir sıralama alırlar. Seçici baskı değeri n^+ , $n^+ = 2 - n^-$ ve $n^- \geq 0$ olarak ayarlanabilir. Baker, n^+ değerini 1,1 olarak önermiştir. LSS'nin dezavantajı, ardışık kromozomlar arasında önemli bir fark olmadığından, daha yavaş yakınsamaya yol açabilir.

2.1.4. Üstel sıralama seçimi

Üstel sıralama seçim yöntemi, seçim olasılıkların üstel olarak hesaplanması bakımından doğrusal sıralama seçim tekniğinden farklıdır. Kromozomlara dizi tabanlı

değerler atamak için sabit bir katsayı r kullanılır ve $0 < r < 1$ ($r \simeq 1.0$) koşuluyla seçim olasılıkları atanır. Seçim olasılığı;

$$p_i = \frac{r^{K-i}}{\sum_{j=1}^K r^{K-j}} ; i \in \{1, \dots, K\} \quad (2.3)$$

Toplam $\sum_{j=1}^K r^{K-j}$, $\sum_{i=1}^K p_i = 1$ eşitliğini sağlamak için olasılıkları normalleştirir [14]. $\sum_{j=1}^K r^{K-j} = \frac{r^{K-1}}{r-1}$, olduğundan Denklem 2.4'te yeniden yazılabilir.

$$p_i = \frac{r-1}{r^{K-1}} r^{K-i}; i \in \{1, \dots, K\} \quad (2.4)$$

2.1.5. Bölünmüş sıralama seçimi

Hussain ve ark. (2020) [16] tarafından önerilen bölünmüş sıralama seçimi küresel ve yerel arama arasında ince bir denge sağlamaktadır. Bu yöntemde tüm bireyler uygunluk değerlerine göre en kötüden en iyiye doğru sıralanır. Aynı uygunluk değerine sahip olsalar bile tüm bireyler farklı bir sıralama alırlar. Popülasyon büyüklüğü K iki eşit parçaya bölünürse, serinin ilk yarısının özeti;

$$\frac{K}{4} \left(\frac{K}{2} + 1 \right) \quad (2.5)$$

Serinin son yarısının özeti;

$$\frac{K^2}{4} + \frac{K}{4} \left(\frac{K}{2} + 1 \right) \quad (2.6)$$

Dolayısıyla bireyin olasılık dağılımı şu şekildedir:

$$P(i) = \begin{cases} \lambda^- \left(\frac{8i}{K(K+2)} \right); & i \leq \frac{K}{2} \\ \lambda^+ \left(\frac{8i}{K(3K+2)} \right); & i > \frac{K}{2} \end{cases} \quad (2.7)$$

Burada, $\lambda^- + \lambda^+ = 1$ ve $\lambda^- \geq 0$ olmalıdır. Seçim baskısı, λ^+ parametre ayarlanması ile kısıtlanabilir. Küresel ve yerel arama arasındaki dengenin korunması için $\lambda^+ = 0.7$

seçilmeli, yani %70 lük kısım son yarıdaki bireylere atanırsa olasılık dağılımı aşağıdaki gibi olur.

$$P(i) = \begin{cases} \lambda^- \left(\frac{12i}{5K(K+2)} \right); & i \leq \frac{K}{2} \\ \lambda^+ \left(\frac{28i}{5K(3K+2)} \right); & i > \frac{K}{2} \end{cases} \quad (2.8)$$

Aynı şekilde popülasyon büyüklüğü tek sayılı olması durumlarında bireylerin olasılık dağılımları aşağıdaki gibi olur.

$$P(i) = \begin{cases} \lambda^- \left(\frac{8i}{(K^2-1)} \right); & i \leq \frac{K-1}{2} \\ \lambda^+ \left(\frac{8i}{(K+1)(3K+1)} \right); & i > \frac{K-1}{2} \end{cases} \quad (2.9)$$

2.1.6. Yeni turnuva seçimi

Yeni turnuva seçimi, Naqvi ve ark. [17] tarafından 2023 yılında ortaya atılmıştır. Önerilen yöntemde, bireyler uygunluk puanlarına göre en kötünden en iyiye doğru sıralanır ve böylece uygunluk ölçekleme sorunu ortadan kaldırılır. Daha sonra, bireylere olasılık ataması, keşif ve sömürü arasında bir denge sağlama amacıyla Denklem 2.10'a uygun olarak gerçekleştirilir;

$$P_i = \frac{2(3i-1)}{K(3K+1)} \quad (2.10)$$


2.2. Yeni Seçim Operatör Önerileri

2.2.1. Keşif-sömürü denge seçimi

2.2.1.1. Motivasyon


Seçilim baskılarının sınırlı aralığı nedeniyle, LSS nispeten yavaş bir yakınsama hızı ve alt optimum bir çözüme yakınsama eğiliminin arttığını göstermektedir. UOS temel özellikleri sömürüye atfedilebilirken, LSS keşfetme dürtüsüyle şekillenir. Keşif ve sömürü arasındaki dengeyi korumak için, seçilim baskısını değiştirme yeteneğine sahip olmak esastır. Bu amaçla, epsilon açgözlü yönteminden esinlenerek seçilim baskısını ayarlanabilir hale getiren bir yöntem geliştiriyoruz. Epsilon-açgözlü yönteminin temel kavramı, bir olasılık katsayısı ϵ [80] kullanımı yoluyla açgözlü bir algoritmanın veya rastgele bir

algoritmanın uygulanmasını düzenlemektir. Şekil 2.3, önerilen yöntemimizin epsilon açgözlü algoritmasından nasıl esinlendiğini göstermektedir.



Şekil 2.3. Keşif-sömür dengesi

Keşif ve sömürü arasındaki dengeyi iyileştirmek için bireylerin uyarlanabilir seçimine izin veren yöntem önerilmektedir [81]. Tüm bireyler uygunluk değerlerine göre sıralanır. Bireylere olasılık dağılımları atamak ve popülasyonu iki eşit parçaya bölmek yerine, popülasyon keşif ve sömürü katsayılarına göre bölünür. Şekil 2.4'te verildiği gibi, bölünen popülasyonun ilk kısmı sömürü, ikinci kısmı keşif olacak şekilde seçilecek adayların bir listesi oluşturulur.



Şekil 2.4. Keşif ve sömürü aday listelerinin belirlenmesi

Sömürü oranı keşif oranından az ise, sömürü ağırlığı artırılır, keşif ağırlığı azaltılır ve keşif adayları arasından bir birey seçilir. Bu durumda, daha fazla keşif için baskın bir tercih yapılır. Sömürü oranı keşif oranından fazla ise, sömürü ağırlığı azaltılır, keşif ağırlığı artırılır

ve sömürü adayları arasından bir birey seçilir. Bu durumda, daha fazla sömürü için baskın bir tercih yapılır. Önerilen yöntemin çalışma prensibi Algoritma 1'de verilmiştir.

Algoritma 1: Keşif-sömürü denge seçimi (KSDS)

```

1  Girdi: Popülasyon
2  Çıktı: SecilenBirey
3  Başla
4      Başlangıç sömürü  $\lambda^x$  ve keşif  $\lambda^y$  parametrelerini belirleyin
5       $\lambda^x + \lambda^y = 1$ , olmak üzere
6       $kesifAdayListesi = [], sömürüAdayListesi = []$ 
7       $sıralıPopülasyon = sort(popülasyon)$ 
8       $K = len(popülasyon)$ 
9      for  $i \leftarrow 0$  to  $round(K * \lambda^x)$  do
10         |  $sömürüAdayListesi.append(sıralıPopülasyon_i)$ 
11      for  $i \leftarrow round(K * \lambda^x)$  to  $K$  do
12         |  $kesifAdayListesi.append(sıralıPopülasyon_i)$ 
13      Eğer( $\lambda^x < \lambda^y$ )
14         |  $\lambda^x = min(1.0, \lambda^x * 1.1)$ 
15         |  $\lambda^y = max(0.1, \lambda^y * 0.9)$ 
16         |  $secilenBirey = rasgeleSec(kesifAdayListesi)$ 
17      Eğer( $\lambda^x > \lambda^y$ )
18         |  $\lambda^x = max(0.1, \lambda^x * 0.9)$ 
19         |  $\lambda^y = min(1.0, \lambda^y * 1.1)$ 
20         |  $secilenBirey = rasgeleSec(sömürüAdayListesi)$ 
21      Eğer( $\lambda^x = \lambda^y$ )
22         |  $secilenBirey = rasgeleSec(sıralıPopülasyon)$ 
23      Dön  $secilenBirey$ 
24  Son

```

Burada K popülasyon büyüklüğünü, λ^x sömürü parametresini ve λ^y keşif parametresini temsil eder.

2.2.1.2. Zaman karmaşıklığı analizi

Önerilen yöntemin toplam gerekli olan zaman karmaşıklığı, sıralama ve döngü (keşif ve sömürü aday listelerinin oluşturulması) işlemlerinden oluştuğundan toplam zaman karmaşıklığı $O(K \log K) + O(K) = O(K \log K)$ olur. Bellek karmaşıklığı açısından, algoritma girdi olarak sağlanan popülasyon üzerinde çalışır. Sömürü aday listesi yaklaşık $k \cdot \lambda^x$ öge içerirken, keşif adayları listesi yaklaşık $K \cdot (1 - \lambda^x)$ öge içerir ve toplamda ek $O(K)$ bellek gerektirir.

2.2.2. Hibrit seçim

Seçilim süreçlerinin, seçim baskısını değiştirerek çözüm alanının keşfi ve sömürülme seviyesini kontrol edebileceğini Back [6] tarafından göstermiştir. Daha yüksek seçim baskısı, aramayı sömürüye doğru iterken ve daha düşük seçim baskısı ise, aramayı keşfe doğru iter. Bu nedenle, genetik veya evrimsel algoritma işleminin en önemli unsurlarından biri, potansiyel çözümlerin yeni popülasyonlarının (bireyler) yaratıldığı bir seçim aşamasıdır. Seçim baskısı, bir seçim mekanizmasının tasarlanmasında kritik öneme sahiptir ve evrimsel algoritmalar alanında yaygın olarak incelenmiştir. Algoritmanın erken aşamalarında keşif özelliğini artırmak için seçim baskısı düşük tutulurken, ilerleyen aşamalarda sömürü özelliğini güçlendirmek amacıyla seçim baskısı artırılması fikrine dayanan ve hibrit bir seçim yöntemi (HS) önerilmektedir. HS, keşif ve sömürü arasında dengeyi yöneten α kontrol parametresi ile yapılandırılmıştır. UOS operatörü, sömürü yapılması, KSDS operatörü, keşif yapılması ve YTS yönteminin ise denge durumunda kullanılması hibrit yaklaşım olarak tasarlanabilir. Algoritmanın başlangıç durumunda, çözüm uzayında keşif yapmak için KSDS yöntemi ile başlanıp son aşamalarda, bulunan çözümleri iyileştirmek üzere UOS yöntemi devreye alınmıştır. Denge durumunda YTS yöntemi tercih edilmiştir. Böylece keşif ve sömürü arasındaki dengenin sağlanması amaçlanmıştır. Hibrit seçim yöntemi Algoritma 2’de verilmiştir.

Algoritma 2: Hibrit seçim (HS)

1	Girdi: Popülasyon P , mevcut nesil t , maksimum nesil T , alfa kontrol stratejisi C
2	Çıktı: <i>secimYöntemi</i>
3	Başla
7	$\alpha \leftarrow \text{alphaHesapla}(P, t, T, C)$
8	Eğer $\alpha \leq 0.7$ ise
9	$\text{secimYöntemi} \leftarrow \text{dict_selector_operators}["EEBS"]$ // Keşif ağırlıklı seçim
10	Aksi Eğer $0.7 < \alpha \leq 0.8$ ise
11	$\text{secimYöntemi} \leftarrow \text{dict_selector_operators}["NTS"]$ // Dengeleyici seçim
12	Aksi
13	$\text{secimYöntemi} \leftarrow \text{dict_selector_operators}["FPS"]$ // Sömürü ağırlıklı seçim
14	$\text{ga_engine.selector.set}(\text{secimYöntemi})$
15	Dön <i>secimYöntemi</i>
16	Son

Literatürde keşif sömürü dengesini sağlayan parametre bazlı yöntemler Tablo 2.2’de verilmiştir [82, 83]. Genetik algoritmalar çerçevesinde adaptif seçim mekanizmalarında kayda değer ilerlemeler kaydedilmesine rağmen, mevcut çalışmaların çoğunluğu, ağırlıklı olarak deterministik, adaptif ve öz-uyarlamalı teknikleri kapsayan sınırlı bir parametre

kontrol stratejileri alt kümesine odaklanmıştır. Bu yaklaşımlar çeşitli bağlamlarda etkililik göstermiş olsa da bulanık mantık, entropi tabanlı adaptasyon, takviyeli öğrenme ve çok kollu haydut algoritmaları gibi alternatif parametre kontrol stratejilerini dahil ederek metodolojik kapsamı genişletmek için değerli bir fırsat bulunmaktadır.

Tablo 2.2. Keşif-sömürü dengesini sağlayan parametre bazlı yöntemler

Yöntem adı	Tanım	Referans
Deterministik parametre kontrolü	Parametreler sabit ve önceden belirlenmiş.	[84, 85]
Bulanık mantık kural tabanlı kontrol	Bulanık mantıkla hem çeşitlilik hem de uygunluk değeri değişimine bağlı olarak parametreler ayarlanır.	[86]
Adaptif parametre kontrolü	Parametreler otomatik olarak güncellenir; erken veya geç aşamada uygun parametreler tercih edilir.	[87, 88]
Öz-uyarlamalı parametre kontrolü	Parametreler genetik yapı ile birlikte evrimleşir; farklı bireyler farklı ayarlarla evrimleşebilir.	[89, 90, 91]
Entropi /Çeşitlilik tabanlı yöntemler	Popülasyondaki çeşitlilik düşükse (örneğin entropi ölçümüyle), mutasyon oranı artırılarak keşif teşvik edilir.	[92, 93]
Q-Learning ile parametre ayarı	Reinforcement learning kullanılarak çevre (popülasyon durumu) gözlemlenir ve parametreler akıllı şekilde ayarlanır.	[94, 95]
Multi-Armed Bandit (MAB) yaklaşımı	Operatörlerin başarı oranına göre seçim yapılır.	[96]

Bu çalışmada, keşif ve sömürü dengesini kontrol eden α parametresi, çeşitli parametre bazlı stratejilerle adaptif olarak güncellenmiş ve bu güncellemeye bağlı olarak yedi farklı hibrit seçim yöntemi önerilmiştir. Deterministik Hibrit Seçim (DHS) Bulanık Mantık Tabanlı Hibrit Seçim (BMHS), Adaptif Hibrit Seçim (AHS), Öz-Uyarlamalı Hibrit Seçim (ÖUHS), Q-Öğrenmeye Dayalı Hibrit Seçim (QÖHS), Çok Kollu Bantit Tabanlı Hibrit Seçim (ÇKHHS).

2.2.2.1. Deterministik hibrit seçimi

Deterministik kontrol stratejisinde, α parametresi evrimsel süreçten herhangi bir geri besleme almadan, önceden belirlenmiş zamana bağlı bir programa göre ayarlanır. Bu yöntem, Flores-Torres ve ark. [97] tarafından önerilen yaklaşıma dayanmaktadır. Bu yöntemde α , nesil sayacı t toplam nesil sayısı T 'ye doğru ilerledikçe, minimum değer olan


α_{min} 'den maksimum değer olan α_{max} 'e doğru lineer olarak artar. Bu kontrol kuralı aşağıdaki şekilde formüle edilir:

$$\alpha(t) = \alpha_{min} + (\alpha_{max} - \alpha_{min}) \frac{t}{T}, \quad t = 0, 1, \dots, T \quad (2.11)$$

Bu lineer zaman çizelgesi, α etkisinin zamanla artmasını sağlayarak, keşif aşamasından sömürü aşamasına doğru kademeli ve deterministik bir geçiş sağlar.


2.2.2.2. Bulanık mantık hibrit seçimi

Bulanık mantık kuralları kullanılarak popülasyon çeşitliliği ve jenerasyon sayısı giriş değişkenleri olarak belirlenmiştir [86]. Çıkış değişkeni olarak α parametresi olarak belirlenmiştir ve Şekil 2.5'te verilmiştir.




Şekil 2.5. Bulanık mantık giriş popülasyon çeşitliliği ve jenerasyon oranı çıkış alfa değeri

Giriş dilsel değişkenleri beş dilsel değere sahiptir: düşük (L), düşük-orta (LM), orta (M), yüksek-orta (HM) ve yüksek (H) ve bu değerler 0-1 aralığında tanımlanmıştır ve Şekil 2.6, 2.7 ve 2.8'de grafiksel olarak verilmiştir.




Şekil 2.6. Giriş dilsel değeri popülasyon çeşitliliğini temsil eden bulanık kümelerin grafiksel gösterimi

Popülasyon çeşitliliği 0-0.25 arasında ise yüksek, 0-0.25-0.5 arasında ise yüksek orta, 0.25-0.5-0.7 arasında ise orta, 0.5-0.7-1 arasında düşük orta ve 0.75-1 değerleri arasında düşük olarak etiketlenmiştir.



Şekil 2.7. Giriş dilsel değeri jenerasyon oranını temsil eden bulanık kümelerin grafiksel gösterimi

Jenerasyon oranı 0-0.25 arasında ise düşük, 0-0.25-0.5 arasında ise düşük orta, 0.25-0.5-0.7 arasında ise orta, 0.5-0.7-1 arasında yüksek orta ve 0.75-1 değerleri arasında yüksek olarak etiketlenmiştir.




Şekil 2.8. Çıkış dilsel değeri alfa değerini temsil eden bulanık kümelerin grafiksel gösterimi

α değeri 0-0.25 arasında ise düşük, 0-0.25-0.5 arasında ise düşük orta, 0.25-0.5-0.7 arasında ise orta, 0.5-0.7-1 arasında yüksek orta ve 0.75-1 değerleri arasında yüksek olarak etiketlenmiştir. α parametre değerlerinin kontrolü için belirlenen kurallar Tablo 2.3'de verilmiştir.

Tablo 2.3. Alfa parametre değerinin kontrolü için bulanık kurallar

Çeşitlilik/Jenerasyon	L	LM	M	HM	H
L	M	M	HM	H	H
LM	M	M	M	HM	H
M	LM	M	M	M	HM
HM	L	LM	M	M	M
H	L	L	LM	M	M

Kurallara göre popülasyon içindeki çeşitlilik düşük olduğunda, jenerasyonun erken aşamalarında α değeri dengeli olarak seçilir, ileriki aşamalarda alfa değeri yükselterek sömürü yapmak için alfa değeri artırılır. Çeşitlilik yüksek olduğunda jenerasyonun erken aşamalarında, α değeri düşük tutularak keşif yapılır ve ileriki aşamalarda α artırılarak sömürüye ağırlıklı baskın seçim yapılır. Şekil 2.9'da bulanık mantığın giriş değerlerine yüzey çıkış grafiği gösterilmektedir.



Şekil 2.9. Popülasyon çeşitliliği ve jenerasyon oranı girişlerine karşılık çıkış alfa değer yüzey grafiği

Popülasyon içindeki çeşitliliği ölçmek için Denklem 2.12’de verilen çiftler arasındaki hamming mesafesi kullanılmıştır. Bulanık sistemin tasarım varsayımını yerine getirmek için (popülasyon çeşitliliği 0’a eşit olduğunda çeşitlilik değeri 1’e eşit olmalıdır), çift toplam değeri 1’den çıkarılır.

$$H(x_i, x_j) = 1 - \sum_{i=1}^{K-1} \sum_{j=i+1}^K f(x_i, x_j) \quad (2.12)$$

Ek olarak, dilsel değer popülasyon çeşitliliği için tam değişkenlik aralığını elde etmek amacıyla 0-1 aralığında normalleştirdik. Normalleştirme, algoritmanın her yinelemesinden sonra dinamik olarak gerçekleştirildi:

$$H_{Norm,i} = \frac{H_i - H_{min}}{H_{max} - H_{min}} \quad (2.13)$$

Burada, $H_{Norm,i}$, algoritmanın i. yinelemesinde önerilen bulanık denetleyicinin girişine eklenen dilsel değişken popülasyon çeşitliliğinin normalleştirilmiş değeridir, H_{min} , i. yenilemedeki popülasyon çeşitliliğinin en düşük değeridir, H_{max} , i. yenilemedeki popülasyon çeşitliliğinin en yüksek değeridir, H_i , algoritmanın i. yinelemesi için elde edilen ortalama çeşitlilik değeridir.

α parametresinin uyarlanabilir kontrolü sorununu incelersek, şu şekilde düşünebiliriz: Evrimsel sürecin erken aşamasında, açgözlülüğü azaltmak ve arama alanını mümkün olduğunca keşfetmek faydalıdır. Süreç geliştikçe, keşfin kademeli olarak azaltılması

gerekirken, sömürüye olan vurgumuz artırılmalıdır. Bu kavramı yansıtan kural tabanı Tablo 2.3'de gösterilmiştir.

$$Jenerasyon\ oranı = \frac{iterasyon}{iterasyon_{max}} \quad (2.14)$$

Burada: *iterasyon*, algoritmanın geçerli bir yineleme sayısıdır, *iterasyon_{max}* maksimum algoritmanın yineleme sayısını ifade eder. Elbette, *iterasyon_{max}* parametresinin değeri önceden belirlenmelidir ve genellikle bilinmez ve problemin türüne bağlıdır.

2.2.2.3. Entropi tabanlı hibrit seçimi

Entropi, başlangıçta termodinamikte düzensizlik ölçüsü olarak tanımlanmış, daha sonra 1948 yılında Shannon [98] tarafından bilgi kuramına uyarlanarak belirsizliği ölçmekte kullanılmıştır. Evrimsel hesaplamada ise popülasyon çeşitliliğini ölçmek ve parametreleri uyarlamak amacıyla etkili bir metrik olarak kullanılmaktadır. Bu çalışmada önerilen Entropi Tabanlı Kontrol (EBC) yönteminde, GA'daki α parametresi, popülasyonun entropisine göre dinamik olarak ayarlanır. Yüksek entropi, popülasyonun çeşitli olduğunu ve keşif aşamasında olduğunu gösterirken; düşük entropi, yakınsamayı ve sömürüyü işaret eder [93]. Permütasyon tabanlı problemler için, her gen pozisyonundaki şehir frekanslarına dayalı olarak pozisyonel entropi hesaplanır:

$$H_j = - \sum_{k=1}^n p_{jk} \log_2 p_{jk} \quad (2.15)$$

Toplam popülasyon entropisi, tüm pozisyonların ortalaması olarak tanımlanır:

$$\bar{H} = \frac{1}{n} \sum_{j=1}^n H_j \quad (2.16)$$

Bu değer doğrudan α parametresi olarak atanır:

$$\alpha = \bar{H} \quad (2.17)$$

Bu sayede algoritma, popülasyon çeşitliliğine göre keşif ve sömürü dengesini otomatik biçimde ayarlayarak hem yakınsamayı iyileştirir hem de erken yakınsamayı önler.

2.2.2.4. Adaptif hibrit seçimi

Evrimsel algoritmelerde keşif ve sömürü dengesinin doğru şekilde kurulması hem çözüm kalitesi hem de yakınsama hızı açısından kritiktir. Sabit ya da zaman çizelgesine bağlı parametreler, arama sürecindeki değişken koşullara yeterince uyum sağlayamaz. Bu nedenle, geri beslemeye dayalı uyarlamalı kontrol stratejileri geliştirilmiştir [99]. Bu çalışmada, α parametresi, her nesilde elde edilen en iyi uygunluk değerine göre güncellenmektedir. Güncelleme, üstsel ağırlıklı hareketli ortalama kullanılarak yapılır:

$$\alpha_t = \gamma \alpha_{t-1} + (1 - \gamma) (\alpha_{t-1} + \Delta) \quad (2.18)$$

Burada γ hafıza katsayısıdır (genellikle 0.9), Δ ise uygunluk değişimine bağlı olarak şu şekilde hesaplanır:

$$\Delta = \max(\delta_{max}, \min(\delta_{max}, \frac{f_{prev} - f_{current}}{k})) \quad (2.19)$$

Bu yapıyla, uygunluk değerinde ilerleme sağlandığında α artırılarak sömürü güçlendirilir; ilerleme olmadığında ise α azaltılarak keşif teşvik edilir. Parametre güncellemeleri sınırlandırıldığı için aşırı dalgalanmalar önlenmiş olur. Önerilen adaptif kontrol yöntemi, arama sürecine dinamik şekilde uyum sağlayarak hem erken yakınsama riskini azaltmakta hem de algoritmanın genel başarımını artırmaktadır.

2.2.2.5. Öz uyarlamalı hibrit seçimi

Öz uyarlamalı hibrit seçimi, evrimsel algoritmelerde parametre ayarlaması için güçlü bir mekanizma sunar. Bu yaklaşımda, örneğin mutasyon oranı, çaprazlama olasılığı veya bu çalışmada olduğu gibi keşif-sömürü dengesini yöneten α parametresi, bireylerin gen tipine dâhil edilir ve çözüm adaylarıyla birlikte evrimleşir. Böylece dışsal bir zaman çizelgesi veya kural tanımlamaya gerek kalmadan, algoritma parametreleri kendi içinde öğrenir ve günceller [19, 99]. Bu çalışmada önerilen yapıda, her birey kendi α parametresine sahiptir ve bu değer evrimsel süreç boyunca rastgele mutasyonlarla değişime uğrar. Böylece farklı arama alanları ve evrimsel süreçlerin farklı aşamaları için en uygun α değerleri, doğal seçimle öğrenilir. Parametre güncellemesi şu şekilde yapılır:

$$\alpha_i^{(t+1)} = clip(\alpha_i^{(t)} + N(0, \sigma^2), 0, 1) \quad (2.20)$$

Burada $\alpha_i^{(t)}$, t . nesildeki. i . bireyin α değerini; $N(0, \sigma^2)$, ortalaması sıfır ve varyansı olan σ^2 normal (gauss) dağılımı; $clip(.)$ ise değer $[0,1]$ aralığında kalmasını sağlar. Popülasyona ait genel eğilim, her nesilde ortalama α değeri hesaplanarak gözlemlenir:

$$\bar{\alpha}^{(t)} = \frac{1}{N} \sum_{i=1}^N \alpha_i^{(t)} \quad (2.21)$$

Düşük bir $\bar{\alpha}$ değeri, algoritmanın keşfe daha fazla ağırlık verdiğini gösterirken, yüksek bir değer sömürüye yönelim anlamına gelir. Bu bilgiye göre seçim mekanizması dinamik olarak ayarlanır: $\bar{\alpha}$ düşükse keşif odaklı, yüksekse sömürü odaklı operatörler tercih edilir. Bu kendini uyarlayan strateji sayesinde hem çözüm adayları hem de kontrol parametreleri birlikte evrimleşerek algoritmanın arama baskısı doğal bir şekilde dengelenir.

2.2.2.6. Q-öğrenme tabanlı hibrit seçimi

Q-Öğrenme (Q-Learning), ortamın dinamiklerini önceden bilmeye gerek duymadan, bir ajanın rastlantısal bir ortamla etkileşime girerek en uygun kararları öğrenmesini sağlayan, modelden bağımsız ve off-policy bir pekiştirmeli öğrenme algoritmasıdır [100]. GA bağlamında, Q-öğrenme algoritması, özellikle keşif ile sömürü arasındaki dengeyi yöneten α parametresinin uyarlanabilir biçimde ayarlanması için ilkesel bir çerçeve sunar.

Durum Temsili: Q-öğrenme ajanı, ortamı iki temel özelliğe göre tanımlar: popülasyon çeşitliliği ve nesil ilerlemesi. Her iki özellik de $[0,1]$ aralığında normalize edilir ve 5 ayrı kategoriye ayrılır. Bu şekilde $5 \times 5 = 25$ durumdan oluşan sonlu bir Markov karar süreci (MDP) elde edilir. Yakınsama tespitine öncelik verilmesi için çeşitlilik ters çevrilerek hesaplanır ve burada, her çeşitlilik, jenerasyon oranı çifti, özgün bir durumu temsil eder.

$$H(x_i, x_j) = 1 - (\sum_{i=1}^{K-1} \sum_{j=i+1}^K f(x_i, x_j)) \times 4 \quad (2.22)$$

$$Jenerasyon\ orani = \left(\frac{iterasyon}{iterasyon_{max}} \right) \times 4 \quad (2.23)$$

Eylem Uzayı: Ajan, önceden tanımlanmış olan aşağıdaki α değerleri arasından seçim yapar:

$$A = \{0.1, 0.3, 0.5, 0.7, 0.9\} \quad (2.24)$$

Eylem Seçimi: Yeterli keşif sağlamak için ϵ açgözlü (epsilon-greedy) bir politika uygulanır:

$$\alpha = f(x) = \begin{cases} \text{rastgele eylem, olasılık } \epsilon \\ \arg \max_{\alpha'} Q(s, \alpha'), \text{ olasılık } 1 - \epsilon \end{cases} \quad (2.25)$$

Ödül Sinyali: Ödül, ardışık nesiller arasında en iyi bireyin uygunluk değerindeki iyileşmeye göre verilir ve aşırı değerlerden kaçınmak için sınırlanır:

$$r_t = \text{clip}(f_{t-1} - f_t, -10, 1000) \quad (2.26)$$

Q-değeri güncelleme kuralı: Q-tablosu klasik zaman farkı yöntemi ile güncellenir:

$$Q(s, \alpha) \leftarrow Q(s, \alpha) + \alpha_{\text{learn}}[r + \gamma \max_{\alpha'} Q(s', \alpha') - Q(s, \alpha)] \quad (2.27)$$

Burada α_{learn} öğrenme oranı, γ ise gelecekteki ödüllere verilen önemi gösteren indirim katsayısıdır. Ayrıca s ve α mevcut durum ve eylemi, s' bir sonraki durumu ve r elde edilen ödülü temsil eder.

GA ile Entegrasyon: Her nesilde, Q-öğrenme ajanı mevcut durumu gözlemler ve buna uygun bir α değeri seçer. Bu değer, GA'nın seçim stratejisini yönlendirmede kullanılır. Zamanla Q-değerleri, durumlara bağlı olarak en uygun α kontrol politikasına doğru yakınsar. Böylece GA, evrimsel süreç boyunca popülasyonun özelliklerine göre keşif ve sömürü dengesini dinamik olarak ayarlayabilir.

2.2.2.7. Çok kollu haydut hibrit seçimi

Multi-Armed Bandit (Çok Kollu Haydut), karar verme teorisi ve makine öğrenmesinde kullanılan klasik bir problem modelidir. İsmi, birden fazla kolu (kol makinesi ya da slot makinesi gibi) olan bir oyun makinesinden alır. Evrimsel algoritmalarda, keşif ile sömürü arasındaki dengeyi etkin bir şekilde yönetmek, arama verimliliği ve çözüm kalitesi için kritik öneme sahiptir. Bu dengeyi kontrol etmek için kullanılan adaptif yöntemlerden biri, hiperparametrelerin özellikle α parametresinin belirsizlik altında karar verme problemi olarak ele alınmasıdır. Bu bağlamda, çok kollu haydut çerçevesi, çevrimiçi ödül maksimize ederek optimal parametre değerlerini öğrenmek için prensipli bir yaklaşım sunar.

Haydut Modeli: Aksiyon kümesi aşağıdaki gibi tanımlanır:

$$A = \{0.1, 0.3, 0.5, 0.7, 0.9\} \quad (2.28)$$

Her $a_i \in A$ bir α değeri adaydır. Her nesil t 'de algoritma, GA'nın mevcut iterasyonunda uygulanacak α değerini bu kümeden seçer ve popülasyonun en iyi bireyinin uygunluk değerindeki kümülatif artışı maksimize etmeyi hedefler [101].

Seçim için Üst Güven Sınırı (ÜGS): Haydut problemlerindeki keşif-sömürü ikilemini çözmek için ÜGS1 stratejisi kullanılır [102]. Her kol i , kümülatif ödül R_i ve seçim sayısı N_i 'yi tutar. Nesil t 'de kolun ÜGS değeri:

$$\text{ÜGS}_i(t) = \frac{R_i}{N_i} + \sqrt{2 \frac{\log \sum_j N_j}{N_i}} \quad (2.29)$$

Buradaki birinci terim yüksek ortalama ödüllü kolları (sömürü) tercih ederken, ikinci terim az seçilen kolların (keşif) seçilmesini teşvik ederek dinamik bir denge sağlar.

