



**T.C.
DÜZCE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**UYGUNLUK MESAFE DENGESİ TABANLI SEZGİSEL
OPTİMİZASYON ALGORİTMALARININ GÜÇ SİSTEMİ
PROBLEMLERİNE UYGULANMASI**

HÜSEYİN BAKIR

**DOKTORA TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMAN
PROF. DR. UĞUR GÜVENÇ**

DÜZCE, 2022

T.C.
DÜZCE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

UYGUNLUK MESAFE DENGESİ TABANLI OPTİMİZASYON
ALGORİTMALARININ GÜÇ SİSTEMİ PROBLEMLERİNE
UYGULANMASI

Hüseyin BAKIR tarafından hazırlanan tez çalışması aşağıdaki jüri tarafından Düzce Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Prof. Dr. Uğur GÜVENÇ

Düzce Üniversitesi

Eş Danışman

Prof. Dr. Hamdi Tolga KAHRAMAN

Karadeniz Teknik Üniversitesi

Jüri Üyeleri

Prof. Dr. Uğur GÜVENÇ

Düzce Üniversitesi

Prof. Dr. Yusuf SÖNMEZ

Gazi Üniversitesi

Doç. Dr. Serhat DUMAN

Bandırma Onyedli Eylül Üniversitesi

Prof. Dr. Hamdi Tolga KAHRAMAN

Karadeniz Teknik Üniversitesi

Doç. Dr. Mehmet Kenan DÖŞOĞLU

Düzce Üniversitesi

Doç. Dr. Salih TOSUN

Düzce Üniversitesi

Dr. Öğr. Üyesi Mustafa DURSUN

Düzce Üniversitesi

Tez Savunma Tarihi: 18/02/2022

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

18 Şubat 2022

Hüseyin BAKIR



TEŞEKKÜR

Doktora öğrenimimde ve bu tezin hazırlanmasında gösterdiği her türlü destek ve yardımdan dolayı çok değerli hocam Prof. Dr. Uğur GÜVENÇ'e en içten dileklerimle teşekkür ederim.

Tez çalışmam boyunca değerli katkılarını esirgemeyen ikinci danışmanım Prof. Dr. Hamdi Tolga KAHRAMAN'a şükranlarımı sunarım.

Değerli zamanlarını ayırarak tez çalışmasının kalitesini artırmaya yönelik katkıları, yapıcı yorumları ve süreç boyunca desteklerinden dolayı Prof. Dr. Yusuf SÖNMEZ ve Doç. Dr. Serhat DUMAN'a en içten dileklerimle teşekkürlerimi sunarım. Doktora süreci boyunca desteklerini hissettiren Arş. Gör. Dr. Ümit AĞBULUT'a ve Öğr. Gör. Muhammet Sinan BAŞARSLAN'a en içten dileklerimle teşekkürlerimi sunarım.

Bu çalışma boyunca yardımlarını ve desteklerini esirgemeyen sevgili aileme ve çalışma arkadaşlarıma sonsuz teşekkürlerimi sunarım.

Eğitim hayatımın tüm evrelerinde vermiş olduğu burs ve teşviklerden dolayı TÜBİTAK'a teşekkür ederim. Bu tez çalışması, TÜBİTAK 2211-A Yurtiçi Lisansüstü ve 100/2000 YÖK Doktora Burs Programları kapsamında hazırlanmıştır.

18 Şubat 2022

Hüseyin BAKIR

İÇİNDEKİLER

Sayfa No

ŞEKİL LİSTESİ.....	viii
ÇİZELGE LİSTESİ.....	x
KISALTMALAR.....	xiii
SİMGELER	xiv
ÖZET	xvi
ABSTRACT	xvii
EXTENDED ABSTRACT	xviii
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI.....	6
3. YÖNTEM	18
3.1. METASEZGİSEL OPTİMİZASYON SÜRECİ.....	18
3.1.1. Tek Amaçlı Optimizasyon	18
3.1.2. Çok Amaçlı Optimizasyon.....	22
3.2. FDB SEÇİM YÖNTEMİ	24
3.3. ÖNERİLEN DİNAMİK FDB SEÇİM YÖNTEMİ	28
3.4. UYGUNLUK MESAFE DENGESİ TABANLI TEK AMAÇLI OPTİMİZASYON ALGORİTMALARI.....	32
3.4.1. Önerilen FDBLFD Algoritması	33
3.4.1.1. LFD Algoritmasına Genel Bakış.....	33
3.4.1.2. FDBLFD Algoritması Tasarımı	36
3.4.1.3. FDBLFD Algoritmasının CEC 2017 ve CEC 2020 Benchmark Problemlerinde Test Edilmesi	39
3.4.1.4. FDBLFD Algoritması Arama Performansının Rekabetçi MSA Algoritmaları ile Karşılaştırılması	57
3.4.2. Önerilen FDBAGSK Algoritması	65
3.4.2.1. AGSK Algoritmasına Genel Bakış	65
3.4.2.2. FDBAGSK Algoritması Tasarımı.....	70
3.4.2.3. FDBAGSK Algoritmasının CEC 2017 ve CEC 2020 Benchmark Problemlerinde Test Edilmesi	75
3.4.3. Önerilen dFDB-MRFO Algoritması.....	93
3.4.3.1. MRFO Algoritmasına Genel Bakış	94
3.4.3.2. dFDB-MRFO Algoritması Tasarımı	96
3.4.3.3. dFDB-MRFO Algoritmasının CEC Benchmark Problemlerinde Test Edilmesi	98
3.5. ÇOK AMAÇLI ÇEKİRGE OPTİMİZASYON ALGORİTMASI	102
3.5.1. Pareto Tabanlı Çok Amaçlı Metasezgisel Arama Süreci	102
3.5.2. Çekirge Optimizasyon Algoritmasına Genel Bakış	104
3.5.3. Çok-Amaçlı Çekirge Optimizasyon Algoritmasının Tasarımı	107
4. YENİLENEBİLİR ENERJİ KAYNAKLARI VE YÜKSEK GERİLİM DOĞRU AKIM İLETİM HATTI İÇEREN GÜÇ SİSTEMLERİNDE ÇOK AMAÇLI OPTİMAL GÜÇ AKIŞI.....	110

4.1. ÇOK AMAÇLI OPTİMAL GÜÇ AKIŞI PROBLEMİNİN MATEMATİKSEL FORMÜLASYONU	111
4.1.1. Durum Değişkenleri	113
4.1.2. Kontrol Değişkenleri	113
4.1.3. Enerji Kaynaklarının Maliyet Modelleri	114
4.1.3.1. Termal Jeneratörlerin Üretim Maliyeti	114
4.1.3.2. Termal Jeneratörlerin Emisyon ve Karbon Vergisi Modeli	115
4.1.3.3. Yenilenebilir Enerji Kaynaklarının Doğrudan Maliyet Modeli	115
4.1.3.4. Yenilenebilir Enerji Kaynaklarının Belirsizlik Maliyet Modeli	116
4.2. RÜZGAR/GÜNEŞ/HİDRO/GELGİT ENERJİSİ VE BELİRSİZLİK MODELLERİ	117
4.2.1. Rüzgâr Enerjisi Ünitelerinin Stokastik Gücünün Hesaplanması	117
4.2.2. Güneş Enerjisi Ünitelerinin Stokastik Gücünün Hesaplanması	118
4.2.3. Hidro Enerji Ünitelerinin Stokastik Gücünün Hesaplanması	119
4.2.4. Gelgit Enerjisi Stokastik Gücünün Hesaplanması	120
4.3. AMAÇ FONKSİYONLARI VE KISITLAR	124
4.3.1. Amaç Fonksiyonları	124
4.3.1.1. Toplam Üretim Maliyeti	124
4.3.1.2. Valf Nokta Etkisi ile Toplam Üretim Maliyeti	124
4.3.1.3. Emisyon ve Karbon Vergisi ile Toplam Üretim Maliyeti	124
4.3.1.4. Gerilim Sapması	125
4.3.1.5. Aktif Güç Kayıpları	125
4.3.2. Problem Kısıtları	126
4.3.2.1. Eşitlik Kısıtları	126
4.3.2.2. Eşitsizlik Kısıtları	127
4.4. ÇOK AMAÇLI OPTİMAL GÜÇ AKIŞI PROBLEMİNİN SİMÜLASYON ÇALIŞMALARI, SONUÇLARI VE KARŞILAŞTIRMALARI	128
4.5. SONUÇLAR: ÇOK AMAÇLI OPTİMAL GÜÇ AKIŞI	148
5. DAĞITILMIŞ ÜRETİM VE YÜKSEK GERİLİM DOĞRU AKIM İLETİM HATLARINI İÇEREN GÜÇ SİSTEMLERİNDE OPTİMAL REAKTİF GÜÇ AKIŞI	149
5.1. OPTİMAL REAKTİF GÜÇ AKIŞI PROBLEMİNİN TANIMI VE MATEMATİKSEL FORMÜLASYONU	150
5.2. AMAÇ FONKSİYONLARI VE KISITLAR	152
5.2.1. Amaç Fonksiyonları	152
5.2.1.1. Güç kayıpları minimizasyonu	153
5.2.1.2. Gerilim sapması	153
5.2.1.3. Gerilim kararlılığının iyileştirilmesi	153
5.2.2. Kısıtlar	154
5.2.2.1. Eşitlik Kısıtları	154
5.2.2.2. Eşitsizlik Kısıtları	157
5.3. OPTİMAL REAKTİF GÜÇ AKIŞI PROBLEMİNİN SİMÜLASYON ÇALIŞMALARI VE SONUÇLARI	159
5.3.1. Modifiye IEEE 30 Baralı Test Sistemi	164
5.3.2. Modifiye IEEE 57 Baralı Test Sistemi	177
5.4. İSTATİSTİKSEL ANALİZ VE LİTERATÜR KARŞILAŞTIRMASI	187
5.5. SONUÇLAR: AA/DA OPTİMAL REAKTİF GÜÇ AKIŞI	190
6. OPTİMAL OTOMATİK GERİLİM REGÜLATÖRÜ TASARIMI	191
6.1. OGR SİSTEMİNİN MATEMATİKSEL MODELİ	192

6.2. OGR TASARIMINDA KULLANILAN KONTROLCÜLER	196
6.3. AMAÇ FONKSİYONLARI.....	198
6.4. OPTİMAL OGR TASARIMI PROBLEMİNİN SİMÜLASYON ÇALIŞMALARI, SONUÇLARI VE KARŞILAŞTIRMALARI	199
6.4.1. PID Kontrolcü ile OGR Tasarımı.....	200
6.4.2. PIDF Kontrolcü ile OGR Tasarımı	205
6.4.3. FOPID Kontrolcü ile OGR Tasarımı	209
6.4.4. PIDD ² Kontrolcü ile OGR Tasarımı	213
6.4.5. FDBLFD Tabanlı Kontrolcü Performanslarının Karşılaştırılması	217
6.5. LİTERATÜR KARŞILAŞTIRMASI.....	219
6.6. SONUÇLAR: OPTİMAL OGR TASARIMI	222
7. YÖNLÜ AŞIRI AKIM RÖLELERİ KOORDİNASYON PROBLEMİNİN MODELLENMESİ VE OPTİMİZASYONU	223
7.1. YAAR KOORDİNASYON PROBLEMİNİN MATEMATİKSEL MODELİ	224
7.2. YAAR KOORDİNASYON PROBLEMİNİN SİMÜLASYON ÇALIŞMALARI, SONUÇLARI VE KARŞILAŞTIRMALARI	227
7.3. İSTATİSTİKSEL ANALİZ VE YAKINSAMA ANALİZİ	250
7.4. SONUÇLAR: YAAR KOORDİNASYON PROBLEMİ	259
8. SONUÇLAR.....	261
9. KAYNAKLAR.....	268
10. EKLER	282
10.1. EK 1 KLASİK TEST PROBLEMLERİ.....	282
10.2. EK 2 IEEE CEC 2014	283
10.3. EK 3 IEEE CEC 2017	284
10.4. EK 4 IEEE CEC 2020	286
ÖZGEÇMİŞ	287

ŞEKİL LİSTESİ

Sayfa No

Şekil 3.1. FDB seçim yönteminin pratik bir uygulaması (a) Çözüm adayları konumu, (b) Normalize fitness değerleri, (c) Normalize mesafe değerleri, (d) Çözüm adaylarının FDB puanı.	26
Şekil 3.2. w ağırlık parametresi değişiminin keşif ve sömürüye etkisi (a) Çözüm adayları konumu (b) Farklı w değerleri için FDB puanı.	28
Şekil 3.3. Farklı frekanslar için w FDB sinyalinin üretilmesi (a) $F = 1$, (b) $F = 5$	31
Şekil 3.4. CEC 2017 test problemleri için box-plot grafikleri.....	47
Şekil 3.5. CEC 2020 test problemleri için box-plot grafikleri.....	49
Şekil 3.6. CEC 2020 test takımından seçilen farklı problem tipleri için LFD ve FDBLFD versiyonlarının yakınsama eğrileri.....	53
Şekil 3.7. LFD ve FDBLFD versiyonları için 30, 50 ve 100 boyutlu arama uzayındaki karmaşıklık bilgisi.	56
Şekil 3.8. CEC 2020 test takımından seçilen farklı problem tipleri için rekabetçi algoritmaların yakınsama eğrileri (Boyut=30, 50, 100).	62
Şekil 3.9. CEC 2017 test problemleri için box-plot grafikleri.....	84
Şekil 3.10. CEC 2020 test problemleri için box-plot grafikleri.....	87
Şekil 3.11. CEC 2017 test takımından seçilen farklı problem tipleri için AGSK ve FDBAGSK versiyonlarının yakınsama eğrileri.	90
Şekil 3.12. AGSK ve FDBAGSK versiyonlarının hesaplama karmaşıklığı.....	93
Şekil 3.13. MRFO ve varyantları için hesaplama karmaşıklığı.....	101
Şekil 3.14. Pareto tabanlı çok amaçlı optimizasyonun genel konsepti.	103
Şekil 4.1. Önerilen ÇAOGA probleminin şematik diyagramı.....	112
Şekil 4.2. (a) ve (b) Bara 8 ve 13'teki rüzgâr çiftliği için rüzgâr hızı (v_w) dağılımı, (c) Bara 11'deki PV sistem için solar radyasyon (G_{pv}) dağılımı, (d) Bara 11'deki hidro enerji ünitesi için nehir akış hızı (Q_{wsh}) dağılımı (e) Bara 13'teki gelgit enerjisi için deşarj oranı (Q_{TDL}) dağılımı.	121
Şekil 4.3. Yenilenebilir enerji kaynakları ve GKD tabanlı ÇTYGDA iletim hattı ile modifiye edilmiş IEEE 30-baralı test sistemi.....	129
Şekil 4.4. (a) Durum-1 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.....	132
Şekil 4.5. (a) Durum-2 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.....	135
Şekil 4.6. (a) Durum-3 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.....	138
Şekil 4.7. (a) Durum-4 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.....	140
Şekil 4.8. (a) Durum-5 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.....	143
Şekil 4.9. (a) Durum-6 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.....	146
Şekil 5.1. Dağıtılmış üretim (DG) ve DA iletim hattı ile modellenen AA bara.	155
Şekil 5.2. İki terminalli YGDA iletim hattı.	157
Şekil 5.3. İki terminalli YGDA iletim hattı eşdeğer devre modeli.	157
Şekil 5.4. AA/DA ORGA probleminin optimizasyon süreci.....	163
Şekil 5.5. Durum-1: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	165
Şekil 5.6. Durum-2: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	167

Şekil 5.7. Durum-3: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	168
Şekil 5.8. Durum-4: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	170
Şekil 5.9. Durum-5: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	171
Şekil 5.10. Durum-6: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	173
Şekil 5.11. Durum-7: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	174
Şekil 5.12. Durum 8: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	178
Şekil 5.13. Durum-9: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	179
Şekil 5.14. Durum-10: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	181
Şekil 5.15. Durum-11: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	182
Şekil 5.16. Durum-12: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.	184
Şekil 6.1. OGR sisteminin basitleştirilmiş modeli.....	193
Şekil 6.2. Kontrolcü kullanılmadığında OGR sisteminin birim basamak tepkisi.....	195
Şekil 6.3. Kontrolör ile modellenen OGR sisteminin transfer fonksiyon modeli.....	195
Şekil 6.4. PID kontrolcü blok diyagramı.	196
Şekil 6.5. PIDF kontrolcü blok diyagramı.	196
Şekil 6.6. FOPID kontrolcü blok diyagramı.	197
Şekil 6.7. PIDD ² kontrolcü blok diyagramı.	198
Şekil 6.8. Optimal OGR tasarımı optimizasyon probleminin şematik diyagramı.	199
Şekil 6.9. PID denetleyici tabanlı OGR sisteminin birim basamak tepkisi.	201
Şekil 6.10. Zaman sabitlerinin nominal değer -%50 ve +%50 aralığındaki değişimi için FDBLFD-PID ile tasarlanan OGR sistemi birim basamak tepkisi (a) TA, (b) TE, (c) TG, (d) TS.....	203
Şekil 6.11. PIDF denetleyici tabanlı OGR sisteminin birim basamak tepkisi.	206
Şekil 6.12. Zaman sabitlerinin nominal değer -%50 ve +%50 aralığındaki değişimi için FDBLFD-PIDF ile tasarlanan OGR sistemi birim basamak tepkisi (a) TA, (b) TE, (c) TG, (d) TS.....	207
Şekil 6.13. FOPID denetleyici tabanlı OGR sisteminin birim basamak tepkisi.	210
Şekil 6.14. Zaman sabitlerinin nominal değer -%50 ve +%50 aralığındaki değişimi için FDBLFD-FOPID ile tasarlanan OGR sistemi birim basamak tepkisi (a) TA, (b) TE, (c) TG, (d) TS.	211
Şekil 6.15. PIDD ² denetleyici tabanlı OGR sisteminin birim basamak tepkisi.	214
Şekil 6.16. Zaman sabitlerinin nominal değer -%50 ve +%50 aralığındaki değişimi için FDBLFD-PIDD ² ile tasarlanan OGR sistemi birim basamak tepkisi (a) TA, (b) TE, (c) TG, (d) TS.....	215
Şekil 6.17. PID, PIDF, FOPID ve PIDD ² kontrolcüler ile tasarlanan OGR sisteminin birim basamak tepkisi.....	218
Şekil 7.1. Birincil/yedek röle çiftlerini içeren temsili bir elektrik şebekesi.	223
Şekil 7.2. Birincil ve yedek röleler arasında koordinasyon.	226
Şekil 7.3. IEEE 3-baralı test sistemi.	229
Şekil 7.4. IEEE 4-baralı test sistemi.	232
Şekil 7.5. Standart 8-baralı test sistemi.....	235
Şekil 7.6. Standart 9-baralı test sistemi.....	239
Şekil 7.7. IEEE 30-baralı test sistemi.	243
Şekil 7.8. Box-plot grafikleri (a) Test Sistemi-1, (b) Test Sistemi-2, (c) Test Sistemi-3, (d) Test Sistemi-4, (e) Test Sistemi-5.	252
Şekil 7.9. Optimizasyon algoritmalarının yakınsama eğrileri	257

ÇİZELGE LİSTESİ

Sayfa No

Çizelge 3.1. Metasezgisel arama süreci genel adımları.....	20
Çizelge 3.2. Pareto baskınlık kavramı terminolojisi.....	23
Çizelge 3.3. Dinamik ayarlanabilir <i>wdFDB</i> sinyali üretmek için kullanılan sözde-kod.....	31
Çizelge 3.4. <i>Lévy_Flight</i> alt fonksiyonu genel adımları.....	35
Çizelge 3.5. FDBLFD versiyonlarının matematiksel modeli.....	38
Çizelge 3.6. Önerilen FDBLFD algoritmasının sözde-kodu.....	38
Çizelge 3.7. FDBLFD versiyonları ve LFD için Friedman testi ile elde edilen sıralar.....	40
Çizelge 3.8. LFD ve FDBLFD versiyonları arasında Wilcoxon ikili karşılaştırma sonuçları.....	41
Çizelge 3.9. Farklı problem tipleri için LFD ve FDBLFD versiyonlarının Friedman sıralaması.....	42
Çizelge 3.10. CEC 2020 test problemleri için elde edilen ortalama hata ve standart sapma değerleri.....	44
Çizelge 3.11. LFD ve FDBLFD versiyonları için algoritma karmaşıklığı bilgisi.....	56
Çizelge 3.12. FDBLFD ve rakip algoritmalar için Friedman testi ile elde edilen sıralar.....	57
Çizelge 3.13. FDBLFD ve rekabetçi algoritmalar arasında Wilcoxon ikili karşılaştırma sonuçları.....	59
Çizelge 3.14. Rekabetçi MSA algoritmalarının karmaşıklık bilgisi.....	64
Çizelge 3.15. GSK algoritmasının optimizasyon şeması.....	66
Çizelge 3.16. Genç bilgi edinme-paylaşma aşamasının sözde-kodu.....	67
Çizelge 3.17. Kıdemli bilgi edinme-paylaşma aşamasının sözde-kodu.....	68
Çizelge 3.18. Adaptif prosedür.....	69
Çizelge 3.19. Önerilen FDBAGSK versiyonlarının matematiksel modeli.....	72
Çizelge 3.20. Önerilen FDBAGSK algoritmasının sözde-kodu.....	72
Çizelge 3.21. FDBAGSK versiyonları ve AGSK için Friedman testi ile elde edilen sıralar.....	76
Çizelge 3.22. AGSK ve FDBAGSK versiyonları arasında Wilcoxon ikili karşılaştırma sonuçları.....	76
Çizelge 3.23. Farklı problem tipleri için AGSK ve FDBAGSK versiyonlarının Friedman sıraları.....	77
Çizelge 3.24. CEC 2017 test problemleri için elde edilen ortalama ve standart sapma değerleri.....	79
Çizelge 3.25. Algoritma karmaşıklığı bilgisi.....	92
Çizelge 3.26. MRFO algoritmasında kullanılan çözüm aday bilgileri ve <i>dFDB</i> stratejisinin uygulanması.....	96
Çizelge 3.27. FDB ve <i>dFDB</i> seçim yöntemleri ile tasarlanan MRFO varyantları.....	97
Çizelge 3.28. Önerilen <i>dFDB</i> -MRFO algoritmasının sözde-kodu.....	97
Çizelge 3.29. MRFO versiyonları için Friedman testi ile elde edilen sıralar.....	99
Çizelge 3.30. Wilcoxon ikili karşılaştırma sonuçları.....	100
Çizelge 3.31. MRFO ve varyantları için algoritma karmaşıklığı bilgisi.....	101
Çizelge 3.32. GOA algoritmasının sözde-kodu.....	107
Çizelge 3.33. MOGOA algoritmasının sözde-kodu.....	108
Çizelge 4.1. Yenilenebilir enerji kaynaklarının stokastik modelleri için ODF	

parametreleri.....	120
Çizelge 4.2. Modifiye IEEE 30-baralı test sistemi konfigürasyonu.	128
Çizelge 4.3. Termal jeneratörlerin maliyet ve emisyon katsayıları.	130
Çizelge 4.4. Stokastik yenilenebilir enerji kaynaklarının doğrudan, fazla-tahmin ve eksik-tahmin maliyet katsayıları.	130
Çizelge 4.5. Simülasyon çalışmalarının özeti.	131
Çizelge 4.6. Durum-1 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.	133
Çizelge 4.7. Durum-2 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.	136
Çizelge 4.8. Durum-3 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.	139
Çizelge 4.9. Durum-4 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.	141
Çizelge 4.10. Durum-5 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.	144
Çizelge 4.11. Durum-6 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.	147
Çizelge 5.1. IEEE 30 ve IEEE 57-baralı test sistemleri konfigürasyonu.	160
Çizelge 5.2. AA/DA ORGA problemi durum değişkenlerinin minimum ve maksimum limitleri.	160
Çizelge 5.3. AA/DA ORGA problemi kontrol değişkenlerinin minimum ve maksimum limitleri.	161
Çizelge 5.4. Simülasyon çalışmalarının özeti.	164
Çizelge 5.5. IEEE 30-baralı test sistemi simülasyon sonuçları.	176
Çizelge 5.6. IEEE 57-baralı test sistemi simülasyon sonuçları.	185
Çizelge 5.7. 20 bağımsız deneme için elde edilen istatistiksel analiz sonuçları.	187
Çizelge 5.8. Literatür karşılaştırması.	189
Çizelge 6.1. OGR sisteminde kullanılan parametrelerin limitleri ve seçilen değerler.	194
Çizelge 6.2. Kontrolcü parametrelerinin limit değerleri.	200
Çizelge 6.3. Önerilen FDBLFD ve rekabetçi algoritmalar ile optimize edilen PID kontrolcü parametreleri ve OGR sistemi geçici tepki özellikleri.	200
Çizelge 6.4. FDBLFD tabanlı PID kontrolcü ile tasarlanan OGR sisteminin sağlamlık analizi sonuçları.	202
Çizelge 6.5. Önerilen FDBLFD ve rekabetçi algoritmalar ile optimize edilen PIDF kontrolcü parametreleri ve OGR sistemi geçici tepki özellikleri.	205
Çizelge 6.6. FDBLFD tabanlı PIDF kontrolcü ile tasarlanan OGR sisteminin sağlamlık analizi sonuçları.	206
Çizelge 6.7. Önerilen FDBLFD ve rekabetçi algoritmalar ile optimize edilen FOPID kontrolcü parametreleri ve OGR sistemi geçici tepki özellikleri.	209
Çizelge 6.8. FDBLFD tabanlı FOPID kontrolcü ile tasarlanan OGR sisteminin sağlamlık analizi sonuçları.	210
Çizelge 6.9. Önerilen FDBLFD ve rekabetçi algoritmalar ile optimize edilen PIDD ² kontrolcü parametreleri ve OGR sistemi geçici tepki özellikleri.	213
Çizelge 6.10. FDBLFD tabanlı PIDD ² kontrolcü ile tasarlanan OGR sisteminin sağlamlık analizi sonuçları.	215
Çizelge 6.11. FDBLFD tabanlı PID, PIDF, FOPID ve PIDD ² kontrolcülerini ile tasarlanan OGR sisteminin geçici tepki parametreleri.	217
Çizelge 6.12. Literatür karşılaştırması.	220
Çizelge 7.1. Simülasyon çalışmalarında kullanılan test sistemleri konfigürasyonu.	228

Çizelge 7.2. Farklı test sistemleri için kısıtlar.	228
Çizelge 7.3. Test Sistemi-1 için röle tarafından okunan arıza akımı (I_i).	229
Çizelge 7.4. Birincil/yedek röle çiftleri için arıza akımı (I_i) değerleri (Test Sistemi-1).	229
Çizelge 7.5. Test Sistemi-1 simülasyon sonuçları.	230
Çizelge 7.6. Test Sistemi-1 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.	231
Çizelge 7.7. Test Sistemi-1 için birincil rölelerin çalışma süresi.	231
Çizelge 7.8. Test Sistemi-2 için röle tarafından okunan arıza akımı (I_i).	232
Çizelge 7.9. Birincil/yedek röle çiftleri için arıza akımı (I_i) değerleri (Test Sistemi-2).	232
Çizelge 7.10. Test Sistemi-2 simülasyon sonuçları.	233
Çizelge 7.11. Test Sistemi-2 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.	234
Çizelge 7.12. Test Sistemi-2 için birincil rölelerin çalışma süresi.	234
Çizelge 7.13. Birincil/yedek röle çiftleri ve arıza akımı (I_f) (Test Sistemi-3).	235
Çizelge 7.14. Test Sistemi-3 simülasyon sonuçları.	236
Çizelge 7.15. Test Sistemi-3 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.	237
Çizelge 7.16. Test Sistemi-3 için birincil rölelerin çalışma süresi.	237
Çizelge 7.17. Birincil/yedek röle çiftleri ve arıza akımı (I_f) (Test Sistemi-4).	239
Çizelge 7.18. Test Sistemi-4 simülasyon sonuçları.	240
Çizelge 7.19. Test sistemi-4 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.	241
Çizelge 7.20. Test sistemi-4 için birincil rölelerin çalışma süresi.	242
Çizelge 7.21. Birincil/yedek röle çiftleri ve arıza akımı (I_f) (Test Sistemi-5).	244
Çizelge 7.22. Test sistemi-5 simülasyon sonuçları.	245
Çizelge 7.23. Test sistemi-5 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.	247
Çizelge 7.24. Test sistemi-5 için birincil rölelerin çalışma süresi.	249
Çizelge 7.25. 30 deneme için elde edilen minimum, ortalama, maksimum ve standart sapma değerleri.	251
Çizelge 7.26. Wilcoxon ikili işaret testi sonuçları.	252
Çizelge 10.1. Klasik test fonksiyonları[19].	282
Çizelge 10.2. CEC 2014 test fonksiyonları [104].	283
Çizelge 10.3. CEC 2017 test fonksiyonları [85, 102].	284
Çizelge 10.4. CEC 2020 test fonksiyonları [103].	286

KISALTMALAR

AA	Alternatif Akım
AGSK	Adaptive Gaining Sharing Knowledge
CEC	Congress on Evolutionary Computation
ÇAOGA	Çok Amaçlı Optimal Güç Akışı
ÇTYGDA	Çok Terminalli Yüksek Gerilim Doğru Akım
DA	Doğru Akım
dFDB	Dynamic Fitness Distance Balance
FDB	Fitness Distance Balance
FOPID	Fractional Order- Proportional Integral Derivative
GKD	Gerilim Kaynağı Dönüştürücü
IEEE	Institute of Electrical and Electronics Engineer
LFD	Levy Flight Distribution
MOGOA	Multi-objective Grasshopper Optimization Algorithm
MRFO	Manta Ray Foraging Optimization
MSA	Meta-Sezgisel Arama
ODF	Olasılık Dağılım Fonksiyonu
OGA	Optimal Güç Akışı
OGR	Otomatik Gerilim Regülatörü
ORGA	Optimal Reaktif Güç Akışı
PCS	Pickup Current Setting
PID	Proportional Integral Derivative
PIDD ²	Proportional Integral Derivative plus Second Order Derivative
PIDF	Proportional Integral Derivative with Filter
TDS	Time Dial Setting
YAAR	Yönlü Aşırı Akım Röleleri
YGDA	Yüksek Gerilim Doğru Akım

SİMGELER

A_i	Rüzgâr Hareketi
A	Arşiv (Bastırılmayan Çözüm Adayları)
c	Öğrenme Oranı
CT	Akım Trafosu
CTI	Koordinasyon Zaman Aralığı
CT_{rating}	Akım Trafosu Dönüştürme Oranı
D	Tasarım Değişkenleri Sayısı
d_{ij}	i . ve j . Çekirge Arasındaki Mesafe
f	Fitness (Uygunluk) Fonksiyonu
F	Frekans
F_{obj}	Amaç Fonksiyonu
g	Yerçekimi Sabiti
g_k	Eşitlik Kısıtları
G_i	i . Çekirge Üzerindeki Yerçekimi Kuvveti
h_l	Eşitsizlik Kısıtları
$Iter$	Mevcut İterasyon İndeksi
$I_{f,i}$	Akım Trafosu Primer Terminallerindeki Arıza Akımı
I_i	i . Röle Tarafından Okunan Arıza Akımı
k_f	Bilgi Faktörü
k_r	Bilgi Oranı
K	Bilgi Paylaşım Katsayısı
K_A	Yükseltici Kazanç Katsayısı
K_E	Uyarıcı Kazanç Katsayısı
K_G	Jeneratör Kazanç Katsayısı
K_S	Sensör Kazanç Katsayısı
kg/m^3	Kilogram/Metreküp
lb	Tasarım Parametresi Alt Limiti
L_{index}	Gerilim Kararlılığı İndeksi
max	Maksimum
$maxFEs$	Maksimum Fitness Fonksiyonu Değerlendirme Sayısı
min	Minimum
m/s^2	Metre/ Saniye Kare
$MVAr$	Megavolt-Amper
MOF	Modifiye Amaç Fonksiyonu
MW	Megawatt
N	Çözüm Adayları Sayısı (Popülasyon Büyüklüğü)
ND	Normal Dağılım
η	Verim
$normf$	Normalize Fitness Değeri
$normU$	Normalize Uzaklık (Mesafe) Değeri
n_{obj}	Amaç Fonksiyonu Sayısı
O_A	Arşivdeki Çözüm Adaylarının Amaç Fonksiyonu Değeri
O_P	P-popülasyonundaki Çözüm Adaylarının Amaç Fonksiyonu Değeri
OS	Maksimum Aşım
P	Çözüm Adayları Seti (Popülasyon)
P/B	Birincil/Yedek

P_{loss}	Aktif Güç Kayıpları
p.u.	Per Unit
rad/MW	Radyan/ Megawatt
s	Saniye
S_i	Sosyal Etkileşim
S_P	FDB Skor Vektörü
T_A	Yükseltici Zaman Sabiti
T_{br}	Yedek Röle Çalışma Süresi
T_E	Uyarıcı Zaman Sabiti
T_G	Jeneratör Zaman Sabiti
T_{max}	Maksimum İterasyon Sayısı
T_{pr}	Birincil Röle Çalışma Süresi
T_S	Sensör Zaman Sabiti
t_r	Yükselme Zamanı
t_s	Yerleşme Zamanı
u	Sürüklenme Katsayısı
ub	Tasarım Parametresi Üst Limiti
U_P	Uzaklık (Mesafe) Vektörü
VD	Gerilim Sapması
$\vec{x}$	Tasarım Değişkenleri Vektörü
x_{best}	En İyi Çözüm
x_{dFDB}	dFDB Yöntemi ile Seçilen Rehber Çözüm Adayı
x_{FDB}	FDB Yöntemi ile Seçilen Rehber Çözüm Adayı
x_m	Daha İyi veya Orta Bireyler
x_{pbest}	En İyi Bireyler
x_{pworst}	En Kötü Bireyler
x_r	Referans Çözüm Adayı
x_{RFDB}	Rulet FDB Yöntemi ile Seçilen Rehber Çözüm Adayı
w_{dFDB}	dFDB Ağırlık Katsayısı
Γ	Gama Fonksiyonu
\$/h	Dolar/Saat
\$/MWh	Dolar/Megawatt Saat
Δ_{ps}	İyileştirme Oranı

ÖZET

UYGUNLUK MESAFE DENGESİ TABANLI SEZGİSEL OPTİMİZASYON ALGORİTMALARININ GÜÇ SİSTEMİ PROBLEMLERİNE UYGULANMASI

Hüseyin BAKIR

Düzce Üniversitesi

Lisansüstü Eğitim Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Doktora Tezi

Danışman: Prof. Dr. Uğur GÜVENÇ

Şubat 2022, 286 sayfa

Bu tez çalışmasında, modern güç sistemlerinin planlanması ve işletiminde kritik öneme sahip kısıtlı güç sistemi problemlerinin çözümü için hibrit optimizasyon algoritmalarının geliştirilmesi amaçlanmıştır. Bu kapsamda, optimizasyon alanında iki önemli konu üzerinde araştırma yapılmış ve önemli kazanımlar elde edilmiştir. Bu konulardan ilki, uygunluk-mesafe dengesi (Fitness-Distance Balance, FDB) ve dinamik uygunluk-mesafe dengesi (Dynamic Fitness Distance-Balance, *d*FDB) seçim yöntemlerini kullanarak tek amaçlı metasezgisel algoritmaların arama performansının geliştirilmesidir. Erken yakınsama ve zayıf çeşitlilik problemlerinden muzdarip olan uyarlanabilir bilgi edinme-paylaşma (Adaptive Gaining-Sharing Knowledge, AGSK) ve Levy uçuş dağılımı (Levy Flight Distribution, LFD) algoritmalarının handikaplarını ortadan kaldırmak ve böylece arama performansını iyileştirmek için FDB seçim yöntemi kullanılmıştır. Baz algoritmaların seçim stratejileri FDB yöntemi kullanılarak yeniden tasarlanmış ve global optimizasyon problemlerini etkin bir şekilde çözüme yeteneğine sahip hibrit FDBAGSK ve FDBLFD algoritmaları geliştirilmiştir. Bu çalışmanın orijinal katkılarından biri olarak geliştirilen *d*FDB seçim yöntemi manta ışıını yiyecek arama optimizasyonu (Manta Ray Foraging Optimization, MRFO) algoritmasına uygulanmış ve *d*FDB-MRFO olarak isimlendirilen yeni bir hibrit algoritma önerilmiştir. Araştırmanın yürütüldüğü ikinci konu, kısıtlı güç sistemi problemlerinin optimizasyonudur. Bu kapsamda ilk olarak, stokastik rüzgâr, güneş, hidro ve gelgit enerji kaynakları ile Çok-Terminalli Yüksek Gerilim Doğru Akım (ÇTYGDA) iletim hattı bağlantılarını içeren IEEE 30-baralı güç sisteminde Çok-Amaçlı Optimal Güç Akışı (ÇAOGA) probleminin optimizasyon modeli sunulmuştur. Önerilen problemin optimizasyonunda çok amaçlı çekirge optimizasyon algoritması (Multi-objective Grasshopper Optimization Algorithm, MOGOA) ve literatürdeki güçlü optimizasyon yöntemleri kullanılmıştır. Simülasyon sonuçları, MOGOA yönteminin, elde edilen Pareto optimal çözümlerin doğruluğu ve bunların dağılımı açısından oldukça rekabetçi sonuçlar elde ettiğini göstermiştir. Ardından, önerilen FDBAGSK algoritması dağıtılmış üretim ve iki terminalli YGDA iletim bağlantılarını içeren IEEE 30 ve IEEE 57-baralı güç sistemlerinde Alternatif Akım/Doğru Akım Optimal Reaktif Güç Akışı (AA/DA ORGA) probleminin çözümüne uygulanmıştır. Simülasyon sonuçlarından elde edilen bulgular, hibrit FDBAGSK algoritmasının büyük ölçekli güç sistemlerinde ORGA probleminin farklı konfigürasyonlarını verimli bir şekilde çözebildiğini göstermiştir. Optimal Otomatik Gerilim Regülatörü (OGR) tasarımında kullanılan PID, PIDF, FOPID ve PIDD² kontrolcü parametrelerinin optimizasyonuna hibrit FDBLFD algoritması uygulanmıştır. Optimum OGR tasarımı için en iyi kontrolcü performansı, FDBLFD tabanlı PIDD² ile elde edilmiştir. Son olarak, Yönlü Aşırı Akım Röleleri (YAAR) koordinasyon problemi hibrit *d*FDB-MRFO algoritması kullanılarak optimize edilmiştir. Önerilen optimizasyon yönteminin etkinliğini doğrulamak için, farklı karmaşıklığa sahip beş test sistemi üzerinde kapsamlı bir simülasyon gerçekleştirilmiştir. Simülasyon sonuçları, önerilen hibrit algoritmanın, YAAR koordinasyon problemini çözmek için verimli ve güvenilir bir yöntem olduğunu doğrulamıştır. Tüm sonuçlar bir arada düşünüldüğünde tez çalışmasında önerilen uygunluk mesafe dengesi tabanlı hibrit optimizasyon algoritmalarının güç sistemi problemlerine karşılaştırılan diğer algoritmalara kıyasla daha düşük hata ve yüksek doğruluk ile optimum çözümler üretebildiği gözlemlenmiştir.

Anahtar sözcükler: Güç sistemi problemlerinin optimizasyonu, Metasezgisel algoritma tasarımı, Uygunluk-mesafe dengesi tabanlı seçim yöntemleri, Yenilenebilir enerji kaynakları.

ABSTRACT

APPLICATION OF FITNESS DISTANCE BALANCE BASED HEURISTIC OPTIMIZATION ALGORITHMS TO POWER SYSTEM PROBLEMS

Hüseyin BAKIR

Düzce University

Graduate School, Department of Electrical-Electronics Engineering

Doctoral Thesis

Supervisor: Prof. Dr. Uğur GÜVENÇ

February 2022, 286 pages

In this thesis study, it is aimed to develop hybrid optimization algorithms for the solution of constrained power system problems that are critical in the planning and operation of modern power systems. In this context, research was carried out on two important issues in the field of optimization and significant achievements were obtained. The first of these issues was to improve the search performance of single-objective metaheuristic algorithms by using Fitness-Distance Balance (FDB) and Dynamic Fitness-Distance Balance (d FDB) selection methods. FDB selection method was used to eliminate the handicaps of Adaptive Gaining-Sharing Knowledge (AGSK) and Levy Flight Distribution (LFD) algorithms, which suffer from premature convergence and poor diversity, and thus improve the search performance. The selection strategies of the original algorithms were redesigned using the FDB method, and thus hybrid FDBAGSK and FDBLFD algorithms were developed, which have the ability to effectively solve global optimization problems. The d FDB selection method, which was developed as one of the original contributions of this study, was applied to the Manta Ray Foraging Optimization (MRFO) algorithm and a new hybrid algorithm called d FDB-MRFO was proposed. The second subject on which research was conducted was the optimization of constrained power system problems. In this regard, firstly, the optimization model of the Multi-Objective Optimal Power Flow (MO-OPF) problem in IEEE 30-bus power system incorporating stochastic wind, solar, hydro, tidal energy sources and Multi-Terminal High Voltage Direct Current (MTHVDC) transmission links were presented. In the optimization of the proposed problem, the Multi-objective Grasshopper Optimization Algorithm (MOGOA) and the powerful optimization methods in the literature are used. The simulation results showed that the MOGOA method obtained very competitive results in terms of the accuracy of the obtained Pareto optimal solutions and their distribution. Then, the FDBAGSK algorithm is applied to the solution of the Alternating Current/Direct Current Optimal Reactive Power Flow (AC/DC ORPF) problem in IEEE 30 and IEEE 57-bus power systems incorporating distributed generation and two-terminal HVDC transmission links. Findings from the simulation results showed that the proposed FDBAGSK algorithm can efficiently solve different configurations of the ORPF problem in large-scale power systems. After that, the hybrid FDBLFD algorithm was applied to the optimization of the PID, PIDF, FOPID and PIDD² controller parameters used in the optimal design of the Automatic Voltage Regulator (AVR). The best controller performance for optimal AVR design was achieved by FDBLFD based PIDD². Finally, the Directional Overcurrent Relays (DOCRs) coordination problem was optimized using the hybrid d FDB-MRFO algorithm. To verify the effectiveness of the proposed optimization method, a comprehensive simulation was performed on five test systems with different complexities. The simulation results confirmed that the proposed hybrid algorithm is an efficient and reliable method to solve the DOCRs coordination problem. When all the results are considered together, it has been observed that the fitness distance balance-based hybrid optimization algorithms proposed in the thesis study can produce optimum solutions with lower error and high accuracy compared to other algorithms for power system problems.

Keywords: Fitness-distance balance based selection methods, Metaheuristic algorithm design, Optimization of power system problems, Renewable energy sources.

EXTENDED ABSTRACT

APPLICATION OF FITNESS DISTANCE BALANCE BASED HEURISTIC OPTIMIZATION ALGORITHMS TO POWER SYSTEM PROBLEMS

Hüseyin BAKIR

Düzce University

Graduate School, Department of Electrical-Electronics Engineering

Doctoral Thesis

Supervisor: Prof. Dr. Uğur GÜVENÇ

February 2022, 286 pages

1. INTRODUCTION

Metaheuristic search algorithms are generally developed by testing on simple and classical optimization problems. However, optimizing, non-convex, non-linear, and high-dimensional real-world engineering problems is a major challenge. Because the requirements of engineering design problems are different from traditional search problems. This case necessitates the development of an efficient and powerful metaheuristic search algorithm for every real-world engineering problem. In this thesis, it is aimed to improve the search performance of single objective metaheuristic algorithms to successfully optimize constrained power system problems.

2. MATERIAL AND METHODS

In this thesis study, three new algorithms named FDBAGSK, FDBLFD and d FDB-MRFO have been developed to solve global numerical optimization problems by hybridizing FDB and d FDB selection methods with traditional AGSK, LFD and MRFO algorithms. Unimodal, multimodal, hybrid and composition type problems in CEC 2017 and CEC 2020 were used to test the exploration, exploitation and balanced search capabilities of hybrid algorithms developed using the FDB selection method. The performance of the hybrid d FDB-MRFO algorithm designed with the d FDB selection method was evaluated in 90 benchmark problems in the Classic, CEC 2014 and CEC 2017 test suites. In the experimental studies, 51 independent runs were conducted for each test function. The dimension of the test functions was dynamically selected as 30, 50 and 100. Data obtained from experimental studies were analyzed using non-parametric Wilcoxon and Friedman statistical test methods. Moreover, the performance of the MOGOA algorithm was tested in proposed multi-objective power system problem. In this context, MOGOA and four competitive optimization algorithms were applied to the

optimization of the MO-OPF problem. The performance of the algorithms was evaluated by multiple simulation cases in a modified IEEE 30-bus power system incorporating renewable energy sources and multi-terminal high voltage direct current links. The hybrid FDBAGSK algorithm was used to solve the AC/DC ORPF problem in IEEE 30 and IEEE 57-bus power systems incorporating distributed generation and two-terminal high voltage direct current links. The proposed FDBLFD method has been applied to the optimization of the PID, PIDF, FOPID and PIDD² controller parameters. The DOCRs problem was optimized using the developed *d*FDB-MRFO algorithm. To verify the efficacy of the proposed optimization method, a comprehensive simulation has been conducted on five test systems (IEEE 3-bus, IEEE 4-bus, Standard 8-bus, Standard 9-bus, and IEEE 30-bus) with different complexities.

3. RESULTS AND DISCUSSIONS

Wilcoxon and Friedman statistical analysis results showed that FDB and *d*FDB selection methods were effective in eliminating the premature convergence and poor diversity handicaps of AGSK, LFD and MRFO algorithms. The proposed hybrid FDBAGSK, FDBLFD and *d*FDB-MRFO methods converged to lower error values in unimodal problems compared to base algorithms. Similarly, the proposed hybrid methods exhibited stronger diversity capability in multimodal type problems. Thus, the premature convergence problem is largely eliminated. It has been observed that FDB and *d*FDB based algorithms exhibit more successful search performance compared to traditional methods in the optimization of hybrid and composition type test functions. The underlying reason for this success is directly related to the fact that FDB-based selection methods contribute to the improvement of the exploitation-exploration balance of the base algorithms. On the other hand, in the optimization of the MO-OPF problem, the total cost for all test cases has been increased to a level that can provide high profit with the MOGOA algorithm. Moreover, the MOGOA method exhibited a competitive performance in terms of other objective functions. For the optimization of the AC/DC ORPF problem in the IEEE 30-bus test system, a reduction of 0.8379%, 0.2248%, 0.2124%, 0.8252% and 0.0573% were obtained in active power losses with FDBAGSK compared to the AGSK algorithm. Moreover, an improvement of 0.0584% and 2.5761% for voltage deviation and voltage stability index objective functions was observed with the proposed algorithm. In the IEEE 57-bus power system, a decrease of 9.7898%, 7.1020% and 8.7070% was achieved in active power losses for different operating

conditions with the hybrid FDBAGSK method compared to the base algorithm. For the same test system, the voltage deviation and voltage stability index value improved by 21.15% and 3.3587% with the FDBAGSK algorithm, respectively. It has been determined that the proposed hybrid FDBLFD algorithm offered higher quality unit step response for the AVR system compared to its competitors. The improvements achieved by the FDBLFD algorithm in the optimization process are highlighted by the robustness analysis as well as the step response of the AVR system under nominal conditions. Comparison between FDBLFD tuned controllers showed that PID² achieved better quality unit step response compared to PID, PIDF and FOPID controllers. In the optimization of DOCRs coordination, especially the Standard 8-bus, Standard 9-bus and IEEE 30-bus power system simulation results were distinctive in terms of the search performance of the d FDB-MRFO method. Accordingly, in the relevant test systems, the FDBAGSK method reduced the total operating time of the primary relays by 20.5216%, 4.3033% and 1.9148%, respectively, compared to the base algorithm.

4. CONCLUSION AND OUTLOOK

Based on the experimental results of this thesis, it is possible to say that FDB and d FDB selection methods significantly improve the search performance of population-based meta-heuristic algorithms. Moreover, it has been observed that the dynamizing of the w -coefficient used in the FDB score calculation improves the performance of the selection method. On the other hand, it has been proven that the hybrid algorithms developed within the scope of the thesis study can produce feasible solutions to the problems of optimal reactive power flow, optimal automatic voltage regulator design and directional overcurrent relays coordination problems. In this regard, researchers can use the hybrid algorithms developed in this study to solve the same or different types of optimization problems, as well as develop new methods to solve their problems by using FDB and d FDB selection methods. Also, in order to improve the performance of the hybrid algorithms advocated throughout the thesis, new hybrid models can be created with the use of a third algorithm, and thus algorithms can be provided to reach the solution with lower error.

1. GİRİŞ

Optimizasyon temel olarak uygun maliyetli ve verimli optimal çözümleri bulma sürecidir. Daha genel bir ifadeyle, belirli kısıtlar altında seçilen amaç fonksiyonunun minimize veya maksimize edilmesi için tasarım parametrelerinin değerinin belirlenmesi ile ilgilenmektedir [1]. Gerçek hayatta, mühendislik, ekonomi, imalat, finans, ulaşım ve iletişim ağları gibi çeşitli bilim alanlarını içeren birçok optimizasyon problemi örneğine maruz kalıyoruz. Örneğin; bir yatırımcı minimum riskle getiriye maksimize etmeyi amaçlarken, bir trafik planlayıcısı trafiği yönlendirmek için mümkün olan en iyi yolları bularak tıkanıklığı en aza indirmek istemektedir. Bu alanlardaki problemler, teknik sınırlamalardan, iş planlarından, insan ihtiyaçlarından, kanunlardan vb. kaynaklanan kısıtlamalarla karakterize edilir. Bu nedenle bir optimizasyon tekniği ilgili amaçları optimize ederken tüm kısıtlamaları göz önünde bulunduran karar değişkeni değerlerini seçebilmelidir [2], [3].

Son yıllarda, meta-sezgisel arama algoritmaları mühendislik tasarımı, dijital görüntü işleme, haberleşme, güç ve enerji yönetimi, veri analizi, makine öğrenmesi, tıbbi teşhis ve robotik gibi birçok farklı uygulama alanında çeşitli optimizasyon problemlerini çözmek için popüler araçlar haline gelmiştir [2], [4]. Çoğu meta-sezgisel yöntem çözüm adayları popülasyonunun arama uzayı içinde farklı aday çözümleri keşfetmek için belirli kurallar dizisini uyguladığı popülasyon tabanlı arama şemalarını modellemektedir. Meta-sezgisel algoritmaların optimizasyon çerçevesi, bireyler arasındaki etkileşim (farklı çözümler arasında bilgi alışverişini teşvik eder) ve popülasyonun çeşitlendirilmesi başta olmak üzere çeşitli avantajlar sunar. Popülasyon çeşitliliğinin sağlanması, arama uzayının verimli bir şekilde araştırılması ve yerel çözüm tuzaklarının üstesinden gelme görevlerinin yerine getirilmesi için oldukça önemlidir [5].

Keşif ve sömürü meta-sezgisel algoritma için belirli bir optimizasyon problemini çözerken başarıya ulaşmadaki en önemli özellikleri temsil eder. Keşif, arama uzayının farklı bölgelerine yayılmış çözüm adaylarını keşfetme yeteneğini ifade eder. Öte yandan, sömürü, daha iyi çözümler bulmak veya mevcut olanları iyileştirmek amacıyla çözüm uzayının umut vaat eden bölgelerini arama sürecini yoğunlaştırma fikrini temsil eder [6], [7]. Bu kavramlarla ilgili olarak deneysel çalışmalar keşif-sömürü kapasitesi ile yakınsama oranı arasında güçlü bir ilişki olduğunu göstermiştir. Özellikle, sömürü

stratejilerinin küresel bir optimuma doğru yakınsama hızını arttırdığı bilinirken, aynı zamanda yerel optimuma yakalanma olasılığını arttırdığı da bilinmektedir. Aksine, sömürü yerine keşfi tercih eden arama stratejileri, arama alanı içinde küresel optimumun bulunma olasılığının daha yüksek olduğu bölgeleri ziyaret etme eğilimindedir. Popülasyon tabanlı arama yöntemlerinin çoğunda, elitizm ve çeşitliliği dengelemek için mevcut popülasyon arasında öne çıkan çözümlerin seçilmesine izin veren seçim mekanizmaları yaygındır. Örneğin, açgözlü seçim mekanizmalarında tüm aday çözümler arasında en iyi uygunluk (fitness) değerine sahip bireylerin gelecek nesil için bozulmadan kalması sağlanır ve umut vaat eden çözümlere yakınsama hızını arttırdığı bilinmektedir [2], [8].

Meta-sezgisel arama yöntemleri, tasarım ve potansiyel uygulamalar açısından çok sayıda ve çeşitlidir [9]. Ancak böylesine bol optimizasyon teknikleri ailesi için yanıtlanması gereken önemli bir soru vardır: Bir meta-sezgisel algoritmadaki tasarımın hangi bölümü arama performansına daha fazla katkıda bulunur? Araştırmacılar arasındaki yaygın görüş optimal çözümlerin araştırılmasında keşif ve sömürü arasında uygun bir denge sağlandığında meta-sezgisel arama yöntemlerinin daha iyi bir performansa ulaşabileceğidir [2].

Sömürü ve keşif görevlerini daha etkin bir şekilde gerçekleştirmek ve böylece daha başarılı arama performansı elde etmek için son yıllarda yüzlerce yeni Meta-Sezgisel Arama (MSA) algoritması geliştirilmiştir [10]-[12]. Bu çalışmaların çoğu, arama operatörlerinin tasarımına veya iyi bilinen MSA algoritmaları varyantlarının geliştirilmesine odaklanmıştır [13]-[16]. Ancak arama sürecinin başarısı sadece MSA algoritmalarının arama operatörlerine bağlı değildir [17]-[19]. MSA algoritmalarının performansı üzerinde doğrudan bir etkisi olmasına rağmen araştırmacıların seçim yöntemleri konusunda konuya daha az ilgi gösterdikleri görülmektedir. Meta-sezgisel arama sürecinin başarısı için temel koşul seçim yöntemleri ve arama operatörlerinin birbirini destekleyecek şekilde çalışmasıdır. Çünkü; arama operatörleri görevlerini yerine getirmek için girdi parametreleri olarak referans çözüm adaylarını kullanırlar. Diğer bir ifadeyle arama sürecinin başarısı arama operatörlerinin yetenekleri kadar seçim yöntemiyle belirlenen çözüm adaylarının arama uzayındaki konumuna da bağlıdır. Bu durum MSA sürecinde seçim yöntemlerinin önemli rolünü açıkça göstermektedir [19].