Ödül Sinyali: Bir α seçiminin ödülü, ardışık nesiller arasındaki en iyi bireyin fitness artışından hesaplanır:

$$r_t = \text{clip}(f_{t-1} - f_t, -10, 1000) \quad (2.30)$$

Burada f_t , t neslinde gözlenen en iyi uygunluk değeridir. Ödül, aşırı negatif değerleri engellemek ve öğrenmeyi stabilize etmek için sınırlandırılır.

Değişken Ortam ve Sıfırlama Politikası: Uygunluk değeri ortamının zamanla değişmesi ve erken duraklamayı önlemek için, ödül istatistikleri (R_i, N_i) her k nesilde veya son nesilde sıfırlanır:

$$\text{Eğer } t \bmod k = 0 \text{ ise } R_i \leftarrow 0, N_i \leftarrow 1 \quad \forall_i \quad (2.31)$$

GA Entegrasyonu: Seçilen α , GA'da seçim baskısını ayarlar. Düşük α değerleri çeşitliliği ve keşfi teşvik ederken, yüksek α değerleri yüksek kaliteli bireylerin seçimine öncelik verir. Zamanla ÇKHHS kontrolörü, sürekli uygunluk değeri iyileşmesi sağlayan α değerlerini tercih edecek şekilde uyum sağlar.

2.3. Çaprazlama Operatörleri

Çaprazlama operatörleri, iki ebeveynin genetik bilgilerini birleştirerek çocuk üretme sürecidir. Seçim sürecinden sonra, popülasyon çaprazlama yoluyla daha iyi bireylerle

zenginleştirilir ve farklı çözümler arasında bilgi alışverişi sağlanır. Bu çalışmada kısmi eşleştirmeli çaprazlama (KEÇ), dairesel çaprazlama (DÇ), sıralı çaprazlama (SÇ), sıraya dayalı çaprazlama (SDÇ), pozisyona dayalı çaprazlama (PDÇ), kenar birleştirme çaprazlama (KBC), maksimum korumacı çaprazlama (MKÇ), genişletilmiş kısmi eşleştirmeli çaprazlama (GKEÇ), aç gözlü çaprazlama (AÇ), gelişmiş aç gözlü çaprazlama (GAÇ) ve sıralı yapıcı çaprazlama (SYÇ) yöntemleri incelenmiştir [9, 59, 103].

2.3.1. Kısmi eşleştirmeli çaprazlama

Goldberg ve Lingle tarafından 1985 yılında geliştirilmiştir [104]. Algoritmanın çalışma prensibi Şekil 2.10, 2.11, 2.12 ve 2.13’de verilmiştir.

Ebeveyn 1: (1 2 3 4 5 6 7 8)	Ebeveyn 2: (3 7 5 1 6 8 2 4)
------------------------------	------------------------------

Şekil 2.10. Kısmi eşleşmeli çaprazlama öncesi ebeveyn kromozomlar

İlk olarak dizi boyunca iki kesim noktası seçilir. İlk kesim noktasını 3-4. bit arasına ikinci kesim noktalarını ise 6-7. bit arasına yerleştirilelim.

Ebeveyn 1: (1 2 3 4 5 6 7 8)	Ebeveyn 2: (3 7 5 1 6 8 2 4)
------------------------------	------------------------------

Şekil 2.11. Ebeveyn kromozomların kesim noktalarının belirlenmesi

Kesim noktalarının arasında kalan dizi eşleştirme dizisidir. Yani örnekte 4-1, 5-6, 6-8 ile eşleşir. İlk ebeveynin eşleştirme bölümü ikinci çocuğa, ikinci ebeveynin eşleştirme bölümü ise birinci çocuğa aktarılır.

Çocuk 1: (- - - 1 6 8 - -)	Çocuk 2: (- - - 4 5 6 - -)
----------------------------	----------------------------

Şekil 2.12. Ebeveyn kromozomlarda eşleşen dizilerin çocuk kromozomlara yerleştirilmesi

Daha sonra çocuğa ebeveynlerinin elemanları kopyalanır. Bir şehir çocukta var ise, eşleştirmeye göre yerleştirilir. Örnek olarak birinci çocuğa baktığımızda ve birinci ebeveynde ilk eleman 1’dir. Ama 1 çocukta olduğu için eşleşmesi olan (1-4) 4 yazılır. İkinci eleman 2’dir. Bu çocukta olmadığı için 2 olarak yazılır. Bu şekilde çocuklar oluşturulur [9, 105].

Çocuk 1: (4 2 3|1 6 8|7 5) Çocuk 2: (3 7 8|4 5 6|2 1)

Şekil 2.13. Kısmi eşleşmeli çaprazlama sonrası oluşan çocuk kromozomlar

2.3.2. Dairesel çaprazlama

1987 yılında Oliver ve arkadaşları tarafından önerilmiştir [106]. Alt küme mantığı ile çalışır ve çalışma prensibi sırasıyla Şekil 2.14, 2.15 ve 2.16’da verilmiştir.

Ebeveyn 1: (1 2 3 4 5 6 7 8) Ebeveyn 2: (2 4 6 8 7 5 3 1)

Şekil 2.14. Dairesel çaprazlama öncesi ebeveyn kromozomlar

Ebeveyn 1’de bulunan ilk şehir 1 iken, Ebeveyn 2’de aynı pozisyonda şehir 2 bulunur. Ebeveyn 1’de bulunan şehir 2 iken, Ebeveyn 2’de aynı pozisyonda şehir 4 bulunur. Ebeveyn 1’de bulunan şehir 4 iken, Ebeveyn 2’de aynı pozisyonda şehir 8 bulunur. Ebeveyn 1’de bulunan şehir 8 iken, Ebeveyn 2’de aynı pozisyonda şehir 1 bulunur. Ebeveyn 1’de bulunan şehir 1 iken, Ebeveyn 2’de aynı pozisyonda şehir 2 bulunur.

1	2	4	8	1
2	4	8	1	2

Şekil 2.15. Dairesel çaprazlama alt küme oluşturma işlemi

Alt küme oluşturma işlemi tekrar başa dönene kadar devam eder.

Ebeveyn 1: (1 2 3 4 5 6 7 8)	Çocuk 1: (1 2 6 4 7 5 3 8)
Ebeveyn 2: (2 4 6 8 7 5 3 1)	Çocuk 2: (2 4 3 8 5 6 7 1)

Şekil 2.16. Dairesel çaprazlama sonrası oluşan çocuk kromozomlar

Alt kümede bulunan şehirler çocuklarda sabit olarak bırakılırken, geri kalan şehirler aynı pozisyonlarda kopyalanır [9, 105].

2.3.3. Sıralı çaprazlama

Davis tarafından 1985 yılında önerilmiştir [107]. Şehirlerin konumundan ziyade sırasını dikkate alır ve algoritmanın çalışma prensibi Şekil 2.17, 2.18 ve 2.19’da sırasıyla

verilmiştir. İlk olarak kesim noktaları rasgele seçilir. İlk kesim noktasını 2-3. bit arasına ikinci kesim noktalarını ise 5-6. bit arasına yerleştirelim [9, 105]

Ebeveyn 1: (1 2|3 4 5|6 7 8) Ebeveyn 2: (2 4|6 8 7|5 3 1)


Şekil 2.17. Sıralı çaprazlama öncesi ebeveyn kromozomlar

Kesim noktaları arasında kalan bölge çocuklara kopyalanır.

Çocuk 1: (- -|3 4 5|- -) Çocuk 2: (- -|6 8 7|- -)

Şekil 2.18. Kesim noktaları arasındaki bölgelerin çocuk kromozomlara kopyalanması


Daha sonra ikinci kesim noktasından itibaren, mevcut olan şehirler atlanarak diğer ebeveynde varsa çocuğa kopyalanır ve dizinin sonunda geldiğinde ilk pozisyonundan devam eder.



Şekil 2.19. Sıralı çaprazlama sonrası oluşan çocuk kromozomlar

2.3.4. Sıraya dayalı çaprazlama

1991 yılında Syswerda [108] tarafından önerilen bu yöntemde, ebeveynden rasgele pozisyonlar seçilir ve ardından bu pozisyonlarda bulunan şehirler diğer ebeveynde aranır. Birinci ebeveynde 2, 3 ve 6 pozisyonlar seçilmiş olsun. Burada bulunan şehirler 2, 3 ve 6. şehirler olup ikinci ebeveynde taranır. Bu şehirler ikinci ebeveynde 1, 3 ve 7. pozisyonlardadır. Bu pozisyonlardaki şehirler çocuğa, birinci ebeveyn sırasına göre kopyalanır [9, 105]. Algoritmanın çalışma prensibi Şekil 2.20’de verilmiştir.



Şekil 2.20. Sıraya dayalı çaprazlama sonrası çocuk kromozomlar

İkinci ebeveynden 2, 3 ve 6. pozisyonlardaki şehirlerin seçildiğini varsayarsak, birinci ebeveynde 4, 5 ve 6. pozisyonlardadır. Bu pozisyonlardaki şehirler çocuğa, ikinci ebeveyn sırasına göre kopyalanır [9, 105].


2.3.5. Pozisyona dayalı çaprazlama

1991 yılında Syswerda [108] tarafından önerilen bu yöntemde, rasgele pozisyonlar seçilir. Birinci ebeveynden 2, 3 ve 6. pozisyonların seçildiğini kabul edelim. İkinci ebeveynde bu pozisyonlara karşılık gelen şehirler birinci çocuğa kopyalanır. Algoritmanın çalışma prensibi Şekil 2.21 ve 2.22’de verilmiştir.

Ebeveyn 1: (1 2 3 4 5 6 7 8)	Çocuk 2: (- 4 6 - - 5 - -)
Ebeveyn 2: (2 4 6 8 7 5 3 1)	Çocuk 2: (- 2 3 - - 6 - -)
(2↔4, 3↔6, 6↔5)	

Şekil 2.21. Pozisyona dayalı çaprazlama öncesi ebeveyn kromozomlar

Aynı şekilde birinci ebeveynde bu pozisyonlara karşılık gelen şehirler ikinci çocuğa kopyalanır [9, 105].



Şekil 2.22. Pozisyona dayalı çaprazlama sonrası çocuk kromozomlar

2.3.6. Kenar birleştirme çaprazlama

1989 yılında Whitley [109] ve arkadaşları tarafında önerilen kenar birleştirme çaprazlama yöntemi, her bir şehrin kenar sayısı dikkate alınarak yapılır. Çaprazlama işlemlerinin yapılabilmesi için kenar haritası kullanılmaktadır ve örnek olarak Tablo 2.4’te verilmiştir. Ayrıca, çaprazlama yönteminin çalışma adımları ve çocuk kromozomlar Tablo 2.5’te verilmiştir.

Tablo 2.4. Şehirlerin bağlantılı olduğu kenar haritası

Şehir	Bağlantılı olduğu şehirler
1	2, 6, 3, 5
2	1, 3, 4, 6
3	2, 4, 1
4	3, 5, 2
5	4, 6, 1
6	1, 5, 2

Tablo 2.5. Kenar birleştirme çaprazlama operatörü adımları

Operatör adımları	Çocuk Kromozom
Ebeveyn 1: (1 2 3 4 5 6) Ebeveyn 2: (2 4 3 1 5 6)	Çocuk: (- - - - -)
Adım 1: Ebeveyn 1'den başlangıç şehirlerinden biriyle başlatılır. Başlangıç şehirler 1 ve 2'dir ve Tablo 4'e göre her ikisi de 4 bağlantılı kenara sahiptir. Rasgele olarak 2 seçildiğini varsayalım.	Çocuk: (2 - - - -)
Adım 2: Şehir 2 için bağlantılı kenar listesi bir sonraki adayları ifade eder. Tablo 4'de 1, 3, 4, 6 aday şehirler olup, şehir 3, şehir 4 ve şehir 6 için iki bağlantılı kenarı bulunurken, şehir 1 için üç bağlantılı şehir bulunur. Dolayısıyla şehir 3, 4 ve 6 arasından rasgele şehir 3 seçildiğini varsayalım.	Çocuk: (2 3 - - -)
Adım 3: Şehir 3 için bağlantılı kenar listesi, şehir 1 ve şehir 4 tür. Şehir 4'ün bir tane bağlantılı kenarı bulunurken (5), şehir 1'in iki bağlantılı kenarı bulunur (5, 6). Şehir 4 seçilir.	Çocuk: (2 3 4 - -)
Adım 4: Şehir 4 için bağlantılı kenar listesinde sadece bir tane kenar bulunur (5). Şehir 5 seçilir	Çocuk: (2 3 4 5 -)
Adım 5: Şehir 5 için bağlantılı kenar listesinde şehir 1 ve şehir 6 bulunur. Şehir 1'de (6) ve şehir 6'da (1) birer bağlantılı şehir bulunduğundan, rasgele olarak şehir 1 seçilir.	Çocuk: (2 3 4 5 1 -)
Adım 6: Şehir 1 için bağlantılı kenar listesinde sadece şehir 6 kalmıştır. Son olarak 6 seçilir.	Çocuk: (2 3 4 5 1 6)


2.3.7. Maksimum korumacı çaprazlama

1988 yılında Mühlenbein ve ark. [110] tarafından ortaya atılan bu yöntem, kısmi eşleşmeli çaprazlama operatörü gibi çalışır. İlk ebeveynden rasgele alt dizi seçilir. Bu dizi uzunluğu maksimum 10 olacak şekilde ve daha büyük uzunlukta olanlar için 2 ile bölümüne eşit ya da daha küçük olarak seçilir. Bu kısıtlamanın nedeni, ebeveynlerin herhangi birinden çocuklara aktarılabilecek bilginin, kaybolmasını engellemektir [9, 105]. Algoritmanın çalışma prensibi Şekil 2.23 ve 2.24'te verilmiştir.

Ebeveyn 1: (1 2 3 4 5 6 7 8) Ebeveyn 2: (2 4 6 8 7 5 3 1)

Şekil 2.23. Maksimum korumacı çaprazlama öncesi ebeveyn kromozomlar

Birinci ebeveynden (3, 4, 5) alt dizisi seçildiğini varsayarsak, bu şehirler ikinci ebeveynden çıkartılır. (3, 4, 5) alt dizisi çocukta başa yazılarak, kalanlar ikinci ebeveyndeki sıra ile kopyalanır. İkinci ebeveynden (8, 7, 5) alt dizisi seçildiğini varsayarsak, bu şehirler birinci ebeveynden çıkartılır. (8, 7, 5) alt dizisi çocukta başa yazılarak, kalanlar birinci ebeveyndeki sıra ile kopyalanır.




Şekil 2.24. Maksimum korumacı çaprazlama sonrası çocuk kromozomlar

2.3.8. Genişletilmiş kısmi eşleşmeli çaprazlama


Kısmi eşleşmeli çaprazlama (KEÇ), ebeveynlerin eşlenmiş şehirlere denk gelmesi durumlarında, aynı şehirleri algılayamaz ve çift şehir çaprazlama ile sonuçlanır. Gezgini satıcı problemlerini çözmek için uygun değildir ve tekrarlayan çocuklar üretilebilir. Bu sorunun üstesinden gelmek için GKEÇ, 2008 yılında Tao tarafından önerilmiştir [111]. Operatörün çalışma prensibi Şekil 2.25, 2.26 ve 2.27 ve 2.28’de verilmiştir.

Adım 1: Her iki ebeveynden keyfi bir nokta seçilir. 4. nokta olduğunu varsayalım. İlk kısım eşleşme bölgesi, ikinci kısım ise çaprazlama bölgesi olarak adlandırılır. Eşleşme bölgeleri a ve b alt listeler olarak atanırsa;



Şekil 2.25. Genişletilmiş kısmi eşleşmeli çaprazlama öncesi ebeveyn kromozomlar

Adım 2: Alt liste a’daki şehir 2 ve 3, alt liste b’de tekrarlamayan şehirlerdir. Aynı şekilde, alt liste b’de şehir 8 ve 6, alt liste a’da tekrarlamayan şehirlerdir. Dolayısıyla;



Şekil 2.26. Genişletilmiş kısmi eşleşmeli çaprazlama için tekrarlamayan şehirler

Adım 3: Çaprazlama bölgenin şehirleri, adım 2’de bulunan eşleşmeye göre değiştirilir.

Ebeveyn 1: (1 2 3 4 5 3 7 2)	Ebeveyn 2: (1 4 8 6 8 6 5 7)
------------------------------	------------------------------

Şekil 2.27. Genişletilmiş kısmi eşleşmeli çaprazlama için şehirlerin transferi

Adım 4: Çapraz bölgeler değiştirilir.

Çocuk 1: (1 2 3 4 8 6 5 7)	Çocuk 2: (1 4 8 6 5 3 7 2)
----------------------------	----------------------------

Şekil 2.28. Genişletilmiş kısmi eşleşmeli çaprazlama sonrası çocuk kromozomlar

2.3.9. Açgözlü çaprazlama

1985 yılında Grefenstette [112] tarafından önerilen açgözlü çaprazlama, şehirlerarası uzaklık matrisi göz önünde alınarak çalışır. Ebeveyniden ilk şehir seçilir ve bu seçilen şehrin, yanındaki şehirlere olan uzaklıkları karşılaştırılır. Hangi şehir daha yakınsa o şehir seçilir. Eğer, bir şehir çocukta varsa, diğer şehir seçilir. Her iki şehirde çocukta bulunuyorsa, seçilmemiş bir şehir rasgele çocuğa kopyalanır [9]. Şehirlerarası uzaklık matrisi Tablo 2.6’da gösterilmiştir. Ayrıca operatörün çalışma adımları Tablo 2.7’de verilmiştir.

Tablo 2.6. Şehirlerarası uzaklık matrisi

	1	2	3	4	5	6	7	8
1	0	50	40	70	80	20	10	70
2	50	0	30	20	60	50	20	40
3	40	30	0	40	30	60	30	10
4	70	20	40	0	60	30	10	50
5	80	60	30	60	0	20	60	20
6	20	50	60	30	20	0	40	40
7	10	20	30	10	60	40	0	30
8	70	40	10	50	20	40	30	0

Tablo 2.7. Açgözlü çaprazlama operatörü çalışma adımları

Operatör adımları	Çocuk Kromozom
Ebeveyn 1: (4 7 3 2 8 6 1 5) Ebeveyn 2: (6 2 5 8 4 3 7 1)	Çocuk: (-----)

Tablo 2.7. Devam ediyor


Adım 1: Ebeveyn 1'den seçilen ilk şehir 4 olsun. Şehir 4 çocuğa kopyalanır.	Çocuk: (4 --- ---)
Adım 2: Ebeveyn 1'de şehir 4 için komşu şehir 7 ve ebeveyn 2'de şehir 4 için komşu şehir 3 tür. Şehir 4-7 arasındaki uzaklık 10 iken, şehir 4-3 arasındaki uzaklık 40'dır. Şehir 7 daha yakın olduğu için çocuğa kopyalanır.	Çocuk: (4 7 -- ---)
Adım 3: Ebeveyn 1'de şehir 7 için komşu şehir 3 ve ebeveyn 2'de şehir 7 için komşu şehir 1'dir. Şehir 7-3 arasındaki uzaklık 30 iken, şehir 7-1 arasındaki uzaklık 10 dur. Şehir 1 daha yakın olduğu için çocuğa kopyalanır.	Çocuk: (4 7 1 - ---)
Adım 4: Ebeveyn 1'de şehir 1 için komşu şehir 5 ve ebeveyn 2'de şehir 1 için komşu şehir 6'dır. Şehir 1-5 arasındaki uzaklık 80 iken, şehir 1-6 arasındaki uzaklık 20'dir. Şehir 6 daha yakın olduğu için çocuğa kopyalanır	Çocuk: (4 7 1 6 ----)
Adım 5: Ebeveyn 1'de şehir 6 için komşu şehir 1 ve ebeveyn 2'de şehir 6 için komşu şehir 5'dir. Şehir 1 çocukta bulunduğundan, şehir 2 çocuğa kopyalanır.	Çocuk: (4 7 1 6 2 ---)
Adım 6: Ebeveyn 1'de şehir 2 için komşu şehir 8 ve ebeveyn 2'de şehir 2 için komşu şehir 5'dir. Şehir 2-8 arasındaki uzaklık 40 iken, şehir 2-5 arasındaki uzaklık 60'dır. Şehir 8 daha yakın olduğu için çocuğa kopyalanır.	Çocuk: (4 7 1 6 2 8 --)
Adım 7: Ebeveyn 1'de şehir 8 için komşu şehir 6 ve ebeveyn 2'de şehir 8 için komşu şehir 4'tür. Her iki aday şehirde çocukta bulunduğundan, daha önce seçilmemiş olan şehirlerden en son eklenen şehre (8) en yakın olan şehir, çocuk kromozoma eklenir buda şehir 3 olur.	Çocuk: (4 7 1 6 2 8 3 -)
Adım 8: Ebeveyn 1'de şehir 3 için komşu şehir 2 ve ebeveyn 2'de şehir 3 için komşu şehir 7'dir. Her iki aday şehirde çocukta bulunduğundan, daha önce seçilmemiş olan şehirlerden en son eklenen şehre (3) en yakın olan şehir, çocuk kromozoma eklenir buda şehir 5 olur.	Çocuk: (4 7 1 6 2 8 3 5)

2.3.10. Gelişmiş açgözlü çaprazlama

Açgözlü çaprazlamanın yavaş olması nedeniyle ve doğruluk oranını artırmak için GAÇ operatörü, 2012 yılında, Ismkhan ve ark. [68] tarafından ortaya atılmıştır. Açgözlü çaprazlama ile benzerdir fakat her adımda çocuklara kopyalanan şehirler ebeveynlerden atılır. Ebeveynler üzerinde çift bağlantılı liste kullanılarak (double-linked list), bir şehir çocuğa kopyalandığı sırada, her iki bağlantılı ebeveyn listesindeki aday listesinden çıkartılır. Operatörün çalışma prensibi Şekil 2.29 ve Tablo 2.8'de verilmiştir.

Tablo 2.8. Gelişmiş açgözlü çaprazlama çalışma adımları

Operatör adımları	Çocuk Kromozom
Ebeveyn 1: (1 2 3 7 5 4 8 6) Ebeveyn 2: (2 6 3 7 1 5 8 4)	Çocuk: (-----)
Adım 1: Keyfi olarak birinci ebeveyn 1'den şehir 4 seçilerek çocuğa kopyalanır.	Çocuk: (4-----)
Adım 2: Ebeveyn 1'de şehir 4 için komşu şehir 5 ve 8'dir. Ebeveyn 2'de şehir 4 için komşu şehir 8 ve 2'dir. Tablo 5'e göre şehir 4 ve şehir 2 arası 20 olup en kısa mesafededir. Dolayısı ile şehir 2 seçilir.	Çocuk: (4 2-----)
Adım 3: Ebeveyn 1'de şehir 2 için komşu şehir 3 ve 1'dir. Ebeveyn 2'de şehir 2 için komşu şehir 8 ve 6'dır. Tablo 5'e göre şehir 2 ve şehir 3 arası 30 olup en kısa mesafededir. Dolayısı ile şehir 3 seçilir.	Çocuk: (4 2 3-----)
Adım 4: Ebeveyn 1'de şehir 3 için komşu şehir 7 ve 1'dir. Ebeveyn 2'de şehir 3 için komşu şehir 7 ve 6'dır. Tablo 5'e göre şehir 3 ve şehir 7 arası 30 olup en kısa mesafededir. Dolayısı ile şehir 7 seçilir.	Çocuk: (4 2 3 7-----)
Adım 5: Ebeveyn 1'de şehir 7 için komşu şehir 5 ve 1'dir. Ebeveyn 2'de şehir 7 için komşu şehir 1 ve 6'dır. Tablo 5'e göre şehir 7 ve şehir 1 arası 10 olup en kısa mesafededir. Dolayısı ile şehir 1 seçilir.	Çocuk: (4 2 3 7 1-----)
Adım 6: Ebeveyn 1'de şehir 1 için komşu şehir 5 ve 6'dır. Ebeveyn 2'de şehir 1 için komşu şehir 5 ve 6'dır. Tablo 5'e göre şehir 1 ve şehir 6 arası 20 olup en kısa mesafededir. Dolayısı ile şehir 6 seçilir.	Çocuk: (4 2 3 7 1 6-----)
Adım 7: Ebeveyn 1'de şehir 6 için komşu şehir 5 ve 8'dir. Ebeveyn 2'de şehir 6 için komşu şehir 5 ve 8'dir. Tablo 5'e göre şehir 6 ve şehir 5 arası 20 olup en kısa mesafededir. Dolayısı ile şehir 5 seçilir.	Çocuk: (4 2 3 7 1 6 5-----)
Adım 8: Ebeveyn 1 ve 2'de şehir 5 için tek komşu şehir 8'dir. Dolayısı ile şehir 8 seçilir.	Çocuk: (4 2 3 7 1 6 5 8)



Şekil 2.29. Gelişmiş açgözlü çaprazlama sonrası çocuk kromozomlar

2.3.11. Sıralı yapıcı çaprazlama

Ahmad tarafından 2010 yılında [58, 113] önerilen Sıralı Yapıcı Çaprazlama, ebeveynlerden minimum maliyeti olan düğümleri seçerek yavru kromozomların üretilmesine dayanır.

Tablo 2.9. Şehirlerarası maliyet matrisi

	1	2	3	4	5	6	7
1	999	75	99	9	35	63	8
2	51	999	86	46	88	29	20
3	100	5	999	16	28	35	28
4	20	45	11	999	59	53	49
5	86	63	33	65	999	76	72
6	36	53	89	31	21	999	52
7	58	31	43	67	52	60	999

Bu yaklaşım, ebeveyn kromozomların sıralı yapısını korumayı amaçlar. Şehirlerarası maliyet matrisi Tablo 2.9’de gösterilmektedir. Yöntemin çalışma prensibi Tablo 2.10’da verilmiştir.

Tablo 2.10. Sıralı yapıcı çaprazlama operatörü çalışma adımları

Operatör adımları	Çocuk Kromozom
Ebeveyn 1: (1 5 7 3 6 4 2) Ebeveyn 2: (1 6 2 4 3 5 7)	Çocuk: (-----)
Adım 1: İlk ebeveyninden ilk şehir seçilir ve çocuğa kopyalanır.	Çocuk: (1-----)
Adım 2: Şehir 1 için, aday şehirler ebeveyn 1’de 5 ve ebeveyn 2’de 6’dır (C15=35 ve C16=63). Maliyetin C16>C15 olması nedeniyle, şehir 5 seçilir.	Çocuk: (1 5-----)
Adım 3: Şehir 5’ten sonraki aday şehir, hem ebeveyn 1 hem de 2. şehir 7’dir. Şehir 7, çocuğa kopyalanır.	Çocuk: (1 5 7-----)

Tablo 2.10. Devam ediyor

Adım 4: Şehir 7'den sonra aday şehirler, ebeveyn 1'de şehir 3'tür, ancak ebeveyn 2'de mevcut değildir. Ebeveyn 2 için komşu şehir 2 olarak kabul edilir: (2, 3, 4, 5, 6, 7). Maliyet $C73=43 > C72=31$ olduğundan şehir 2 çocuğa kopyalanır.	Çocuk: (1 5 7 2 – – –)
Adım 5: Şehir 2'den sonra aday şehirler, ebeveyn 1'de mevcut değil, ebeveyn 2'de şehir 4'tür. Ebeveyn 1 için komşu şehir 3 olarak kabul edilir: (2, 3, 4, 5, 6, 7). Maliyet $C23=86 > C24=46$ olduğundan şehir 4 çocuğa kopyalanır.	Çocuk: (1 5 7 2 4 – –)
Adım 6: Şehir 4'den sonra aday şehirler, ebeveyn 1'de değil, ebeveyn 2'de şehir 3'tür. Ebeveyn 1 için komşu şehir 5 olarak kabul edilir: (2, 3, 4, 5, 6, 7). Maliyet $C45=59 > C43=11$ olduğu için şehir 3 çocuğa kopyalanır.	Çocuk: (1 5 7 2 4 3 –)
Adım 7: Şehir 3'ten sonra komşu şehir, ebeveyn 1'deki şehir 6'dır, ancak ebeveyn 2'de mevcut değildir. Ebeveyn 2 için, komşu şehir 4 olarak kabul edilir: (2, 3, 4, 5, 6, 7). Maliyet $C23=86 > C24=46$ olmasına rağmen çocukta şehir 4 mevcut olduğundan şehir 6 çocuğa kopyalanır.	Çocuk: (1 5 7 2 4 3 6)

2.4. Mutasyon Operatörleri

Çaprazlama işlemlerinden sonra bireyler mutasyona uğrar. Mutasyon operatörü popülasyondaki genetik çeşitliliği korumak için uygulanır. Mutasyon süreci çaprazlamadan doğan çocukların belirli bir yüzdesine uygulanır. Buna mutasyon oranı denir. Mutasyonun uygulanma olasılığı genellikle çok düşük olarak belirlenir. Literatürde bulunan altı farklı mutasyon operatörü, yer değiştirme mutasyon (YDM) [105], değişim mutasyon (DM) [105], ekleme mutasyon (EM) [105], ters çevirme mutasyon (TÇM) [105], basit ters çevirme mutasyon (BTÇM) [105] ve karıştırma mutasyon (KM) [105] operatörleri araştırılmıştır.

2.4.1. Yer değiştirme mutasyon operatörü

Michalewicz tarafından 1992 yılında önerilen yer değiştirme mutasyonu, genden rasgele bir alt tur seçilir ve gen içinden çıkarılır. Çıkarılan alt tur gende rasgele bir konuma yerleştirilir. Operatörün çalışma prensibi Şekil 2.30, 2.31 ve 2.32'de verilmiştir.

(1 2 3 4 5 6 7 8)


Şekil 2.30. Yer değiştirme mutasyonu öncesi gen dizilimi

Gen içerisinde rasgele (3 4 5) alt turunun seçildiğini varsayalım. Alt tur çıkarıldıktan sonra gen dizilimi aşağıdaki gibi olur.

(1 2 6 7 8)

Şekil 2.31. Yer değiştirme mutasyonu alt tur çıkarıldıktan sonraki gen dizilimi

Çıkarılan alt turun, şehir 7'den sonra yerleştirildiği varsayılırsa, yeni gen dizilimi oluşturulur. Ayrıca kesme mutasyonu olarak adlandırılır [105].



Şekil 2.32. Yer değiştirme mutasyonu operatörü sonrası gen dizilimi


2.4.2. Değişim mutasyonu operatörü

Takas mutasyonu olarak adlandırılan değişim mutasyonu 1990 yılında Banzhaf tarafından ortaya atılmış olup gen içinden rasgele seçilen iki şehrin takas edilmesi işlemidir. Operatörün çalışma prensibi Şekil 2.33 ve 2.34'te gösterilmiştir.

(1 2 3 4 5 6 7 8)

Şekil 2.33. Değişim mutasyon operatörü öncesi gen dizilimi


Örneğin rasgele seçilen şehir 3 ile şehir 5 in yer değiştirdiğini varsayarsak gen dizilim, aşağıdaki gibi olur [105].



Şekil 2.34. Değişim mutasyon operatörü sonrası gen dizilimi


2.4.3. Ekleme mutasyon operatörü

1988 yılında Fogel tarafından önerilen, yerleştirme mutasyon operatörü genden rastgele bir şehir seçilir ve genden çıkarılır ve rastgele seçilen bir yere eklenir. Ekleme mutasyon operatörünün çalışma prensibi Şekil 2.35 ve 2.36’da gösterilmiştir.



Şekil 2.35. Ekleme mutasyon operatörü öncesi gen dizilimi

Örneğin şehir 4’ün seçildiğini ve genden kaldırılıp, 7. şehirden sonra rastgele eklediğini varsayalım.




Şekil 2.36. Ekleme mutasyon operatörü sonrası gen dizilimi

Ekleme mutasyon operatörü aynı zamanda konum tabanlı mutasyon operatörü olarak da bilinir [105].


2.4.4. Basit ters çevirme mutasyon operatörü

Holland tarafından 1975 yılında önerilmiş basit ters çevirme mutasyon operatöründe, gen içinden rastgele iki kesme noktası seçilir ve bu iki kesme noktası arasındaki alt diziyi tersine çevrilir. Basit ters çevirme operatörünün çalışma prensibi Şekil 2.37 ve 2.38’te verilmiştir.



Şekil 2.37. Basit ters çevirme mutasyon operatörü öncesi gen dizilimi


Örneğin, genden ilk kesim noktası 2. ve 3. şehir, ikinci kesim noktası olarak 5. ve 6. şehir seçildiği varsayılırsa, gen dizilimi aşağıdaki gibi olur [105].



Şekil 2.38. Basit ters çevirme mutasyon operatörü sonrası gen dizilimi


2.4.5. Ters çevirme mutasyon operatörü

Ters çevirme mutasyon operatörü, yer değiştirme mutasyon operatörüne benzemekle beraber Fogel tarafından 1990 yılında önerilmiştir. Gen içinden rastgele bir alt tur seçilir, alt tur, genden çıkarılır ve rastgele seçilen bir konuma ters çevrilerek eklenir. Algoritmanın çalışma prensibi Şekil 2.39 ve 2.40’de verilmiştir.