Bu çalışmada MSA algoritmalarının sömürü ve keşif yeteneklerini etkin bir şekilde gerçekleştirmelerini sağlamak ve böylece daha başarılı bir arama performansı elde etmek için uygunluk-mesafe dengesi (Fitness-Distance Balance, FDB [19]) ve tez çalışmasının orijinal katkılarından biri olarak geliştirilen dinamik uygunluk-mesafe dengesi (Dynamic Fitness-Distance Balance, *d*FDB [20]) seçim yöntemleri kullanılmıştır. MSA algoritmalarının arama performansını iyileştirmek için geliştirilen FDB yöntemi, uygulaması kolay adımlardan oluşmaktadır. FDB yönteminde her adayın seçim süreci için puanı hesaplanır. FDB puanı adayların uygunluk değerleri ve uzaklık değerleri kullanılarak hesaplanmaktadır. Uygunluk değeri çözüm adayının başarısını gösterirken uzaklık değeri en iyi çözüm adayı ile arasındaki farkı göstermektedir. İki çözüm adayının arasındaki mesafenin uzun olması, bu iki adayın birbirine benzemediğini ve birbirlerinin eksikliklerini tamamlama potansiyeline sahip olduğunu bir göstergesidir. Uygunluk değeri yüksek olan bir adayın uzaklık değeri de yüksekse arama sürecine önemli bir katkıda bulunabileceğine dair güçlü bir kanıttır. Diğer bir ifadeyle; yüksek puana sahip çözüm adayları mevcut popülasyondaki en iyi çözümün dezavantajını ortadan kaldırma potansiyeline sahiptir. Uygunluk değeri yüksek olmasına rağmen popülasyondaki en iyi adaya çok yakın olan bir çözüm adayının arama sürecini iyileştirme potansiyeli zayıftır. Bu aday erken yakınsama problemi için bir çözüm olamaz ve nüfus çeşitliliğine katkıda bulunamaz. Fakat komşuluk aramasına kısmen katkıda bulunabilir. Böyle bir çözüm adayının uzaklık değeri sıfıra yakın olacağından puan değeri de çok düşük olacaktır. FDB skor hesabı ile arama sürecine katkı sağlayamayan hatta erken yakınsamaya neden olan çözüm adaylarını belirlemek ve ortadan kaldırmak mümkündür. FDB seçim yöntemi yerel optimum tuzaklardan kaçınmak için güçlü bir çözümdür. Önerilen *d*FDB yöntemi FDB seçim yönteminin güçlü bir varyantıdır. *d*FDB seçim yönteminin geliştirilmesindeki motivasyon şu şekildedir: MSA algoritmalarında arama süreci yaşam döngüsü yüzbinlerce döngüden oluşan uzun bir süreçtir. Buna bağlı olarak arama sürecinin her aşamasında ihtiyaçlar değişmektedir. Algoritmalar sağlam bir sömürü yeteneği sergilemek isteseler de genellikle arama sürecinin ilk aşamalarında erken yakınsama yaşarlar. Yerel çözüm tuzaklarından kaçınmanın yolu keşif kabiliyetini kademeli olarak arttırmaktır. Bu nedenle arama sürecinin bazı dönemlerinde erken yakınsama problemini elimine etmek için daha fazla çeşitliliğe (daha güçlü bir keşif işlemine) ihtiyaç duyulurken, bazı dönemlerde ise sömürüye ihtiyaç duyulmaktadır. Özellikle arama sürecinin son dönemlerinde hassas bir arama yapılması esastır. Bu zorlukların üstesinden gelebilmek için geliştirilen *d*FDB seçim yönteminde çözüm adaylarının FDB skor

hesabında kullanılan w -katsayısı arama süreci yaşam döngüsünün adımlarına bağlı olarak dinamik ayarlanabilen bir parametreye dönüştürülmüştür.

Meta-sezgisel algoritmalar modern güç sistemlerindeki uygulamalarda karşılaşılan problemlerle başa çıkabilme potansiyeline sahiptir. Yapay zekâ tabanlı meta-sezgisel yöntemlerin uygulanması güç sistemi mühendisliğinin birçok alanında başarılı olmuştur. Ancak modern güç sistemlerinin artan karmaşıklığı nedeniyle önümüzde hala birçok zorluk vardır. Bu nedenle, hem geleneksel elektrik güç tedarik endüstrisinde hem de rekabetçi elektrik piyasası ortamında artan sayıda kısıtlamaya sahip büyük ölçekli karmaşık güç sistemi problemleriyle başa çıkabilmek için meta-sezgisel algoritmaların performansı sürekli olarak geliştirilmelidir [2], [21].

Güç sistemi optimizasyon problemleri doğrusal olmayan amaç fonksiyonlarının yanı sıra doğrusal olmayan eşitlik ve eşitsizlik kısıtlarını içeren yüksek boyutlu karmaşık problemlerdir. Lineer olmayan, dışbükey olmayan ve yüksek boyutlu güç sistemi problemlerini optimize etmek büyük bir zorluktur. Bu tür problemlerin çözümünde meta-sezgisel arama algoritmaları sıklıkla kullanılmaktadır. Ancak MSA algoritmalarının performansı, optimizasyon probleminin tipine ve karmaşıklığına bağlı olarak değişmektedir. Bu durum, her bir gerçek dünya mühendislik problemi için en etkili MSA algoritmasının geliştirilmesini gerekli kılar ve bu da kapsamlı araştırma gerektirir [22]. Bu tez çalışmasında, literatürdeki güncel meta-sezgisel algoritmalarından ikisi olan uyarlanabilir bilgi edinme-paylaşma (Adaptive Gaining-Sharing Knowledge, AGSK [23]) ve Levy uçuş dağılımı (Levy Flight Distribution, LFD [24]) algoritmalarının seçim stratejileri FDB seçim yöntemi kullanılarak yeniden tasarlanmış ve FDBAGSK ve FDBLFD olarak isimlendirilen keşif ve dengeli arama yetenekleri güçlendirilmiş hibrit algoritmalar geliştirilmiştir. FDB seçim yöntemi kullanılarak geliştirilen algoritmalarından ilki (FDBAGSK) Alternatif Akım/Doğru Akım Optimal Reaktif Güç Akışı (AA/DA ORGA) probleminin çözümüne uygulanmıştır. Diğeri (FDBLFD) ise, popüler gerçek dünya mühendislik problemlerinden biri olan Otomatik Gerilim Regülatörü (OGR) sistem tasarımı optimizasyon problemine yüksek kaliteli çözümler üretmek için kullanılmıştır. FDB seçim yönteminin etkili bir varyantı olarak geliştirilen d FDB seçim yöntemi ise güçlü ve sağlam temellere sahip bir meta-sezgisel yöntem olan manta ışıını yiyecek arama optimizasyon (Manta Ray Foraging Optimization, MRFO [25]) algoritmasına uygulanmıştır. d FDB seçim yöntemi kullanılarak geliştirilen d FDB-MRFO algoritması güç sistemlerinin güvenli işletimi için kritik öneme sahip kısıtlı Yönlü Aşırı

Akım Röleleri (YAAR) koordinasyonu optimizasyon problemini çözmek için kullanılmıştır. Ayrıca, Mirjalili ve arkadaşları tarafından geliştirilmiş çok-amaçlı çekirge optimizasyon algoritması (Multi-objective Grasshopper Optimization Algorithm, MOGOA [26]) rüzgar, güneş, hidro ve gelgit enerji kaynaklarını içeren Çok-Terminalli Yüksek Gerilim Doğru Akım (ÇTYGDA) güç sistemlerinde Çok-Amaçlı Optimal Güç Akışı (ÇAOGA) probleminin çözümüne uygulanmıştır.

Tez çalışmasının geri kalanı şu şekilde düzenlenmiştir: Bölüm 2, tez çalışmasında optimal çözümü araştırılan güç sistemi problemleri hakkında kapsamlı bir literatür taraması içermektedir. Bölüm 3, tek ve çok amaçlı optimizasyon yapısını, FDB ve d FDB seçim yöntemleri kullanılarak geliştirilen optimizasyon algoritmalarını (FDBLFD, FDBAGSK ve d FDB-MRFO) ve çok-amaçlı optimal güç akışı probleminin çözümüne uygulanan MOGOA algoritmasının temellerini açıklamaktadır. Bölüm 4, yenilenebilir enerji kaynakları (rüzgâr, güneş, hidro ve gelgit) ve Gerilim Kaynağı Dönüştürücü (GKD) tabanlı ÇTYGDA iletim hattı ile modifiye edilmiş IEEE 30-baralı güç sisteminde ÇAOGA probleminin optimizasyonunu ele almaktadır. Çoklu dağıtılmış üretim ve iki terminalli YGDA iletim hatlarını içeren IEEE 30 ve IEEE 57-baralı güç sistemlerinde ORGA probleminin çözümü Bölüm 5'te kapsamlı bir şekilde ele alınmıştır. Bölüm 6'da popüler gerçek dünya mühendislik problemlerinden biri olan optimal OGR tasarımı optimizasyon probleminin çözümü sunulmuştur. OGR sistem tasarımında kullanılan PID, PIDF, FOPID ve PIDD² kontrolcü parametreleri FDBLFD ve rekabetçi optimizasyon algoritmaları ile ayarlanmıştır. Bölüm 7'de, d FDB seçim yöntemi kullanılarak geliştirilen d FDB-MRFO algoritması kısıtlı yönlü aşırı akım röleleri koordinasyonu optimizasyon problemine uygulanmıştır. Tez çalışmasının sonuçları ve gelecekteki potansiyel çalışmalar Bölüm 8'de tartışılmıştır.

2. LİTERATÜR TARAMASI

Bu bölümde, tez çalışması kapsamında ele alınan kısıtlı güç sistemi problemlerinin modellenmesi ve meta-sezgisel optimizasyon algoritmaları ile çözümü hakkında son yıllarda yapılmış önemli çalışmalar yer almaktadır. Tez çalışmasında farklı karmaşıklığa sahip dört adet güç sistemi problemi ele alınmıştır. Bu problemleri iki kategoriye ayırmak mümkündür. Birinci kategoride, yenilenebilir enerji kaynaklarını içeren çok terminalli yüksek gerilim doğru akım elektrik şebekelerinde çok amaçlı optimal güç akışı probleminin çözümü yer almaktadır. İkinci kategoride ise tek amaçlı güç sistemi problemleri incelenmiştir. Bu bağlamda, dağıtılmış üretim ve iki terminalli yüksek gerilim doğru akım iletim bağlantılarını içeren güç sistemlerinde optimal reaktif güç akışı, optimal otomatik gerilim regülatörü tasarımı ve yönlü aşırı akım röleleri koordinasyonu problemlerinin çözümü gerçekleştirilmiştir.

Güç sistemlerinin ekonomik, teknik ve çevresel çalışma gereksinimlerini dikkate alan optimal güç akışı güç sistemi araştırmacılarının hala çözmeye çalıştığı iyi bilinen zorlu bir optimizasyon problemidir. Güç sistemlerinin optimal işletimi ve planlanmasındaki önemli rolü nedeniyle Optimal Güç Akışı (OGA) problemi güç sistemi araştırmacılarının yoğun ilgi gösterdiği bir araştırma konusu olarak hala güncelliğini korumaktadır. Başlangıçta araştırmacılar OGA problemini sadece termal üretim birimlerini dikkate alarak modellemişler ve problemin çözümüne birçok meta-sezgisel optimizasyon algoritmasını uygulamışlardır. Duman ve arkadaşları, klasik OGA problemine (sadece termal jeneratörleri içeren) yüksek kaliteli çözümler üretmek amacıyla yerçekimi arama algoritmasını (Gravitational Search Algorithm, GSA) uygulamışlardır [27]. Sinsuphan ve arkadaşları, OGA problemini çözmek için kısa hesaplama süresinde optimal çözümler elde edebilen geliştirilmiş harmoni arama (Improved Harmony Search, IHS) algoritmasını önermişlerdir [28]. Boucekara ve arkadaşları, öğretme-öğrenme tabanlı optimizasyon (Teaching-Learning Based Optimization, TLBO) yöntemini kullanarak OGA probleminin çözümünü gerçekleştirdiler [29]. Ulaş, OGA problemini termik jeneratörlerin valf nokta etkisi ve yasaklı çalışma bölgelerini dikkate alarak modellemiş ve ilgili problemin çözümüne geri izleme arama algoritmasını (Backtracking Search Algorithm, BSA) uygulamıştır [30]. Attia ve arkadaşları, geleneksel OGA problemine optimal çözümler üretmek için değiştirilmiş sinüs-kosinüs algoritmasını (Modified Sine-

Cosine Algorithm, MSCA) uygulamışlardır [31]. Güvenç ve arkadaşları, OGA problemini termal jeneratörlerin yasaklı çalışma bölgelerini dikkate alarak modellemişlerdir [32]. Yazarlar, toplam üretim maliyetini minimize etmek için manta ışıını yiyecek arama optimizasyon (Manta Ray Foraging Optimization, MRFO) algoritmasını kullanmışlardır.

Son yıllarda artan nüfus ve hızla gelişen teknoloji ile artan enerji talebi iletim hatları üzerindeki baskıyı artırmıştır. Güç sistemi araştırmacıları, modern güç sistemlerinin güvenli çalışmasını sağlamak ve iletim hatları üzerindeki baskıyı azaltmak için GKD tabanlı ÇTYGDA iletim bağlantılarını kullanmışlardır. Bu bağlantıların en önemli avantajları arasında dinamik zaman ölçekleri üzerinde bağımsız aktif ve reaktif güç kontrolü ve güç kayıplarının azaltılması yer almaktadır. Özellikle GKD teknolojisinin gelişimi ile hibrit AA-ÇTYGDA güç sistemlerinin optimal işletimi ve kontrolü popüler konulardan biri haline gelmiştir. Abdül-hamied ve arkadaşları, hibrit AA/DA elektrik şebekelerinde OGA problemini çözmek için denge optimize edici (Equilibrium Optimizer, EO) yöntemini kullanmışlardır [33]. Araştırmacılar GKD tabanlı YGDA bağlantılarını içeren hibrit güç sistemlerinin optimal işletimi için modern elektrik sistemlerinin çevresel, teknik ve ekonomik gereksinimlerini dikkate alan amaç fonksiyonlarını kullanmışlardır. Elattar ve arkadaşları, GKD istasyonlarını içeren hibrit IEEE 30-baralı AA-ÇTYGDA güç sisteminin optimal işletimi için geliştirilmiş manta ışıını yiyecek arama optimizasyon (Improved Manta Ray Foraging Optimizer, IMRFO) algoritmasını önermişlerdir [34]. ÇAOGA konfigürasyonunda toplam üretim maliyeti, emisyon ve güç kayıpları gibi güç sisteminin ekonomik ve çevresel özelliklerini dikkate alan amaç fonksiyonları minimize edilmiştir. Shaheen ve arkadaşları, AA-ÇTYGDA güç sisteminde OGA problemlerine yüksek kaliteli çözümler üretmek için çok-amaçlı manta ışıını yiyecek arama optimizasyon (Multi-Objective Manta Ray Foraging Optimization, MOMRFO) algoritmasını geliştirmişlerdir [35]. Feng ve arkadaşları, hibrit AA/DA güç sisteminde GKD tabanlı ÇTYGDA iletim hattı bağlantılarının etkisini ortaya koymak için yeni bir yaklaşım önermişlerdir [36]. Bu yaklaşımda, ÇTYGDA bağlantılarının operasyonel faydaları, fayda/maliyet oranlarını türetmek için yatırım maliyetlerine göre değerlendirilmiştir. Çalışmanın sonuçları, GKD tabanlı ÇTYGDA iletim hattı entegrasyonunun toplam işletme maliyetinde bir azalma sağladığı ve toplam güç kayıplarının azaltılmasının büyük ölçüde iletim hattı konfigürasyonuna bağlı olduğunu ortaya koymuştur. Duyarlılık analizlerinden elde edilen sonuçlar, GKD kayıplarının

orijinal seviyenin üçte birine düşürülebilmesi durumunda sistemden elde edilen toplam faydanın yaklaşık %70 oranında artacağını göstermiştir. Zhao ve arkadaşları, GKD tabanlı hibrit AA-ÇTYGDA şebeke için optimum güç akışı probleminin çözümünde dönüştürücü kayıplarının etkisini araştırmışlardır [37]. Yazarların motivasyonu, yüksek gerilim doğru akım iletim hattı bağlantılarının kullanılması ile dönüştürücü istasyonlarının sayısında bir artış olacağı ve sonuç olarak dönüştürücü kayıplarının göz ardı edilemeyeceğidir. Bu amaçla, GKD tabanlı ÇTYGDA şebekeleri ve AA sistemlerinin bir kombinasyonu göz önüne alınarak genişletilmiş bir OGA modeli önerilmiştir. Elde edilen sonuçlar, dönüştürücü kayıplarının basitleştirilmiş bir şekilde modellenmesinin özellikle DA hatları için çok farklı güç akışı çözümlerine yol açabileceğini göstermiştir. Elsayed ve arkadaşları hibrit AA-ÇTYGDA güç sistemlerinin optimal işletimi için tek ve çok-amaçlı optimizasyon çerçevesi sunmuşlardır [38]. Simülasyon sonuçları, önerilen geliştirilmiş çok-amaçlı deniz avcılığı algoritmasının (Improved Multi-Objective Marine Predators Optimizer, IMMPO) güç sistemi planlama probleminde optimum çözümler üretmede rakiplerine kıyasla daha başarılı olduğunu göstermiştir.

Günümüzde fosil yakıt kaynaklarının hızla tükenmesi sebebiyle çevre dostu yenilenebilir enerji kaynaklarının güç sistemlerine geniş ölçekte entegrasyonu güç sistemi karmaşıklığını artırmış ve araştırmacıları yenilenebilir enerji kaynaklarını içeren OGA probleminin çözümünü araştırmaya teşvik etmiştir. Biswas ve arkadaşları, geleneksel termal jeneratörlerin yanı sıra rüzgâr ve güneş enerjisi kaynaklarını içeren OGA probleminin matematiksel modelini ve çözümünü sunmuşlardır [39]. Önerilen problemin optimizasyonuna başarı geçmişine dayalı adaptif diferansiyel evrim (Success History-Based Adaptation Technique of Differential Evolution, SHADE) algoritması uygulanmıştır. Simülasyon sonuçları, IEEE 30-baralı güç sisteminde yük talebini karşılamak için geleneksel termal jeneratörler yerine yenilenebilir enerji kaynaklarının kullanılmasıyla toplam üretim maliyetinde önemli bir azalma elde edildiğini göstermiştir. Khan ve arkadaşları, termal jeneratör, rüzgâr ve güneş enerjisi kaynaklarını içeren OGA problemini çözmek için gri kurt optimize edici (Grey Wolf Optimizer, GWO) yöntemini kullanmışlardır [40]. İncelenen güç sistemi probleminde yenilenebilir enerji kaynaklarının stokastik doğası olasılık dağılım fonksiyonları ile modellenmiştir. Ayrıca üretim maliyeti optimizasyonunda rüzgâr ve güneş enerji kaynaklarının fazla ve eksik tahmin maliyetleri dikkate alınmıştır. GWO algoritmasının performansı IEEE 30 ve IEEE

57-baralı güç sistemlerinde gerçekleştirilen simülasyon çalışmaları ile test edilmiştir. Sonuçlar önerilen algoritmanın yenilenebilir enerji kaynaklarını içeren kısıtlı AA-OGA problemine yüksek kaliteli çözümler üretebildiğini doğrulamıştır. Diğer bir çalışmada Duman ve arkadaşları, stokastik rüzgâr, güneş, şarjlı elektrikli araç (Plug-in Electric Vehicle, PEV) enerji sistemlerini içeren OGA probleminin matematiksel modelini sunmuşlardır [41]. Araştırmacılar fotovoltaik ve PEV enerji sistemlerinin birleşimini aktif güç üretim birimi olarak dikkate almışlardır. Önerilen AA/DA OGA probleminin yenilenebilir enerji kaynakları ile çözülebilirliğini göstermek için simbiyotik organizmalar arama (Symbiotic Organisms Search, SOS) algoritması IEEE 30 ve IEEE 57-baralı test sistemlerine uygulanmıştır. Wilcoxon istatistiksel analiz sonuçları SOS algoritmasının rakiplerine karşı üstün olduğunu göstermiştir. Sulaiman ve Mustaffa, OGA probleminin toplam üretim maliyeti, aktif güç kayıpları ve eş zamanlı maliyet-emisyon amaç fonksiyonlarını minimize etmek için barnacles çiftleşme optimize edici (Barnacles Mating Optimizer, BMO) isimli algoritmayı kullanmışlardır [42]. Yazarlar, BMO yönteminin performansını stokastik rüzgâr-güneş-hidroelektrik enerji üretim birimlerini içeren modifiye IEEE 30 ve IEEE 57-baralı test sistemlerinde gerçekleştirilen simülasyon çalışmaları ile test etmişlerdir. İstatistiksel analiz sonuçları önerilen algoritmanın tüm simülasyon durumları için en iyi sonuçları elde ettiğini göstermiştir. Kaymaz ve arkadaşları, termal üretim birimleri ve stokastik rüzgâr enerjisi ile modellenen OGA problemini tek ve çok-amaçlı optimizasyon çerçevesinde ele almışlardır [43]. Araştırmacılar, önerilen problemi çözmek için Lévy çakal optimizasyon algoritmasını (Lévy Coyote Optimization Algorithm, LCOA) uygulamışlardır ve önerilen yöntemin performansını büyük ölçekli güç sistemlerinde (IEEE 30, 57 ve 118-baralı) test etmişlerdir. Tek ve çok-amaçlı optimizasyon çerçevesinde yakıt maliyeti, emisyon, aktif güç kayıpları, voltaj sapması ve voltaj kararlılığı iyileştirilmesi amaç fonksiyonlarını içeren on sekiz farklı simülasyon durumu incelenmiştir. Sonuçlar, önerilen LCOA algoritmasının stokastik rüzgâr enerjisini dikkate alan OGA problemine optimal bir çözüm bulmada diğer optimizasyon yöntemlerinden daha etkili olduğunu göstermiştir. Khan ve arkadaşları, hidroelektrik, rüzgâr ve güneş enerji santrallerini içeren AA-OGA problemini çözmek için artırılmış gri kurt optimizasyon (Augmented Grey Wolf Optimization, AGWO) yöntemini kullanmışlardır [44]. Önerilen algoritmanın performansı IEEE 30, 57 ve 118-baralı güç sistemlerinde test edilmiştir. Güvenç ve arkadaşları, stokastik güneş ve rüzgâr enerjisini içeren güvenlik kısıtlı OGA probleminin çözümünü gerçekleştirmişlerdir [22]. Araştırmacılar, önerilen probleme yüksek kaliteli

çözümler üretmek için uygunluk-mesafe dengesine dayalı ayarlanabilir diferansiyel evrim (Fitness–Distance Balance based Adaptive Guided Differential Evolution, FDBAGDE) yöntemini uygulamışlardır. Literatürde, sınırlı alan nedeniyle burada ifade edemediğimiz yenilenebilir enerji kaynakları entegreli OGA problemini ele alan birçok çalışma mevcuttur. İlgili literatür çalışmaları, güç sistemi araştırmacılarının yenilenebilir enerji kaynaklarını içeren OGA problemini çözmek için daha önce çeşitli MSA algoritmalarını kullandıklarını göstermektedir. OGA problemine birçok MSA yöntemi uygulanmış olsa da öncekileri iyileştiren sonuçlar sağlamak için güçlü bir optimizasyon algoritmasına ihtiyaç vardır.

Güç sistemlerinin optimal işletimi için hem GKD tabanlı ÇTYGDA iletim bağlantılarını hem de çoklu yenilenebilir enerji kaynaklarını eş zamanlı olarak içeren OGA problemini ele alan bir çalışma literatürde not edilmemiştir. Bu çalışmada iletim hatlarının maruz kaldığı baskıyı ve termal jeneratörlerin çevreye olan zararlı etkilerini azaltmak amacıyla GKD tabanlı ÇTYGDA iletim bağlantıları ve rüzgâr, güneş, hidroelektrik, gelgit yenilenebilir enerji kaynaklarını içeren ÇAOGA probleminin çözümü gerçekleştirilmiştir. Önerilen çok amaçlı güç sistemi problemi toplam maliyet, valf noktası etkisi ile toplam maliyet, emisyonlar ve karbon vergisi ile toplam maliyet, gerilim sapması ve güç kayıpları amaç fonksiyonlarının ikili ve üçlü kombinasyonlarını optimize eder. Yenilenebilir enerji kaynakları ve gerilim kaynağı dönüştürücü tabanlı çok terminalli yüksek gerilim doğru akım iletim bağlantılarını içeren çok amaçlı optimal güç akışı probleminin Pareto-optimal çözümlerini elde etmek için Mirjalili ve arkadaşları tarafından geliştirilmiş güçlü temellere sahip MOGOA yöntemi kullanılmıştır.

Tez çalışmasında optimal çözümü araştırılan tek amaçlı güç sistemi problemlerinin ilki Optimal Reaktif Güç Akışı (ORGA) problemidir. ORGA hem planlama hem de işletme aşamalarında güç sistemi operatörleri için önemli bir araçtır. Güç sistemlerinin ekonomik ve güvenli çalışmasında önemli bir etkiye sahip olan ORGA, optimal güç akışı olarak bilinen daha genel güç sistemi probleminin bir alt kümesi olarak düşünülebilir. Bir güç sisteminde aktif güç kayıpları, gerilim profili ve gerilim güvenliği büyük ölçüde iletim hatlarındaki reaktif güç akışına bağlıdır. ORGA jeneratör voltajlarının, transformatör kademe oranının ve şönt kapasitörlerin kontrolü ile ilgilenir. Tüm bu değişkenler, sistemdeki reaktif gücün akışını güçlü bir şekilde etkiler. ORGA probleminde, aktif güç kayıpları en aza indirilir ve belirli bir çalışma ve fiziksel kısıtlamalar kümesi karşılanırken voltaj profili iyileştirilir. Güç sistemi araştırmacıları ORGA problemini çözmek için son

yıllarda birçok MSA algoritması kullanmışlardır. Ayan ve Kılıç, güç sistemlerinde aktif güç kaybını en aza indirmek için yapay arı kolonisi (Artificial Bee Colony, ABC) algoritmasına dayalı optimum reaktif güç akışı optimizasyonunu incelemişlerdir [45]. IEEE 30 ve IEEE 118-baralı güç sistemlerinde gerçekleştirilen simülasyon çalışmalarından elde edilen bulgular ABC'nin incelenen güç sistemi problemini çözmek için etkili ve verimli bir yöntem olduğunu ortaya koymuştur. Cao ve arkadaşları, optimal reaktif güç akışı probleminin çözümü için yerel arama strateji ile modifiye edilmiş biyocoğrafya tabanlı optimizasyon (Biogeography-based Optimization, BBO) algoritmasını kullanmışlardır [46]. Önerilen algoritmanın performansı büyük ölçekli (IEEE 30 ve 118-baralı) güç sistemlerinde test edilmiştir. Simülasyon sonuçları önerilen yaklaşımın büyük ölçekli güç sistemlerinde optimal reaktif güç akışı problemine yüksek kaliteli çözümler üretebildiğini göstermiştir. Moghadam ve Seifi, bulanık mantığa dayalı öğretim-öğrenme tabanlı optimizasyon (Teaching-Learning-Based Optimization, TLBO) algoritmasını kullanarak kısıtlı reaktif güç planlama probleminin çözümünü gerçekleştirmişlerdir [47]. IEEE 30-baralı test sistemi sonuçları önerilen algoritmanın ORGA problemini çözmek için güçlü bir alternatif olduğunu kanıtlamıştır. Sulaiman ve arkadaşları, gri kurt optimizasyon (Grey Wolf Optimizer, GWO) algoritmasını kullanarak ORGA problemi kontrol değişkenleri optimizasyonuna odaklanmışlardır [48]. GWO algoritmasının performansı, IEEE 30 ve IEEE 118-baralı güç sistemlerinde test edilmiş ve önerilen yöntemin incelenen güç sistemi planlama problemine yüksek kaliteli ve uygulanabilir çözümler üretebildiği gözlemlenmiştir. Mehdinejad ve arkadaşları, reaktif güç kaynaklarının optimal yönetimi için hibrit parçacık sürüş-emperyalist rekabetçi algoritmayı (Particle Swarm Optimization-Imperialist Competitive Algorithm, PSO-ICA) kullanmışlardır [49]. Önerilen hibrit algoritmanın performansı IEEE 57 ve IEEE 118-baralı güç sistemlerinde farklı çalışma koşulları altında test edilmiştir. Simülasyon sonuçları önerilen algoritmanın PSO ve ICA yöntemlerine kıyasla daha kaliteli çözümler elde edebildiğini göstermiştir. Lenin ve arkadaşları, ORGA problemini çözmek için hibrit tabu arama-benzetim tavlama (Hybrid Tabu Search-Simulated Annealing, HTSSA) yöntemini uygulamışlardır [50]. IEEE 30-baralı güç sistemi simülasyon sonuçları önerilen algoritmanın aktif güç kayıplarını önemli ölçüde azaltabildiğini göstermiştir. Mei ve arkadaşları, güve alevi optimizasyon (Moth-Flame Optimization, MFO) algoritmasını kullanarak optimal reaktif güç yönetimi probleminin kontrol değişkenleri optimizasyonuna odaklanmışlardır [51]. Simülasyon sonuçları, önerilen yöntemin rakiplerine kıyasla daha düşük güç kaybı değeri sunduğunu ortaya koymuştur. Sakr ve

arkadaşları, diferansiyel evrime dayalı optimal reaktif güç yönetimi problemini incelemişlerdir [52]. Yazarlar, geliştirilmiş diferansiyel evrim (Modified Differential Evolution, MDE) algoritmasının aktif güç kayıplarını en aza indirme ve voltaj profilini iyileştirmedeki başarısını araştırmışlardır. Simülasyon çalışmaları üç farklı IEEE test sisteminde (14-baralı, 30-baralı ve 57-baralı) gerçekleştirilmiştir. Ayrıca önerilen prosedür Mısır ana şebeke sisteminin bir parçasına uygulanmıştır. Simülasyon sonuçlarından elde edilen bulgular MDE algoritmasının eşitlik ve eşitsizlik kısıtlarına tabi olarak güç kayıplarını ve gerilim sapsmasını minimize etmek için etkili bir yöntem olduğunu göstermiştir. Fadel ve arkadaşları, dağıtılmış üretim birimlerini ve iki terminalli yüksek gerilim doğru akım iletim hattı bağlantılarını içeren modifiye IEEE 30 ve IEEE 57-baralı güç sistemlerinde ORGA problemini çözmek için geri izleme arama algoritmasını (Backtracking Search Algorithm, BSA) kullanmışlardır [53]. Simülasyon sonuçları, incelenen güç sistemi problemine optimum çözümler üretmede BSA yönteminin kararlı ve sağlam bir performans sergilediğini ortaya koymuştur. Literatürdeki çalışmalar detaylı olarak incelendiğinde, bu çalışmaların büyük çoğunluğunda araştırmacıların geleneksel optimal reaktif güç akışı probleminin çözümüne odaklandığı tespit edilmiştir. Bu tez çalışmasında ise dağıtılmış üretim ve iki terminalli yüksek gerilim doğru akım iletim hatları ile gerçek dünyaya en yakın şekilde modellenen IEEE 30 ve IEEE 57-baralı güç sistemlerinde ORGA probleminin çözümü gerçekleştirilmiştir. İncelenen problemin optimizasyonunda tez çalışmasının orijinal katkılarından biri olarak geliştirilen FDBAGSK algoritması kullanılmıştır.

Tez çalışması kapsamında optimal çözümü araştırılan diğer bir güç sistemi problemi ise Otomatik Gerilim Regülatörü (OGR) tasarımıdır. Bir elektrik güç sisteminin en temel görevlerinden biri, besleme voltajı büyüklüğünü korumaktır. Besleme voltajındaki değişiklik bağlı elektrikli cihazlara zarar verebilir veya performanslarını düşürebilir. Ek olarak, aktif ve reaktif güç akışı ve dolayısıyla güç kaybı da voltajın büyüklüğüne bağlıdır. Bu nedenle, voltajdaki küçük bir sapma reaktif güç akışında oldukça büyük bir değişikliğe neden olabilir. Gerilim sapsması izin verilen sınırdan (nominal voltajın $\pm\%5$ 'i) fazla olması durumunda, büyük bir güç kaybına neden olur ve bu da ekonomik kayıplara yol açar. Belirtilen sorunları önlemek ve tüm çalışma koşullarında senkron jeneratörün voltaj seviyesini kontrol etmek için OGR kullanmak ideal bir çözümdür [54]-[56]. Arzu edilen sistem tepkisini elde etmek için OGR tasarımında kullanılan kontrolcü parametrelerinin iyi ayarlanması gerekir. Çünkü kontrolcü performansı büyük oranda

kazanç parametrelerinin doğru bir şekilde ayarlanmasına bağlıdır. Son yıllarda güç sistemi araştırmacılarının kontrolcü parametrelerinin optimal değerini belirlemek için çeşitli meta-sezgisel optimizasyon algoritmalarını uyguladıkları görülmektedir. Gaing, PID denetleyici tabanlı OGR tasarlamak için parçacık sürüsü optimizasyon (Particle Swarm Optimization, PSO) algoritmasını kullanmış ve bunu genetik algoritma (Genetic Algorithm, GA) yöntemi ile karşılaştırmıştır [57]. Sahu ve arkadaşları, diferansiyel evrim (Differential Evolution, DE) algoritması ile paralel 2-DOF PID kontrolcü parametrelerini optimize etmişlerdir [58]. Öğretme-öğrenmeye dayalı optimizasyon (Teaching–Learning Based Optimization, TLBO) yöntemi, Chatterjee ve Mukherjee tarafından PIDF tabanlı OGR tasarımı için kullanılmıştır [59]. Karimi ve arkadaşları, daha hassas kontrol ve gelişmiş performans elde etmek için OGR sisteminde klasik PID denetleyicisini FOPID denetleyici ile değiştirmişlerdir [60]. Kontrolcü parametrelerinin ayarlanmasında denge optimize edici (Equilibrium Optimizer, EO) yöntemi kullanılmıştır. Klasik PID denetleyicisi ile karşılaştırıldığında FOPID denetleyicisinin yükselme süresi, yerleşme süresi vb. geçici tepki parametreleri açısından üstün performans sergilediği gözlemlenmiştir. Bingül ve Karahan, PID ve FOPID kontrolcü kazanç parametrelerini ayarlamak için yapay arı kolonisi (Artificial Bee Colony, ABC) ve parçacık sürüsü optimizasyonu (Particle Swarm Optimization, PSO) algoritmalarını uygulamışlardır [61]. Güvenç ve arkadaşları, OGR sistemi geçici durum yanıtını iyileştirmek için biyocoğrafya tabanlı optimizasyon (Biogeography-based Optimization, BBO) algoritmasını kullanmışlardır [62]. Çelik, PID tabanlı OGR tasarım problemine stokastik fraktal arama (Stochastic Fractal Search, SFS) algoritmasını uygulamıştır [63]. Micev ve arkadaşları, parametre belirsizliği ve bozunum gibi nominal olmayan çalışma koşullarında OGR sisteminin regülasyon performansını artırmak için PID kontrolcü parametrelerini denge optimize edici (Equilibrium Optimizer, EO) yöntemini kullanarak ayarlamışlardır [64]. Bhookya ve Jatoth, OGR sisteminin arzu edilen terminal voltajını düzenleyebilmesi için sinüs-kosinüs algoritması (Sine-Cosine Algorithm, SCA) tabanlı FOPID kontrolcü kullanmışlardır [65]. Ayas ve Şahin, OGR sistemi dinamik tepki performansını artırmak için FOPID-FF olarak isimlendirilen yeni bir kontrolcü modeli önermişlerdir [66]. İlgili çalışmada önerilen kontrolcü parametreleri SCA yöntemi ile optimize edilmiştir. İkinci ve Hekimoğlu, PID kontrolcü kazanç katsayılarını geliştirilmiş böbrek ilhamlı algoritma (Improved Kidney-Inspired Algorithm, IKA) ile optimize etmiştir [67]. Sahib, OGR sistemi için orantısız, integral, türev ve ikinci dereceden türev terimlerinden oluşan (PIDD²) isimli yeni bir kontrolcü önermiştir [68]. Khan ve arkadaşları, OGR sisteminin

dinamik tepki ve kararlılık özelliklerini iyileştirmek için salp sürü algoritması (Salp Swarm Algorithm, SSA) tabanlı FOPID kontrolcüyü kullanmışlardır [69]. Mokeddem ve Mirjalili, OGR sistemi kontrol performansını artırmak için kullanılan PID² denetleyici tasarımına geliştirilmiş balina optimizasyon algoritmasını (Improved Whale Optimization Algorithm, IWOA) uygulamışlardır [70]. Çelik ve Durgut, PID denetleyici parametrelerini simbiyotik organizmalar arama (Symbiotic Organisms Search, SOS) algoritmasını kullanarak optimize etmişlerdir [56]. Literatürde rapor edilen çalışmalar optimal OGR tasarımı için birçok meta-sezgisel optimizasyon algoritmasının başarıyla uygulandığını göstermektedir. No-Free Lunch (NFL) teoremine göre herhangi bir optimizasyon algoritması tüm optimizasyon problemlerini çözmede eşit derecede iyi değildir [71]. Daha açık bir ifadeyle, Algoritma X bir optimizasyon problemi için optimal bir çözüm bulmada Algoritma Y'den daha iyi performans gösteriyorsa Algoritma Y, başka bir optimizasyon problemini çözmede Algoritma X'den daha iyi performans gösterebilir. Bu bağlamda, incelen güç sistemi problemine yüksek kaliteli çözümler üretebilmek için tez çalışmasının orijinal katkılarından biri olarak geliştirilen hibrit FDBLFD optimizasyon algoritması kullanılmıştır. Bu tez çalışmasında PID, PIDF, FOPID ve PID² kontrolcü parametrelerinin önerilen FDBLFD algoritması kullanılarak ayarlanması yoluyla optimal OGR tasarım probleminin çözümü gerçekleştirilmiştir. PID, PIDF, FOPID ve PID² denetleyicileri ile kontrol edilen OGR sisteminin performansı, zaman alanı ve sağlamlık analizi ile test edilmiştir. Ek olarak kontrolcü performanslarının karşılaştırmalı analizi sunulmuştur.

Tez çalışmasının son bölümünde elektrik şebekelerinin güvenli işletimi için kritik öneme sahip Yönlü Aşırı Akım Röleleri (YAAR) koordinasyonu optimizasyon probleminin çözümü gerçekleştirilmiştir. YAAR, elektrik üretim şebekelerinin dağıtım ve iletim sistemlerini korumak için yaygın olarak kullanılmaktadır. Bu rölelerin çeşitli çalışma koşullarına göre uygun ayarlarının belirlenmesi, güç sistemindeki arızalı noktanın zamanında izolasyonu için kritiktir. YAAR, güç sistemlerinde birincil ve yedek koruma sağlayabildiği için bu rölelerin optimal koordinasyonu güç sistemi mühendisliği için önemli bir konudur. Bu koordinasyonda öncelikle birincil röleler ile korunan alandaki arızaların giderilmesi amaçlanır ve arıza durumunda ilgili yedek röle belirli bir koordinasyon zaman gecikmesi ile arızayı giderir [72]. Yapay zekâ ve doğadan ilham alan algoritmalar kullanılarak YAAR optimal koordinasyonu, son yıllarda güç sistemi araştırmacılarının üzerine çalıştığı popüler konulardan biri olmuştur. Khurshaid ve

arkadaşları, YAAR koordinasyonu optimizasyon probleminde röle parametrelerini ayarlamak için parçacık sürü optimizasyonunun (Particle Swarm Optimization, PSO) güçlü bir varyantını önermişlerdir [73]. Thangaraj ve arkadaşları, YAAR koordinasyon problemini çözmek için diferansiyel evrim (Differential Evolution, DE) algoritmasının geliştirilmiş beş farklı versiyonunu kullanmışlardır [74]. Simülasyon çalışmalarında IEEE 3, IEEE 4 ve IEEE 6-baralı olmak üzere farklı karmaşıklığa sahip üç test sistemi kullanılmıştır. Nümerik sonuçlar, önerilen DE varyantlarının baz algoritmadan daha iyi performans gösterdiğini ortaya koymuştur. Irfan ve arkadaşları, YAAR koordinasyonu optimizasyon problemini çözmek için Harris şahinleri optimizasyon (Harris Hawks Optimization, HHO) algoritmasını uygulamışlardır [75]. Rölelerin toplam çalışma süresini en aza indirmek için röle çalışma süresiyle doğrudan ilişkili olan iki (TDS ve PCS) parametre optimize edilmiştir. Önerilen algoritmanın performansı, üç farklı IEEE test sisteminde değerlendirilmiştir. Kim ve arkadaşları, YAAR koordinasyonu probleminin kontrol değişkenlerini optimize etmek için gri kurt optimizasyon (Grey Wolf Optimization, GWO) algoritmasını kullanmışlardır [76]. İncelenen güç sistemi probleminde dikkate alınan amaç fonksiyonu birincil rölelerin toplam çalışma süresidir. Önerilen algoritmanın etkinliğini göstermek için IEEE 6 ve IEEE 30-baralı test sistemleri kullanılmış ve sonuçlar literatürdeki benzer çalışmalar ile karşılaştırılmıştır. Karşılaştırmalı analiz, önerilen şemanın YAAR koordinasyon problemini çözmek için etkili bir yöntem olduğunu doğrulamıştır. Singh ve arkadaşları, YAAR optimal koordinasyonu için öğretme-öğrenme tabanlı optimizasyon (Teaching-Learning Based Optimization, TLBO) algoritmasının etkinliğini incelemişlerdir [77]. Önerilen algoritmanın performansı IEEE 3, IEEE 4 ve IEEE 6-baralı test sistemlerinde değerlendirilmiştir. TLBO yöntemi, 0,3-0,8 s aralığında optimal koordinasyon marjı sunmuştur. Birincil ve yedek röle çiftleri arasında yanlış koordinasyon olmadan optimal koordinasyon sağlanmıştır. Sadeghi ve arkadaşları, ağ topolojisi değişikliği koşullarında YAAR koordinasyonunu sağlamak için sağlam ve etkili bir model önermişlerdir [78]. Önerilen şema, DIgSILENT yazılım ortamında gerçek ve geleneksel bir dağıtım sistemi olan Kanada dağıtım sisteminde test edilmiştir. Ahmadi ve arkadaşları, iletim sistemlerinde yönlü aşırı akım ve mesafe koruma rölelerinin optimal koordinasyonunu sağlamak için yeni bir yaklaşım sunmuşlardır [79]. Yazarlar seçicilik kriterlerini karşılamak ve yönlü aşırı akım rölelerinin zaman ayar çarpanlarını ve başlatma akımlarını optimize etmek için yeni bir amaç fonksiyonu önermişlerdir. Önerilen yöntem 9-baralı ve 39-baralı test sistemlerine uygulanmıştır. Optimum parametre ayarlarını elde etmek için

optimizasyon araçları olarak GA ve insan davranışına dayalı optimizasyon (Human Behavior-Based Optimization, HBBO) yöntemleri kullanılmıştır. Boucekara ve arkadaşları, YAAR optimal koordinasyonu için modifiye elektromanyetik alan optimizasyon (Modified Electromagnetic Field Optimization, MEFO) algoritmasını uygulamışlardır [80]. Önerilen algoritma standart 8, 9 ve 15-baralı test sistemleri olmak üzere farklı karmaşıklığa sahip üç test sistemine uygulanmıştır. Önerilen MEFO yöntemi kullanılarak elde edilen sonuçlar, geleneksel EFO ve literatürdeki güçlü optimizasyon algoritmalarının simülasyon sonuçları ile karşılaştırılmıştır. Karşılaştırma sonuçları önerilen algoritmanın YAAR optimal koordinasyonu için röle çalışma süresini en aza indirmedeki etkinliğini göstermiştir. Shih ve arkadaşları, YAAR koordinasyonu için geliştirilmiş diferansiyel evrim (Enhanced Differential Evolution, e-DE) algoritmasını önermişlerdir [81]. Önerilen algoritma IEEE 14 ve IEEE 57-baralı test sistemlerine uygulanmıştır. Srivastava ve arkadaşları, dağıtılmış üretim birimlerini içeren güç sisteminde aşırı akım rölelerinin koordinasyonu için parçacık sürüsü optimizasyon (Particle Swarm Optimization, PSO) ve yerçekimi arama algoritmasını (Gravitational Search Algorithm, GSA) uygulamışlardır [82]. Rizk ve El-Fergany, optimum röle koordinasyon problemi için hibrit optimizasyon modeli önermişlerdir [83]. Araştırmacılar, gradyan-tabanlı optimize edici (Gradient-Based Optimizer, GBO) ve lineer popülasyon azaltma tekniği ile güçlendirilmiş başarı geçmişine dayalı uyarlanabilir diferansiyel evrim (Linear Population Size Reduction Technique of Success-History-based Adaptive Differential Evolution, LSHADE) algoritmalarının güçlü yönlerini birleştirdiler. Önerilen optimizasyon yönteminin etkinliğini göstermek için farklı karmaşıklığa sahip üç test sistemi (8-baralı, 15-baralı ve IEEE 30-baralı) üzerinde kapsamlı bir simülasyon gerçekleştirilmiştir. Hibrit algoritma ile elde edilen optimal ayarların incelenen sistemler için herhangi bir kısıt ihlali olmaksızın optimal YAAR koordinasyonunu sağladığı gözlemlenmiştir. Korashy ve arkadaşları, YAAR optimal koordinasyon problemini etkin bir şekilde çözmek için su döngüsü algoritmasının geliştirilmiş versiyonunu kullanmışlardır [84]. Önerilen algoritmanın performansı 8, 9, 15 ve 30 baralı standart test sistemleri kullanılarak değerlendirilmiştir. Sonuçlar, geleneksel WCA ve rekabetçi optimizasyon teknikleri ile karşılaştırıldığında önerilen algoritmanın daha kaliteli çözümler elde edebildiğini göstermiştir. Akdağ ve Yeroğlu, röle çiftleri arasındaki koordinasyon marjına tabi olarak optimum röle koordinasyonunu sağlamak için manta ışıını yiyecek arama optimizasyon (Manta Ray Foraging Optimization, MRFO) algoritmasını uygulamışlardır [72]. Önerilen algoritmanın

performansını test etmek için standart 9 ve 15-baralı test sistemleri kullanılmıştır. Ayrıca, önerilen koruma şeması Türkiye'nin Hatay ilinde rüzgâr enerjili dağıtılmış üretim ünitelerini içeren 10-baralı dağıtım ağı kesitinin sanal modeline uygulanmıştır. Sonuçlar önerilen yöntemin standart ve gerçek güç sistemi için röle koordinasyonunu sağlamada etkili olduğunu göstermiştir. Literatür incelemesi MSA algoritmaları kullanılarak YAAR koordinasyon probleminin optimal çözümünü araştıran birçok çalışma olduğunu göstermiştir. İlgili güç sistemi problemi önerilen optimizasyon algoritmalarının performansını test etmek için uygun bir yapıya sahiptir. Çünkü yönlü aşırı akım röleleri koordinasyon problemi optimum çözüm elde etmenin zor olduğu karmaşık arama uzayına sahip kısıtlı gerçek dünya mühendislik problemidir. YAAR koordinasyon problemi, tez çalışmasının orijinal katkılarından biri olarak geliştirilen *d*FDB-MRFO algoritmasının arama performansını doğrulamak için en uygun problemlerden biridir çünkü rekabet eden birçok çalışma vardır. Önerilen hibrit *d*FDB-MRFO yönteminin performansı farklı karmaşıklığa sahip güç sistemleri (IEEE 3, IEEE 4, Standart 8-baralı, Standart 9-baralı ve IEEE 30-baralı) kullanılarak test edilmiştir.



3. YÖNTEM

Bu bölüm, tek amaçlı optimizasyon problemlerinin çözümü için tez çalışması kapsamında geliştirilen hibrit optimizasyon algoritmalarını ve önerilen çok amaçlı optimizasyon probleminin çözümü için kullanılan MOGOA yöntemini sunar. Bu kapsamda beş alt bölüm hazırlanmıştır. Bu alt bölümlerde sırasıyla aşağıdaki konular ele alınmıştır:

- İlk alt bölümde, meta-sezgisel optimizasyon süreci tanıtılmıştır. Tek ve çok-amaçlı optimizasyon süreci detaylı olarak sunulmuştur.
- İkinci alt bölüm, popülasyon tabanlı meta-sezgisel arama algoritmalarında arama sürecine rehberlik edecek çözüm aday/adaylarının popülasyondan seçimi için kullanılan FDB yöntemi hakkındadır.
- Üçüncü alt bölümde, tez çalışmasının orijinal katkılarından biri olarak geliştirilen d FDB seçim yönteminin tasarımı anlatılmıştır.
- Dördüncü alt bölümde, tez çalışması kapsamında geliştirilmiş tek amaçlı meta-sezgisel arama algoritmaları sunulmuştur. Bu kapsamda geliştirilen algoritmalar şunlardır: FDBLFD, FDBASGK ve d FDB-MRFO. Algoritmaların geliştirilmesinde ikinci ve üçüncü alt bölümlerde detayları sunulan FDB ve d FDB seçim yöntemleri kullanılmıştır.
- Beşinci alt bölümde, çok-amaçlı optimizasyon problemlerinin çözümü için literatürde sıklıkla kullanılan MOGOA algoritması tanıtılmıştır.

3.1. METASEZGİSEL OPTİMİZASYON SÜRECİ

Bu bölümde, metasezgisel optimizasyonun temelleri anlatılmıştır. Bu amaçla iki alt bölüm hazırlanmıştır. Bu alt bölümlerde sırasıyla tek ve çok-amaçlı optimizasyon süreci detaylı olarak incelenmiştir.

3.1.1. Tek Amaçlı Optimizasyon

Tek amaçlı optimizasyon, eşitlik ve eşitsizlik kısıtlamalarına tabi olarak seçilen bir amaç fonksiyonunun minimize veya maksimize edilme süreci olarak tanımlanır. Buna göre tek

amaçlı bir optimizasyon problemi matematiksel olarak Eşitlik (3.1)'de gösterildiği gibi tanımlanmaktadır [6], [19].

$$\begin{aligned}
& \min/\max_{x \in R^n} \quad OF(\vec{x}) \\
& \vec{x} = (x_1, x_2, \dots, x_D) \\
& lb_d \leq x_d \leq ub_d \quad d = 1, 2, \dots, D \\
& \text{subject to } g_k(x) = 0 \quad k = 1, 2, \dots, K \\
& h_l(x) \leq 0 \quad l = 1, 2, \dots, L
\end{aligned} \tag{3.1}$$

Burada, D sürekli değerli ve kısıtlı bir optimizasyon problemindeki tasarım değişkenlerinin sayısını ifade eder. $\vec{x}$ tasarım değişkenleri vektörüdür ve şu şekilde tanımlanır: $x = (x_1, x_2, \dots, x_D)$, $D \in N^+$. Tasarım değişkenlerinin limitleri $[lb, ub]$, $lb, ub \in R$ ve $-\infty < (lb, ub) < +\infty$ olarak ifade edilir. $OF(\vec{x})$ amaç fonksiyonunu, g_k ve h_l ise sırasıyla eşitlik ve eşitsizlik kısıtlarını gösterir.

Eşitlik (3.1) ile modellenen tek amaçlı optimizasyon probleminin çözümü için bir optimizasyon algoritmasının kullanılmasına ihtiyaç vardır. Literatürdeki optimizasyon yöntemleri detaylı olarak incelendiğinde genel olarak deterministik ve stokastik olmak üzere iki sınıfa ayrıldıkları gözlemlenmektedir. Deterministik optimizasyon yöntemleri, gradyan (gradient) tabanlı ve gradyan tabanlı olmayan (non-gradient) olmak üzere iki kategoriye ayrılır [85]. Küresel (global) bir çözüm bulmak için gradyan bilgisini kullanan yöntem, matematiksel programlama yöntemlerinden yararlanır [86]. Matematiksel programlama yöntemlerinin dezavantajı, doğrusal olmayan arama uzaylarında yerel optimumda sıkışma olasılığının yüksek olmasıdır. Sorunun üstesinden gelmek için, farklı bir başlangıç tasarımı denenebilir, yöntemler değiştirilebilir ve farklı algoritmalarla melezleştirilebilir, bu da bazen onları belirli bir problem için benzersiz kılar. Gradyan tabanlı olmayan deterministik yaklaşımların dezavantajları arasında uygulanmasının karmaşık olması, anlaşılması ve kullanılması için yüksek matematiksel hazırlık gerektirmesi yer almaktadır [87].

Optimizasyon problemlerinin çözümü için bir başka alternatif, stokastik optimizasyon kategorisine giren meta-sezgisel arama algoritmalarını uygulamaktır. Meta-sezgisel yöntemler, yerel çözüm tuzaklarını elimine eder ve alanı (arama uzayı) global olarak

aramak için keşif ve sömürü operatörlerini kullanır. Meta-sezgisel algoritmaların anlaşılması ve uygulanması diğer yöntemlere göre oldukça kolaydır. Meta-sezgisel optimizasyon algoritmalarının küresel optimuma yakın çözümler üretebilmesi, problemten bağımsız çalışma mekanizması, esnekliği ve non-gradient doğası, yaygın kullanımlarının nedeni olarak sayılabilecek öne çıkan özelliklerdir [85], [88].

Sürekli değerli ve kısıtlı bir optimizasyon probleminin meta-sezgisel optimizasyon algoritmaları ile başarılı bir şekilde çözülebilmesi için öncelikle MSA sürecinin detaylı olarak analiz edilmesi gerekmektedir. MSA algoritmalarını kullanarak optimizasyon problemlerini modelleme süreci Referans [89]'dan ilham alınarak oluşturulmuş ve Çizelge 3.1'de sunulmuştur. Çizelge 3.1'de verilen sözde-kod tek amaçlı optimizasyon problemlerini meta-sezgisel algoritmalar ile modellemek isteyen araştırmacılar için rehber niteliğindedir.

Çizelge 3.1. Metasezgisel arama süreci genel adımları.

1.	Başla
2.	Başlangıç popülasyonu P vektörünü oluştur (Eşitlik 3.2)
3.	for $i=1: N$ (çözüm adayları sayısı) do
4.	Çözüm adaylarının fitness değerini f hesapla (Eşitlik 3.3)
5.	end
6.	while <i>arama süreci yaşam döngüsü: sonlandırma kriteri sağlanıncaya kadar</i> do
7.	<i>// Seçim Aşaması //</i> • Popülasyondan (P) referans çözüm adaylarının (x_r) seçilmesi
8.	<i>// Arama Aşaması //</i> • Sömürü (Referans çözüm adayları (x_r) etrafında komşuluk araması) • Keşif (Popülasyonda P çeşitlilik sağlama işlemleri)
9.	<i>// Güncelleme Aşaması //</i> • Çözüm adaylarının fitness değerlerine bağlı olarak popülasyonun P güncellenmesi
10.	end
11.	En iyi çözüm: x_{best}
12.	Bitir

MSA süreci iki kısma ayrılır. Birinci kısım, başlangıç çözüm adayları popülasyonunun rastgele oluşturulması ve fitness değerlerinin hesaplanmasından oluşmaktadır. İlk olarak Eşitlik (3.2)'de gösterildiği gibi popülasyon (P) oluşturulur. Burada N popülasyondaki çözüm adayı sayısını gösterir ve her bir çözüm adayı $x_i = (x_1, x_2, \dots, x_D)$ ile temsil edilir. Başlangıç popülasyonunun oluşturulmasının ardından ilgili çözüm adaylarının fitness değerleri Eşitlik (3.1) kullanılarak hesaplanır. Çözüm adaylarının fitness değerleri Eşitlik (3.3)'de gösterilen $N \times 1$ boyutlu vektör ile temsil edilir. MSA sürecinin bu kısmı tüm meta-sezgisel arama algoritmalarında ortaktır [6].

$$P \equiv [x_{11} \dots x_{1D} : \vdots : x_{N1} \dots x_{ND}]_{N \times D} \quad (3.2)$$

$$f = [f_1 \dots f_N]_{N \times 1} \quad (3.3)$$

MSA sürecinin ikinci adımında arama süreci yaşam döngüsü başlatılır. Bu adımda sırasıyla seçim, arama ve güncelleme işlemleri gerçekleştirilir. Seçim işlemi arama sürecine rehberlik edecek çözüm adaylarının (x_r) belirlenmesidir. r indeksi ($r < N$) popülasyondan seçilecek referans çözüm adaylarının sayısını gösterir. Çizelge 3.1 detaylı olarak incelendiğinde seçim aşamasında belirlenen rehber çözüm adaylarının arama aşamasının girdileri olduğu ve dolayısıyla algoritmanın başarısını doğrudan etkilediği açıkça görülmektedir. Sömürü sürecinde, x_r referans çözüm adaylarının etrafında arama işlemi yoğunlaştırılır. Komşuluk araması olarak da bilinen sömürü görevi basittir ve tüm MSA algoritmaları tarafından kolaylıkla yerine getirilebilir. Keşif işlemi, arama uzayındaki umut vadeden çözüm adaylarının araştırılması işlemidir. Daha açık bir ifadeyle popülasyonda çeşitlilik sağlamaktan ibarettir. Özellikle çok boyutlu ve karmaşık arama uzaylarında, algoritmayı yerel çözüm tuzaklarından kurtaracak bir çeşitlilik sağlamak önemli bir zorluktur [19]. Bu tür arama uzaylarında küresel çözümler bulmanın tek yolu, güçlü bir çeşitlilik operatörüne sahip olmaktır. Bu nedenle MHS algoritmalarında en zor görev güçlü ve etkin bir çeşitlilik sağlamaktır. Arama süreci yaşam döngüsünün son adımında çözüm adaylarının fitness değerlerine bağlı olarak popülasyon (P) güncellenir MSA sürecinin ikinci adımı sonlandırma kriteri sağlanıncaya kadar devam eder. Arama süreci yaşam döngüsü sonunda elde edilen en iyi çözüm (x_{best}), P popülasyondaki en iyi fitness değerine sahip çözüm adaydır [6].

3.1.2. Çok Amaçlı Optimizasyon

Bu alt bölümde, çok amaçlı optimizasyon terminolojisi detaylı olarak sunulmuştur. Bu amaçla ilk olarak çok amaçlı optimizasyon problemlerinin matematiksel modeli tanıtılmış ve ardından Pareto-baskınlık (Pareto-Dominance) kavramı açıklanmıştır.

Optimizasyon problemlerini amaç fonksiyonları sayısı, karar değişkenleri sayısı, kısıt fonksiyonları ve amaç uzayları gibi çeşitli özelliklere göre sınıflandırmak veya kategorize etmek mümkündür. Optimizasyon problemlerinin amaç fonksiyonu sayısına göre sınıflandırılması bu özellikler arasında en belirgin olanıdır. Çünkü tek ve çok-amaçlı optimizasyon yapıları birbirinden oldukça farklıdır [90]-[92]. İsimlendirilmesinden de anlaşılacağı gibi çok-amaçlı optimizasyon, problemin birden fazla amaç fonksiyonu için optimizasyonunu ifade eder. Buna göre çok-amaçlı optimizasyon problemleri matematiksel olarak aşağıdaki gibi ifade edilir [93]:

$$\begin{aligned} \min/\max_{\vec{x} \in R^n} \quad & O(\vec{x}) = \{o_1(\vec{x}), o_2(\vec{x}), \dots, o_p(\vec{x})\} \\ & \vec{x} = (x_1, x_2, \dots, x_D) \\ & lb_d \leq x_d \leq ub_d \quad d = 1, 2, \dots, D \\ \text{subject to} \quad & g_k(\vec{x}) = 0 \quad k = 1, 2, \dots, K \\ & h_l(\vec{x}) \leq 0 \quad l = 1, 2, \dots, L \end{aligned} \tag{3.4}$$

Eşitlik (3.4)'te, $O(\vec{x})$ amaç vektörünü, $\vec{x}$ ise tasarım değişkenleri vektörünü temsil eder. lb_d ve ub_d , sırasıyla ilgili tasarım parametresinin alt ve üst limitleri olarak tanımlanır. p –boyutlu çok amaçlı optimizasyon problemi için, karar uzayının sınırları $\vec{x}$ vektörünün tüm olası değerleri ile tanımlanır. Öte yandan, amaç fonksiyonu vektörünün $O(\vec{x})$ tüm olası değerleri, amaç uzayının sınırlarını belirler.

Tek amaçlı optimizasyon problemlerinde amaç fonksiyonu için optimal (minimum veya maksimum) değeri veren tek bir çözüm vardır ve bu çözümün arama uzayındaki konumunun belirlenmesi amaçlanır. Çok-amaçlı optimizasyonda ise, bastırılmayan çözümlerden oluşan bir Pareto-Set (PS) ve bu PS'ye karşılık gelen amaç uzayında uygun çözümler kümesini temsil eden bir Pareto yüzey (Pareto-Front, PF) vardır. Çok amaçlı optimizasyonda amaç, en iyi PF setine karşılık gelen PS 'yi bulmaktır [93], [94].

Çok-amaçlı optimizasyon problemlerinde amaç fonksiyonlarının çatışıp çatışmadığı problemin çözüm süreci için son derece önemlidir [94]. Amaç fonksiyonları çatışma halinde değilse, tüm amaç fonksiyonları için en uygun değeri üreten tek bir çözüm noktası vardır. Bu tür bir problemde amaç fonksiyonları çeşitli yöntemler (ağırlıklı toplama vb.) kullanılarak tek amaçlı fonksiyona dönüştürülebilir ve problem tek bir amaç fonksiyonu ile çözülebilir. Öte yandan amaç fonksiyonları çatışma halinde ise; bir amaç fonksiyonu için optimum değer üreten bir çözüm, diğer amaç fonksiyonu için zayıf bir değer üretebilir [91], [93]. Bu durumda iki çözümün karşılaştırılması, çok amaçlı fonksiyon değerlerinin karşılaştırılmasına olanak sağlayan Pareto-baskınlık kavramına göre yapılır. Pareto tabanlı yaklaşımın genel konsepti Çizelge 3.2’de verilmiştir [93], [97].

Çizelge 3.2. Pareto baskınlık kavramı terminolojisi.

Ögeler	Kavram	Açıklama
Tanım-1	Karar uzayı	Eşitlik (3.4)’te tanımlanan p -boyutlu çok amaçlı optimizasyon problemi için, D -boyutlu karar değişkenlerinin ($\vec{x}$) alt ($\overrightarrow{lb_d}$) ve üst ($\overrightarrow{ub_d}$) sınırları arasındaki bölgeye arama uzayı (karar değişkenleri uzayı) denir.
Tanım-2	Amaç uzayı	p -boyutlu amaç fonksiyonu vektörünün tüm olası değerleri, amaç uzayının sınırlarını temsil eder. $O(\vec{x}) = \{o_1(\vec{x}), o_2(\vec{x}), \dots, o_p(\vec{x})\}$
Tanım-3	Pareto baskınlık	İki çözüm vektörü olduğunu varsayalım: $\vec{x} = (x_1, x_2, \dots, x_D)$ and $\vec{y} = (y_1, y_2, \dots, y_D)$. Ayrıca, kısıtların sağlandığı tüm çözümlerin kümesini Ω ile gösterelim. Buna göre $\vec{x}$ çözümünün $\vec{y}$ çözümünden daha iyi (baskın) olabilmesi için herhangi bir amaç fonksiyonunda $\vec{y}$ ’den kötü olmaması ve en azından bir amaç fonksiyonunda $\vec{y}$ ’den daha iyi bir değer elde etmesi gerekir. Bu koşul sağlanırsa, $\vec{x}$ çözümü $\vec{y}$ çözümüne baskındır (Pareto baskınlık) denir ve $\vec{x} < \vec{y}$ şeklinde gösterilir. $\vec{x}, \vec{y} \in \Omega$ if $\begin{cases} \forall i \in \{1, 2, \dots, p\} & o_i(\vec{x}) < o_i(\vec{y}) \\ \wedge \exists j \in \{1, 2, \dots, p\} & o_j(\vec{x}) < o_j(\vec{y}) \end{cases} \quad \vec{x} < \vec{y}$
Tanım-4	Pareto optimal	Eğer aşağıdaki koşul sağlanırsa $\vec{x} \in \Omega$ çözümü Pareto-optimal olarak adlandırılır. $\nexists \vec{y} \in \Omega \mid \vec{y} < \vec{x}$
Tanım-5	Pareto optimal-set, (PS)	Tüm Pareto-optimal çözümlerin kümesi Pareto set olarak adlandırılır. $PS = \{\vec{x}, \vec{y} \in \Omega \mid \nexists \vec{y} < \vec{x}\}$
Tanım-6	Pareto optimal-front, (PF)	Pareto çözümleri kümesi için amaç fonksiyonlarının değerini içeren set PF olarak adlandırılır. $PF = \{O(\vec{x}) \mid \vec{x} \in PS\}$

3.2. FDB SEÇİM YÖNTEMİ

MSA algoritmalarının arama performansını iyileştirmek için geliştirilen uygunluk-mesafe dengesi (Fitness-Distance Balance-FDB [19]) yöntemi, uygulaması kolay adımlardan oluşmaktadır. FDB yönteminde her bir çözüm adayının seçim süreci için puanı hesaplanır. FDB skor hesabında çözüm adaylarının uygunluk (fitness) ve uzaklık değerleri kullanılır. Uygunluk değeri çözüm adayının başarısını gösterirken, uzaklık değeri en iyi çözüm adayı ile arasındaki farkı göstermektedir. İki çözüm adayının arasındaki mesafenin uzun olması, bu iki adayın birbirine benzemediğini ve birbirlerinin eksikliklerini tamamlama potansiyeline sahip olduğunu bir göstergesidir. Uygunluk değeri yüksek olan çözüm adayının, uzaklık değeri de yüksekse arama sürecine önemli bir katkıda bulunabileceğine dair güçlü bir kanıttır. Diğer bir ifadeyle, yüksek puana sahip adaylar, mevcut popülasyondaki en iyi çözümün dezavantajını ortadan kaldırma potansiyeline sahiptir. Uygunluk değeri yüksek olmasına rağmen, popülasyondaki en iyi adaya çok yakın olan bir çözüm adayının arama sürecini iyileştirme potansiyeli zayıftır. Bu çözüm adayı, popülasyon çeşitliliğine katkıda bulunamaz ancak komşuluk arayışına kısmen katkıda bulunabilir. Böyle bir adayın mesafe değeri sıfıra yakın olacağı için FDB skor değeri de çok düşük olacaktır. FDB skor hesabı ile arama sürecine katkı sağlayamayan, hatta erken yakınsamaya neden olan çözüm adaylarını belirlemek ve ortadan kaldırmak mümkündür. FDB seçim yöntemini kullanarak puanın hesaplanması, yerel optimum tuzaklardan kaçınmak için güçlü bir çözümdür [6], [19].

FDB seçim yönteminin amacı popülasyon içindeki arama sürecine en fazla katkıyı sağlayacak aday veya adayları istikrarlı ve etkili bir şekilde keşfetmektir. Böylece, çeşitlilik (keşif) ve komşuluk arama (sömürü) görevlerinin dengeli bir şekilde yürütülmesi sağlanacaktır.

FDB yöntemini uygulamak için aşağıdaki adımlar takip edilmelidir [19]:

- (i) FDB yönteminin ilk adımında, popülasyondaki çözüm adaylarının mevcut en iyi çözüme olan uzaklığı hesaplanır. N popülasyondaki çözüm adayı sayısı, D ise tasarım parametrelerinin sayısı olmak üzere, i . çözüm adayının (x_i) en iyi çözüm adayına (x_{best}) olan Öklid uzaklığı Eşitlik (3.5) kullanılarak hesaplanır.

$$U_{x,i} = \sqrt{(x_{i[1]} - x_{best[1]})^2 + (x_{i[2]} - x_{best[2]})^2 + \dots + (x_{i[D]} - x_{best[D]})^2} \quad (3.5)$$

P -popülasyonundaki çözüm adaylarının U_P uzaklık vektörü Eşitlik (3.6) ile temsil edilir.

$$U_P \equiv [U_{x,1} \dots U_{x,N}]_{Nx1} \quad (3.6)$$

(ii) FDB yönteminin ikinci adımında P -popülasyonundaki çözüm adayları için skor hesaplanır. Skor hesabında çözüm adaylarının fitness değerlerinin (Eşitlik 3.3) yanı sıra en iyi çözüm adayına olan uzaklığı (Eşitlik 3.6) dikkate alınır. Buna göre çözüm adaylarının FDB skor değeri Eşitlik (3.7) kullanılarak hesaplanır.

$$S_{x[i]} = w * normf_{x[i]} + (1 - w) * normU_{x[i]} \quad (3.7)$$

FDB skor hesabında çözüm adaylarının normalize edilmiş fitness değeri ($normf_{x[i]}$) ve normalize edilmiş uzaklık değeri ($normU_{x[i]}$) kullanılır. Bunun sebebi bu iki nümerik değerin skor hesabında birinin diğerine baskın olmasını engellemektir. Eşitlik (3.7)'de verilen w -parametresi, $f_{x[i]}$ ve $U_{x[i]}$ değerlerinin etkisini ağırlıklandırmak için kullanılır. FDB yönteminde $w = 0.5$ olarak kabul edilmiştir.


Popülasyondaki çözüm adaylarının FDB skorlarını temsil eden N -boyutlu vektör Eşitlik (3.8) ile temsil edilir.

$$S_P \equiv [s_{x,1} \dots s_{x,N}]_{Nx1} \quad (3.8)$$


S_P vektörü oluşturulduktan sonra, arama sürecine rehberlik edecek çözüm adaylarını belirlemek için MSA algoritmalarında açgözlü veya olasılıksal seçim yöntemleri kullanılabilir. Bu çalışmada arama sürecine rehberlik edecek çözüm adaylarının S_P vektöründen seçiminde hem açgözlü yöntem (x_{FDB}) hem de olasılıksal rulet seçim yöntemi (x_{RFDB}) kullanılmıştır. FDB yöntemi hakkında detaylı bilgi Referans [19]'da verilmiştir.

FDB seçim yönteminin etkisini somut verilerle açıklamak için basit bir örnek hazırlanmıştır. $G = (x_1 - 20)^2 + (x_2 - 10)^2$ amaç fonksiyonunu minimize edecek tasarım parametreleri x_1 ve x_2 'nin optimize edileceğini varsayalım. Bu problemi optimize etmek için 10 aday çözümden oluşan bir popülasyon ($P \equiv [P_1, P_2, \dots, P_{10}]$) oluşturulmuştur. Çözüm adaylarının arama uzayındaki konumları Şekil 3.1 (a)'da gösterilmiştir. Çözüm adaylarının normalize edilmiş uygunluk ve uzaklık değerleri sırasıyla Şekil 3.1 (b) ve (c)'de gösterilmiştir. Uygunluk değerleri karşılaştırıldığında popülasyondaki en iyi

çözüm adayı P_5 'tir. Fakat Şekil 3.1 (d)'de gösterildiği gibi FDB seçim yöntemi ile arama sürecine en fazla katkı sağlayacak çözüm adayının P_6 (en yüksek FDB skor değeri) olduğu gözlemlenmiştir.




(a)




(b)

Şekil 3.1. FDB seçim yönteminin pratik bir uygulaması (a) Çözüm adayları konumu, (b) Normalize fitness değerleri, (c) Normalize mesafe değerleri, (d) Çözüm adaylarının FDB puanı.



(c)




(d)


Şekil 3.1. (devam) FDB seçim yönteminin pratik bir uygulaması (a) Çözüm adayları konumu, (b) Normalize fitness değerleri, (c) Normalize mesafe değerleri, (d) Çözüm adaylarının FDB puanı.

3.3. ÖNERİLEN DİNAMİK FDB SEÇİM YÖNTEMİ

MSA algoritmalarında arama süreci yaşam döngüsü, binlerce döngüden oluşan uzun bir süreçtir. Meta-sezgisel arama süreci boyunca global optimuma yakınsama için algoritmalar farklı arama yeteneklerine ihtiyaç duyarlar [98], [99]. Her ne kadar global optimum değere yakınsamak için sağlam bir sömürü yeteneği sergilemek isteseler de, genellikle arama sürecinin ilk aşamalarında yerel çözüm tuzaklarında sıkışma ve erken yakınsama problemi yaşarlar. Yerel çözüm tuzaklarından kaçınmanın yolu, keşif kabiliyetini kademeli olarak artırmaktır. Bu nedenle, arama sürecinin bazı dönemlerinde erken yakınsama problemini önlemek için daha fazla çeşitliliğe ihtiyaç duyulurken, bazı dönemlerde ise sömürüye ihtiyaç duyulmaktadır. Özellikle arama sürecinin son dönemlerinde hassas bir arama yapılması esastır [20], [100], [101]. Bu zorlukların üstesinden gelebilmek için, FDB seçim yönteminde sömürü ve keşif arasındaki dengeyi sağlayan w -katsayısının dinamik olarak değişen bir parametreye dönüştürülmesi gerekmektedir. w değerindeki değişimin sömürü ve keşif üzerindeki etkisini incelemek için Şekil 3.2 (a)'da verilen çözüm adaylarının FDB puanları $w = [0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8; 0,9]$ için yeniden hesaplanmıştır. Buna göre popülasyondan seçilen çözüm adaylarının farklı w -katsayı değerleri için hesaplanan FDB puanları Şekil 3.2 (b)'de verilmiştir.



Şekil 3.2. w ağırlık parametresi değişiminin keşif ve sömürüye etkisi (a) Çözüm adayları konumu (b) Farklı w değerleri için FDB puanı.



(b)

Şekil 3.2. (devam) w ağırlık parametresi değişiminin keşif ve sömürüye etkisi

(a) Çözüm adayları konumu (b) Farklı w değerleri için FDB puanı.

w ağırlık parametresi değişiminin keşif ve sömürü üzerindeki etkisini ortaya koymak için FDB skor hesabında kullanılan Eşitlik (3.7) detaylı olarak incelenmelidir. Buna göre w parametresinin FDB skor hesabını iki yönden etkilediği görülmektedir [20].

- w ağırlık parametresi, çözüm adayının fitness değerinin ($normf_{x_{[i]}}$) çarpanıdır. Dolayısıyla fitness değerinin FDB puanı üzerindeki etkisi ağırlık katsayısı değişimi ile doğrudan ilişkilidir. w değeri arttıkça fitness değerinin FDB skor üzerindeki etkisi de artmaktadır. Bu durum, kaliteli çözümler elde etmek için sömürü işlemini daha da güçlendiren rehber çözüm adayı seçmeyi mümkün kılar.
- w değerindeki değişim ile uzaklık parametresinin ($normU_{x_{[i]}}$) FDB puanına etkisi ters orantılıdır. w değeri azaldıkça mesafe değerinin FDB skor hesabına etkisi artmaktadır. Buna göre, keşif sürecini daha da güçlendiren bir çözüm adayının popülasyondan seçilme olasılığı artar.

Şekil 3.2, w ağırlık katsayısı değişiminin keşif ve sömürüye etkisini göstermek için hazırlanmıştır. Buna göre w parametresinin minimum ($w=0.1$) ve maksimum ($w=0.9$) değerleri için FDB skorları en yüksek çözüm adayları sırasıyla P_7 ve P_{10} olarak belirlenmiştir. Şekil 3.2 (a)'da çözüm adaylarının iki boyutlu koordinat sistemindeki

konumu gösterilmiştir. İlgili şekilde dört çözüm adayı farklı renkler ile vurgulanmıştır. Bunlar; optimizasyon probleminin global çözümü (P_{global}), popülasyondaki en iyi fitness değerine sahip çözüm adayı ($P_{best} = P_5$), w katsayısının minimum ($w=0.1$) ve maksimum ($w=0.9$) değerleri için FDB skor değeri en iyi olan çözüm adaylarıdır (P_7 ve P_{10}).

$dFDB$ yöntemini geliştirmenin amacı, P_5 (mevcut iterasyonda popülasyondaki en iyi çözüm adayı) çözüm adayını P_{global} konumuna mümkün olduğunca yakınlaştırmak için w -parametresini dinamik bir şekilde ayarlamaktır. Şekil 3.2 (a)'da gösterilen çözüm adaylarının konumları incelendiğinde, P_{10} çözüm adayının P_{best} 'e (P_5) en yakın aday olduğu görülmektedir. Buna göre w ağırlık katsayısının yüksek değerleri için P_{best} 'e en çok benzeyen P_{10} çözüm adayı seçilmiş ve sömürü görevi başarılı bir şekilde yerine getirilmiştir. Öte yandan P_7 çözüm adayının P_{best} 'den uzak olmasına rağmen en yüksek katkıyı sağlayabilecek çözüm adayı olduğu anlaşılmaktadır. Buna göre P_7 ve P_{best} arasında gerçekleştirilecek çaprazlama işlemi çok güçlü bir keşif yeteneği sağlayabilir.

$dFDB$ seçim yönteminde w_{dFDB} ağırlık parametresi, arama süreci yaşam döngüsünün ihtiyaçlarına (keşif ve sömürü) göre dinamik olarak ayarlanacak şekilde geliştirilmiştir. Arama süreci yaşam döngüsünün her adımı, mevcut fitness fonksiyonu değerlendirme sayısı (FES) ile temsil edilir. Arama süreci yaşam döngüsü durdurma kriteri maksimum fitness fonksiyonu değerlendirme sayısı (Maximum Number of Function Evaluations, $maxFES$) olarak kabul edilmiştir. Buna göre önerilen $dFDB$ seçim yönteminde w_{dFDB} ağırlık parametresi Eşitlik (3.9) kullanılarak arama süreci yaşam döngüsü boyunca dinamik olarak ayarlanır.


$$w_{dFDB} = \frac{FES}{maxFES} * (1 - w_{dFDB_{[min]}}) + w_{dFDB_{[min]}} \quad (3.9)$$

Eşitlik (3.9)'da $w_{dFDB_{[min]}}$ ağırlık katsayısının minimum değerini temsil eder ve matematiksel olarak şu şekilde tanımlanır: ($0 < w_{dFDB_{[min]}} < 0.5$, $w_{dFDB_{[min]}} \in R$). Frekans (F) ayarlı w_{dFDB} sinyali üretmek için kullanılan sözde-kod Çizelge 3.3'te verilmiştir [20].

Çizelge 3.3. Dinamik ayarlanabilir w_{dFDB} sinyali üretmek için kullanılan sözde-kod.


1.	Başla
2.	F (frekans) ve $maxFEs$ değerlerini belirle
3.	if ($maxFEs / F \geq 1$)
4.	$mod_ref = round(maxFEs / F)$
5.	for $s=1: maxFEs$
6.	$Iter = (s \bmod mod_ref)$
7.	$w_{dFDB} = \frac{Iter}{maxFEs} * (1 - w_{dFDB_{[min]}}) + w_{dFDB_{[min]}}$
8.	end for
9.	end if
10.	Bitir

Çizelge 3.3'te kullanılan F parametresinin w_{dFDB} sinyaline etkisini incelemek için $F=1$ ve $F=5$ değerleri için iki sinyal üretilmiştir. Her iki frekans değeri için üretilen w_{dFDB} sinyallerinin $Iter$ değerine bağlı olarak değişimi Şekil 3.3'te gösterilmiştir.



(a)

Şekil 3.3. Farklı frekanslar için w_{dFDB} sinyalinin üretilmesi (a) $F = 1$, (b) $F = 5$.



Şekil 3.3. (devam) Farklı frekanslar için w_{dFDB} sinyalinin üretilmesi (a) $F = 1$, (b) $F = 5$

Önerilen $dFDB$ seçim yönteminde arama sürecine en fazla katkı sağlayacak çözüm adayları Eşitlik (3.10) kullanılarak belirlenmektedir.

$$i=1^N \forall x_i, S_{x[i]} = w_{dFDB} * normf_{x[i]} + (1 - w_{dFDB}) * normU_{x[i]} \quad (3.10)$$

Şekil 3.3 detaylı olarak incelendiğinde ağırlık katsayısının nümerik değeri $w_{dFDB} = 0.2$ 'den başlayarak lineer olarak artar ve $Iter = maxFEs$ koşulu sağlandığında maksimum değerine ($w_{dFDB}=1$) ulaşır. Daha açık bir ifadeyle arama sürecinin ilk adımlarında erken yakınsama problemini önlemek için keşif süreci baskındır. Arama sürecinin sonraki aşamalarında keşif ve sömürü arasındaki baskınlık ortadan kalkar ve bir denge kurulur. Arama sürecinin son aşamalarında ise sömürü süreci baskın hale gelir ve hassas bir yakınsama yeteneği sergilenir.

3.4. UYGUNLUK MESAFE DENGESİ TABANLI TEK AMAÇLI OPTİMİZASYON ALGORİTMALARI

Bu bölümde FDB ve $dFDB$ seçim yöntemleri kullanılarak tek amaçlı optimizasyon problemlerinin çözümü için geliştirilen meta-sezgisel optimizasyon algoritmalarının tasarım süreci sunulmuştur. Bu kapsamda ilk olarak, LFD ve AGSK algoritmalarının seçim stratejileri FDB seçim yöntemi kullanılarak yeniden tasarlanmış ve böylece uygunluk-mesafe dengesi tabanlı Levy uçuş dağılımı (Fitness-Distance Balance Levy

Flight Distribution, FDBLFD) ve uygunluk-mesafe dengesi tabanlı uyarlanabilir bilgi edinme-paylaşma (Fitness-Distance Balance Adaptive Gaining-Sharing Knowledge, FDBAGSK) olarak isimlendirilen iki yeni algoritma önerilmiştir. Ardından bu çalışmanın orijinal katkılarından biri olarak geliştirilen $dFDB$ seçim yöntemi MRFO algoritmasının arama performansını iyileştirmek için uygulanmış ve dinamik uygunluk mesafe-dengesi tabanlı manta ışını yiyecek arama optimizasyonu (Dynamic Fitness-Distance Balance Manta Ray Foraging Optimization, $dFDB$ -MRFO) olarak isimlendirilen güçlü bir algoritma literatüre sunulmuştur. Sonraki alt bölümlerde sırasıyla önerilen FDBLFD, FDBAGSK ve $dFDB$ -MRFO algoritmalarının tasarımı sunulmuştur.

3.4.1. Önerilen FDBLFD Algoritması

3.4.1.1. LFD Algoritmasına Genel Bakış

Lévy uçuş dağılımı (Levy Flight Distribution, LFD [24]) Houssein ve arkadaşları tarafından optimal arama teorisine dayanan doğa temelli Lévy uçuş rastgele yürüyüşünden ilham alınarak geliştirilmiş popüler ve güncel bir optimizasyon yöntemidir. Levy uçuşlarını uygulamak veya rastgele yürüyüşler oluşturmak için iki özellik tanımlanmalıdır. Bunlar adım uzunluğu ve hareketin hedef konuma ulaşmasını sağlayacak yöndür. Bu özellikleri tanımlamak için birçok yöntem kullanılabilir, ancak en basit ve verimli olanı Mantegna algoritmasıdır. Adım uzunluğu S aşağıdaki gibi tanımlanır [24]:

$$S = \frac{U}{V^{(1/\beta)}} \quad (3.11)$$

$$U \sim ND(0, \sigma_u^2) \quad V \sim ND(0, \sigma_v^2) \quad (3.12)$$

Eşitlik (3.11)'de kullanılan β Levy dağılım endeksi olarak tanımlanır ve $0 < \beta \leq 2$ aralığında sınırlandırılır. Eşitlik (3.12)'de verilen standart sapma (σ_u ve σ_v) matematiksel olarak aşağıdaki gibi modellenir [24]:

$$\sigma_u = \left\{ \frac{\Gamma(1+\beta) \sin(\frac{\pi\beta}{2})}{\Gamma[\frac{1+\beta}{2}] \beta \times 2^{((\beta-1)/2)}} \right\}^{1/\beta} \quad \sigma_v = 1 \quad (3.13)$$

Eşitlik (3.13)'te kullanılan Gama fonksiyonu Γ , a tamsayısı için matematiksel olarak aşağıdaki gibi tanımlanır:

$$\Gamma(a) = \int_0^{\infty} t^{a-1} e^{-t} dt \quad (3.14)$$

Diğer birçok popülasyon tabanlı MSA algoritması gibi, LFD algoritmasının optimizasyon süreci de popülasyon (P) olarak adlandırılan çözüm adayları topluluğunun rastgele oluşturulmasıyla başlar. Eşitlik (3.2)'de tanımlandığı gibi popülasyon, N adet çözüm adayını içerir ve her bir çözüm adayı $x_i = [x_{i1}, x_{i2}, \dots, x_{iD}]$, vektörü ile temsil edilir, burada D tasarım değişkenleri sayısıdır. Ardından çözüm adaylarının fitness değerleri $f_i, (i = 1, 2, \dots, N)$ hesaplanır ve Eşitlik (3.3)'te gösterildiği gibi f vektörü oluşturulur. Böylece meta-sezgisel arama sürecinin ilk aşaması tamamlanmış olur. Bu aşama popülasyon tabanlı meta-sezgisel algoritmaların tamamında ortaktır [6].

MSA sürecinin ikinci aşamasında arama süreci yaşam döngüsü başlatılır. Algoritma, ilk iki komşu çözüm adayı x_i ve x_j (i . çözüm adayının komşusu) arasındaki Öklid mesafesini ($\bar{OM}$) hesaplayarak arama süreci yaşam döngüsünü başlatır [24].

$$\bar{OM}(x_i, x_j) = \sqrt{(a_2 - a_1)^2 + (b_2 - b_1)^2} \quad (3.15)$$

Eşitlik (3.15)'te verilen (a_1, b_1) ve (a_2, b_2) sırasıyla i . çözüm adayı (x_i) ve j . çözüm adayının (x_j) koordinatlarını temsil eder. $\bar{OM}$ değeri önceden tanımlı bir eşik ($threshold=2$) değeri ile karşılaştırılır. Eğer $\bar{OM}$ değeri eşik değerden düşükse, algoritma Eşitlik (3.16) ve Eşitlik (3.17)'yi kullanarak komşu çözüm adaylarının (x_j) konumunu günceller [24].

$$x_j(t+1) = Lévy_Flight(x_j(t), x_{Leader}, lb, ub) \quad (3.16)$$

Eşitlik (3.16)'da t iterasyon indeksini temsil eder, $Lévy_Flight$ ise Lévy uçuşlarını adım uzunluğu ve yönü açısından modelleyen bir alt fonksiyondur. $Lévy_Flight$ alt fonksiyonunun sözde-kodu Çizelge 3.4'te verilmiştir. lb ve ub , sırasıyla tasarım parametrelerinin alt ve üst limitleri olarak tanımlanır. x_{Leader} , en düşük sayıda komşuya sahip olan ve Levy uçuş yönü olarak kullanılacak olan çözüm adayının konumudur. Eşitlik (3.16), x_j çözüm adayını x_{Leader} konumuna doğru hareket ettirir [24].

Çizelge 3.4. *Lévy_Flight* alt fonksiyonu genel adımları.

1.	Girdi: <i>Mevcut Konum, Rehber Konum, lb, ub</i>
2.	Çıktı: <i>Hedef Konum</i>
3.	Başla
4.	Adım uzunluğunu S hesapla (Eşitlik 3.11)
5.	Fark faktörünü hesapla $DF = 0,01 \times S \times (Mevcut Konum - Rehber Konum)$
6.	$Hedef Konum = Mevcut Konum + S \times rand() \times [size(Mevcut Konum)]$
7.	$Hedef Konum$ için sınır değerleri (lb, ub) kontrol et
8.	<i>Hedef Konum</i>
9.	end

Eşitlik (3.17), algoritmanın keşif yeteneğini artırmak için daha fazla şans sunar. Bu denklem, x_j konumunu arama uzayında başka çözüm adaylarının olmadığı yeni bir bölgeye günceller [24].

$$x_j(t+1) = lb + (ub - lb) rand(0,1) \quad (3.17)$$

Algoritma, x_j konumunu güncellemek için R değerini karşılaştırmalı skaler değer (Comparative Scalar Value, CSV) ile karşılaştırır. Eğer $R < CSV$ koşulu sağlanırsa, j . çözüm adayını x_j güncellemek için Eşitlik (3.16), aksi takdirde Eşitlik (3.17) kullanılır.

$$R = rand(0,1), \quad CSV = 0.5 \quad (3.18)$$

x_i çözüm adayının yeni ve nihai (hedef) konumu sırasıyla Eşitlik (3.19) ve Eşitlik (3.20) kullanılarak güncellenir.

$$x_i(t+1) = TP + \alpha_1 TF_{neighbours} + rand \alpha_2 \left(\frac{TP + \alpha_3 * x_{Leader}}{2} - x_i(t) \right) \quad (3.19)$$

$$x_i^{new}(t+1) = Lévy_Flight(x_i(t+1), TP, lb, ub) \quad (3.20)$$

Yukarıdaki eşitliklerde hedef konum olarak adlandırılan TP en iyi fitness değerine sahip çözümü temsil eder. α_1, α_2 , ve α_3 (0-10) aralığında rastgele üretilen sayılardır. Eşitlik (3.19)'da i . çözüm adayının yeni konumunu hesaplamada kullanılan $x_i(t)$ etrafındaki komşularının toplam hedef uygunluğu $TF_{neighbours}$ aşağıdaki gibi hesaplanır [24]:

$$TF_{neighbours} = \sum_{z=1}^{NN} \frac{D(z) * x_z}{NN} \quad (3.21)$$

$$D(z) = \frac{\partial_1 (V - (V))}{(V) - \min(V)} + \partial_2 \quad (3.22)$$

$$V = \frac{f(x_j(t))}{f(x_i(t))}, \quad 0 < \partial_1 \quad \partial_2 \leq 1 \quad (3.23)$$

Eşitlik (3.21)'de, z komşu sayısı indeksini, NN komşuların toplam sayısını gösterir. x_z , $x_i(t)$ 'nin komşu konumunu, $D(z)$ her komşu için fitness derecesini temsil etmektedir.

3.4.1.2. FDBLFD Algoritması Tasarımı

Bu alt bölümde, FDB tabanlı seçim mekanizmasının LFD algoritmasına uygulanması ve önerilen hibrit FDBLFD algoritmasının matematiksel modeli tanıtılmıştır. Bu bölümün daha iyi anlaşılabilmesi için ‘‘Bölüm (3.2) ve (3.4.1.1)’’ gözden geçirilmelidir.

LFD güçlü temellere sahip, doğadan ilham alan bir meta-sezgisel arama algoritmasıdır. LFD yöntemi doğa temelli bir yaklaşım olarak geliştirilmiştir ve başarısı, doğayı taklit etme yeteneğine bağlıdır. Optimizasyon sürecinde algoritma, sürülerin göç davranışını taklit eder. Sürüler hayatta kalabilmek için besin kaynaklarını takip ederek en uygun habitata göç ederler. Buna göre sürünün hayatta kalabilmesi için göç yollarını iyi bilen arama ajanları tarafından yönlendirilmeleri zorunludur. Çünkü sürüler doğada bu şekilde hayatta kalabilmektedir. Bu açıklamaların ışığında, LFD algoritmasının doğanın işleyişini taklit etmek için üç ana yeteneğe sahip olması gerekir: sömürü, keşif ve dengeli arama. Literatürdeki en güncel ve zorlu kıyaslama takımlarından ikisi olan CEC 2017 [102] ve CEC 2020'nin [103] farklı türdeki test problemleri kullanılarak gerçekleştirilen deneysel çalışmalarda LFD algoritmasının erken yakınsadığı ve özellikle çok modlu (multimodal) tip problemlerin arama uzayında yerel çözüm tuzaklarına yakalandığı tespit edilmiştir. Bu durum, LFD yönteminin keşif ve dengeli arama yeteneklerinin yetersiz olduğuna işaret etmiştir. Bu iki yeteneği güçlendirmenin ve arama performansını iyileştirmenin olası yolu, LFD algoritması tasarımını doğa ile uyumlu hale getirmektir. LFD yöntemi göç süreci tasarımı incelendiğinde, sürüyü yönlendiren arama ajanlarından birinin seçim sürecinin doğanın işleyişine uygun olarak tasarlanmadığını gözlemlenmiştir. Bu uyumsuzluğu ortadan kaldırmak ve algoritmanın doğayı taklit etme yeteneğini güçlendirmek için rehber seçim sürecinin yeniden tasarlanmasına karar verilmiştir.

Bu çalışmada, sürünün göç yollarını en iyi bilen arama ajanları tarafından yönlendirilmesini sağlamak için rehber seçim aşamasında FDB yöntemi kullanılmıştır. LFD algoritmasının doğayı taklit etme yeteneğini geliştirmek için algoritmanın tasarımında iki büyük değişiklik yapılmıştır.

İlk olarak *Lévy_Flight* (Çizelge 3.4) alt fonksiyonunda aramanın yönünü belirleyen ‘Rehber Konum (*Guide Position*)’ yeniden tasarlanmıştır. LFD algoritmasında doğadaki Levy uçuşları Eşitlik (3.16) ve (3.20) ile modellenmektedir. Bu eşitliklerde kullanılan x_{Leader} ve TP , *Lévy_Flight* alt fonksiyonunda ‘Rehber Konum’ olarak adlandırılan arama ajanına karşılık gelmektedir. Burada x_{Leader} , en az sayıda komşuya sahip arama ajanını, TP ise açgözlü seçim yöntemiyle seçilen arama ajanını temsil etmektedir. Ancak doğada Levy uçuşlarını bu şekilde tanımlayan hiçbir şey yoktur. Levy uçuşlarında doğanın işleyişini başarılı bir şekilde taklit etmek için, arama sürecini etkin bir şekilde yönlendiren bir yönleme ihtiyacı vardır. Bu amaçla Eşitlik (3.16)’da, %70 oranında x_{Leader} yerine FDB yöntemi (x_{FDB}) ile seçilen arama ajanı kullanılmıştır. Eşitlik (3.20)’de TP yerine FDB yöntemi ile seçilen x_{FDB} arama ajanının kullanılması önerilmiştir.

İkinci değişiklik, arama ajanının arama uzayında rastgele bir bölgeye yönlendirildiği Eşitlik (3.17)’de yapılmıştır. Rastgele bir yönlendirme yerine, arama sürecine en fazla katkı sağlayacak x_{FDB} arama ajanının kullanılması önerilmiştir. x_{FDB} , Eşitlik (3.8)’de tanımlanan S_p vektöründeki en yüksek FDB puanına sahip arama ajanını temsil eder.

LFD algoritmasının keşif ve dengeli arama yeteneklerini geliştirmek için FDB seçim yönteminin uygulandığı onlarca versiyon oluşturulmuş ve bunların arasından en başarılı olan ilk üç FDBLFD versiyonu (Versiyon-1, Versiyon-2 ve Versiyon-3) sunulmuştur. FDB yönteminin uygulandığı denklemler ve FDBLFD versiyonlarının matematiksel modelleri Çizelge 3.5’te verilmiştir.

Çizelge 3.5. FDBLFD versiyonlarının matematiksel modeli.

Algoritma	FDB tabanlı LFD versiyonları (önerilen)
Versiyon-1	Eşitlik (3.20) için önerilen geliştirmede, TP yerine FDB yöntemi (x_{FDB}) ile seçilen arama ajanı kullanılmıştır.
	LFD: $x_i^{new}(t+1) = Lévy_Flight(x_i(t+1), TP, lb, ub)$ FDB-LFD versiyonu: $x_i^{new}(t+1) = Lévy_Flight(x_i(t+1), x_{FDB}, lb, ub)$ (3.24)
Versiyon-2	Eşitlik (3.17) için önerilen geliştirmede, rastgele bir yönlendirme yerine FDB yöntemiyle (x_{FDB}) seçilen arama ajanı kullanılmıştır.
	LFD: $x_j(t+1) = lb + (ub - lb) rand(0,1)$ FDB-LFD versiyonu: $x_j(t+1) = x_{FDB}$ (3.25)
Versiyon-3	Eşitlik (3.16) için önerilen geliştirmede, %70 oranında x_{Leader} yerine FDB yöntemiyle (x_{FDB}) seçilen arama ajanı kullanılmıştır.
	LFD: $x_j(t+1) = Lévy_Flight(x_j(t), x_{Leader}, lb, ub)$ FDB-LFD versiyonu: $x_j(t+1) = Lévy_Flight(x_j(t), x_{FDB}, lb, ub)$ (3.26)

Önerilen FDBLFD algoritmasının optimizasyon çerçevesi ve FDB seçim yönteminin uygulandığı bölümler Çizelge 3.6’da detaylı olarak gösterilmiştir. Gri gölgeli satırlar, FDBLFD algoritmasını oluşturmak için gerçekleştirilen yenilikleri temsil eder.

Çizelge 3.6. Önerilen FDBLFD algoritmasının sözde-kodu.

1.	Girdi: Arama ajanı sayısı (N), <i>Eşik Değer</i> , <i>CSV</i> , R , $maxFEs$
2.	Çıktı: x_{best}
3.	Başla
4.	P : Rastgele başlangıç popülasyonunu oluştur (Eşitlik 3.2)
5.	for $i=1: N$ (arama ajanı sayısı) do
6.	f : P ’deki her bir arama ajanının fitness değerini hesapla (Eşitlik 3.3)
7.	end
8.	while <i>arama süreci yaşam döngüsü: sonlandırma kriteri sağlanıncaya kadar</i> do
9.	//Seçim Aşaması//
10.	FDB seçim yöntemini kullanarak P -popülasyondan rehber arama ajanlarının seçilmesi
11.	<i>FDB skor hesaplanması:</i>
12.	for $i=1: N$ do
13.	x_i arama ajanının en iyi arama ajanına x_{best} uzaklığını hesapla (Eşitlik 3.5)
14.	Arama ajanının FDB skor değerini hesapla (Eşitlik 3.7)
15.	end for
16.	FDB skor değerine göre S_P vektöründen (Eşitlik 3.8), arama sürecine rehberlik edecek arama ajanını x_{FDB} seç

Çizelge 3.6. (devam) Önerilen FDBLFD algoritmasının sözde-kodu.

17.	x_{FDB} en yüksek FDB skor değerine sahip arama ajanını temsil eder
18.	//Arama aşaması (Keşif ve Sömürü) //
19.	for i=1: N do
20.	for j=1: N do
21.	Öklid mesafesini (ÖM) hesapla: Eşitlik (3.15)'i kullanarak x_i (main) ve x_j (neighbour) arama ajanları arasındaki mesafeyi hesapla
22.	if ÖM < Eşik Değer
23.	if R < CSV
24.	$x_j(t + 1)$ arama ajanını güncelle (Eşitlik 3.26) //Versiyon-3//
25.	else
26.	$x_j(t + 1)$ arama ajanını güncelle (Eşitlik 3.25) //Versiyon-2//
27.	end if
28.	end if
29.	end for
30.	$x_i^{new}(t + 1)$ arama ajanını güncelle (Eşitlik 3.24) //Versiyon-1//
31.	end for
32.	$x_i^{new}(t + 1)$ arama ajanı için yeni fitness değerini hesapla ve en iyi çözümü x_{best} belirle
33.	//Güncelleme aşaması //
34.	Eğer daha iyi çözüm varsa en iyi arama ajanını x_{best} güncelle
35.	end while
36.	En iyi çözüm: x_{best}
37.	Bitir

3.4.1.3. FDBLFD Algoritmasının CEC 2017 ve CEC 2020 Benchmark Problemlerinde Test Edilmesi

Bu alt bölümde, FDBLFD versiyonlarının arama performansı incelenmiştir. Bu amaçla, FDBLFD algoritmasının üç farklı versiyonu kullanılmış ve Versiyon-1, Versiyon-2 ve Versiyon-3 olarak adlandırılmıştır. FDBLFD algoritmasının varyasyonları hakkında ayrıntılı bilgi için “Bölüm 3.4.1.2 (Önerilen FDBLFD algoritması)” detaylı olarak incelenmelidir. Takip eden alt bölümlerde, sırasıyla, rekabetçi algoritmaların istatistiksel analizi, yakınsama analizi ve algoritma karmaşıklığı detaylı olarak incelenmiştir.

- *İstatistiksel Analiz*

Deneysel çalışmalardan elde edilen veri parametrik olmayan istatistiksel test yöntemleri ile analiz edilmiştir. Buna göre, algoritmalar arasındaki ikili karşılaştırmalar için Wilcoxon ikili işaret testi, ikiden fazla algoritma arasındaki karşılaştırmalar için Friedman testi kullanılmıştır.

İstatistiksel analizler için kullanılan veri 39 test fonksiyonu, 3 farklı boyut, 51 bağımsız deneme ve 4 MSA (LFD ve FDBLFD varyantları) algoritmasını içermektedir. Deneysel çalışmalardan elde edilen 23.868 ($39 \times 3 \times 51 \times 4$) veri ögesi, en iyi arama performansına sahip FDB tabanlı versiyonu belirlemek için Friedman testi ile analiz edilmiştir. Friedman puanları, her deneysel çalışmada algoritmalar tarafından elde edilen ortalama hata değerleri kullanılarak hesaplanmıştır. Bu puanlar, algoritmaların istatistiksel olarak elde ettiği sıraları temsil eder. Her deney için elde edilen en iyi puan (sıra), Çizelge 3.7’de koyu ve gri gölgeli renklendirme ile işaretlenmiştir.

Çizelge 3.7. FDBLFD versiyonları ve LFD için Friedman testi ile elde edilen sıralar.

Algoritma	Boyut=30		Boyut=50		Boyut=100		Ortalama Sıra
	CEC 2017	CEC 2020	CEC 2017	CEC 2020	CEC 2017	CEC 2020	
Versiyon-1	1,13	1,51	1,18	1,56	1,13	1,36	1,31
Versiyon-2	2,72	2,51	2,41	2,19	2,35	2,08	2,37
Versiyon-3	2,98	2,90	3,09	3,01	3,07	3,16	3,03
LFD	3,15	3,05	3,30	3,23	3,43	3,38	3,25

Friedman testi sonucunda algoritmaların farklı test takımları ve arama uzaylarında elde ettiği başarı sıralaması Çizelge 3.7’de verilmiştir. Buna göre, Versiyon-1, Versiyon-2 ve Versiyon-3, tüm deneylerde LFD algoritmasının baz modelinden daha iyi arama performansı sergilemiştir. Versiyon-1 tüm deneysel çalışmalarda rakip algoritmalarından daha iyi arama performans göstermiş ve ‘Ortalama Sıra’ indeksine göre FDBLFD versiyonlarının en başarılısı olarak belirlenmiştir.

Geleneksel LFD algoritması ve FDB tabanlı LFD versiyonları arasındaki ikili karşılaştırma sonuçlarını özetleyen Wilcoxon test sonuçları Çizelge 3.8’de verilmiştir. Örneğin; ilgili çizelgenin ilk satırında verilen “Versiyon-1 vs. LFD”, FDBLFD varyantı (Versiyon-1) ile LFD algoritmasının baz modeli arasındaki ikili karşılaştırmayı gösterir. Çizelge 3.8’de her hücrede verilen nümerik değerlerin toplamı, ilgili CEC kıyaslama takımındaki test fonksiyonlarının sayısına eşittir. Her bir hücrede verilen puanlar (+/=/-) sırasıyla, FDB tabanlı LFD varyantının baz algoritmadan üstün olduğu test problemi sayısını, iki rakip algoritmanın benzer performans sergilediği test problemlerinin sayısını ve FDBLFD varyantının rakibine mağlup olduğu test problemlerinin sayısını gösterir. Örneğin, Çizelge 3.8’in ikinci hücresinde 18/4/7 (Versiyon-2 / CEC 2017/ Boyut = 30) olarak verilen deney sonucuna göre; Versiyon-2 yirmi dokuz test probleminin on

sekizinde LFD algoritmasından daha iyi, dört problemde benzer, yedi problemde ise LFD'den daha kötü performans göstermiştir.

Çizelge 3.8. LFD ve FDBLFD versiyonları arasında Wilcoxon ikili karşılaştırma sonuçları.

vs. LFD +/-	Boyut=30		Boyut=50		Boyut=100	
	CEC 2017	CEC 2020	CEC 2017	CEC 2020	CEC 2017	CEC 2020
Versiyon-1	29/0/0	9/0/1	27/1/1	8/1/1	28/0/1	9/0/1
Versiyon-2	18/4/7	7/2/1	23/3/3	9/0/1	26/0/3	9/0/1
Versiyon-3	8/19/2	2/7/1	7/21/1	2/8/0	14/14/1	5/4/1

Çizelge 3.8'de verilen Wilcoxon ikili karşılaştırma sonuçları, algoritmaların farklı test takımı ve problem uzaylarındaki arama performansı hakkında önemli bilgiler sağlar. Boyut = 30 için gerçekleştirilen deneysel çalışmalar analiz edildiğinde, FDBLFD varyantlarının hem CEC 2017 hem de CEC 2020 kıyaslama problemlerinde baz LFD yönteminden daha iyi performans sergilediği görülmektedir. Boyut = 50 için, CEC 2020 test problemlerinde Versiyon-2 en iyi puana (9/0/1) sahiptir. CEC 2017 test problemlerinde ise FDBLFD versiyonları baz algoritmaya ezici bir üstünlük kurmuştur. Boyut=100 için gerçekleştirilen Wilcoxon ikili karşılaştırma testi, FDBLFD versiyonlarının yüksek boyutlu karmaşık arama uzaylarında her iki test takımı için de geleneksel LFD'den daha güçlü bir arama performansına sahip olduğunu açıkça ortaya koymuştur.

MSA algoritmaları yüksek boyutlu karmaşık arama uzaylarında global optimum çözüm elde etmede oldukça zorlanmaktadırlar. Bu sorunun üstesinden gelmek için algoritmanın iki önemli yeteneğinin geliştirilmesi gerekmektedir: keşif ve dengeli arama. Çizelge 3.8'deki sonuçlar derinlemesine analiz edildiğinde, problem boyutu ile FDBLFD versiyonları arasında pozitif bir korelasyon olduğu gözlemlenmiştir. Diğer bir ifadeyle, problem boyutu arttıkça FDB etkisi daha net ortaya çıkmıştır. Bu durum FDB seçim yönteminin baz LFD algoritmasının keşif ve dengeli arama yeteneklerini geliştirmedeki etkisini açıkça ortaya koymuştur.

Çizelge 3.9, LFD ve FDBLFD versiyonlarını problem tipi özelinde keşif, sömürü ve dengeli arama yeteneklerini ayrıntılı olarak analiz etmek için hazırlanmıştır. İlgili çizelge, tek-modlu (unimodal), çok-modlu (multimodal), hibrit (hybrid) ve kompozisyon

(composition) problem tipleri için geleneksel LFD ve FDBLFD versiyonlarının Friedman sıralamalarını özetler. Dört farklı problem tipi ve üç farklı boyut için CEC 2017 (12) ve CEC 2020 (12) test takımlarında toplam 24 deneysel çalışma gerçekleştirilmiştir. Buna göre, her deney için elde edilen en iyi sonuçlar koyu-gri renkle işaretlenmiştir.

Çizelge 3.9. Farklı problem tipleri için LFD ve FDBLFD versiyonlarının Friedman sıralaması.

	Problem Tipi		LFD	Versiyon-1	Versiyon-2	Versiyon-3
CEC 2017	Tek-modlu	Boyut=30	3,04	1,00	2,95	3,00
		Boyut=50	3,13	1,00	2,75	3,11
		Boyut=100	3,33	1,05	2,34	3,26
	Çok-modlu	Boyut=30	3,25	1,11	2,45	3,17
		Boyut=50	3,06	1,30	2,53	3,09
		Boyut=100	2,99	1,34	2,64	3,01
	Hibrit	Boyut=30	2,97	1,07	2,88	3,05
		Boyut=50	3,28	1,04	2,40	3,25
		Boyut=100	3,49	1,06	2,28	3,16
	Kompozisyon	Boyut=30	3,24	1,22	2,78	2,74
		Boyut=50	3,46	1,27	2,35	2,90
		Boyut=100	3,69	1,06	2,25	2,99
CEC 2020	Tek-modlu	Boyut=30	3,47	1,00	2,47	3,05
		Boyut=50	3,49	1,00	2,07	3,43
		Boyut=100	3,64	1,00	2,01	3,33
	Çok-modlu	Boyut=30	2,69	2,11	2,16	3,02
		Boyut=50	2,85	2,08	2,17	2,88
		Boyut=100	2,73	2,07	2,29	2,89
	Hibrit	Boyut=30	3,00	1,00	3,09	2,90
		Boyut=50	3,35	1,00	2,39	3,24
		Boyut=100	3,62	1,00	2,00	3,37
	Kompozisyon	Boyut=30	3,34	1,60	2,29	2,75
		Boyut=50	3,41	1,77	2,03	2,77
		Boyut=100	3,69	1,15	1,98	3,16

Çizelge 3.9'daki Friedman istatistiksel analiz sonuçlarına göre, FDBLFD versiyonları, CEC 2017 test takımında gerçekleştirilen 12 deneysel çalışmanın 9 tanesinde klasik LFD yönteminden daha iyi performans sergilemiştir. Aynı test seti için LFD'nin üstün olduğu deneyler şu şekildedir: çok-modlu (Boyut = 50 ve Boyut = 100) ve hibrit (D = 30) problem

tipleri. CEC 2020 kıyaslama takımındaki deneyler incelendiğinde, FDBLFD versiyonlarının çok-modlu problem tipindeki deneyler dışındaki tüm deneylerde baz algoritmadan daha iyi performans gösterdiği gözlemlenmiştir. Sonuç olarak burada toplam 24 deneysel çalışma gerçekleştirildi ve tüm deneylerde Versiyon-1 olarak isimlendirilen FDB tabanlı algoritma, rakiplerinden daha iyi performans gösterdi. Ayrıca FDB tabanlı LFD versiyonlarının tüm problem türleri için baz algoritmadan daha iyi performans göstermesi, FDB seçim yönteminin geleneksel LFD algoritmasının keşif, sömürü ve dengeli arama yeteneklerini geliştirildiğini açıkça göstermiştir.

Çizelge 3.10, CEC 2020 kıyaslama takımı test fonksiyonlarında LFD ve FDBLFD versiyonları tarafından elde edilen amaç fonksiyonu değerleri için hata istatistiklerini (ortalama ve standart sapma) sunar. Hata değeri şu şekilde hesaplanmıştır: “ $(f(x) - f(x^*))$ ”, burada $f(x)$ algoritmaların elde ettiği amaç fonksiyon değerini, $f(x^*)$ her bir kıyaslama fonksiyonunun global optimum değerini temsil etmektedir. İlgili tabloda en iyi değerler koyu renkle vurgulanmıştır. Hata değerlerinin anlaşılmasını ve yorumlanmasını kolaylaştırmak için CEC 2017 ve CEC 2020 kıyaslama takımlarındaki dört farklı problem tipi için box-plot grafikleri çizdirilmiştir. 30, 50 ve 100 boyutlu arama uzaylarında LFD ve FDBLFD versiyonlarının farklı tip (tek-modlu/çok-modlu/hibrit/kompozisyon) test problemlerindeki performansı Şekil 3.3 ve 3.4’te gösterilmiştir.


Çizelge 3.10. CEC 2020 test problemleri için elde edilen ortalama hata ve standart sapma değerleri.