Şekil 2.39. Ters çevirme mutasyon operatörü öncesi gen dizilimi


Gen içerisinden rasgele (3 4 5) alt turunun seçildiğini varsayalım. Alt tur çıkarıldıktan sonra, ters çevrilerek şehir 7’den sonraya eklenirse gen dizilimi aşağıdaki gibi olur [105].



Şekil 2.40. Ters çevirme mutasyon operatörü sonrası gen dizilimi


2.4.6. Karıştırma mutasyon operatörü

1991 yılında, Syswerda karıştırma mutasyon operatörünü önermiştir ve gen içinden rastgele bir alt tur seçip, içindeki şehirleri karıştırılır. Algoritmanın çalışma prensibi Şekil 2.41 ve 2.42’de verilmiştir.



Şekil 2.41. Karıştırma mutasyon operatörü öncesi gen dizilimi

Gen içerisinden rasgele (4 5 6 7) alt turunun seçildiğini varsayalım. Alt tur karıştırılıp tekrar aynı pozisyonlara yerleştirilir [105].



Şekil 2.42. Karıştırma mutasyon operatörü sonrası gen dizilimi

2.5. Değerlendirme Kriterleri

2.5.1. Yüzdesel hata

Denklem 2.32’de verilen yüzdelik hata, bulunan çözüm ile optimum çözüm arasındaki bağıl farkın ölçülmesiyle belirlenebilir. Burada bulunan çözüm değeri, çözülen problem için GA veya herhangi bir diğer optimizasyon yöntemi ile elde edilen değerdir ve optimum çözüm değeri, analitik veya kapsamlı yöntemlerle elde edilen problem için en iyi bilinen veya olası değer anlamına gelir [66].

$$\text{hata} = \frac{\text{Bulunan Çözüm} - \text{Optimum Çözüm}}{\text{Optimum Çözüm}} * 100 \quad (2.32)$$

2.5.2. İki kuyruklu t-testi

t-testi, iki grubun ortalamalarını karşılaştırmak ve aralarındaki farkın anlamlılığını test etmek için kullanılan istatistiksel bir yöntemdir [114]. GA'nın olasılıklı arama algoritmaları sınıfına ait olması göz önüne alındığında, t-testi istatistiksel bir hipotez testi olarak kullanılır. t-testi sonuçları, $\bar{x}_1$ ve s_1 'in referans operatörün ortalamasını ve standart sapmasını (SD), $\bar{x}_2$ ve s_2 'nin diğer rekabet eden operatörlerin ortalamasını ve SD'sini ifade eden Denklem 2.33 kullanılarak belirlenir.

$$t = \frac{\bar{x}_1 - \bar{x}_2}{s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \quad (2.33)$$

Burada, $s_p = \sqrt{\frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1+n_2-2}}$ olarak ifade edilir. Bu araştırma boyunca istatistiksel

olarak anlamlı tüm farklar, $p = 0,05$ (95% güven) anlamlılık düzeyinde 58 serbestlik derecesine sahip iki örneklemlili (bağımsız örnekler) t-testi kullanılarak gösterilmiştir. p değeri 0.05'ten küçükse, iki yöntem arasında istatistiksel olarak anlamlı bir fark olduğu sonucuna varılabilir. t-testi puanı, referans operatörün anlamlı bir iyileşme ($t \leq -2.00$) veya anlamlı bir azalma ($t \geq -2.00$) gösterip göstermediğini ifade eder.

2.5.3. Kritik fark diyagramı

Geleneksel istatistiksel yöntemlerin bazı kısıtlamaları mevcuttur. Örneğin, t-testi yalnızca iki yöntem karşılaştırmaya uygundur ve çoklu karşılaştırmalarda Tip I hata oranını artırır, tek yönlü ANOVA birden fazla yöntemi test etse de hangi çiftlerin farklı olduğunu doğrudan göstermez, post-hoc testler ise bu farkları belirlese bile sonuçları genellikle tablo halinde sunduğundan görsel yorumlama zordur. Kritik fark diyagramı, çoklu algoritma karşılaştırmaları için hem istatistiksel güvenilirliği (Friedman + post-hoc testler) hem de görsel açıklığı bir arada sunduğu için geleneksel istatistiksel yöntemlere göre tercih edilir. Operatörlerin doğruluk oranları, farklı veri setleri arasında istatistiksel olarak karşılaştırılabilirlikleri amacıyla, minimum-maksimum normalizasyon yöntemiyle 0-1 aralığına dönüştürülmüştür ve Denklem 2.34'te verilmiştir [115].

$$x_{ölçek} = 1 - \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.34)$$

Burada; x bulunan çözümü, x_{min} optimum çözümü, x_{max} ilk jenerasyonda elde edilen maksimum çözümü, $x_{ölçek}$ ölçeklendirilmiş doğruluk oranını temsil eder. Kritik fark (KFD) diyagramları, Friedman testinin sonuçlarının çoklu karşılaştırma analizlerinde görsel bir temsildir. Friedman testi, bağımlı gruplar arasındaki farkları değerlendirmek için kullanılan parametrik olmayan bir istatistiksel testtir [114, 116]. Üç veya daha fazla ilişkili grubu karşılaştıran verileri analiz etmek için yaygın bir istatistiksel araçtır. Terim r_i^j , N veri kümesinin i'ncisindeki k algoritmanın j'ncisinin sınıflandırmasını temsil ettiğini varsayalım. Friedman testi, algoritmaların ortalama sıralamalarının, $R_j = \frac{1}{N} \sum_i r_i^j$ olarak ifade edilen bir karşılaştırmasını içerir. Gruplar arasında anlamlı bir fark olmadığı şeklindeki sıfır hipotezini reddetmek için, Friedman istatistiği, Denklem 2.35'te verilen $k - 1$ serbestlik derecesine göre dağıtılır.

$$X_F^2 = \frac{12N}{K(K+1)} \left[\sum_j R_j^2 - \frac{k(k+1)^2}{4} \right] \quad (2.35)$$

Her grubun sıralama puanları hesaplanır ve elde edilen veriler incelenerek gruplar arasında istatistiksel olarak anlamlı bir fark olup olmadığı belirlenir. Friedman testinin uygulanmasıyla anlamlı bir fark belirlenirse, genellikle bu gözlemlenen farktan hangi grupların sorumlu olduğunu belirlemek için post-hoc testler kullanılır.

Friedman testinin sonucunun istatistiksel olarak anlamlı olduğu kabul edilirse, sonraki adım, hangi grupların farklı davranış sergilediğini belirlemek için Wilcoxon işaretli sıra testini gerçekleştirmektir. Wilcoxon testinden elde edilen p değerleri Holm düzeltmesine tabi tutulur. Bu, çoklu karşılaştırmalardan kaynaklanan yanlış pozitif sonuçların olasılığını en aza indirmek için kullanılır. Holm düzeltmesi şu şekilde uygulanır: en küçük p değeriyle yapılan karşılaştırma önce düzeltilir ve bu işlem p değerlerinin sırasına göre devam eder. Düzeltilen p değerleri kritik değerden düşükse, ilgili gruplar arasında anlamlı bir fark olduğu sonucuna varılır ve kritik fark Denklem 2.36'de verilmiştir.

$$KFD = q_{\alpha} \sqrt{\frac{k(k+1)}{6N}} \quad (2.36)$$

Bu bağlamda, kritik değerler q_{α} , Studentized aralık istatistiğinin $\sqrt{2}$ 'ye bölünmesiyle elde edilir.

2.5.4. Çeşitlilik analizi

Popülasyon çeşitliliğini ölçmek için en yaygın kullanılan yöntemlerden biri, aşağıdaki şekilde tanımlanan çiftler arası hamming mesafesidir ve Denklem 2.37'de verilmiştir:

$$H(x_i, x_j) = \sum_{i=1}^{K-1} \sum_{j=i+1}^K f(x_i, x_j) \quad (2.37)$$

Burada K popülasyon büyüklüğüdür, x_i ve x_j popülasyondaki i 'inci ve j 'inci bireylerin dizilerini temsil eder [117]. Her nesil için popülasyon çeşitliliği hesaplandıktan sonra, her nesil için bir algoritmadaki keşif ve sömürü yüzdesi Denklem 2.38 ve 2.39'dan belirlenebilir.

$$Xpl\% = \frac{Div}{Div_{max}} * 100 \quad (2.38)$$

$$Xpt\% = \frac{|Div - Div_{max}|}{Div_{max}} * 100 \quad (2.39)$$

Bu bağlamda, Div belirli bir nesildeki popülasyonun çeşitliliğini ifade eder. Öte yandan Div_{max} , tüm nesillerde gözlemlenen maksimum çeşitliliği temsil eder. $Xpl\%$ ve $Xpt\%$ terimleri, belirli bir nesil için sırasıyla keşif ve sömürü yüzdeleri belirtmek için kullanılır [118].

2.6. Deney Ayarları

2.6.1. TSPLIB veri seti

Genetik operatörlerinin verimliliğini karşılaştırmak için, 11 simetrik ve 19 asimetrik olmak üzere toplam 30 seyyar satıcı problem örnekleri üzerinde test edilmiştir. Simetrik bir veri seti, Şehir A'dan Şehir B'ye eşit mesafeler gösterirken, asimetrik bir veri seti bu şehirler arasında farklı mesafeler gösterebilir. Bu tutarsızlık göz önüne alındığında, asimetrik GSP'ler, çözüm alanı yalnızca şehirler arasındaki mesafeleri değil, aynı zamanda grafik kenarlarının yönünü de kapsadığından, simetrik muadillerinden doğası gereği daha zordur. Ayrıca, veri setlerini problem ölçeği açısından değerlendirmek için 17'si küçük ölçekli, 6'sı orta ölçekli ve 7'si büyük ölçekli olarak sınıflandırılmıştır. Veri setlerinin özellikleri Tablo 2.11'de verilmiştir [119].

Tablo 2.11. TSPLIB veri setleri

İsim	Şehir sayısı	Tipi	Veri Seti Büyüklüğü	Optimum tur uzunluğu	Veri Seti Türü
gr21	21	Matris	Küçük	2707	Simetrik
fri26	26	Matris	Küçük	937	Simetrik
bayg29	29	Coğrafi Uzaklık	Küçük	1610	Simetrik
dantzig42	42	Matris	Küçük	699	Simetrik
eil51	51	Öklid Uzaklık	Küçük	426	Simetrik
berlin52	52	Öklid Uzaklık	Küçük	7542	Simetrik
pr76	76	Öklid Uzaklık	Orta	108159	Simetrik
lin105	105	Öklid Uzaklık	Orta	14379	Simetrik
pr226	226	Öklid Uzaklık	Büyük	80369	Simetrik
a280	280	Öklid Uzaklık	Büyük	2579	Simetrik
att532	532	Özel Uzaklık	Büyük	27686	Simetrik
br17	17	Matris	Küçük	39	Asimetrik
ftv33	34	Matris	Küçük	1286	Asimetrik
ftv35	36	Matris	Küçük	1473	Asimetrik
ftv38	39	Matris	Küçük	1530	Asimetrik
p43	43	Matris	Küçük	5620	Asimetrik
ftv44	45	Matris	Küçük	1613	Asimetrik
ftv47	48	Matris	Küçük	1776	Asimetrik
ry48p	48	Matris	Küçük	14422	Asimetrik
ft53	53	Matris	Küçük	6905	Asimetrik
ftv55	56	Matris	Küçük	1608	Asimetrik
ftv64	65	Matris	Küçük	1839	Asimetrik
ft70	70	Matris	Orta	38673	Asimetrik
ftv70	71	Matris	Orta	1950	Asimetrik
kro124p	100	Matris	Orta	36230	Asimetrik
ftv170	171	Matris	Orta	2755	Asimetrik
rbg323	323	Matris	Büyük	1326	Asimetrik
rbg358	358	Matris	Büyük	1163	Asimetrik
rbg403	403	Matris	Büyük	2465	Asimetrik
rbg443	443	Matris	Büyük	2720	Asimetrik

2.6.2. Çelik üretim veri seti

Haddeleme planlama problemi asimetrik seyyar satıcı problemine indirgenmiştir. Levha sayısı GSP'deki şehir sayısına eşittir ve yuvarlanan levhalar arasındaki ceza değeri GSP'deki şehirlerarasındaki mesafeye eşittir. Zımba malzemesinin levhasının genişliğindeki değişimin daha dar olma eğiliminde olması ve ısınma malzemesinin genişliğindeki değişimin daha geniş olma eğiliminde olması gerektiğinden, daraltma için ceza değeri genişleme için ceza değerinden farklıdır. Bu problem asimetrik seyyar satıcı problemine dönüşür.

Sıcak haddeleme sürecinde, genişlik, kalınlık, sertlik, diş açma sıcaklığı, bitirme sıcaklığı ve sarma sıcaklığı gibi çelişen parametreler arasındaki değişimi en aza indirmek için matematiksel modeli Denklem 2.40'da verilmiştir.

$$\min f = \sum_{k=1}^m \sum_{i,j \in 1} d_{ij} x_{ijk} \quad (2.40)$$

Burada i ve j levha numarasını, k haddeleme ünitesi numarasını, m haddeleme ünitesi sayısını ve d_{ij} levha i ile levha j arasındaki haddeleme genişliği, haddeleme kalınlığı, haddeleme sertliği, diş açma sıcaklığı, bitirme haddeleme sıcaklığı ve haddeleme sıcaklığı değişimi için toplam ceza değerini temsil eder. x_{ijk} , ise levha sıralarını ifade eder.

2.6.3. Deney parametreleri ve bilgisayar özellikleri

Seçilim operatörlerinin performanslarını karşılaştırmak amacıyla, popülasyon büyüklüğü 80, çaprazlama oranı 1, mutasyon oranı 0.02, durdurma kriteri 1000 jenerasyon, YDM mutasyon yöntemi ve KEÇ çaprazlama yöntemi sabit olarak seçilmiş olup, Tablo 2.12'de verilmiştir. Seçim operatörlerinden maksimum performans elde etmek için literatürdeki tavsiye edilen parametrik değerler kullanılmıştır. Örneğin, Baker, LSS'nin $\eta^+ = 1.1$ 'de optimum performans gösterdiğini göstermektedir [16]. TS için, en uygun turnuva boyutu iki olarak tavsiye edilmektedir; aksi takdirde çeşitlilik kaybına neden olabilir. ÜSS için, parametrik değer r , 1'e çok yakındır ve bu da iyi performans gösterdiğini göstermişlerdir. Bu nedenle, $r = 0.99$ olarak belirlendi. Ek olarak, Husaain ve ark.'nın [16] BSS'nin etkili bir yaklaşım olduğunu göstermesi nedeniyle $\lambda^+ = 0.7$ ve $\lambda^- = 0.3$ olarak seçilmiştir. Ancak, UOS ve YTS için belirlenecek bir parametre değeri olmadığından parametre ayarı yapılamamıştır. KSDS operatörü için, parametre testleri doğrultusunda, başlangıç λ^x keşif parametre değerlerini 0.2 ve başlangıç λ^y sömürü parametre değerini ise

0.8 olarak belirlendi. BMHS yöntemi için alfa eşik değerleri sırasıyla keşif için 0-0.7 olarak, denge için 0.7-0.8 ve sömürü 0.8-1.0 olarak belirlenmiştir.

Tablo 2.12. Seçilim operatör deneyleri için kullanılan parametreler

Parametreler	Değeri
Popülasyon Büyüklüğü	80
Çaprazlama Oranı	1
Çaprazlama Yöntemi	KEÇ
Mutasyon Yöntemi	YDM
Mutasyon Oranı	0.02
Maksimum Jenerasyon	1000
Deney Tekrar Sayısı	30

Mutasyon operatörlerinin performanslarını karşılaştırmalı olarak değerlendirebilmek amacıyla, deneysel çalışmalarda bazı algoritma parametreleri sabit tutularak kontrollü bir ortam sağlanmıştır. Bu kapsamda, popülasyon büyüklüğü 80, çaprazlama oranı 1, mutasyon oranı 1, durdurma kriteri 1000 jenerasyon, KEÇ çaprazlama yöntemi, UOS seçim operatörü sabit olarak seçilmiştir ve Tablo 2.13'te belirlenen parametreler verilmiştir. Mutasyon oranının 1 olarak belirlenmesi, her bireyin her genine mutasyon uygulamak, mutasyonun etkisini önemli ölçüde artırır.

Tablo 2.13. Mutasyon operatör deneyleri için kullanılan parametreler

Parametreler	Değeri
Popülasyon Büyüklüğü	80
Çaprazlama Oranı	1
Çaprazlama Yöntemi	KEÇ
Seçilim Yöntemi	UOS
Mutasyon Oranı	1
Maksimum Jenerasyon	1000
Deney Tekrar Sayısı	30

Çaprazlama operatörlerinin performanslarını değerlendirmek için belirlenen parametre değerleri Tablo 2.14'te verilmiştir.

Tablo 2.14. Çaprazlama operatör deneyleri için kullanılan parametreler

Parametreler	Değeri
Popülasyon Büyüklüğü	80
Çaprazlama Oranı	1
Mutasyon Oranı	0.02
Mutasyon Yöntemi	DM
Seçilim Yöntemi	UOS
Maksimum Jenerasyon	1000
Deney Tekrar Sayısı	30

Mutasyon operatörleri arasında, literatürde çoğunlukla DM operatörü kullanıldığından, mutasyon operatörü DM olarak seçilmiştir. Seçim yöntemi UOS olarak seçilmiştir. Popülasyon büyüklüğü 80, çaprazlama oranı 1, mutasyon oranı 0.02, durdurma kriteri 1000 jenerasyon seçilmiştir.

Tüm deneyler, Intel (R) Core i5-7200u (2.71 GHz) CPU ile donatılmış bir dizüstü bilgisayarda Python Pyevolve kütüphanesinde gerçekleştirilmiştir.

3. DENEYSEL SONUÇLAR

3.1. Gezgin Satıcı Problemi Üzerinde Uygulamalar

3.1.2. Seçilim operatörlerinin karşılaştırılması

Gezgin satıcı problemlerindeki 30 veri seti için uygunluk ve jenerasyon grafikleri EK 1’de gösterilmiştir. Seçilim yöntemler arasında yapılan deneyler doğrultusunda, ÜSS ve LSS operatörleri yerel minimumda kaldığı gözlemlenirken, diğer seçilim operatörleri birbirine yakın performans göstermiştir. BMHS ve KSDS operatörlerinin, veri seti büyüklüğü arttıkça daha minimum değerlere erişebildiği görülmüştür. EK 2’de ortalama ve minimum yakınsama oranları verilmiş olup, ÜSS ve LSS yöntemlerinin erken yakınsadığını görebiliriz. BMHS, KSDS ve BSS yöntemleri en iyi performansları sergileyen yöntemler olmuşlardır. EK 3’de her bir seçilim operatörünün, ortalama hesaplama süreleri verilmiştir. Hesaplama süreleri açısından YTS operatörü en uzun süre alan operatörü olmuştur.

İstatistiksel bir bakış açısından, p değerleri kritik değerden (0.05) küçükse, yöntemler arasında bir fark olduğu sonucuna varılabilir. Kalın t-testi ($t \leq -2.00$) değerleri, BMHS yönteminin performansında önemli ölçüde iyileşme olduğunu gösterirken, kalın olmayan değerler ($t \geq 2.00$) BMHS tarafından önemli bir performans düşüklüğü olduğunu gösterir. Negatif ancak kalın olmayan t-testi değerleri, BMHS operatörünün ortalamaya göre biraz iyileşmiş performansını temsil eder. EK 2’de, pozitif t-değerine sahip olan tek yöntem KSDS yöntemi olmuştur. Simetrik veri setlerinde, berlin52 (1.40), pr76 (0.64), pr226 (3.73), a280 (4.52), att532 (7.96) örneklerinde KSDS yöntemi, BMHS yönteminde göre daha iyi performans gösterdiğini gözlemleyebiliriz. Aynı şekilde Asimetrik veri setlerinde, p43 (1.04), ft53 (1.35), ftv55 (0.17), ftv70 (0.58), kro124p (0.67), ftv170 (2.80), rbg323 (5.02), rbg358 (3.83), rbg403 (3.81) ve rbg443 (3.97) örneklerinde KSDS yöntemi BMHS yöntemine göre daha iyi performans göstermiştir.


Çeşitli veri kümeleri arasında yöntemlerin performanslarını değerlendirmek için, öncelikle Demsar (2006) [116]’daki öneriyi dikkate alarak, sıfır hipotezini reddetmek için Friedman testi [120] gerçekleştirildi. Çözümün doğruluğu, bulunan çözümün bilinen optimuma yakınlığının ölçülmesine olanak tanıyan, daha önce sunulan Denklem 2.16 kullanılarak ölçeklendirilmiştir. Friedman testini takiben, Benavoli ve ark. tarafından önerilen çiftler halinde post-hoc analizini gerçekleştirildi [121], burada ortalama sıra

karşılaştırması, Holm'un alfa (%5) düzeltmeli Wilcoxon işaretli sıra testi ile değiştirildi [114]. Son olarak, bu istatistiksel sonuçları görselleştirmek için en sağdaki modelden başlayarak, modellerin yanında belirtilen ortalama sıralama eksenine yansıtılan kritik fark diyagramını kullanıldı. Daha düşük bir sıralama, belirli bir model için diğerlerine kıyasla ortalama olarak üstün performansı gösterir. Model gruplarını birbirine bağlayan yatay çizgiler, bağlı modellerin birbirinden önemli ölçüde farklı olmadığını gösterir.

Tablo 3.1. Friedman testi ile elde edilen ortalama sıralamalar, istatistikler ve karşılık gelen p-değerleri

Yöntemler	Simetrik	Asimetrik	Matris	Öklid
TS	6.68	6.44	6.50	6.83
LSS	5.72	5.76	5.65	6.66
ÜSS	5.27	6.60	6.15	6.33
UOS	4.54	5.07	5.02	4.50
YTS	4.90	4.89	4.77	5.16
BSS	3.40	2.73	3.02	2.50
KSDS	2.90	2.28	2.56	1.83
BMHS	2.54	2.18	2.29	2.16
Friedman istatistik	30.66	79.43	79.45	30.50
Friedman p değeri	7.15e-05	1.79e-14	1.78e-14	7.68e-05


Tablo 3.1, seçim yöntemlerin sıralamalarını, Friedman istatistiğini ve Friedman p-değerini gösterir ve sırasıyla simetrik, asimetrik, matris veri kümelerinde 2.54, 2.18, 2.29 sıralamasıyla BMHS en iyi performans gösteren algoritma olarak vurgular. Ayrıca, Öklid uzaklık tipi veri setinde 1.83 ile ortalama en iyi sıralamaya sahip yöntem KSDS olarak vurgulanmıştır. Friedman testinden elde edilen p-değerleri (7.15e-05, 1.79e-14, 1.78e-14, 7.68e-05), incelenen algoritmalar arasında önemli farklılıkların varlığını güçlü bir şekilde göstermektedir. Ek 2'de elde edilen sonuçlara göre, Şekil 3.1, 3.2, 3.3 ve 3.4 sırasıyla simetrik, asimetrik matris tipi ve öklid uzaklık veri kümeleri için istatistiksel sonuçları göstermektedir. Diyagramda yöntemlerin yanındaki küçük sayılar, Friedman testinden elde edilen ortalama sıralamaları temsil etmektedir.



Şekil 3.1. Seçim operatörlerinde simetrik veri kümeleri için kritik fark diyagramı


Simetrik veri kümesinde, tüm operatörler birbirine bağlıdır ve istatistiksel olarak hiçbir tutarsızlık olmadan birbirlerinin alternatifi olarak kullanılabilir. Başka bir deyişle tüm

yöntemler arasında istatistiksel olarak fark yoktur. BMHS yöntemi (2.54) en iyi sıralamayı aldığından dolayı diğer yöntemlere kıyasla daha iyi performans göstermiştir.




Şekil 3.2. Seçim operatörlerinde asimetrik veri kümeleri için kritik fark diyagramı

Asimetrik veri kümelerinde, ÜSS-TS-LSS-YTS grubu ve LSS-UOS-YTS grubu istatistiksel olarak bağlantılıdır. BSS, KSDS ve BMHS dışındaki operatörler benzer performans göstermiş olup birbirlerinin yerine kullanılabilir. BSS-KSDS-BMHS yöntemleri birbirine bağlantılı olup, istatistiksel olarak benzer performans göstermiştir. Ayrıca, BMHS yöntemi en düşük sıralamayı (2.18) aldığından dolayı diğer tüm yöntemlerden istatistiksel olarak üstün performans göstermiştir.



Şekil 3.3. Seçim operatörlerinde matris tipi veri kümeleri için kritik fark diyagramı


Matris veri kümelerinde, ÜSS-TS-LSS-YTS grubu, LSS-UOS-YTS grubu, BSS-KSDS grubu ve KSDS-BMHS grubu istatistiksel olarak bağlantılıdır. BSS-KSDS-BMHS yöntemleri herhangi bir yöntemle bağlı olmadığından, diğer tüm yöntemlerden istatistiksel olarak üstün performans göstermişlerdir. BMHS yöntemi (2.29) en düşük sıralamaya sahip olduğundan, tüm yöntemlerden daha iyi performans sergilemiştir.



Şekil 3.4. Seçim operatörlerinde öklid uzaklık tipi veri kümeleri için kritik fark diyagramı


Öklid uzaklık veri setinde, tüm yöntemler arasında bağlantı bulunduğundan, istatistiksel olarak birbirlerine benzer performans göstermiştir. En küçük dereceye sahip olan yöntem KSDS olarak en iyi performansı gösterirken, TS en büyük derecelendirmeye sahip olarak en düşük performansı göstermiştir.

Ayrıca hibrit seçim yöntemleri için elde edilen kritik fark diyagramı sonuçları simetrik ve asimetrik veri setleri için Şekil 3.5 ve 3.6’da verilmiştir.



Şekil 3.5. Hibrit seçim operatörlerinde simetrik veri kümeleri için kritik fark diyagramı

Simetrik veri setleri bağlamında, değerlendirilen tüm hibrit stratejilerin aynı istatistiksel eşdeğerlik grubuna ait olduğu ve performans açısından anlamlı bir fark bulunmadığı gözlemlenmiştir. Ancak, QÖHS stratejisi en iyi ortalama sıralamayı elde ederek problem örnekleri genelinde tutarlı bir üstün performans sergilemiştir. Buna karşın, AHS operatörü en düşük sıralamaya sahip olup, ele alınan yöntemler arasında nispeten daha zayıf bir etkinlik göstermiştir.



Şekil 3.6. Hibrit seçim operatörlerinde simetrik veri kümeleri için kritik fark diyagramı

Asimetrik GSP veri setleri bağlamında ise hibrit stratejilerin iki istatistiksel olarak birbirinden ayırt edilemeyen grup oluşturduğu tespit edilmiştir: (i) AHS, DHS, ÖUHS, ETHS ve ÇKHHS; (ii) DHS, ÖUHS, ETHS, BMHS, ÇKHHS ve QÖHS. Bu gruplar içinde veya gruplar arasında anlamlı bir fark bulunmamaktadır. Dolayısıyla, asimetrik örnekler genelinde değerlendirilen hibrit stratejileri arasında performans açısından genel anlamda istatistiksel bir farklılık olmadığı sonucuna varılmıştır. İstatistiksel benzerliğe rağmen, QÖHS en yüksek ortalama sıralamayı elde ederek problem örneklerinde sürekli güçlü bir

performans göstermiştir. Buna karşılık, AHS en düşük ortalama sıralamaya sahip olup, diğer yaklaşımlara kıyasla nispeten daha düşük etkinlik sergilemiştir.

3.1.3. Mutasyon operatörlerinin karşılaştırılması

Gezgin satıcı problemlerindeki 30 veri seti için uygunluk ve jenerasyon grafikleri EK 4'te gösterilmiştir. EK 4'deki sonuçlara göre küçük ve orta boyutlu veri setlerinde basit ters çevirme mutasyon operatörünün (BTÇM) diğer yöntemlerine göre daha iyi performans gösterdiği gözlemlenmiştir. rbg323 ve rbg358 gibi büyük veri setlerinde değişim mutasyonu operatörünün (DM) optimal tur uzunluğuna daha iyi yakınsadığı görülmüştür. EK 5'de her bir mutasyon operatörleri için en iyi çözümler, ortalama çözümler ve hesaplama süreleri verilmiştir. Küçük ve orta boyutlu veri setlerinde optimum çözüme en yakın çözüme sahip olması nedeniyle BTÇM mutasyon operatörü en iyi sonucu vermiştir. Veri setinin boyutu arttıkça DM operatörü yakınsama açısından daha iyi performans gösterdiği görülebilir. EK 6'da her bir mutasyon operatörünün hesaplama süre aralıkları verilmiştir. Hesaplama süresi açısından en kısa süreyi KM mutasyon operatörü alırken, en uzun hesaplama süresini YDM mutasyon operatöründe gözlemlenmiştir.

İstatistiksel t testi açısından değerlendirildiğinde, kalın t-testi ($t \leq -2.00$) değerleri, DM yönteminin performansında önemli ölçüde iyileşme olduğunu gösterirken, kalın olmayan değerler ($t \geq 2.00$) KSDS tarafından önemli bir performans düşüklüğü olduğunu gösterir. Negatif ancak kalın olmayan t-testi değerleri, DM operatörünün ortalamaya göre biraz iyileşmiş performansını temsil eder. EK 5'de, küçük boyutlu veri setlerinde, BTÇM ve KM operatörleri, DM operatörüne göre anlamlı olmayan sonuçlar gösterir. Örneğin, gr21, fri26, bayg29, dantzig42, eil51, berlin52, br17, ftv33, ftv35, ftv38, p43 ve ftv47 veri setlerinde, pozitif t-değerine sahip BTÇM ve bazı durumlarda KM operatörleri, DM operatörden daha iyi performans gösterdiğini gözlemleyebiliriz.


Tablo 3.2, seçim yöntemlerin sıralamalarını, Friedman istatistiğini ve Friedman p-değerini göstermektedir. Ortalama sıralamalar doğrultusunda, simetrik veri setinde BTÇM (1.31), asimetrik veri setinde DM (2.13), matris veri setinde BTÇM-KM (2.13) ve öklid veri kümelerinde ise BTÇM (1.33) yöntemleri en iyi performans gösteren algoritma olmuştur. Friedman testinden elde edilen p-değerleri, kritik değere göre (0.05) küçük olduğundan, algoritmalar arasında önemli farklılıklar olduğunu belirtmektedir. Diyagramda yöntemlerin

yanındaki küçük sayılar, Friedman testinden elde edilen ortalama sıralamaları temsil etmektedir.

Tablo 3.2. Friedman testi ile elde edilen ortalama sıralamalar, istatistikler ve karşılık gelen p-değerleri


Yöntemler	Simetrik	Asimetrik	Matris	Öklid
YDM	5.63	4.97	5.11	5.50
EM	3.45	3.60	3.61	3.50
TÇM	5.36	5.81	5.70	5.50
BTÇM	1.31	2.28	2.13	1.33
KM	2.77	2.18	2.13	3.16
DM	2.45	2.13	2.29	2.00
Friedman istatistik	45.44	72.28	58.73	25.80
Friedman p değeri	1.17e-08	3.42e-14	8.12e-11	9.71e-05

Simetrik veri setinde, YDM-TÇM yöntemleri birbirine bağlı olduğundan istatistiksel olarak fark yoktur. EM-KM-DM operatörleri ve aynı zamanda DM-BTÇM operatörleri birbiri ile grup olarak birbirine bağlı olduğundan istatistiksel olarak benzer performans göstermişlerdir. En düşük dereceye sahip olduğundan dolayı BTÇM en başarılı yöntem olmuştur. Ek 5'te elde edilen sonuçlara göre, simetrik, asimetrik, matris ve öklid uzaklık tipi veri setleri için istatistiksel sonuçlar göstermektedir Şekil 3.7, 3.8, 3.9 ve 3.10'te verilmiştir.




Şekil 3.7. Mutasyon operatörlerinde simetrik veri kümeleri için kritik fark diyagramı

Asimetrik veri setinde sadece BTÇM-KM-DM operatörleri birbirine bağlantılı olup, istatistiksel olarak birbirlerinin yerine kullanılabilirler. En düşük dereceye DM operatörü sahipken yani en iyi performansı gösterirken, TÇM en yüksek dereceye sahip olup en düşük performansı sergilemiştir.