Fonksiyon	Arama Uzayı	LFD	Versiyon-1	Versiyon-2	Versiyon-3
F1	Boyut=30	6,45E+10 (7,55E+09)	3,02E+06 (7,55E+05)	4,86E+10 (1,53E+10)	5,58E+10 (1,07E+10)
	Boyut=50	1,20E+11 (1,70E+10)	2,16E+07 (6,43E+06)	7,69E+10 (2,35E+10)	1,20E+11 (1,35E+10)
	Boyut=100	2,71E+11 (1,11E+10)	2,25E+08 (8,38E+07)	1,45E+11 (4,85E+10)	2,63E+11 (1,32E+10)
F2	Boyut=30	7,37E+03 (3,60E+02)	4,32E+03 (7,50E+02)	4,78E+03 (5,26E+02)	7,44E+03 (3,39E+02)
	Boyut=50	1,34E+04 (5,34E+02)	7,95E+03 (9,10E+02)	8,72E+03 (9,33E+02)	1,35E+04 (4,43E+02)
	Boyut=100	2,88E+04 (9,10E+02)	1,80E+04 (1,31E+03)	2,03E+04 (2,21E+03)	2,90E+04 (6,89+02)
F3	Boyut=30	7,71E+02 (3,70E+01)	4,63E+02 (8,76E+01)	7,83E+02 (5,37E+01)	7,70E+02 (3,69E+01)
	Boyut=50	1,23E+03 (2,63E+01)	8,74E+02 (1,21E+02)	1,30E+03 (7,92E+01)	1,22E+03 (2,88E+01)
	Boyut=100	2,85E+03 (6,00E+01)	2,38E+03 (2,24E+02)	3,12E+03 (1,66E+02)	2,86E+03 (5,69E+01)
F4	Boyut=30	1,78E-14 (6,17E-14)	3,89E-01 (2,08E-01)	0,00E+00 (0,00E+00)	1,56E-13 (1,07E-13)
	Boyut=50	2,01E-13 (7,40E-14)	2,05E+00 (5,98E-01)	0,00E+00 (0,00E+00)	2,36E-13 (1,36E-13)
	Boyut=100	3,83E-13 (1,16E-13)	7,76E+00 (2,25E+00)	3,52E-07 (2,51E-06)	4,64E-13 (2,13E-13)
F5	Boyut=30	4,85E+07 (1,99E+07)	9,20E+05 (6,91E+05)	5,84E+07 (8,38E+07)	4,58E+07 (1,73E+07)
	Boyut=50	2,89E+08 (7,36E+07)	2,17E+06 (9,94E+05)	3,34E+08 (4,84E+08)	2,71E+08 (8,87E+07)
	Boyut=100	1,17E+09 (2,06E+08)	6,37E+06 (2,59E+06)	1,43E+08 (4,80E+07)	1,09E+09 (1,88E+08)
F6	Boyut=30	3,11E+03 (3,58E+02)	7,34E+02 (2,79E+02)	3,41E+03 (2,40E+03)	3,18E+03 (3,88E+02)
	Boyut=50	6,58E+03 (6,69E+02)	1,88E+03 (4,81E+02)	3,82E+03 (8,09E+02)	6,56E+03 (6,24E+02)
	Boyut=100	2,36E+04 (2,75E+03)	5,26E+03 (9,68E+02)	8,84E+03 (1,39E+03)	2,13E+04 (3,27E+03)
F7	Boyut=30	1,48E+07 (6,82E+06)	4,19E+05 (3,44E+05)	8,87E+07 (1,15E+08)	1,31E+07 (7,11E+06)
	Boyut=50	6,14E+07 (1,99E+07)	1,02E+06 (4,63E+05)	1,06E+08 (1,84E+08)	6,03E+07 (2,13E+07)


Çizelge 3.10. (devam) CEC 2020 test problemleri için elde edilen ortalama hata ve standart sapma değerleri.

F7	Boyut=100	4,22E+08 (1,15E+08)	3,81E+06 (1,59E+06)	5,08E+07 (1,74E+07)	4,52E+08 (1,04E+08)
F8	Boyut=30	7,34E+03 (5,82E+02)	4,22E+03 (1,93E+03)	5,49E+03 (7,53E+02)	7,36E+03 (7,60E+02)
	Boyut=50	1,38E+04 (4,52E+02)	8,51E+03 (1,07E+03)	1,01E+04 (7,00E+02)	1,39E+04 (5,25E+02)
	Boyut=100	3,02E+04 (8,64E+02)	1,95E+04 (1,47E+03)	2,22E+04 (1,38E+03)	3,02E+04 (8,69E+02)
F9	Boyut=30	1,05E+03 (8,19E+01)	9,70E+02 (1,48E+02)	9,75E+02 (1,71E+02)	8,11E+02 (4,72E+01)
	Boyut=50	1,77E+03 (1,59E+02)	1,77E+03 (2,27E+02)	1,48E+03 (3,27E+02)	1,26E+03 (5,37E+01)
	Boyut=100	5,56E+03 (6,88E+02)	2,66E+03 (2,16E+02)	3,12E+03 (7,69E+02)	3,31E+03 (2,21E+02)
F10	Boyut=30	4,86E+03 (8,67E+02)	4,06E+02 (1,98E+01)	3,34E+03 (1,07E+03)	4,72E+03 (8,82E+02)
	Boyut=50	1,52E+04 (1,09E+03)	5,92E+02 (2,46E+01)	1,01E+04 (2,98E+03)	1,45E+04 (1,46E+03)
	Boyut=100	2,78E+04 (2,44E+03)	9,07E+02 (5,63E+01)	1,74E+04 (3,94E+03)	2,64E+04 (2,83E+03)


Şekil 3.4, CEC 2017 kıyaslama takımından seçilen F3 (tek-modlu), F5 (çok-modlu), F19 (hibrit) ve F25 (kompozisyon) test fonksiyonları için LFD ve FDBLFD versiyonlarının box-plot grafiklerini göstermektedir. İlgili şekilden, FDB tabanlı rehber seçim mekanizması kullanılarak geliştirilmiş Versiyon-1 ve Versiyon-2 algoritmalarının dört problem tipinde de baz algoritmaya kıyasla daha kararlı bir arama performansı sergilediği ve minimum hata değerine yakınsayabildiği görülmektedir. Öte yandan, Versiyon-3, LFD'ye kıyasla rekabetçi bir performans sergilemiştir. Şekil 3.5, CEC 2020 kıyaslama takımından seçilen F1 (tek-modlu), F2 (çok-modlu), F5 (hibrit) ve F10 (kompozisyon) test problemleri için algoritmaların ortalama hata ve standart sapma değerini içeren box-plot grafiklerini sunar. Box-plot grafikleri (Şekil 3.5) detaylı olarak incelendiğinde, FDB tabanlı Versiyon-1 algoritmasının kararlı bir şekilde optimum çözümler bulabildiği buna karşın baz algoritmanın (LFD) erken yakınsama problemi nedeniyle minimum hata değeri elde etmede yetersiz olduğu anlaşılmaktadır. Özetle; her iki test takımından seçilen farklı karmaşıklığa sahip problemler düşük (Boyut=30), orta (Boyut=50) ve yüksek boyutlu (Boyut=100) arama uzaylarında test edilmiş ve FDB tabanlı Versiyon-1 yönteminin rakiplerine kıyasla daha güçlü ve kararlı bir arama performansı sergilediği gözlemlenmiştir.




(a) F3 (Tek-modlu) Boyut = 30




(b) F3 (Tek-modlu) Boyut = 50




(c) F3 (Tek-modlu) Boyut = 100



(d) F5 (Çok-modlu) Boyut = 30




(e) F5 (Çok-modlu) Boyut = 50




(f) F5 (Çok-modlu) Boyut = 100


Şekil 3.4. CEC 2017 test problemleri için box-plot grafikleri.




(g) F19 (Hibrit) Boyut = 30




(h) F19 (Hibrit) Boyut = 50




(i) F19 (Hibrit) Boyut = 100



(j) F25 (Kompozisyon) Boyut = 30




(k) F25 (Kompozisyon) Boyut = 50




(l) F25 (Kompozisyon) Boyut = 100


Şekil 3.4. (devam) CEC 2017 test problemleri için box-plot grafikleri.




(a) F1 (Tek-modlu) Boyut = 30




(b) F1 (Tek-modlu) Boyut = 50




(c) F1 (Tek-modlu) Boyut = 100



(d) F2 (Çok-modlu) Boyut = 30




(e) F2 (Çok-modlu) Boyut = 50




(f) F2 (Çok-modlu) Boyut = 100


Şekil 3.5. CEC 2020 test problemleri için box-plot grafikleri.




(g) F5 (Hibrit) Boyut = 30




(h) F5 (Hibrit) Boyut = 50




(i) F5 (Hibrit) Boyut = 100



(j) F10 (Kompozisyon) Boyut = 30



(k) F10 (Kompozisyon) Boyut = 50



(l) F10 (Kompozisyon) Boyut = 100

Şekil 3.5. (devam) CEC 2020 test problemleri için box-plot grafikleri.

- *Yakınsama Analizi*

FDB seçim yönteminin LFD algoritmasının global optimuma yakınsama performansına etkisini ortaya koymak için yakınsama analizi gerçekleştirilmiştir. Bu amaçla CEC 2020 kıyaslama takımından dört farklı problem tipi seçilmiş ve algoritmaların 30, 50 ve 100 boyutlu arama uzaylarındaki yakınsama eğrileri incelenmiştir. Şekil 3.6, F1 (tek-modlu), F3 (çok-modlu), F6 (hibrit) ve F10 (kompozisyon) test problemleri için LFD ve FDBLFD versiyonlarının yakınsama eğrilerini göstermektedir.

Şekil 3.6 (a, b, c), tek-modlu F1 problemi için algoritmaların yakınsama eğrilerini göstermektedir. Yakınsama eğrileri detaylı olarak incelendiğinde, Versiyon-1'in farklı karmaşıklığa sahip arama uzaylarında kararlı bir şekilde arama yapabildiği ve minimum hata değerine yakınsamada rakiplerine kıyasla üstün bir arama performansı sergilediği anlaşılmaktadır. F1 problemi için elde edilen sonuçlar, FDB tabanlı Versiyon-1 yönteminin sömürü yeteneğinin rakiplerinden daha üstün olduğunu ortaya koymuştur.


Şekil 3.6 (d, e, f) çok-modlu F3 problemi için baz LFD ve FDB tabanlı LFD versiyonlarının yakınsama eğrilerini göstermektedir. Grafiklerden, birden fazla yerel çözüm tuzağı içeren çok-modlu test probleminde baz algoritmanın (LFD) erken yakınsama problemi nedeniyle minimum hata değerine yakınsamada zorlandığı tespit edilmiştir. Buna karşın, Versiyon-1 rakiplerine kıyasla 30, 50 ve 100 boyutlu arama uzaylarında daha sağlam ve kararlı bir arama performans sergiledi. Bu durum FDB tabanlı Versiyon-1 algoritmasının güçlü keşif yeteneği ile yerel çözüm tuzaklarında sıkışma ve erken yakınsama problemlerini elimine edebildiğinin bir göstergesidir.

Şekil 3.6 (g, h, i), hibrit F6 problemi için optimizasyon algoritmalarının yakınsama eğrilerini sunar. Hibrit tipte bir problem için başarılı arama, güçlü sömürü-keşif dengesine bağlıdır. Grafiklerden düşük, orta ve yüksek boyutlu arama uzaylarında FDBLFD versiyonlarının baz algoritmaya kıyasla daha düşük hata değerine yakınsadığı görülmektedir. Bu durum FDB seçim yönteminin baz algoritmanın dengeli arama yeteneğini geliştirdiğinin bir göstergesidir.


Şekil 3.6 (j, k, l) kompozisyon tip F10 problemi için LFD ve FDBLFD versiyonlarının yakınsama eğrilerini gösterir. Kompozisyon tip problemler deneysel çalışmalarda kullanılan kıyaslama problemleri arasında en yüksek karmaşıklığa sahip olan problemlerdir. Şekil 3.6 (j-l)'de verilen eğriler, LFD algoritmasının kompozisyon tipi problemleri optimize etmede diğer problem tiplerine kıyasla daha fazla zorluk yaşadığını

göstermektedir. Öte yandan FDBLFD versiyonlarının LFD yöntemine kıyasla daha düşük hata değerine yakınsadığı görülmektedir. Versiyon-1 tüm boyutlarda 10^3 'ten daha küçük hata değerine yakınsayan tek algoritmadır. Sonuç olarak FDBLFD versiyonlarının keşif ve sömürü görevlerini dengeli bir şekilde yerine getirmede başarılı oldukları gözlemlenmiştir.







(a) F1 (Tek-modlu) Boyut = 30




(b) F1 (Tek-modlu) Boyut = 50




(c) F1 (Tek-modlu) Boyut = 100



(d) F3 (Çok-modlu) Boyut = 30




(e) F3 (Çok-modlu) Boyut = 50




(f) F3 (Çok-modlu) Boyut = 100


Şekil 3.6. CEC 2020 test takımından seçilen farklı problem tipleri için LFD ve FDBLFD versiyonlarının yakınsama eğrileri.




(g) F6 (Hibrit) Boyut = 30




(h) F6 (Hibrit) Boyut = 50




(i) F6 (Hibrit) Boyut = 100



(j) F10 (Kompozisyon) Boyut = 30



(k) F10 (Kompozisyon) Boyut = 50



(l) F10 (Kompozisyon) Boyut = 100

Şekil 3.6. (devam) CEC 2020 test takımından seçilen farklı problem tipleri için LFD ve FDBLFD versiyonlarının yakınsama eğrileri.

- *Algoritma Karmaşıklığı Analizi*


Optimizasyon algoritması tasarımında temel amaç minimum hata değeri ile global optimuma yakınsamak olsa da bu amaca hızlı ve düşük hesaplama karmaşıklığı ile ulaşmak da oldukça önemlidir. Bu çalışmada geliştirilen FDBLFD versiyonları ve LFD algoritmasının kullanılabilirlik ve işlevsellik özelliklerini ortaya koymak için algoritma karmaşıklığı analizi gerçekleştirilmiştir. Algoritma karmaşıklığı hesabında IEEE CEC 2014 [104]'te verilen problem tanımları ve değerlendirme kriterleri referans alınmıştır. Buna göre algoritma karmaşıklığı $(T_2-T_1)/T_0$ formülü kullanılarak hesaplanmıştır. Burada T_0 parametresi, Referans [104]'te tanımlanan spesifik bir test programı için algoritmanın hesaplama süresini, T_1 ise algoritmanın F18 problemini bir kez hesaplamak için geçen zamanı gösterir. T_2 , algoritmanın tam hesaplama süresini temsil eder ve F18 test probleminin 200.000 defa değerlendirilmesi için geçen süre olarak tanımlanır.

LFD ve FDBLFD versiyonları için algoritma karmaşıklığı bilgisi Çizelge 3.11 ve Şekil 3.7'de sunulmuştur. Buna göre, arama süreci yaşam döngüsünde FDB seçim yöntemi tarafından ek bir işlem yükü olmasına rağmen, Versiyon-1 ve Versiyon-3 algoritmalarının LFD yönteminden daha düşük hesaplama karmaşıklığına sahip olduğu gözlemlenmiştir. Bu başarının nedeni; FDB yöntemi ile tasarlanmış bu iki algoritmanın yerel çözüm tuzaklarını ortadan kaldırmada baz algoritmaya göre daha başarılı olması ve bu sayede global çözümü daha kısa sürede bulmasıdır. Versiyon-2, rakiplerine kıyasla daha yüksek bir hesaplama karmaşıklığına sahiptir.

Algoritma karmaşıklığı ve arama uzayı boyutu arasındaki ilişkiyi göstermek için, LFD ve FDBLFD versiyonlarının hesaplama karmaşıklığı 30, 50 ve 100 boyutlu arama uzayları için hesaplanmıştır. Çizelge 3.11'in son satırında verilen p_1, p_2 değerleri, arama uzayı boyutu artışına bağlı olarak algoritma karmaşıklığındaki yüzdesel artış miktarını göstermektedir. Yüzdesel artışın hesaplanmasında 30 boyut için hesaplanan algoritma karmaşıklığı bilgisi referans alınmıştır. Buna göre Çizelge 3.11'in son satırında verilen sonuçlardan arama uzayı boyutundaki artıştan en az etkilenen algoritmanın LFD ($p_1=\%11,83$, $p_2=\%42,22$), en çok etkilenen algoritmaların ise Versiyon-2 ($p_1=\%20,24$, $p_2=\%60,41$) ve Versiyon-3 ($p_1=\%18,38$, $p_2=\%65,88$) olduğu tespit edilmiştir.

Çizelge 3.11. LFD ve FDBLFD versiyonları için algoritma karmaşıklığı bilgisi.

Arama uzayı	T_0	T1	LFD	Versiyon-1	Versiyon-2	Versiyon-3
Boyut=30	0,13	1,4101	566,08	515,41	1197,97	370,66
Boyut=50		2,3261	633,05	594,26	1440,46	438,81
Boyut=100		6,9361	805,12	802,36	1921,67	614,87
% p_1, p_2			$p_1=\%11,83$ $p_2=\%42,22$	$p_1=\%15,29$ $p_2=\%55,67$	$p_1=\%20,24$ $p_2=\%60,41$	$p_1=\%18,38$ $p_2=\%65,88$



Şekil 3.7. LFD ve FDBLFD versiyonları için 30, 50 ve 100 boyutlu arama uzayındaki karmaşıklık bilgisi.

Özetle, bu alt bölümde FDB seçim yönteminin geleneksel LFD algoritmasının keşif, sömürü ve dengeli arama yetenekleri üzerindeki etkisi incelenmiştir. FDBLFD versiyonlarının (Versiyon-1, Versiyon-2 ve Versiyon-3) LFD yöntemine kıyasla daha kararlı ve sağlam bir arama performansı sergilediği gözlemlenmiştir. Deneysel çalışma sonuçları, FDB seçim yönteminin geleneksel LFD algoritmasının yerel çözüm tuzaklarına takılma ve erken yakınsama problemlerinin elimine edilmesinde önemli katkılarının olduğunu ortaya koymuştur. Versiyon-1, FDB tabanlı algoritmalar arasında en başarılı olanıdır ve tez çalışmasının sonraki bölümlerinde FDBLFD olarak isimlendirilmiştir.

3.4.1.4. FDBLFD Algoritması Arama Performansının Rekabetçi MSA Algoritmaları ile Karşılaştırılması

Bu alt bölümde, en başarılı FDBLFD varyantı olarak sunulan Versiyon-1 ve Çizelge 3.12’de detaylandırılan 11 MSA algoritmasının arama performansları incelenmiştir. Bu amaçla, FDBLFD yöntemi de dahil olmak üzere 12 MSA algoritmasının keşif, sömürü ve dengeli arama yeteneklerini test etmek için tek-modlu, çok-modlu, hibrit ve kompozisyon problem tipleri kullanılmıştır. Ayrıca, algoritmaların düşük (Boyut=30), orta (Boyut=50) ve yüksek boyutlu (Boyut=100) arama uzaylarındaki performansını test etmek için dinamik olarak boyutlandırılmış test fonksiyonları dikkate alınmıştır. Takip eden alt bölümlerde, sırasıyla, rekabetçi algoritmaların istatistiksel analizi, yakınsama analizi ve algoritma karmaşıklığı bilgisi sunulmuştur.

- *İstatistiksel Analiz*

İstatistiksel analiz için CEC kıyaslama takımlarındaki 39 problem, her bir problem için 51 bağımsız çalıştırma, 3 farklı problem boyutu ve 12 MSA algoritması kullanılarak gerçekleştirilen deneysel çalışmalardan elde edilen veri ($39 \times 51 \times 3 \times 12 = 71.604$) kullanıldı. CEC 2017 ve CEC 2020 kıyaslama takımları ve bu kıyaslama problemlerinin üç farklı boyutu için altı farklı deneysel çalışma yapılmıştır. Her deneysel çalışma için elde edilen en iyi Friedman skoru, Çizelge 3.12’de koyu gölgeli olarak gösterilmiştir.

Çizelge 3.12. FDBLFD ve rakip algoritmalar için Friedman testi ile elde edilen sıralar.

Algoritma	Boyut=30		Boyut=50		Boyut=100		Ortalama Sıra
	CEC 2017	CEC 2020	CEC 2017	CEC 2020	CEC 2017	CEC 2020	
FDBLFD	4,01	3,63	3,57	3,08	3,07	2,66	3,34
DE [105]	3,29	3,99	3,36	4,56	3,76	5,20	4,03
BMO [106]	4,65	3,73	4,97	4,21	5,24	4,40	4,53
HHO [107]	5,78	4,61	5,20	4,17	4,84	4,06	4,78
MFO [108]	4,79	4,77	5,53	4,73	6,38	5,32	5,25
GSA [109]	7,27	6,68	6,17	5,34	5,02	4,46	5,82
WOA [110]	7,61	6,03	7,08	5,83	6,80	5,20	6,43
CSA [111]	3,01	11,99	3,10	12	3,39	12	7,58
HGSO [112]	7,65	5,90	8,09	6,5	8,36	6,83	7,22
SCA [113]	8,05	7,83	8,77	8,33	9,26	8,91	8,53
LFD [24]	10,96	9,40	10,95	9,32	10,60	9,01	10,04
DDAO[114]	10,93	9,45	11,19	9,93	11,28	9,95	10,46

Algoritmaların Friedman test sıralaması, tüm deneylerde elde edilen puan değerlerinin ortalamasına göre hesaplanmış ve Çizelge 3.12'nin son sütununda verilmiştir. Buna göre rekabetçi algoritmalar arasında en iyi sıralamaya sahip ilk beş algoritma sırasıyla uygunluk-mesafe dengesi tabanlı Levy dağılım (Fitness-Distance Balance Levy flight Distribution, FDBLFD), diferansiyel evrim (Differential Evolution, DE), barnacles çiftleşme optimize edici (Barnacles Mating Optimizer, BMO), Harris şahinleri optimizasyon (Harris Hawks Optimization, HHO) ve güve alevi optimizasyon (Moth-Flame Optimization, MFO) yöntemleridir. Çizelge 3.12'de görüldüğü gibi, önerilen FDBLFD yöntemi 12 rekabetçi algoritma arasında ilk sırada yer alırken, baz LFD algoritması 11. sırada yer almıştır. Bu iki algoritmanın Friedman sıralamalarındaki farklılık, FDB seçim yönteminin LFD algoritmasının arama performansını dikkate değer bir şekilde iyileştirdiğine işaret etmiştir.

Çizelge 3.12'de verilen Friedman test sonuçları derinlemesine analiz edildiğinde, tüm deneysel çalışmalarda rakiplerine üstünlük kuran tek bir algoritmanın mevcut olmadığı görülmektedir. Bu durum, algoritmaların arama performansının arama uzayı boyutuna (Boyut = 30, 50 ve 100) ve CEC kıyaslama test takımlarındaki problem tiplerine bağlı olarak değiştiğini açıkça göstermektedir. Buna göre CSA, DE ve FDBLFD algoritmalarının CEC 2017 test problemlerindeki performansları dikkat çekicidir. CSA, CEC17 Boyut = 30 ve Boyut=50 için gerçekleştirilen deneylerde ilk sırada yer almasına rağmen, önerilen FDBLFD algoritması yüksek boyutlu karmaşık arama uzayında (Boyut = 100) daha başarılı olmuştur. FDBLFD, DE, HHO ve BMO algoritmaları, CEC 2020 test takımı kullanılarak gerçekleştirilen deneylerde rakiplerinden daha iyi arama performansı sergilemiştir. Ayrıca deneysel çalışmalarda ilginç sonuçlar da gözlemlenmiştir. Örneğin, Boyut=30 ve Boyut=50 için CEC 2017 kıyaslama takımı test problemleri kullanılarak gerçekleştirilen deneylerde CSA algoritması ilk sırada yer almasına rağmen, genel sıralamada ilk beşte yer almadı. Bu durum, zorlu CEC 2020 test takımı problemlerindeki CSA'nın zayıf performansı ile açıklanabilir. Öte yandan deneylerin hiçbirinde birinci sırada yer alamayan BMO algoritması, genel sıralamada rekabetçi 12 algoritma arasında üçüncü sırada yer aldı. Buna göre BMO algoritmasının deneysel çalışmalarda kararlı bir arama performansı sergilediğini söylemek mümkündür.

Önerilen FDBLFD algoritması, altı deneysel çalışmanın dördünde rakiplerini geride bıraktı ve ilk sırada yer aldı. CEC 2017 kıyaslama problemleri kullanılarak gerçekleştirilen iki deneysel çalışmada (Boyut=30 ve Boyut=50) FDBLFD, CSA ve DE

algoritmalarının ardından üçüncü sırada yer almıştır. CEC 2020 test takımındaki tüm deneylerde en başarılı arama performansı sergileyen algoritma FDBLFD olmuştur. Özetle, FDBLFD kararlı ve sağlam bir arama performansı sergilemiş ve deneylerin çoğunda rakiplerini geride bırakarak genel değerlendirmede ilk sırada yer almıştır.

FDBLFD ve rekabetçi algoritmalar arasında ikili karşılaştırma yapmak için literatürdeki en yaygın istatistiksel analiz yöntemlerinden biri olan Wilcoxon işaretli sıra testi kullanıldı. Çizelge 3.13, FDBLFD ve en başarılı dört rakip algoritma (DE, BMO, HHO ve MFO) arasındaki %5 anlamlılık düzeyinde gerçekleştirilen Wilcoxon işaretli sıra testi sonuçlarını sunar. + / = / - işaretleri, rakip algoritmanın sırasıyla daha iyi, benzer veya daha kötü performans gösterdiği test problemlerinin sayısını temsil eder. İkili karşılaştırmada, FDBLFD algoritmasının rakiplerinden daha iyi performans gösterdiği deneyler koyu renkle işaretlenmiştir. Buna göre, FDBLFD tüm deneysel çalışmalarda BMO, HHO ve MFO algoritmalarına üstünlük sağlamıştır. DE vs FDBLFD arasındaki ikili karşılaştırmada, CEC 2020 test takımında gerçekleştirilen 50 ve 100 boyutlu deneylerde FDBLFD daha iyi performans gösterirken, CEC 2017 test takımındaki 30 boyutlu deneyde ise DE üstündür. Öte yandan tüm deneyler için bir kıyaslama yapıldığında FDBLFD yönteminin DE algoritmasına üstünlük sağladığı deneysel çalışma sayısı daha fazladır. Wilcoxon ikili karşılaştırma sonuçları, problem boyutundaki artışa bağlı olarak FDBLFD algoritmasının arama performansının arttığını ve FDBLFD'nin yüksek boyutlu karmaşık arama uzaylarında etkili olabileceğini göstermiştir.

Çizelge 3.13. FDBLFD ve rekabetçi algoritmalar arasında Wilcoxon ikili karşılaştırma sonuçları.

vs. FDBLFD +/-/-	Boyut=30		Boyut=50		Boyut=100	
	CEC 2017	CEC 2020	CEC 2017	CEC 2020	CEC 2017	CEC 2020
DE	16/2/11	5/0/5	13/3/13	4/0/6	14/1/14	3/0/7
BMO	12/4/13	3/2/5	8/3/18	2/0/8	5/0/24	2/0/8
HHO	0/5/24	1/1/8	0/6/23	1/1/8	1/2/26	1/0/9
MFO	10/8/11	1/3/6	7/3/19	1/2/7	7/1/21	3/1/6

Özetle; Friedman ve Wilcoxon istatistiksel analiz sonuçları önerilen FDBLFD algoritmasının genel arama performansının rakiplerine kıyasla daha üstün olduğunu doğrulamıştır. Ayrıca DE, BMO, HHO ve MFO yöntemleri diğer rekabetçi algoritmalarından daha iyi performans sergileyerek en başarılı beş algoritma arasında yer

almıştır. İstatistiksel analiz sonuçları, önerilen FDBLFD yönteminin rekabetçi performans sergilediğini ve küresel optimizasyon problemlerinin çözümü için kullanılabilecek güçlü bir algoritma olduğunu ortaya koymuştur.

- *Yakınsama Analizi*

Algoritmaların yakınsama performansını incelemek için, CEC 2020 kıyaslama takımından dört farklı problem tipi seçilmiştir: F1 (tek-modlu), F2 (çok-modlu), F5 (hibrit) ve F10 (kompozisyon) test fonksiyonları. 30, 50 ve 100 boyutlu arama uzayında dört farklı problem tipi için algoritmaların yakınsama eğrileri Şekil 3.8’de sunulmuştur.

Şekil 3.8 (a, b, c) F1 test fonksiyonu için rekabetçi algoritmaların yakınsama grafiklerini göstermektedir. Buna göre tek-modlu problem tipinde FDBLFD algoritması yakınsama hızı ve doğruluğu açısından rakiplerine kıyasla üstün bir arama performansı sergilemiştir. Grafiklerden BMO ve MFO yöntemlerinin özellikle 50 ve 100 boyutlu arama uzaylarında minimum hata değerine yakınsamada yetersiz oldukları görülmektedir. DE ve HHO algoritmalarının arama performansının ise oldukça yakın olduğu gözlemlenmiştir.


Şekil 3.8 (d, e, f), çok-modlu F2 test problemi için rekabetçi algoritmaların yakınsama eğrilerini sunar. İlgili şekilden düşük (Boyut=30), orta (Boyut=50) ve yüksek boyutlu (Boyut=100) arama uzaylarında önerilen FDBLFD yönteminin minimum hata değerine başarılı bir şekilde yakınsadığı görülmektedir. Diğer algoritmalar ise özellikle 100 boyutlu karmaşık arama uzayında erken yakınsamış ve minimum hata değerine ulaşmada başarısız olmuştur. Yüksek boyutlu (Boyut=100) karmaşık arama uzayında, algoritmaların arama performansında büyük farklılıklar gözlemlenmiştir. Buna göre, hata değeri $1,8 \times 10^4$ ’ün altında olan tek algoritma FDBLFD’dir. Bu durum, FDBLFD algoritmasının yüksek boyutlu problemlerde güçlü keşif yeteneği ile global optimuma ulaşmada etkili olabileceğini göstermiştir.

Şekil 3.8 (g, h, i), F5 (hibrit) problemi için algoritmaların yakınsama eğrilerini gösterir. Hibrit tip problemlerde algoritmaların başarılı performansı, dengeli arama yeteneklerine bağlıdır. Şekil 3.8’de F5 problemi için verilen yakınsama eğrileri, küçük (Boyut=30) ve yüksek boyutlu (Boyut=100) boyutlu arama uzaylarında FDBLFD yönteminin dengeli arama kabiliyetinin rakiplerinden çok daha iyi olduğunu göstermektedir. Eğriler dikkatlice incelendiğinde 30 ve 100 boyutlu arama uzaylarında 10^6 ve 10^7 hata değerlerinin altına sadece FDBLFD algoritmasının yakınsadığı görülmektedir. FDBLFD ve BMO, 50 boyutta rakiplerinden daha iyi arama performansı elde etmiştir. Özetle,


FDBLFD keşif ve sömürüyü başarılı bir şekilde dengeleme yeteneğine sahiptir.

Şekil 3.8 (j, k, l), kompozisyon tip (F10) test problemi için algoritmaların yakınsama eğrilerini sunar. 30 ve 50 boyutlu deneylerde BMO rakiplerine kıyasla daha zayıf bir performans sergilemiştir. 100 boyutlu arama uzayında ise MFO algoritması erken yakınsadı. Öte yandan FDBLFD tüm boyutlarda en iyi değer elde eden yöntem olmuştur. Önerilen FDBLFD yönteminin kararlı ve sağlam bir arama performansı sergilediğini söylemek mümkündür.







(a) F1 (Tek-modlu) Boyut = 30




(b) F1 (Tek-modlu) Boyut = 50




(c) F1 (Tek-modlu) Boyut = 100



(d) F2 (Çok-modlu) Boyut = 30




(e) F2 (Çok-modlu) Boyut = 50




(f) F2 (Çok-modlu) Boyut = 100


Şekil 3.8. CEC 2020 test takımından seçilen farklı problem tipleri için rekabetçi algoritmaların yakınsama eğrileri (Boyut=30, 50, 100).




(g) F5 (Hibrit) Boyut = 30




(h) F5 (Hibrit) Boyut = 50




(i) F5 (Hibrit) Boyut = 100



(j) F10 (Kompozisyon) Boyut = 30



(k) F10 (Kompozisyon) Boyut = 50



(l) F10 (Kompozisyon) Boyut = 100

Şekil 3.8. (devam) CEC 2020 test takımından seçilen farklı problem tipleri için rekabetçi algoritmaların yakınsama eğrileri (Boyut=30, 50, 100).

Özetle, parametrik olmayan istatistiksel analiz sonuçları FDBLFD, DE, BMO, HHO ve MFO algoritmalarının on iki rakip algoritma arasında en iyi arama performansına sahip rekabetçi algoritmalar olduğunu göstermiştir. FDBLFD ve rakip algoritmaların farklı türdeki test problemlerinin çözümündeki performansı incelenmiş ve sonuçlar önerilen algoritmanın literatürdeki güçlü optimizasyon algoritmaları ile rekabetçi bir performans sergilediğini göstermiştir.

- *Algoritma Karmaşıklığı*

Algoritma karmaşıklığı hesaplamasına ilişkin teknik bilgiler *Bölüm 3.4.1.3*’te verilmiştir. FDBLFD, DE, BMO, HHO ve MFO algoritmalarının hesaplama karmaşıklığı bilgisi Çizelge 3.14’te verilmiştir.

Çizelge 3.14. Rekabetçi MSA algoritmalarının karmaşıklık bilgisi.

Arama Uzayı	T0	T1	FDBLFD	DE	BMO	HHO	MFO
Boyut=30	0,1448	1,5607	475,6238	62,9054	43,6204	40,7795	30,4623
Boyut=50		2,3812	543,2020	65,8719	64,7535	47,5110	35,6731
Boyut=100		6,9686	709,9137	71,2293	1710,171	69,2337	46,4847

Çizelge 3.14’te verilen sonuçlar, MFO algoritmasının rakiplerine kıyasla daha düşük hesaplama karmaşıklığına sahip olduğunu göstermiştir. DE ve HHO algoritmaları benzer karmaşıklığa sahiptir. Arama uzayı boyutunun artmasına rağmen, bu iki algoritmanın hesaplama karmaşıklığındaki kararlılık etkileyicidir. BMO algoritması, Boyut=30 ve Boyut=50 için kabul edilebilir bir algoritma karmaşıklığına sahiptir. Ancak yüksek boyutlu (Boyut=100) arama uzayında en yüksek algoritma karmaşıklığı BMO yöntemine aittir. Önerilen FDBLFD yönteminin rakiplerine kıyasla daha yüksek algoritma karmaşıklığına sahip olması, arama süreci yaşam döngüsünde karmaşık prosedürlerin uygulanmasına ve FBD seçim yöntemi prosedüründen kaynaklanan ek işlemlere bağlanabilir.

3.4.2. Önerilen FDBAGSK Algoritması

3.4.2.1. AGSK Algoritmasına Genel Bakış

Uyarlanabilir bilgi edinme-paylaşma (Adaptive Gaining-Sharing Knowledge, AGSK [23]) yöntemi 2020 yılında Mohamed ve arkadaşları tarafından geliştirilmiş popülasyon tabanlı bir meta-sezgisel algoritmadır. AGSK, bilgi edinme-paylaşma (Gaining-Sharing Knowledge, GSK [115]) algoritmasının arama kabiliyetini güçlendirmek ve zorlu optimizasyon problemlerini hızlı yakınsama ve yüksek doğrulukla çözebilmek için geliştirilmiştir. AGSK algoritmasının güçlü yönü, bilgi faktörü (k_f) ve bilgi oranı (k_r) parametrelerinin dinamik olarak ayarlanmasıdır. AGSK algoritması, GSK yöntemi ile adaptif prosedür birleştirilerek geliştirilmiştir. AGSK yönteminin anlaşılmasını kolaylaştırmak için GSK algoritmasının temelleri ve adaptif prosedür aşağıda detaylı olarak incelenmiştir.

- *Bilgi edinme-paylaşma algoritması (Gaining-Sharing Knowledge, GSK)*

Bilgi-edinme paylaşma (Gaining-Sharing Knowledge, GSK) yöntemi, 2020 yılında Mohamed ve arkadaşları tarafından insanların yaşamları boyunca bilgi edinme ve paylaşma davranışlarından ilham alarak geliştirilmiş güçlü bir meta-sezgisel algoritmadır. Algoritma, insan ömrü boyunca bilgi edinme ve paylaşma sürecini taklit eder. Bu süreç iki hayati aşamaya dayanır: genç bilgi edinme-paylaşma (junior gaining-sharing knowledge) ve kıdemli bilgi edinme-paylaşma (senior gaining-sharing knowledge). GSK, meta-sezgisel arama sürecinde bu iki aşamanın matematiksel modelini kullanmaktadır [115].

Çizelge 3.15'te gösterildiği gibi, GSK optimizasyon süreci üç aşamadan oluşmaktadır: seçim, arama ve güncelleme. Seçim aşamasında arama sürecine yön verecek rehber çözüm adayları belirlenir. GSK algoritması, rehber çözüm adaylarını belirlemek için sıralı, rastgele ve açgözlü seçim yöntemlerini kullanır. Arama süreci yaşam döngüsünün ikinci adımında, sömürü ve keşif operatörleri aracılığıyla global optimum değer aranır. Son olarak, P popülasyonu çözüm adaylarının fitness değerlerine göre güncellenir.

Çizelge 3.15. GSK algoritmasının optimizasyon şeması.

1.	Başla
2.	P : Rastgele başlangıç popülasyonunu oluştur (Eşitlik 3.2)
3.	for $i=1: N$ (çözüm aday sayısı) do
4.	f : Çözüm adaylarının fitness değerlerini hesapla (Eşitlik 3.3)
5.	end
6.	while arama süreci yaşam döngüsü: sonlandırma kriteri sağlanıncaya kadar do
7.	Adım 1: Seçim Süreci
8.	Arama sürecine rehberlik edecek referans çözüm adaylarının P 'den seçilmesi ($x_{i-1}, x_{i+1}, x_R, x_{pbest}, x_m, x_{pworst}$)
9.	Adım 2: Arama Süreci (Sömürü ve Keşif)
10.	Genç bilgi edinme paylaşma aşaması (x_{i-1}, x_{i+1}, x_R)
11.	Kıdemli bilgi edinme paylaşma aşaması ($x_{pbest}, x_m, x_{pworst}$)
12.	Adım 3: Güncelleme işlemi
13.	Çözüm adaylarının fitness değerlerine göre P - popülasyonu güncelle
14.	end while
15.	Bitir

Diğer meta-sezgisel algoritmalarda olduğu gibi, GSK optimizasyon sürecinin ilk adımında çözüm adaylarını içeren popülasyonun (P) oluşturulması ve çözüm adayları fitness (f) değerlerinin hesaplanması işlemleri gerçekleştirilir. Bu kapsamda ilk olarak N çözüm aday ve D tasarım parametresini içeren $P_{N \times D}$ matrisi Eşitlik (3.2)'de gösterildiği gibi oluşturulur. Ardından çözüm adaylarının fitness değerlerini temsil eden $N \times 1$ boyutlu f vektörü ise Eşitlik (3.3) ile temsil edilir. Genç ve kıdemli bilgi kazanma-paylaşma aşamalarındaki işlemlere tabi tutulacak tasarım parametresinin sayısı deneyim denklemi olarak adlandırılan Eşitlik (3.27) kullanılarak belirlenir [23].

$$D_{genç_bilgi_edinme-paylaşma} = D * \left(1 - \frac{FEs}{maxFEs}\right)^K \quad (3.27)$$

$$D_{kıdemli_bilgi_edinme-paylaşma} = D - D_{genç_bilgi_edinme-paylaşma}$$

Eşitlik (3.27)'de FEs ve $maxFEs$ sırasıyla mevcut ve maksimum fitness fonksiyonu değerlendirme sayısı olarak tanımlanır. Genç bilgi kazanma-paylaşma aşaması kullanılarak güncellenecek tasarım parametresi sayısı başlangıçta maksimum değerini alır ve zaman içinde kıdemli bilgi kazanma-paylaşma aşaması kullanılarak güncellenecek tasarım parametresi sayısı artar. Bu matematiksel yaklaşım, insanın yaşamının bazı zamanlarında öğrenme ve bilgi paylaşma hızının artması, bazı zamanlarda ise azalması süreci taklit edilerek modellenmiştir. Dinamik süreç, Eşitlik (3.27)'deki bilgi paylaşım

katsayısı K parametresi ($K>0$) ayarlanarak yönetilir. Buna göre, popülasyonun heterojen dağılımı nedeniyle, K parametresi popülasyon bireylerinin yarısı için 0-1 aralığında rastgele bir değer ve diğer yarısı için 1-20 aralığında bir tamsayı değeri alır [23], [115].

Genç bilgi edinme-paylaşma aşamasında, bilgi edinme kaynakları sınırlıdır. Bu nedenle her birey yalnızca en yakın aile üyelerinden ve akrabalarından bilgi alma eğilimindedir. Bu aşamada çözüm adayları aşağıdaki adımlar takip edilerek güncellenir [115]:

Adım 1: P -popülasyonundaki çözüm adayları Eşitlik (3.28)'de gösterildiği gibi fitness değerlerine göre artan düzende sıralanır. Burada, x_{best} ve x_{worst} sırasıyla en iyi ve en kötü fitness değerine sahip çözüm adaylarını temsil eder.

$$P' = \begin{bmatrix} x_{best} \\ \vdots \\ x_{i-1} \\ x_i \\ x_{i+1} \\ \vdots \\ x_{worst} \end{bmatrix}_{N \times D} \quad (3.28)$$

Adım 2: Eşitlik (3.28) (P') kullanılarak her bir birey ($x_i, i = 1, 2, \dots, N$) için x_{i-1} (en yakın daha iyi) ve x_{i+1} (en yakın daha kötü) belirlenir. Bilgi paylaşımı, popülasyondan rastgele seçilen bir birey x_R ile yapılır.

Genç bilgi edinme-paylaşma aşamasının sözde-kodu Çizelge 3.16'da verilmiştir [115].

Çizelge 3.16. Genç bilgi edinme-paylaşma aşamasının sözde-kodu.

1.	Başla
2.	for i=1: N do
3.	for j=1: D do
4.	if rand $\leq k_r$ (bilgi oranı) then
5.	if $f(x_i) > f(x_R)$ then
6.	$x_{ij}^{new} = x_i + k_f [(x_{i-1} - x_{i+1}) + (x_R - x_i)]$
7.	else
8.	$x_{ij}^{new} = x_i + k_f [(x_{i-1} - x_{i+1}) + (x_i - x_R)]$
9.	end if
10.	else
11.	$x_{ij}^{new} = x_{ij}^{old}$
12.	end if
13.	end for
14.	end for
15.	Bitir

Kıdemli bilgi edinme-paylaşma aşamasında, bireyler geniş arkadaş ağlarından, sosyal medyadan ve kitaplardan bilgi edinme ve paylaşma konusunda üstün bir yeteneğe sahiptir. Bu aşama, en iyi ve en kötü olarak sınıflandırılan bireylerin diğer bireyler üzerindeki etkilerini inceler. Buna göre çözüm adayları aşağıdaki adımlar takip edilerek güncellenir [115].

Adım 1: İlk olarak, Eşitlik (3.8)'de verilen sıralama (P' -fitness değerine göre artan) dikkate alınarak popülasyon üç kategoriye ayrılır. Buna göre popülasyon en iyi bireyler (x_{pbest}), daha iyi/orta bireyler (x_m) ve en kötü bireyler (x_{pworst}) olmak üzere üç kategoriye ayrılır.

- x_{pbest} %100p
- x_m $N-(2 \times \%100p)$
- x_{pworst} %100p

Adım 2: Ardından, her bir birey için, kıdemli şema, bilgi kazanım kısmını oluşturmak için N boyutlu mevcut popülasyondaki en iyi (x_{pbest}) ve en kötü (x_{pworst}) birey kategorilerinden rastgele seçilmiş iki vektörü kullanır. Üçüncü vektör ise bilgi paylaşımı amacıyla daha iyi/orta bireyler kategorisinden (x_m) rastgele seçilir. En iyi ve en kötü kategorilerdeki bireylerin yüzdesi ($\%100p$) p parametresi ile belirlenir. Bu çalışmada p parametresinin nümerik değeri 0.1 olarak ayarlanmıştır. Buna göre $P'_{[Nx1]}$ vektöründeki çözüm adaylarının üstte kalan %10 çözüm adayı en iyi kategoride (x_{pbest}), altta kalan %10 çözüm adayı ise en kötü kategoride (x_{pworst}) yer alır. Diğer çözüm adayları ise daha iyi/orta bireyler kategorisinde (x_m) yer alır.

Kıdemli bilgi edinme-paylaşma aşamasının sözde kodu Çizelge 3.17'de verilmiştir [115].

Çizelge 3.17. Kıdemli bilgi edinme-paylaşma aşamasının sözde-kodu.

1.	Başla
2.	for i=1: N do
3.	for j=1: D do
4.	if rand $\leq k_r$ (bilgi oranı) then
5.	if $f(x_i) > f(x_m)$ then
6.	$x_{ij}^{new} = x_i + k_f [(x_{pbest} - x_{pworst}) + (x_m - x_i)]$
7.	else
8.	$x_{ij}^{new} = x_i + k_f [(x_{pbest} - x_{pworst}) + (x_i - x_m)]$
9.	end if
10.	else

Çizelge 3.17 (devam). Kıdemli bilgi edinme-paylaşma aşamasının sözde-kodu.

11.	$x_{ij}^{new} = x_{ij}^{old}$
12.	end if
13.	end for
14.	end for
15.	Bitir

- *Adaptif Prosedür*

AGSK algoritmasının arama performansı, sömürü ve keşif yeteneklerinin sergilendiği genç ve kıdemli bilgi edinme-paylaşma aşamalarının başarısı ile doğrudan ilişkilidir. Bilgi faktörü (k_f) ve bilgi oranı (k_r) parametreleri arama süreci yaşam döngüsünde genç ve kıdemli kazanma-paylaşma aşamalarını yönetmekten sorumludur. Etkili keşif ve dengeli arama performansı elde etmek için k_f ve k_r parametrelerinin arama sürecinin gereksinimlerini karşılayacak şekilde dinamik olarak ayarlanması gerekir [23]. Bu iki parametrenin dinamik ayarı için uygulanması gereken prosedür Çizelge 3.18’de verilmiştir [23].

Çizelge 3.18. Adaptif prosedür.

1.	Başla
2.	Parameter ayar havuzunu (k_f and k_r), ve olasılık parametresini Kw_P başlat
3.	while $FES < maxFES$
4.	if $FES > 0.1 * maxFES$ then
5.	Kw_P değerini güncelle (Eşitlik 3.31)
6.	end if
7.	Kw_P değerine göre her bireye bir ayar ata
8.	GSK algoritmasını kullanarak yeni bireyleri üret (x_i^{new})
9.	x_i^{new} ve FES güncelle
10.	Her ayar için iyileştirme oranını hesapla Δ_{ps}
11.	end while
12.	Bitir

Adaptif süreç parametre ayar havuzu ve bir olasılık parametresi Kw_P ile başlar. Parametre ayar havuzu $k_f = [0.1 \ 1 \ 0.5 \ 1]$ ve $k_r = [0.2 \ 0.1 \ 0.9 \ 0.9]$ vektörlerinden oluşur. Olasılık parametresi Kw_P ’nin uyarlanması, maksimum fitness fonksiyonu değerlendirme sayısının ($maxFES$) %10’undan sonra başlar [23].

$$w_{ps} = \sum_{i=1}^k f(x_i^{new}) - f(x_i^{old}) \quad (3.29)$$

Eşitlik (3.29)'da w_{ps} parametre ayarına ait her bir birey için eski ve yeni fitness değeri arasındaki farkların toplamını ifade eder. f fitness fonksiyonudur. x_i^{new} ve x_i^{old} sırasıyla yeni ve eski bireyler olarak tanımlanır. k parametre ayarına ait bireylerin sayısıdır.

Eşitlik (3.30) kullanılarak her parametre ayarı için iyileştirme oranı (Δ_{ps}) hesaplanır. Son olarak, her parametre ayarı için iyileştirme oranı kullanılarak (Δ_{ps}), Kw_P güncellenir [23].

$$\Delta_{ps} = \max(0.05, \frac{w_{ps}}{\sum(w_{ps})}) \quad (3.30)$$

$$Kw_P_{g+1} = (1 - c) Kw_P_g + c \Delta_{ps} \quad (3.31)$$

Eşitlik (3.31)'de kullanılan c parametresi öğrenme oranı temsil eder. AGSK'nın arama performansını iyileştirmek için popülasyon büyüklüğü her iterasyonda güncellenir. Popülasyon büyüklüğü Eşitlik (3.32) kullanılarak kademeli olarak azaltılır. Eşitlik (3.32)'de N_{g+1} sonraki iterasyon için popülasyon büyüklüğünü temsil eder. Popülasyon büyüklüğünün başlangıç değeri $popsiz_{init} = 40 * D$, minimum değeri $popsiz_{min} = 12$ olarak ayarlanmıştır [23].

$$N_{g+1} = \text{round} \left[\left(\frac{popsiz_{min} - popsiz_{init}}{\max FEs} \right) FEs + popsiz_{init} \right] \quad (3.32)$$

3.4.2.2. FDBAGSK Algoritması Tasarımı

Bu alt bölümde, önerilen FDBAGSK algoritmasının tasarımı sunulmuştur. Bu kapsamda ilk olarak FDB yöntemi uygulanarak tasarlanan FDBAGSK versiyonları tanıtılmıştır. Ardından önerilen yöntemin sözde kodu sunulmuştur.

AGSK algoritmasının güçlü yönü, arama uzayını etkili bir şekilde araştırmak için bilgi faktörü (k_f) ve bilgi oranı (k_r) parametrelerini dinamik olarak ayarlayabilmesidir. Fakat CEC 2017 ve CEC 2020 test takımlarındaki tek-modlu (unimodal), çok-modlu (multimodal), hibrit (hybrid) ve kompozisyon (compositon) tip problemler kullanılarak 30/50/100 boyutlu arama uzaylarında gerçekleştirilen deneysel çalışmalar AGSK algoritmasının erken yakınsadığını ve keşif-sömürü dengesini sağlamada yetersiz

olduğunu ortaya koymuştur. Algoritmanın zayıf keşif yeteneği, özellikle birçok yerel çözüm tuzağı içeren çok-modlu problemlerde erken yakınsamanın temel sebebidir. Ayrıca AGSK diğer problem tiplerine kıyasla daha yüksek karmaşıklığa sahip hibrit ve kompozisyon tip problemlerin çözümü içine gereken keşif ve sömürü dengesini sağlamak için yetersizdir. AGSK yönteminin bu eksiklikleri algoritmanın arama performansının geliştirilmesi konusunda bir çalışma yapmak için motivasyon kaynağı olmuştur. Bu amaca ulaşmak için AGSK algoritmasının seçim stratejisinde bir takım tasarım değişiklikleri gerçekleştirilmiştir. Algoritmanın arama performansını iyileştirmek amacıyla arama sürecine en fazla katkı sağlayacak rehber çözüm adaylarının popülasyonundan etkin bir şekilde seçilmesi önerilmiştir. Bu amaçla algoritmanın arama süreci yaşam döngüsüne FDB seçim yöntemi prosedürleri entegre edilmiştir.

FDB tabanlı rehber seçim mekanizması kullanılarak oluşturulan FDBAGSK versiyonlarının (Versiyon-1,...,Versiyon-5) tanımları ve matematiksel modelleri Çizelge 3.19'da verilmiştir. Buna göre Versiyon-1 ve Versiyon-2 olarak adlandırılan FDB tabanlı algoritmalar kademli bilgi edinme-paylaşma aşamasında rehber çözüm adaylarının seçimi için FDB yöntemi kullanılarak tasarlanmıştır. Daha açık bir ifadeyle Versiyon-1 Çizelge 3.17'de (Satır 6 ve 8) verilen çözüm adayı güncelleme denklemlerinde x_m çözüm adayının yerine FDB ile seçilen çözüm adayının (x_{FDB}) kullanılması prensibine dayanır. Versiyon-2 ise aynı denklemlerdeki x_{pworst} çözüm adayının yerine FDB yöntemi ile seçilen x_{FDB} çözüm adayı kullanılarak tasarlanmıştır. Versiyon-3, Versiyon-4 ve Versiyon-5, FDB yönteminin AGSK algoritmasının genç bilgi edinme-paylaşma aşamasına uygulandığı FDB tabanlı algoritmalarıdır. Bu üç varyantta Çizelge 3.16'da (Satır 6 ve 8) verilen çözüm adayı güncelleme denklemleri FDB tabanlı seçim yöntemleri kullanılarak revize edilmiştir. Buna göre Versiyon-3, referans çözüm adayı x_{i+1} yerine x_{RFDB} , x_R yerine ise x_{FDB} kullanılarak tasarlanmıştır. Versiyon-4 için FDB tabanlı yöntemlerle iki farklı çözüm adayının seçilmesi önerilmiştir. Bu versiyonda x_{i-1} çözüm adayı rulet FDB yöntemi x_{RFDB} ile seçilirken, x_R çözüm adayı FDB yöntemi x_{FDB} ile belirlenmiştir. FDB tabanlı Versiyon-5, aynı denklemlerde x_R rehber çözüm adayı yerine arama sürecine en fazla katkı sağlayacak x_{FDB} çözüm adayı kullanılarak geliştirilmiştir.

FBAGSK versiyonlarında kullanılan x_{FDB} and x_{RFDB} , Eşitlik (3.8)'de verilen FDB skor vektöründen sırasıyla açgözlü (yani en yüksek FDB puanına sahip çözüm adayları) ve rulet seçim yöntemi ile seçilen referans çözüm adaylarını temsil eder. FDB varyantlarının tasarımı Çizelge 3.19'da ayrıntılı olarak açıklanmıştır. Önerilen FDBAGSK

algoritmasının sözde-kodu Çizelge 3.20’de verilmiştir.

Çizelge 3.19. Önerilen FDBAGSK versiyonlarının matematiksel modeli.

Algoritma	FDB tabanlı AGSK versiyonları (önerilen)
Versiyon-1	Çizelge 3.17-Satır 6 ve 8’de verilen çözüm adayı güncelleme denklemlerinde, x_m yerine FDB yöntemi ile seçilen çözüm adayı (x_{FDB}) kullanılmıştır.
	$x_{ij}^{new} = x_i + k_f [(x_{pbest} - x_{pworst}) + (x_{FDB} - x_i)] \quad (3.33)$
	$x_{ij}^{new} = x_i + k_f [(x_{pbest} - x_{pworst}) + (x_i - x_{FDB})] \quad (3.34)$
Versiyon-2	Çizelge 3.17-Satır 6 ve 8’de verilen çözüm adayı güncelleme denklemlerinde, x_{pworst} yerine FDB yöntemi ile seçilen çözüm adayı (x_{FDB}) kullanılmıştır.
	$x_{ij}^{new} = x_i + k_f [(x_{pbest} - x_{FDB}) + (x_{FDB} - x_i)] \quad (3.35)$
	$x_{ij}^{new} = x_i + k_f [(x_{pbest} - x_{FDB}) + (x_i - x_{FDB})] \quad (3.36)$
Versiyon-3	Çizelge 3.16-Satır 6 ve 8’de verilen çözüm adayı güncelleme denklemlerinde, x_{i+1} yerine rulet FDB yöntemi ile seçilen çözüm adayı (x_{RFDB}), x_R yerine ise FDB yöntemi ile seçilen çözüm adayı (x_{FDB}) kullanılmıştır.
	$x_{ij}^{new} = x_i + k_f [(x_{i-1} - x_{RFDB}) + (x_{FDB} - x_i)] \quad (3.37)$
	$x_{ij}^{new} = x_i + k_f [(x_{i-1} - x_{RFDB}) + (x_i - x_{FDB})] \quad (3.38)$
Versiyon-4	Çizelge 3.16-Satır 6 ve 8’de verilen kullanılan çözüm adayı güncelleme denklemlerinde, x_{i-1} yerine rulet FDB yöntemi ile seçilen çözüm adayı (x_{RFDB}), x_R yerine ise FDB yöntemi ile seçilen çözüm adayı (x_{FDB}) kullanılmıştır.
	$x_{ij}^{new} = x_i + k_f [(x_{RFDB} - x_{i+1}) + (x_{FDB} - x_i)] \quad (3.39)$
	$x_{ij}^{new} = x_i + k_f [(x_{RFDB} - x_{i+1}) + (x_i - x_{FDB})] \quad (3.40)$
Versiyon-5	Çizelge 3.16-Satır 6 ve 8’de verilen çözüm adayı güncelleme denklemlerinde, x_R yerine FDB yöntemi ile seçilen çözüm adayı (x_{FDB}) kullanılmıştır.
	$x_{ij}^{new} = x_i + k_f [(x_{i-1} - x_{i+1}) + (x_{FDB} - x_i)] \quad (3.41)$
	$x_{ij}^{new} = x_i + k_f [(x_{i-1} - x_{i+1}) + (x_i - x_{FDB})] \quad (3.42)$

Çizelge 3.20. Önerilen FDBAGSK algoritmasının sözde-kodu.

1.	Başla
2.	Başlangıç parametrelerini tanımla ($N, D, maxFES, k_f, k_r, K, p, Kw_P$)
3.	Rastgele bir başlangıç popülasyonu (P) oluştur (Eşitlik 3.2)
4.	for $i=1: N$
5.	Her bir çözüm adayının fitness değerini hesapla ve f vektörünü oluştur (Eşitlik 3.3)
6.	end
7.	while $FES < maxFES$ do
8.	if $FES > 0,1 * maxFES$ then
9.	Adaptif prosedür (Çizelge 3.18)
10.	end if

Çizelge 3.20. (devam) Önerilen FDBAGSK algoritmasının sözde-kodu.