Şekil 3.8. Mutasyon operatörlerinde asimetrik veri kümeleri için kritik fark diyagramı

Matris veri setinde sadece BTÇM-KM-DM operatörleri birbirine bağlantılı olup, istatistiksel olarak birbirlerinin yerine kullanılabilirler. En düşük dereceye KM operatörü sahipken yani en iyi performansı gösterirken, TÇM en yüksek dereceye sahip olup en düşük performansı sergilemiştir.



Şekil 3.9. Mutasyon operatörlerinde matris tipi veri kümeleri için kritik fark diyagramı

Öklid veri setlerinde BTÇM operatörü en başarılı operatör olmakla birlikte tüm operatörler birbirine bağlantılı olduğundan istatistiksel olarak anlamlı fark gözlemlenmiştir.



Şekil 3.10. Mutasyon operatörlerinde öklid uzaklık tipi veri kümeleri için kritik fark diyagramı

3.1.4. Çaprazlama operatörlerinin karşılaştırılması

30 veri seti için uygunluk ve jenerasyon grafikleri EK 7’de gösterilmiştir. Jenerasyon sonunda elde edilen uygunluk değerine göre grafiği karşılaştırdığımızda, GAÇ ve SYÇ çaprazlama yöntemler diğer çaprazlama yöntemlerine göre daha iyi performans göstermektedir. EK 8’de her operatör için en iyi çözümler, ortalama çözümler ve hesaplama süreleri verilmiştir. Küçük ve orta büyüklükteki setinde da yapılan test sonuçlarında GAÇ yönteminin diğer yöntemlere göre daha iyi olduğu görülmektedir. Şehir sayısı 300 ve üzerindeki büyük veri setlerinde SYÇ yönteminin GAÇ yönteminden daha verimli olduğu gözlemlenmiştir. Şehir sayısı arttıkça tüm yöntemlerde optimizasyon performansının düştüğü ve hesaplama sürelerinin arttığı görülmektedir. Hesaplama sürelerini daha iyi gözlemleyebilmek için her bir operatörün analizi yapılmıştır ve EK 9’da gösterilmiştir. GAÇ yönteminin diğer yöntemlerden daha uzun süre hesaplama yaptığı gözlemlenmiştir.


t-testi istatistiği açısından, kalın t-testi ($t \leq -2,00$) değerleri GAÇ yönteminin performansında önemli ölçüde iyileşme olduğunu gösterirken, kalın olmayan değerler ($t \geq 2,00$) GAÇ tarafından önemli bir performans düşüşü olduğunu gösterir. Negatif ancak kalın olmayan t-testi değerleri GAÇ operatörünün ortalamaya göre biraz iyileşmiş performansını temsil eder. Ek 8'e göre, gr21 veri setinde, SÇ yöntemi pozitif t-testi değerine (0.48) sahip olduğundan GAÇ yönteminden daha iyi performans göstermiştir. Ayrıca, rbg323 (7.06), rbg358 (10.01) ve rbg443 (0.50) veri kümelerindeki pozitif t-testi değerleri göz önüne alındığında, SYÇ yönteminin bu özel durumlarda GAÇ yönteminden daha iyi performans gösterdiği sonucuna varılabilir.

Kritik fark diyagramı açısından değerlendirildiğinde, yöntemlerin Friedman istatistiği ve Friedman p-değeri sıraları, Tablo 3.3'te verilmiştir ve GAÇ yöntemi sırasıyla simetrik, asimetrik, matris ve öklid uzaklık tipi veri setlerinde 2.13, 1.57, 1.86, 1.00 ortalama sıralamasıyla, en iyi performans gösteren algoritma olarak vurgulanmıştır. Friedman testinden elde edilen p-değerleri, incelenen algoritmalar arasında önemli farklılıkların varlığını güçlü bir şekilde göstermektedir. Ek 8'de elde edilen sonuçlar doğrultusunda, Şekil 3.11, 3.12, 3.13 ve 3.14 simetrik, asimetrik, matris ve öklid uzaklık tipi veri setleri için istatistiksel sonuçları göstermektedir.

Tablo 3.3. Friedman testi ile elde edilen ortalama sıralamalar, istatistikler ve karşılık gelen p-değerleri


Yöntemler	Simetrik	Asimetrik	Matris	Öklid
KEÇ	4.45	4.73	4.81	4.50
DÇ	8.36	8.31	8.00	9.50
SÇ	6.09	5.84	5.68	7.66
SDÇ	5.86	5.31	5.27	5.83
MKÇ	7.72	7.21	7.59	7.00
PDC	4.81	4.97	4.88	5.00
GKEÇ	6.22	5.65	5.86	6.16
KBÇ	11.00	10.05	10.18	11.00
AÇ	6.22	10.31	9.56	6.33
GAÇ	2.13	1.57	1.86	1.00
SYÇ	3.09	2.00	2.27	2.00
Friedman istatistik	65.56	147.21	154.56	46.60
Friedman p değeri	3.16e-10	1.39e-26	4.28e-28	1.11e-06

Simetrik veri setinde tüm operatörler arasında bağlantı bulunduğundan dolayı anlamlı fark gözlenmemiştir. Fakat GAÇ operatörü en düşük dereceye sahip olduğundan ortalama olarak diğer yöntemlerden daha iyi performans göstermiştir.




Şekil 3.11. Çaprazlama operatörlerinde simetrik veri kümeleri için kritik fark diyagramı

Asimetrik veri setinde, AÇ-KBÇ grubu, DÇ-MKÇ grubu, MKÇ-SÇ-EMKÇ-SDÇ-PDÇ grubu, KEÇ-SÇ-EMKÇ-SDÇ-PDÇ ve SYÇ-GAÇ grubu birine bağlıdır ve bu gruplar kendi içinde istatistiksel olarak anlamlı farklılık yoktur. GAÇ operatörü, diğer operatörlere göre daha düşük dereceye sahip olduğundan en başarılı yöntem olmuştur.




Şekil 3.12. Çaprazlama operatörlerinde asimetrik veri kümeleri için kritik fark diyagramı

Matris veri setinde, AÇ-KBÇ grubu, DÇ-MKÇ grubu, MKÇ-SÇ-EMKÇ-SDÇ-PDÇ grubu, KEÇ-SÇ-EMKÇ-SDÇ-PDÇ ve SYÇ-GAÇ grubu birine bağlıdır ve bu gruplar kendi içinde istatistiksel olarak anlamlı farklılık yoktur. GAÇ operatörü, diğer operatörlere göre daha düşük dereceye sahip olduğundan en başarılı yöntem olmuştur.



Şekil 3.13. Çaprazlama operatörlerinde matris tipi veri kümeleri için kritik fark diyagramı


Öklid uzaklık tipi veri setlerinde operatörler arasında anlamlı farklılıklar bulunmamakta ve GAÇ yöntemi en başarılı yöntem olurken, KBÇ en verimsiz yöntem olmuştur.



Şekil 3.14. Çaprazlama operatörlerinde öklid uzaklık tipi veri kümeleri için kritik fark diyagramı


3.1.5. Çeşitlilik analizi sonuçları

Seçim yöntemleri için popülasyon içindeki çeşitliliğin ölçüm sonuçları Şekil 3.15'te verilmiştir. LSS ve ÜSS'nin keşfe daha yatkın olduğunu, TS'de çeşitlilik kaybı olduğunu ve UOS'nin sömürüye daha yatkın olduğunu gözlemleyebiliriz. Ek olarak, UOS, YTS ve BSS'nin sömürüye hemen başladığı, KSDS'nin ise erken aşamalarda keşif ve belirli aralıklarla keşif yapmaya devam ettiği gözlemlenebilir. Sürecin sonraki aşamalarında, KSDS sömürüye odaklanarak mevcut çözümleri geliştirmeye odaklanır.



Şekil 3.15. Seçim operatörleri için keşif-sömürü dengesi

Şekil 3.16'da sunulan hibrit seçim yöntemlerinin ürettiği α parametre değerinin, evrimsel optimizasyon sürecinde seçim baskısının nasıl evrildiğine dair çeşitli dinamikler ortaya koymaktadır. Her strateji, keşif ve sömürü dengesine yönelik farklı bir kontrol yaklaşımını temsil etmektedir.




Şekil 3.16. Hibrit seçim yöntemlerinde α parametresinin dinamik davranışı

DHS stratejisi, α 'yı nesil bazlı doğrusal olarak artırır; bu da kontrollü bir yakınsama sağlar ancak problem dinamiklerine duyarsızdır. BMHS yöntemi, çeşitlilik ve nesil sayısı gibi nüfus özelliklerine bağlı olarak α 'yı uyarlayarak daha esnek ve geri bildirim temelli bir kontrol sunar. ETHS, çeşitlilik azaldığında α 'yı düşürerek keşif yapmasına teşvik eder ve erken yakınsamayı önlemeye çalışır. AHS, α 'da erken hızlı, sonra yavaşlayan logaritmik bir artış sağlar; bu da başlangıçta esneklik, sonrasında kararlılık sunar. ÖUHS, α 'yı bireylerin genetik yapısına dahil eder; böylece parametre, evrimsel süreçte doğal olarak optimize olur. QÖHS, performansa dayalı geri bildirimle α 'yı dinamik biçimde günceller; başlangıçta dalgalı, sonrasında daha dengelidir. ÇKHHS ise genellikle sabit kalan α değerleri üretir; bu da kararlılığı artırırken esnekliği sınırlayabilir. Sonuç olarak, her stratejinin α üzerindeki kontrol biçimi, optimizasyon sürecinin keşif-sömürü dengesini farklı şekillerde etkileyerek genel performansa yön vermektedir.


Şekil 3.17'de, hibrit seçim stratejilerinin nesil bazında keşif ve sömürü oranları gösterilmektedir. DHS, sabit kuralı nedeniyle popülasyon dinamiklerine duyarsız olup, gereksiz keşiflerle aramada gürültü yaratabilir. AHS, bireysel başarıya dayalı tepki verir ancak gecikmeli ve çeşitliliğe duyarsızdır; bu da erken aşamada aşırı sömürü veya keşfe yol açabilir. BMHS, popülasyon çeşitliliği ve nesil bilgisiyle α 'yı kural tabanlı uyarlayarak

erken dönemde agresif keşif, sonraki nesillerde stabil sömürü sağlar. ETHS, entropiye bağlı olarak çeşitlilik azaldığında keşfi artırıp, arttığında ise sömürüye yönelerek dengeyi sistematik optimize eder. ÖUHS, α 'yı genetik yapıya entegre ederek bireysel uyumla hızlı adaptasyon sağlar. QÖHS, geçmiş ödüllere dayanarak α 'yı dinamik ayarlayıp erken keşif ve geç dönem sömürüyü dengeler; ortalama keşif oranı %11,79'dur ancak keşifler daha verimlidir. ÇKHHS ise en düşük %10,55 keşif oranına rağmen, verimli keşiflerle yüksek yakınsama başarısı gösterir. Bu sonuç, keşif kalitesinin niceliğinden daha önemli olduğunu ortaya koymaktadır.




Şekil 3.17. Hibrit seçim operatörleri için keşif-sömürü dengesi

Şekil 3.18'te sunulan mutasyon operatörleri için keşif ve sömürü dengesi grafiği incelendiğinde, YDM, TÇM ve EM mutasyon operatörlerinin arama uzayında daha geniş bir tarama yeteneğine sahip olduğu ve bu nedenle keşif odaklı çalıştığı gözlemlenmiştir. Buna karşın, KM ve BTÇM operatörlerinin popülasyon içindeki çeşitliliği azaltma eğiliminde oldukları ve dolayısıyla daha çok sömürüye yönelik bir davranış sergiledikleri görülmektedir. Keşif ve sömürü arasındaki dengeyi en etkin şekilde sağlayan mutasyon stratejisi ise, hem çeşitliliği koruyarak yeni çözümler üretme potansiyelini hem de mevcut iyi çözümler üzerinde yoğunlaşma kabiliyetini bir arada sunan DM operatörü olmuştur.



Şekil 3.18. Mutasyon operatörleri için keşif-sömürü dengesi

Şekil 3.19’da sunulan çaprazlama operatörlerine ait keşif ve sömürü dengesi grafiği incelendiğinde, SÇ, MKÇ, KBC, AÇ ve GAÇ operatörlerinin yüksek düzeyde keşif yeteneği sergilediği gözlemlenmiştir. Bu operatörlerin, çözüm uzayında farklı bölgeleri taramaya olanak tanıyan yapısal özellikleri sayesinde, popülasyon içi çeşitliliği koruma konusunda etkili oldukları değerlendirilmektedir.



Şekil 3.19. Çaprazlama operatörleri için keşif-sömürü dengesi

Diğer yandan, KEÇ, DÇ, SDÇ, PDÇ ve GKEÇ gibi operatörlerde zamanla çeşitlilik kaybının yaşandığı, dolayısıyla daha çok sömürüye yönelik bir eğilim gösterdikleri tespit edilmiştir. Bu durum, söz konusu operatörlerin genetik bilginin ebeveynlerden yavrulara

daha doğrudan aktarımına olanak tanınması ve böylece mevcut iyi çözümler üzerinde yoğunlaşmalarından kaynaklanır. PDÇ ve SDÇ operatörleri, diğer sömürü odaklı yöntemlere kıyasla çeşitliliği daha geç kaybetmesiyle dikkat çekmektedir. Öte yandan, SYÇ operatörü, hem arama alanında yeterli çeşitliliği sürdürebilmesi hem de kaliteli çözümler üzerinde odaklanabilmesi açısından, keşif ve sömürü arasında en dengeli performansı sergileyen yöntem olarak öne çıkmaktadır.

3.2. Endüstri Problemi Üzerinde Uygulamalar


Çelik üretiminde genişlik, kalınlık, sertlik, kılavuz çekme sıcaklığı, son işlem sıcaklığı ve sarma sıcaklığı gibi haddelenmiş levha parametreleri arasındaki nitelik farkını en aza indirmek amacıyla GA tabanlı bir optimizasyon yaklaşımı uygulanmıştır. Öncelikle problem asimetrik GSP olarak modellenmiştir. Üretim özelliklerini elde etmek için sentetik birikim veri oluşturucusu (synthetic backlog data generator) kullanılmıştır [122]. Seçim ve çaprazlama yöntemlerinin performansları, modellenmiş veri seti üzerinde uygulanmıştır.

Seçim operatörleri için seçilen parametreler Tablo 2.10’de, 3 farklı çelik veri seti için minimum ortalama standart sapma, t-testi ve ortalama hesaplama süreleri Tablo 3.4’te verilmiştir. T-test istatistiği açısından, pozitif t-testi değeri, random30 (0.32), random80 (4.51) ve çelik (6.37) veri setlerinde gözlemlendiğinden, KSDS yöntemi, BMHS yönteminden istatistiksel olarak daha iyi performans sergilemiştir. Uygunluk-jenerasyon grafikleri ve ortalama hesaplama süresi aralıkları Şekil 3.20’de verilmiştir. Yakınsama oranları açısından, BMHS yöntemi random30 veri setinde en iyi performansı gösterirken random80 ve çelik veri setinde KSDS yöntemi en iyi performansı göstermiştir. Hesaplama süresi açısından en az süre gerektiren yöntem BSS olmuştur.

Çaprazlama operatörlerinin çelik veri seti üzerindeki performansını değerlendirmek için Tablo 2.12’de verilen parametre değerleri kullanılmış olup, 3 farklı çelik veri setinde elde edilen sonuçlar Tablo 3.5’te ve Şekil 3.21’de sunulmuştur. İstatistiksel açıdan, GAÇ yöntemi referans alınmış olup, diğer yöntemlere göre pozitif t-testi değeri bulunmadığından en verimli yöntem GAÇ operatörü olmuştur ve en düşük SD değerine sahiptir. KEÇ operatörü hesaplama süresi açısından en verimli yöntem iken, GAÇ operatörü en çok zaman alan yöntem olduğunu göstermektedir. Yeni nesil üretim sürecinde çocuklar şehirlerarası mesafe matrisi kullanılarak seçildiğinden, sezgisel çaprazlama yöntemlerinin (AÇ, GAÇ, SYÇ) hesaplama karmaşıklığı sezgisel olmayan yöntemlerden (KEÇ, DÇ, SÇ, SDÇ, PDÇ, MKÇ, KBÇ ve GKEÇ) daha fazladır.

Tablo 3.4. Seçim operatörlerin çelik verisi üzerinde karşılaştırılması

Veri Seti	Sonuçlar	TS	UOS	LSS	ÜSS	BSS	YTS	KSDS	BMHS
random30	Minimum	3.2E+11	3.8E+11	4.4E+11	5.6E+11	3.2E+11	3.6E+11	2.9E+11	2.5E+11
	Ortalama	4.43E+11	4.33E+11	5.12E+11	6.58E+11	3.85E+11	4.29E+11	3.52E+11	3.55E+11
	SD	4.49E+10	3.01E+10	3.73E+10	7.48E+10	2.94E+10	3.97E+10	3.36E+10	4.29E+10
	t-test (p değeri)	-7.65 (2.32e-10)	-8.03 (5.30e-11)	-14.81 (2.21e-21)	-18.91 (1.76e-26)	-3.10 (0.002)	-6.80 (6.11e-09)	0.32 (0.74)	-
	Süre(s)	21.58	18.11	20.96	21.21	16.84	19.84	17.74	82.56
random80	Minimum	1.65E+12	1.77E+12	2.26E+12	2.67E+12	1.61E+12	1.74E+12	1.37E+12	1.52E+12
	Ortalama	1.88E+12	1.90E+12	2.49E+12	2.99E+12	1.76E+12	1.92E+12	1.55E+12	1.64E+12
	SD	1.01E+11	7.66E+10	1.28E+11	1.59E+11	6.62 E+10	7.91E+10	7.64E+10	6.2E+10
	t-test (p değeri)	-10.99 (8.08e-16)	-14.52 (5.52e-21)	-32.56 (5.76e-39)	-42.53 (2.0e-45)	-7.80 (1.27e-10)	-15.11 (8.84e-22)	4.51 (3.1e-05)	-
	Süre(s)	87.30	87.03	111.64	104.57	78.26	86.11	88.58	232.31
Çelik verisi	Minimum	2.95E+12	3.03E+12	3.96E+12	4.44E+12	2.82E+12	3.02E+12	2.40E+12	2.58E+12
	Ortalama	3.19E+12	3.29E+12	4.30E+12	5.19E+12	3.00E+12	3.24E+12	2.59E+12	2.77E+12
	SD	1.03E+11	1.17E+11	1.77E+11	3.60E+11	1.02E+11	1.15E+11	1.05E+11	9.41e+10
	t-test (p değeri)	-16.61 (1.02e-23)	-19.03 (1.28e-26)	-41.40 (9.01e-45)	-35.08 (9.38e-41)	-9.25 (5.10e-13)	-17.03 (3.06e-24)	6.37 (3.2e-08)	-
	Süre(s)	81.334	83.55	99.26	113.19	81.28	87.68	91.35	249.85




Şekil 3.20. Seçim operatörlerinin çelik veri setindeki performansları

Tablo 3.5. Çaprazlama operatörlerinin çelik verisi üzerinde karşılaştırılması

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
random30	Minimum	6.50001E+11	7.30002E+11	4.20001E+11	5.50001E+11	4.80001E+11	3.60001E+11	1.15E+12	6.80002E+11	4.10001E+11	90000170388	1E+11
	Ortalama	7.34335E+11	8.26335E+11	5.37668E+11	6.94335E+11	6.67668E+11	4.81335E+11	1.25134E+12	7.83002E+11	5.35001E+11	90000176313	1.07667E+11
	SD	3.96 E+10	4.45 E+10	4.46 E+10	5.25 E+10	8.06 E+10	5.75 E+10	3.92 E+10	4.05 E+10	4.65 E+10	6350	4.95 E+9
	t-test (p değeri)	-87.53 (2.61 e-63)	-89.04 (9.80 e-64)	-53.93 (2.91 e-51)	-61.89 (1.13 e-54)	-38.59 (4.65 e-43)	-36.62 (8.65 e-42)	-159.45 (2.37 e-78)	-92.12 (1.37 e-64)	-51.50 (4.01 e-50)	-	-19.19 (8.27 e-27)
	Süre(s)	131.581	440.151	201.882	2446.189	4200.927	477.727	726.999	569.801	14282.664	61237.435	7298.804
random80	Minimum	2.58001E+12	2.88001E+12	2.07001E+12	2.50001E+12	2.29001E+12	1.85001E+12	4.14001E+12	2.77001E+12	1.44E+12	1E+11	1.30001E+11
	Ortalama	2.73867E+12	3.08434E+12	2.18901E+12	2.69667E+12	2.63767E+12	2.02501E+12	4.26367E+12	2.96601E+12	1.65334E+12	1.07334E+11	1.58334E+11
	SD	7.68E+10	8.14E+10	6.06E+10	1.02E+11	1.37E+11	6.40 E+10	5.25E+10	7.93E+10	9.92E+10	5.12 E+9	1.49 E+10
	t-test (p değeri)	-183.99 (5.99 e-82)	-196.48 (1.33 e-83)	-184.24 (5.53 e-82)	-135.76 (2.61 e-74)	-99.12 (2.02 e-66)	-160.67 (1.53 e-78)	-424.29 (5.60 e-103)	-193.69 (3.06 e-83)	-83.75 (3.32e-62)	-	-17.64 (5.41 e-25)
	Süre(s)	214.971	1460.970	310.151	2655.861	5089.389	289.717	445.483	660.308	33795.042	197238.119	106913.926

Tablo 3.5. devam ediyor

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
Çelik verisi	Minimum	4.30014E+12	4.96018E+12	3.43014E+12	4.05019E+12	4.2302E+12	3.32019E+12	7.05024E+12	4.67021E+12	3.89E+12	2.4E+11	3E+11
	Ortalama	4.65352E+12	5.15886E+12	3.7035E+12	4.53419E+12	4.4572E+12	3.49183E+12	7.24823E+12	4.96719E+12	4.12E+12	2.54E+11	3.38E+11
	SD	1.47E+11	1.27E+11	1.23E+11	1.80E+11	1.37E+11	1.00E+11	7.14E+10	1.29E+11	1.59E+11	9.16 E+9	2.77 E+10
	t-test (p değeri)	-160.23 (1.79 e-78)	-206.95 (6.61 e-85)	-149.90 (8.46 e-77)	-127.23 (1.11 e-72)	-164.47 (3.95 e-79)	-173.45 (1.82 e-80)	-522.97 (3.04 e-108)	-195.05 (2.03 e-83)	-130.17 (2.97 e-73)	-	-15.91 (7.98 e-23)
	Süre(s)	236.99	1655.23	338.26	3292.05	5590.67	306.01	476.73	746.62	38790.13	218974.25	148531.90



Şekil 3.21. Çaprazlama operatörlerinin çelik veri setindeki performansları

4. TARTIŞMA VE YORUM

Hem simetrik hem de asimetrik GSP veri setlerinde elde ettiğimiz sonuçlar literatürde yer alan çalışmaların sonuçları ile karşılaştırılmıştır. Ahmed ve ark. (2010) [58] KBÇ, GNÇ ve SYÇ operatörlerinin performanslarını karşılaştırmıştır. Deneysel sonuçlar, asimetrik ve asimetrik veri kümesindeki en etkili operatörün SYÇ yöntemi ile sonuçlandığını göstermiştir. Örneğin, kro124P veri kümesinde KBÇ % 30.96, GNÇ %25.72 ve SYÇ %4.24 hata oranlarıyla sonuçlanırken, lin105 veri kümesinde KBÇ %30.05, GNÇ %48.13 ve SYÇ %2.52 hata oranlarıyla sonuçlanmıştır.

2017'de Hussain ve ark. [43] DÇ2 yöntemini önermişler ve KEÇ, SÇ yöntemleri ile karşılaştırmışlardır. Deneysel sonuçlar, önerilen yöntemin, diğer yöntemlerden daha etkili olduğunu göstermiştir. fri26 veri setinde yapılan deneylerde, KEÇ, SÇ ve DÇ2 operatörleri için sırasıyla, %12.70, %17.29 ve %12.16 hata oranları elde edilirken, ftv170 veri setinde %384.42, %451.72, %133.06 hata oranları elde edilmiştir.

2015 yılında Khan, [66] sekiz farklı çaprazlama yani, İNÇ, KEÇ, DÇ, KÇ, KBÇ, TDSTÇ, ADÇ ve SYÇ operatörlerini karşılaştırmak için deneysel çalışma yapmıştır. Çalışmada, ftv170 veri seti için, SYÇ yöntemi %29.27 hata oranı ile en iyi performansı göstermiştir.

Ismkhan ve ark. (2015) [67], KEÇ, GKEÇ, GAA-2, AÇ, İSÇ ve MKO olmak üzere 6 farklı çaprazlama operatörünü karşılaştırmıştır. eil51 veri setinde, AÇ (%0.0), İSÇ (%0.0) ve MKO (%0.7) hata oranları açısından en iyi performansları göstermiştir.

Gopal ve ark. [123] KEÇ, SÇ ve DÇ operatörlerini önerdikleri modifiyeli sıralı çaprazlama (MSC) operatörüyle karşılaştırarak deneysel çalışmalar yürüttüler. Önerilen yöntemin eil51 veri setinde %5 hata oranıyla optimum değere yakınsadığı ve sırasıyla KEÇ (%125.35), SÇ (%129.57) ve DÇ (%169.95) hata oranlarıyla sonuçlandığı gösterilmiştir.

Uray ve ark. (2023) [69] DKTÇ operatörünü önermiş ve EİSÇ operatörü ile karşılaştırmıştır. Veri seti olarak eil51 kullanılmış ve EİSÇ operatörü %7.98 hata oranına sahipken, DKTÇ operatörü %3.75 hata oranıyla daha iyi performans göstermiştir.

Deneysel olarak elde ettiğimiz en iyi mutasyon DM operatörü ve GAÇ çaprazlama yöntemleri kullanılarak, 3 farklı seçim yöntemleri sırasıyla UOS, BSS ve önerilen KSDS ile

elde edilen sonuçlar, literatürde yer alan deneysel sonuçlar ile karşılaştırılmış ve özet tablosu Tablo 4.1’de verilmiştir.

Tablo 4.1. Literatürde elde edilen sonuçlar ile deneysel sonuçlarımız ile karşılaştırılması

Literatür	Veri seti	Yöntemler	Deneysel Sonuçlar		
Ahmad ve ark (2010) [58]	kro124p	KBÇ (%30.96)	GAÇ + UOS (%8.91)	GAÇ + BSS (%7.73)	GAÇ + KSDS (%6.54)
		GNÇ (%25.72)			
		SYÇ (%4.24)			
Ahmad ve ark (2010) [58]	lin105	KBÇ (%30.05)	GAÇ + UOS (%1.33)	GAÇ + BSS (%0.73)	GAÇ + KSDS (%1.16)
		GNÇ (%48.13)			
		SYÇ (%2.52)			
Hussain ve ark. (2017) [43]	fri26	KEÇ (%12.70)	GAÇ + UOS (%0.00)	GAÇ + BSS (%0.00)	GAÇ + KSDS (%0.00)
		SÇ (17.29)			
		DÇ2 (12.16)			
Hussain ve ark. (2017) [43]	ftv170	KEÇ (%384.42)	GAÇ +UOS (%16.58)	GAÇ+BSS (%13.39)	GAÇ+KSDS (%10.96)
		SÇ (%451.72)			
		DÇ2 (%133.06)			
Khan (2015) [66]	ftv170	İNÇ (%77.38)	GAÇ +UOS (%16.58)	GAÇ+BSS (%13.39)	GAÇ+KSDS (%10.96)
		KEÇ (%127.38)			
		DÇ (%128.46)			
		KÇ (%206.92)			
		KBÇ (%249.17)			
		TDSTÇ (%102.06)			
		ADÇ (%137.29)			
		SYÇ (%29.72)			
Ismkhan ve ark (2015) [67]	eil51	KEÇ (%1.88)	GAÇ +UOS (%1.77)	GAÇ +BSS (%1.08)	GAÇ +KSDS (%1.52)
		GKEC (%1.64)			
		AGA-2 (%0.47)			
		AÇ (%0.0)			
		İSÇ (%0.0)			
		MKO (%0.7)			
Gopal ve ark (2015) [123]	eil51	KEÇ (%125.35)	GAÇ + UOS (%1.77)	GAÇ + BSS (%1.08)	GAÇ +KSDS (%1.52)
		SÇ (%129.57)			
		DÇ (%169.95)			
		MSÇ (%5.0)			
Uray ve ark (2023) [69]	eil51	DKTÇ (%3.75)	GAÇ +UOS (%1.77)	GAÇ + BSS (%1.08)	GAÇ +KSDS (%1.52)
		EİSÇ (%7.98)			
Hussain ve ark (2020) [16]	ftv33	KEÇ (%8.24)	GAÇ + UOS (%5.23)	GAÇ + BSS (%2.33)	GAÇ + KSDS (%2.33)
		SÇ (%6.29)			
		DÇ (%10.18)			
Hussain ve ark (2020) [16]	berlin52	KEÇ (% 0.94)	GAÇ + UOS (%0.09)	GAÇ + BSS (%0.09)	GAÇ + KSDS (%0.09)
		SÇ (% 0.54)			
		DÇ (%1.19)			
Hussain ve ark (2020) [16]	ft70	KEÇ (% 3.07)	GAÇ + UOS (%4.38)	GAÇ + BSS (%3.92)	GAÇ + KSDS (%3.53)
		SÇ (% 1.92)			
		DÇ (%3.13)			
Hussain ve ark (2020) [16]	ftv170	KEÇ (%7.33)	GAÇ +UOS (%16.58)	GAÇ+BSS (%13.39)	GAÇ+ KSDS (%10.96)
		SÇ (% 8.05)			
		DÇ (%9.07)			
Hussain ve ark (2020) [16]	pr226	KEÇ (% 1.50)	GAÇ +UOS (%0.83)	GAÇ+BSS (%0.83)	GAÇ+KSDS (%0.83)
		SÇ (%0.92)			
		DÇ (%1.62)			

Uygulanan seçim yöntemlerinin avantaj ve dezavantajları Tablo 4.2’te özetlenmiştir. Yüksek keşif oranı gösteren yöntemler arasında özellikle LSS ve ÜSS öne çıkmaktadır. Bu yöntemler, bireyler arasındaki seçim olasılıklarını daha homojen şekilde dağıtarak, popülasyonda çeşitliliğin korunmasını sağlar. Böylece algoritma, çözüm uzayının daha geniş bölgelerini keşfedebilir ve yerel minimumlara sıkışma riski azalır. Ancak bu yaklaşımların

dezavantajı, iyi bireylerin seçilme olasılığının düşük kalması nedeniyle algoritmanın yakınsama hızının düşmesidir. Bu da çözüm kalitesinin daha geç iyileşmesine neden olabilir.

TS ve UOS yöntemleri, yüksek sömürü gücüyle öne çıkmaktadır. Bu operatörler, yüksek uygunluk değerine sahip bireyleri daha yüksek olasılıkla seçerek bu bireylerin popülasyon içinde baskın hale gelmesini sağlar. Böylece algoritma, iyi çözümler etrafında yoğunlaşarak hızlı bir yakınsama eğilimi gösterir. Bununla birlikte, bu baskın seçim stratejisi, popülasyon içindeki genetik çeşitliliği azaltır ve algoritmanın erken dönemlerde yerel optimuma sıkışma riskini artırır. Bu durum özellikle karmaşık ve çok tepeli problemlerde performans kaybına neden olabilir.

BSS, YTS, KSDS ve BMHS yöntemleri, keşif ve sömürü arasında daha dengeli bir yapı sergilemiştir. Bu yöntemler, bir yandan iyi bireylerin seçilmesini desteklerken, diğer yandan zayıf bireylere de sınırlı düzeyde şans tanıyarak çeşitliliği koruma eğilimindedir. Bu denge sayesinde, algoritmalar hem istikrarlı bir yakınsama eğilimi gösterir hem de farklı çözüm alanlarını keşfetme kapasitesini kısmen korur. Özellikle uzun vadeli çalışmalarda ve zorlu optimizasyon problemlerinde bu yöntemler daha kararlı ve tutarlı performans sergilemiştir.