11.	Eşitlik (3.27)'de verilen deneyim denklemini kullanarak genç ve kıdemli bilgi edinme paylaşma boyutlarını hesapla
12.	<i>// Seçim Süreci //</i>
13.	Popülasyondan referans çözüm adaylarını seç ($x_{i-1}, x_{i+1}, x_R, x_{pbest}, x_m, x_{pworst}$)
14.	<i>FDB seçim yöntemi</i>
15.	for $i=1: N$ do
16.	x_i ve x_{best} arasındaki Öklid mesafesini hesapla (Eşitlik 3.5)
17.	Her bir çözüm adayı (x_i) için FDB skor değeri hesapla (Eşitlik 3.7)
18.	end for
19.	Eşitlik (3.8)'de verilen FDB skor vektörünü (S_p) kullanarak x_{FDB} ve x_{RFDB} çözüm adaylarını seç
20.	<i>// Arama Süreci -Sömürü ve Keşif//</i>
21.	<i>//Genç bilgi edinme-paylaşma aşaması //</i>
22.	for $i=1: N$ do
23.	for $j=1: D$ do
24.	if $\text{rand} \leq k_r$ (bilgi oranı) then
25.	<i>//Versiyon-3//</i>
26.	if $f(x_i) > f(x_r)$ then
27.	$x_{ij}^{new} = x_i + k_f [(x_{i-1} - x_{RFDB}) + (x_{FDB} - x_i)]$ <i>//Eşitlik. (3.37) //</i>
28.	else
29.	$x_{ij}^{new} = x_i + k_f [(x_{i-1} - x_{RFDB}) + (x_i - x_{FDB})]$ <i>//Eşitlik (3.38) //</i>
30.	end if
31.	<i>//Versiyon-4//</i>
32.	if $f(x_i) > f(x_r)$ then
33.	$x_{ij}^{new} = x_i + k_f [(x_{RFDB} - x_{i+1}) + (x_{FDB} - x_i)]$ <i>//Eşitlik (3.39) //</i>
34.	else
35.	$x_{ij}^{new} = x_i + k_f [(x_{RFDB} - x_{i+1}) + (x_i - x_{FDB})]$ <i>//Eşitlik. (3.40) //</i>
36.	end if
37.	<i>//Versiyon-5//</i>
38.	if $f(x_i) > f(x_r)$ then
39.	$x_{ij}^{new} = x_i + k_f [(x_{i-1} - x_{i+1}) + (x_{FDB} - x_i)]$ <i>//Eşitlik. (3.41) //</i>
40.	else
41.	$x_{ij}^{new} = x_i + k_f [(x_{i-1} - x_{i+1}) + (x_i - x_{FDB})]$ <i>//Eşitlik (3.42) //</i>
42.	end if
43.	else
44.	$x_{ij}^{new} = x_{ij}^{old}$
45.	end if

Çizelge 3.20. (devam) Önerilen FDBAGSK algoritmasının sözde-kodu.

46.	end for
47.	end for
48.	<i>//Kıdemli bilgi edinme-paylaşma aşaması //</i>
49.	for i=1: N do
50.	for j=1: D do
51.	if rand $\leq k_r$ (bilgi oranı) then
52.	<i>//Versiyon-1//</i>
53.	if $f(x_i) > f(x_m)$ then
54.	$x_{ij}^{new} = x_i + k_f [(x_{pbest} - x_{pworst}) + (x_{FDB} - x_i)]$ <i>//Eşitlik.</i> (3.33) <i>//</i>
55.	else
56.	$x_{ij}^{new} = x_i + k_f [(x_{pbest} - x_{pworst}) + (x_i - x_{FDB})]$ <i>//Eşitlik.</i> (3.34) <i>//</i>
57.	end if
58.	<i>//Versiyon-2//</i>
59.	if $f(x_i) > f(x_m)$ then
60.	$x_{ij}^{new} = x_i + k_f [(x_{pbest} - x_{FDB}) + (x_{FDB} - x_i)]$ <i>//Eşitlik</i> (3.35) <i>//</i>
61.	else
62.	$x_{ij}^{new} = x_i + k_f [(x_{pbest} - x_{FDB}) + (x_i - x_{FDB})]$ <i>//Eşitlik</i> (3.36) <i>//</i>
63.	end if
64.	else
65.	$x_{ij}^{new} = x_{ij}^{old}$
66.	end if
67.	end for
68.	end for
69.	<i>// Güncelleme Süreci //</i>
70.	if $f(x_i^{new}) \leq f(x_i^{old})$ then
71.	$x_i^{old} = x_i^{new}, f(x_i^{old}) = f(x_i^{new})$
72.	end if
73.	if $f(x_i^{new}) \leq f(x_{best}^g)$ then
74.	$x_{best}^g = x_i^{new}, f(x_{best}^g) = f(x_i^{new})$
75.	end if
76.	end while
77.	En iyi çözüm: x_{best}
78.	Bitir

3.4.2.3. FDBAGSK Algoritmasının CEC 2017 ve CEC 2020 Benchmark Problemlerinde Test Edilmesi

Bu alt bölüm, CEC 2017 ve CEC 2020 test problemleri kullanılarak gerçekleştirilen baz AGSK ve FDBAGSK versiyonlarının karşılaştırmalı analizini sunar. Bu kapsamda sırasıyla istatistiksel analiz, yakınsama analizi ve algoritma karmaşıklığı analizi gerçekleştirilmiştir.

- *İstatistiksel Analiz*

Bu alt bölümde, FDBAGSK algoritmasının FDB tabanlı versiyonlarının performansları incelenmiştir. Bu amaçla, *Bölüm 3.4.2.2*'de tanıtilan FDBAGSK algoritmasının beş farklı varyasyonu kullanılmış ve bu bölümde Versiyon-1, Versiyon-2, Versiyon-3, Versiyon-4 ve Versiyon-5 olarak adlandırılmıştır. FDBAGSK algoritmasının versiyonları hakkında ayrıntılı bilgi için "*Bölüm 3.4.2.2. Önerilen FDBAGSK Algoritması*" gözden geçirilmelidir. Buna göre, AGSK algoritmasının altı farklı versiyonunun (baz AGSK ve FDB tabanlı AGSK) arama performansı karşılaştırılmıştır. Deneysel çalışmalardan toplam $6 \times 39 \times 51 \times 3 = 35.802$ (rekabetçi algoritma sayısı, test problemi sayısı, her bir test problemi için bağımsız çalışma sayısı, arama uzayı boyutu sayısı) veri elde edilmiştir. Bu veriler, en iyi varyasyonu belirlemek için Friedman testi ile analiz edilmiştir.

FDBAGSK versiyonları ve AGSK için Friedman testi ile elde edilen sıralalar Çizelge 3.21'de verilmiştir. CEC 2017 ve CEC 2020 test takımları için 30, 50 ve 100 boyutlu arama uzaylarında toplam altı deneysel çalışma gerçekleştirilmiştir. Her bir deneysel çalışma için algoritmaların elde ettiği en iyi puan Çizelge 3.21'de koyu ve gri gölgeli olarak vurgulanmıştır. Rekabetçi algoritmaların Friedman sıralaması, tüm deneylerin ortalamasını dikkate alan ve Çizelge 3.21'in son sütununda verilen "*Ortalama Sıra*" indeksine göre belirlenmiştir. İlgili çizelge detaylı olarak incelendiğinde FDB tabanlı *Versiyon-1* algoritmasının en iyi arama performansına sahip olduğu görülmektedir.

Çizelge 3.21. FDBAGSK versiyonları ve AGSK için Friedman testi ile elde edilen sıralar.

Algoritma	Boyut=30		Boyut=50		Boyut=100		Ortalama Sıra
	CEC 2017	CEC 2020	CEC 2017	CEC 2020	CEC 2017	CEC 2020	
Versiyon-1	2,87	2,93	2,73	2,71	2,98	2,78	2,83
Versiyon-2	3,45	3,35	3,41	3,12	3,32	2,94	3,26
Versiyon-3	3,35	3,35	3,44	3,59	3,40	3,54	3,44
Versiyon-4	3,35	3,34	3,54	3,77	3,44	3,73	3,52
Versiyon-5	3,70	3,62	3,72	3,53	3,51	3,70	3,63
AGSK	4,25	4,37	4,13	4,25	4,33	4,28	4,26

AGSK ve FDBAGSK versiyonları arasında Wilcoxon ikili karşılaştırma sonuçları Çizelge 3.22’de verilmiştir. Çizelge 3.22’de FBD tabanlı algoritmaların baz algoritmaya üstünlük kurduğu deneyler koyu renk ile vurgulanmıştır.

Çizelge 3.22. AGSK ve FDBAGSK versiyonları arasında Wilcoxon ikili karşılaştırma sonuçları.

vs. AGSK +/-/-	Boyut=30		Boyut=50		Boyut=100	
	CEC 2017	CEC 2020	CEC 2017	CEC 2020	CEC 2017	CEC 2020
Versiyon-1	20/9/0	8/2/0	17/11/1	8/2/0	18/5/6	7/2/1
Versiyon-2	15/11/3	5/5/0	13/14/2	6/4/0	21/6/2	8/2/0
Versiyon-3	15/14/0	6/4/0	14/14/1	3/7/0	15/13/1	4/5/1
Versiyon-4	20/8/1	5/5/0	12/15/2	3/7/0	19/9/1	5/4/1
Versiyon-5	15/12/2	5/5/0	12/15/2	5/4/1	15/12/2	3/6/1

Çizelge 3.22’de verilen nümerik veriler detaylı olarak analiz edildiğinde CEC 2017 test takımının düşük (Boyut=30) boyutlu arama uzayında gerçekleştirilen deneyde FBD tabanlı Versiyon-1 (20/9/0) ve Versiyon-4 (20/8/1) algoritmalarının oldukça yakın bir arama performansı sergilediği görülmektedir. Aynı test takımındaki 50 boyutlu arama uzayında gerçekleştirilen deneysel çalışmada Versiyon-1 (17/11/1), 100 boyutlu deneyde ise Versiyon-2 (21/6/2) yöntemlerinin arama performansı rakiplerinden daha iyidir. CEC 2020 test takımındaki Boyut=30 ve Boyut=50 için gerçekleştirilen deneylerde Versiyon-1 (8/2/0), Boyut=100 isimli deneyde ise Versiyon-2 (8/2/0) rakiplerine kıyasla üstün bir

performans sergilemiştir. Wilxocon test sonuçlarından FDB tabanlı versiyonların tüm deneylerde AGSK algoritmasına ezici üstünlük sağladığı gözlemlenmiştir.

Çizelge 3.23, AGSK ve FDBAGSK versiyonlarının sömürü, keşif ve dengeli arama performanslarını ayrıntılı olarak analiz etmek için hazırlanmıştır. İlgili çizelge, dört farklı problem tipi için rekabetçi algoritmaların Friedman test sonuçlarını özetler. Buna göre, her deney için elde edilen en iyi sonuç koyu renkle işaretlenmiştir. CEC 2017 (12) ve CEC 2020 (12) kıyaslama takımlarındaki deneysel çalışmaların (24 adet) sonuçları Çizelge 3.23'te sunulmuştur.

Çizelge 3.23. Farklı problem tipleri için AGSK ve FDBAGSK versiyonlarının Friedman sıraları.

	Problem Tipi		AGSK	Versiyon-1	Versiyon-2	Versiyon-3	Versiyon-4	Versiyon-5
CEC 2017	Tek-modlu	Boyut=30	4,06	3,25	3,06	3,48	3,59	3,56
		Boyut=50	4,28	3,32	3,48	3,19	3,48	3,25
		Boyut=100	4,71	2,87	3,50	3,18	3,73	3,00
	Çok-modlu	Boyut=30	4,41	2,20	3,39	3,29	3,72	3,98
		Boyut=50	4,48	2,09	3,32	3,38	3,73	4,00
		Boyut=100	4,48	2,06	3,35	3,41	3,76	3,94
	Hibrit	Boyut=30	4,12	3,08	3,48	3,30	3,24	3,78
		Boyut=50	3,92	3,09	3,43	3,50	3,44	3,62
		Boyut=100	4,25	3,05	3,12	3,55	3,31	3,73
	Kompozisyon	Boyut=30	4,15	3,01	3,60	3,49	3,24	3,52
		Boyut=50	4,03	2,64	3,42	3,52	3,59	3,80
		Boyut=100	4,16	3,45	3,46	3,35	3,35	3,23
CEC 2020	Tek-modlu	Boyut=30	5,51	4,45	2,18	2,86	2,57	3,43
		Boyut=50	5,90	4,20	3,67	2,45	2,71	2,08
		Boyut=100	5,86	4,12	4,06	2,06	3,43	1,47
	Çok-modlu	Boyut=30	4,10	2,61	2,66	3,59	3,80	4,24
		Boyut=50	4,10	2,49	2,42	3,71	4,20	4,07
		Boyut=100	3,96	2,58	2,14	4,14	3,98	4,20
	Hibrit	Boyut=30	4,06	2,63	3,82	3,46	3,52	3,52
		Boyut=50	4,12	2,16	3,41	3,87	3,84	3,59
		Boyut=100	4,36	1,20	3,17	3,83	3,96	4,48

Çizelge 3.23. (devam) Farklı problem tipleri için AGSK ve FDBAGSK versiyonlarının Friedman sıraları.

		Boyut=30	4,59	3,08	3,99	3,20	2,97	3,16
	Kompozisyon	Boyut=50	4,00	3,01	3,35	3,59	3,63	3,42
		Boyut=100	4,01	4,12	3,17	3,16	3,36	3,18

Çizelge 3.23'te verilen Friedman testi sonuçlarından FDBAGSK versiyonlarının deneylerin tamamında temel AGSK algoritmasından daha iyi bir sıralama elde ettiği görülmektedir. AGSK algoritmasının dört farklı problem türünde de rakiplerine kıyasla daha kötü bir arama performansı sergilemesi, algoritmanın erken yakınsama problemi olduğunu gösterir. Bu problemin nedeni, AGSK algoritmasının arama süreci yaşam döngüsünde doğadaki süreci etkin bir şekilde taklit edememesi ile ilişkilendirilebilir. Bu sorunu ortadan kaldırmak için meta-sezgisel algoritmaların doğa ile daha uyumlu bir şekilde tasarımına olanak sağlayan FDB seçim yöntemi kullanılmıştır. Sonuç olarak, FDB seçim yöntemi uygulanarak tasarlanan FDBAGSK versiyonlarının baz algoritmaya kıyasla üstün bir arama performansı elde ettiği gözlemlenmiştir.

Çizelge 3.24, 30/50/100 boyutlu arama uzaylarında CEC 2017 test problemleri için elde edilen hata istatistiklerini göstermektedir. İlgili çizelgede her hücre sırasıyla ortalama ve standart sapma değerlerini içerir. Her bir test fonksiyonu için ilgili boyutta elde edilen en iyi değer koyu renkle işaretlenmiştir. Ayrıca algoritmaların arama performansının görsel olarak gözlemlenebilmesi adına box-plot grafikleri çizdirilmiştir. Box-plot grafikleri, 51 bağımsız çalışma için algoritmalar tarafından elde edilen minimum, maksimum ve ortalama/standart sapma hata değerlerini gösterir. CEC 2017 ve CEC 2020 test takımlarından seçilen tek-modlu, çok-modlu, hibrit ve kompozisyon tip test problemleri için box-plot grafikleri sırasıyla Çizelge 3.9 ve 3.10'da gösterilmiştir.

Çizelge 3.24. CEC 2017 test problemleri için elde edilen ortalama ve standart sapma değerleri.

F	Boyut	AGSK	Versiyon-1	Versiyon-2	Versiyon-3	Versiyon-4	Versiyon-5
F1	30	2,17E+05 (2,21E+05)	1,37E+05 (1,44E+05)	2,90E+04 (3,32E+04)	6,65E+04 (1,86E+05)	4,22E+04 (8,43E+04)	7,01E+04 (1,23E+05)
	50	4,96E+06 (3,57E+06)	1,19E+06 (9,45E+05)	1,21E+06 (1,73E+06)	4,29E+05 (4,38E+05)	4,85E+05 (3,99E+05)	3,73E+05 (3,53E+05)
	100	1,29E+08 (5,89E+07)	3,79E+07 (2,18E+07)	2,58E+07 (1,16E+07)	1,77E+07 (1,08E+07)	3,17E+07 (2,47E+07)	1,28E+07 (1,20E+07)
F3	30	8,56E+04 (1,92E+04)	6,72E+04 (1,52E+04)	6,93E+04 (1,47E+04)	7,81E+04 (1,62E+04)	7,83E+04 (1,60E+04)	7,58E+04 (1,93E+04)
	50	1,86E+05 (3,26E+04)	1,79E+05 (2,83E+04)	1,89E+05 (3,05E+04)	1,89E+05 (3,30E+04)	1,89E+05 (2,81E+04)	1,84E+05 (3,21E+04)
	100	5,38E+05 (7,17E+04)	4,93E+05 (6,93E+04)	5,10E+05 (7,32E+04)	5,06E+05 (4,99E+04)	5,04E+05 (5,70E+04)	4,95E+05 (5,90E+04)
F4	30	9,50E+01 (1,06E+01)	9,47E+01 (8,60E+00)	1,07E+02 (1,29E+01)	9,87E+01 (1,24E+01)	1,02E+02 (1,42E+01)	9,82E+01 (1,41E+01)
	50	2,08E+02 (2,75E+01)	2,00E+02 (3,54E+01)	2,00E+02 (3,36E+01)	1,89E+02 (3,37E+01)	1,94E+02 (3,77E+01)	1,93E+02 (3,16E+01)
	100	4,17E+02 (4,20E+01)	3,52E+02 (5,49E+01)	4,02E+02 (3,60E+01)	3,79E+02 (4,96E+01)	3,98E+02 (4,30E+01)	3,65E+02 (4,39E+01)
F5	30	1,49E+02 (1,46E+01)	1,16E+02 (1,20E+01)	1,40E+02 (1,39E+01)	1,37E+02 (1,36E+01)	1,41E+02 (1,61E+01)	1,44E+02 (1,38E+01)
	50	3,25E+02 (1,95E+01)	2,59E+02 (2,01E+01)	3,04E+02 (1,69E+01)	3,12E+02 (1,74E+01)	3,14E+02 (1,72E+01)	3,20E+02 (1,38E+01)
	100	7,82E+02 (2,31E+01)	6,62E+02 (3,46E+01)	7,51E+02 (2,20E+01)	7,67E+02 (3,32E+01)	7,73E+02 (2,53E+01)	7,92E+02 (2,29E+01)
F6	30	1,96E+01 (4,55E+00)	2,26E+00 (1,34E+00)	1,53E+01 (4,64E+00)	1,27E+01 (4,03E+00)	1,50E+01 (3,33E+00)	1,60E+01 (3,51E+00)
	50	2,33E+01 (4,66E+00)	2,54E+00 (1,01E+00)	1,75E+01 (4,91E+00)	1,33E+01 (7,00E+00)	1,84E+01 (5,80E+00)	1,89E+01 (5,21E+00)
	100	2,85E+01 (8,57E+00)	5,53E+00 (1,69E+00)	1,57E+01 (4,84E+00)	1,08E+01 (3,88E+00)	1,67E+01 (6,36E+00)	1,75E+01 (6,09E+00)
F7	30	1,80E+02 (1,50E+01)	1,65E+02 (2,37E+01)	1,54E+02 (1,46E+01)	1,75E+02 (1,21E+01)	1,77E+02 (1,25E+01)	1,83E+02 (1,14E+01)
	50	3,61E+02 (2,23E+01)	3,24E+02 (2,28E+01)	3,18E+02 (2,44E+01)	3,64E+02 (1,89E+01)	3,61E+02 (1,54E+01)	3,72E+02 (1,81E+01)
	100	8,48E+02 (3,37E+01)	8,13E+02 (2,98E+01)	7,73E+02 (2,64E+01)	8,72E+02 (3,15E+01)	8,75E+02 (2,91E+01)	8,93E+02 (2,96E+01)
F8	30	1,59E+02 (1,23E+01)	1,21E+02 (1,10E+01)	1,50E+02 (1,78E+01)	1,47E+02 (1,41E+01)	1,47E+02 (1,28E+01)	1,51E+02 (1,10E+01)
	50	3,22E+02 (2,12E+01)	2,59E+02 (1,82E+01)	3,01E+02 (1,82E+01)	3,09E+02 (1,99E+01)	3,10E+02 (1,81E+01)	3,20E+02 (1,52E+01)
	100	7,78E+02 (2,83E+01)	6,73E+02 (3,21E+01)	7,46E+02 (2,89E+01)	7,69E+02 (3,88E+01)	7,64E+02 (3,01E+01)	7,87E+02 (2,90E+01)
F9	30	4,33E+02 (2,59E+02)	8,44E+01 (6,98E+01)	1,48E+02 (9,81E+01)	1,83E+02 (1,39E+02)	1,92E+02 (1,48E+02)	2,41E+02 (1,85E+02)
	50	8,80E+02 (4,73E+02)	2,31E+02 (1,72E+02)	5,97E+02 (2,75E+02)	3,21E+02 (1,71E+02)	3,97E+02 (2,26E+02)	3,88E+02 (2,03E+02)
	100	2,30E+03 (6,88E+02)	1,40E+03 (5,72E+02)	2,05E+03 (6,13E+02)	1,06E+03 (5,40E+02)	1,30E+03 (5,74E+02)	1,14E+03 (4,82E+02)

Çizelge 3.24. (devam) CEC 2017 test problemleri için elde edilen ortalama ve standart sapma değerleri.

F10	30	5,58E+03 (2,59E+02)	5,57E+03 (2,64E+02)	5,49E+03 (3,49E+02)	5,49E+03 (3,02E+02)	5,57E+03 (2,75E+02)	5,58E+03 (2,29E+02)
	50	1,11E+04 (3,79E+02)	1,11E+04 (3,61E+02)	1,10E+04 (4,25E+02)	1,10E+04 (3,19E+02)	1,10E+04 (4,02E+02)	1,10E+04 (4,57E+02)
	100	2,75E+04 (5,89E+02)	2,74E+04 (7,04E+02)	2,76E+04 (6,88E+02)	2,75E+04 (5,93E+02)	2,75E+04 (5,26E+02)	2,74E+04 (5,34E+02)
F11	30	1,29E+02 (2,93E+01)	1,42E+02 (4,10E+01)	1,16E+02 (3,29E+01)	1,26E+02 (2,60E+01)	1,18E+02 (2,22E+01)	1,25E+02 (2,38E+01)
	50	2,50E+02 (6,70E+01)	2,58E+02 (6,16E+01)	2,06E+02 (4,10E+01)	2,44E+02 (6,11E+01)	2,63E+02 (5,59E+01)	2,55E+02 (5,31E+01)
	100	1,70E+04 (7,59E+03)	4,80E+03 (1,65E+03)	8,04E+03 (2,64E+03)	1,58E+04 (7,36E+03)	1,60E+04 (7,71E+03)	1,68E+04 (5,88E+03)
F12	30	4,66E+05 (3,64E+05)	8,17E+05 (9,67E+05)	4,78E+05 (3,57E+05)	5,50E+05 (5,54E+05)	5,33E+05 (3,82E+05)	6,88E+05 (5,19E+05)
	50	3,59E+06 (1,60E+06)	4,03E+06 (3,37E+06)	3,53E+06 (1,69E+06)	3,06E+06 (1,66E+06)	3,12E+06 (1,57E+06)	2,94E+06 (1,49E+06)
	100	3,13E+07 (1,32E+07)	3,28E+07 (1,85E+07)	2,59E+07 (8,82E+06)	2,68E+07 (1,19E+07)	2,68E+07 (1,28E+07)	2,51E+07 (1,22E+07)
F13	30	1,83E+04 (1,47E+04)	1,32E+04 (1,20E+04)	1,80E+04 (1,03E+04)	1,48E+04 (1,05E+04)	1,71E+04 (1,09E+04)	1,86E+04 (1,39E+04)
	50	2,27E+04 (2,14E+04)	3,70E+04 (2,47E+04)	9,59E+03 (5,45E+03)	2,41E+04 (1,60E+04)	1,93E+04 (1,22E+04)	2,50E+04 (1,35E+04)
	100	1,06E+04 (2,98E+03)	2,61E+04 (1,60E+04)	1,06E+04 (2,32E+03)	8,36E+03 (3,67E+03)	6,82E+03 (2,80E+03)	9,15E+03 (4,45E+03)
F14	30	1,62E+02 (3,55E+01)	1,54E+02 (4,25E+01)	1,45E+02 (3,75E+01)	1,45E+02 (3,87E+01)	1,45E+02 (4,19E+01)	1,44E+02 (3,16E+01)
	50	1,77E+03 (2,20E+03)	3,56E+03 (6,80E+03)	1,85E+03 (2,16E+03)	1,41E+03 (1,04E+03)	1,62E+03 (2,93E+03)	1,88E+03 (3,20E+03)
	100	4,36E+05 (2,87E+05)	1,56E+05 (1,02E+05)	2,72E+05 (1,27E+05)	2,93E+05 (1,23E+05)	3,58E+05 (2,00E+05)	3,07E+05 (1,80E+05)
F15	30	9,17E+02 (6,29E+02)	7,20E+02 (7,53E+02)	8,39E+02 (7,16E+02)	5,01E+02 (2,12E+02)	5,29E+02 (2,25E+02)	6,73E+02 (4,64E+02)
	50	9,35E+03 (6,69E+03)	1,09E+04 (8,13E+03)	7,68E+03 (5,53E+03)	6,30E+03 (5,13E+03)	5,28E+03 (4,44E+03)	6,02E+03 (4,63E+03)
	100	7,11E+03 (4,87E+03)	1,93E+04 (1,17E+04)	2,65E+03 (1,68E+03)	6,78E+03 (6,67E+03)	4,40E+03 (4,81E+03)	8,40E+03 (5,80E+03)
F16	30	1,16E+03 (1,55E+02)	9,94E+02 (1,07E+02)	1,12E+03 (1,68E+02)	1,09E+03 (1,13E+02)	1,08E+03 (1,23E+02)	1,12E+03 (1,27E+02)
	50	2,29E+03 (1,93E+02)	1,83E+03 (2,07E+02)	2,22E+03 (2,24E+02)	2,11E+03 (1,98E+02)	2,08E+03 (2,07E+02)	2,16E+03 (1,98E+02)
	100	6,62E+03 (2,39E+02)	5,64E+03 (3,57E+02)	6,50E+03 (3,60E+02)	6,40E+03 (3,16E+02)	6,35E+03 (3,40E+02)	6,45E+03 (2,97E+02)
F17	30	3,75E+02 (8,24E+01)	3,03E+02 (7,33E+01)	3,62E+02 (7,02E+01)	3,49E+02 (6,73E+01)	3,27E+02 (7,54E+01)	3,44E+02 (7,34E+01)
	50	1,55E+03 (1,49E+02)	1,35E+03 (1,67E+02)	1,48E+03 (2,30E+02)	1,49E+03 (1,36E+02)	1,44E+03 (1,64E+02)	1,45E+03 (1,73E+02)
	100	4,04E+03 (1,92E+02)	3,56E+03 (2,54E+02)	3,89E+03 (2,89E+02)	3,97E+03 (2,53E+02)	3,98E+03 (2,65E+02)	4,05E+03 (2,06E+02)


Çizelge 3.24. (devam) CEC 2017 test problemleri için elde edilen ortalama ve standart sapma değerleri.

F18	30	9,97E+04 (4,40E+04)	4,64E+04 (2,92E+04)	6,45E+04 (3,74E+04)	6,91E+04 (3,78E+04)	6,79E+04 (6,01E+04)	7,97E+04 (3,62E+04)
	50	4,47E+05 (2,97E+05)	1,27E+05 (6,86E+04)	3,11E+05 (3,73E+05)	4,42E+05 (2,85E+05)	3,76E+05 (2,34E+05)	4,33E+05 (2,24E+05)
	100	3,41E+06 (1,24E+06)	8,61E+05 (3,37E+05)	2,41E+06 (1,02E+06)	3,19E+06 (9,63E+05)	3,21E+06 (1,10E+06)	3,18E+06 (9,83E+05)
F19	30	5,19E+02 (9,81E+02)	2,47E+02 (2,98E+02)	7,05E+02 (1,63E+03)	2,40E+02 (4,30E+02)	2,83E+02 (5,23E+02)	5,21E+02 (6,43E+02)
	50	3,39E+03 (4,24E+03)	3,35E+03 (4,97E+03)	6,36E+03 (6,00E+03)	5,49E+03 (5,34E+03)	6,42E+03 (6,62E+03)	5,57E+03 (6,01E+03)
	100	4,67E+03 (4,22E+03)	2,41E+04 (3,08E+04)	1,90E+03 (2,17E+03)	4,33E+03 (5,17E+03)	3,01E+03 (3,49E+03)	7,51E+03 (1,48E+04)
F20	30	4,65E+02 (5,85E+01)	4,00E+02 (7,18E+01)	4,02E+02 (1,01E+02)	4,38E+02 (7,21E+01)	4,32E+02 (6,88E+01)	4,40E+02 (5,63E+01)
	50	1,30E+03 (1,12E+02)	1,15E+03 (1,20E+02)	1,24E+03 (1,89E+02)	1,19E+03 (1,42E+02)	1,18E+03 (1,28E+02)	1,20E+03 (1,55E+02)
	100	4,22E+03 (2,06E+02)	3,98E+03 (2,23E+02)	4,09E+03 (2,70E+02)	4,07E+03 (1,88E+02)	4,08E+03 (1,73E+02)	4,13E+03 (2,44E+02)
F21	30	3,43E+02 (1,28E+01)	3,16E+02 (1,30E+01)	3,37E+02 (1,29E+01)	3,33E+02 (1,17E+01)	3,34E+02 (1,49E+01)	3,39E+02 (1,20E+01)
	50	5,15E+02 (1,72E+01)	4,55E+02 (1,33E+01)	4,97E+02 (1,94E+01)	4,99E+02 (1,93E+01)	4,97E+02 (2,08E+01)	5,07E+02 (1,65E+01)
	100	9,91E+02 (3,04E+01)	8,98E+02 (3,20E+01)	9,49E+02 (2,82E+01)	9,78E+02 (2,72E+01)	9,74E+02 (2,84E+01)	9,83E+02 (2,92E+01)
F22	30	2,62E+02 (2,78E+02)	1,58E+02 (4,79E+01)	2,04E+02 (1,14E+02)	1,36E+02 (3,96E+01)	1,27E+02 (3,29E+01)	1,66E+02 (2,66E+02)
	50	1,14E+04 (1,46E+03)	1,12E+04 (1,70E+03)	1,12E+04 (1,42E+03)	1,14E+04 (5,43E+02)	1,12E+04 (1,07E+03)	1,06E+04 (2,88E+03)
	100	2,86E+04 (5,21E+02)	2,87E+04 (7,35E+02)	2,87E+04 (5,00E+02)	2,86E+04 (7,04E+02)	2,86E+04 (5,51E+02)	2,87E+04 (5,19E+02)
F23	30	4,81E+02 (1,47E+01)	4,59E+02 (9,29E+00)	4,69E+02 (1,31E+01)	4,74E+02 (8,91E+00)	4,73E+02 (1,16E+01)	4,75E+02 (1,34E+01)
	50	7,20E+02 (1,79E+01)	6,85E+02 (2,47E+01)	6,94E+02 (2,12E+01)	7,14E+02 (1,78E+01)	7,16E+02 (1,96E+01)	7,12E+02 (2,00E+01)
	100	1,28E+03 (3,27E+01)	1,21E+03 (4,49E+01)	1,22E+03 (3,78E+01)	1,24E+03 (2,51E+01)	1,24E+03 (2,75E+01)	1,25E+03 (2,56E+01)
F24	30	5,36E+02 (9,70E+00)	5,22E+02 (1,17E+01)	5,30E+02 (1,28E+01)	5,33E+02 (1,08E+01)	5,29E+02 (1,01E+01)	5,30E+02 (1,21E+01)
	50	7,54E+02 (1,56E+01)	7,37E+02 (1,93E+01)	7,40E+02 (1,22E+01)	7,54E+02 (1,86E+01)	7,49E+02 (1,47E+01)	7,52E+02 (1,58E+01)
	100	1,54E+03 (3,45E+01)	1,60E+03 (5,21E+01)	1,51E+03 (3,56E+01)	1,55E+03 (3,08E+01)	1,53E+03 (3,40E+01)	1,54E+03 (2,96E+01)
F25	30	3,91E+02 (7,66E+009)	3,91E+02 (6,33E+00)	3,93E+02 (6,00E+00)	3,89E+02 (4,48E+00)	3,89E+02 (1,52E+00)	3,89E+02 (1,10E+00)
	50	5,71E+02 (1,98E+01)	5,48E+02 (1,92E+01)	5,68E+02 (2,14E+01)	5,64E+02 (1,85E+01)	5,60E+02 (2,00E+01)	5,59E+02 (2,09E+01)
	100	1,01E+03 (5,70E+01)	9,55E+02 (5,15E+01)	9,80E+02 (3,96E+01)	9,59E+02 (5,19E+01)	9,85E+02 (5,64E+01)	9,37E+02 (4,11E+01)


Çizelge 3.24. (devam) CEC 2017 test problemleri için elde edilen ortalama ve standart sapma değerleri.

F26	30	2,30E+03 (1,55E+02)	2,11E+03 (2,62E+02)	2,14E+03 (1,37E+02)	2,13E+03 (4,34E+02)	2,11E+03 (3,89E+02)	2,13E+03 (4,48E+02)
	50	3,84E+03 (1,61E+02)	3,61E+03 (2,03E+02)	3,58E+03 (1,93E+02)	3,77E+03 (1,70E+02)	3,71E+03 (1,75E+02)	3,83E+03 (1,69E+02)
	100	9,89E+03 (3,46E+02)	1,03E+04 (4,61E+02)	9,35E+03 (3,63E+02)	9,78E+03 (2,90E+02)	9,70E+03 (2,44E+02)	9,86E+03 (3,04E+02)
F27	30	5,22E+02 (1,24E+01)	5,24E+02 (1,48E+01)	5,30E+02 (1,81E+01)	5,22E+02 (9,92E+00)	5,25E+02 (1,53E+01)	5,24E+02 (9,49E+00)
	50	7,30E+02 (1,01E+02)	6,51E+02 (8,64E+01)	7,66E+02 (1,15E+02)	6,60E+02 (7,86E+01)	7,00E+02 (9,00E+01)	7,05E+02 (9,90E+01)
	100	7,64E+02 (3,08E+01)	7,55E+02 (4,12E+01)	8,22E+02 (3,62E+01)	7,43E+02 (2,86E+01)	7,44E+02 (2,98E+01)	7,35E+02 (2,70E+01)
F28	30	4,47E+02 (1,72E+01)	4,50E+02 (2,42E+01)	4,41E+02 (2,04E+01)	4,40E+02 (1,76E+01)	4,39E+02 (1,88E+01)	4,35E+02 (1,57E+01)
	50	5,35E+02 (3,07E+01)	5,34E+02 (3,02E+01)	5,60E+02 (2,71E+01)	5,25E+02 (2,88E+01)	5,32E+02 (3,07E+01)	5,22E+02 (2,77E+01)
	100	8,35E+02 (5,83E+01)	8,52E+02 (2,20E+02)	8,39E+02 (5,86E+01)	7,96E+02 (5,31E+01)	8,45E+02 (5,95E+01)	7,66E+02 (5,21E+01)
F29	30	1,04E+03 (1,18E+02)	8,94E+02 (1,08E+02)	9,78E+02 (1,15E+02)	1,01E+03 (1,10E+02)	9,82E+02 (8,28E+01)	9,93E+02 (8,11E+01)
	50	1,68E+03 (1,68E+02)	1,48E+03 (2,43E+02)	1,68E+03 (1,78E+02)	1,66E+03 (1,86E+02)	1,69E+03 (1,74E+02)	1,74E+03 (1,56E+02)
	100	5,18E+03 (2,64E+02)	4,66E+03 (4,15E+02)	5,02E+03 (3,48E+02)	5,07E+03 (3,11E+02)	5,05E+03 (3,78E+02)	5,11E+03 (3,39E+02)
F30	30	1,21E+04 (6,58E+03)	1,42E+04 (7,43E+03)	1,12E+04 (4,71E+03)	1,31E+04 (5,58E+03)	1,47E+04 (8,12E+03)	1,56E+04 (8,24E+03)
	50	1,31E+06 (3,53E+05)	1,38E+06 (3,50E+05)	1,24E+06 (2,45E+05)	1,27E+06 (2,78E+05)	1,39E+06 (2,63E+05)	1,37E+06 (3,72E+05)
	100	7,22E+04 (3,71E+04)	1,07E+05 (6,53E+04)	9,57E+04 (4,00E+04)	4,22E+04 (1,98E+04)	4,20E+04 (2,05E+04)	5,07E+04 (3,31E+04)


Şekil 3.9, CEC 2017 kıyaslama takımındaki F1 (tek-modlu), F5 (çok-modlu), F18 (hibrit) ve F21 (kompozisyon) test fonksiyonlarının 30/50/100 boyutlu arama uzaylarındaki box-plot grafiklerini göstermektedir. F1 test fonksiyonu grafikleri (Şekil 3.9 a-c), FDBAGSK versiyonlarının tüm boyutlar için minimum hata değerine yakınsamada temel algoritmadan üstün olduğunu göstermektedir. Sonuçlar, FDB yönteminin FDBAGSK versiyonlarının sömürü yeteneği üzerindeki etkisini açıkça ortaya koymuştur. Şekil 3.9 (d-f), F5 (çok-modlu) test fonksiyonu için FDB tabanlı Versiyon-1 algoritmasının 30/50/100 boyutlu arama uzaylarında kararlı bir arama yapabildiğini ve minimum hata değerine yakınsamada AGSK algoritmasına ezici bir üstünlük sağladığını göstermektedir. İlgili grafiklerden çok-modlu test probleminde (F5) AGSK yönteminin yerel çözüm tuzaklarına takıldığı ve buna bağlı olarak erken yakınsadığı anlaşılmaktadır. Öte yandan, Versiyon-1'in üstün performansı, FDB seçim yönteminin bu problemleri elimine ederek AGSK yönteminin keşif yeteneğini önemli ölçüde geliştirdiğini kanıtlamıştır. Hibrit ve kompozisyon problem tipinde algoritmaların yakınsama performansı dikkat çekicidir. Şekil 3.9 (g-i)'deki eğriler, AGSK algoritmasının çeşitlilik sağlamakta zorlandığını göstermektedir. Hibrit tipte bir problem için başarılı arama, güçlü bir sömürü-keşif dengesine bağlıdır. Bu nedenle, AGSK algoritmasının temel modelinde bu dengenin sağlanmasında bir sorun vardır. Deneysel çalışmalarda kullanılan kıyaslama problemleri arasında en yüksek karmaşıklığa sahip olan kompozisyon problem tipidir. Şekil 3.9 (j-l)'deki eğriler, AGSK algoritmasının kompozisyon tipi problemleri optimize etmede diğer problem tiplerine kıyasla daha fazla zorluk yaşadığını göstermektedir. Ek olarak, FDB tabanlı Versiyon-1 algoritması kompozisyon tip problemin tüm boyutlarında rakiplerinden daha başarılı bir arama performansı sergilemiştir.




(a) F1 (Tek-modlu) Boyut = 30




(b) F1 (Tek-modlu) Boyut = 50




(c) F1 (Tek-modlu) Boyut = 100



(d) F5 (Çok-modlu) Boyut = 30




(e) F5 (Çok-modlu) Boyut = 50




(f) F5 (Çok-modlu) Boyut = 100


Şekil 3.9. CEC 2017 test problemleri için box-plot grafikleri.




(g) F18 (Hibrit) Boyut = 30




(h) F18 (Hibrit) Boyut = 50




(i) F18 (Hibrit) Boyut = 100



(j) F21 (Kompozisyon) Boyut = 30



(k) F21 (Kompozisyon) Boyut = 50




(l) F21 (Kompozisyon) Boyut = 100


Şekil 3.9. (devam) CEC 2017 test problemleri için box-plot grafikleri.

Şekil 3.10, CEC 2020 test takımından seçilen tek-modlu (F1), çok-modlu (F3), hibrit (F5) ve kompozisyon tip (F10) test fonksiyonları için 30, 50 ve 100 boyutlardaki AGSK ve FDBAGSK versiyonlarının hata değerlerini özetler. Algoritmaların sömürü yeteneğini test etmek için tasarlanan tek-modlu (F1) problem tipi için verilen grafikler (Şekil 3.10 a-c) incelendiğinde FDBAGSK versiyonlarının sömürü görevini yerine getirmede baz algoritmaya kıyasla daha başarılı olduğu anlaşılmaktadır. Birden fazla yerel çözüm tuzağı içeren çok-modlu problem tipinde güçlü bir yakınsama için algoritmanın etkin çeşitlilik ve güçlü keşif yeteneğine sahip olması gerekir. F3 problemi için verilen box-plot grafikleri (Şekil 3.10 d-f) Versiyon-1 ve Versiyon-2 varyantlarının rakiplerine kıyasla minimum hata değerine yakınsamada rakiplerinden daha başarılı olduğunu göstermiştir. Hibrit ve kompozisyon problem tiplerinde karmaşık arama uzayları nedeniyle global optimuma yakınsama oldukça zorlu bir görevdir. Ayrıca bu problem tiplerinde başarılı bir yakınsama için algoritmanın dengeli arama yeteneğinin güçlü olması gerekir. Bu bilgiler ışığında, F5 (hibrit) ve F10 (kompozisyon) problem tipleri için verilen box-plot grafikleri (Şekil 3.10 g-l) detaylı olarak analiz edildiğinde FDB tabanlı Versiyon-1 yönteminin minimum hata değerine başarılı bir şekilde yakınsadığı görülmektedir.







(a) F1 (Tek-modlu) Boyut = 30




(b) F1 (Tek-modlu) Boyut = 50




(c) F1 (Tek-modlu) Boyut = 100



(d) F3 (Çok-modlu) Boyut = 30




(e) F3 (Çok-modlu) Boyut = 50




(f) F3 (Çok-modlu) Boyut = 100


Şekil 3.10. CEC 2020 test problemleri için box-plot grafikleri.




(g) F5 (Hibrit) Boyut= 30




(h) F5 (Hibrit) Boyut = 50




(i) F5 (Hibrit) Boyut = 100



(j) F10 (Kompozisyon) Boyut = 30



(k) F10 (Kompozisyon) Boyut = 50



(l) F10 (Kompozisyon) Boyut = 100

Şekil 3.10. (devam) CEC 2020 test problemleri için box-plot grafikleri.

- *Yakınsama Analizi*


Bu alt bölüm, AGSK ve FDBAGSK versiyonlarının yakınsama analizi hakkında bilgi sunar. Yakınsama analizinin amacı, farklı problem türleri için rakip algoritmaların yakınsama performansını göstermektir. CEC 2017 test takımından seçilen tek modlu (F1), çok modlu (F9), hibrit (F15) ve kompozisyon (F29) tipi test fonksiyonları için rekabetçi algoritmaların yakınsama grafikleri Şekil 3.11’de gösterilmiştir.

Şekil 3.11 (a-c)’de tek-modlu tip F1 problemi için algoritmaların yakınsama eğrileri verilmiştir. İlgili yakınsama grafikleri incelendiğinde AGSK algoritmasının yakınsama performansının problem boyutu arttıkça kötüleştiği görülmektedir. Öte yandan, FDB tabanlı AGSK versiyonlarının baz algoritmaya kıyasla sömürü görevini daha başarılı bir şekilde yerine getirebildiği gözlemlenmiştir.


Şekil 3.11 (d-f)’de çok-modlu tip F9 problemi için AGSK ve FDBAGSK versiyonlarının yakınsama eğrileri verilmiştir. Grafiklerden, FDB tabanlı Versiyon-3’ün 30 boyutlu arama uzayında, Versiyon-1’in ise 50 ve 100 boyutlu arama uzaylarında en iyi yakınsama performansına sahip olduğu görülmektedir. Bu durum Versiyon-1 ve Versiyon-3’ün keşif yeteneğinin rakiplerinden daha güçlü olduğunun somut kanıtıdır.

Şekil 3.11 (g-i)’de algoritmaların hibrit tip F15 problemi için yakınsama eğrileri verilmiştir. Yakınsama grafiklerinden baz algoritmanın erken yakınsadığı ve arama performansının rakiplerine kıyasla daha kötü olduğu görülmektedir. FDBAGSK versiyonları arasındaki karşılaştırma Versiyon-1 ve Versiyon-5 algoritmalarının, 30, 50 ve 100 boyutlu arama uzaylarında daha düşük hata değerine yakınsadığını ortaya koymuştur. Bu iki algoritmanın hibrit tip problem uzayındaki performansı, dengeli arama yeteneklerinin rakiplerinden daha güçlü olduğunu göstermiştir.


Şekil 3.11 (j-l)’de, kompozisyon tip F29 test problemi için AGSK ve FDBAGSK versiyonlarının yakınsama eğrileri verilmiştir. Grafikler, algoritmaların yakınsama performanslarının problem boyutuna bağlı olarak değiştiğini göstermektedir. Kompozit tip F29 probleminde, FDBAGSK versiyonlarının yakınsama oranı ve doğruluğu açısından baz algoritmadan daha başarılı olduğu görülmektedir. Bu durum, FDB ile tasarlanan algoritmaların yüksek karmaşıklıkta problem uzaylarında sömürü ve keşif arasındaki dengeyi başarıyla kurabildiğini gösterir.




(a) F1 (Tek-modlu) Boyut = 30




(b) F1 (Tek-modlu) Boyut = 50




(c) F1 (Tek-modlu) Boyut = 100



(d) F9 (Çok-modlu) Boyut = 30




(e) F9 (Çok-modlu) Boyut = 50




(f) F9 (Çok-modlu) Boyut = 100


Şekil 3.11. CEC 2017 test takımından seçilen farklı problem tipleri için AGSK ve FDBAGSK versiyonlarının yakınsama eğrileri.




(g) F15 (Hibrit) Boyut = 30




(h) F15 (Hibrit) Boyut = 50




(i) F15 (Hibrit) Boyut = 100



(j) F29 (Kompozisyon) Boyut = 30



(k) F29 (Kompozisyon) Boyut = 50



(l) F29 (Kompozisyon) Boyut = 100

Şekil 3.11. (devam) CEC 2017 test takımından seçilen farklı problem tipleri için AGSK ve FDBAGSK versiyonlarının yakınsama eğrileri.


➤ *Algoritma Karmaşıklığı Analizi*

FDB tabanlı AGSK varyantlarının baz AGSK algoritmasına kıyasla daha iyi bir arama performansı sergilediği istatistiksel analiz ve yakınsama eğrileri kullanılarak gösterilmiştir. Optimizasyon algoritması tasarımında temel hedef minimum hata değeri ile global optimuma yakınsamak olsa da bu amaca hızlı ve düşük hesaplama karmaşıklığı ile ulaşmak da oldukça önemlidir. Bunun için AGSK ve FDBAGSK varyantlarının hesaplama karmaşıklığı ayrıntılı olarak incelenmelidir. Bu kapsamda optimizasyon algoritmalarının 30, 50 ve 100 boyutlu arama uzaylarındaki hesaplama karmaşıklığı *Bölüm 3.4.1.3*’te detaylı olarak verilen teknik bilgiler kullanılarak hesaplanmıştır. AGSK ve önerilen FDBAGSK yönteminin küçük, orta ve yüksek boyutlu arama uzaylarındaki karmaşıklık bilgisi Çizelge 3.25’te sunulmuştur.

Çizelge 3.25. Algoritma karmaşıklığı bilgisi.

Arama Uzayı	T0	T1	AGSK	Versiyon-1	Versiyon-2	Versiyon-3	Versiyon-4	Versiyon-5
Boyut=30	0,0835	0,7196	10,8256	11,2007	11,6684	12,4257	12,3683	11,3258
Boyut=50		1,2782	15,9880	16,8325	17,5389	18,4981	18,5160	16,8157
Boyut=100		3,9926	65,9463	67,4490	70,0552	70,4011	70,1947	67,1269

Çizelge 3.25 detaylı olarak incelendiğinde baz AGSK ve FDBAGSK varyantlarının farklı arama uzayları için benzer hesaplama karmaşıklığına sahip olduğu görülmektedir. Önerilen FDBAGSK (Versiyon-1) yönteminin problem boyutundaki artışa rağmen algoritma karmaşıklığı açısından istikrarlı performansı, yüksek boyutlu optimizasyon problemlerinin çözümü için kullanılabilecek güçlü bir alternatif olduğunun göstergesidir. Ayrıca, FDB seçim yönteminin arama süreci yaşam döngüsünde ekstra hesaplama karmaşıklığı oluşturmamasına rağmen FDBAGSK versiyonları algoritma karmaşıklığının temel algoritmaya kıyasla yalnızca biraz artmış olması etkileyicidir. Problem boyutuna bağlı olarak algoritma karmaşıklığı değişimini görsel olarak inceleyebilmek amacıyla Şekil 3.12 hazırlanmıştır. İlgili şekil, Çizelge 3.25’te verilen nümerik değerler kullanılarak oluşturulmuştur. Şekil 3.12’den FDB seçim yönteminin algoritma karmaşıklığına olan etkisinin düşük olduğu görülmektedir.



Şekil 3.12. AGSK ve FDBAGSK versiyonlarının hesaplama karmaşıklığı.

Özetle, *Bölüm 3.4.2.3*'te gerçekleştirilen deneysel çalışmalarda FDB seçim yönteminin AGSK algoritmasının arama performansı üzerindeki etkisi araştırılmıştır. Bu kapsamda, CEC 2017 ve CEC 2020 kıyaslama takımlarında yer alan tek-modlu, çok-modlu, hibrit ve kompozisyon tip problemler kullanılarak 30,50 ve 100 boyutlu arama uzayları için algoritmaların sömürü, keşif ve dengeli arama yetenekleri incelenmiştir. Deneysel sonuçlar, FDB tabanlı AGSK versiyonlarının baz algoritmaya (AGSK) kıyasla daha iyi arama performansı sergilediğini ortaya koymuştur. Ayrıca, FDBAGSK varyantları arasındaki kıyaslamada en başarılı varyantın Versiyon-1 olduğu görülmüştür. Buna göre, Versiyon-1 tez çalışmasının sonraki bölümlerinde FDBAGSK olarak isimlendirilmiştir.

3.4.3. Önerilen *d*FDB-MRFO Algoritması

Bu alt bölümde, tez çalışmasının orijinal katkılarından biri olarak geliştirilen *d*FDB seçim yöntemi kullanılarak güçlü bir optimizasyon algoritması tasarımı gerçekleştirilmiştir. Bu kapsamda yakın zamanda geliştirilmiş bir meta-sezgisel arama algoritması olan manta ışıını yiyecek arama optimizasyonunun (Manta Ray Foraging Optimization, MRFO [25]) arama performansını iyileştirmek için *d*FDB seçim yöntemi uygulanmıştır. *d*FDB yöntemi ile tasarlanan MRFO algoritmasının arama performansında dikkate değer bir iyileşme gözlemlenmiştir. Takip eden alt bölümlerde sırasıyla geleneksel MRFO algoritmasının temelleri ve önerilen hibrit *d*FDB-MRFO algoritması tanıtılmıştır.

3.4.3.1. MRFO Algoritmasına Genel Bakış

MRFO, Zhao ve arkadaşları [25] tarafından manta ışınlarının (hayalet vatoz) yiyecek arama stratejilerinden esinlenerek geliştirilmiş popülasyon tabanlı bir meta-sezgisel algoritmadır. MRFO, verimli bir optimizasyon modeli geliştirmek için manta ışınlarının üç benzersiz besin arama stratejisini taklit eder: zincir (*chain*), kasırga (*cyclone*) ve takla (*somersault*). Zincir besin arama stratejisi, önceki manta ışını tarafından gözden kaçırılan veya fark edilmeyen kayıp avı yakalamak için, manta ışınlarının düzenli bir şekilde sıralandığı içsel yiyecek arama aktivitesini simüle eder. Kasırga tipi yiyecek arama stratejisi, avın (plankton) konsantrasyon miktarı önemli olduğunda gerçekleşir. Takla tipi besin arama stratejisinde manta ışınları geriye doğru dönüş hareketleri yapar ve av planktonlarının etrafında daire çizerek onları açık ağızlarına çekerler. Bu üç farklı yiyecek arama mekanizması, MRFO yönteminin temel arama stratejilerini oluşturur [20], [25].

- *Zincir besin arama (Chain foraging)*

Manta vatozlarında beslenme süreci için kullanılan stratejilerden ilki zincir (*chain*) tipli yiyecek aramadır. Bu stratejinin matematiksel modeli Eşitlik (3.43) ve (3.44)'te verilmiştir [25]:

$$x_i^d(t+1) = \begin{cases} x_i^d(t) + r \cdot (x_{best}^d - x_i^d(t)) + \alpha \cdot (x_{best}^d - x_i^d(t)), i = 1 \\ x_i^d(t) + r \cdot (x_{i-1}^d(t) - x_i^d(t)) + \alpha \cdot (x_{best}^d - x_i^d(t)), i = 2, \dots, N \end{cases} \quad (3.43)$$

$$\alpha = 2 \cdot r \cdot \sqrt{|\log(r)|} \quad (3.44)$$

Manta ışınları popülasyonundaki, i . çözüm adayı x_i ($i = 1, \dots, N$) ile temsil edilir. MRFO algoritmasında çözüm adayları besin kaynağının konumu ile temsil edilir. Buna göre D (tasarım parametrelerinin sayısı) boyutlu bir optimizasyon problemi için, herhangi bir t anında d . ($d=1, \dots, D$) boyut için manta ışınının konum vektörü $x_i^d(t)$ ile gösterilir. Zincir tipli yiyecek arama stratejisine göre hareket eden bir manta ışınının ($t+1$) anındaki yeni konumu Eşitlik (3.43) kullanılarak hesaplanır. Eşitlik (3.43)'te r [0-1] aralığında rastgele oluşturulmuş bir vektördür. x_{best}^d manta ışını popülasyonunda en yüksek plankton yoğunluğuna sahip konum vektörünü temsil eder. α ise ağırlık katsayısı vektörü olarak tanımlanır ve Eşitlik (3.44) kullanılarak hesaplanır.

- *Kasırğa besin arama (Cyclone foraging)*

MRFO algoritmasında beslenme için kullanılan ikinci yöntem, kasırğa tipi yiyecek arama stratejisidir. Bu stratejinin karakteristik özelliği, manta ışınlarının spiral bir şekil oluşturması ve derin sularda planktona doğru yüzmesidir. Eşitlik (3.45), N boyutlu bir arama uzayında spiral hareketi modellemek için kullanılır [25]:

$$x_i^d(t+1) = \begin{cases} x_{best}^d + r \cdot (x_{best}^d - x_i^d(t)) + \beta \cdot (x_{best}^d - x_i^d(t)), i = 1 \\ x_{best}^d + r \cdot (x_{i-1}^d(t) - x_i^d(t)) + \beta \cdot (x_{best}^d - x_i^d(t)), i = 2, \dots, N \end{cases} \quad (3.45)$$

$$\beta = 2e^{r_1 \frac{T-t+1}{T}} \cdot \sin(2\pi r_1) \quad (3.46)$$

Yukarıdaki denklemlerde, r [0-1] aralığında rastgele bir sayıdır. β ve T sırasıyla ağırlık katsayısı ve maksimum iterasyon sayısı olarak tanımlanır.

Arama uzayında her bir çözüm adayı mevcut en iyi konumdan uzakta yeni bir konum aramaya zorlanır. Bu strateji esas olarak keşif görevine odaklanır ve MRFO'nun kapsamlı bir küresel arama yapmasını sağlar [25].

$$x_i^d(t+1) = \begin{cases} x_{rand}^d + r \cdot (x_{rand}^d - x_i^d(t)) + \beta \cdot (x_{rand}^d - x_i^d(t)), i = 1 \\ x_{rand}^d + r \cdot (x_{i-1}^d(t) - x_i^d(t)) + \beta \cdot (x_{rand}^d - x_i^d(t)), i = 2, \dots, N \end{cases} \quad (3.47)$$

$$x_{rand}^d = lb^d + r \cdot (ub^d - lb^d) \quad (3.48)$$

Eşitlik (3.47)'de x_{rand}^d arama uzayında rastgele üretilen bir konumu temsil eder. lb^d ve ub^d sırasıyla d . tasarım parametresinin alt ve üst sınırları olarak tanımlanır.

- *Takla besin arama (Somersault foraging)*

MRFO algoritmasında beslenme için kullanılan üçüncü yöntem, takla yiyecek arama stratejisidir. Bu stratejide yiyeceğin konumu pivot (dayanak-eksen) olarak görülür. Her birey pivot etrafında bir ileri bir geri yüzme ve yeni bir pozisyona takla atma eğilimindedir. Bu nedenle, konumlarını her zaman o ana kadar bulunan en iyi konum etrafında güncellerler. Matematiksel model aşağıdaki gibidir [25]:

$$x_i^d(t+1) = x_i^d(t) + S \cdot (r_2 \cdot x_{best} - r_3 \cdot x_i(t)) \quad i = 1, 2, \dots, N \quad (3.49)$$

Eşitlik (3.49)'da kullanılan S takla faktörünü gösterir. S parametresinin nümerik değeri 2 olarak ayarlanmıştır. r_2 ve r_3 [0-1] aralığındaki rastgele sayılardır. Manta ışınları daha iyi

plankton konumu bulmak için mevcut konumları ile en iyi manta ışını konumu arasında arama yapar. Özetle, takla yiyecek arama stratejisi algoritmanın etkin bir sömürü yeteneği sergilemesine katkıda bulunur.

3.4.3.2. *dFDB-MRFO Algoritması Tasarımı*

Bu alt bölümde, MRFO algoritmasının arama performansını iyileştirmek için yürütülen çalışmalar sunulmuştur. Bu kapsamda MRFO algoritmasının seçim stratejisi *dFDB* yöntemi ile yeniden tasarlanmış ve önerilen *dFDB-MRFO* algoritmasının arama performansı incelenmiştir.

MRFO algoritmasının matematiksel modeli incelendiğinde *dFDB* yönteminin uygulanabileceği birçok senaryo olduğu görülmektedir. Buna göre manta ışınlarının beslenme stratejilerinin modellendiği eşitliklerde (Eşitlik 3.43, 3.45, 3.47, 3.49) *dFDB* yöntemi ile seçilebilecek çözüm adayları mevcuttur. MRFO algoritmasının meta-sezgisel arama sürecinde kullanılan eşitlikler ve bu eşitliklerde tanımlanan çözüm adaylarının *dFDB* yöntemi kullanılarak seçimi ile ilgili bilgiler Çizelge 3.26’da sunulmuştur.

Çizelge 3.26. MRFO algoritmasında kullanılan çözüm adayı bilgileri ve *dFDB* stratejisinin uygulanması.

Beslenme stratejisi	Eşitlik numarası	Eşitlikte tanımlanan çözüm adayları	<i>dFDB</i> seçim yönteminin uygulanması
Zincir tipli	(3.43)	x_{best}, x_i, x_{i-1}	Beslenme stratejilerinde kullanılan dört farklı çözüm adayının <i>dFDB</i> yöntemi kullanılarak popülasyondan etkili bir şekilde seçilmesi önerilmiştir $x_{best} = x_{dFDB}, x_i = x_{dFDB},$ $x_{i-1} = x_{dFDB}, x_{rand} = x_{dFDB}$
Kasırga tipli	(3.45) ve (3.47)	$x_{best}, x_{rand}, x_i, x_{i-1}$	
Takla tipli	(3.49)	x_{best}, x_i	

Çizelge 3.26’da verilen çözüm adayı bilgileri referans alınarak, FDB ve *dFDB* seçim yöntemleri ile onlarca MRFO versiyonu oluşturulmuş ve üstün arama performansı sergileyen beş versiyon seçilmiştir. MRFO algoritmasının FDB ve *dFDB* seçim yöntemleri ile tasarlanmış en etkili versiyonları Çizelge 3.27’de verilmiştir.

Çizelge 3.27. FDB ve d FDB seçim yöntemleri ile tasarlanan MRFO varyantları.

MRFO varyantı	w sınırları [w_{min} , w_{max}]	F (frekans)	Uygulama aşaması	Açıklama
Versiyon-1: MRFO-FDB	0.5 (sabit)	-	FDB ve d FDB seçim yöntemleri zincir tipli besin arama aşamasına uygulanmıştır (Eşitlik 3.43)	Eşitlik (3.43)'te kullanılan x_{best} çözüm adayı yerine FDB (x_{FDB}) ve d FDB (x_{dFDB}) yöntemleri ile seçilen çözüm adayları kullanılmıştır.
Versiyon-2: MRFO- d FDB	[0; 1]	1		
Versiyon-3: MRFO- d FDB	[0.4; 1]	1		
Versiyon-4: MRFO- d FDB	[0; 1]	100		
Versiyon-5: MRFO- d FDB	[0.4; 1]	100		

Çizelge 3.27'de FDB yöntemi kullanılarak oluşturulan Versiyon-1'de w -katsayısının sabit olduğu görülmektedir. Öte yandan, d FDB yönteminde w ve F parametreleri için farklı nümerik değerler kullanılarak dört farklı varyant (Versiyon-2, Versiyon-3, Versiyon-4 ve Versiyon-5) oluşturulmuştur. Önerilen d FDB-MRFO algoritmasının (Versiyon-3) sözde kodu Çizelge 3.28'de verilmiştir.

Çizelge 3.28. Önerilen d FDB-MRFO algoritmasının sözde-kodu.

1.	Başla
2.	P : Rastgele başlangıç popülasyonunu oluştur (Eşitlik 3.2)
3.	for $i=1: N$
4.	Çözüm adaylarının fitness değerini hesapla ve f vektörünü oluştur (Eşitlik 3.3)
5.	end
6.	while arama süreci yaşam döngüsü: sonlandırma kriteri sağlanıncaya kadar do
7.	for $i=1: N$
8.	if (rand<0.5) then // Kasırga besin arama stratejisi //
9.	if (t/T_{max} <rand) then
10.	$x_{rand}^d = lb^d + r. (ub^d - lb^d)$
11.	$x_i^d(t+1) = \begin{cases} x_{rand}^d + r. (x_{rand}^d - x_i^d(t)) + \beta. (x_{rand}^d - x_i^d(t)), i = 1 \\ x_{rand}^d + r. (x_{i-1}^d(t) - x_i^d(t)) + \beta. (x_{rand}^d - x_i^d(t)), i = 2, \dots, N \end{cases}$
12.	else
13.	$x_i^d(t+1) = \begin{cases} x_{best}^d + r. (x_{best}^d - x_i^d(t)) + \beta. (x_{best}^d - x_i^d(t)), i = 1 \\ x_{best}^d + r. (x_{i-1}^d(t) - x_i^d(t)) + \beta. (x_{best}^d - x_i^d(t)), i = 2, \dots, N \end{cases}$
14.	end if
15.	else // Zincir besin arama stratejisi (Bu strateji d FDB yöntemi ile modellendi)//
16.	$x_i^d(t+1) = \begin{cases} x_i^d(t) + r. (x_{best}^d - x_i^d(t)) + \alpha. (x_{dFDB}^d - x_i^d(t)), i = 1 \\ x_i^d(t) + r. (x_{i-1}^d(t) - x_i^d(t)) + \alpha. (x_{dFDB}^d - x_i^d(t)), i = 2, \dots, N \end{cases}$

Çizelge 3.28. (devam) Önerilen *d*FDB-MRFO algoritmasının sözde-kodu.

17	end if
18	end for
19	// Çözüm Adayı Güncelleme Aşaması //
20	for i=1: <i>N</i>
21	Çözüm adaylarının fitness değerlerini hesapla $f(x_i(t + 1))$
22	if $f(x_i(t + 1)) < f(x_{best})$ then
23	$x_{best} = x_i(t + 1)$
24	end if
25	end for
26	// Takla besin arama stratejisi //
27	for i=1: <i>N</i>
28	$x_i^d(t + 1) = x_i^d(t) + S \cdot (r_2 \cdot x_{best} - r_3 \cdot x_i(t))$
29	end for
30	// Çözüm Adayı Güncelleme Aşaması //
31	for i=1: <i>N</i>
32	Çözüm adaylarının fitness değerlerini hesapla $f(x_i(t + 1))$
33	if $f(x_i(t + 1)) < f(x_{best})$ then
34	$x_{best} = x_i(t + 1)$
35	end if
36	end for
37	end while
38	En iyi çözüm: x_{best}
39	Bitir

3.4.3.3. *d*FDB-MRFO Algoritmasının CEC Benchmark Problemlerinde Test Edilmesi

Bu alt bölümde, geleneksel MRFO, FDB-MRFO ve *d*FDB-MRFO versiyonlarının arama performansı incelenmiştir. FDB yöntemi ile tasarlanan MRFO, Versiyon-1 olarak isimlendirilirken *d*FDB tabanlı MRFO varyasyonları Versiyon-2, Versiyon-3, Versiyon-4 ve Versiyon-5 olarak isimlendirilmiştir. Bu varyasyonlar hakkında ayrıntılı bilgi için Çizelge 3.27 gözden geçirilmelidir.

- *İstatistiksel analiz*

Klasik [19], CEC 2014 [104], ve CEC 2017 [102] test problemleri kullanılarak gerçekleştirilen deneysel çalışmalarda 82.620 (90*3*6*51) adet veri elde edilmiştir. Deneysel çalışma ayarları şu şekildedir: 90 test problemi, 3 farklı problem boyutu, 6 rakip algoritma ve her bir test fonksiyonu için 51 bağımsız çalışma. Bu verilere dayalı olarak gerçekleştirilen Friedman testi sonucunda elde edilen algoritmaların sıraları Çizelge 3.29’da verilmiştir. İlgili çizelgede her bir deneysel çalışma için algoritmaların elde ettiği

en iyi deęer koyu ve gri gölgeli olarak vurgulanmıřtır.

Çizelge 3.29. MRFO versiyonları için Friedman testi ile elde edilen sıralar.

Algoritma	Boyut = 30			Boyut = 50			Boyut = 100			Ortalama Sıra
	Klasik	CEC 2014	CEC 2017	Klasik	CEC 2014	CEC 2017	Klasik	CEC 2014	CEC 2017	
Versiyon-1	3,3938	3,4905	3,4578	3,4703	3,3670	3,3444	3,3350	3,3529	3,2585	3,3856
Versiyon-2	3,5033	3,4719	3,5291	3,5585	3,5520	3,5373	3,5618	3,5954	3,6389	3,5498
Versiyon-3	3,3232	3,3990	3,2752	3,3895	3,3536	3,2444	3,4121	3,3141	3,2480	3,3288
Versiyon-4	3,4340	3,4431	3,5206	3,4271	3,4938	3,4428	3,4614	3,5016	3,4814	3,4673
Versiyon-5	3,4353	3,3794	3,2075	3,3876	3,3676	3,3131	3,4206	3,3647	3,3209	3,3552
MRFO	3,9105	3,8160	4,0098	3,7670	3,8660	4,1180	3,8092	3,8712	4,0523	3,9133

Klasik, CEC 2014 ve CEC 2017 test takımları için 30, 50 ve 100 boyutlu arama uzaylarında dokuz deneysel çalışma gerçekleştirilmiřtir. Çizelge 3.29 detaylı olarak incelendięinde 9 deneysel çalışmanın 5 tanesinde rakiplerine üstünlük kuran *d*FDB tabanlı Versiyon-3 rakiplerine kıyasla başarılı bir arama performansı sergilemiřtir. Versiyon-5, 3 deneysel çalışmada rakiplerine üstünlük sağlamıřtır. Friedman testi ile elde edilen ortalama sıra indeksine göre; Versiyon-3'ün altı rekabetçi algoritma arasında en başarılı arama performansına sahip olduęu, Versiyon-5'in ise ikinci sırada yer aldığı görölmektedir. Her iki algoritma da MRFO'nun *d*FDB seçim yöntemi ile tasarlanmıř varyantlarıdır. *d*FDB tabanlı bu iki algoritmada *w*-katsayının sınır deęerleri eřittir, ancak frekans deęerleri farklıdır (Çizelge 3.27). Öte yandan, Versiyon-1 olarak isimlendirilen FDB-MRFO varyantı altı rekabetçi algoritma arasında üçüncü sırada yer almıřtır. Buna göre, FDB tabanlı MRFO varyantının (Versiyon-1) *d*FDB kullanılarak tasarlanan Versiyon-2 ve Versiyon-4'e kıyasla daha başarılı bir arama performansı sergiledięi gözlemlenmiřtir. MRFO algoritmasının geleneksel versiyonu altı algoritma arasında son sırada yer almıřtır. Bu durum, FDB ve *d*FDB seçim yöntemlerinin baz algoritmanın arama performansına etkisini açıkça göstermiřtir. *d*FDB tabanlı Versiyon-3 ve Versiyon-5 algoritmalarının deneysel çalışmaların büyük çoęunluęunda rakiplerinden daha iyi performans göstermesi, bu tez çalışmasının orijinal katkılarından biri olarak geliştirilen *d*FDB seçim yönteminin başarısının açık kanıtıdır.

Wilcoxon testine göre MRFO algoritması ve FDB tabanlı MRFO varyasyonları için elde edilen karşılařtırma sonuçları Çizelge 3.30'da verilmiřtir. Çizelge 3.30'da her bir hücrede verilen puanlar, sırasıyla MRFO algoritmasının rakibine karşı başarısız olduęu test problemlerinin sayısını, iki rakip algoritmanın benzer arama performansı sergiledięi test

problemlerinin sayısını ve FDB-*d*FDB tabanlı algoritmaların baz algoritmaya üstünlük sağladığı test problemlerinin sayısını gösterir. İlgili çizelgenin birinci hücresinde 8/21/1 olarak verilen puana göre MRFO algoritması 30 problemin sekiz tanesinde Versiyon-1 varyantına karşı kaybetmiş, yirmi bir problemde iki algoritma benzer arama performansı göstermiş ve bir problemde MRFO algoritması daha iyi performans göstermiştir. Çizelge 3.30’da verilen istatistiksel analiz sonuçları derinlemesine analiz edildiğinde FDB-MRFO ve *d*FDB-MRFO varyantlarının tüm deneylerde baz algoritmaya üstünlük sağladığı görülmektedir. İkili karşılaştırma sonuçları, *d*FDB seçim yönteminin MRFO algoritmasının performansı üzerindeki olumlu etkisini açıkça ortaya koymuştur.

Çizelge 3.30.Wilcoxon ikili karşılaştırma sonuçları.

vs. MRFO +/-/-	Boyut = 30			Boyut = 50			Boyut = 100		
	Klasik	CEC 2014	CEC 2017	Klasik	CEC 2014	CEC 2017	Klasik	CEC 2014	CEC 2017
Versiyon-1	8/21/1	8/19/3	15/14/1	7/22/1	5/23/2	13/15/2	7/22/1	5/24/1	14/14/2
Versiyon-2	8/21/1	8/19/3	16/13/1	7/22/1	8/19/3	10/19/1	7/22/1	5/23/2	11/18/1
Versiyon-3	8/21/1	9/20/1	16/13/1	7/22/1	8/22/0	15/14/1	7/23/0	4/25/1	12/18/0
Versiyon-4	7/22/1	10/18/2	16/13/1	8/21/1	7/22/1	12/17/1	8/21/1	6/23/1	12/16/2
Versiyon-5	7/22/1	12/17/1	17/12/1	8/21/1	6/23/1	16/14/0	8/22/0	5/24/1	13/17/0


- *Algoritma Karmaşıklığı Analizi*

Optimizasyon algoritmalarının performansını değerlendirmede önemli kriterlerden biri de algoritma karmaşıklığı bilgisidir. Bu bilgi, önerilen bir meta-sezgisel algoritmanın kullanılabilirliğini ve işlevselliğini göstermek için kritik öneme sahiptir. Yüksek hesaplama karmaşıklığına sahip bir algoritmanın kullanılabilirliği azdır. Bu tip bir algoritma çok boyutlu ve karmaşık arama uzaylarındaki problemlerin çözümü için araştırmacılar tarafından tercih edilmez. Bu nedenle, bir algoritmanın arama performansının yanı sıra hesaplama karmaşıklığını da analiz etmek gerekir. Geleneksel MRFO, FDB tabanlı MRFO varyantı (Versiyon-1) ve *d*FDB ile tasarlanmış MRFO varyantlarının (Versiyon-2,...,Versiyon-5) hesaplama karmaşıklığı bilgisi Çizelge 3.31’de verilmiştir. Algoritma karmaşıklığı hesaplanmasında *Bölüm 3.4.1.3 (Algoritma Karmaşıklığı Analizi)*’de detaylı olarak sunulan IEEE CEC 2014 [104] standartları referans alınmıştır.

Çizelge 3.31. MRFO ve varyantları için algoritma karmaşıklığı bilgisi.

Arama Uzayı	T0	T1	MRFO	Versiyon-1	Versiyon-2	Versiyon-3	Versiyon-4	Versiyon-5
Boyut=30	0,0835	0,86	84,77	93,25	87,36	83,34	84,20	83,86
Boyut=50		1,53	97,22	99,32	102,39	100,93	97,68	99,81
Boyut=100		5,28	145,84	140,66	136,04	133,05	134,89	138,73

Çizelge 3.31’de verilen algoritma karmaşıklığı bilgisinden $dFDB$ yönteminin MRFO algoritmasının hesaplama karmaşıklığı üzerinde önemli bir etkisi olmadığı anlaşılmaktadır. Öte yandan, deneysel çalışmalarda en başarılı performansı sergileyen Versiyon-3 isimli algoritmanın hesaplama karmaşıklığı, rakiplerine göre daha düşüktür. Bu başarının nedeni ise $dFDB$ yöntemi ile tasarlanmış Versiyon-3 algoritmasının yerel çözüm tuzaklarını ortadan kaldırmada rakiplerine göre daha başarılı olması ve bu sayede global çözümü daha kısa sürede bulmasıdır. Problem boyutuna bağlı olarak algoritma karmaşıklığı değişimini görsel olarak inceleyebilmek amacıyla Şekil 3.13 hazırlanmıştır.



Şekil 3.13. MRFO ve varyantları için hesaplama karmaşıklığı.

Özetle, $dFDB$ yöntemi ile modifiye edilen MRFO algoritmasının arama performansında önemli iyileştirmeler elde edilmiştir. Farklı problem tiplerinde ve düşük/orta/yüksek boyutlu arama uzaylarında test edilen $dFDB$ -MRFO algoritması, tüm deneysel çalışmalarda rakiplerine karşı daha kararlı ve sağlam bir arama performansı sergilemiştir. Bu başarı, tez çalışmasında önerilen $dFDB$ yönteminin meta-sezgisel arama algoritmalarının arama performansının geliştirilmesinde kullanılabilecek etkili bir yöntem olduğunu ortaya koymuştur. Deneysel çalışma sonuçlarına göre, $dFDB$ -MRFO

varyantları arasında en başarılı olan algoritma Versiyon-3'dür. Versiyon-3, tez çalışmasının sonraki bölümlerinde *dFDB-MRFO* olarak isimlendirilmiştir.


3.5. ÇOK AMAÇLI ÇEKİRGE OPTİMİZASYON ALGORİTMASI

Bu bölümde çekirge optimizasyon algoritmasının (Grasshopper optimization algorithm, GOA [116]) çok amaçlı versiyonu tanıtılmıştır. Bu amaçla iki alt bölüm hazırlanmıştır. Birinci alt bölümde, tek amaçlı problem uzayında arama yapmak için tasarlanmış popülasyon tabanlı MSA algoritmalarının Pareto tabanlı çok amaçlı optimizasyon modeline dönüştürülme süreci incelenmiştir. İkinci alt bölümde ise, çok-amaçlı çekirge optimizasyon algoritmasının (Multi-objective Grasshopper Optimization Algorithm, MOGOA [26]) genel çerçevesi sunulmuştur.

3.5.1. Pareto Tabanlı Çok Amaçlı Metasezgisel Arama Süreci

Bu alt bölümde, tek-amaçlı problem uzaylarında arama yapmak için tasarlanmış popülasyon tabanlı meta-sezgisel arama algoritmalarının Pareto tabanlı çok amaçlı optimizasyon yöntemin dönüştürülme süreci sunulmuştur. Çok-amaçlı optimizasyon süreci, popülasyonun ele alınması ve güncellenmesi açısından tek amaçlı optimizasyon sürecinden farklıdır. Diğer bir ifadeyle, tek amaçlı optimizasyon, çözüm adaylarının fitness değerlerine göre popülasyonu yönetirken, çok amaçlı optimizasyonda çözüm adaylarının birbirleri üzerindeki baskınlıkları dikkate alınır. Bu nedenle çok-amaçlı optimizasyon algoritmaları, popülasyondaki bastırılmayan (non-dominated) çözümlerin arşivlendiği bir belleğin oluşturulmasına ve kontrolüne ihtiyaç duyar [93], [97]. *Bölüm 3.1.2*'de açıklanan *Tanım 5 (Pareto-set)* ve *Tanım 6 (Pareto-front)*, bastırılmayan çözümler ile tanımlanan arşiv kavramını özetler. Özetle, tek amaçlı arama uzayları için tasarlanmış bir MSA algoritmasını çok amaçlı optimizasyon modeline dönüştürmek için, bastırılmayan bir çözüm arşivi oluşturma ve yönetme süreci arama süreci yaşam döngüsü adımları ile birleştirilmelidir.

Referans [93]'te verilen yaklaşıma dayalı olarak hazırlanan Pareto tabanlı çok-amaçlı optimizasyonun akış şeması Şekil 3.14'te gösterilmiştir. Bu akış şeması, popülasyon tabanlı tek amaçlı MSA algoritmalarını Pareto tabanlı çok-amaçlı optimizasyon modeline dönüştürmek isteyen araştırmacılar için rehber niteliğindedir. Bu dönüşümün bir sonucu olarak elde edilen çok amaçlı optimizasyon algoritmaları ile çatışan amaç fonksiyonlarına sahip çok amaçlı optimizasyon problemleri başarıyla çözülebilir.



Şekil 3.14. Pareto tabanlı çok amaçlı optimizasyonun genel konsepti.

Şekil 3.14'te verilen Pareto-tabanlı çok amaçlı optimizasyonun genel konsepti detaylı olarak incelendiğinde temel olarak iki sürecin entegrasyonundan oluştuğu görülmektedir. Bunlar, tek amaçlı algoritmaların meta-sezgisel arama süreci ve bastırılmayan çözümlerin yönetildiği Pareto tabanlı arşivleme sürecidir. Şekil 3.14'te bu iki işlemin öğelerini birbirinden ayırt etmek için, Pareto-tabanlı arşivleme işleminin adımları açık mavi renk ile, MSA süreci öğeleri ise yeşil renk ile gösterilmiştir. Bu iki sürecin doğru bir şekilde entegre edilmesi ile çok amaçlı optimizasyon algoritması tasarımı gerçekleştirilir. Pareto tabanlı çok amaçlı optimizasyonun genel konsepti detaylı olarak incelendiğinde tek amaçlı MSA algoritmasının çözüm adayları popülasyonu ve karşılık gelen amaç fonksiyonu değerlerinin sırasıyla P ve O_P vektörleri ile temsil edildiği görülmektedir. Ayrıca, bastırılmayan (non-dominated) çözümler kümesi ve bu

kümedeki çözümlerin amaç fonksiyon değerleri sırasıyla A ve O_A vektörleri ile gösterilmiştir.

Pareto tabanlı meta-sezgisel optimizasyon sürecinin ilk adımında A , O_A , P ve O_P vektörleri oluşturulur. İkinci adımda, MSA algoritmasının arama süreci yaşam döngüsü çalıştırılarak Pareto tabanlı arşivleme süreci başlatılır ve arama uzayında keşfedilen yeni konumların başarısı araştırılır. Bu süreçte, *Bölüm 3.1.2*'de açıklanan *Tanım 3 (Pareto baskınlık)* ve *Tanım-4 (Pareto-optimal)* referans alınarak yeni keşfedilen pozisyonlar arasından baskın olmayan çözüm adayları belirlenir. Böylece A arşivi güncellenir. İkinci adım, arama süreci yaşam döngüsü sonlandırma kriterleri karşılanana kadar devam eder. Arama süreci sonlandırma kriterleri sağlandığında baskın olmayan çözüm adaylarından oluşan PS seti (*Tanım-5*) ve bu çözüm adaylarının amaç fonksiyon değerlerini temsil eden PF (*Tanım-6*) elde edilir.

3.5.2. Çekirge Optimizasyon Algoritmasına Genel Bakış

Çekirge optimizasyon algoritması (Grasshopper Optimization Algorithm, GOA [116]), Mirjalili ve arkadaşları tarafından çekirgelerin yiyecek arama davranışlarından esinlenerek geliştirilmiş popülasyon tabanlı bir meta-sezgisel arama algoritmasıdır. Bitkisel üretime ve tarıma verdikleri zararlardan dolayı zararlı olarak kabul edilen çekirgeler, doğada tek tek görülmelerine rağmen aslında sürüler halinde hareket etmektedirler. Çekirgelerin hem larva hem de yetişkinlik olarak adlandırılan yaşam döngülerinde sürüler halinde hareket etmeleri benzersiz bir özelliktir. Sürünün larva aşamasındaki ana özelliği çekirgelerin küçük adımlarla yavaş hareket etmesi, yetişkinlikte ise uzun menzilli ve ani hareket etmesidir. Yiyecek kaynağı arayışı, çekirge sürüsünün bir diğer önemli özelliğidir. Buna göre, sürünün larva ve yetişkinlik aşamalarındaki hareketi, çekirgelerin yiyecek arama davranışını simüle etmek için matematiksel olarak modellenmiş ve böylece doğadan ilham alan GOA algoritması geliştirilmiştir. Algoritmanın optimizasyon süreci aşağıda detaylı olarak açıklanmıştır [116], [117].

Çekirgelerin sürü davranışını simüle etmek için kullanılan matematiksel model Eşitlik (3.50)'de verilmiştir.

$$x_i = S_i + G_i + A_i \quad i = 1, 2, \dots, N \quad (3.50)$$

Eşitlik (3.50)'de x_i , i . çekirgenin konumunu, G_i , i . çekirge üzerindeki yerçekimi kuvvetini, A_i ise rüzgar hareketini temsil eder. S_i ise sosyal etkileşimdir ve Eşitlik (3.51) ile hesaplanır [64].

$$S_i = \sum_{\substack{j=1 \\ j \neq i}}^N s(d_{ij}) \hat{d}_{ij} \quad (3.51)$$

$$s(r) = f e^{-\frac{r}{l}} - e^{-r} \quad (3.52)$$

$$d_{ij} = |x_j - x_i|, \quad \hat{d}_{ij} = \frac{x_j - x_i}{d_{ij}} \quad (3.53)$$

Eşitlik (3.51)'de s sosyal kuvvetlere karşılık gelen bir fonksiyondur. d_{ij} i . ve j . çekirge arasındaki mesafe olarak tanımlanır, $\hat{d}_{ij}$ ise birim vektördür. f ve l sırasıyla çekim yoğunluğu ve çekici uzunluk ölçeği olarak tanımlanır.

Eşitlik (3.50)'de kullanılan G_i ve A_i bileşenleri matematiksel olarak aşağıdaki gibi tanımlanır:

$$G_i = -g \hat{e}_g \quad (3.54)$$

$$A_i = u \hat{e}_w \quad (3.55)$$

Eşitlik (3.54) ve (3.55)'te verilen g ve u sırasıyla yerçekimi sabitini ve sürüklenme katsayısını temsil eder. $\hat{e}_g$, dünyanın merkezine doğru bir birim vektörü gösterirken, $\hat{e}_w$ rüzgâr yönündeki birim vektör olarak tanımlanır.

S_i , G_i ve A_i bileşenlerinin matematiksel ifadeleri Eşitlik (3.50)'de yerine yazıldığında i . çekirgenin pozisyonunu güncellenmek için kullanılan eşitlik aşağıdaki gibi gösterilir.

$$x_i = \sum_{\substack{j=1 \\ j \neq i}}^N s(|x_j - x_i|) \frac{x_j - x_i}{d_{ij}} - g \hat{e}_g + u \hat{e}_w \quad (3.56)$$

Eşitlik (3.56)'da verilen matematiksel model, çekirgelerin hızlı bir şekilde konfor bölgesine ulaşması ve sürünün belirli bir noktaya yakınsamaması nedeniyle optimizasyon problemlerini çözmek için doğrudan kullanılamaz. Optimizasyon problemlerini çözmek için bu denklemin değiştirilmiş versiyonu (Eşitlik 3.57) önerilmiştir.

$$x_i^d = c \left(\sum_{\substack{j=1 \\ j \neq i}}^z c \frac{ub_d - lb_d}{2} s(|x_j^d - x_i^d|) \frac{x_j - x_i}{d_{ij}} \right) + \widehat{xbest}_d \quad (3.57)$$

Eşitlik (3.57)'de, lb_d ve ub_d , sırasıyla d. tasarım değişkeninin alt ve üst sınırları olarak tanımlanır. c konfor bölgesini, itme bölgesini ve çekim bölgesini küçültmek için optimizasyon sürecince kademeli olarak azaltılan bir katsayıyı temsil eder. $\widehat{xbest}_d$, d. boyut için şu ana kadar bulunan en iyi çözüm (hedef) değeridir. Eşitlik (3.57)'de verilen matematiksel model detaylı olarak incelendiğinde, çekirgenin bir sonraki konumunun, mevcut konumu, hedefin konumu ve diğer tüm çekirgelerin konumuna göre tanımlandığı görülmektedir.

Önerilen matematiksel modeller, arama uzayında umut vaat eden çözüm adaylarını bulma (keşif) ve çözüm adaylarının komşuluğunda aramayı yoğunlaştırma (sömürü) işlemlerini yapmak için yeterlidir. Ancak, arama operatörlerinin keşif ve sömürü işlemlerini ayarlayacak bir mekanizma olmalıdır. Bunun için keşif ve sömürüyü dengelemek amacıyla c parametresi kademeli olarak azaltılır. Bu mekanizma, yineleme sayısı arttıkça sömürüyü teşvik eder.

$$c = c_{max} - FES \frac{c_{max} - c_{min}}{maxFES} \quad (3.58)$$

Eşitlik (3.58)'de FE ve $maxFES$ sırasıyla mevcut ve maksimum fitness fonksiyonu değerlendirme sayısı olarak tanımlanır. c parametresinin alt ve üst limitleri şu şekilde ayarlanmıştır: $c_{min} = 0.00004$, $c_{max} = 1$.

GOA algoritmasının sözde-kodu, Referans [89]'da verilen MSA algoritmalarının arama süreci genel adımlarını içeren yaklaşıma dayalı olarak oluşturulmuştur. Buna göre, tek amaçlı optimizasyon problemlerinin çözümü için geliştirilmiş olan GOA algoritmasının sözde-kodu Çizelge 3.32'de verilmiştir.

Çizelge 3.32. GOA algoritmasının sözde-kodu.

1.	Başla
2.	c_{min} , c_{max} , $maxFEs$ parametrelerini ayarla
3.	P : Başlangıç popülasyonunu oluştur (Eşitlik 3.2)
4.	for $i=1: N$ (çözüm adayları sayısı) do
5.	Çözüm adaylarının fitness değerlerini hesapla $O_{x[i]}$
6.	end for
7.	while arama süreci yaşam döngüsü: sonlandırma kriteri sağlanıncaya kadar do
8.	Adım 1: Seçim Süreci (Rehber çözüm adaylarının P 'den seçilmesi)
9.	Adım 2: Arama Süreci (Sömürü ve keşif işlemleri)
10.	Adım 3: Güncelleme Süreci (Fitness değerlerine göre çözüm adaylarının güncellenmesi)
11.	end while
12.	x_{best}
13.	Bitir

3.5.3. Çok-Amaçlı Çekirge Optimizasyon Algoritmasının Tasarımı

Bu alt bölüm, GOA algoritmasının çok amaçlı versiyonunu tanıtmaktadır. Bu kapsamda tek amaçlı optimizasyon problemlerinin çözümü için geliştirilen GOA algoritması, Şekil 3.14'te verilen genel çerçeve referans alınarak çok amaçlı optimizasyon modeline dönüştürülmüştür.

Çizelge 3.32'de verilen tek amaçlı GOA algoritmasının sözde kodundan, popülasyondaki çözüm adaylarının başarısının fitness değeri ($O_{x[i]}$) performans indeksine göre karşılaştırıldığı görülmektedir. Bu yaklaşım, tek amaçlı arama uzaylarında çözüm adaylarını karşılaştırmak için etkili ve popüler bir yöntemdir. Ancak amaç fonksiyonlarının çatışma halinde olduğu p -boyutlu amaç uzayında ($p \geq 2$) (Eşitlik 3.4) çözüm adaylarının başarısını fitness değerine göre karşılaştırmak mümkün değildir [93]. Bu durumda yapılması gereken, Tanım 3, 4, 5 ve 6'da (Çizelge 3.2) detaylı olarak açıklandığı gibi çözüm adaylarının Pareto baskınlık ilişkilerinin dikkate alınmasıdır. Bu tanımlamalar ışığında GOA algoritmasının çok amaçlı optimizasyon modeline dönüştürülmesi için gerçekleştirilen işlemler aşağıdaki gibidir:

- *Arşiv vektörü (A) oluşturuldu:* Arşiv (A), Tanım 3'te ifade edilen Pareto baskınlık kavramı kullanılarak oluşturulmuştur. A vektörü sıralanmış bastırılabilen (non-dominated) çözümleri tutmak için kullanılmıştır. Bastırılabilen çözümlerin sayısı arşiv boyutunu aştığında kalabalıklık mesafesi (crowding-distance) yaklaşımına dayalı sıralama yöntemi kullanılmıştır.

- Çözüm adaylarının birbirlerine üstünlükleri için fitness değeri yerine Pareto baskınlık kavramı kullanıldı: Çözüm adaylarının p -boyutlu arama uzayındaki ($p \geq 2$) önceki ve mevcut konumlarının performansını araştırmak için Pareto optimal kavramı (Tanım 4) kullanılmıştır.
- Seçim süreci yeniden tasarlandı: Çözüm adayları popülasyon (P) yerine arşiv vektöründen (A) seçilmiştir.
- Pareto-set (PS) ve Pareto-front (PF) vektörleri oluşturuldu: MOGOA'da yalnızca bir optimal çözüm yerine, Pareto optimal-set (PS -Tanım 5) ve Pareto optimal-front (PF -Tanım 6) kavramları kullanılmıştır.

MOGOA algoritmasının sözde-kodu Çizelge 3.33'te verilmiştir. Çizelge 3.33 detaylı olarak incelendiğinde MOGOA algoritmasının tasarımı için Şekil 3.14'te verilen genel konseptin uygulandığı görülmektedir. GOA algoritmasının adımları ile Pareto tabanlı arşivleme yönteminin adımları arasında ayırım yapabilmek için Çizelge 3.33'te iki farklı renk kullanılmıştır. İlgili çizelgede yeşil renk ile vurgulanan kısımlar GOA algoritmasının adımlarını temsil ederken mavi renk ile işaretlenen kısımlar kalabalık-mesafesine dayalı Pareto arşivleme yöntemini kullanan baskın olmayan sıralamanın adımlarını göstermektedir.

Çizelge 3.33. MOGOA algoritmasının sözde-kodu.

1.	Başla
2.	A, O_A : Varsayılan bir arşiv oluştur
3.	P : Başlangıç popülasyonunu oluştur
4.	while arama süreci yaşam döngüsü: sonlandırma kriteri sağlanıncaya kadar do
5.	for $i=1: N$ (Çözüm adayları sayısı) do
6.	Popülasyondaki (P) her bir çözüm adayının (x_i) fitness değerini hesapla
7.	$O_{P[i]} = \text{Fitness}(x_{[i]})$
8.	Pareto baskınlık kavramını kullanarak P 'de elit/en iyi çözümü (<i>non-dominated</i>) güncelle (Tanım 3 ve Tanım 4'te gösterildiği gibi)
9.	if $\text{dominates}(O_{P[i]}, \text{Elite_fitness})$ do
10.	$\text{Elite_fitness} = O_{P[i]}, \text{Elite_position} = x_{[i]}$
11.	end if
12.	end for
13.	// Arşiv güncelleme süreci // $[A, O_A] = f_{\text{Archive_Update}}(A, O_A, P, O_P)$
14.	$[C, O_C] = \text{Arşiv}(A, O_A)$ ve popülasyonu (P, O_P) birleştir
15.	for $i=1: N$ (A ve P 'de yer alan çözüm adayı sayısı) do
16.	for $i=1: N-1$ do
17.	PS ve PF vektörlerini oluştur (Tanım 5 ve 6'da ifade edildiği gibi)

Çizelge 3.33. (devam) MOGOA algoritmasının sözde-kodu.

18.	<i>Pareto baskınlık kavramını kullanarak (Tanım 3 ve 4) $[C, O_C]$ için bastırılmayan (non-dominated) çözümler kümesini belirle</i>
19.	end for
20.	end for
21.	if (Bastırılmayan çözümlerin sayısı > Arşiv Boyutu) do
22.	<i>Sıralama (ranking/sorting) süreci: $[C, O_C]$'de yer alan çözüm adaylarının kalabalıklık mesafesini (crowding-distance) hesapla ve en yakın komşularının sayısını belirle</i>
23.	<i>Arşiv yönetimi: Arşivi $[A, O_A]$ yönetmek için kalabalıklık-mesafesi bilgisini ve elitist/rulet seçim yöntemini kullan</i>
24.	end if
25.	// Meta-sezgisel arama süreci //
26.	Adım 1: Seçim Süreci: (Rehber çözüm adaylarının arşivden (A) seçilmesi)
27.	Adım 2: Arama Süreci: (Keşif ve sömürü operatörleri)
28.	Adım 3: Güncelleme Süreci: (Pareto baskınlık kavramına göre arşivin (A) güncellenmesi)
29.	end while
30.	<i>PS and PF</i>
31.	Bitir

4. YENİLENEBİLİR ENERJİ KAYNAKLARI VE YÜKSEK GERİLİM DOĞRU AKIM İLETİM HATTI İÇEREN GÜÇ SİSTEMLERİNDE ÇOK AMAÇLI OPTİMAL GÜÇ AKIŞI

Optimal Güç Akışı (OGA), bir elektrik şebekesinin ekonomik ve verimli çalışması için kararlı durum parametrelerinin belirlenmesini amaçlayan, doğrusal olmayan karmaşık optimizasyon problemidir [118]. OGA problemini çözmek, güç sistemi araştırmacıları arasında popüler ancak zorlu bir görev olmaya devam etmektedir. Araştırmacılar başlangıçta geleneksel OGA problemini sadece termal üretim birimlerini dikkate alarak modellemişlerdir. Fakat son yıllarda artan nüfus ve hızla gelişen teknoloji ile birlikte enerji talebinin artması iletim hatlarının yoğun bir baskıya maruz kalmasına neden olmuştur. Bu nedenle güç sistemlerinin güvenli çalışmasını sağlamak ve iletim hatları üzerindeki baskıyı azaltmak için araştırmacılar güç sistemine Gerilim Kaynağı Dönüştürücü (GKD) tabanlı Çok-Terminalli Yüksek Gerilim Doğru Akım (ÇTYGDA) iletim hatlarını entegre ederek Alternatif Akım/Doğru Akım (AA/DA) optimal güç akışı problemini çözmeye odaklanmışlardır. GKD teknolojisinin gelişimi ile hibrit AA-ÇTYGDA güç sistemlerinin optimal işletimi ve kontrolü güç sistemi araştırmacıları için popüler konulardan biri haline gelmiştir. Günümüzde küresel ısınma, iklim değişikliği ve enerji üretim maliyetlerini düşürmenin kritik gerekliliği gibi sebepler araştırmacıları çevre dostu yenilenebilir enerji kaynaklarını OGA problemine dahil etmeye yöneltmiştir. Bu kapsamda, araştırmacılar yenilenebilir enerji kaynaklarını içeren OGA probleminin çözümünü araştırmışlardır. Fakat tez çalışması kapsamında yapılan literatür taramasında hem GKD tabanlı ÇTYGDA iletim hatlarını hem de rüzgar, güneş, hidro ve gelgit enerji kaynaklarını eş zamanlı olarak içeren OGA probleminin matematiksel formülasyonu ve çözümüne rastlanmamıştır.

Bu çalışmada, rüzgar, güneş, hidro ve gelgit enerji kaynaklarını içeren hibrit alternatif akım-çok terminalli yüksek gerilim doğru akım güç sistemlerinde Çok-Amaçlı Optimal Güç Akışı (ÇAOGA) probleminin modellenmesi ve optimizasyonu literatüre ilk kez sunulmuştur. Rüzgar ve güneş enerjisi kaynaklarının belirsiz gücü, sırasıyla Weibull ve Lognormal Olasılık Dağılım Fonksiyonu (ODF) aracılığıyla simüle edilmiştir. Öte

yandan, hidro ve gelgit enerji kaynaklarının stokastik doğası Gumbel ODF kullanılarak simüle edilmiştir. IEEE 30-baralı test sisteminde yenilenebilir enerji kaynaklarını içeren doğrusal olmayan, yüksek boyutlu ÇAOGA probleminin Pareto optimal çözümlerini elde etmek için çok amaçlı çekirge optimizasyon algoritması (Multi-objective Grasshopper Optimization Algorithm, MOGOA), çok amaçlı salp sürü algoritması (Multi-objective Salp Swarm Algorithm, MSSA [119]), çok amaçlı yusufçuk algoritması (Multi-objective Dragonfly Algorithm, MODA [120]), çok amaçlı karınca aslanı optimize edici (Multi-objective Ant Lion Optimizer, MOALO [121]), ve çok amaçlı halka topolojisi tabanlı parçacık sürü optimizasyon algoritması (Multi-objective Particle Swarm Optimizer Using Ring Topology, MO_Ring_PSO_SCD [122]) kullanılmıştır. Optimizasyon algoritmalarının performansı toplam maliyet, valf noktası etkisi ile toplam maliyet, emisyonlar ve karbon vergisi ile toplam maliyet, gerilim sapması ve aktif güç kayıpları amaç fonksiyonlarının ikili ve üçlü kombinasyonlarını içeren çok amaçlı simülasyon durumları ile test edilmiştir.

Bu bölümün geri kalanı şu şekilde düzenlenmiştir: Bölüm 4.1’de, rüzgâr, güneş, hidro ve gelgit enerji kaynaklarını içeren ÇAOGA probleminin matematiksel formülasyonu sunulmuştur. Bölüm 4.1, durum değişkenleri, kontrol değişkenleri ve enerji kaynaklarının maliyet modellerini içeren üç alt bölümden oluşmaktadır. Bölüm 4.2, rüzgar, güneş, hidro ve gelgit enerji kaynaklarının enerji belirsizliği ve güç modellerini özetler. Bölüm 4.3’te önerilen ÇAOGA probleminin amaç fonksiyonları ve kısıtları sunulmuştur. Bölüm 4.4, yenilenebilir enerji kaynaklarını içeren modifiye IEEE 30-baralı güç sisteminde ÇAOGA probleminin simülasyon sonuçlarını özetler. Bölüm 4.5’te sonuçlar analiz edilmiştir.


4.1. ÇOK AMAÇLI OPTİMAL GÜÇ AKIŞI PROBLEMİNİN MATEMATİKSEL FORMÜLASYONU

Modern güç sistemlerinin planlanması ve işletilmesindeki en önemli problemlerden biri olan OGA, çeşitli eşitlik ve eşitsizlik kısıtlarına tabi olarak minimum yakıt maliyeti elde etmeyi amaçlayan bir optimizasyon problemi olarak modellenmiştir [123], [124]. Bu tez çalışmasında geleneksel OGA probleminin aksine, GKD tabanlı ÇTYGDA iletim hatları ve yenilenebilir enerji kaynakları ile modellenen ÇAOGA problemi ele alınmıştır.

Önerilen çok amaçlı optimizasyon probleminin genel formu Eşitlik (4.1)'de gösterilmiştir [93]:

$$\begin{aligned}
 & \text{minimize } F = \{ F_1(Y, Z), F_2(Y, Z) \dots, F_m(Y, Z) \} \\
 & \text{subject to } g(Y, Z) = 0 \\
 & \quad \quad \quad h(Y, Z) \leq 0
 \end{aligned} \tag{4.1}$$

Eşitlik (4.1)'de m amaç fonksiyonu sayısını, $F_j(Y, Z)$ ($j = 1, 2, \dots, m$) ÇAOGA probleminin j . amaç fonksiyonunu gösterir. Y ve Z , durum ve kontrol değişkenleri (optimize edilen) vektörleridir. $g(Y, Z)$ ve $h(Y, Z)$ sırasıyla eşitlik ve eşitsizlik kısıtları olarak tanımlanır. ÇAOGA problemi, toplam maliyet, valf noktası etkisi ile toplam maliyet, emisyonlar ve karbon vergisi ile toplam maliyet, gerilim sapması ve aktif güç güç kayıpları amaç fonksiyonlarının ikili ve üçlü konfigürasyonlarını optimize eder. Önerilen ÇAOGA probleminin şematik diyagramı Şekil 4.1'de gösterilmiştir.



Şekil 4.1. Önerilen ÇAOGA probleminin şematik diyagramı.

4.1.1. Durum Değişkenleri

Önerilen ÇAOGA probleminin AA şebeke ile ilgili durum değişkenleri aşağıdaki gibi listelenebilir:

- i. Salınım jeneratörü aktif gücü P_{TG_1}
- ii. Yük barası gerilim büyüklüğü V_L
- iii. Termal jeneratörün reaktif gücü Q_{TG}
- iv. Rüzgar jeneratörünün reaktif gücü Q_{WS}
- v. Kombine güneş-hidro enerji sisteminin reaktif gücü Q_{PVSH}
- vi. Kombine rüzgar-gelgit enerji sisteminin reaktif gücü Q_{WS+TDL}
- vii. İletim hattı yüklenebilirliği S_L

ÇAOGA optimizasyon probleminin AA şebeke durum değişkenleri vektör formunda aşağıdaki gibi gösterilir:

$$Y_{AA} = \left[P_{TG_1}, V_{L_1} \dots V_{L_{NPQ}}, Q_{TG_1} \dots Q_{TG_{NTG}}, Q_{WS_1} \dots Q_{WS_{NWS}}, Q_{PVSH_1} \dots Q_{PVSH_{NPVSH}}, Q_{WS+TDL_1} \dots Q_{WS+TDL_{NWSTD L}}, S_{L_1} \dots S_{L_{NTL}} \right] \quad (4.2)$$

Eşitlik (4.2)'de P_{TG_1} salınım jeneratörünün aktif güç çıkışını, V_L yük baralarının gerilim büyüklüğünü gösterir. Q_{TG} , Q_{WS} , Q_{PVSH} and Q_{WS+TDL} termal üretim birimlerinin, rüzgar çiftliği, kombine güneş-hidro ve kombine rüzgar-gelgit enerji sistemlerinin reaktif gücünü temsil eder. S_L iletim hattı yüklenebilirliğini göstermektedir. NTG , NPQ , NWS , $NPVSH$, $NWSTD L$ ve NTL sırasıyla termal jeneratörler, yük baraları, rüzgar enerjisi üniteleri, kombine güneş-hidro güç üniteleri, kombine rüzgar-gelgit enerjisi sistemleri ve iletim hatlarının sayısını gösterir.

GKD tabanlı ÇTYGDA şebekenin durum değişkenleri iki kategoriye ayrılmıştır. Birincisi DA bara gerilimleri, ikincisi DA iletim hatlarındaki güç akışıdır.

4.1.2. Kontrol Değişkenleri

Önerilen ÇAOGA probleminin kontrol değişkenleri aşağıdaki gibidir:

- i. Termal jeneratörlerin (salınım jeneratörü hariç) aktif gücü P_{TG}
- ii. Rüzgar jeneratörünün aktif gücü P_{WS}
- iii. Kombine güneş-hidro enerji sisteminin aktif gücü P_{PVSH}
- iv. Kombine rüzgar-gelgit enerji sisteminin aktif gücü P_{WS+TDL}
- v. Termal jeneratör gerilim büyüklüğü V_{TG}
- vi. Transformatör kademe ayarı T

vii. GKD kontrol parametreleri ($V_{dc_i}, V_{c_i}, P_{s_i}, Q_{s_i}$)

Güç akışını düzenlemek için optimize edilmesi gereken kontrol değişkenleri Eşitlik (4.3)'te gösterilen Z vektörü ile temsil edilir. Z vektörü AA ve DA şebekelerine ait kontrol değişkenlerinden oluşmaktadır.

$$Z = [Z_{AA}, Z_{CTYGDA}]$$

$$Z_{AA} = \begin{bmatrix} P_{TG_2} \dots P_{TG_{NTG}}, P_{WS_1} \dots P_{WS_{NWS}}, P_{PVSH_1} \dots P_{PVSH_{NPVSH}}, P_{WS+TDL_1} \dots P_{WS+TDL_{NWSTDL}}, \\ V_{TG_1} \dots V_{TG_{NTG}}, T_1 \dots T_{NT} \end{bmatrix} \quad (4.3)$$

$$Z_{CTYGDA} = [V_{dc_i}, V_{c_i}, P_{s_i}, Q_{s_i}]$$

Eşitlik (4.3)'te P_{TG} salınım jeneratörü haricindeki termal jeneratörlerin aktif gücünü, P_{WS} , P_{PVSH} ve P_{WS+TDL} sırasıyla rüzgar çiftliği, kombine güneş-hidro ve kombine rüzgar-gelgit enerji sistemlerinin aktif gücünü göstermektedir. V_{TG} termal jeneratörlerin gerilim büyüklüğü olarak tanımlanır. NT transformatör sayısını gösterir. V_{dc_i} DA şebekedeki i . baranın gerilim büyüklüğüdür. V_{c_i} , gerilim kaynağı dönüştürücünün AA terminalindeki gerilim büyüklüğünü göstermektedir. P_{s_i} ve Q_{s_i} , AA şebekeye bağlı dönüştürücüden gelen aktif ve reaktif güç değeridir.

4.1.3. Enerji Kaynaklarının Maliyet Modelleri

4.1.3.1. Termal Jeneratörlerin Üretim Maliyeti

Termal jeneratörlerin yakıt veya üretim maliyeti (\$/h), üretilen aktif güç (MW) çıkışına dayalı ikinci dereceden bir maliyet fonksiyonu ile modellenir [39].

$$CF_0(P_{TG}) = \sum_{i=1}^{NTG} m_i + l_i P_{TGi} + k_i P_{TGi}^2 \quad (4.4)$$

Eşitlik (4.4)'te m_i , l_i ve k_i , P_{TGi} güç çıkışını üreten i . termal jeneratörün maliyet katsayılarıdır. NTG termal jeneratör sayısını temsil eder.

Maliyet fonksiyonunun daha gerçekçi ve hassas bir şekilde modellenmesi için valf noktası etkisinin dikkate alınması gerekir. Çok valfli buhar türbinlerinin valf yükleme etkisi mutlak değeri Eşitlik (4.4)'teki temel maliyet fonksiyonuna eklenen sinüzoidal fonksiyon olarak modellenmiştir [39].

$$CF(P_{TG}) = \sum_{i=1}^{NTG} m_i + l_i P_{TGi} + k_i P_{TGi}^2 + |n_i \times \sin(r_i \times (P_{TGi}^{min} - P_{TGi}))| \quad (4.5)$$

Eşitlik (4.5)'teki n_i ve r_i , valf nokta etkisini temsil eden katsayılardır. P_{TGi}^{min} , i . termal ünitenin ürettiği minimum güç değeridir.

4.1.3.2. Termal Jeneratörlerin Emisyon ve Karbon Vergisi Modeli

Fosil yakıt ile çalışan termal jeneratörlerden kaynaklanan toplam emisyon değeri Eşitlik (4.6)'da verilen matematiksel model kullanılarak hesaplanmaktadır. Ayrıca, artan küresel ısınma nedeniyle bir karbon vergisi modeli düşünülmüş ve Eşitlik (4.7)'de gösterildiği gibi karbon vergisi değeri toplam emisyona eklenerek emisyon maliyet değeri hesaplanmıştır [39], [125].

$$E_{total} = \sum_{i=1}^{NTG} ((\mu_i + \varphi_i P_{TGi} + \alpha_i P_{TGi}^2) \times 0.01 + \gamma_i e^{(\xi_i P_{TGi})}) \quad (4.6)$$

$$C_E = C_{tax} \times E_{total} \quad (4.7)$$

Eşitlik (4.6) ve (4.7)'de E_{total} , C_E ve C_{tax} sırasıyla toplam emisyon, emisyon maliyeti ve vergi değerleridir. μ_i , φ_i , α_i , γ_i , ve ξ_i , i . termal jeneratör için emisyon katsayılarını temsil eder. Termal üretim birimleri için maliyet ve emisyon katsayıları Çizelge 4.3'te verilmiştir.

4.1.3.3. Yenilenebilir Enerji Kaynaklarının Doğrudan Maliyet Modeli

Rüzgâr enerjisi kaynağının doğrudan maliyet modeli, planlanmış gücün doğrusal fonksiyonu ile gösterilmektedir. Eşitlik (4.8)'de DC_W , wp ve P_{WS} rüzgâr gücünün doğrudan maliyet fonksiyonunu, doğrudan maliyet katsayısını ve i . rüzgâr enerjisi sisteminin planlanmış gücünü temsil eder [39].

$$DC_W = CF_W(P_{WS}) = wp \times P_{WS} \quad (4.8)$$

Kombine güneş ve hidro enerji santralinin doğrudan maliyeti ilgili enerji kaynakları maliyetlerinin toplamından elde edilmektedir. Kombine enerji santralinin doğrudan maliyet modeli Eşitlik (4.9)'da verilmiştir. DC_{PVSH} kombine güneş-hidro elektrik santralinin doğrudan maliyetini, $P_{PVSH,s}$ ve $P_{PVSH,sh}$ sırasıyla güneş ve hidro enerji santrallerinin planlanmış gücünü gösterir. pv ve sh güneş ve hidro enerji ünitelerinin maliyet katsayılarıdır [126].

$$\begin{aligned} DC_{PVSH} &= CF_{PVSH} (P_{PVSH,s} + P_{PVSH,sh}) \\ &= (pv_i \times P_{PVSH,s}) + (sh_i \times P_{PVSH,sh}) \end{aligned} \quad (4.9)$$

Kombine rüzgar ve gelgit enerji santralinin doğrudan maliyeti ilgili enerji kaynakları maliyetlerinin toplamından elde edilir. Eşitlik (4.10) kombine enerji santralinin doğrudan maliyet modelini göstermektedir. Eşitlik (4.10)'da $DC_{WSTDL,i}$ kombine rüzgar-gelgit enerji santralinin doğrudan maliyet fonksiyonunu gösterir. $P_{TDLs,i}$ gelgit enerjisinin planlanmış gücüdür. tdl,i gelgit enerjisi maliyet katsayısıdır [125].

$$DC_{WSTDL,i} = CF_{WSTDL,i}(P_{WS+TDL,i}) = (wp,i \times P_{WS,i}) + (tdl,i \times P_{TDLs,i}) \quad (4.10)$$

4.1.3.4. Yenilenebilir Enerji Kaynaklarının Belirsizlik Maliyet Modeli

Rüzgar, kombine güneş-hidro ve kombine rüzgar-gelgit enerji sistemlerinin belirsizlik maliyet modelleri, yenilenebilir enerji kaynaklarının fazla (overestimation) ve eksik tahmin (underestimation) durumları dikkate alınarak modellenmiştir.