Tablo 4.2. Seçim operatörleri avantaj ve dezavantajları

Operatörler	Avantajları	Dezavantajları	Eğilim
UOS	• Uygulanması kolay bir tekniktir. • Bireylerin adil seçilme şansı. • Çeşitliliği korur.	• En iyi uygunluk değerine sahip bireyin çarkın büyük kısmını kapsamaması nedeniyle, diğer bireylerin seçim şansı azalır. • Sömürü yapmaya yatkındır.	• Sömürü eğilimli
TS	• Çeşitliliği korur. • Paralel olarak uygulanabilir. • Sıralama gerektirmez. • Turnuva boyutunda bir değişiklik, seçim baskısı değiştirilebilir.	• Turnuva boyutu büyüdükçe aynı bireyin seçilmesinden dolayı çeşitlilik kaybı olabilir.	• Küçük turnuva boyutu: keşif eğilimli, • Büyük turnuva boyutu: sömürü eğilimli
LSS/ÜSS	• Çeşitliliği korur. • Seçim baskısı parametrelerle kontrol edilebilir.	• En iyi bireyler arasında belirgin fark olmadığından daha yavaş yakınsamaya neden olabilir. • Yüksek hesaplama süresi. • Keşif yapmaya yatkındır.	• Keşif eğilimli
BSS	• UOS'nin sömürü özelliğini ve LSS'nin keşif özelliğini birleştirilerek dengeli seçim yapılmasını sağlar.	• Gruplama sabit bölümlere ayrılmıştır. Bu, tüm çözüm alanını verimli bir şekilde aramayı zorlaştırabilir. • Yerel minimumlarda takılma riski.	• Dengeli: • Elit grup: sömürü eğilimli • Alt grup: keşif eğilimli
YTS	• Yeterli seçim baskısı.	• Seçim baskısı için herhangi bir parametre ayarı bulunmamaktadır. • Yüksek hesaplama süresi.	• Dengeli

Tablo 4.2. Devam ediyor

KSDS (Önerilen)	- Önce keşif yapar, daha sonraki aşamalarda sömürüye başlar. - Değişken seçim baskısı.	Algoritmanın ileri aşamasında çeşitlilik metrikleri dikkate alınmadığından, bölünme oranı her durumda etkili olmayabilir.	- Dengeli: - Elit grup: sömürü eğilimli - Alt grup: keşif eğilimli
BMHS (Önerilen)	- Fuzzy kuralları doğrultusunda popülasyon içindeki çeşitlilik ve jenerasyon oranı durumlarına göre önce keşif yaparak başlar daha sonra sömürü yapmaya başlar. - Değişken seçim baskısı	- Hangi yöntemlerin hibrit olarak kullanılacağını optimize edilmesini gerektirir. - Yüksek hesaplama süresi	Dengeli

Ayrıca, Tablo 4.3, istatistiksel sonuçlara dayanarak gözlemlenen hibrit stratejilerin avantaj ve dezavantajlarının bir özetini sunmaktadır.

Tablo 4.3. Hibrit seçim operatörleri avantaj ve dezavantajları

Operatörler	Avantajları	Dezavantajları	Eğilim
DHS (Önerilen)	- Basit ve uygulaması kolay. - Öngörülebilir ve düzgün α artışı.	- Problem dinamiklerine uyarlanamaz. - Zamanlama uygun değilse, optimum olmayan performansa neden olabilir.	Dengeli
BMHS (Önerilen)	- Çeşitliliğe ve yinelemeye dayalı olarak α'yı uyarlar. - Belirsizliği ve doğrusal olmayan ilişkileri iyi yönetir.	- Üyelik fonksiyonlarının ve kurallarının ayarlanmasını gerektirir. - Ek hesaplama yükü.	Dengeli
ETHS (Önerilen)	- Hassas çeşitlilik ölçümü için Shannon entropisini kullanır. - Popülasyon çeşitliliğine dayalı dinamik α ayarlaması.	- Hesaplama açısından entropi hesaplaması. - Gürültüye duyarlıdır, normalizasyon gerektirir.	Dengeli
AHS (Önerilen)	- En iyi çözümdeki iyileştirmeye dayalı olarak α'yı ayarlar. - Düzenleştirme ve kararlılık sağlar.	- Geçmiş ve parametre ayarlaması gerektirir. - Küçük uygunluk değişikliklerine yavaş tepki verir.	Dengeli
ÖUHS (Önerilen)	- Her birey kendi α'sını taşır ve çeşitliliği mümkün kılar. - Erken yakınsamaya karşı daha dayanıklıdır.	- Genom ve mutasyon yönetimine karmaşıklık katar. - Analizi ve ayarlaması zordur.	Dengeli
QÖHS (Önerilen)	- Keşif/sömürü dengesini sağlayan α politikalarını öğrenir. - Durumlar ve α arasındaki karmaşık ilişkileri keşfedebilir.	- Parametre ayarlamasını öğrenmeyi gerektirir. - Yüksek hesaplama yükü ve yavaş ilk öğrenme.	Dengeli
ÇKHHS (Önerilen)	- UCB aracılığıyla keşif ve sömürünün verimli bir şekilde dengelenmesi. - Tam RL yöntemlerine kıyasla basittir.	- İlk keşif aşaması verimsiz olabilir. - Ödül kalitesine bağlıdır ve dikkatli kullanım gerektirir.	Dengeli

Mutasyon yöntemleri için gözlemlenen avantajlar, dezavantajlar ve keşif sömürü eğilimleri Tablo 4.4'te verilmiştir. Yüksek keşif eğilimi gösteren yöntemler arasında YDM, TÇM ve EM öne çıkmaktadır. YDM yöntemi, kromozom üzerindeki belirli bir alt dizinin başka bir konuma taşınmasıyla gerçekleştirilir. Bu işlem, bireyin yapısında büyük değişiklikler meydana getirerek, çözüm uzayında yeni bölgelerin keşfedilmesine olanak

tanır. TÇM operatörü, seçilen bir alt diziyi ters çevirerek kromozomun yapısında radikal değişiklikler oluşturur. Bu da genetik çeşitliliği artırır ve algoritmanın farklı çözüm alanlarını incelemesini sağlar. Benzer şekilde, EM operatörü de bir genin başka bir konuma yerleştirilmesiyle çalışır ve birey üzerinde yeni gen dizilimlerinin oluşmasına imkân tanır. Bu üç yöntemin ortak özelliği, algoritmanın erken dönemlerinde keşfi destekleyerek, daha geniş bir çözüm uzayında arama yapılmasını sağlamasıdır. Ancak bu yüksek keşif kapasitesi, iyi çözümlerden uzaklaşma ve yakınsama süresinin uzaması gibi dezavantajlara da yol açabilmektedir.

Sömürü ağırlıklı mutasyon yöntemleri özellikle KM ve BTÇM operatörlerinde görülmektedir. KM, rasgele seçilen alt dizinin karıştırılması ile uygulanır. Ancak, kesim bölgeleri arasında kalan bölge genellikle küçük seçildiğinde, çeşitlilik yetersiz kalır ve yapılan değişiklikler sadece mevcut çözümün çevresinde sınırlı kalır. Öte yandan BTÇM belirli bir alt dizinin ters çevrilmesiyle gerçekleştirilir. KM ile benzer şekilde, kesim bölgesi arasında kalan alt dizi küçük seçildiğinde, çeşitlilik yetersiz kalır ve sömürü yapmaya eğilimlidir.

DM yöntemi, keşif ve sömürü arasında dengeli bir yapı sergileyen mutasyon operatörü olarak öne çıkmaktadır. Bu yöntem, kromozom üzerindeki iki genin yerlerinin değiştirilmesiyle uygulanır. Gerçekleştirilen değişim, hem birey yapısında küçük ölçüde farklılık yaratır hem de yeni dizilimlerin ortaya çıkmasına imkân tanır. DM, hem mevcut iyi çözümlerden tamamen uzaklaşmadan yerel çevrede iyileştirme yapar, hem de genetik çeşitliliği belirli düzeyde koruyarak çözüm uzayının yeni bölgelerini keşfetme olasılığını açık tutar. Bu denge özelliği sayesinde, literatürde birçok çalışmada varsayılan mutasyon yöntemi olarak tercih edilmiştir.

Tablo 4.4. Mutasyon operatörleri avantaj ve dezavantajları

Operatörler	Avantajları	Dezavantajları	Eğilim
YDM	- Alt dizileri koruyarak başka konuma taşır. - GSP gibi problemlerde etkilidir.	- Hesaplama maliyeti yüksektir. - Rastgele yerleştirme çözümü bozabilir.	Keşif eğilimli
DM	- Uygulaması basit ve hızlı - GSP gibi sıralama problemlerinde temel yöntem	- Değişim çok küçük olabilir - Yeterli çeşitlilik sağlamayabilir.	Dengeli
TÇM	- Alt dizi yapısını korur - Yerel minimumlardan kaçmaya yardımcı olur.	Rastgele ters çevirme çözüm kalitesini olumsuz etkileyebilir.	Keşif eğilimli
BTÇM	- Uygulaması basit ve hızlı - Küçük yerel değişiklikler yapar	Küresel arama etkisi düşüktür.	Sömürü eğilimli

Tablo 4.4. Devam ediyor

KM	- Alt diziyi rastgele karıştırır. - Küçük bölgede rastgelelik sağlar	- Keşif gücü düşüktür. - Küresel optimuma ulaşmada yetersiz kalabilir.	Sömürü eğilimli
EM	- Genetik çeşitlilik sağlar. - Bazı problemlerde etkili.	- Önemli sıralamaları bozabilir - Yetersiz çözüm uzayı taraması olabilir.	Keşif eğilimli

Çaprazlama yöntemleri için gözlemlenen avantajlar, dezavantajlar ve keşif sömürü eğilimleri Tablo 4.5’te verilmiştir. Yüksek keşif oranına sahip yöntemler arasında AÇ, KBÇ, OX, MKÇ ve GAÇ operatörleri yer almaktadır. AÇ, bireyler arasında agresif şekilde farklı genetik yapıların birleştirilmesini sağladığından, çözüm uzayında çok geniş bir tarama gerçekleştirir. KBÇ, kenar bilgilerine odaklanarak benzersiz yollar oluşturur ve çeşitliliği son derece artırır. SÇ, ebeveynler arasındaki gen sıralarını yeni ve farklı bireyler üretmek için kullanırken, MKÇ genetik materyali daha rastlantısal ve çeşitli şekillerde aktardığı için, popülasyona yüksek düzeyde varyasyon kazandırır ve çözüm uzayının daha geniş alanlarının keşfedilmesine katkı sağlar. GAÇ ise greedy yapıyı geliştirerek hem yapı koruma hem de çeşitlilik üretme kapasitesini en üst seviyeye çıkarır. Bu yöntemler sayesinde algoritma, geniş bir çözüm uzayında farklı kombinasyonları keşfedebilir. Ancak yüksek keşif oranı, iyi çözümlere odaklanmayı zorlaştırdığı için yakınsama süresini uzatabilir ve kararlılığı azaltabilir.

Yüksek sömürüye sahip yöntemler arasında KEÇ, DÇ, GKEÇ ve kısmen de olsa SDÇ ile PDÇ yer almaktadır. DÇ, ebeveynlerden gelen genetik yapıları korumaya yönelik davranarak, iyi çözümlerin daha çok yayılmasını sağlar. KEÇ ise ebeveynlerin belirli bir bölümünü koruyarak çocuk üretir, bu da elit çözümlerden uzaklaşmayı engeller. GKEÇ, KEÇ’in geliştirilmiş bir versiyonu olup, sömürü gücünü daha da artırmıştır. SDÇ ve PDÇ da genetik yapının büyük kısmını koruduğundan, iyi bireylerin popülasyona hâkim olmasına neden olur. Bu operatörlerin ortak avantajı hızlı yakınsama ve elit bireylerin korunmasıdır. Ancak genetik çeşitliliğin azalması, algoritmanın erken jenerasyonlarda yerel minimumlarda sıkışmasına neden olabilir.

SYÇ operatörü, keşif ve sömürü arasında daha dengeli bir yapı sunmaktadır. SYÇ, ebeveynlerden bilgi alırken aynı zamanda yeni yapılar oluşturabilme kabiliyetine sahiptir. Bu sayede, algoritmanın hem mevcut iyi çözümlerden faydalanması hem de çözüm uzayının yeni kısımlarına yönelmesi mümkün olur. SDÇ ve PDÇ her ne kadar sömürü ağırlıklı olsa

da Şekil 3.16’da sunulan %16 civarındaki keşif oranlarıyla az da olsa çeşitlilik sağlarlar. Bu operatörler, özellikle orta jenerasyonlarda algoritmanın kararlılığını koruyarak hem çözüm kalitesi hem de çeşitliliği dengelemek adına faydalıdır.

Tablo 4.5. Çaprazlama operatörleri avantaj ve dezavantajları

Operatörler	Avantajları	Dezavantajları	Eğilim
KEÇ	- Ebeveynlerin genetik bilgilerini belli bir bölgede doğrudan aktarır. - Hem pozisyon hem de sıralama bilgisi korunur. - Permütasyon problemleri için uygundur (özellikle GSP)	- Yerleştirme çakışmalarının çözümü karmaşıktır. - Çeşitlilik oluşturma gücü sınırlıdır.	Sömürü eğilimli
DÇ	- Her gen yalnızca bir ebeveyn den gelir (özgün aktarım) - Pozisyon ve yapı ilişkileri korunur. - Tekrarlayan gen problemi olmaz	- Bazı döngüler çok kısa olabilir → düşük çeşitlilik - Her zaman etkili yeni birey üretmeyebilir.	Sömürü eğilimli
SÇ	- Kopyalanan alt dizinin dışındaki genler, ikinci ebeveynin sırasına göre yerleştirildiğinden sıralama bozulmaz. - Permütasyon koruyucudur.	- Kesilen alt dizi dışında kalan genler ikinci ebeveyn den kopyalandığı için çeşitli yapılar ortaya çıkabilir - Keşif yapmaya yatkındır	Keşif eğilimli
SDÇ	Alt diziden bağımsız olarak genler belirli pozisyonlara yerleştirildiğinden, yapı daha sabit kalır.	- Üretilen bireyler ebeveynlere çok benzeyebilir, çeşitlilik sınırlı olabilir. - Sömürü yapmaya yatkındır	Sömürü eğilimli
PDÇ	- Belirli genlerin pozisyonlarını ebeveyn den koruyarak aktarır. - Genetik yapıyı kısmen korur.	- Az pozisyon seçilirse çocuk birey ebeveynlere çok benzer olabilir - Sömürü yapmaya yatkındır	Sömürü eğilimli
MKÇ	Ebeveynlerden gelen genlerin belirli pozisyonlara göre aktarılması, çözüm yapısının belirli bölümlerinin korunmasını sağlar.	- Alt dizi çok küçükse, birey büyük ölçüde diğer ebeveyn den tamamlanır ve çeşitli yapılar ortaya çıkabilir. - Keşif yapmaya yatkındır	Keşif eğilimli
KBÇ	- Komşuluk ilişkilerini korur (GSP için mükemmel) - Daha iyi yol bağlantıları oluşturabilir.	- Veri yapısı karmaşıktır (komşuluk listesi gerekir) - Yüksek hesaplama süresi	Keşif eğilimli
GKEÇ	- KEÇ’e göre daha esnektir. - Sıralama ve pozisyon koruma daha dengelidir.	- Uygulaması KEÇ’ten karmaşık olabilir. - Uygulamada beklenen çeşitliliği her zaman sağlamayabilir.	Sömürü eğilimli
AÇ	- Sezgisel kurallarla birey üretir (ör. kısa mesafeyi seç) - En geniş keşif kabiliyetine sahiptir. - Çok sayıda alternatif çözüm üretir.	- Çok yavaş yakınsama - Kararsız çözüm üretimi	Keşif eğilimli
GAÇ	- AÇ’in eksiklerini iyileştirir. - Sezgisel kurallarla birey üretir (ör. kısa mesafeyi seç) - Hızlı yakınsama sağlar.	Yüksek hesaplama süresi	Keşif eğilimli
SYÇ	- Sezgisel kurallarla birey üretir (ör. kısa mesafeyi seç) - Hızlı yakınsama sağlar.	Uzun süreli çalışmalarda çeşitliliğin korunması için mutasyon ile desteklenmesi gerekir.	Dengeli

5. SONUÇ

Keşif ve sömürü arasındaki dengeyi iyileştirmek için seçim yöntemleri yeni alanların keşfedilmesinde hayati bir role sahiptir. UOS seçim yöntemi sadece sömürü üzerinde etkili iken, LSS seçim yöntemi keşif yapmaya yatkındır. Keşif ve sömürü dengesinin iyileştirilmesi amacıyla, KSDS seçim yöntemi önerildi. Popülasyon en iyiden kötüye sıralanır ve iki alt listeye bölünür: güçlü bireyler, sömürü adayları listesi olarak belirlenirken, daha zayıf bireyler ise keşif adayları listesini oluşturmaktadır. Seçim işleminin ilk aşamasında, adaylar keşif listesinden seçilmiş ve daha sonra sömürü listesinden adaylar keşif-sömürü katsayıları güncellenerek seçilmiştir. Bu süreç, popülasyon içindeki çeşitliliğin korunmasını ve en uygun bireylerin sonraki nesillere aktarılmasını sağlar. Ayrıca KSDS, YTS ve UOS yöntemlerin özellikleri bir araya getiren hibrit seçim yaklaşımı önerildi. Hibrit yöntemde keşif ve sömürü kontrolünü yönetmek amacıyla, parametresi için deterministik, bulanık mantık, entropi tabanlı, adaptif, kendini uyarlamalı, Q-öğrenme ve çok kollu haydut tabanlı güncelleme stratejileri önerilmiştir.

Önceki yapılan çalışmalar dikkate alınarak literatürdeki 11 simetrik ve 19 asimetrik TSPLIB veri seti üzerinde analiz edilmiştir. Operatörlerin birden fazla veri kümesindeki ortalama performansı, kritik fark diyagramları kullanılarak istatistiksel olarak değerlendirildi. Yapılan deneysel sonuçlarda seçim yöntemleri arasında en verimli yöntem QÖHS olurken, mutasyon operatörlerinde DM yöntemi olmuştur. Çaprazlama yöntemleri için GAÇ operatörünün diğer yöntemlere göre daha iyi performans gösterdiği gözlemlenmiştir.

Çelik üretiminde genişlik, kalınlık, sertlik, kılavuz çekme sıcaklığı, son işlem sıcaklığı ve sarma sıcaklığı gibi haddelenmiş levha parametreleri arasındaki nitelik farkını en aza indirmek amacıyla, problem asimetrik GSP olarak modellenmiştir. Önerilen operatörler, araştırmacılar tarafından gerçek dünya problemlerini ele almak için literatürde belgelenen mevcut operatörlere bir alternatif olarak kullanılabilir.

KAYNAKLAR

- [1] A. A. Muazu, A. S. Hashim and A. Sarlan, "Review of nature inspired metaheuristic algorithm selection for combinatorial t-way testing," *IEEE Access*, vol. 10, p. 27404–27431, 2022.
- [2] R. Matai, S. P. Singh and M. L. Mittal, "Traveling salesman problem: an overview of applications, formulations, and solution approaches," *Traveling salesman problem, theory and applications*, vol. 1, p. 1–25, 2010.
- [3] C. Cariou, L. Moiroux-Arvis, F. Pinet and J.-P. Chanet, "Evolutionary algorithm with geometrical heuristics for solving the Close Enough Traveling Salesman Problem: Application to the trajectory planning of an Unmanned Aerial Vehicle," *Algorithms*, vol. 16, p. 44, 2023.
- [4] J. Stork, A. E. Eiben and T. Bartz-Beielstein, "A new taxonomy of global optimization algorithms," *Natural Computing*, p. 1–24, 2020.
- [5] H. M. Pandey, A. Chaudhary and D. Mehrotra, "A comparative review of approaches to prevent premature convergence in GA," *Applied Soft Computing*, vol. 24, p. 1047–1077, 2014.
- [6] T. Back, "Selective pressure in evolutionary algorithms: A characterization of selection mechanisms," in *Proceedings of the first IEEE conference on evolutionary computation. IEEE World Congress on Computational Intelligence*, 1994.
- [7] D. Gupta and S. Ghafir, "An overview of methods maintaining diversity in genetic algorithms," *International journal of emerging technology and advanced engineering*, vol. 2, p. 56–60, 2012.
- [8] Y. Yang, Y. Yang and B. Liao, "Dual population multi-objective evolutionary algorithm for dynamic co-transformations," *Evolutionary Intelligence*, vol. 17, p. 3269–3289, 2024.

- [9] M. Pulat and İ. D. Kocakoç, "Gezgin satıcı probleminin genetik algoritmalar kullanarak çözümünde çaprazlama operatörlerinin örnek olaylar bazlı incelenmesi," İzmir İktisat Dergisi, vol. 34, p. 225–243, 2019.
- [10] K. Puljić and R. Manger, "Comparison of eight evolutionary crossover operators for the vehicle routing problem," Mathematical Communications, vol. 18, p. 359–375, 2013.
- [11] O. Al Jadaan, L. Rajamani and C. R. Rao, "Improved Selection Operator for GA.," Journal of Theoretical & Applied Information Technology, vol. 4, 2008.
- [12] N. M. Razali and J. Geraghty, "Genetic algorithm performance with different selection strategies in solving TSP," in Proceedings of the world congress on engineering, 2011.
- [13] H. M. Pandey, "Performance evaluation of selection methods of genetic algorithm and network security concerns," Procedia Computer Science, vol. 78, p. 13–18, 2016.
- [14] A. Shukla, H. M. Pandey and D. Mehrotra, "Comparative review of selection techniques in genetic algorithm," in 2015 international conference on futuristic trends on computational analysis and knowledge management (ABLAZE), 2015.
- [15] J. H. Holland, "Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence," MIT press, 1992.
- [16] A. Hussain and Y. S. Muhammad, "Trade-off between exploration and exploitation with genetic algorithm using a novel selection operator," Complex & intelligent systems, vol. 6, p. 1–14, 2020.
- [17] S. Yasir Abbas Naqvi and Z. Iqbal, "To improve the performance of genetic algorithms by using a novel selection operator," Journal of Statistical Computation and Simulation, vol. 93, p. 3067–3081, 2023.

- [18] A. Hussain, S. Riaz, M. S. Amjad and E. u. Haq, "Genetic algorithm with a new round-robin based tournament selection: Statistical properties analysis," Plos one, vol. 17, p. e0274456, 2022.
- [19] T. Back, "Evolutionary algorithms in theory and practice: evolution strategies, evolutionary programming, genetic algorithms", Oxford university press, 1996.
- [20] B. A. Julstrom, "It's all the same to me: Revisiting rank-based probabilities and tournaments," in Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406), 1999.
- [21] S. Prayudani, A. Hizriadi, E. B. Nababan and S. Suwilo, "Analysis effect of tournament selection on genetic algorithm performance in traveling salesman problem (TSP)," in Journal of Physics: Conference Series, 2020.
- [22] J. E. Baker, "Reducing bias and inefficiency in the selection algorithm," in Proceedings of the second international conference on genetic algorithms, 1987.
- [23] K. Jebari and M. Madiafi, "Selection methods for genetic algorithms," International Journal of Emerging Sciences, vol. 3, p. 333–344, 2013.
- [24] H. Mühlenbein and D. Schlierkamp-Voosen, "Predictive models for the breeder genetic algorithm I. Continuous parameter optimization," Evolutionary computation, vol. 1, p. 25–49, 1993.
- [25] T. Blickle and L. Thiele, "A comparison of selection schemes used in evolutionary algorithms," Evolutionary Computation, vol. 4, p. 361–394, 1996.
- [26] J. E. Baker, "Adaptive selection methods for genetic algorithms," in Proceedings of the first international conference on genetic algorithms and their applications, 2014.
- [27] Z. Michalewicz, "Genetic algorithms+data structures= evolution programs," Springer Science & Business Media, 2013.

- [28] N. Lukkananuruk and S. Hengpraproh, "The Distance-Based Selection Technique for Crossover in Genetic Algorithm," in 2022 19th International Joint Conference on Computer Science and Software Engineering (JCSSE), 2022.
- [29] S. Kirkpatrick, C. D. Gelatt Jr and M. P. Vecchi, "Optimization by simulated annealing," *science*, vol. 220, p. 671–680, 1983.
- [30] N. Saini, "Review of selection methods in genetic algorithms," *International Journal of Engineering and Computer Science*, vol. 6, p. 22261–22263, 2017.
- [31] S. L. Yadav and A. Sohal, "Comparative study of different selection techniques in genetic algorithm," *International Journal of Engineering, Science and Mathematics*, vol. 6, p. 174–180, 2017.
- [32] K. A. De Jong, "An analysis of the behavior of a class of genetic adaptive systems," University of Michigan, 1975.
- [33] C. Chudasama, S. M. Shah and M. Panchal, "Comparison of parents selection methods of genetic algorithm for TSP," in *International conference on computer communication and networks CSI-COMNET-2011, Proceedings*, 2011.
- [34] F. Yu, X. Fu, H. Li and G. Dong, "Improved roulette wheel selection-based genetic algorithm for TSP," in *2016 International conference on network and information systems for computers (ICNISC)*, 2016.
- [35] E.-u. Haq, I. Ahmad, A. Hussain and I. M. Almanjahie, "A novel selection approach for genetic algorithms for global optimization of multimodal continuous functions," *Computational intelligence and neuroscience*, vol. 2019, p. 8640218, 2019.
- [36] M. F. Azeem and A. M. Saad, "Modified queen bee evolution based genetic algorithm for tuning of scaling factors of fuzzy knowledge base controller," in *Proceedings of the IEEE INDICON 2004. First India Annual Conference*, 2004., 2004.

- [37] R. Abd Rahman, R. Ramli, Z. Jamari and K. R. Ku-Mahamud, "Evolutionary Algorithm with Roulette-Tournament Selection for Solving Aquaculture Diet Formulation," *Mathematical Problems in Engineering*, vol. 2016, p. 3672758, 2016.
- [38] M. Kaya, "The effects of two new crossover operators on genetic algorithm performance," *Applied soft computing*, vol. 11, p. 881–890, 2011.
- [39] H.-L. Wang, Q. Yang, X.-D. Gao and Z.-Y. Lu, "Population-Level Hybridization between Roulette Wheel Selection and Tournament Selection for Particle Swarm Optimization," in *2024 11th International Conference on Machine Intelligence Theory and Applications (MiTA)*, 2024.
- [40] M. K. Rafsanjani and S. Eskandari, "A new combinational selection operator in genetic algorithm," *Indian Journal of Science and Technology*, vol. 5, 2012.
- [41] M. K. Rafsanjani and S. Eskandari, "The effect of a new generation based sequential selection operator on the performance of genetic algorithm," *Indian Journal of Science and Technology*, vol. 5, p. 3758–3761, 2012.
- [42] O. Abdoun and J. Abouchabaka, "A comparative study of adaptive crossover operators for genetic algorithms to resolve the traveling salesman problem," *arXiv preprint arXiv:1203.3097*, 2012.
- [43] A. Hussain, Y. S. Muhammad, M. Nauman Sajid, I. Hussain, A. Mohamd Shoukry and S. Gani, "Genetic algorithm for traveling salesman problem with modified cycle crossover operator," *Computational intelligence and neuroscience*, vol. 2017, 2017.
- [44] A. Hussain, Y. S. Muhammad and M. N. Sajid, "An improved genetic algorithm crossover operator for traveling salesman problem," *Turkish Journal of Mathematics and Computer Science*, vol. 9, p. 1–13, 2018.
- [45] A. Hussain and I. Ahmad, "Development a new crossover scheme for traveling salesman problem by aid of genetic algorithm," *Int. J. Intell. Syst. Appl*, vol. 11, p. 46–52, 2019.

- [46] S. Akter, N. Nahar, M. ShahadatHossain and K. Andersson, "A new crossover technique to improve genetic algorithm and its application to TSP," in 2019 International Conference on Electrical, Computer and Communication Engineering (ECCE), 2019.
- [47] M. A. Al-Omeer and Z. H. Ahmed, "Comparative study of crossover operators for the MTSP," in 2019 International Conference on Computer and Information Sciences (ICCIS), 2019.
- [48] M. Kuroda, K. Yamamori, M. Munetomo, M. Yasunaga and I. Yoshihara, "Development of a novel crossover of hybrid genetic algorithms for large-scale traveling salesman problems," *Artificial Life and Robotics*, vol. 15, p. 547–550, 2010.
- [49] A. Hussain, Y. S. Muhammad and M. N. Sajid, "A simulated study of genetic algorithm with a new crossover operator using traveling salesman problem," *Punjab University Journal of Mathematics*, vol. 51, 2020.
- [50] Z. H. Ahmed, "Adaptive sequential constructive crossover operator in a genetic algorithm for solving the traveling salesman problem," *International Journal of Advanced Computer Science and Applications*, vol. 11, 2020.
- [51] Z. H. Ahmed, "Genetic algorithm with comprehensive sequential constructive crossover for the travelling salesman problem," *International Journal of Advanced Computer Science and Applications*, vol. 11, 2020.
- [52] R. T. Bye, M. Gribbestad, R. Chandra and O. L. Osen, "A comparison of ga crossover and mutation methods for the traveling salesman problem," in *Innovations in Computational Intelligence and Computer Vision: Proceedings of ICICV 2020*, 2021.
- [53] X.-A. Dou, Q. Yang, X.-D. Gao, Z.-Y. Lu and J. Zhang, "A Comparative Study on Crossover Operators of Genetic Algorithm for Traveling Salesman Problem," in 2023 15th International Conference on Advanced Computational Intelligence (ICACI), 2023.

- [54] H. Bennaceur and E. Alanzi, "Genetic algorithm for the travelling salesman problem using enhanced sequential constructive crossover operator," *International Journal of Computer Science and Security (IJCSS)*, vol. 11, p. 42, 2017.
- [55] G. Tao and Z. Michalewicz, "Inver-over operator for the TSP," in *International Conference on Parallel Problem Solving from Nature*, 1998.
- [56] G. Üçoluk, "Genetic algorithm solution of the TSP avoiding special crossover and mutation," *Intelligent Automation & Soft Computing*, vol. 8, p. 265–272, 2002.
- [57] L.-Y. Wang, J. Zhang and H. Li, "An improved genetic algorithm for tsp," in *2007 International Conference on Machine Learning and Cybernetics*, 2007.
- [58] Z. H. Ahmed, "Genetic algorithm for the traveling salesman problem using sequential constructive crossover operator," *International Journal of Biometrics & Bioinformatics (IJBB)*, vol. 3, p. 96, 2010.
- [59] S. B. Dalkilic, A. Özgür and H. Erdem, "A Comparison of Crossover Operators in Genetic Algorithms for Steel Domain," in *Steel 4.0: Digitalization in Steel Industry*, Springer, 2024, p. 103–123.
- [60] F. Su, F. Zhu, Z. Yin, H. Yao, Q. Wang and W. Dong, "New crossover operator of genetic algorithms for the TSP," in *2009 International Joint Conference on Computational Sciences and Optimization*, 2009.
- [61] D. Satyananda, "Modification of Crossover Operator on GA Application for TSP," in *Proceeding of International Conference On Research, Implementation And Education Of Mathematics And Sciences*, 2015.
- [62] P. Zhang, J. Wang, Z. Tian, S. Sun, J. Li and J. Yang, "A genetic algorithm with jumping gene and heuristic operators for traveling salesman problem," *Applied Soft Computing*, vol. 127, p. 109339, 2022.

- [63] P. D. Thanh, H. T. T. Binh and B. T. Lam, "New mechanism of combination crossover operators in genetic algorithm for solving the traveling salesman problem," *Advances in Intelligent Systems and Computing*, vol. 326, p. 367–379, 2015.
- [64] A. B. A. Hassanat and E. Alkafaween, "On enhancing genetic algorithms using new crossovers," *International Journal of Computer Applications in Technology*, vol. 55, p. 202–212, 2017.
- [65] B. Koohestani, "A crossover operator for improving the efficiency of permutation-based genetic algorithms," *Expert Systems with Applications*, vol. 151, p. 113381, 2020.
- [66] I. H. Khan, "Assessing different crossover operators for travelling salesman problem," *International Journal of Intelligent Systems and Applications*, vol. 7, p. 19–25, 2015.
- [67] H. Ismkhan and K. Zamanifar, "Study of some recent crossovers effects on speed and accuracy of genetic algorithm, using symmetric travelling salesman problem," *arXiv preprint arXiv:1504.02590*, 2015.
- [68] H. Ismkhan and K. Zamanifar, "Developing improved greedy crossover to solve symmetric traveling salesman problem," *arXiv preprint arXiv:1209.5339*, 2012.
- [69] M. Uray, S. Wintersteller and S. Huber, "CSRX: A novel Crossover Operator for a Genetic Algorithm applied to the Traveling Salesperson Problem," *arXiv preprint arXiv:2303.12447*, 2023.
- [70] A. Özgür, Y. Uygun and M.-T. Hütt, "A review of planning and scheduling methods for hot rolling mills in steel production," *Computers & Industrial Engineering*, vol. 151, p. 106606, 2021.
- [71] F. Su, L. Kong, H. Wang and Z. Wen, "Modeling and application for rolling scheduling problem based on TSP," *Applied Mathematics and Computation*, vol. 407, p. 126333, 2021.

- [72] E. Balas, "The prize collecting traveling salesman problem," *Networks*, vol. 19, p. 621–636, 1989.
- [73] E. D. Kosiba, J. R. Wright and A. E. Cobbs, "Discrete event sequencing as a traveling salesman problem," *Computers in Industry*, vol. 19, p. 317–327, 1992.
- [74] L. Lopez, M. W. Carter and M. Gendreau, "The hot strip mill production scheduling problem: A tabu search approach," *European Journal of Operational Research*, vol. 106, p. 317–335, 1998.
- [75] L. Tang, J. Liu, A. Rong and Z. Yang, "A multiple traveling salesman problem model for hot rolling scheduling in Shanghai Baoshan Iron & Steel Complex," *European Journal of Operational Research*, vol. 124, p. 267–282, 2000.
- [76] T. Zhang, W. A. Chaovalitwongse, Y.-J. Zhang and P. M. Pardalos, "The hot-rolling batch scheduling method based on the prize collecting vehicle routing problem," *Journal of Industrial and Management Optimization*, vol. 5, p. 749–765, 2009.
- [77] L. Tang, X. Zhang and Q. Guo, "Two hybrid metaheuristic algorithms for hot rolling scheduling," *ISIJ international*, vol. 49, p. 529–538, 2009.
- [78] Y. Xue, N. Sun, J. Fei and M. Hua, "Optimum hot rolling plan with modified discrete particle swarm optimization," in *2010 IEEE International Symposium on Intelligent Control*, 2010.
- [79] J. Zhao, Q. Liu, W. Wang, Z. Wei and P. Shi, "A parallel immune algorithm for traveling salesman problem and its application on cold rolling scheduling," *Information Sciences*, vol. 181, p. 1212–1223, 2011.
- [80] T. Yang, S. Zhang and C. Li, "A multi-objective hyper-heuristic algorithm based on adaptive epsilon-greedy selection," *Complex & Intelligent Systems*, vol. 7, p. 765–780, 2021.

- [81] Ş. B. Dalkılıç, A. Özgür and H. Erdem, "Balancing exploration and exploitation in genetic algorithm optimization: a novel selection operator," *Evolutionary Intelligence*, vol. 18, p. 40, 2025.
- [82] Y. Zhang, G. Chen, L. Cheng, Q. Wang and Q. Li, "Methods to balance the exploration and exploitation in differential evolution from different scales: A survey," *Neurocomputing*, vol. 561, p. 126899, 2023.
- [83] G. Karafotias, M. Hoogendoorn and Á. E. Eiben, "Parameter control in evolutionary algorithms: Trends and challenges," *IEEE Transactions on Evolutionary Computation*, vol. 19, p. 167–187, 2014.
- [84] D. E. Goldberg, "A note on Boltzmann tournament selection for genetic algorithms and population-oriented simulated annealing," *Complex Systems*, vol. 4, p. 445–460, 1990.
- [85] M. De la Maza and B. Tidor, "Boltzmannn weighted selection improves performance of genetic algorithms," 1991.
- [86] A. Slowik, "Fuzzy control of trade-off between exploration and exploitation properties of evolutionary algorithms," in *International Conference on Hybrid Artificial Intelligence Systems*, 2011.
- [87] M. Affenzeller, "Segregative Genetic Algorithms (SEGA): A hybrid superstructure upwards compatible to genetic algorithms for retarding premature convergence.," *Int. J. Comput. Syst. Signal*, vol. 2, p. 16–30, 2001.
- [88] G. Rudolph and J. Sprave, "A cellular genetic algorithm with self-adjusting acceptance threshold," in *First International Conference on Genetic Algorithms in Engineering Systems: Innovations and Applications*, 1995.
- [89] T. Bäck, "Self-adaptation in genetic algorithms," in *Proceedings of the first european conference on artificial life*, 1992.

- [90] J. Smith and T. C. Fogarty, "Self adaptation of mutation rates in a steady state genetic algorithm," in Proceedings of IEEE international conference on evolutionary computation, 1996.
- [91] T. Bäck and M. Schütz, "Intelligent mutation rate control in canonical genetic algorithms," in International Symposium on Methodologies for Intelligent Systems, 1996.
- [92] R. K. Ursem, "Diversity-guided evolutionary algorithms," in International conference on parallel problem solving from nature, 2002.
- [93] S.-H. Liu, M. Mernik and B. R. Bryant, "To explore or to exploit: An entropy-driven approach for evolutionary algorithms," International journal of knowledge-based and intelligent engineering systems, vol. 13, p. 185–206, 2009.
- [94] T. N. Huynh, D. T. T. Do and J. Lee, "Q-Learning-based parameter control in differential evolution for structural optimization," Applied Soft Computing, vol. 107, p. 107464, 2021.
- [95] H. Zhang, J. Sun, T. Bäck, Q. Zhang and Z. Xu, "Controlling sequential hybrid evolutionary algorithm by q-learning," IEEE Computational Intelligence Magazine, vol. 18, no. 1, p. 84–103, 2023.
- [96] Á. Fialho, L. Da Costa, M. Schoenauer and M. Sebag, "Analyzing bandit-based adaptive operator selection mechanisms," Annals of Mathematics and Artificial Intelligence, vol. 60, p. 25–64, 2010.
- [97] L. Flores-Torres, M. Quiroz-Castellanos, O. Ramos-Figueroa and S. Amador-Larrea, "An experimental approach to design deterministic and adaptive control schemes for grouping genetic algorithms," Neural Computing and Applications, p. 1–30, 2025.
- [98] C. E. Shannon, "A mathematical theory of communication," The Bell system technical journal, vol. 27, p. 379–423, 1948.
- [99] A. E. Eiben and J. E. Smith, "Introduction to evolutionary computing," 2015.







- [100] C. J. C. H. Watkins and P. Dayan, "Q-learning," *Machine learning*, vol. 8, p. 279–292, 1992.
- [101] Á. Fialho, R. Ros, M. Schoenauer and M. Sebag, "Comparison-based adaptive strategy selection with bandits in differential evolution," p. 194–203, 2010.
- [102] P. Auer, N. Cesa-Bianchi and P. Fischer, "Finite-time analysis of the multiarmed bandit problem," *Machine learning*, vol. 47, p. 235–256, 2002.
- [103] S. B. Dalkılıç, A. Özgür and H. Erdem, "Comparison of Genetic Crossover Operators for Traveling Salesman Problem.," *Gazi University Journal of Science*, vol. 38, 2025.
- [104] D. E. Goldberg and R. Lingle, "Alleles, loci, and the traveling salesman problem," in *Proceedings of the first international conference on genetic algorithms and their applications*, 2014.
- [105] P. Larranaga, C. M. H. Kuijpers, R. H. Murga, I. Inza and S. Dizdarevic, "Genetic algorithms for the travelling salesman problem: A review of representations and operators," *Artificial intelligence review*, vol. 13, p. 129–170, 1999.
- [106] I. M. Oliver, D. Smith and J. R. C. Holland, "Study of permutation crossover operators on the traveling salesman problem," in *Genetic algorithms and their applications: proceedings of the second International Conference on Genetic Algorithms: July 28-31, 1987 at the Massachusetts Institute of Technology, Cambridge, MA, 1987*.
- [107] D. Lawrence, "Handbook of genetic algorithms," Van Nostrand Reinhold, 1991.
- [108] G. Syswerda, "Schedule optimization using genetic algorithms," *Handbook of genetic algorithms*, 1991.
- [109] L. D. Whitley, T. Starkweather and D. Fuquay, "Scheduling problems and traveling salesmen: The genetic edge recombination operator," in *ICGA*, 1989.









- [110] H. Mühlenbein, M. Gorges-Schleuter and O. Krämer, "Evolution algorithms in combinatorial optimization," *Parallel computing*, vol. 7, p. 65–85, 1988.
- [111] Z. Tao, "TSP Problem solution based on improved Genetic Algorithm," in *2008 Fourth International Conference on Natural Computation*, 2008.
- [112] J. Grefenstette, R. Gopal, B. Rosmaita and D. Van Gucht, "Genetic algorithms for the traveling salesman problem," in *Proceedings of the first International Conference on Genetic Algorithms and their Applications*, 2014.
- [113] S. Samanta, A. De and S. Singha, "Solution of traveling salesman problem on scx based selection with performance analysis using genetic algorithm," *International Journal of Engineering Science and Technology*, vol. 3, 2011.
- [114] J. Derrac, S. García, D. Molina and F. Herrera, "A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms," *Swarm and Evolutionary Computation*, vol. 1, p. 3–18, 2011.
- [115] A. Özgür, "Classifier Selection in Resource Limited Hardware: Decision Analysis and Resolution Approach," *Journal of Intelligent Systems: Theory and Applications*, vol. 4, p. 37–42, 2021.
- [116] J. Demšar, "Statistical comparisons of classifiers over multiple data sets," *Journal of Machine learning research*, vol. 7, p. 1–30, 2006.
- [117] R. W. Morrison and K. A. De Jong, "Measurement of population diversity," in *International conference on artificial evolution (evolution artificielle)*, 2001.
- [118] K. Hussain, M. N. M. Salleh, S. Cheng and Y. Shi, "On the exploration and exploitation in popular swarm-based metaheuristic algorithms," *Neural Computing and Applications*, vol. 31, p. 7665–7683, 2019.
- [119] G. Reinelt, "Tsplib95," *Interdisziplinäres Zentrum für Wissenschaftliches Rechnen (IWR), Heidelberg*, vol. 338, p. 1–16, 1995.









- [120] M. Friedman, "A comparison of alternative tests of significance for the problem of m rankings," *The annals of mathematical statistics*, vol. 11, p. 86–92, 1940.
- [121] A. Benavoli, G. Corani and F. Mangili, "Should we really use post-hoc tests based on mean-ranks?," *The Journal of Machine Learning Research*, vol. 17, p. 152–161, 2016.
- [122] D. C. Merten, "Improved Steel Production Planning through Data Analysis and Optimization," 2023.
- [123] G. Gopal, R. Kumar, I. Jawa and N. Kumar, "Enhanced order crossover for permutation problems," *International Journal of Innovative Research in Science, Engineering and Technology*, vol. 4, 2015.









EKLER

EK 1: Seçilim Operatörlerinin Jenerasyon-Uygunluk Performansları









EK 2: Seçilim Operatörlerinin Karşılaştırılması

Veri Seti	Sonuçlar	TS	UOS	LSS	ÜSS	BSS	YTS	KSDS	BMHS
gr21	Minimum	2707.00 (%0.00)	2707.00 (%0.00)	2707.00 (%0.00)	2707.00 (%0.00)	2707.00 (%0.00)	2707.00 (%0.00)	2707.00 (%0.00)	2707.00 (%0.00)
	Ortalama	2939.17 (%8.57)	2827.50 (%4.45)	2823.40 (%4.29)	2824.37 (%4.33)	2844.90 (%5.09)	2828.57 (%4.49)	2807.27 (%3.70)	2799.83 (%3.42)
	SD	175.28	146.52	152.69	151.78	156.08	148.60	149.77	140.42
	t-test (p değeri)	-3.34 (0.001)	-0.73 (0.46)	-0.61 (0.54)	-0.63 (0.52)	-1.15 (0.25)	-0.79 (0.42)	-0.19 (0.84)	-
	Süre(s)	2.907	3.273	3.804	3.015	3.148	4.840	2.483	27.68
fri26	Minimum	995 (%6.18)	937 (%0.00)	937 (%0.00)	937 (%0.00)	953 (%1.70)	937 (%0.00)	937 (%0.00)	937 (%0.00)
	Ortalama	1046.60 (%11.69)	1005.07 (%7.26)	1016.77 (%8.51)	1014.73 (%8.29)	1000.37 (%6.76)	1018.07 (%8.65)	991.93 (%5.86)	988.30 (%5.47)
	SD	37.28	39.92	48.57	45.31	42.95	27.06	30.78	28.96
	t-test (p değeri)	-6.64 (1.13e-08)	-1.83 (0.07)	-2.71 (0.008)	-2.64 (0.01)	-1.25 (0.21)	-3.00 (0.003)	-0.46 (0.64)	-
	Süre(s)	3.444	3.129	3.115	3.184	3.097	5.075	2.668	29.92
bayg29	Minimum	1687 (%4.78)	1618 (%0.49)	1610 (%0.00)	1615 (%0.31)	1627 (%1.05)	1627 (%1.05)	1635 (%1.55)	1620 (%0.62)
	Ortalama	1786.80 (%10.98)	1733.67 (%7.68)	1734.10 (%7.70)	1770.30 (%9.95)	1733.83 (%7.69)	1768.00 (%9.81)	1709.97 (%6.20)	1708.53 (%6.12)
	SD	45.43	71.92	78.28	90.13	75.86	55.53	61.00	58.25
	t-test (p değeri)	-5.70 (4.16e-07)	-1.46 (0.14)	-1.41 (0.16)	-3.09 (0.002)	-1.42 (0.15)	-3.01 (0.003)	-0.09 (0.92)	-
	Süre(s)	3.256	3.264	3.281	3.350	3.255	5.338	2.824	24.65

Veri Seti	Sonuçlar	TS	UOS	LSS	ÜSS	BSS	YTS	KSDS	BMHS
dantzig42	Minimum	840 (% 20.17)	775 (%10.87)	789 (%12.87)	753 (%7.72)	757 (%8.29)	760 (%8.72)	773 (%10.58)	730 (%4.43)
	Ortalama	926.33 (%32.52)	858.60 (%22.83)	878.73 (%25.71)	870.10 (%24.49)	841.73 (%20.41)	868,87 (%20.30)	840.53 (%20.24)	821.33 (%17.50)
	SD	56.97	56.33	57.92	63.46	51.12	42.12	40.80	53.45
	t-test (p değeri)	-7.23 (1.16e-09)	-2.58 (0.01)	-3.92 (0.0002)	-3.16 (0.002)	-1.48 (0.14)	-3.13 (0.002)	-1.51 (0.13)	-
	Süre(s)	3.972	3.917	4.063	4.485	3.844	5.514	4.567	28.32
eil51	Minimum	551.63 (%29.49)	485.55 (%13.98)	490.45 (%15.13)	465.35 (%9.23)	476.19 (%11.78)	507.09 (%19.03)	471.54 (%10.68)	472.69 (%10.96)
	Ortalama	585.81 (%37.51)	544.99 (%27.93)	564.43 (% 32.49)	562.45 (%32.03)	529.33 (%24.25)	556.57 (%30.65)	520.88 (%22.27)	516.48 (%21.24)
	SD	19.66	31.97	36.83	38.52	25.69	25.66	26.39	27.84
	t-test (p değeri)	-10.95 (9.61e-16)	-3.61 (0.0006)	-5.59 (6.35e-07)	-5.20 (2.63e-06)	-1.82 (0.07)	-5.41 (1.24e-06)	-0.61 (0.53)	-
	Süre(s)	4.429	4.948	4.593	4.719	4.127	4.826	4.529	35.37
berlin52	Minimum	9177.09 (%21.67)	8567.87 (%13.60)	9157.18 (%21.41)	8915.288 (%18.20)	8344.99 (%10.64)	8980.04 (%19.06)	8415.35 (%11.57)	8401.48 (%11.39)
	Ortalama	10392.60 (%37.79)	9695.66 (%28.55)	10040.31 (%33.12)	9992.47 (%32.49)	9584.22 (%27.07)	9844.99 (%30.53)	9174.13 (%21.64)	9355.02 (%24.03)
	SD	618.47	681.43	513.86	606.93	551.01	444.32	465.04	512.21
	t-test (p değeri)	-6.95 (3.44e-09)	-2.15 (0.03)	-5.08 (4.10e-06)	-4.32 (6.13e-05)	-1.64 (0.10)	-3.64 (0.0005)	1.40 (0.16)	-
	Süre(s)	5.088	4.652	5.198	5.054	4.676	6.126	4.634	32.33
pr76	Minimum	165558.29 (%53.06)	163120.55 (%50.81)	164383.4 (%51.98)	174926.3787 (%61.73)	149184.53 (%37.93)	160514.97 (%48.40)	150568.29 (%39.21)	151109.2 (%39.71)
	Ortalama	189275.32 (%74.99)	182867.43 (%69.07)	189281.60 (%75.00)	196083.25 (%81.29)	171893.67 (%58.92)	181185.23 (%67.51)	165121.21 (%52.66)	166639.52 (%54.06)
	SD	10549.43	14090.05	12384.69	11715.42	15352.64	7988.87	8009.62	9822.11
	t-test (p değeri)	-8.45 (1.05e-11)	-5.08 (4.08e-06)	-7.71 (1.85e-10)	-10.37 (7.89e-15)	-1.55 (0.12)	-5.18 (2.83e-06)	0.64 (0.52)	-
	Süre(s)	5.88	7.448	6.767	8.171	5.411	7.092	5.835	41.93

Veri Seti	Sonuçlar	TS	UOS	LSS	ÜSS	ÜSS	YTS	KSDS	BMHS
lin105	Minimum	32233.18 (%124.16)	28604.85 (%98.93)	32274.56 (%124.45)	34812.72 (%142.10)	28054.18 (%95.10)	28820.33 (%100.43)	25073.20 (%74.37)	24397.55 (%69.67)
	Ortalama	35192.73 (%144.75)	33667.38 (%134.14)	36775.43 (%155.75)	39864.66 (%177.24)	32009.58 (%122.61)	33010.41 (%129.57)	28706.59 (%99.64)	28700.73 (%99.60)
	SD	1813.67	2138.51	2157.76	2514.38	3817.56	1654.53	1662.50	1966.06
	t-test (p değeri)	-13.07 (6.21e-19)	-9.20 (6.04e-13)	-14.89 (1.75e-21)	-18.83 (2.15e-26)	-4.14 (0.0001)	-7.80 (1.29e-10)	-0.01 (0.99)	-
	Süre(s)	7.616	7.824	8.171	9.377	7.614	12.837	8.912	58.58
pr226	Minimum	471646.1 (%486.85)	464855.33 (%478.40)	554501.68 (%589.94)	645132.25 (%702.71)	423470.62 (%426.90)	469668.76 (%484.39)	358353.02 (%345.88)	379063.4 (%371.65)
	Ortalama	508790.65 (%533.06)	513179.83 (%538.52)	615526.01 (%665.87)	735117.54 (%814.67)	488852.30 (%508.25)	505636.00 (%529.14)	409711.24 (%409.78)	431439.16 (%436.82)
	SD	23862.13	28212.87	30068.88	57191.11	55112.80	21110.57	21482.51	22769.33
	t-test (p değeri)	-12.62 (2.72e-18)	-12.14 (1.44e-17)	-26.28 (6.57e-34)	-26.56 (3.70e-34)	-5.18 (2.86e-06)	-13.05 (6.51e-19)	3.73 (0.0004)	-
	Süre(s)	19.368	20.406	22.919	25.918	19.598	24.091	20.109	90.59
a280	Minimum	11992.69 (%365.01)	11804.54 (%357.71)	13551.3 (%425.44)	15896.7 (%516.38)	11245.93 (%336.05)	11428.33 (%343.13)	10227.79 (%296.57)	10464.99 (%305.77)
	Ortalama	12809.33 (%396.67)	12723.35 (%393.34)	15010.78 (%482.03)	17904.94 (%594.25)	12017.34 (%365.96)	12720.82 (%393.24)	10878.85 (%321.82)	11281.53 (%337.43)
	SD	432.94	403.88	497.53	989.47	843.16	356.62	357.16	319.25
	t-test (p değeri)	-15.29 (5.13e-22)	-15.08 (9.87e-22)	-33.97 (5.56e-40)	-34.30 (3.23e-40)	-4.39 (4.78e-05)	-13.50 (1.48e-19)	4.52 (3.02e-05)	-
	Süre(s)	27.926	29.293	33.449	38.145	26.809	31.918	29.763	113.10
att532	Minimum	647320.45 (%2238.07)	657802.53 (%2275.93)	814338.2 (%2841.33)	910225.7 (%3187.67)	614838.69 (%2120.75)	655376.93 (%2267.17)	554664.61 (%1903.4)	575233.17 (%1977.70)
	Ortalama	681883.94 (%2362.91)	695476.89 (%2412.01)	874440.43 (%3058.42)	1006208.12 (%3534.35)	647622.66 (%2239.17)	691969.25 (%2399.34)	582010.83 (%2002.1)	610969.82 (%2106.78)
	SD	15428.31	18869.68	35449.97	54271.70	16846.03	13921.83	14078.48	13609.48
	t-test (p değeri)	-18.56 (4.46e-26)	-19.56 (3.23e-27)	-37.36 (2.82e-42)	-38.04 (1.04e-42)	-9.11 (8.59e-13)	-18.36 (7.50e-26)	7.96 (7.03e-11)	-
	Süre(s)	87.501	83.863	109.966	123.442	85.529	114.556	84.263	240.22

Veri Seti	Sonuçlar	TS	UOS	LSS	ÜSS	BSS	YTS	KSDS	BMHS
br17	Minimum	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)
	Ortalama	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)
	SD	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	t-test (p değeri)	nan (nan)	nan (nan)	nan (nan)	nan (nan)	nan (nan)	nan (nan)	nan (nan)	-
	Süre(s)	2.847	3.088	2.888	3.088	2.827	4.178	2.770	23.12
ftv33	Minimum	1388 (%7.93)	1337 (%3.96)	1438 (%11.81)	1361 (%5.83)	1380 (%7.30)	1392 (%8.24)	1364 (%6.06)	1374 (%6.84)
	Ortalama	1601.80 (%24.55)	1517.63 (%18.01)	1605.87 (%24.87)	1602.97 (%24.64)	1509.27 (%17.36)	1591.53 (%23.75)	1495.47 (%16.28)	1494.00 (%16.17)
	SD	86.67	83.95	101.23	89.29	85.54	61.58	66.24	53.88
	t-test (p değeri)	-5.68 (4.42e-07)	-1.27 (0.20)	-5.25 (2.23e-06)	-5.62 (5.57e-07)	-0.81 (0.41)	-4.07 (0.0001)	-0.09 (0.92)	-
	Süre(s)	3.416	3.631	3.611	3.755	3.347	5.551	3.653	26.16
ftv35	Minimum	1659 (%12.62)	1569 (%6.51)	1553 (%5.43)	1652 (%12.15)	1553 (%5.43)	1558 (%5.77)	1558 (%5.77)	1558 (%5.77)
	Ortalama	1849.77 (%25.57)	1762.63 (%19.66)	1835.33 (%24.59)	1822.37 (%23.71)	1734.03 (%17.72)	1736.93 (%17.91)	1703.00 (%15.61)	1699.27 (%15.36)
	SD	92.62	113.37	122.99	95.75	86.31	84.93	85.78	70.58
	t-test (p değeri)	-6.95 (3.42)	-2.55 (0.01)	-5.16 (3.05e-06)	-5.57 (6.82e-07)	-1.67 (0.09)	-1.55 (0.12)	-0.18 (0.85)	-
	Süre(s)	3.931	3.578	4.071	3.773	4.064	5.122	3.688	27.53
ftv38	Minimum	1795 (%17.32)	1745 (%14.05)	1656 (%8.23)	1630 (%6.53)	1617 (%5.68)	1672 (%9.28)	1651 (%7.90)	1620 (%5.88)
	Ortalama	1981.27 (%29.49)	1873.03 (%22.42)	1929.27 (%26.09)	1920.07 (%25.49)	1835.77 (%19.98)	1879.57 (%22.84)	1808.67 (%18.21)	1790.00 (%16.99)
	SD	99.31	88.30	107.99	125.17	119.92	84.17	84.35	95.92
	t-test (p değeri)	-7.45 (4.95e-10)	-3.42 (0.001)	-5.19 (2.79e-06)	-4.44 (4.07e-05)	-1.60 (0.11)	-3.48 (0.0009)	-0.78 (0.43)	-
	Süre(s)	4.231	3.972	4.168	4.888	3.615	5.512	3.866	27.23







Veri Seti	Sonuçlar	TS	UOS	LSS	ÜSS	BSS	YTS	KSDS	BMHS
p43	Minimum	5650 (%0.53)	5632 (%0.21)	5631 (%0.19)	5635 (%0.26)	5630 (%0.17)	5631 (%0.19)	5626 (%0.10)	5628 (%0.14)
	Ortalama	5855.17 (%4.18)	5655.80 (%0.63)	5664.73 (%0.79)	5672.80 (%0.93)	5654.37 (%0.61)	5662.93 (%0.76)	5647.97 (%0.49)	5651.50 (%0.56)
	SD	955.34	15.15	22.33	24.51	14.35	11.86	11.96	13.65
	t-test (p değeri)	-1.14 (0.25)	-1.13 (0.26)	-2.72 (0.008)	-4.08 (0.0001)	-0.77 (0.43)	-2.71 (0.008)	1.04 (0.29)	-
	Süre(s)	3.943	4.025	4.006	4.344	3.696	6.580	4.133	30.26
ftv44	Minimum	2063 (%27.89)	1895 (%17.48)	1951 (%20.95)	1979 (%22.69)	1830.00 (%13.45)	1877.00 (%16.36)	1736.00 (%7.62)	1789 (%10.91)
	Ortalama	2270.07 (%40.73)	2165.40 (%34.24)	2197.83 (%36.25)	2221.87 (%37.74)	2072.73 (%28.50)	2146.90 (%33.09)	2047.60 (%26.94)	2033.13 (%26.04)
	SD	118.64	163.31	134.34	121.53	134.93	113.73	115.43	127.29
	t-test (p değeri)	-7.33 (8.09e-10)	-3.43 (0.001)	-4.79 (1.1 e-05)	-5.77 (3.19e-07)	-1.14 (0.25)	-3.48 (0.0009)	-0.45 (0.65)	-
	Süre(s)	4.422	4.019	4.530	4.487	3.862	6.315	4.053	30.14
ftv47	Minimum	2312 (%30.18)	2137 (%20.32)	2175 (%22.46)	2181 (%22.80)	2059 (%15.93)	2098 (%18.13)	2087 (%17.51)	2019 (%13.68)
	Ortalama	2577.30 (%45.11)	2425.30 (%36.55)	2486.57 (%40.00)	2485.40 (%39.94)	2323.57 (%30.83)	2393.03 (%34.74)	2284.33 (%28.62)	2254.63 (%26.95)
	SD	120.07	160.09	175.41	157.36	154.31	112.45	113.27	133.26
	t-test (p değeri)	-9.68 (9.95e-14)	-4.41 (4.5e-05)	-5.66 (4.7e-07)	-6.02 (1.23e-07)	-1.82 (0.07)	-3.76 (0.0003)	-0.91 (0.36)	-
	Süre(s)	4.203	4.513	4.681	4.679	4.272	5.792	4.330	31.75
ry48p	Minimum	17261 (%19.68)	16270 (%12.81)	15872 (%10.05)	16122 (%11.78)	15547 (%7.80)	16094 (%11.59)	16141 (%11.91)	15047 (%4.33)
	Ortalama	18681.00 (%29.53)	17674.77 (%22.55)	17918.27 (%24.24)	18004.23 (%24.83)	16707.67 (%15.84)	17706.93 (%22.77)	16887.53 (%17.09)	16572.13 (%14.90)
	SD	633.84	1147.48	1205.89	1221.19	715.39	514.83	521.49	566.74
	t-test (p değeri)	-13.35 (2.40e-19)	-4.63 (2.0e-05)	-5.44 (1.1e-06)	-5.72 (3.80e-07)	-0.79 (0.42)	-5.26 (2.1e-06)	-2.20 (0.031)	-
	Süre(s)	4.677	4.453	4.199	4.876	4.176	6.028	4.277	30.29









Veri Seti	Sonuçlar	TS	UOS	LSS	ÜSS	BSS	YTS	KSDS	BMHS
ft53	Minimum	8676 (%25.64)	8605 (%24.61)	8427 (%22,042)	8779 (%27.13)	8288 (%20.02)	8927 (%29.28)	7668 (%11.04)	8038 (%16.40)
	Ortalama	9894.63 (%43.29)	9698.87 (%40.46)	9777.53 (%41.60)	9914.57 (%43.58)	9265.60 (%34.18)	9691.80 (%40.35)	8937.70 (%29.43)	9101.67 (%31.81)
	SD	464.77	491.55	529.32	478.23	503.08	494.16	501.46	412.46
	t-test (p değeri)	-6.87 (4.8e-09)	-5.01 (5.38e-06)	-5.42 (1.18e-06)	-6.93 (3.81e-09)	-1.35 (0.18)	-4.87 (8.6e-06)	1.35 (0.17)	-
	Süre(s)	4.644	4.895	4.515	4.641	5.384	6.024	4.615	32.30
ftv55	Minimum	2285 (%42.10)	2264 (%40.79)	2269 (%41.10)	2289 (%42.35)	1986 (%23.50)	1971 (%22.57)	2104 (%30.84)	1957 (%21.70)
	Ortalama	2594.20 (%61.33)	2477.67 (%54.08)	2536.10 (%57.71)	2624,07 (%63.18)	2351,10 (%46.21)	2403.57 (%49.47)	2274.30 (%41.43)	2279.57 (%41.76)
	SD	167.80	157.41	126.61	167.90	157.53	111.56	112.17	120.86
	t-test (p değeri)	-8.19 (2.9e-11)	-5.37 (1.42e-06)	-7.89 (9.28e-11)	-8.96 (1.50e-12)	-1.94 (0.057)	-3.05 (0.003)	0.171 (0.86)	-
	Süre(s)	5.278	4.927	5.350	5.175	4.452	5.711	4.683	31.69
ftv64	Minimum	2968 (%61.39)	2690 (%46.27)	2936 (%59.65)	2807 (%52.63)	2321 (%26.20)	2637 (%43.39)	2460 (%33.76)	2373 (%29.03)
	Ortalama	3259.40 (%77.23)	3124.10 (%69.88)	3223.77 (%75.29)	3242.37 (%76.31)	2881.40 (%56.68)	2983.77 (%62.24)	2797.93 (%52.14)	2767.77 (%50.50)
	SD	122.10	184.34	179.06	136.21	209.10	152.83	153.03	174.38
	t-test (p değeri)	-12.43 (5.2e-18)	-7.56 (3.32e-10)	-9.82 (5.95e-14)	-11.55 (1.13e-16)	-2.24 (0.02)	-4.36 (5.3e-05)	-0.70 (0.48)	-
	Süre(s)	5.464	5.537	5.556	6.918	5.039	6.836	5.301	37.37
ft70	Minimum	45308 (%17.15)	44190 (%14.26)	44519 (%15.11)	45055 (%16.50)	43422 (%12.27)	43428 (%12.29)	43073 (%11.37)	42811 (%10.69)
	Ortalama	46481.40 (%20.19)	45629.70 (%17.98)	46819.53 (%21.06)	46941.97 (%21.38)	45252.53 (%17.01)	45644.57 (%18.02)	44609.53 (%15.35)	44469.90 (%14.98)
	SD	561.45	948.69	949.74	1000.45	928.39	676.84	680.30	773.26
	t-test (p değeri)	-11.33 (2.4e-16)	-5.10 (3.86e-06)	-10.33 (9.14e-15)	-10.52 (4.45e-15)	-3.48 (0.0009)	-4.62 2.1e-05)	-0.73 (0.46)	-
	Süre(s)	5.468	5.703	5.833	6.364	5.725	6.998	5.525	36.85