Eşitlikler (4.11) ve (4.12) rüzgar enerjisinin belirsizlik maliyet modellerini tanımlamaktadır. Bu eşitliklerde, OC_W ve UC_W rüzgar gücünün fazla ve eksik tahmin maliyet değerlerini gösterir. C_{OW} ve C_{UW} belirsizlik maliyet katsayılarını temsil eder. P_{wav} and P_{wr} , sırasıyla rüzgar çiftliğinin mevcut ve nominal gücü olarak tanımlanır [39], [126].

$$OC_W = C_{OW}(P_{WS} - P_{wav}) = C_{OW} \int_0^{P_{WS}} (P_{WS} - p_w) f_w(p_w) dp_w \quad (4.11)$$

$$UC_W = C_{UW}(P_{wav} - P_{WS}) = C_{UW} \int_{P_{WS}}^{P_{wr}} (p_w - P_{WS}) f_w(p_w) dp_w \quad (4.12)$$

Kombine güneş-hidro elektrik enerjisi, aktif güç üretim ünitesi olarak modellenmiştir. Kombine enerji santrali için fazla ve eksik tahmin durumlarını içeren belirsizlik modelleri sırasıyla Eşitlik (4.13) ve (4.14)'te verilmiştir. Burada, OC_{PVSH} ve UC_{PVSH} kombine enerji ünitesinin fazla ve eksik tahmin maliyet değerlerini gösterir. C_{Opvsh} ve C_{Upvsh} belirsizlik maliyet katsayılarıdır. P_{PVSHav} kombine güneş-hidro enerji ünitesinin mevcut gücünü temsil eder [126].

$$\begin{aligned} OC_{PVSH} &= C_{Opvsh}(P_{PVSH} - P_{PVSHav}) \\ &= C_{Opvsh} * f_{PVSH}(P_{PVSHav} < P_{PVSH}) \\ &\quad * [P_{PVSH} - E(P_{PVSHav} < P_{PVSH})] \end{aligned} \quad (4.13)$$

$$\begin{aligned}
UC_{PVSH} &= C_{Upvsh}(P_{PVSHav} - P_{PVSH}) \\
&= C_{Upvsh} * f_{PVSH} (P_{PVSHav} > P_{PVSH}) \\
&\quad * [E (P_{PVSHav} > P_{PVSH}) - P_{PVSH}]
\end{aligned} \tag{4.14}$$

Gelgit enerji sistemi, aktif güç üretim birimi olarak modellenmiştir. Eşitlik (4.15) ve (4.16) gelgit enerji sisteminin fazla ve eksik tahmin maliyet modellerini göstermektedir. Burada, OC_{TDL} ve UC_{TDL} gelgit enerji sisteminin fazla ve eksik tahmin maliyet değerlerini tanımlar. C_{Otdl} ve C_{Utdl} belirsizlik maliyet katsayılarıdır. P_{TDLav} , gelgit enerji santralinin mevcut gücünü temsil eder [125].

$$\begin{aligned}
OC_{TDL} &= C_{Otdl}(P_{TDL} - P_{TDLav}) \\
&= C_{Otdl} * f_{TDL} (P_{TDLav} < P_{TDL}) \\
&\quad * [P_{TDL} - E (P_{TDLav} < P_{TDL})]
\end{aligned} \tag{4.15}$$

$$\begin{aligned}
UC_{TDL} &= C_{Utdl}(P_{TDLav} - P_{TDL}) \\
&= C_{Utdl} * f_{TDL} (P_{TDLav} > P_{TDL}) \\
&\quad * [E (P_{TDLav} > P_{TDL}) - P_{TDL}]
\end{aligned} \tag{4.16}$$

4.2. RÜZGAR/GÜNEŞ/HİDRO/GELGİT ENERJİSİ VE BELİRSİZLİK MODELLERİ

4.2.1. Rüzgâr Enerjisi Ünitelerinin Stokastik Gücünün Hesaplanması

Rüzgâr hızı dağılımının Weibull olasılık yoğunluk fonksiyonunu izlediği iyi bilinmektedir [127]-[129]. Şekil faktörü (λ) ve ölçek faktörü (ω) ile Weibull dağılımını takip eden rüzgâr hızı v_w m/s olasılığı matematiksel olarak Eşitlik (4.17) ile temsil edilmektedir [39].

$$f_v(v_w) = \left(\frac{\lambda}{\omega}\right) \left(\frac{v_w}{\omega}\right)^{(\lambda-1)} \left(\exp\left(-\left(\frac{v_w}{\omega}\right)^\lambda\right)\right) \quad 0 < v_w < \infty \tag{4.17}$$

Bu tez çalışmasında, IEEE 30-baralı test sisteminin 8 ve 13 numaralı baralarındaki geleneksel jeneratörler, rüzgâr enerjisi ile değiştirilmiştir. Weibull şekil (λ) ve ölçek (ω) parametrelerinin seçilen değerleri Çizelge 4.1’de verilmiştir. Şekil 4.2, 8000 Monte-Carlo senaryosu çalıştırıldıktan sonra elde edilen Weibull ve rüzgâr hızı frekans dağılımlarını göstermektedir. Bara 5’e bağlı rüzgâr çiftliği her biri 3 MW’lık benzer karakteristiğe sahip 25 türbinden oluşmaktadır ve toplam çiftlik kapasitesi 75 MW’dır. Bara 13’e bağlı rüzgâr çiftliği ise her biri 3 MW’lık benzer karakteristiğe sahip 10 türbinden oluşmaktadır

ve toplam çiftlik kapasitesi 30 MW değerindedir.

Bir rüzgâr türbininin çıkış gücü (p_w), rüzgâr hızına (v_w) bağlı olarak değişir. Çıkış gücü ve rüzgâr hızı arasındaki ilişki Eşitlik (4.18)'de verilmiştir [39].

$$p_w(v_w) = \begin{cases} 0 & v_w < v_{in} \text{ and } v_w > v_{out} \\ p_{wr} \left(\frac{v_w - v_{in}}{v_r - v_{in}} \right)^3 & v_{in} \leq v_w \leq v_r \\ p_{wr} & v_r < v_w < v_{out} \end{cases} \quad (4.18)$$

Eşitlik (4.18)'de p_{wr} tek bir rüzgâr türbininin nominal çıkış gücüdür. v_{in} , v_r and v_{out} sırasıyla türbinin devreye girme (cut-in), anma (rated) ve devreden çıkma (cut-out) rüzgâr hızlarıdır. Enercon E82-E4 türbin verileri doğrultusunda çeşitli hız değerleri şu şekilde seçilmiştir: $v_{in}=3$ m/s, $v_r= 16$ m/s ve $v_{out}=25$ m/s [39].

Rüzgâr türbini çıkış gücü, Eşitlik (4.18)'de gösterildiği gibi belirli rüzgâr hızlarında ayrıktır. Rüzgâr hızı (v_w), devreye girme hızının (v_{in}) altında veya devreden çıkma hızının (v_{out}) üstünde olduğunda güç çıkışı sıfırdır. Nominal rüzgâr hızı (v_r) ve devreden çıkma hızı (v_{out}) arasında türbin nominal güç (p_{wr}) üretir. Bu ayrık bölgeler için rüzgâr gücü olasılıkları aşağıdaki gibi hesaplanır [39]:

$$f_w(p_w)\{p_w = 0\} = 1 - e^{-\left(\frac{v_{in}}{\omega}\right)^\lambda} + e^{-\left(\frac{v_{out}}{\omega}\right)^\lambda} \quad (4.19)$$

$$f_w(p_w)\{p_w = p_{wr}\} = e^{-\left(\frac{v_r}{\omega}\right)^\lambda} - e^{-\left(\frac{v_{out}}{\omega}\right)^\lambda} \quad (4.20)$$

Rüzgâr türbini güç çıkışı, rüzgârın devreye girme hızı (v_{in}) ile nominal hızı (v_r) arasında süreklidir. Sürekli bölge için olasılık değeri Eşitlik (4.21) kullanılarak hesaplanır [39].

$$f_w(p_w) = \left[\frac{\lambda(v_r - v_{in})}{\omega^\lambda p_{wr}} \right] \times \left(v_{in} + \left(\frac{p_w}{p_{wr}} \right) (v_r - v_{in}) \right)^{\lambda-1} \times e^{-\left(\frac{v_{in} + \left(\frac{p_w}{p_{wr}} \right) (v_r - v_{in})}{\omega} \right)^\lambda} \quad (4.21)$$

4.2.2. Güneş Enerjisi Ünitelerinin Stokastik Gücünün Hesaplanması

Lognormal olasılık dağılım fonksiyonunun, güneş ışınlamı (G_{pv}) dağılımını başarılı bir şekilde temsil ettiği iyi bilinmektedir [130], [131]. Ortalama ξ ve standart sapma ϑ parametreleri ile Lognormal olasılık dağılımını takip eden güneş ışınlamının (G_{pv}) olasılığı aşağıdaki gibi hesaplanır [39]:

$$f_G(G_{pv}) = \frac{1}{G_{pv} \vartheta \sqrt{2\pi}} e^{\frac{-(\ln G_{pv} - \xi)^2}{2\vartheta^2}} \quad for \ G_{pv} > 0 \quad (4.22)$$

IEEE 30-baralı test sisteminin 11 numaralı barasındaki termal jeneratör, solar PV ünitesi ile değiştirilmiştir. 8000 örneklem büyüklüğünde Monte Carlo simülasyonu çalıştırıldıktan sonra, Çizelge 4.1’de verilen ODF parametreleri (ξ ve ϑ) kullanılarak elde edilen güneş ışınlımı Lognormal eğrisi ve frekans dağılımı Şekil 4.2 (c)’de gösterilmiştir.

Solar PV için güneş ışınlımının (G_{pv}) enerjiye dönüşümü Eşitlik (4.23) kullanılarak hesaplanmaktadır [39].

$$P_{pv}(G_{pv}) = \begin{cases} P_{pv,rate} \times \left(\frac{G_{pv}^2}{G_{pvstd} \times R_C} \right) & for \ 0 < G_{pv} < R_C \\ P_{pv,rate} \times \left(\frac{G_{pv}}{G_{pvstd}} \right) & for \ G_{pv} \geq R_C \end{cases} \quad (4.23)$$

Eşitlik (4.23)’te G_{pvstd} standart ortamdaki güneş ışınlımını temsil eder. $G_{pvstd} = 1000 \text{ W/m}^2$ olarak ayarlanmıştır. $R_C = 180 \text{ W/m}^2$ olarak ayarlanmış belirli bir ışınlım noktasıdır. $P_{pv,rate}$ solar PV ünitesinin nominal çıkış gücüdür [93].

4.2.3. Hidro Enerji Ünitelerinin Stokastik Gücünün Hesaplanması

Nehir akış hızının Gumbel dağılımını takip ettiği iyi bilinmektedir [132], [133]. Konum (ψ) ve ölçek ($\tilde{Y}$) parametreleri ile Gumbel dağılımını takip eden nehir akış hızının Q_{wsh} olasılığı Eşitlik (4.24) kullanılarak hesaplanır [126].

$$f_Q(Q_{wsh}) = \frac{1}{\tilde{Y}} \exp\left(\frac{Q_{wsh} - \psi}{\tilde{Y}}\right) \exp\left(-\exp\left(\frac{Q_{wsh} - \psi}{\tilde{Y}}\right)\right) \quad (4.24)$$

IEEE 30-baralı test sisteminin 11 numaralı barasına termal jeneratör yerine, solar PV ünitesi ile birlikte hidro enerji ünitesi entegre edilmiştir. Şekil 4.2 (d), nehir akış hızı frekans dağılımı ve Gumbel eğrisini göstermektedir. Şekilde verilen eğriler, Çizelge 4.1’deki ODF parametreleri (ψ , $\tilde{Y}$) ile 8000 Monte Carlo senaryosu çalıştırıldıktan sonra elde edilmiştir.

Küçük bir hidro üniteden elde edilen güç çıkışı, su akış hızına (Q_{wsh}) ve etkin basınç değerine (H_{wsh}) bağlıdır. Küçük hidro ünitenin güç çıkışı matematiksel olarak Eşitlik (4.25) ile modellenir [126].

$$P_{SH}(Q_{wsh}) = \eta \times \varphi \times g \times Q_{wsh} \times H_{wsh} \quad (4.25)$$

Eşitlik (4.25)'te η türbin-jeneratör tertibatının verimi, φ su yoğunluğu ve g yerçekiminden kaynaklanan ivmedir. Hidroelektrik hesabında dikkate alınan parametrelerin nümerik değerleri şu şekildedir: $\eta = 0,85$, $\varphi = 1000 \text{ kg/m}^3$, $g = 9,81 \text{ m/s}^2$, and $H_{wsh} = 25 \text{ m}$ [126].

4.2.4. Gelgit Enerjisi Stokastik Gücünün Hesaplanması

Gelgit aralığındaki deşarj hızının (Q_{TDL}) olasılık modeli, Eşitlik (4.26)'da gösterildiği gibi Gumbel dağılımı kullanılarak tanımlanmıştır [125].

$$f_{Q_{TDL}}(Q_{TDL}) = \frac{1}{\zeta} e^{\left(\frac{Q_{TDL}-\psi}{\zeta}\right)} e^{\left(-e^{\left(\frac{Q_{TDL}-\psi}{\zeta}\right)}\right)} \quad (4.26)$$

IEEE 30-baralı test sisteminin 13 numaralı barasına termal jeneratörün yerine, rüzgar enerji ünitesi ile birlikte gelgit enerji ünitesi entegre edilmiştir. Gelgit enerjisinin çıkış gücü Eşitlik (4.27) kullanılarak hesaplanır [125].

$$P_{TDL}(Q_{TDL}) = \beta \times g \times Q_{TDL} \times H \times \eta \quad (4.27)$$

Eşitlik (4.27)'de β su yoğunluğu (kg/m^3), g yer çekimi ivmesi (m/s^2), Q_{TDL} türbin boyunca deşarj değeri (m^3/s), H yüksek ve düşük su seviyeleri arasındaki fark, η ise türbin verimidir. Gelgit aralığı sistem parametrelerinin sayısal değerleri şu şekildedir: $\beta = 1025 \text{ kg/m}^3$, $g = 9,81 \text{ m/s}^2$, $H = 3,2 \text{ m}$, and $\eta = 0,85$ [125].


Çizelge 4.1. Yenilenebilir enerji kaynaklarının stokastik modelleri için ODF parametreleri.

Modifiye IEEE 30-baralı test sistemi					
Rüzgar Enerjisi Sistemi (Bara:8)					
Türbin Sayısı	Toplam anma gücü (p_{wr})			Weibull dağılım parametreleri	
15	45 MW			$\lambda=2$	$\omega=10$
Kombine Güneş-Hidro Enerji Sistemi (Bara:11)					
Güneş Enerjisi Sistemi			Hidro Enerjisi Sistemi		
Toplam anma gücü ($P_{pv,rate}$)	Lognormal dağılım parametreleri		Anma gücü (P_{SH})	Gumbel dağılım parametreleri	
45 MW	$\xi=5$	$\vartheta=0.6$	5 MW	$\psi=15$	$\Upsilon=1.2$

Çizelge 4.1. (devam) Yenilenebilir enerji kaynaklarının stokastik modelleri için ODF parametreleri.



Kombine Rüzgar-Gelgit Enerji Sistemi (Bara:13)						
Rüzgar Enerji Sistemi				Gelgit Enerji Sistemi		
Türbin Sayısı	Toplam anma gücü (P_{wr})	Weibull dağılım parametreleri		Anma gücü (P_{TDL})	Gumbel dağılım parametreleri	
10	30 MW	$\lambda=2$	$\omega=9$	10 MW	$\psi=220$	$\zeta=24.52$

Şekil 4.2 (a-e), 8000 örneklem büyüklüğünde Monte Carlo simülasyonu çalıştırıldıktan sonra Weibull, Lognormal ve Gumbel olasılıksal dağılım fonksiyonları kullanılarak elde edilen rüzgâr hızı (v_w), güneş ışıınımı (G_{pv}), nehir akış hızı (Q_{wsh}) ve deşarj hızının (Q_{TDL}) frekans dağılımını gösterir.





(a)

Şekil 4.2. (a) ve (b) Bara 8 ve 13'teki rüzgâr çiftliği için rüzgâr hızı (v_w) dağılımı, (c) Bara 11'deki PV sistem için solar radyasyon (G_{pv}) dağılımı, (d) Bara 11'deki hidro enerji ünitesi için nehir akış hızı (Q_{wsh}) dağılımı (e) Bara 13'teki gelgit enerjisi için deşarj oranı (Q_{TDL}) dağılımı.



Şekil 4.2. (devam) (a) ve (b) Bara 8 ve 13'teki rüzgâr çiftliği için rüzgâr hızı (v_w) dağılımı, (c) Bara 11'deki PV sistem için solar radyasyon (G_{pv}) dağılımı, (d) Bara 11'deki hidro enerji ünitesi için nehir akış hızı (Q_{wsh}) dağılımı (e) Bara 13'teki gelgit enerjisi için deşarj oranı (Q_{TDL}) dağılımı.



Şekil 4.2. (devam) (a) ve (b) Bara 8 ve 13'teki rüzgâr çiftliği için rüzgâr hızı (v_w) dağılımı, (c) Bara 11'deki PV sistem için solar radyasyon (G_{pv}) dağılımı, (d) Bara 11'deki hidro enerji ünitesi için nehir akış hızı (Q_{wsh}) dağılımı (e) Bara 13'teki gelgit enerjisi için deşarj oranı (Q_{TDL}) dağılımı.

4.3. AMAÇ FONKSİYONLARI VE KISITLAR

4.3.1. Amaç Fonksiyonları

4.3.1.1. Toplam Üretim Maliyeti

Termal jeneratörler ve yenilenebilir enerji kaynaklarının toplam üretim maliyeti Eşitlik (4.28) ile hesaplanır.

$$\begin{aligned} F_{obj}(Y, Z) &= F_{obj1} \\ &= CF_0(P_{TG}) \\ &+ \sum_{i=1}^{NW} (DC_{W,i} + OC_{W,i} + UC_{W,i}) \\ &+ \sum_{i=1}^{NPVSH} (DC_{PVSH,i} + OC_{PVSH,i} + UC_{PVSH,i}) \\ &+ \sum_{i=1}^{NWSTD L} (DC_{WSTD L,i} + OC_{W,i} + OC_{TDL,i} + UC_{W,i} + UC_{TDL,i}) \end{aligned} \quad (4.28)$$

4.3.1.2. Valf Nokta Etkisi ile Toplam Üretim Maliyeti

Termal jeneratörlerin yanı sıra rüzgar, kombine güneş-hidro ve kombine rüzgar-gelgit enerji kaynaklarını içeren önerilen ÇAOGA probleminin valf noktası etkisi ile toplam üretim maliyeti Eşitlik (4.29) kullanılarak hesaplanır.

$$\begin{aligned} F_{obj}(Y, Z) &= F_{obj2} \\ &= CF(P_{TG}) \\ &+ \sum_{i=1}^{NW} (DC_{W,i} + OC_{W,i} + UC_{W,i}) \\ &+ \sum_{i=1}^{NPVSH} (DC_{PVSH,i} + OC_{PVSH,i} + UC_{PVSH,i}) \\ &+ \sum_{i=1}^{NWSTD L} (DC_{WSTD L,i} + OC_{W,i} + OC_{TDL,i} + UC_{W,i} + UC_{TDL,i}) \end{aligned} \quad (4.29)$$

4.3.1.3. Emisyon ve Karbon Vergisi ile Toplam Üretim Maliyeti

Fosil yakıt kullanarak çalışan termal jeneratörlerden kaynaklanan toplam emisyon değeri ve artan küresel ısınma nedeniyle dikkate alınan karbon vergisi modelini içeren toplam üretim maliyeti amaç fonksiyonu Eşitlik (4.30)'da verilmiştir.

$$\begin{aligned}
F_{obj}(Y, Z) &= F_{obj3} \\
&= CF(P_{TG}) \\
&+ \sum_{i=1}^{NW} (DC_{W,i} + OC_{W,i} + UC_{W,i}) \\
&+ \sum_{i=1}^{NPVSH} (DC_{PVSH,i} + OC_{PVSH,i} + UC_{PVSH,i}) \\
&+ \sum_{i=1}^{NWSTD L} (DC_{WSTD L,i} + OC_{W,i} + OC_{TDL,i} + UC_{W,i} + UC_{TDL,i}) + C_{E(P_{TG})}
\end{aligned} \tag{4.30}$$

4.3.1.4. Gerilim Sapması

Voltaj büyüklüğündeki küçük bir değişikliğin tüm sistemi etkilemesi ve şebekenin devre dışı kalması gibi nedenlerden dolayı gerilim sapması modern güç sistemlerinde en önemli güvenlik indekslerinden biri olarak kabul edilmektedir [134], [135]. ÇAOGA probleminde hibrit AA-DA güç sistemi için gerilim sapması amaç fonksiyonu aşağıdaki gibidir [33]:

$$F_{obj}(Y, Z) = F_{obj4} = \sum_{i=1}^{NPQ} (V_{L_i} - 1)^2 + \sum_{m=1}^{N_{DA}} (V_{dc,m} - 1)^2 \tag{4.31}$$

Eşitlik (4.31)'de, V_{L_i} and $V_{dc,m}$ sırasıyla i . AC yük barasının ve m . DA baranın gerilim büyüklüklerini temsil eder. NPQ , AC şebekedeki yük baralarının sayısını, N_{DA} , DA şebeke bara sayısını gösterir.

4.3.1.5. Aktif Güç Kayıpları

Aktif güç kayıpları minimizasyonu amaç fonksiyonu Eşitlik (4.32)'de gösterilmiştir [38], [136].

$$F_{obj}(Y, Z) = F_{obj5} = P_{loss_AA} + P_{loss_DA} + P_{loss_GKD} \tag{4.32}$$

AA ve DA şebekelerdeki güç kayıpları sırasıyla Eşitlik (4.33) ve (4.34) kullanılarak hesaplanmaktadır [38].

$$P_{loss_AA} = \sum_{i,j \in N_{AA}} G_{ij} [V_i^2 + V_j^2 - 2 V_i V_j \cos(\delta_i - \delta_j)] \tag{4.33}$$

$$P_{loss_DA} = \sum_{i,j \in N_{DA}} R_{ij} I_{ij}^2 \tag{4.34}$$

GKD kayıpları, Eşitlik (4.35)'te gösterildiği gibi dönüştürücü akımının ikinci dereceden bir fonksiyonu ile modellenir. Burada, ψ_1 , ψ_2 , ve ψ_3 , GKD kayıp katsayılarını, N_{GKD} ise gerilim kaynağı dönüştürücü sayısını göstermektedir [38].

$$P_{loss_GKD} = \sum_{i=1}^{N_{GKD}} \psi_{1,i} I_{c,i}^2 + \psi_{2,i} I_{c,i} + \psi_{3,i} \quad (4.35)$$

4.3.2. Problem Kısıtları

4.3.2.1. Eşitlik Kısıtları

Bu alt bölümde, yenilenebilir enerji kaynaklarını içeren ÇAOGA probleminin eşitlik kısıtları sunulmuştur. AA şebeke yük akışı güç dengesi denklemleri aşağıdaki gibidir [137].

$$P_{Gi} - P_{Li} - V_i \sum_{j=1}^{N_{AA}} V_j [G_{ij} \cos(\delta_i - \delta_j) + B_{ij} \sin(\delta_i - \delta_j)] = 0 \quad i = 1, 2, \dots, N_{AA} \quad (4.36)$$

$$Q_{Gi} + Q_{ci} - Q_{Li} - V_i \sum_{j=1}^{N_{AA}} V_j [G_{ij} \sin(\delta_i - \delta_j) - B_{ij} \cos(\delta_i - \delta_j)] = 0 \quad i = 1, 2, \dots, N_{AA} \quad (4.37)$$

Eşitlik (4.36)'da P_{Gi} and P_{Li} sırasıyla i . üretim biriminin (termal, rüzgar, kombine güneş-hidro ve kombine rüzgar-gelgit) ve yük baralarının aktif gücüdür. Eşitlik (4.37)'de kullanılan Q_{Gi} , Q_{ci} and Q_{Li} sırasıyla i . üretim birimi (termal, rüzgar, kombine güneş-hidro ve kombine rüzgar-gelgit), şönt VAR kompanzatör ve yük baralarının reaktif gücünü gösterir. V_i , V_j , δ_i ve δ_j sırasıyla i . ve j . bara için gerilim büyüklüğü ve gerilim fazör açılarını temsil eder. G_{ij} ve B_{ij} , i . ve j . baralar arasındaki iletim hattının iletkenlik ve süseptans değerleridir.

DA şebeke yük akışı matematiksel olarak Eşitlik (4.38)'de gösterildiği gibi formüle edilmiştir [138]:

$$P_{dc,i} = V_{dc,i} \sum_{\substack{i=1 \\ i \neq j}}^{N_{GKD}} G_{dc,ij} (V_{dc,i} - V_{dc,j}) \quad (4.38)$$

Eşitlik (4.38)'de $P_{dc,i}$ DA iletim hattındaki aktif güç akışını gösterir. $G_{dc,ij}$, i . ve j . DA baraları arasındaki hattın iletkenliğini gösterir. $V_{dc,i}$ ve $V_{dc,j}$, sırasıyla i . ve j . DA baralarının gerilim büyüklükleri olarak tanımlanır.

4.3.2.2. Eşitsizlik Kısıtları

AA şebeke eşitsizlik kısıtları matematiksel olarak Eşitlikler (4.39)-(4.50)'de modellenmiştir.

$$P_{TG,i}^{min} \leq P_{TG,i} \leq P_{TG,i}^{max} \quad \forall i \in NTG \quad (4.39)$$

$$P_{WS,i}^{min} \leq P_{WS,i} \leq P_{WS,i}^{max} \quad \forall i \in NWS \quad (4.40)$$

$$P_{PVSH,i}^{min} \leq P_{PVSH,i} \leq P_{PVSH,i}^{max} \quad \forall i \in NPVSH \quad (4.41)$$

$$P_{WS+TDL,i}^{min} \leq P_{WS+TDL,i} \leq P_{WS+TDL,i}^{max} \quad \forall i \in NWSTD L \quad (4.42)$$

$$Q_{TG,i}^{min} \leq Q_{TG,i} \leq Q_{TG,i}^{max} \quad \forall i \in NTG \quad (4.43)$$

$$Q_{WS,i}^{min} \leq Q_{WS,i} \leq Q_{WS,i}^{max} \quad \forall i \in NWS \quad (4.44)$$

$$Q_{PVSH,i}^{min} \leq Q_{PVSH,i} \leq Q_{PVSH,i}^{max} \quad \forall i \in NPVSH \quad (4.45)$$

$$Q_{WS+TDL,i}^{min} \leq Q_{WS+TDL,i} \leq Q_{WS+TDL,i}^{max} \quad \forall i \in NWSTD L \quad (4.46)$$

$$V_{TG,i}^{min} \leq V_{TG,i} \leq V_{TG,i}^{max} \quad \forall i \in NTG \quad (4.47)$$

$$V_{L,i}^{min} \leq V_{L,i} \leq V_{L,i}^{max} \quad \forall i \in NPQ \quad (4.48)$$

$$T_i^{min} \leq T_i \leq T_i^{max} \quad \forall i \in NT \quad (4.49)$$

$$|S_{L,i}| \leq S_{L,i}^{max} \quad \forall i \in NTL \quad (4.50)$$

GKD tabanlı ÇTYGDA şebekenin eşitsizlik kısıtları Eşitlikler (4.51)-(4.54)'te verilmiştir.

$$P_{S_i}^{min} \leq P_{S_i} \leq P_{S_i}^{max} \quad \forall i \in N_{GKD} \quad (4.51)$$

$$Q_{S_i}^{min} \leq Q_{S_i} \leq Q_{S_i}^{max} \quad \forall i \in N_{GKD} \quad (4.52)$$

$$V_{C_i}^{min} \leq V_{C_i} \leq V_{C_i}^{max} \quad \forall i \in N_{GKD} \quad (4.53)$$

$$V_{dc,i}^{min} \leq V_{dc,i} \leq V_{dc,i}^{max} \quad \forall i \in N_{DA} \quad (4.54)$$

4.4. ÇOK AMAÇLI OPTİMAL GÜÇ AKIŞI PROBLEMİNİN SİMÜLASYON ÇALIŞMALARI, SONUÇLARI VE KARŞILAŞTIRMALARI

Bu alt bölümde, rüzgar, güneş, hidro, gelgit enerji kaynakları ve çok terminalli yüksek gerilim doğru akım iletim hatları ile modifiye edilmiş IEEE 30-baralı güç sisteminde ÇAOGA probleminin simülasyon sonuçları sunulmuştur. Önerilen güç sistemi probleminin optimizasyonunda MOGOA, MSSA, MODA, MOALO ve MO_Ring_PSO_SCD optimizasyon algoritmaları kullanılmıştır. Çok amaçlı optimizasyon algoritmalarının performansı, Şekil 4.3'te şematik diyagramı verilen modifiye IEEE 30-baralı güç sisteminde farklı simülasyon çalışmaları ile test edilmiştir. Çizelge 4.2'de test sistemi konfigürasyonu verilmiştir.

Çizelge 4.2. Modifiye IEEE 30-baralı test sistemi konfigürasyonu.

Modifiye IEEE 30-Baralı Test Sistemi		
Ögeler	Nicelik	Detaylar
Bara	30	[139]
İletim hattı	41	[139]
Termal jeneratör	3	Baralar: 1 (salınım barası), 2 ve 5
Rüzgâr enerjisi	2	Baralar: 8 ve 13
Güneş enerjisi	1	Bara: 11
Hidro enerji	1	Bara: 11
Gelgit enerjisi	1	Bara: 13
Transformatör	4	İletim Hatları: 11, 12, 15, ve 36
Şönt kapasitör	2	Baralar: 10 ve 24
GKD tabanlı ÇTYGDA şebeke	2	ÇTYGDA şebeke-1: GKD-1, GKD-2, GKD-3 ÇTYGDA şebeke-2: GKD-4, GKD-5, GKD-6
Toplam aktif ve reaktif yük	-	283.4 MW, 126.2 MVar
Yük barası voltaj limitleri	24	[0.94-1.06] p.u

Çizelge 4.3. Termal jeneratörlerin maliyet ve emisyon katsayıları.

Maliyet katsayıları					
Üretim Birimi	m (\$/h)	l (\$/MWh)	k (\$/MW ² h)	n (\$/h)	r (rad/MW)
TG_1	0	2.00	0.0037	18	0.0370
TG_2	0	1.75	0.0175	16	0.0380
TG_5	0	1.00	0.0625	14	0.0400
Emisyon katsayıları					
Üretim Birimi	μ (t/h)	φ (t/p.u.MWh)	α (t/p.u.MW ² h)	γ (t/h)	ϵ (p.u.MW ⁻¹)
TG_1	0.0409	-0.0554	0.0649	0.0002	2.8570
TG_2	0.0254	-0.0604	0.0563	0.0005	3.3330
TG_5	0.0425	-0.0509	0.0458	0.0000	8.0000

Çizelge 4.4. Stokastik yenilenebilir enerji kaynaklarının doğrudan, fazla-tahmin ve eksik-tahmin maliyet katsayıları.

Doğrudan maliyet katsayıları (\$/MW)				
Rüzgar (Bara:8)	Güneş (Bara: 11)	Hidro (Bara:11)	Rüzgar (Bara:13)	Gelgit (Bara:13)
$wp, i = 1.75$	$pv, i = 1.70$	$sh, i = 1.50$	$wp, i = 1.60$	$tdl, i = 1.80$
Fazla-tahmin maliyet katsayıları (\$/MW)				
Rüzgar (Bara:8)	Güneş (Bara: 11)	Hidro (Bara:11)	Rüzgar (Bara:13)	Gelgit (Bara:13)
$C_{ow, i} = 3.0$	$C_{opv, i} = 3.0$	$C_{osh, i} = 3.0$	$C_{ow, i} = 3.0$	$C_{otdl, i} = 3.00$
Eksik-tahmin maliyet katsayıları (\$/MW)				
Rüzgar (Bara:8)	Güneş (Bara: 11)	Hidro (Bara:11)	Rüzgar (Bara:13)	Gelgit (Bara:13)
$C_{uw, i} = 1.50$	$C_{upv, i} = 1.65$	$C_{ush, i} = 1.40$	$C_{uw, i} = 1.50$	$C_{utdl, i} = 1.60$

ÇAOGA probleminde toplam üretim maliyeti (F_{obj1}), valf noktası etkisi ile toplam üretim maliyeti (F_{obj2}), emisyon-karbon vergisi ile toplam üretim maliyeti (F_{obj3}), gerilim sapması (F_{obj4}) ve aktif güç kayıpları (F_{obj5}) amaç fonksiyonlarının ikili ve üçlü kombinasyonları farklı optimizasyon algoritmaları ile eş zamanlı olarak optimize edilmiştir. Algoritmalar arasında fırsat eşitliği sağlamak için durdurma kriteri olarak $maxFEs$ (maksimum fitness fonksiyonu değerlendirme sayısı) kullanıldı ve değeri $10000 \cdot n_{obj}$ olarak ayarlandı. Burada, n_{obj} amaç fonksiyonu sayısını gösterir. Ayrıca simülasyon çalışmalarında genel bir kabul olarak çok amaçlı optimizasyon algoritmalarının popülasyon sayısı $200 \cdot n_{obj}$ olarak belirlenmiştir. Simülasyon çalışmalarında yenilenebilir enerji kaynaklarının reaktif güç limitleri $-0.4 \times P_{RES, i}^{max}$ p.u.

ve $-0.5 \times P_{RES,i}^{max}$ p.u. olacak şekilde ayarlanmıştır. $P_{RES,i}^{max}$, i . yenilenebilir enerji sistemi için maksimum aktif gücü temsil eder. Simülasyon çalışmalarında kullanılan GKD-1 ve GKD-4, $V_{dc} - Q_c$ kontrol moduna, GKD-2, GKD-3, GKD-5 ve GKD-6 ise $P_{dc} - V_c$ kontrol moduna ayarlanmıştır. Yenilenebilir enerji kaynaklarını içeren önerilen ÇAOGA probleminin yük akışı denklemleri MATACDC [141] paket programı kullanılarak hesaplanmıştır. Simülasyon çalışmaları Çizelge 4.5'te tanımlanan test senaryolarına göre gerçekleştirilmiştir.


Çizelge 4.5. Simülasyon çalışmalarının özeti.

Modifiye IEEE 30-Baralı Test Sistemi					
Simülasyon Durumu	Toplam maliyet	Valf nokta etkisi ile toplam maliyet	Emisyon-karbon vergisi ile toplam maliyet	Gerilim sapması	Aktif güç kayıpları
Durum-1	✓			✓	
Durum-2	✓		✓		
Durum-3	✓				✓
Durum-4		✓		✓	✓
Durum-5		✓	✓	✓	
Durum-6		✓	✓		✓


Durum-1: Toplam üretim maliyeti ve gerilim sapması amaç fonksiyonlarının eş zamanlı optimizasyonu

Durum-1'de, toplam üretim maliyeti (F_{obj1}) ve gerilim sapması (F_{obj4}) amaç fonksiyonlarının eş zamanlı minimizasyonu çalışılmıştır. Rüzgâr, güneş, hidro ve gelgit enerji kaynaklarının yanı sıra termik jeneratörleri içeren toplam üretim maliyeti amaç fonksiyonu Eşitlik (4.28)'de verilmiştir. Gerilim sapması minimizasyonunda ise Eşitlik (4.31)'de verilen amaç fonksiyonu kullanılmıştır. Çizelge 4.6, MOGOA ve rekabetçi algoritmalar ile edilen simülasyon sonuçlarını özetler. Buna göre MOGOA, MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmalarının en iyi uzlaşmacı çözümleri için optimize edilmiş toplam üretim maliyeti ve gerilim sapması değerleri şu şekildedir: 790,8614 \$/h / 0,022467 p.u., 830,1512 \$/h / 0,044264 p.u., 838,3166 \$ /h / 0,067425 p.u., 823,1880 \$/h / 0,039292 p.u. ve 814,6006 \$/h / 0,045641 p.u. Simülasyon sonuçlarından en iyi amaç fonksiyonu değerlerinin MOGOA algoritması ile elde edilen

790,8614 \$/h ve 0,022467 p.u olduğu anlaşılmaktadır. MOGOA ve rekabetçi çok amaçlı optimizasyon algoritmaları ile elde edilen Pareto-optimal yüzeyler Şekil 4.4-(a)'da gösterilmiştir. MOGOA yöntemi kullanılarak elde edilen Pareto-optimal yüzeyin diğer algoritmalarla kıyasla daha iyi dağıtılmış olduğu şekilden açıkça görülmektedir. Şekil 4.4-(b)'de verilen eğrilerden, optimizasyon sonunda yük baraları gerilim büyüklüklerinin belirtilen sınırlar (0,94-1,06 p.u) içinde olduğu açıkça görülmektedir.



Şekil 4.4. (a) Durum-1 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler,
(b)Yük baraları gerilim profili.



(b)

Şekil 4.4. (devam) (a) Durum-1 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.

Çizelge 4.6. Durum-1 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.

Parametreler	Min.	Max.	Durum-1				
			MOGOA	MSSA	MODA	MOALO	MO_Ring_PSO_SCD
P_{TG_1} (MW)	50	200	169,2259	177,2494	144,1403	150,7313	168,2721
P_{TG_2} (MW)	20	80	47,5611	49,1726	39,9248	67,5704	45,1096
P_{TG_5} (MW)	15	50	19,8456	22,4113	32,3559	21,2222	21,7235
P_{WS} (MW)	0	45	26,0560	17,9889	45,0000	36,3939	40,0739
P_{PVSH} (MW)	0	50	12,6528	24,8415	13,9912	4,7251	9,1841
P_{WS+TDL} (MW)	0	40	22,2456	9,2577	27,5293	18,7550	14,9451
V_1 (p.u)	0,95	1,10	1,0842	1,0325	1,0286	1,1000	1,0680
V_2 (p.u)	0,95	1,10	1,0678	1,0180	1,0299	1,0789	1,0537
V_5 (p.u)	0,95	1,10	1,0378	0,9954	1,0263	1,0503	1,0256
V_8 (p.u)	0,95	1,10	1,0293	0,9922	1,0178	1,0409	1,0064
V_{11} (p.u)	0,95	1,10	1,0484	0,9922	1,0182	1,0798	1,0842
V_{13} (p.u)	0,95	1,10	1,0341	0,9711	1,0487	1,0262	1,0109
T_{11} (p.u)	0,90	1,10	1,0455	0,9058	1,0845	0,9579	0,9289
T_{12} (p.u)	0,90	1,10	1,0062	0,9830	1,0266	1,0453	1,0639
T_{15} (p.u)	0,90	1,10	0,9998	1,0568	0,9000	0,9734	0,9897
T_{36} (p.u)	0,90	1,10	0,9482	0,9806	1,0360	1,0197	0,9417
Q_{TG_1} (MVar)	-20	150	43,3902	-14,9168	-8,5923	103,6416	25,8838
Q_{TG_2} (MVar)	-20	60	35,5196	21,7449	51,8053	18,3424	39,7406
Q_{TG_5} (MVar)	-15	62,5	24,8255	19,5458	34,3769	18,4974	34,6184


Çizelge 4.6. (devam) Durum-1 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.

$Q_{WS} (MVar)$	-18	22,5	11,5543	21,8934	18,4121	15,2721	11,4394
$Q_{PVSH} (MVar)$	-16	20	20,2366	-10,4101	23,2007	13,9043	22,1829
$Q_{WS+TDL} (MVar)$	-16	20	7,8124	3,0218	13,5649	-5,0329	11,5529
$V_{dc,1} (p.u)$	0,9	1,10	1,0623	0,9423	1,0968	0,9860	1,0471
$V_{dc,4} (p.u)$	0,9	1,10	0,9895	1,0677	1,1000	1,0829	0,9169
$V_{c_2} (p.u)$	0,9	1,10	1,0368	0,9963	1,0198	1,0453	1,0133
$V_{c_3} (p.u)$	0,9	1,10	0,9289	0,9960	1,1000	1,0964	0,9590
$V_{c_5} (p.u)$	0,9	1,10	1,0149	0,9773	1,0052	1,0311	0,9735
$V_{c_6} (p.u)$	0,9	1,10	1,0229	1,0097	1,0166	1,0134	0,9460
$P_{s_2} (MW)$	-100	100	12,3325	42,6318	36,5722	0,8363	16,7406
$P_{s_3} (MW)$	-100	100	22,2605	48,3604	36,5464	47,6796	13,9934
$P_{s_5} (MW)$	-100	100	10,4756	24,6793	39,2900	37,6316	15,3125
$P_{s_6} (MW)$	-100	100	8,2145	15,9588	32,6486	1,4586	12,0972
$Q_{s_1} (MVar)$	-100	100	5,5510	22,0825	1,1254	10,7995	14,2817
$Q_{s_4} (MVar)$	-100	100	-36,7672	13,5842	-7,1943	-72,8596	-17,7100
$P_{loss_AA} (MW)$	-	-	5,6638	3,8137	4,4303	3,8953	6,1276
$P_{loss_DA} (MW)$	-	-	0,4494	3,1432	2,4163	1,8586	0,5302
$P_{loss_GKD} (MW)$	-	-	8,0738	10,5644	12,6949	10,2440	9,2505
$F_{obj1} (\$/h)$			790,8614	830,1512	838,3166	823,1880	814,6006
$F_{obj4} (p.u)$			0,022467	0,044264	0,067425	0,039292	0,045641

Durum-2: Toplam üretim maliyeti ve emisyon-karbon vergisi ile toplam üretim maliyeti amaç fonksiyonlarının eş zamanlı optimizasyonu


Durum-2’de, modifiye IEEE 30-baralı güç sisteminin optimum çalışması için toplam üretim maliyeti (F_{obj1}) ve emisyon-karbon vergisi ile toplam üretim maliyeti (F_{obj3}) amaç fonksiyonlarının eş zamanlı olarak minimize edilmesi amaçlanmıştır. Çok amaçlı optimizasyon algoritmaları ile optimize edilen kontrol değişkenlerinin yanı sıra amaç fonksiyonu değerleri Çizelge 4.7’de rapor edilmiştir. Çizelgeden, MOGOA, MSSA, MODA, MOALO ve MO_Ring_PSO_SCD yöntemlerinin en iyi uzlaşmacı çözümleri için toplam üretim maliyeti (F_{obj1}) ve emisyon-karbon vergisi ile toplam üretim maliyeti (F_{obj3}) amaç fonksiyonu değerlerinin sırasıyla 793,2147 \$/h / 828,6416 \$/h, 815,9265 \$/h / 859,7561 \$/h, 816,0642 \$/h / 845,7673 \$/h, 803,4233 \$/h / 833,7541 \$/h ve 798,2384 \$/h / 834,9732 \$/h olduğu görülmektedir. Simülasyon sonuçlarından MOGOA algoritmasının her iki amaç fonksiyonu için de en iyi uzlaşmacı değerleri sunduğu gözlemlenmiştir. Daha açık bir ifadeyle MOGOA yöntemi MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmalarının en iyi sonuçlarına kıyasla %2,7835, %2,7999,

%1,2706 ve %0,6293 oranında daha düşük olan F_{obj1} değerini (793,2147 \$/h) elde etmiştir. Ayrıca, MOGOA yönteminin F_{obj3} değeri (828,6416 \$/h), rekabetçi algoritmaların simülasyon sonuçlarından sırasıyla %3,6189, %2,0248, %0,6131 ve %0,7582 daha düşüktür. Mevcut simülasyon durumu için optimizasyon algoritmaları ile elde edilen Pareto-optimal yüzeyler ve PQ bara gerilim profili Şekil 4.5'te gösterilmiştir. Şekil 4.5-(a)'dan MOGOA yöntemi ile elde edilen Pareto-optimal yüzeyin diğer yöntemlere kıyasla daha iyi dağıldığını söylemek mümkündür. Şekil 4.5- (b)'de verilen eğriler Durum-2 için tüm optimizasyon algoritmalarının yük bara gerilim büyüklüklerini kabul edilebilir sınırlar içinde tutmada başarılı olduğunu açıkça göstermektedir.



(a)

Şekil 4.5. (a) Durum-2 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.



(b)

Şekil 4.5. (devam) (a) Durum-2 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.

Çizelge 4.7. Durum-2 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.

Parametreler	Min.	Max.	Durum-2				
			MOGOA	MSSA	MODA	MOALO	MO_Ring_PSO_SCD
$P_{TG_1} (MW)$	50	200	164,8343	174,7432	157,0900	157,9324	166,5720
$P_{TG_2} (MW)$	20	80	47,1477	53,3391	32,4667	40,5640	53,4103
$P_{TG_5} (MW)$	15	50	18,0494	26,7270	25,4551	18,4271	16,5780
$P_{WS} (MW)$	0	45	29,2712	18,8297	43,6367	36,5732	27,0957
$P_{PVSH} (MW)$	0	50	12,2377	12,1024	15,4744	11,7030	16,7990
$P_{WS+TDL} (MW)$	0	40	26,1945	16,5093	24,8735	32,6995	18,0119
$V_1 (p.u)$	0,95	1,10	1,0404	1,0480	1,0280	1,0362	1,0944
$V_2 (p.u)$	0,95	1,10	1,0180	1,0353	1,0263	1,0191	1,0601
$V_5 (p.u)$	0,95	1,10	0,9871	1,0091	1,0241	0,9995	1,0603
$V_8 (p.u)$	0,95	1,10	1,0026	1,0161	1,0237	1,0100	1,0203
$V_{11} (p.u)$	0,95	1,10	1,0592	1,0248	1,0279	1,0206	1,0513
$V_{13} (p.u)$	0,95	1,10	1,0703	1,0311	1,0635	1,0539	0,9846
$T_{11} (p.u)$	0,90	1,10	0,9876	1,0260	1,1000	1,0982	0,9638
$T_{12} (p.u)$	0,90	1,10	1,0800	0,9672	0,9783	1,0344	1,0979
$T_{15} (p.u)$	0,90	1,10	0,9606	0,9322	0,9433	0,9441	0,9751
$T_{36} (p.u)$	0,90	1,10	0,9234	0,9591	1,0049	0,9569	1,0616
$Q_{T_1} (MVar)$	-20	150	3,2011	7,2545	-19,4909	30,9052	51,1176
$Q_{TG_2} (MVar)$	-20	60	23,0922	19,2949	26,6213	-16,0564	22,3768
$Q_{TG_5} (MVar)$	-15	62.5	15,4057	18,4938	37,5096	26,6004	57,1875


Çizelge 4.7. (devam) Durum-2 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.

$Q_{WS} (MVar)$	-18	22,5	21,8662	22,4995	19,3702	19,3977	-5,4117
$Q_{PVSH} (MVar)$	-16	20	21,3090	11,0321	23,5211	24,9892	14,6150
$Q_{WS+TDL} (MVar)$	-16	20	19,9914	-2,4184	19,6819	16,1426	-7,7066
$V_{dc,1} (p.u)$	0,9	1,10	1,0993	1,0377	0,9618	1,0005	1,0353
$V_{dc,4} (p.u)$	0,9	1,10	1,0890	1,0392	0,9733	1,0441	1,0825
$V_{c_2} (p.u)$	0,9	1,10	1,0064	1,0198	1,0257	1,0132	1,0327
$V_{c_3} (p.u)$	0,9	1,10	0,9669	0,9881	1,1000	1,0652	0,9678
$V_{c_5} (p.u)$	0,9	1,10	1,0341	1,0331	1,0151	1,0152	0,9850
$V_{c_6} (p.u)$	0,9	1,10	1,0052	1,0579	1,0287	1,0569	0,9774
$P_{s_2} (MW)$	-100	100	9,4812	24,1018	34,2897	21,7108	22,7578
$P_{s_3} (MW)$	-100	100	23,7285	25,7679	21,9843	16,5110	20,8302
$P_{s_5} (MW)$	-100	100	15,5420	37,4266	11,1940	10,9115	20,7550
$P_{s_6} (MW)$	-100	100	8,2551	39,4141	27,1592	16,4880	7,0065
$Q_{s_1} (MVar)$	-100	100	-13,6404	11,6879	7,7055	29,1583	-31,8525
$Q_{s_4} (MVar)$	-100	100	10,4012	1,0753	-8,3176	-26,8993	0,8368
$P_{loss_AA} (MW)$	-	-	5,6357	4,7181	4,7905	5,5217	5,7200
$P_{loss_DA} (MW)$	-	-	0,4651	2,0871	1,4648	0,6278	0,7316
$P_{loss_GKD} (MW)$	-	-	8,2340	12,0457	9,3411	8,3497	8,6153
$F_{obj1} (\$/h)$			793,2147	815,9265	816,0642	803,4233	798,2384
$F_{obj3} (\$/h)$			828,6416	859,7561	845,7673	833,7541	834,9732

Durum-3: Toplam üretim maliyeti ve aktif güç kayıpları amaç fonksiyonlarının eş zamanlı optimizasyonu

MOGOA ve rekabetçi optimizasyon algoritmaları kullanılarak toplam maliyet (F_{obj1}) ve aktif güç kaybı (F_{obj5}) amaç fonksiyonları eş zamanlı olarak optimize edilmiştir. Durum-3 için çok amaçlı optimizasyon algoritmaları ile elde edilen simülasyon sonuçları Çizelge 4.8’de verilmiştir. Buna göre, hem toplam üretim maliyeti hem de aktif güç kayıpları minimizasyonu için en iyi uzlaşmacı çözümler (792,5745 \$/h / 14,4138 MW) MOGOA algoritması tarafından elde edilmiştir. Daha açık bir ifadeyle, MOGOA algoritması ile elde edilen toplam üretim maliyeti ve aktif güç kayıpları amaç fonksiyonu değerleri MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmalarının Çizelge 4.8’de rapor edilen en iyi sonuçlarına kıyasla 30,1971 \$/h / %27,0501, 13,4401 \$/h / %3,1968, 11,0379 \$/h / %4,7852 ve 19,7191 \$/h / %14,1943 daha düşüktür. Şekil 4.6-(a), MOGOA ve rekabetçi algoritmalar tarafından elde edilen Pareto-optimal yüzeyleri göstermektedir. İlgili şekilden, en iyi amaç fonksiyonu değerlerini de içeren iyi dağıtılmış Pareto optimal yüzeyi elde edebilen algoritmanın MOGOA olduğu açıkça görülmektedir. Şekil 4.6-(b), optimizasyon süreci sonunda tüm algoritmaların PQ baraların gerilim büyüklüğünü izin

verilen sınırlar içinde tutabildiğini göstermektedir.




Şekil 4.6. (a) Durum-3 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.

Çizelge 4.8. Durum-3 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.


Parametreler	Min.	Max.	Durum-3				
			MOGOA	MSSA	MODA	MOALO	MO_Ring_ PSO_SCD
$P_{TG_1} (MW)$	50	200	164,7626	161,4687	150,9891	165,3260	172,6750
$P_{TG_2} (MW)$	20	80	43,9895	53,7531	61,3329	35,0056	57,6855
$P_{TG_5} (MW)$	15	50	22,4759	24,1104	21,1168	25,6872	17,5031
$P_{WS} (MW)$	0	45	30,0162	19,6948	36,6034	31,8399	14,4357
$P_{PVSH} (MW)$	0	50	13,2102	22,3986	11,7232	13,0257	8,9581
$P_{WS+TDL} (MW)$	0	40	23,3594	21,7328	16,5244	27,6538	28,9408
$V_1 (p.u)$	0,95	1,10	1,0977	1,0458	0,9736	1,0824	1,0838
$V_2 (p.u)$	0,95	1,10	1,0742	1,0311	0,9696	1,0633	1,0379
$V_5 (p.u)$	0,95	1,10	1,0668	1,0314	0,9500	1,0445	0,9838
$V_8 (p.u)$	0,95	1,10	1,0463	1,0240	0,9540	1,0525	1,0075
$V_{11} (p.u)$	0,95	1,10	1,0062	1,0509	1,1000	1,0687	1,0472
$V_{13} (p.u)$	0,95	1,10	1,0345	1,0210	1,0597	1,0513	1,0539
$T_{11} (p.u)$	0,90	1,10	1,0725	1,0134	0,9119	1,0030	0,9992
$T_{12} (p.u)$	0,90	1,10	0,9896	0,9876	0,9000	0,9890	0,9146
$T_{15} (p.u)$	0,90	1,10	0,9155	1,0080	0,9000	0,9777	0,9821
$T_{36} (p.u)$	0,90	1,10	1,0847	1,0291	1,1000	1,0367	1,0382
$Q_{TG_1} (MVar)$	-20	150	71,6081	1,5465	-19,9652	74,6499	65,7745
$Q_{TG_2} (MVar)$	-20	60	15,9200	19,1721	26,6244	50,2891	-7,4824
$Q_{TG_5} (MVar)$	-15	62,5	46,2814	33,6575	23,5159	25,6848	1,0689
$Q_{WS} (MVar)$	-18	22,5	21,3179	17,7817	11,8033	22,4897	13,9900
$Q_{PVSH} (MVar)$	-16	20	7,1748	19,7269	24,7275	13,0104	13,0110
$Q_{WS+TDL} (MVar)$	-16	20	-9,0775	9,5231	5,7795	1,8811	12,6133
$V_{dc,1} (p.u)$	0,9	1,10	0,9953	0,9942	1,0622	0,9494	0,9891
$V_{dc,4} (p.u)$	0,9	1,10	0,9832	1,0036	0,9138	1,0980	0,9309
$V_{c_2} (p.u)$	0,9	1,10	1,0489	1,0287	0,9580	1,0544	1,0145
$V_{c_3} (p.u)$	0,9	1,10	1,0947	1,0604	1,1000	0,9883	0,9290
$V_{c_5} (p.u)$	0,9	1,10	1,0285	1,0107	1,0502	1,0440	1,0279
$V_{c_6} (p.u)$	0,9	1,10	0,9601	1,0422	1,0262	1,0372	0,9602
$P_{s_2} (MW)$	-100	100	14,3359	39,8348	6,5325	37,3035	11,4446
$P_{s_3} (MW)$	-100	100	18,8608	46,1143	32,6893	16,1047	15,6536
$P_{s_5} (MW)$	-100	100	9,2548	43,4903	19,4574	23,1474	7,2295
$P_{s_6} (MW)$	-100	100	7,9328	31,2748	15,9646	4,5392	25,7177
$Q_{s_1} (MVar)$	-100	100	-0,2835	-11,9201	6,7850	-34,4852	-9,6685
$Q_{s_4} (MVar)$	-100	100	-44,7300	6,4911	0,7977	-66,3770	7,8885
$P_{loss_AA} (MW)$	-	-	5,9716	3,1809	5,0464	4,4526	7,3604
$P_{loss_DA} (MW)$	-	-	0,4339	3,6737	0,9830	1,2901	0,5922
$P_{loss_GKD} (MW)$	-	-	8,0083	12,9039	8,8605	9,3955	8,8456
$F_{obj1} (\$/h)$			792,5745	822,7716	806,0146	803,6124	812,2936
$F_{obj5} (MW)$			14,4138	19,7585	14,8898	15,1382	16,7982

Durum-4: Valf nokta etkisi ile toplam üretim maliyeti, gerilim sapması ve aktif güç kayıpları amaç fonksiyonlarının eş zamanlı optimizasyonu

Durum-4'te, optimizasyon algoritmalarının kısıtlı ÇAOGA problemini çözmedeki etkinliğini test etmek için valf noktası etkisi ile toplam maliyet (F_{obj2}), gerilim sapması (F_{obj4}) ve aktif güç kayıpları (F_{obj5}) olmak üzere üç amaç fonksiyonunun eş zamanlı optimizasyonu incelenmiştir. MOGOA, MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmalarının simülasyon sonuçları Çizelge 4.9'da verilmiştir. Simülasyon sonuçlarından, valf noktası etkisi ile toplam maliyet ve aktif güç kayıpları amaç fonksiyonları minimizasyonu için MOGOA yöntemi ile elde edilen değerin (828.0918 \$/h / 13.3912 MW) rakiplerine kıyasla daha iyi olduğu tespit edilmiştir. Ayrıca gerilim sapması amaç fonksiyonu optimizasyonunda en iyi sonucun (0,018828 p.u.) MSSA algoritmasına ait olduğu gözlemlenmiştir. MOGOA ve rekabetçi algoritmalar ile elde edilen Pareto-optimal yüzeyler Şekil 4.7'de gösterilmiştir. İyi dağıtılmış Pareto optimal çözümleri elde etmek için iki yöntemin (MOGOA ve MOALO) öne çıktığı şekilden açıkça görülmektedir. Şekil 4.7-(b)'de verilen gerilim profili detaylı olarak incelendiğinde yük baraları gerilim büyüklüğü kısıtını ihlal eden herhangi bir algoritmanın olmadığı gözlemlenmiştir.