Veri Seti	Sonuçlar	TS	UOS	LSS	ÜSS	BSS	YTS	KSDS	BMHS
ftv70	Minimum	3197 (%63.94)	2966 (%52.10)	3233 (%65.79)	3235 (%65.89)	2786 (%42.87)	3052 (%56.51)	2631 (%34.92)	2853 (%46.30)
	Ortalama	3649.20 (%87.13)	3433.10 (%76.05)	3580.60 (%83.62)	3649.83 (%87.17)	3260.30 (%67.19)	3456.53 (%77.25)	3137.10 (%60.87)	3163.83 (%62.24)
	SD	154.12	267.54	203.40	212.37	160.75	185.37	185.54	159.99
	t-test (p değeri)	-11.76 (5.34e-17)	-4.65 (1.95e-05)	-8.67 (4.62e-12)	-9.84 (5.56e-14)	-2.29 (0.025)	-6.63 (1.18e-08)	0.58 (0.55)	-
	Süre(s)	5.879	5.876	6.148	6.336	5.473	6.249	5.620	38.68
kro124p	Minimum	61445 (%69.59)	59385 (%63.91)	64370 (%77.67)	66852 (%84.52)	57766 (%59.44)	58721 (%62.07)	54614.00 (%50.74)	56274 (%55.32)
	Ortalama	68775.30 (%89.82)	64850.17 (%78.99)	71046.70 (%96.09)	75285.37 (%107.79)	63745.17 (%75.94)	64299.87 (%77.47)	60110 (%65.91)	60494.83 (%66.97)
	SD	2851.93	3386.76	3226.93	3107.73	2907.92	1886.31	1896.20	2392.481
	t-test (p değeri)	-11.97 (2.54e-17)	-5.65 (4.98e-07)	-14.14 (1.85e-20)	-20.30 (4.81e-28)	-4.64 (1.97e-05)	-5.21 (2.59e-06)	0.67 (0.49)	-
	Süre(s)	7.543	8.127	9.128	9.645	7.069	10.151	8.047	45.94
ftv170	Minimum	9907 (%259.60)	9223 (%234.77)	10789 (%291.61)	11460 (%315.97)	8749 (%217.56)	9713.00 (%252.55)	8297.00 (%201.16)	8671 (%214.73)
	Ortalama	10565.13 (%283.48)	10252.70 (%272.14)	11456.90 (%315.85)	12372.83 (%349.10)	9792.80 (%255.45)	10308.87 (%274.18)	9042.10 (%228.20)	9332.23 (%238.73)
	SD	419.61	475.68	386.99	585.03	383.63	367.41	369.95	417.03
	t-test (p değeri)	-11.22 (3.63e-16)	-7.83 (1.15e-10)	-20.11 (7.92e-28)	-22.79 (1.24e-30)	-4.37 (5.08e-05)	-10.14 (1.83e-14)	2.80 (0.006)	-
	Süre(s)	13.989	14.063	15.949	16.037	13.678	15.670	14.477	67.01
rbg323	Minimum	2915 (%119.83)	2979 (%124.66)	3225 (%143.21)	3469 (%161.61)	2820 (%112.66)	2930 (%120.96)	2617 (%97.36)	2723 (%105.35)
	Ortalama	3052.87 (%130.23)	3059.13 (%130.70)	3425.20 (%158.31)	3720.90 (%180.61)	2932.40 (%121.14)	3070.20 (%131.53)	2739.33 (%106.58)	2822.60 (%112.86)
	SD	71.39	62.47	97.91	158.80	68.24	65.41	65.60	60.57
	t-test (p değeri)	-13.24 (3.48e-19)	-14.63 (3.92e-21)	-28.18 (1.52e-35)	-28.46 (9.0e-36)	-6.48 (2.17e-08)	-16.22 (3.21e-23)	5.02 (5.19e-06)	-
	Süre(s)	43.739	37.262	54.490	49.504	36.260	41.922	37.487	125.05







Veri Seti	Sonuçlar	TS	UOS	LSS	ÜSS	BSS	YTS	KSDS	BMHS
rbg358	Minimum	3184 (%173.77)	3193 (%174.54)	3576 (%207.48)	3860 (%231.90)	3018 (%159.50)	3149 (%170.76)	2814 (%141.96)	2889 (%148.40)
	Ortalama	3304.97 (%184.17)	3340.47 (%187.22)	3730.33 (%220.75)	4221.73 (%263.00)	3168.17 (%172.41)	3305.20 (%184.19)	2970.53 (%155.41)	3037.23 (%161.15)
	SD	64.61	72.83	111.92	207.77	69.17	68.83	69.86	62.21
	t-test (p değeri)	-16.07 (4.94e-23)	-17.04 (2.93e-24)	-29.14 (2.46e-36)	-29.41 (1.51e-36)	-7.57 (3.12e-10)	-15.42 (3.48e-22)	3.83 (0.0003)	-
	Süre(s)	56.386	60.458	67.922	71.834	43.152	50.564	46.996	139.28
rbg403	Minimum	4207 (%70.66)	4253 (%72.53)	4596 (%86.45)	4881 (%98.01)	4160 (%68.76)	4213 (%70.91)	3927 (%59.31)	4014 (%62.83)
	Ortalama	4365.13 (%77.08)	4380.93 (%77.72)	4777.20 (%93.80)	5150.40 (%108.94)	4260.93 (%72.85)	4384.40 (%77.86)	4074.27 (%65.28)	4132.90 (%67.66)
	SD	56.27	54.90	95.01	156.08	53.53	58.29	58.29	58.66
	t-test (p değeri)	-15.38 (3.91e-22)	-16.62 (9.90e-24)	-31.07 (7.55e-38)	-32.86 (3.48e-39)	-8.68 (4.46e-12)	-16.39 (1.90e-23)	3.81 (0.0003)	-
	Süre(s)	58.723	55.421	84.877	85.860	53.767	54.378	51.584	161.17
rbg443	Minimum	4729 (%73.86)	4655 (%71.13)	5095 (%87.31)	5363 (%97.16)	4541 (%66.94)	4740 (%74.26)	4436 (%63.08)	4525 (%66.36)
	Ortalama	4856.17 (%78.53)	4840.97 (%77.97)	5275.67 (%93.95)	5763.93 (%111.90)	4710.23 (%73.17)	4848.93 (%78.26)	4537.77 (%66.82)	4591.73 (%68.81)
	SD	69.43	63.61	93.09	168.58	61.75	54.37	54.60	48.57
	t-test (p değeri)	-16.80 (5.86e-24)	-16.76 (6.52e-24)	-35.07 (9.47e-41)	-35.98 (2.30e-41)	-8.12 (3.82e-11)	-18.04 (1.79e-25)	3.97 (0.0001)	-
	Süre(s)	61.257	62.524	72.986	82.720	61.919	70.147	68.597	179.60



EK 3: Seçim Operatörleri İçin Hesaplama Süreleri Karşılaştırılması









































EK 4: Mutasyon Operatörlerinin Jenerasyon-Uygunluk Performansları









EK 5: Mutasyon Operatörlerinin Karşılaştırılması

Veri Seti	Sonuçlar	YDM	DM	EM	BTÇM	TÇM	KM
gr21	Minimum	3104 (%14.66)	2709 (%0.07)	2757 (%1.84)	2707.00 (%0.00)	2930 (%8.23)	2707 (%0.00)
	Ortalama	3421.60 (%26.39)	3075.57 (%13.61)	3115.47 (%15.08)	2824.20 (%4.32)	3468.57 (%28.13)	3102.33 (%14.60)
	SD	231.24	246.89	225.21	125.65	252.09	241.72
	t-test (p değeri)	-5.60 (6.09e-07)	-	-0.65 (0.515)	4.96 (6.26e-06)	-6.10 (9.30e-08)	-0.42 (0.67)
	Süre(s)	31.333	27.839	29.068	26.467	30.791	24.583
fri26	Minimum	1181 (%26.04)	1026 (%9.49)	1003 (%7.04)	937 (%0.00)	1088 (%16.11)	953 (%1.70)
	Ortalama	1290.10 (%37.68)	1139.30 (%21.59)	1139.83 (%21.64)	986.13 (%5.24)	1290.23 (%37.69)	1080.70 (%15.33)
	SD	60.58	69.31	80.66	38.29	78.24	73.58
	t-test (p değeri)	-8.97 (1.47e-12)	-	-0.02 (0.97)	10.59 (3.50e-15)	-7.90 (8.71e-11)	3.17 (0.002)
	Süre(s)	31.307	27.323	28.593	24.835	31.316	25.338
bayg29	Minimum	2089 (%29.75)	1837 (%14.09)	1803 (%11.98)	1610 (%0.00)	2122 (%31.80)	1642 (%1.98)
	Ortalama	2311.80 (%43.59)	2043.10 (%26.90)	2086.50 (%29.59)	1695.80 (%5.32)	2326.70 (%44.51)	1876.53 (%16.55)
	SD	121.34	116.71	149.09	43.379	108.37	145.69
	t-test (p değeri)	-8.74 (3.55e-12)	-	-1.25 (0.21)	15.27 (5.42e-22)	-9.75 (7.77e-14)	4.88 (8.44e-06)
	Süre(s)	32.060	29.002	29.379	26.214	32.018	25.954

Veri Seti	Sonuçlar	YDM	DM	EM	BTÇM	TÇM	KM
dantzig42	Minimum	1280 (%83.11)	975 (%39.48)	991 (%41.77)	756 (%8.15)	1176 (%68.24)	866 (%23.89)
	Ortalama	1426.20 (%104.03)	1118.57 (%60.02)	1175.33 (%68.14)	812.00 (%16.16)	1380.90 (%97.55)	1052.13 (%50.51)
	SD	81.25	83.03	93.34	35.64	100.35	109.55
	t-test (p değeri)	-14.50 (5.97e-21)	-	-2.48 (0.015)	18.58 (4.23e-26)	-11.03 (7.21e-16)	2.64 (0.010)
	Süre(s)	36.322	32.038	32.830	28.804	36.498	28.551
eil51	Minimum	812.70 (%90.77)	643.48 (%51.05)	698.70 (%64.01)	469.81 (%10.28)	810.95 (%90.36)	597.26 (%40.20)
	Ortalama	900.49 (%111.38)	704.77 (%65.43)	786.81 (%84.69)	518.63 (%21.74)	895.96 (%110.31)	696.50 (%63.49)
	SD	41.04	43.07	40.60	28.61	42.03	50.20
	t-test (p değeri)	-18.01 (1.97e-25)	-	-7.58 (2.98e-10)	19.71 (2.18e-27)	-17.39 (1.08e-24)	0.68 (0.49)
	Süre(s)	39.836	33.145	34.277	29.809	42.765	29.862
berlin52	Minimum	13993.54 (%85.54)	10442.34 (%38.45)	11311.30 (%49.97)	8706.90 (%15.44)	14113.26 (%87.12)	9692.95 (%28.51)
	Ortalama	15491.03 (%105.39)	12094.90 (%60.36)	13404.94 (%77.73)	9503.42 (%26.00)	15462.54 (%105.01)	11909.64 (%57.91)
	SD	693.6181	866.5177	796.8027	527.0494	675.3764	1012.605
	t-test (p değeri)	-16.75 (6.70e-24)	-	-6.09 (9.48e-08)	13.99 (3.00e-20)	-16.78 (6.14e-24)	0.76 (0.44)
	Süre(s)	40.490	34.551	34.236	29.657	39.991	29.415
pr76	Minimum	304190.5 (%181.24)	208599.08 (%92.86)	238244.68 (%120.27)	168727.14 (%55.99)	300630.62 (%177.95)	224327.01 (%107.40)
	Ortalama	328204.99 (%203.44)	233546.54 (%115.92)	280520.76 (%159.35)	185907.06 (%71.88)	325084.36 (%200.56)	252466.64 (%133.42)
	SD	12908.35	14267.16	12979.47	10195.93	12912.92	17025.26
	t-test (p değeri)	-26.49 (4.2e-34)	-	-13.11 (5.34e-19)	14.62 (4.01e-21)	-25.61 (2.59e-33)	-4.58 (2.45e-05)
	Süre(s)	46.468	40.426	41.834	36.172	46.513	34.591

Veri Seti	Sonuçlar	YDM	DM	EM	BTÇM	TÇM	KM
lin105	Minimum	60766.83 (%322.60)	37291.72 (%159.34)	47311.88 (%229.03)	33554.67 (%133.35)	63220.4 (%339.67)	48216.05 (%235.32)
	Ortalama	67956,34 (%372.60)	43816.25 (%204.72)	55749.46 (%287.71)	37495.15 (%160.76)	67853.33 (%371.89)	54593.03 (%279.67)
	SD	3122.38	2491.97	3218.65	2258.76	2526.94	3911.35
	t-test (p değeri)	-32.54 (5.97e-39)	-	-15.78 (1.16e-22)	10.12 (1.98e-14)	-36.47 (1.08e-41)	-12.51 (4.04e-18)
	Süre(s)	64.558	50.547	55.786	45.738	65.203	45.426
pr226	Minimum	1023994.91 (%1174.11)	570714.60 (%610.11)	794725.00 (%888.84)	631823.51 (%686.15)	1047459.13 (%1203.31)	857640.80 (%967.12)
	Ortalama	1111815.47 (%1283.38)	615744.15 (%666.14)	866161.31 (%977.73)	690755.82 (%759.48)	1112987.82 (%1284.84)	946224.43 (%1077.35)
	SD	38816.13	27496.78	34644.63	37102.51	30541.13	50740.31
	t-test (p değeri)	-57.11 (1.11e-52)	-	-31.01 (8.41e-38)	-8.89 (1.96e-12)	-66.27 (2.27e-56)	-31.36 (4.51e-38)
	Süre(s)	146.149	95.929	118.425	88.815	148.562	87.942
a280	Minimum	22435.54 (%769.93)	13186.92 (%411.31)	17663.93 (%584.91)	14633.65 (%467.41)	22325.67 (%765.67)	19211.96 (%644.93)
	Ortalama	23513.06 (%811.71)	13958.90 (%441.25)	18780.36 (%628.20)	16127.41 (%525.33)	23480.89 (%810.46)	20850.66 (%708.47)
	SD	564.45	408.40	498.91	627.99	561.53	722.04
	t-test (p değeri)	-75.11 (1.73e-59)	-	-40.95 (1.66e-44)	-15.85 (9.47e-23)	-75.11 (1.73e-59)	-45.50 (4.45e-47)
	Süre(s)	198.361	124.550	158.523	115.923	199.335	115.549
att532	Minimum	1169849.6 (%45260)	673755.32 (%26024)	873685.1 (%33776)	818597.92 (%31640)	1163379.186 (%45009)	1002035.2 (%38753)
	Ortalama	1212079.18 (%46898)	699102.81 (%27007)	905807.47 (%35022)	928175.12 (%35889)	1208936.54 (%46776)	1088674.00 (%42113)
	SD	21832.33	15617.32	18991.74	38978.68	17600.97	49884.33
	t-test (p değeri)	-102.91 (2.32e-67)	-	-45.27 (5.95e-47)	-29.37 (1.61e-36)	-116.67 (1.65e-70)	-40.13 (5.19e-44)
	Süre(s)	170.054	83.422	126.608	81.774	178.983	77.901

Veri Seti	Sonuçlar	YDM	DM	EM	BTÇM	TÇM	KM
br17	Minimum	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)
	Ortalama	40.23 (%3.16)	39.77 (%1.96)	39.33 (%0.85)	39.00 (%0.00)	39.93 (%2.39)	39.40 (%1.02)
	SD	1.45	1.19	1.02	0.0	1.28	1.30
	t-test (p değeri)	-1.35 (0.17)	-	1.50 (0.13)	3.51 (0.0008)	-0.52 (0.60)	1.13 (0.26)
	Süre(s)	29.085	26.829	26.596	23.665	28.868	23.820
ftv33	Minimum	1943 (%51.08)	1698 (%32.03)	1805 (%40.35)	1489 (%15.78)	2269 (%76.43)	1496 (%16.32)
	Ortalama	2256.43 (%75.46)	1903.20 (%47.99)	2031.47 (%57.96)	1770.93 (%37.70)	2495.97 (%94.08)	1781.07 (%38.49)
	SD	118.52	120.91	112.92	130.55	120.35	133.01
	t-test (p değeri)	-11.42 (1.76e-16)	-	-4.24 (7.95e-05)	4.07 (0.0001)	-19.03 (1.28e-26)	3.72 (0.0004)
	Süre(s)	33.785	30.188	30.632	26.927	33.495	27.119
ftv35	Minimum	2357 (%60.01)	1906 (%29.39)	2113 (%43.44)	1846 (%25.32)	2656 (%80.31)	1823 (%23.76)
	Ortalama	2636.10 (%78.96)	2208.80 (%49.95)	2331.57 (%58.28)	2061.30 (%39.93)	2856.17 (%93.90)	2126.07 (%44.33)
	SD	132.90	133.35	122.61	114.41	106.28	150.26
	t-test (p değeri)	-12.43 (5.36e-18)	-	-3.71 (0.0004)	4.59 (2.35e-05)	-20.79 (1.44e-28)	2.25 (0.027)
	Süre(s)	34.400	31.685	31.340	27.633	34.930	27.900
ftv38	Minimum	2569 (%67.90)	2106 (%37.64)	2188 (%43.00)	1960 (%28.10)	2743 (%79.28)	1883 (%23.07)
	Ortalama	2788.83 (%82.27)	2381.53 (%55.65)	2495.57 (%63.10)	2174.77 (%42.14)	3042.63 (%98.86)	2264.40 (%48.00)
	SD	135.30	136.80	169.65	125.41	140.40	147.94
	t-test (p değeri)	-11.59 (9.74e-17)	-	-2.86 (0.005)	6.10 (9.23e-08)	-18.47 (5.70e-26)	3.18 (0.002)
	Süre(s)	35.405	31.530	32.526	28.101	35.698	28.138







Veri Seti	Sonuçlar	YDM	DM	EM	BTÇM	TÇM	KM
p43	Minimum	5770 (%2.66)	5716 (%1.70)	5730 (%1.95)	5632 (%0.21)	5778 (%2.81)	5659 (%0.69)
	Ortalama	5853.70 (%4.15)	5778.57 (%2.82)	5786.73 (%2.96)	5656.53 (%0.65)	5858.57 (%4.24)	6256.13 (%11.31)
	SD	40.65	30.87	34.54	20.60	44.71	1630.67
	t-test (p değeri)	-8.06 (4.82e-11)	-	-0.96 (0.33)	18.00 (2.00e-25)	-8.06 (4.79e-11)	-1.6 (0.11)
	Süre(s)	35.917	31.706	30.891	27.621	34.129	27.873
ftv44	Minimum	3053 (%89.27)	2348 (%45.56)	2691 (%66.83)	2356 (%46.06)	3224 (%99.87)	2304 (%42.83)
	Ortalama	3411.03 (%111.47)	2694.33 (%67.03)	2973.83 (%84.36)	2644.83 (%63.96)	3669.97 (%127.52)	2635.63 (%63.39)
	SD	166.25	160.85	186.58	164.45	185.77	225.39
	t-test (p değeri)	-16.68 (8.32e-24)	-	-6.10 (8.97e-08)	1.15 (0.25)	-21.38 (3.44e-29)	1.14 (0.25)
	Süre(s)	36.711	32.290	32.852	28.740	36.506	28.537
ftv47	Minimum	3527 (%98.59)	2829 (%59.29)	2865 (%61.31)	2503 (%40.93)	3759 (%111.65)	2687 (%51.29)
	Ortalama	3802.50 (%114.10)	3057.87 (%72.17)	3339.60 (%88.04)	2949.47 (%66.07)	4190.33 (%135.94)	2991.37 (%68.43)
	SD	164.61	153.86	174.62	168.30	172.70	153.80
	t-test (p değeri)	-18.10 (1.56e-25)	-	-6.63 (1.22e-08)	2.60 (0.011)	-26.81 (2.23e-34)	1.67 (0.09)
	Süre(s)	40.439	32.093	32.511	28.137	37.586	28.337
ry48p	Minimum	25021 (%73.49)	19221 (%33.27)	20144 (%39.67)	15938 (%10.51)	24637 (%70.82)	18384 (%27.47)
	Ortalama	27440.20 (%90.26)	22286.43 (%54.53)	24167.97 (%67.57)	17977.47 (%24.65)	27505.33 (%90.71)	22211.23 (%54.00)
	SD	1361.64	1232.18	1619.91	903.66	1548.34	1851.47
	t-test (p değeri)	-15.11 (8.96e-22)	-	-4.97 (6.07e-06)	15.18 (7.17e-22)	-14.20 (1.54e-20)	0.18 (0.85)
	Süre(s)	36.715	32.200	33.102	28.647	36.864	28.641









Veri Seti	Sonuçlar	YDM	DM	EM	BTÇM	TÇM	KM
ft53	Minimum	12844 (%86.01)	11113 (%60.94)	11767 (%70.41)	10444 (%51.25)	14154 (%104.98)	10313 (%49.35)
	Ortalama	14299.97 (%107.09)	12287.00 (%77.94)	12963.53 (%87.74)	11776.33 (%70.54)	15936.43 (%130.79)	12140.30 (%75.81)
	SD	714.33	681.21	693.95	662.45	853.13	826.94
	t-test (p değeri)	-10.98 (8.60e-16)	-	-3.74 (0.0004)	2.89 (0.0053)	-18.00 (2.04e-25)	0.73 (0.46)
	Süre(s)	38.017	33.776	34.355	29.365	39.930	29.492
ftv55	Minimum	3725 (%131.65)	2880 (%79.10)	3234 (%101.11)	2775 (%72.57)	4103 (%155.16)	2611 (%62.37)
	Ortalama	4207.50 (%161.66)	3099.57 (%92.75)	3670.73 (%128.27)	3060.70 (%90.34)	4552.43 (%183.11)	3155.40 (%96.23)
	SD	175.045	128.835	188.767	165.639	206.313	225.539
	t-test (p değeri)	-27.45 (6.35e-35)	-	-13.45 (1.71e-19)	0.997 (0.322)	-32.16 (1.13e-38)	-1.15 (0.251)
	Süre(s)	41.594	35.845	37.255	32.162	41.695	32.170
ftv64	Minimum	4878 (%165.25)	3439 (%87.00)	4090 (%122.40)	3489 (%89.72)	5310 (%188.74)	3371 (%83.30)
	Ortalama	5208.27 (%183.21)	3859.10 (%109.84)	4574.17 (%148.73)	3944.20 (%114.47)	5658.73 (%207.70)	4067.23 (%121.16)
	SD	170.01	166.48	228.74	236.65	181.46	259.21
	t-test (p değeri)	-30.53 (1.96e-37)	-	-13.61 (1.04e-19)	-1.58 (0.118)	-39.35 (1.56e-43)	-3.63 (0.0005)
	Süre(s)	44.755	38.116	39.848	34.348	44.885	34.124
ft70	Minimum	53254 (%37.70)	47508 (%22.84)	49812 (%28.80)	47769 (%23.52)	55927 (%44.61)	48903 (%26.45)
	Ortalama	55160.40 (%42.63)	49474.07 (%27.92)	52115.57 (%34.75)	50696.73 (%31.09)	58293.60 (%50.73)	50828.03 (%31.43)
	SD	1106.15	920.07	1116.06	1254.22	1011.72	1132.62
	t-test (p değeri)	-21.28 (4.36e-29)	-	-9.83 (5.73e-14)	-4.23 (8.32e-05)	-34.73 (1.64e-40)	-4.99 (5.68e-06)
	Süre(s)	47.550	43.873	42.317	37.447	47.519	37.645









Veri Seti	Sonuçlar	YDM	DM	EM	BTÇM	TÇM	KM
ftv70	Minimum	5262 (%169.84)	3771 (%93.38)	4601 (%135.94)	3669 (%88.15)	5941 (%204.66)	4211 (%115.94)
	Ortalama	5754.90 (%195.12)	4292.63 (%120.13)	5160.67 (%164.64)	4478.23 (%129.65)	6391.07 (%227.74)	4672.53 (%139.61)
	SD	229.95	188.55	243.88	257.86	224.17	225.70
	t-test (p değeri)	-26.48 (4.40e-34)	-	-15.16 (7.68e-22)	-3.12 (0.002)	-38.57 (4.75e-43)	-6.95 (3.47e-09)
	Süre(s)	48.060	39.806	42.519	36.008	47.838	36.011
kro124p	Minimum	103318 (%185.17)	72571 (%100.30)	91188 (%151.69)	74249 (%104.93)	106485 (%193.91)	86802 (%139.58)
	Ortalama	113132.23 (%212.26)	80701.17 (%122.74)	98652.77 (%172.29)	81148.43 (%123.98)	116205.80 (%220.74)	93144.63 (%157.09)
	SD	4658.70	3571.93	3712.55	3496.33	3931.68	4253.97
	t-test (p değeri)	-30.25 (3.21e-37)	-	-19.08 (1.11e-26)	-0.49 (0.62)	-36.60 (8.80e-42)	-12.26 (9.30e-18)
	Süre(s)	60.733	48.173	52.961	43.382	60.781	43.381
ftv170	Minimum	16865 (%512.15)	10984 (%298.69)	14356 (%421.08)	13443 (%387.94)	18110 (%557.35)	13584 (%393.06)
	Ortalama	17944.17 (%551.33)	11620.17 (%321.78)	15004.70 (%444.63)	14766.70 (%435.99)	19246.97 (%598.61)	15299.00 (%455.31)
	SD	554.23	358.68	354.42	623.83	505.78	777.39
	t-test (p değeri)	-52.46 (1.39e-50)	-	-36.76 (6.97e-42)	-23.94 (9.23e-32)	-67.37 (8.89e-57)	-23.53 (2.31e-31)
	Süre(s)	95.056	70.744	79.890	62.224	95.438	62.175
rbg323	Minimum	4592 (%246.30)	2907 (%119.23)	3890 (%193.36)	4036 (%204.37)	5134 (%287.17)	3874 (%192.15)
	Ortalama	4753.17 (%258.45)	3052.50 (%130.20)	4016.57 (%202.90)	4313.47 (%225.29)	5294.07 (%299.25)	4195.17 (%216.37)
	SD	72.55	65.23	58.37	169.35	90.42	138.74
	t-test (p değeri)	-95.47 (1.76e-65)	-	-60.32 (4.95e-54)	-38.05 (1.01e-42)	-110.11 (4.69e-69)	-40.82 (2.00e-44)
	Süre(s)	216.359	133.671	173.964	125.177	218.927	125.280









Veri Seti	Sonuçlar	YDM	DM	EM	BTÇM	TÇM	KM
rbg358	Minimum	5118 (%340.06)	3105 (%166.98)	4209 (%261.90)	4443 (%282.02)	5727 (%392.43)	4323 (%271.71)
	Ortalama	5265.30 (%352.73)	3249.93 (%179.44)	4357.67 (%274.69)	4803.90 (%313.06)	5914.33 (%408.54)	4712.60 (%305.21)
	SD	84.31	69.85	73.05	196.81	82.46	182.86
	t-test (p değeri)	-100.8 (7.64e-67)	-	-60.02 (6.56e-54)	-40.75 (2.19e-44)	-135.02 (3.57e-74)	-40.92 (1.74e-44)
	Süre(s)	255.782	152.991	203.541	144.200	258.667	144.734
rbg403	Minimum	5903 (%139.47)	4096 (%66.16)	5077 (%105.96)	5288 (%114.52)	6536 (%165.15)	5241 (%112.61)
	Ortalama	6053.97 (%145.59)	4237.00 (%71.88)	5209.40 (%111.33)	5656.73 (%129.48)	6682.17 (%171.08)	5557.53 (%125.45)
	SD	75.39	67.27	71.08	169.46	74.18	133.99
	t-test (p değeri)	-98.48 (2.93e-66)	-	-54.41 (1.76e-51)	-42.64 (1.71e-45)	-133.72 (6.26e-74)	-48.23 (1.64e-48)
	Süre(s)	303.423	187.801	240.087	169.535	305.904	169.737
rbg443	Minimum	6451 (%137.16)	4644 (%70.73)	5541 (%103.71)	5734 (%110.80)	6965 (%156.06)	5784 (%112.64)
	Ortalama	6650.90 (%144.51)	4732.40 (%73.98)	5700.00 (%109.55)	6235.30 (%129.23)	7265.30 (%167.10)	6135.73 (%125.57)
	SD	82.07	46.41	66.44	183.16	95.58	147.42
	t-test (p değeri)	-111.43 (2.35e-69)	-	-65.38 (4.93e-56)	-43.56 (5.19e-46)	-130.55 (2.50e-73)	-49.73 (2.92e-49)
	Süre(s)	364.620	210.379	287.643	197.557	370.539	197.576

EK 6: Mutasyon Operatörleri İçin Hesaplama Sürelerinin Karşılaştırılması







































EK 7: Çaprazlama Operatörlerinin Jenerasyon-Uygunluk Performansları









EK 8: Çaprazlama Operatörlerinin Karşılaştırılması

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDÇ	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
gr21	Minimum	2707.00 (%0.00)	2707.00 (%0.00)	2707.00 (%0.00)	2707.00 (%0.00)	2707.00 (%0.00)	2767.00 (%2.21)	2853.00 (%5.39)	2707.00 (%0.00)	2758 (%1.88)	2707.00 (%0.00)	2707.00 (%0.00)
	Ortalama	2961.63 (%9.40)	3023.77 (%11.70)	2716.70 (%0.35)	2806.77 (%3.68)	2890.00 (%6.76)	2941.10 (%8.64)	3187.43 (%17.74)	2968.00 (%9.64)	2893.23 (%6.87)	2721.90 (%0.55)	2837.30 (%4.81)
	SD	219.98	225.81	53.12	145.68	191.91	105.35	172.95	188.25	91.43	25.79	90.66
	t-test (p değeri)	-5.92 (1.78e-07)	-7.27 (1.01-09)	0.48 (0.63)	-3.14 (0.002)	-4.75 (1.35e-05)	-11.06 (6.29e-16)	-14.5 (4.67e-21)	-7.09 (2.03e-09)	-9.87 (4.87e-14)	-	-6.70 (9.15e-09)
	Süre(s)	11.531	14.541	13.272	26.575	35.636	23.389	31.030	14.136	67.186	135.098	100.890
fri26	Minimum	937.00 (%0.00)	937.00 (%0.00)	937.00 (%0.00)	937.00 (%0.00)	937.00 (%0.00)	1019.00 (%8.75)	1168.00 (%24.65)	974.00 (%3.94)	937.00 (%0.00)	937.00 (%0.00)	937.00 (%0.00)
	Ortalama	1030.03 (%9.92)	1071.13 (%14.31)	966.70 (%3.16)	1005.33 (%7.29)	1023.73 (%9.25)	1121.57 (%19.69)	1263.17 (%34.80)	1074.03 (%14.62)	950.87 (%1.48)	937.00 (%0.00)	956.83 (%2.11)
	SD	52.26	61.98	22.30	43.30	61.00	56.47	58.19	67.31	22.27	0.00	15.26
	t-test (p değeri)	-9.74 (7.89e-14)	-11.85 (3.94 e-17)	-7.29 (9.45e-10)	-8.64 (5.18e-12)	-7.78 (1.39e-10)	-17.89 (2.70e-25)	-30.70 (1.45e-37)	-11.15 (4.69 e-16)	-3.41 (0.001)	-	-7.11 (1.85e-09)
	Süre(s)	14.200	18.920	15.573	36.505	49.247	28.434	37.510	15.823	99.008	207.546	126.102

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
bayg29	Minimum	1610 (%0.00)	1639 (%1.80)	1610 (%0.00)	1620 (%0.62)	1610 (%0.00)	1872 (%16.27)	1978 (%22.85)	1618 (%0.49)	1826 (%13.41)	1620 (%0.62)	1654 (%2.73)
	Ortalama	1815.26 (%12.74)	1886.40 (%17.16)	1656.70 (%2.90)	1760.80 (%9.36)	1791.63 (%11.28)	2021.96 (%25.58)	2298.00 (%42.73)	1791.16 (%11.25)	2057.20 (%27.77)	1642.43 (%2.01)	1765.50 (%9.65)
	SD	133.58	125.79	45.49	95.64	90.40	87.97	121.49	92.05	103.86	12.79	63.59
	t-test (p değeri)	-7.05 (2.37 e-09)	-10.56 (3.84 e-15)	-1.65 (0.103)	-6.71 (8.69 e-09)	-8.94 (1.6 e-12)	-23.38 (3.26 e-31)	-29.39 (1.57 e-36)	-8.76 (3.24 e-12)	-21.70 (1.56e-29)	-	-10.39 (7.32 e-15)
	Süre(s)	56.331	70.798	67.648	155.822	207.190	117.403	157.280	66.933	470.802	865.269	590.873
dantzig42	Minimum	807 (%15.45)	886 (%26.75)	752 (%7.58)	773 (%10.58)	728 (%4.14)	892 (%27.61)	1296 (%85.40)	858 (%22.74)	699 (%0)	700 (%0.14)	726 (%3.86)
	Ortalama	973.53 (%39.27)	1064.73 (%52.32)	897.93 (%28.45)	886.80 (%26.86)	915.03 (%30.90)	1094.47 (%56.57)	1506.47 (%115.51)	998.47 (%42.84)	699.30 (%0.04)	730.30 (%4.47)	793.70 (%13.54)
	SD	88.91	83.07	62.98	70.38	83.58	81.28	88.70	80.46	1.11	20.22	47.58
	t-test (p değeri)	-14.61 (4.26 e-21)	-21.42 (3.10 e-29)	-13.87 (4.37 e-20)	-11.70 (6.60 e-17)	-11.76 (5.34 e-17)	-23.8 (1.24 e-31)	-46.72 (9.93 e-48)	-17.70 (4.66 e-25)	8.38 (1.40e-11)	-	-6.71 (8.77 e-09)
	Süre(s)	58.340	93.302	75.129	237.208	328.956	151.372	205.517	80.104	682.218	1990.976	1208.474

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
eil51	Minimum	504.38 (%18.40)	590.81 (%38.68)	564.09 (%32.41)	489.73 (%14.96)	491.09 (%15.27)	628.83 (%47.61)	856.77 (%101.12)	556.27 (%30.58)	803.01 (%88.5)	433.54 (%1.77)	457.33 (%7.35)
	Ortalama	582.70 (%36.78)	665.47 (%56.21)	615.93 (%44.58)	577.94 (%35.66)	580.27 (%36.21)	699.55 (%64.21)	920.96 (%116.18)	603.43 (%41.65)	874.33 (%105.24)	443.15 (%4.02)	484.24 (%13.67)
	SD	35.07	36.05	33.50	49.29	58.45	49.25	38.07	28.52	34.19	6.10	16.11
	t-test (p değeri)	-21.46 (2.78 e-29)	-33.29 (1.67 e-39)	-27.78 (3.29 e-35)	-14.86 (1.93 e-21)	-12.77 (1.65 e-18)	-28.29 (1.23 e-35)	-67.86 (5.83 e-57)	-30.09 (4.36 e-37)	-67.99 (5.23e-57)	-	-13.05 (6.50 e-19)
	Süre(s)	15.713	25.938	19.235	76.208	115.601	42.714	57.035	25.149	308.167	705.844	405.421
berlin52	Minimum	9413.55 (%24.81)	10771.57 (%42.82)	9777.88 (%29.64)	9465.73 (%25.50)	8608.91 (%14.14)	10399.26 (%37.88)	14283.66 (%89.38)	9347.68 (%23.94)	13099.76 (%73.69)	7548.99 (%0.09)	8029.10 (%6.45)
	Ortalama	10471.53 (%38.84)	11775.55 (%56.13)	10641.30 (%41.09)	10594.10 (%40.48)	10320.57 (%36.84)	12024.50 (%59.43)	15577.62 (%106.54)	10778.50 (%42.91)	14337.57 (%90.10)	7548.99 (%0.09)	8458.94 (%12.15)
	SD	536.06	713.59	476.69	775.65	873.27	759.40	662.95	693.26	640.58	4.62E-12	291.29
	t-test (p değeri)	-29.86 (6.62 e-37)	-32.44 (7.07 e-39)	-35.53 (4.63 e-41)	-21.50 (2.52 e-29)	-17.38 (1.13 e-24)	-32.27 (9.31 e-39)	-66.33 (2.16 e-56)	-25.51 (3.21 e-33)	-58.04 (4.44e-53)	-	-17.10 (2.45 e-24)
	Süre(s)	16.012	28.612	21.026	80.114	123.002	45.789	64.917	32.367	331.887	746.187	419.372

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
pr76	Minimum	165188.21 (%52.72)	214336.16 (%98.16)	185704.96 (%71.69)	157741.91 (%45.84)	174341.38 (%61.18)	197908.77 (%82.97)	333288.26 (%208.14)	180066.39 (%66.48)	138713.89 (%28.24)	111566.07 (%3.15)	122646.68 (%13.39)
	Ortalama	196375.55 (%81.56)	240958.04 (%122.78)	217855.94 (%101.42)	209293.28 (%93.50)	210191.14 (%94.33)	221261.95 (%104.57)	353820.21 (%227.12)	207115.54 (%91.49)	174092.21 (%60.95)	115581.30 (%6.86)	132545.92 (%22.54)
	SD	10680.86	13872.41	14403.20	23885.01	16667.10	13312.46	11558.39	11496.64	15595.08	1639.85	4992.13
	t-test (p değeri)	-40.95 (1.67 e-44)	-49.16 (5.63 e-49)	-38.64 (4.32 e-43)	-21.43 (2.99 e-29)	-30.94 (9.49 e-38)	-43.15 (8.83 e-46)	-111.77 (1.97 e-69)	-43.17 (8.64 e-46)	-20.43 (3.49e-28)	-	-17.68 (4.91 e-25)
	Süre(s)	19.644	36.619	23.956	142.736	231.373	70.657	93.808	39.840	631.940	1659.563	898.876
lin105	Minimum	32172.41 (%123.74)	42656.67 (%196.65)	37137.34 (%158.27)	33117.13 (%130.31)	31153.95 (%116.66)	35198.41 (%144.790)	72242.21 (%402.41)	36862.97 (%156.36)	39452.19 (%174.37)	14570.89 (%1.33)	16568.88 (%15.22)
	Ortalama	37707.64 (%162.24)	48781.53 (%239.25)	42849.72 (%198.00)	41681.78 (%189.87)	39053.03 (%171.59)	41739.12 (%190.27)	77608.14 (%439.73)	40132.67 (%179.10)	43484.81 (%202.41)	14701.95 (%2.24)	18279.64 (%27.12)
	SD	3059.82	3015.85	2346.14	4209.87	4576.94	3092.39	2637.50	1954.05	2176.16	62.24	662.28
	t-test (p değeri)	-41.17 (1.24 e-44)	-61.88 (1.15 e-54)	-65.68 (3.78 e-56)	-35.09 (9.15 e-41)	-29.13 (2.51 e-36)	-47.87 (2.51 e-48)	-130.59 (2.46 e-73)	-71.24 (3.60 e-58)	-72.41 (1.41e-58)	-	-29.45 (1.38 e-36)
	Süre(s)	97.205	230.008	136.884	1022.902	1724.052	337.152	444.031	257.318	5194.377	17780.690	7097.201

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
pr226	Minimum	538313.66 (%569.80)	766256.38 (%853.42)	625261.28 (%677.98)	603901.17 (%651.41)	559486.81 (%596.14)	554853.93 (%590.38)	1218622.40 (%1416.28)	590992.04 (%635.34)	128454.00 (%59.83)	81040.53 (%0.83)	95110.62617 (%18.34)
	Ortalama	597236.84 (%643.11)	833778.30 (%937.43)	663799.40 (%725.93)	757261.29 (%842.23)	755923.06 (%840.56)	602929.84 (%650.20)	1251152.20 (%1456.75)	645038.91 (%702.59)	144697.93 (%80.04)	82239.78 (%2.32)	102535.40 (%27.58)
	SD	33433.76	30710.66	22259.53	60249.541	72784.75	32043.63	16947.88	27895.69	13427.78	1037.08	4423.61
	t-test (p değeri)	-84.32 (2.24e-62)	-133.96 (5.66 e-74)	-142.94 (1.32e-75)	-61.35 (1.87e-54)	-50.69 (9.89e-50)	-88.95 (1.03e-63)	-377.06 (5.25e-100)	-110.42 (3.98e-69)	-25.40 (4.07e-33)	-	-24.46 (2.98e-32)
	Süre(s)	164.891	575.157	250.616	4250.254	6771.410	644.188	845.768	875.461	7513.296	30536.433	16536.594
a280	Minimum	12853.00 (%398.37)	17648.46 (%584.31)	14749.21 (%471.89)	15131.71 (%486.72)	14859.38 (%476.16)	13402.69 (%419.68)	25651.84 (%894.64)	13847.99 (%436.95)	4060.17 (%57.43)	2640.41 (%2.38)	3256.67 (%26.27)
	Ortalama	13765.74 (%433.76)	18772.39 (%627.89)	15363.21 (%495.70)	16818.76 (%552.14)	17248.26 (%568.79)	14207.77 (%450.90)	26241.04 (%917.48)	14662.50 (%468.53)	4278.72 (%65.90)	2695.62 (%4.52)	3467.66 (%34.45)
	SD	507.99	595.18	379.50	1037.53	1089.11	440.12	382.19	482.33	142.43	28.13	116.98
	t-test (p değeri)	-119.17 (4.87e-71)	-147.7 (1.93e-76)	-182.32 (1.01e-81)	-74.53 (2.71e-59)	-73.16 (7.86e-59)	-142.97 (1.31-75)	-336.51 (3.84e-97)	-135.66 (2.73e-74)	-59.72 (8.76e-54)	-	-35.14 (8.50e-41)
	Süre(s)	61.452	305.613	88.050	963.903	1800.935	119.179	120.700	179.284	5401.276	37800.045	21996.993

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
att532	Minimum	698926.79 (%2424.47)	971839.48 (%3410.21)	705370.56 (%2447.75)	855759.33 (%2990.94)	832197.39 (%2905.84)	681591.62 (%2361.86)	1292158.73 (% 4567.19)	775546.43 (%2701.22)	814604.04 (%2842.29)	93340.05 (%237.13)	115664.74 (%317.77)
	Ortalama	737043.43 (%2562.15)	1025301.29 (%3603.32)	738398.55 (%2567.04)	938418.32 (%3289.50)	938146.67 (%3288.52)	718559.92 (%2495.39)	1319978.22 (%4667.67)	805220.76 (%2808.40)	874937.61 (%3060.21)	95495.14 (%244.92)	123104.69 (%344.64)
	SD	18339.61	23244.98	19154.31	30420.69	45977.59	25994.32	14710.03	20519.42	32961.29	846.56	3263.10
	t-test (p değeri)	-191.39 (6.10e-83)	-218.94 (2.53e-86)	-183.66 (6.66e-82)	-151.70 (4.24e-77)	-100.36 (9.87e-67)	-131.21 (1.87e-73)	-455.17 (9.54e-105)	-189.28 (1.16e-82)	-129.47 (4.05e-73)	-	-44.85 (9.97e-47)
	Süre(s)	121.706	557.048	187.613	7432.941	11243.477	358.552	512.807	1011.013	37071.320	96019.058	63765.646
br17	Minimum	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)	39 (%0.00)
	Ortalama	39.60 (%1.53)	44.00 (%12.82)	39.00 (%0.00)	39.53 (%1.36)	39.63 (%1.62)	39.00 (%0.00)	39.60 (%1.53)	41.50 (%6.41)	39.00 (%0.00)	39.00 (%0.00)	39.03 (%0.08)
	SD	1.45	6.66	0.00	1.33	1.42	0.00	0.77	4.76	0.00	0.00	0.18
	t-test (p değeri)	-2.26 (0.02)	-4.10 (0.0001)	nan (nan)	-2.19 (0.032)	-2.43 (0.018)	nan (nan)	-4.26 (7.40e-05)	-2.87 (0.005)	nan (nan)	-	-0.99 (0.32)
	Süre(s)	10.840	13.284	13.193	23.134	28.793	21.441	26.762	11.903	54.556	148.937	67.543

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
ftv33	Minimum	1415 (%10.03)	1431 (%11.27)	1286 (%0.00)	1415 (%10.03)	1459 (%13.45)	1532 (%19.12)	1982 (%54.12)	1494 (%16.17)	2341 (%82.03)	1316 (%2.33)	1406 (%9.33)
	Ortalama	1653.93 (%28.61)	1749.03 (%36.00)	1519.37 (%18.14)	1614.97 (%25.58)	1644.50 (%27.87)	1837.43 (%42.87)	2194.67 (%70.65)	1700.27 (%32.21)	2636.10 (%104.98)	1353.27 (%5.23)	1470.23 (%14.32)
	SD	106.05	128.01	124.06	117.67	115.95	94.72	103.12	103.00	143.73	16.24	42.01
	t-test (p değeri)	-15.34 (4.36e-22)	-16.79 (5.99e-24)	-7.27 (1.02e-09)	-12.06 (1.87e-17)	-13.62 (1.00e-19)	-27.59 (4.80e-35)	-44.14 (2.462e-46)	-18.22 (1.10e-25)	-48.57 (1.10 e-48)	-	-14.22 (1.45e-20)
	Süre(s)	14.844	21.532	17.971	46.527	63.921	32.502	42.151	18.617	151.758	314.465	190.318
ftv35	Minimum	1616 (%9.70)	1768 (%20.02)	1534 (%4.14)	1647 (%11.81)	1542 (%4.68)	1796 (%21.92)	2315 (%57.16)	1563 (%6.10)	2569 (%74.40)	1532 (%4.00)	1524 (%3.46)
	Ortalama	1845.10 (%25.26)	1973.87 (%34.00)	1741.37 (%18.21)	1847.30 (%25.41)	1857.13 (%26.07)	2108.03 (%43.11)	2542.03 (%72.57)	1877.70 (%27.47)	2922.77 (%98.42)	1550.03 (%5.22)	1632.20 (%10.80)
	SD	113.78	141.94	121.73	121.92	152.44	136.29	125.94	139.69	186.26	7.47	69.78
	t-test (p değeri)	-14.17 (1.70e-20)	-16.33 (2.31e-23)	-8.59 (6.26e-12)	-13.32 (2.62e-19)	-11.02 (7.48e-16)	-22.39 (3.14e-30)	-43.06 (9.93e-46)	-12.82 (1.39e-18)	-40.33 (3.93 e-44)	-	-6.41 (2.82e-08)
	Süre(s)	56.070	85.506	71.843	199.885	275.274	133.614	180.315	75.271	672.684	1376.630	960.381

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
ftv38	Minimum	1753 (%14.57)	1896 (%23.92)	1696 (%10.84)	1802 (%17.77)	1648 (%7.71)	2014 (%31.63)	2581 (%68.69)	1740 (%13.72)	2622 (%71.37)	1572 (%2.74)	1621 (%5.94)
	Ortalama	1965.13 (%28.44)	2126.50 (%38.98)	1942.80 (%26.98)	1992.80 (%30.24)	1958.93 (%28.03)	2267.40 (%48.19)	2777.17 (%81.51)	2008.33 (%31.26)	3152.77 (%106.06)	1606.53 (%5.00)	1689.07 (%10.39)
	SD	136.98	144.89	134.05	144.67	154.33	124.67	111.21	117.69	190.33	7.01	39.20
	t-test (p değeri)	-14.31 (1.06e-20)	-19.63 (2.68e-27)	-13.72 (7.31e-20)	-14.60 (4.32e-21)	-12.49 (4.33e-18)	-28.98 (3.32e-36)	-57.53 (7.34e-53)	-18.66 (3.38e-26)	-44.46 (1.63 e-46)	-	-11.35 (2.29e-16)
	Süre(s)	13.307	21.680	19.723	54.259	78.213	34.477	46.550	20.591	211.613	392.011	253.967
p43	Minimum	5658 (%0.67)	5702 (%1.45)	5663 (%0.76)	5657 (%0.65)	5658 (%0.67)	5679 (%1.04)	5859 (%4.25)	5657 (%0.65)	5693 (%1.29)	5627 (%0.12)	5646 (%0.46)
	Ortalama	5875.00 (%4.53)	8062.07 (%43.45)	5714.20 (%1.67)	6065.27 (%7.92)	5704.40 (%1.50)	5745.70 (%2.23)	5927.73 (%5.47)	7482.77 (%33.14)	5752.97 (%2.36)	5636.63 (%0.29)	5656.80 (%0.65)
	SD	970.64	2695.58	20.85	1357.70	25.44	42.56	34.97	2556.96	26.83	3.66	5.22
	t-test (p değeri)	-1.34 (0.183)	-4.92 (7.27e-06)	-20.06 (9.01e-28)	-1.72 (0.089)	-14.44 (7.29e-21)	-13.98 (3.12e-20)	-45.33 (5.50e-47)	-3.95 (0.0002)	-23.52 (2.36 e-31)	-	-17.31 (1.36e-24)
	Süre(s)	64.001	102.361	83.124	261.871	380.430	162.367	216.043	92.180	987.979	1513.001	1213.568

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
ftv44	Minimum	2026 (%25.60)	2219 (%37.56)	1945 (%20.58)	1847 (%14.50)	1955 (%21.20)	2354 (%45.93)	3069 (%90.26)	1964 (%21.76)	3214 (%99.25)	1675 (%3.84)	1784 (%10.60)
	Ortalama	2279.80 (%57.28)	2516.90 (%72.78)	2299.07 (%66.64)	2273.20 (%61.87)	2287.53 (%71.97)	2626.77 (%76.93)	3449.27 (%127.96)	2332.17 (%61.99)	3633.90 (%125.28)	1710.60 (%8.92)	1855.77 (%20.58)
	SD	120.50	125.95	163.88	213.75	211.12	119.37	174.58	162.46	178.92	30.96	47.85
	t-test (p değeri)	-25.05 (8.41e-33)	-34.04 (4.91e-40)	-19.32 (5.94e-27)	-14.26 (1.26e-20)	-14.80 (2.29e-21)	-40.69 (2.40e-44)	-53.71 (3.69e-51)	-20.58 (2.42e-28)	-58.01 (4.57 e-53)	-	-13.94 (3.48e-20)
	Süre(s)	61.602	99.325	78.721	268.410	377.632	155.370	210.030	89.160	990.624	2138.027	1417.122
ftv47	Minimum	2230 (%25.56)	2514 (%41.55)	2309 (%30.01)	2137 (%20.32)	2028 (%14.18)	2612 (%47.07)	3722 (%109.57)	2359 (%32.82)	3730 (%110.02)	1947 (%9.62)	1958 (%10.24)
	Ortalama	2516.27 (%41.68)	2844.20 (%60.14)	2644.33 (%48.89)	2530.67 (%42.49)	2505.60 (%41.08)	2868.63 (%61.52)	3970.40 (%123.55)	2620.73 (%47.56)	4344.63 (%144.63)	2011.17 (%13.24)	2145.53 (%20.80)
	SD	148.02	182.18	151.92	205.25	269.32	159.64	130.96	113.58	245.46	16.33	78.12
	t-test (p değeri)	-18.57 (4.30e-26)	-24.94 (1.07e-32)	-22.69 (1.55e-30)	-13.81 (5.30e-20)	-10.03 (2.71e-14)	-29.26 (1.98e-36)	-81.30 (1.82e-61)	-29.09 (2.73e-36)	-51.95 (2.44 e-50)	-	-9.22 (5.74e-13)
	Süre(s)	64.906	108.293	86.458	322.350	481.811	190.737	255.892	109.738	1249.263	2419.355	1733.169

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
ry48p	Minimum	17152 (%18.92)	19368 (%34.39)	16967 (%17.64)	16054 (%11.31)	15647 (%8.49)	19266 (%33.58)	25215 (%74.83)	17104 (%18.59)	24049 (%66.75)	14666 (%1.69)	15414 (%6.87)
	Ortalama	19423.03 (%34.67)	21383.43 (%48.26)	18516.13 (%28.38)	18337.17 (%27.14)	19063.63 (%32.18)	21951.97 (%52.21)	27985.97 (%94.05)	19017.07 (%31.86)	26376.87 (%82.89)	14772.13 (%2.42)	16445.33 (%14.02)
	SD	1142.08	1047.51	904.16	1260.49	1576.08	1345.30	1370.17	1345.84	1245.65	53.38	411.22
	t-test (p değeri)	-22.28 (4.06e-30)	-34.52 (2.27e-40)	-22.64 (1.76e-30)	-15.47 (2.95e-22)	-14.90 (1.70e-21)	-29.20 (2.20e-36)	-52.78 (9.96e-51)	-17.26 (1.59e-24)	-50.97 (7.16 e-50)	-	-22.10 (6.20e-30)
	Süre(s)	70.201	117.562	92.724	331.558	474.997	185.067	244.187	104.345	1300.876	2908.600	1760.452
ft53	Minimum	8907 (%28.99)	10234 (%48.21)	9744 (%41.11)	9410 (%36.27)	9646 (%39.69)	9860 (%42.79)	13720 (%98.69)	9478 (%37.26)	13698 (%98.37)	7507 (%8.71)	7815 (%13.17)
	Ortalama	10303.43 (%49.21)	11837.67 (%71.43)	10522.87 (%52.39)	10922.90 (%58.18)	10815.07 (%56.62)	11106.60 (%60.84)	14559.90 (%110.86)	10859.27 (%57.26)	15121.30 (%118.99)	7860.33 (%13.83)	8219.27 (%19.03)
	SD	790.65	718.34	365.82	847.16	809.98	655.14	394.14	633.94	745.36	171.86	221.17
	t-test (p değeri)	-16.53 (1.26e-23)	-29.49 (1.29e-36)	-36.08 (1.97e-41)	-19.40 (4.83e-27)	-19.54 (3.36e-27)	-26.25 (7.01e-34)	-85.34 (1.12e-62)	-25.00 (9.34e-33)	-51.99 (2.34 e-50)	-	-7.01 (2.72e-09)
	Süre(s)	67.878	94.287	86.648	347.366	495.952	178.345	231.684	105.291	1323.236	2765.092	1824.633

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
ftv55	Minimum	2236 (%39.05)	2487 (%54.66)	2395 (%48.94)	2220 (%38.05)	2156 (%34.07)	2773 (%72.45)	4012 (%149.50)	2337 (%45.33)	4118 (%156.09)	1698 (%5.59)	1790 (%11.31)
	Ortalama	2627.40 (%63.39)	3059.47 (%90.26)	2840.87 (%76.67)	2722.03 (%69.28)	2705.13 (%68.22)	3039.80 (%89.04)	4318.23 (%168.54)	2707.00 (%68.34)	4447.20 (%176.56)	1725.87 (%7.33)	1919.20 (%19.35)
	SD	190.03	227.09	168.71	262.74	332.39	173.03	138.64	193.92	203.17	16.84	79.11
	t-test (p değeri)	-25.88 (1.49e-33)	-32.07 (1.31e-38)	-36.01 (2.17e-41)	-20.72 (1.71e-28)	-16.11 (4.37e-23)	-41.39 (9.15e-45)	-101.66 (4.69e-67)	-27.60 (4.67e-35)	-73.11 (8.18 e-59)	-	-13.09 (5.77e-19)
	Süre(s)	72.085	130.861	96.459	426.853	626.283	209.519	272.997	122.716	1665.270	3761.014	2217.655
ftv64	Minimum	2894 (%57.36)	3323 (%80.69)	3216 (%74.87)	2666 (%44.97)	2737 (%48.83)	3354 (%82.38)	5052 (%174.71)	2987 (%62.42)	5130 (%178.95)	1947 (%5.87)	2065 (%12.28)
	Ortalama	3231.13 (%75.70)	3776.77 (%105.37)	3628.57 (%97.31)	3537.87 (%92.37)	3437.60 (%86.92)	3743.10 (%103.54)	5469.10 (%197.39)	3364.40 (%82.94)	5607.53 (%204.92)	1969.63 (%7.10)	2202.70 (%19.77)
	SD	188.79	193.60	212.63	355.16	338.14	208.65	194.07	175.07	259.34	13.59	75.83
	t-test (p değeri)	-36.50 (1.03e-41)	-50.99 (7.02e-50)	-42.64 (1.72e-45)	-24.16 (5.73e-32)	-23.75 (1.40e-31)	-46.45 (1.38e-47)	-98.52 (2.87e-66)	-43.50 (5.61e-46)	-76.72 (5.12 e-60)	-	-16.56 (1.15e-23)
	Süre(s)	70.670	145.642	105.063	533.851	781.402	229.781	310.241	142.478	2169.840	4946.616	3028.843

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
ft70	Minimum	44632 (%15.40)	47335 (%22.39)	46119 (%19.25)	44399 (%14.80)	44690 (%15.55)	46624 (%20.55)	54132 (%39.97)	44853 (%15.98)	54722 (%41.49)	40368 (%4.38)	40897 (%5.75)
	Ortalama	46397.83 (% 19.97)	49680.40 (%28.46)	47721.13 (%23.39)	48093.00 (%24.35)	48736.73 (%26.02)	47962.17 (%24.01)	55952.37 (%44.68)	47642.10 (%23.19)	56968.37 (%47.30)	40669.17 (%5.16)	41813.40 (%8.12)
	SD	1074.08	1079.99	909.01	1584.59	1607.56	958.47	901.84	1010.26	961.68	138.83	556.43
	t-test (p değeri)	-28.97 (3.43e-36)	-45.32 (5.54e-47)	-42.00 (4.03e-45)	-25.56 (2.90e-33)	-27.38 (7.22e-35)	-41.24 (1.12e-44)	-91.73 (1.75e-64)	-37.45 (2.47e-42)	-91.87 (1.60 e-64)	-	-10.92 (1.04e-15)
	Süre(s)	73.973	148.315	101.423	550.267	798.727	221.930	289.246	136.036	2272.096	4615.406	2586.271
ftv70	Minimum	3207 (%64.46)	3906 (%100.30)	3479 (%78.41)	3047 (%56.25)	2971 (%52.35)	3538 (%81.43)	5296 (%171.59)	3491 (%79.02)	5608 (%187.58)	2123 (%8.87)	2195 (%12.56)
	Ortalama	3641.50 (%86.74)	4332.87 (%122.198)	4052.80 (%107.83)	3881.60 (%99.05)	3903.57 (%100.18)	4190.83 (%114.91)	6161.20 (%215.95)	3771.03 (%93.38)	6360.13 (%226.16)	2170.03 (%11.28)	2325.33 (%19.24)
	SD	202.40	260.50	259.51	337.42	357.16	281.95	239.93	198.15	262.15	19.70	89.13
	t-test (p değeri)	-39.63 (1.05e-43)	-45.34 (5.43e-47)	-39.62 (1.06 e-43)	-27.73 (3.64e-35)	-26.54 (3.87e-34)	-39.16 (2.05e-43)	-90.80 (3.16e-64)	-44.03 (2.83e-46)	-87.29 (3.05 e-63)	-	-9.31 (3.97e-13)
	Süre(s)	67.511	140.905	94.856	540.342	805.015	225.886	297.539	144.966	2375.124	5549.571	3443.251

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
kro124p	Minimum	65102 (%79.69)	75632 (%108.75)	73093 (%101.74)	65054 (%79.55)	61456 (%69.62)	69739 (%92.48)	118497 (%227.06)	66569 (%83.74)	110073 (%203.81)	39459 (%8.91)	40625 (%12.13)
	Ortalama	70382.70 (%94.26)	86827.70 (%139.65)	80115.73 (%121.13)	74183.17 (%104.75)	74172.10 (%104.72)	79825.53 (%120.33)	125536.67 (%246.49)	74544.57 (%105.75)	120009.10 (%231.24)	40730.33 (%12.42)	43519.27 (%20.11)
	SD	3808.91	3894.20	3376.59	6118.41	7502.13	4482.85	3239.60	3526.62	4531.07	535.57	1190.76
	t-test (p değeri)	-42.22 (3.00 e-45)	-64.23 (1.36e-55)	-63.09 (3.77e-55)	-29.83 (6.97e-37)	-24.35 (3.81e-32)	-47.42 (4.28e-48)	-141.46 (2.42e-75)	-51.92 (2.53e-50)	-95.17 (2.11e-65)	-	-11.69 (6.73e-17)
	Süre(s)	85.759	199.707	120.140	936.352	1430.037	295.453	432.325	223.050	4629.755	13338.874	6654.634
ftv170	Minimum	9538 (%246.20)	12597 (%357.24)	11684 (%324.10)	11268 (%309.00)	9921 (%260.10)	10861 (%294.22)	18705 (%578.94)	10025 (%263.88)	11452 (%315.68)	3212 (%16.58)	3465 (%25.77)
	Ortalama	10467.07 (%279.93)	13746.50 (%398.96)	12483.80 (%353.13)	12839.03 (%366.02)	12707.17 (%361.24)	11726.83 (%325.65)	19445.80 (%605.83)	11278.90 (%309.39)	12313.37 (%346.94)	3334.17 (%21.02)	3854.97 (%39.92)
	SD	400.06	486.99	393.45	810.38	857.46	438.28	408.81	493.66	402.57	63.97	156.69
	t-test (p değeri)	-96.42 (9.92e-66)	-116.11 (2.19e-70)	-125.71 (2.22e-72)	-64.04 (1.6e-55)	-59.70 (8.89e-54)	-103.78 (1.43e-67)	-213.26 (1.16e-85)	-87.41 (2.82e-63)	-120.65 (2.39e-71)	-	-16.85 (5.10e-24)
	Süre(s)	133.689	415.633	204.601	2660.052	4083.593	494.605	676.936	540.908	13655.647	48947.340	20062.825

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
rbg323	Minimum	2943 (%121.94)	3899 (%194.04)	3299 (%148.79)	3793 (%186.04)	3848 (%190.19)	3114 (%134.84)	4968 (%274.66)	3153 (%137.78)	5596 (%322.02)	1729 (%30.39)	1615 (%21.79)
	Ortalama	3074.10 (%131.83)	4013.00 (%202.64)	3406.37 (%156.89)	4002.57 (%201.85)	4006.83 (%202.17)	3230.60 (%143.63)	5120.97 (%286.19)	3249.30 (%145.04)	5696.37 (%329.59)	1754.43 (%32.31)	1695.33 (%27.85)
	SD	67.29	66.43	64.96	128.69	97.50	71.67	62.43	52.27	59.78	13.26	43.82
	t-test (p değeri)	-105.37 (5.94e-68)	-182.60 (9.28e-82)	-136.46 (1.94e-74)	-95.17 (2.10e-65)	-125.37 (2.60e-72)	-110.91 (3.08e-69)	-288.89 (2.66e-93)	-151.82 (4.05e-77)	-352.57 (2.57e-98)	-	7.06 (2.23e-09)
	Süre(s)	61.211	241.006	92.955	1896.984	3242.363	220.781	300.312	389364	12671.335	46742.729	23066.243
rbg358	Minimum	3177 (%173.17)	4270 (%267.15)	3583 (%208.08)	4310 (%270.59)	4190 (%260.27)	3264 (%180.65)	5602 (%381.68)	3373 (%190.02)	6191 (%432.33)	1667 (%43.33)	1578 (%35.68)
	Ortalama	3328.03 (%186.15)	4451.90 (%282.79)	3701.90 (%218.30)	4458.07 (%283.32)	4452.23 (%282.82)	3483.87 (%199.55)	5724.63 (%392.23)	3552.63 (%205.47)	6347.23 (%445.76)	1737.67 (%49.41)	1655.23 (%42.32)
	SD	85.95	112.51	71.79	83.67	127.04	80.90	50.82	81.26	83.56	25.20	37.38
	t-test (p değeri)	-97.24 (6.10e-66)	-128.93 (5.16e-73)	-141.38 (2.50e-75)	-170.50 (4.93e-80)	-114.78 (4.25e-70)	-112.86 (1.13e-69)	-384.91 (1.59e-100)	-116.83 (1.53e-70)	-289.24 (2.48e-93)	-	10.01 (2.94e-14)
	Süre(s)	67.512	281.052	104.122	2318.058	3853.989	238.597	329.122	463.936	15542.617	92362.618	34153.716

Veri Seti	Sonuçlar	KEÇ	DÇ	SÇ	SDÇ	PDC	MKÇ	KBÇ	GKEÇ	AÇ	GAÇ	SYÇ
rbg403	Minimum	4223 (%71.31)	5205 (%111.15)	4527 (%83.65)	5200 (%110.95)	5088 (%106.40)	4199 (%70.34)	6390 (%159.22)	4435 (%79.91)	6858 (%178.21)	3391 (%37.56)	3327 (%34.96)
	Ortalama	4344.70 (%76.25)	5353.50 (%117.18)	4652.70 (%88.75)	5298.23 (%114.93)	5315.50 (%115.63)	4471.07 (%81.38)	6496.67 (%163.55)	4552.40 (%84.68)	7089.70 (%187.61)	3461.10 (%40.40)	3464.00 (%40.52)
	SD	73.37	79.70	57.31	62.13	97.96	90.74	46.43	57.11	86.80	39.83	64.81
	t-test (p değeri)	-57.96 (4.81e-53)	-116.32 (1.97e-70)	-93.50 (5.86e-65)	-136.33 (2.05e-74)	-96.04 (1.24e-65)	-55.81 (4.13e-52)	-271.75 (9.25e-92)	-85.83 (8.10e-63)	-208.09 (4.80e-85)	-	-0.20 (0.83)
	Süre(s)	80.329	347.886	126.736	2910.703	4728.761	262.226	379.246	621.005	19473.966	92359.136	46628.668
rbg443	Minimum	4693 (%72.53)	5610 (%106.25)	4981 (%83.12)	5686 (%109.04)	5611 (%106.28)	4800 (%76.47)	6937 (%155.03)	4919 (%80.84)	7601 (%179.44)	3872 (%42.35)	3861 (%41.94)
	Ortalama	4814.90 (%77.01)	5863.50 (%115.56)	5128.53 (%88.54)	5843.97 (%114.85)	5819.03 (%113.93)	4941.93 (%81.68)	7070.00 (%159.92)	5049.90 (%85.65)	7696.83 (%182.97)	3952.70 (%45.31)	3946.50 (%45.09)
	SD	64.47	90.98	84.12	98.32	112.90	89.02	51.51	70.86	54.14	39.22	54.95
	t-test (p değeri)	-62.57 (6.09e-55)	-105.63 (5.16e-68)	-69.38 (1.64e-57)	-105.19 (6.57e-68)	-85.52 (9.98e-63)	-55.69 (4.67e-52)	-263.71 (5.26e-91)	-74.19 (3.51e-59)	-306.73 (8.27e-95)	-	0.50 (0.61)
	Süre(s)	194.331	925.876	320.229	3607.286	13342.602	754.944	977.282	1714.381	45339.425	73779.265	91363.523

EK 9: Çaprazlama Operatörleri İçin Hesaplama Sürelerinin Karşılaştırılması