Şekil 4.7. (a) Durum-4 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.



(b)

Şekil 4.7. (devam) (a) Durum-4 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.

Çizelge 4.9. Durum-4 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.

Parametreler	Min.	Max.	Durum-4				
			MOGOA	MSSA	MODA	MOALO	MO_Ring_PSO_SCD
P_{TG_1} (MW)	50	200	136,6766	158,1182	167,4139	151,0548	171,1736
P_{TG_2} (MW)	20	80	53,7894	52,8226	38,7554	59,6183	33,0726
P_{TG_5} (MW)	15	50	21,0033	24,6017	18,5073	18,0183	15,5934
P_{WS} (MW)	0	45	33,4622	27,3753	24,6531	37,2297	33,8443
P_{PVSH} (MW)	0	50	16,4207	21,2952	20,4027	15,0738	14,9270
P_{WS+TDL} (MW)	0	40	35,4382	19,0475	30,0000	16,1303	30,7539
V_1 (p.u.)	0,95	1,10	1,0586	1,0172	1,0453	1,0892	1,0976
V_2 (p.u.)	0,95	1,10	1,0372	1,0032	1,0261	1,0638	1,0587
V_5 (p.u.)	0,95	1,10	1,0351	1,0022	1,0599	1,0496	1,0404
V_8 (p.u.)	0,95	1,10	1,0168	0,9939	1,0422	1,0480	1,0236
V_{11} (p.u.)	0,95	1,10	1,0682	1,0148	1,0173	1,0295	1,0176
V_{13} (p.u.)	0,95	1,10	1,0080	1,0083	1,0392	1,0352	1,0609
T_{11} (p.u.)	0,90	1,10	0,9888	1,0415	1,1000	1,1000	0,9578
T_{12} (p.u.)	0,90	1,10	0,9523	0,9868	0,9761	0,9640	1,0792
T_{15} (p.u.)	0,90	1,10	0,9893	0,9841	1,0056	1,0095	0,9476
T_{36} (p.u.)	0,90	1,10	1,0823	0,9271	1,0805	0,9812	1,0508
Q_{TG_1} (MVar)	-20	150	57,1044	12,4840	2,3170	45,3252	70,5016
Q_{TG_2} (MVar)	-20	60	0,3205	-3,3013	-12,3373	23,5149	32,6777
Q_{TG_5} (MVar)	-15	62,5	46,3852	34,9454	61,8856	35,1679	44,5803
Q_{WS} (MVar)	-18	22,5	5,5534	15,5684	21,1142	21,4288	20,1002


Çizelge 4.9. (devam) Durum-4 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.

$Q_{PVSH} (MVar)$	-16	20	19,5097	18,6899	17,9620	18,4039	-0,2273
$Q_{WS+TDL} (MVar)$	-16	20	-3,8561	8,3660	16,2209	9,1075	16,9538
$V_{dc,1} (p.u)$	0.9	1,10	0,9111	0,9946	1,0047	1,0677	0,9542
$V_{dc,4} (p.u)$	0.9	1,10	1,0214	1,0219	1,0194	1,1000	1,0243
$V_{c_2} (p.u)$	0.9	1,10	1,0242	0,9997	1,0448	1,0506	1,0262
$V_{c_3} (p.u)$	0.9	1,10	0,9896	0,9885	0,9803	0,9198	0,9546
$V_{c_5} (p.u)$	0.9	1,10	1,0110	0,9991	1,0076	1,0170	1,0122
$V_{c_6} (p.u)$	0.9	1,10	0,9968	1,0539	1,0431	1,0173	0,9888
$P_{s_2} (MW)$	-100	100	14,1797	44,2586	32,4261	22,5631	10,4459
$P_{s_3} (MW)$	-100	100	18,2499	39,9340	39,8053	16,2683	9,1575
$P_{s_5} (MW)$	-100	100	13,8055	35,3531	18,7852	19,4591	15,7306
$P_{s_6} (MW)$	-100	100	5,5487	35,8079	23,4804	13,6706	0,4025
$Q_{s_1} (MVar)$	-100	100	-6,1454	15,2302	-23,1734	-30,9169	-36,4785
$Q_{s_4} (MVar)$	-100	100	-37,8976	-5,9619	-1,7895	-15,6791	-10,8370
$P_{loss_AA} (MW)$	-	-	4,7932	3,8921	4,5155	4,2608	7,6365
$P_{loss_DA} (MW)$	-	-	0,5075	3,3432	1,9596	0,6530	0,2443
$P_{loss_GKD} (MW)$	-	-	8,0898	12,6252	9,8574	8,8114	8,0838
$F_{obj2} (\$/h)$			828,0918	856,1847	858,2039	830,6205	831,7387
$F_{obj4} (p.u)$			0,038582	0,018828	0,020903	0,05497	0,022028
$F_{obj5} (MW)$			13,3912	19,8606	16,3324	13,7252	15,9647


Durum-5: Valf nokta etkisi ile toplam üretim maliyeti, emisyon-karbon vergisi ile toplam üretim maliyeti ve gerilim sapması amaç fonksiyonlarının eş zamanlı optimizasyonu

Mevcut simülasyon durumunda, valf noktası ile toplam üretim maliyeti (F_{obj2}), emisyon-karbon vergisi ile toplam üretim maliyeti (F_{obj3}) ve gerilim sapması (F_{obj4}) olmak üzere üç amaç fonksiyonunun eş zamanlı optimizasyonu çalışılmıştır. Çizelge 4.10’da verilen simülasyon sonuçlarından MOGOA yönteminin hem valf nokta etkisi ile toplam üretim maliyeti hem de emisyon-karbon vergisi ile toplam üretim maliyeti amaç fonksiyonları açısından en iyi değerleri elde ettiği açıkça görülmektedir. Gerilim sapması amaç fonksiyonu optimizasyonunda ise MODA rakiplerine kıyasla daha başarılı olmuştur. Çizelge 4.10’da verilen nümerik sonuçlar detaylı olarak analiz edildiğinde, F_{obj2} amaç fonksiyonu için MOGOA ile elde edilen simülasyon sonucu (822,6149 \$/h), MSSA (850,7005 \$/h), MODA (854,4354 \$/h), MOALO (850,1963 \$/h) ve MO_Ring_PSO_SCD (835,8317 \$/h) algoritmalarının rapor edilen en iyi sonuçlarına kıyasla sırasıyla %3,301, %3,724, %3,244 ve %1,5812 daha düşüktür. Sonuçlar F_{obj3} açısından karşılaştırıldığında, MOGOA yönteminin amaç fonksiyonu değeri (827,8809

\$/h), MSSA, MODA, MOALO ve MO_Ring_PSO_SCD yöntemlerinin simülasyon sonuçlarından %3,0858, %3,6805, %3,0177 ve %1,2994 daha düşüktür. MODA algoritmasının F_{obj4} değeri, rekabetçi algoritmaların simülasyon sonuçlarından sırasıyla 0,010671 p.u, 0,030086 p.u, 0,001764 p.u, 0,015983 p.u ve 0,031701 p.u daha düşüktür. Durum-5 için çok amaçlı optimizasyon algoritmaları ile elde edilen üç boyutlu Pareto-optimal yüzeyler Şekil 4.8-(a)'da gösterilmiştir. İlgili şekilden, MOGOA ile elde edilen Pareto-optimal yüzeyin diğer algoritmalara kıyasla iyi dağıtılmış olduğu gözlemlenmiştir. Şekil 4.8-(b)'de verilen grafiklerden yük barası gerilim büyüklüklerinin izin verilen sınırlar (0,94-1,06 p.u) içinde olduğu açıkça görülmektedir.



Şekil 4.8. (a) Durum-5 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler,
(b)Yük baraları gerilim profili.



(b)

Şekil 4.8. (devam) (a) Durum-5 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.

Çizelge 4.10. Durum-5 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.

Parametreler	Min.	Max.	Durum-5				
			MOGOA	MSSA	MODA	MOALO	MO_Ring_PSO_SCD
$P_{TG_1} (MW)$	50	200	189,4288	157,9418	186,8405	154,8988	137,8100
$P_{TG_2} (MW)$	20	80	29,0921	47,6350	35,4682	59,4894	72,9187
$P_{TG_5} (MW)$	15	50	15,0000	28,1700	15,0000	28,0449	25,5175
$P_{WS} (MW)$	0	45	27,3337	28,7126	39,4347	23,2875	26,8711
$P_{PVSH} (MW)$	0	50	12,0970	17,3929	16,5097	13,0906	13,1589
$P_{WS+TDL} (MW)$	0	40	26,0796	22,6595	6,0815	21,9833	21,4299
$V_1 (p.u)$	0,95	1,10	1,0333	1,0238	1,0227	1,0171	1,0877
$V_2 (p.u)$	0,95	1,10	1,0196	1,0016	0,9969	1,0032	1,0497
$V_5 (p.u)$	0,95	1,10	0,9817	1,0070	0,9897	0,9771	0,9917
$V_8 (p.u)$	0,95	1,10	0,9916	1,0013	0,9799	0,9805	1,0206
$V_{11} (p.u)$	0,95	1,10	1,0619	1,0093	1,1000	0,9911	0,9763
$V_{13} (p.u)$	0,95	1,10	1,0766	0,9942	1,0072	0,9820	1,0167
$T_{11} (p.u)$	0,90	1,10	0,9605	0,9721	0,9000	1,0674	1,0569
$T_{12} (p.u)$	0,90	1,10	0,9624	0,9654	0,9919	0,9089	0,9680
$T_{15} (p.u)$	0,90	1,10	0,9132	1,0111	0,9475	0,9067	1,0247
$T_{36} (p.u)$	0,90	1,10	1,0391	1,0055	0,9263	0,9685	1,0686
$Q_{TG_1} (MVar)$	-20	150	4,7685	16,0724	25,3614	-10,8168	63,6908
$Q_{TG_2} (MVar)$	-20	60	44,1954	3,7765	6,4809	-6,9931	-12,3926
$Q_{TG_5} (MVar)$	-15	62,5	9,8557	34,9179	43,7119	24,1000	-9,8021



Çizelge 4.10. (devam) Durum-5 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.

$Q_{WS} (MVar)$	-18	22,5	15,2552	21,5981	14,8305	22,4298	19,4789
$Q_{PVSH} (MVar)$	-16	20	14,9967	3,9897	22,6394	14,5286	2,2555
$Q_{WS+TDL} (MVar)$	-16	20	14,0071	2,6496	-0,7199	-15,1696	9,6152
$V_{dc,1} (p.u)$	0,9	1,10	1,0749	0,9959	1,0148	0,9725	1,0804
$V_{dc,4} (p.u)$	0,9	1,10	1,0596	1,0057	0,9792	0,9797	0,9525
$V_{c2} (p.u)$	0,9	1,10	0,9966	1,0038	0,9847	0,9834	1,0236
$V_{c3} (p.u)$	0,9	1,10	0,9605	1,0049	1,1000	0,9166	0,9088
$V_{c5} (p.u)$	0,9	1,10	1,0400	1,0006	1,0035	1,0054	1,0016
$V_{c6} (p.u)$	0,9	1,10	0,9646	1,0436	1,0308	1,0586	1,0431
$P_{s2} (MW)$	-100	100	11,8586	31,1499	29,8081	20,6323	17,0994
$P_{s3} (MW)$	-100	100	39,7444	46,8604	17,3482	16,9326	30,7494
$P_{s5} (MW)$	-100	100	11,1892	36,2139	23,8493	31,0920	15,9286
$P_{s6} (MW)$	-100	100	11,1522	34,7754	11,0949	35,7035	8,9955
$Q_{s1} (MVar)$	-100	100	10,6056	-17,9899	-2,8476	35,9509	12,9961
$Q_{s4} (MVar)$	-100	100	-11,4895	5,7516	-6,4303	26,1665	-0,0930
$P_{loss_AA} (MW)$	-	-	6,2711	3,4444	5,7854	4,6639	5,0103
$P_{loss_DA} (MW)$	-	-	0,9911	3,1564	1,0543	1,6455	0,8240
$P_{loss_GKD} (MW)$	-	-	8,3689	12,5112	9,0949	11,0850	8,4720
$F_{obj2} (\$/h)$			822,6149	850,7004	854,4354	850,1963	835,8317
$F_{obj3} (\$/h)$			827,8809	854,2415	859,5155	853,6414	838,7808
$F_{obj4} (p.u)$			0,040757	0,012435	0,010671	0,026654	0,042372

Durum-6: Valf nokta etkisi ile toplam üretim maliyeti, emisyon-karbon vergisi ile toplam üretim maliyeti ve aktif güç kayıplarının eş zamanlı optimizasyonu

Durum-6’da, valf nokta etkisi ile toplam üretim maliyeti (F_{obj2}), emisyon-karbon vergisi ile toplam üretim maliyeti (F_{obj3}) ve aktif güç kayıpları (F_{obj5}) amaç fonksiyonlarının eş zamanlı optimizasyonu çalışılmıştır. Çizelge 4.11, çok amaçlı optimizasyon algoritmaları ile ayarlanan kontrol değişkenlerinin yanı sıra amaç fonksiyonu değerlerini sunar. Buna göre MOGOA algoritması ile elde edilen simülasyon sonucu 828,6813 \$/h (F_{obj2}) / 831,5754 \$/h (F_{obj3}) / 13,8972 MW (F_{obj5}), MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmalarının rapor edilen en iyi sonuçlarına kıyasla sırasıyla %2,4508 / %2,4653 / 2,9013 MW, %2,2421 / %2,3400 / 2,5667 MW, %1,8409 / %1,8294 / 0,4530 MW ve %0,7001 / %1,0228 / 3,0521 MW daha düşüktür. Çizelge 4.11’de verilen simülasyon sonuçlarının analizi, MOGOA yönteminin mevcut simülasyon durumu için rakiplerinden daha iyi performans gösterdiğini ortaya koymuştur. Çok amaçlı optimizasyon algoritmaları ile elde edilen Pareto-optimal cepheler ve yük baralarının

gerilim profili Şekil 4.9’da gösterilmiştir. MOGOA yönteminin elde edilen Pareto-optimal çözümlerin doğruluğu ve bunların dağılımı açısından oldukça rekabetçi sonuçlar sağlayabildiği ve optimizasyon sonunda yük baraları gerilim değerlerinin minimum ve maksimum limitler içinde olduğu gözlemlenmiştir.



Şekil 4.9. (a) Durum-6 için algoritmalar tarafından elde edilen Pareto-optimal yüzeyler, (b)Yük baraları gerilim profili.

Çizelge 4.11. Durum-6 için MOGOA ve rekabetçi algoritmaların simülasyon sonuçları.

Parametreler	Min.	Max.	Durum-6				
			MOGOA	MSSA	MODA	MOALO	MO_Ring_ PSO_SCD
$P_{TG_1} (MW)$	50	200	137,8087	146,2263	163,2312	134,4972	195,4144
$P_{TG_2} (MW)$	20	80	56,3246	49,9477	30,3438	75,4296	22,6430
$P_{TG_5} (MW)$	15	50	19,7866	32,8899	25,2491	29,8475	23,4913
$P_{WS} (MW)$	0	45	34,4454	32,0595	45,0000	24,0242	23,7967
$P_{PVSH} (MW)$	0	50	18,1541	14,9842	17,6995	12,9019	10,4880
$P_{WS+TDL} (MW)$	0	40	30,7778	24,0908	18,3404	21,0499	24,5158
$V_1 (p.u)$	0,95	1,10	1,0839	1,0570	1,0712	1,0696	1,0649
$V_2 (p.u)$	0,95	1,10	1,0526	1,0474	1,0644	1,0539	1,0270
$V_5 (p.u)$	0,95	1,10	1,0062	1,0289	1,0675	1,0392	0,9744
$V_8 (p.u)$	0,95	1,10	1,0020	1,0366	1,0348	1,0359	0,9819
$V_{11} (p.u)$	0,95	1,10	0,9552	1,0545	1,1000	1,0773	1,0609
$V_{13} (p.u)$	0,95	1,10	0,9936	0,9991	1,0492	1,0031	1,0150
$T_{11} (p.u)$	0,90	1,10	1,0216	0,9933	0,9832	0,9809	0,9484
$T_{12} (p.u)$	0,90	1,10	0,9908	1,0271	0,9144	0,9867	0,9450
$T_{15} (p.u)$	0,90	1,10	0,9030	1,0552	1,1000	0,9901	1,0521
$T_{36} (p.u)$	0,90	1,10	1,0121	1,0551	1,1000	1,0849	0,9399
$Q_{TG_1} (MVar)$	-20	150	51,8368	-1,1483	-19,8843	56,9634	58,7710
$Q_{TG_2} (MVar)$	-20	60	32,7268	27,8005	44,8956	58,7524	41,6650
$Q_{TG_5} (MVar)$	-15	62,5	14,4949	20,4642	54,0753	27,1486	-3,4331
$Q_{WS} (MVar)$	-18	22,5	13,6153	21,5340	-3,4072	21,2204	13,2566
$Q_{PVSH} (MVar)$	-16	20	-5,6168	18,0198	21,4323	19,1275	17,1155
$Q_{WS+TDL} (MVar)$	-16	20	-15,8915	7,0560	19,9557	-8,5064	13,9938
$V_{dc,1} (p.u)$	0,9	1,10	0,9599	1,0574	1,0512	1,0012	1,0682
$V_{dc,4} (p.u)$	0,9	1,10	0,9267	1,0019	0,9418	0,9155	1,0730
$V_{c_2} (p.u)$	0,9	1,10	1,0073	1,0385	1,0438	1,0385	0,9887
$V_{c_3} (p.u)$	0,9	1,10	0,9621	1,0784	0,9840	1,0576	1,0821
$V_{c_5} (p.u)$	0,9	1,10	1,0008	0,9942	1,0340	1,0185	1,0007
$V_{c_6} (p.u)$	0,9	1,10	0,9888	1,0455	1,0122	1,0112	1,0432
$P_{s_2} (MW)$	-100	100	6,7197	34,5576	49,6937	13,1434	21,8459
$P_{s_3} (MW)$	-100	100	26,8695	27,1400	22,2037	29,2047	51,7589
$P_{s_5} (MW)$	-100	100	4,4734	32,6088	29,7845	30,0117	18,3385
$P_{s_6} (MW)$	-100	100	9,2979	33,9771	7,5697	16,8293	11,2685
$Q_{s_1} (MVar)$	-100	100	3,7315	-2,6275	-4,0044	-50,9231	-7,9366
$Q_{s_4} (MVar)$	-100	100	5,3710	1,5349	1,7604	-40,1507	-10,3135
$P_{loss_AA} (MW)$	-	-	5,7383	3,3421	4,6676	2,9106	5,8059
$P_{loss_DA} (MW)$	-	-	0,5642	2,1404	2,0640	1,3337	1,8226
$P_{loss_GKD} (MW)$	-	-	7,5947	11,3160	9,7322	10,1059	9,3207
$F_{obj2} (\$/h)$			828,6813	849,5016	847,6877	844,2226	834,5245
$F_{obj3} (\$/h)$			831,5754	852,5864	851,5012	847,0723	840,169
$F_{obj5} (MW)$			13,8972	16,7985	16,4639	14,3502	16,9493

4.5. SONUÇLAR: ÇOK AMAÇLI OPTİMAL GÜÇ AKIŞI

- Rüzgâr, güneş, hidro ve gelgit enerji kaynaklarını içeren hibrit alternatif akım/ yüksek gerilim doğru akım şebekede çok amaçlı optimal güç akışı probleminin matematiksel modeli ve çözümü literatüre ilk kez sunulmuştur.
- Yenilenebilir enerji kaynaklarının belirsizliği ve stokastik doğası, olasılık yoğunluk fonksiyonları (Weibull, Lognormal ve Gumbel) ile modellenmiştir.
- Önerilen problemin çözümünde yenilenebilir enerji kaynaklarının fazla tahmini için rezerv maliyeti, eksik tahmini için ise ceza maliyeti dikkate alınmıştır.
- Güneş ve hidro enerji ünitelerinin birleşimi aktif güç üretim birimi olarak dikkate alınmıştır. Benzer şekilde rüzgâr ve gelgit enerji kaynaklarının birleşimi aktif güç üretim birimi olarak modellenmiştir.
- IEEE 30-baralı test sisteminde Bara 8, Bara 11 ve Bara 13'teki termal jeneratörler, rüzgar, aktif güç üretim birimi olarak modellenen kombine güneş-hidro ve kombine rüzgar-gelgit yenilenebilir enerji üniteleri ile değiştirilmiştir.
- MOGOA, MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmaları yenilenebilir enerji kaynakları ve gerilim kaynağı dönüştürücü tabanlı çok terminalli yüksek gerilim doğru akım şebeke ile modifiye edilmiş IEEE 30-baralı test sistemindeki çok amaçlı optimal güç akışı problemini çözmek için uygulanmıştır.
- Önerilen ÇAOGA probleminde, toplam maliyet, valf noktası etkisi ile toplam maliyet, emisyon-karbon vergisi ile toplam maliyet, gerilim sapması ve aktif güç kayıpları amaç fonksiyonlarının ikili ve üçlü konfigürasyonları eş zamanlı olarak optimize edilmiştir.
- Simülasyon sonuçları, MOGOA yönteminin, elde edilen Pareto optimal çözümlerin doğruluğu ve bunların dağılımı açısından oldukça rekabetçi sonuçlar sağlayabildiğini göstermiştir.

5. DAĞITILMIŞ ÜRETİM VE YÜKSEK GERİLİM DOĞRU AKIM İLETİM HATLARINI İÇEREN GÜÇ SİSTEMLERİNDE OPTİMAL REAKTİF GÜÇ AKIŞI

Optimal güç akışı probleminin özel bir versiyonu olan Optimal Reaktif Güç Akışı (ORGA), güç sistemlerinin güvenli ve ekonomik işletimi açısından oldukça önemli bir araçtır. Çünkü modern güç sistemlerindeki aktif güç kaybı, gerilim profili ve gerilim güvenliği büyük ölçüde iletim hatlarındaki reaktif güç akışına bağlıdır. ORGA probleminde temel amaç aktif güç kayıplarını minimize etmektir. Ancak aktif güç kayıplarının en aza indirilmesi amacıyla ayarlanan kontrol değişkenleri farklı baralarda istenmeyen gerilim profiline ve voltaj stabilite marjına neden olabilir. Bu sebepten dolayı ORGA probleminin çözümünde amaç fonksiyonu olarak gerilim profili iyileştirmesi ve gerilim kararlılığı limitini geliştirmeyi dikkate almak oldukça önemlidir [45], [142].

Geleneksel enerji kaynaklarının çevre üzerindeki zararlı etkileri (fosil yakıt ve doğalgaz çevrim santrallerinin karbon salınımı ve nükleer atıkların tamamen yok edilemezliği) nedeniyle yenilenebilir enerji kaynaklarına yapılan yatırımlar her geçen gün artmaktadır. Rüzgâr, güneş vb. yenilenebilir enerji sistemleri iyi bilinen dağıtılmış üretim kaynaklarıdır. Bu kaynakların güç sistemine entegre edilmesinin en önemli avantajları geleneksel güç üretim kaynaklarına olan ihtiyacın azaltılması, güç kayıplarının azaltılması ve gerilim profilinin iyileştirilmesidir [53], [143]-[145].

Son yıllarda, artan küresel enerji talepleri nedeniyle, iletim hatları ve baralar üzerindeki baskı artmıştır. Sistemler üzerindeki baskıyı azaltmak için aktif güç aktarımı yoluyla güç sistemlerinin stabilizasyonu, iletim hattının hızlı kontrolü ve AA iletim hatlarına kıyasla güç kayıplarının azaltılması gibi üstün özelliklerinden dolayı YGDA iletim bağlantılarını içeren yeni planlama ve işletme çalışmaları büyük önem kazanmıştır.

Geleneksel termal jeneratörlerden oluşan bir elektrik şebekesinde optimal reaktif güç akışı probleminin çözümü güç sistemi araştırmacıları tarafından kapsamlı bir şekilde incelenmiştir [45]-[49]. Bu tez çalışmasında geleneksel ORGA probleminden farklı olarak çoklu dağıtılmış üretim (Distributed Generator, DG) ve iki terminalli Yüksek Gerilim Doğru Akım (YGDA) bağlantılarını içeren hibrit AA/DA güç sistemlerinde

ORGA probleminin çözümü araştırılmıştır. Bu kapsamda, tez çalışmasının orijinal katkılarından biri olarak geliştirilen FDBAGSK ve geleneksel AGSK algoritmaları modern güç sistemlerinin planlanması ve işletiminde önemli problemlerden biri olan kısıtlı AA/DA ORGA probleminin çözümüne uygulanmıştır. Optimizasyon algoritmalarının performansı, IEEE 30 ve IEEE 57-baralı test sistemlerinde farklı çalışma koşullarında gerçekleştirilen simülasyon çalışmaları ile test edilmiştir.

Bu bölümün geri kalanı şu şekilde düzenlenmiştir: Bölüm 5.1’de, çoklu Dağıtılmış Üretim (DÜ) ve yüksek gerilim doğru akım iletim bağlantılarını içeren AA/DA ORGA probleminin tanımı ve matematiksel modeli sunulmuştur. Bölüm 5.2, incelenen güç sistemi probleminin çözümünde dikkate alınan amaç fonksiyonları ve kısıtlar hakkındadır. Bölüm 5.3, AA/DA ORGA probleminin simülasyon çalışmaları ve sonuçlarını özetler. Bu kapsamda iki alt bölüm hazırlanmıştır. İlk alt bölümde çoklu dağıtılmış üretim ve yüksek gerilim doğru akım iletim hatlarını içeren IEEE 30-baralı güç sisteminde AA/DA ORGA probleminin çözümü araştırılmıştır. Diğer alt bölüm ise IEEE 57-baralı güç sisteminde gerçekleştirilen simülasyon çalışmaları hakkındadır. Bölüm 5.4’te, FDB yöntemi kullanılarak geliştirilen FDBAGSK ve geleneksel AGSK algoritmalarının istatistiksel analiz sonuçları ve literatür karşılaştırması verilmiştir. Bu kapsamda ilk olarak, optimizasyon algoritmalarının 20 bağımsız deneme için elde ettikleri simülasyon sonuçlarının minimum, ortalama, maksimum ve standart sapma değerleri sunulmuştur. Ardından, bu çalışmada AA/DA ORGA probleminin çözümü için kullanılan algoritmalar (AGSK ve FDBAGSK) ile elde edilen sonuçlar literatürde iyi bilinen güçlü algoritmaların simülasyon sonuçları ile karşılaştırılmıştır. Bölüm 5.5’te AA/DA ORGA probleminin sonuçları özetlenmiştir.

5.1. OPTİMAL REAKTİF GÜÇ AKIŞI PROBLEMİNİN TANIMI VE MATEMATİKSEL FORMÜLASYONU

AA/DA ORGA problemi, çeşitli eşitlik ve eşitsizlik kısıtlarına tabi olarak kontrol değişkenlerinin optimal ayarlanması yoluyla aktif güç kayıpları, gerilim sapması ve gerilim kararlılığı iyileştirmesi gibi seçilen amaç fonksiyonunun optimizasyonu olarak tanımlanmaktadır. AA/DA ORGA probleminin genel konsepti Eşitlik (5.1)’de verilmiştir [53]:

$$\text{minimize } F_{obj}(M, P)$$

$$\text{subject to } g(M, P) = 0 \quad (5.1)$$

$$h(M, P) \leq 0$$

Eşitlik (5.1)'de F_{obj} amaç fonksiyonunu temsil eder. M ve P sırasıyla durum ve kontrol değişkenleri olarak tanımlanır. $g(M, P)$ ve $h(M, P)$, eşitlik ve eşitsizlik kısıtlarını gösterir.

Dağıtılmış üretim ve iki terminalli YGDA iletim bağlantılarını içeren AA/DA ORGA probleminin durum değişkenleri aşağıdaki gibidir [53]:

- i. Salınım jeneratörü aktif güç değeri (P_{THG_1})
- ii. Termal jeneratör reaktif güç değeri (Q_{THG})
- iii. Yük barası gerilimi (V_L)
- iv. Doğrultucu (rectifier) ve evirici (inverter) trafo kademe oranı ayarları (t_r), (t_i)
- v. Doğrultucu ve evirici tarafında uyartım açısı değerleri (α_r), (γ_i)
- vi. Doğrultucu ve evirici tarafında DA gerilim değerleri (v_{dr}), (v_{di})

Durum değişkenleri vektörü M Eşitlik (5.2)'de verilmiştir.

$$M = [M^{AA}, M^{DA}]$$

$$M^{AA} = [P_{THG_1}, Q_{THG_1} \dots Q_{THG_{NTHG}}, V_{L_1} \dots V_{L_{NPQ}}] \quad (5.2)$$

$$M^{DA} = [t_r, t_i, \alpha_r, \gamma_i, v_{dr}, v_{di}]$$

Eşitlik (5.2)'de, P_{THG_1} salınım jeneratörünün aktif güç değerini, Q_{THG} termal jeneratörlerin reaktif güç değerini gösterir. V_L yük barası gerilim değerini temsil eder. $NTHG$ ve NPQ , sırasıyla termal jeneratörlerin ve yük baralarının sayısıdır. Doğrultucu ve evirici tarafındaki transformatörlerin kademe oranı sırasıyla t_r ve t_i ile sembolize edilir. α_r ve γ_i doğrultucu ve evirici uyartım açıları olarak tanımlanır. Doğrultucu ve evirici terminallerinin DA gerilimleri v_{dr} ve v_{di} ile gösterilir.

Dağıtılmış üretim ve iki terminalli YGDA bağlantılarını içeren AA/DA ORGA probleminin kontrol değişkenleri aşağıdaki gibi tanımlanır [53]:

- i. Termal jeneratör aktif güç değeri (P_{THG})
- ii. Termal jeneratör bara gerilimi (V_{THG})
- iii. Transformatör kademe oranı ayarı (T)
- iv. Dağıtılmış üretim ünitesi aktif güç değeri (P_{DG})
- v. Dağıtılmış üretim ünitesi konumu (loc_{DG})
- vi. Doğrultucu ve evirici terminallerinin aktif güç değeri (P_r), (P_i)
- vii. Doğrultucu ve evirici terminallerinin reaktif güç değeri (Q_r), (Q_i)
- viii. Doğru akım (i_d)

AA ve DA kontrol değişkenlerini içeren P vektörü Eşitlik (5.3)'te verilmiştir.

$$P = [P^{AA}, P^{DA}]$$

$$P^{AA} = [P_{THG_2} \dots P_{THG_{NTHG}}, V_{THG_1} \dots V_{THG_{NTHG}}, T_1 \dots T_{NT}, P_{DG_1} \dots P_{DG_{NDG}}, loc_{DG_1} \dots loc_{DG_{NDG}}] \quad (5.3)$$

$$P^{DA} = [P_r, P_i, Q_r, Q_i, i_d]$$

Eşitlik (5.3)'te P_{THG} termal jeneratörlerin aktif gücünü (salınım jeneratörü hariç), V_{THG} jeneratör baralarının gerilim değerini ve T transformatör kademe oranı ayarını sembolize eder. P_{DG} ve loc_{DG} , sırasıyla dağıtılmış üretim birimi aktif gücü ve konumu olarak tanımlanır. $NTHG$, NT , ve NDG termal jeneratör, transformatör ve dağıtılmış üretim birimi sayısını temsil eder. P_r , P_i , Q_r , ve Q_i doğrultucu ve eviricinin aktif ve reaktif güç değerini, i_d ise doğru akım değerini gösterir.

5.2. AMAÇ FONKSİYONLARI VE KISITLAR

5.2.1. Amaç Fonksiyonları

Dağıtılmış üretim ve iki terminalli YGDA iletim hatlarını içeren güç sistemlerinde AA/DA ORGA probleminin amaç fonksiyonları aşağıdaki gibi tanımlanır:

5.2.1.1. Güç kayıpları minimizasyonu

Güç akışı çalışmasında toplam üretim ($P_{THGk} + P_{DGk}$), şebekedeki talep (P_{Lk}) ve kayıpların (P_{loss}) toplamına eşit olmalıdır. Aktif güç kayıpları amaç fonksiyonu Eşitlik (5.4)'te verilmiştir [53].

$$F_{obj} (M, P) = F_{obj1} = P_{loss} = \sum_{k=1}^{NTHG} P_{THGk} + \sum_{k=1}^{NDG} P_{DGk} - \sum_{k=1}^{Nbus} P_{Lk} \quad (5.4)$$

Eşitlik (5.4)'te P_{THGk} , k . baradaki jeneratör aktif gücünü, P_{DGk} , k . baraya bağlı dağıtılmış üretim ünitesinin aktif güç çıkışını, P_{Lk} , k . baradan talep edilen yük değerini temsil eder. N_{bus} , toplam bara sayısını gösterir.

5.2.1.2. Gerilim sapması

Modern güç sistemlerinde gerilim sapması en önemli güvenlik indekslerinden biri olarak kabul edilmektedir. Çünkü; voltajdaki küçük bir değişiklik tüm sistemi etkileyebilir ve bir blokaj durumuna neden olabilir [134]. Gerilim sapması (VD) değeri aşağıdaki gibi hesaplanır:

$$F_{obj} (M, P) = F_{obj2} = VD = \sum_{i=1}^{NPQ} |VL_i - 1| \quad (5.5)$$

Eşitlik (5.5)'te VD gerilim sapmasını, VL_i i . yük barasının gerilim büyüklüğünü, NPQ yük baralarının sayısını gösterir.

5.2.1.3. Gerilim kararlılığının iyileştirilmesi

Artan enerji talepleri iletim hatları üzerindeki baskıyı artırmakta ve buna bağlı olarak güç sistemlerindeki kararlılık problemleri ortaya çıkmaktadır. Gerilim kararlılığı, güç sistemlerindeki önemli kararlılık problemlerinden biridir. Yük baralarının L -index değeri modern güç sistemlerindeki gerilim kararlılığının önemli bir göstergesidir. L -index değerinin 0 ile 1 arasında olması beklenirken, modern bir elektrik şebekesi için daha düşük bir L -index değeri daha kararlı bir durumu gösterir [140], [146].

$$L_{index,j} = \left| 1 - \sum_{i=1}^{NTHG} F_{ji} \frac{V_i}{V_j} \right| \quad j = 1, 2, \dots, NPQ \quad (5.6)$$

$$F_{ji} = - [Y_{LL}]^{-1} [Y_{LG}] \quad (5.7)$$

Eşitlik (5.6)'da $L_{index,j}$, j . baranın $L-index$ değerini temsil eder. Y_{LL} ve Y_{LG} alt matrisleri, Eşitlik (5.8)'de gösterildiği gibi yük ve jeneratör baraları ayrıldıktan sonra bara admittans matrisinden (Y_{BUS}) hesaplanır [134].

$$\begin{bmatrix} I_L \\ I_G \end{bmatrix} = [Y_{BUS}] \begin{bmatrix} V_L \\ V_G \end{bmatrix} = \begin{bmatrix} Y_{LL} & Y_{LG} \\ Y_{GL} & Y_{GG} \end{bmatrix} \begin{bmatrix} V_L \\ V_G \end{bmatrix} \quad (5.8)$$

Eşitlik (5.9)'da verilen gerilim kararlılığı indeksi ORGA problemi amaç fonksiyonu olarak dikkate alınmıştır.

$$F_{obj}(M, P) = F_{obj3} = \min(L_{max}) = \min(\max(L_{index,j})) \quad (5.9)$$

5.2.2. Kısıtlar

F_{obj1} , F_{obj2} ve F_{obj3} amaç fonksiyonları çeşitli eşitlik ve eşitsizlik kısıtlarına tabi olarak optimize edilmelidir. AA/DA ORGA probleminin eşitlik ve eşitsizlik kısıtları takip eden iki alt bölümde özetlenmiştir.

5.2.2.1. Eşitlik Kısıtları

Bu alt bölümde, AA/DA ORGA optimizasyon problemi eşitlik kısıtlarının matematiksel formülasyonu tanıtılmıştır. ORGA problemine ilişkin eşitlik kısıtları AA ve DA sistemleri için ayrı ayrı ele alınmıştır.


- AA şebeke eşitlik kısıtları

Dağıtılmış üretim (Distributed Generation, DG) ve iki terminalli YGDA iletim hattı bağlantılarını içeren AA bara modeli Şekil 5.1'de gösterilmiştir. k . baranın aktif ve reaktif güç eşitlikleri matematiksel olarak aşağıdaki gibi tanımlanır [53]:

$$P_{THGk} + P_{DGk} - P_{Lk} - P_{Dk} - P_k = 0 \quad (5.10)$$

$$Q_{THGk} + Q_{Ck} - Q_{Lk} - Q_{Dk} - Q_k = 0 \quad (5.11)$$

Eşitlikler (5.10) ve (5.11)'de P_{THGk} , P_{DGk} , P_{Lk} , P_k sırasıyla termal jeneratör, dağıtılmış üretim, yük barası ve k . baranın aktif gücü olarak tanımlanır. P_{Dk} , k . barada DA iletim bağlantısına verilen aktif güçtür. Q_{THGk} , Q_{Ck} , Q_{Lk} , Q_k sırasıyla termal jeneratör, şönt kompanzatör, yük barası, ve k . baranın reaktif gücünü gösterir. Q_{Dk} , dönüştürücünün reaktif güç tüketimidir.



Şekil 5.1. Dağıtılmış üretim (DG) ve DA iletim hattı ile modellenen AA bara.

AA sisteme aktarılan aktif ve reaktif güçler aşağıdaki gibi formüle edilir [146]:

$$P_k = v_k \sum_{j=1}^{N_{bus}} v_j [G_{kj} \cos(\delta_k - \delta_j) + B_{kj} \sin(\delta_k - \delta_j)] \quad (5.12)$$

$$Q_k = v_k \sum_{j=1}^{N_{bus}} v_j [G_{kj} \sin(\delta_k - \delta_j) - B_{kj} \cos(\delta_k - \delta_j)] \quad (5.13)$$

Eşitlikler (5.12) ve (5.13)'te v_k ve v_j , sırasıyla k . ve j . baranın gerilim büyüklüğünü gösterir. δ_k ve δ_j sırasıyla k . ve j . baranın gerilim açısı olarak tanımlanır. G_{kj} ve B_{kj} kondüktans ve süseptansı, N_{bus} ise toplam bara sayısını temsil eder.

Transformatör ve dönüştürücü kayıpları ihmal edildiğinden, dönüştürücü terminallerindeki güç eşitlikleri aşağıdaki denklemlerle gösterilir [53]:

$$P_{Dk} = P_r \quad (5.14)$$

$$Q_{Dk} = Q_r \quad (5.15)$$

$$P_{Dk} = -P_i \quad (5.16)$$

$$Q_{Dk} = Q_i \quad (5.17)$$

- DA şebeke eşitlik kısıtları

İki terminalli YGDA iletim hattının şematik diyagramı Şekil 5.2’de gösterilmiştir. İlgili şekilde v_r , v_i , i_r ve i_i sırasıyla doğrultucu ve eviricinin AA gerilim (rms) ve akım değerlerini temsil eder. δ_r , δ_i , ξ_r , ve ξ_i doğrultucu ve eviricinin faz açıları ve AA akım açılarını gösterir. r_{dc} , DA bağlantı direnci olarak tanımlanır [41].

İki terminalli YGDA iletim hattı için doğrultucu terminal denklemleri Eşitlikler (5.18)-(5.22)’de verilmiştir [41], [147], [148]:

$$v_{dor} = k t_r v_r \Rightarrow k = \frac{3\sqrt{2}}{\pi} \quad (5.18)$$

$$v_{dr} = v_{dor} \cos \alpha - r_{cr} i_d \Rightarrow r_{cr} = \frac{3x_{cr}}{\pi} \quad (5.19)$$

$$P_r = v_{dr} i_d \quad (5.20)$$

$$\phi_r = \cos^{-1}(v_{dr}/v_{dor}) \quad (5.21)$$

$$Q_r = |P_r \tan \phi_r| \quad (5.22)$$

Yukarıdaki eşitliklerde, v_{dor} doğrultucu terminali açık devre DA gerilim değerini gösterir. r_{cr} ve ϕ_r doğrultucu tarafındaki komütasyon direnci ve faz açısıdır.

İki terminalli YGDA iletim hattı evirici terminal denklemleri Eşitlik (5.23)-(5.27)’de verilmiştir [41], [147], [148]:

$$v_{doi} = k t_i v_i \Rightarrow k = \frac{3\sqrt{2}}{\pi} \quad (5.23)$$

$$v_{di} = v_{doi} \cos \gamma - r_{ci} i_d \Rightarrow r_{ci} = \frac{3x_{ci}}{\pi} \quad (5.24)$$


$$P_i = v_{di} i_d \quad (5.25)$$

$$\phi_i = \cos^{-1}(v_{di}/v_{doi}) \quad (5.26)$$


$$Q_i = |P_i \tan \phi_i| \quad (5.27)$$

Yukarıdaki eşitliklerde, v_{doi} evirici terminali açık devre DA gerilim değerini gösterir. r_{ci} ve ϕ_i evirici terminali komütasyon direnci ve faz açısı olarak tanımlanır. İki terminalli YGDA iletim hattı eşdeğer devresi Şekil 4.3’te gösterilmiştir. DA bara direnci dikkate alındığında, DA gerilim dengesi matematiksel olarak Eşitlik (5.28) ile temsil edilir [53]:

$$v_{dr} - v_{di} - r_{dc}i_d = 0 \quad (5.28)$$



Şekil 5.2. İki terminalli YGDA iletim hattı.



Şekil 5.3. İki terminalli YGDA iletim hattı eşdeğer devre modeli.

5.2.2.2. Eşitsizlik Kısıtları

Bu alt bölümde AA/DA ORGA probleminin eşitsizlik kısıtları matematiksel olarak formüle edilmiştir [53].

- AA şebeke eşitsizlik kısıtları

$$P_{THGi}^{min} \leq P_{THGi} \leq P_{THGi}^{max} \quad \forall i \in NTHG \quad (5.29)$$

$$P_{DGi}^{min} \leq P_{DGi} \leq P_{DGi}^{max} \quad \forall i \in NDG \quad (5.30)$$

$$Q_{THGi}^{min} \leq Q_{THGi} \leq Q_{THGi}^{max} \quad \forall i \in NTHG \quad (5.31)$$

$$V_{THGi}^{min} \leq V_{THGi} \leq V_{THGi}^{max} \quad \forall i \in NTHG \quad (5.32)$$

$$V_{Li}^{min} \leq V_{Li} \leq V_{Li}^{max} \quad \forall i \in NPQ \quad (5.33)$$

$$T_i^{min} \leq T_i \leq T_i^{max} \quad \forall i \in NT \quad (5.34)$$

- DA şebeke eşitsizlik kısıtları

$$i_d^{min} \leq i_d \leq i_d^{max} \quad (5.35)$$

$$P_{Dk}^{min} \leq P_{Dk} \leq P_{Dk}^{max} \quad k = r, i \quad (5.36)$$

$$Q_{Dk}^{min} \leq Q_{Dk} \leq Q_{Dk}^{max} \quad k = r, i \quad (5.37)$$

$$t_k^{min} \leq t_k \leq t_k^{max} \quad k = r, i \quad (5.38)$$

$$v_{dk}^{min} \leq v_{dk} \leq v_{dk}^{max} \quad k = r, i \quad (5.39)$$

$$\alpha_r^{min} \leq \alpha_r \leq \alpha_r^{max} \quad (5.40)$$

$$\gamma_i^{min} \leq \gamma_i \leq \gamma_i^{max} \quad (5.41)$$

AA/DA ORGA probleminin fitness fonksiyonu Eşitlik (5.42)'de gösterilmiştir. Eşitlik (5.42)'de, $\lambda_1, \lambda_2, \lambda_3, \lambda_4, \lambda_5, \lambda_6, \lambda_7, \lambda_8$, ve λ_9 ceza faktörü terimlerini temsil eder.

$$J_{fitness} = F_{obj}(M, P) + Ceza$$

$$\begin{aligned} Ceza = & \lambda_1 (P_{THG_1} - P_{THG_1}^{lim})^2 + \lambda_2 \sum_{i=1}^{NTHG} (Q_{THGi} - Q_{THGi}^{lim})^2 \\ & + \lambda_3 \sum_{i=1}^{NPQ} (V_{Li} - V_{Li})^2 + \lambda_4 (t_r - t_r^{lim})^2 + \lambda_5 (t_i - t_i^{lim})^2 \\ & + \lambda_6 (\alpha_r - \alpha_r^{lim})^2 + \lambda_7 (\gamma_i - \gamma_i^{lim})^2 + \lambda_8 (v_{dr} - v_{dr}^{lim})^2 \\ & + \lambda_9 (v_{di} - v_{di}^{lim})^2 \end{aligned} \quad (5.42)$$

Durum değişkenlerinin değeri limit değerlerden düşük veya yüksek ise bu değişkenlerin değeri limite ayarlanır. Kısıt ihlali durumları matematiksel olarak Eşitlik (5.43) - (5.51)'de ifade edilmiştir.

$$P_{THG_1}^{lim} = \begin{cases} P_{THG_1}^{min} & \text{if } P_{THG_1} < P_{THG_1}^{min} \\ P_{THG_1}^{max} & \text{if } P_{THG_1} > P_{THG_1}^{max} \end{cases} \quad (5.43)$$

$$Q_{THGi}^{lim} = \begin{cases} Q_{THGi}^{min} & \text{if } Q_{THGi} < Q_{THGi}^{min} \\ Q_{THGi}^{max} & \text{if } Q_{THGi} > Q_{THGi}^{max} \end{cases} \quad (5.44)$$

$$V_{Li}^{lim} = \begin{cases} V_{Li}^{min} & \text{if } V_{Li} < V_{Li}^{min} \\ V_{Li}^{max} & \text{if } V_{Li} > V_{Li}^{max} \end{cases} \quad (5.45)$$

$$t_r^{lim} = \begin{cases} t_r^{min} & \text{if } t_r < t_r^{min} \\ t_r^{max} & \text{if } t_r > t_r^{max} \end{cases} \quad (5.46)$$

$$t_i^{lim} = \begin{cases} t_i^{min} & \text{if } t_r < t_r^{min} \\ t_i^{max} & \text{if } t_r > t_r^{max} \end{cases} \quad (5.47)$$

$$\alpha_r^{lim} = \begin{cases} \alpha_r^{min} & \text{if } \alpha_r < \alpha_r^{min} \\ \alpha_r^{max} & \text{if } \alpha_r > \alpha_r^{max} \end{cases} \quad (5.48)$$

$$\gamma_i^{lim} = \begin{cases} \gamma_i^{min} & \text{if } \gamma_i < \gamma_i^{min} \\ \gamma_i^{max} & \text{if } \gamma_i > \gamma_i^{max} \end{cases} \quad (5.49)$$

$$v_{dr}^{lim} = \begin{cases} v_{dr}^{min} & \text{if } v_{dr} < v_{dr}^{min} \\ v_{dr}^{max} & \text{if } v_{dr} > v_{dr}^{max} \end{cases} \quad (5.50)$$

$$v_{di}^{lim} = \begin{cases} v_{di}^{min} & \text{if } v_{di} < v_{di}^{min} \\ v_{di}^{max} & \text{if } v_{di} > v_{di}^{max} \end{cases} \quad (5.51)$$

5.3. OPTİMAL REAKTİF GÜÇ AKIŞI PROBLEMİNİN SİMÜLASYON ÇALIŞMALARI VE SONUÇLARI

Bu alt bölümde, modern güç sistemlerinin optimal işletimi ve planlanmasında en önemli güç sistemi problemlerinden biri olan çoklu dağıtılmış üretim ve iki terminalli yüksek gerilim doğru akım iletim sistemlerini içeren güç sistemlerinde AA/DA ORGA probleminin optimizasyonu gerçekleştirilmiştir. Kısıtlı güç sistemi planlama probleminin tanımlandığı arama uzayının yüksek geometrik karmaşıklığı bu problem için global optimum çözümü bulmayı zorlaştırmaktadır. Bu durum, hibrit AA/DA elektrik şebekesini içeren optimal reaktif güç akışı problemini çözmek için verimli bir meta-sezgisel arama algoritmasının kullanılmasını gerektirir. Bu çalışmada kısıtlı AA/DA ORGA problemini çözmek için tez çalışmasının orijinal katkılarından biri olarak geliştirilen FDBAGSK ve baz AGSK algoritmaları kullanılmıştır. Optimizasyon algoritmalarının performansı IEEE 30 ve IEEE 57- baralı test sistemlerinde farklı çalışma koşulları altında gerçekleştirilen simülasyon çalışmaları ile test edilmiştir. Güç akışı hesaplamalarında MATPOWER 6.0 [149] paket programı kullanılmıştır. Simülasyon çalışmalarında maksimum iterasyon sayısı ve popülasyon büyüklüğü sırasıyla 200 ve 30 olarak kabul edilmiştir. Algoritmalar her bir simülasyon durumu için 20 kez çalıştırılmış ve en iyi, en kötü, ortalama ve standart sapma değerleri kaydedilmiştir.

Çizelge 5.1, IEEE 30 ve IEEE 57-baralı test sistemleri konfigürasyonunu sunar. IEEE 30-baralı test sisteminde toplam aktif ve reaktif yük değerleri 100 MVA baz değeri için sırasıyla 2,834 ve 1,262 p.u değerindedir. IEEE 57-baralı test sistemi için toplam aktif ve reaktif yük değerleri 100 MVA baz değeri için sırasıyla 12,508 ve 3,364 p.u. değerindedir.

Çizelge 5.2, AA/DA ORGA problemi için durum değişkenlerinin limitlerini özetler. Meta-sezgisel algoritmalar ile optimize edilen kontrol değişkenlerinin minimum ve maksimum değeri Çizelge 5.3’te verilmiştir [53]. Şekil 5.4’te verilen şematik diyagram, önerilen FDBAGSK algoritmasının AA/DA ORGA problemine uygulanma adımlarını göstermektedir.

Çizelge 5.1. IEEE 30 ve IEEE 57-baralı test sistemleri konfigürasyonu.

Ögeler	IEEE 30-Baralı Test Sistemi		IEEE 57-Baralı Test Sistemi	
	Nicelik	Detaylar	Nicelik	Detaylar
Bara	30	[139]	57	[150]
İletim Hattı	41	[139]	80	[150]
Termal jeneratör	5	Baralar: 2, 5, 8, 11 ve 13	6	Baralar: 2, 3, 6, 8, 9 ve 12
Salınım jeneratörü	1	Bara:1	1	Bara:1
Transformatör	4	İletim Hatları: 11, 12, 15 ve 36	17	İletim Hatları:19, 20, 31, 35, 36, 37, 41, 46, 54, 58, 59, 65, 66, 71, 73, 76 ve 80
Şönt kapasitör	2	Baralar: 10 ve 24	3	Baralar: 18, 25 ve 53

Çizelge 5.2. AA/DA ORGA problemi durum değişkenlerinin minimum ve maksimum limitleri.

IEEE 30-Baralı Test Sistemi					
Değişkenler (M^{AA})	M^{AA}_{min}	M^{AA}_{max}	Değişkenler (M^{DA})	M^{DA}_{min}	M^{DA}_{max}
P_{THG_1} (MW)	0	360,2	t_r	0,90	1,10
Q_{THG_1} (MVar)	-100	100			
Q_{THG_2} (MVar)	-40	50	t_i	0,90	1,10
Q_{THG_5} (MVar)	-40	40			
Q_{THG_8} (MVar)	-10	40	α_r (°)	9,74	22,91
$Q_{THG_{11}}$ (MVar)	-6	24	γ_i (°)	8,59	22,91
$Q_{THG_{13}}$ (MVar)	-6	24	v_{dr} (p.u.)	1,00	1,50
$V_{L_1} \dots V_{L_{NPQ}}$ (p.u.)	0,95	1,05	v_{di} (p.u.)	1,00	1,50

Çizelge 5.2. (devam) AA/DA ORGA problemi durum değişkenlerinin minimum ve maksimum limitleri.


IEEE 57-Baralı Test Sistemi					
Değişkenler (M^{AA})	M^{AA}_{min}	M^{AA}_{max}	Değişkenler (M^{DA})	M^{DA}_{min}	M^{DA}_{max}
P_{THG_1} (MW)	20	50	t_r	0,90	1,10
Q_{THG_1} (MVar)	-100	100			
Q_{THG_2} (MVar)	-17	50	t_i	0,90	1,10
Q_{THG_3} (MVar)	-10	60			
Q_{THG_6} (MVar)	-8	25			
Q_{THG_8} (MVar)	-140	200	α_r (°)	5,00	30,00
Q_{THG_9} (MVar)	-3	9	γ_i (°)	10,00	30,00
$Q_{THG_{12}}$ (MVar)	-150	155	v_{dr} (p.u.)	1,00	1,40
$V_{L_1} \dots V_{L_{NPQ}}$ (p.u.)	0,94	1,06	v_{di} (p.u.)	1,00	1,40

Çizelge 5.3. AA/DA ORGA problemi kontrol değişkenlerinin minimum ve maksimum limitleri.

IEEE 30-Baralı Test Sistemi					
Değişkenler (P^{AA})	P^{AA}_{min}	P^{AA}_{max}	Değişkenler (P^{DA})	P^{DA}_{min}	P^{DA}_{max}
P_{THG_2} (MW)	0	140	P_r (p.u.)	0,1	1,50
V_{THG_1} (p.u.)	1,00	1,15			
V_{THG_2} (p.u.)	1,00	1,15	P_i (p.u.)	0,1	1,50
V_{THG_5} (p.u.)	1,00	1,15			
V_{THG_8} (p.u.)	1,00	1,15	Q_r (p.u.)	0,001	0,75
$V_{THG_{11}}$ (p.u.)	1,00	1,15			
$V_{THG_{13}}$ (p.u.)	1,00	1,15	Q_i (p.u.)	0,001	0,75
$T_1 \dots T_{NT}$ (p.u.)	0,90	1,10	i_d	0,1	1,00
$P_{DG1} \dots P_{DGNDG}$ (MW)	0	10			
$loc_{DG1} \dots loc_{DGNDG}$	1	29			

Çizelge 5.3. (devam) AA/DA ORGA problemi kontrol değişkenlerinin minimum ve maksimum limitleri.

IEEE 57-Baralı Test Sistemi					
Değişkenler (P^{AA})	P^{AA}_{min}	P^{AA}_{max}	Değişkenler (P^{DA})	P^{DA}_{min}	P^{DA}_{max}
P_{THG_2} (MW)	15	90	P_r (p.u.)	0,1	1,50
P_{THG_3} (MW)	10	500			
P_{THG_6} (MW)	10	50	P_i (p.u.)	0,1	1,50
P_{THG_8} (MW)	12	50			
P_{THG_9} (MW)	10	360	Q_r (p.u.)	0,001	0,75
$P_{THG_{12}}$ (MW)	5	550			
V_{THG_1} (p.u.)	0,9	1,1	Q_i (p.u.)	0,001	0,75
V_{THG_2} (p.u.)	0,9	1,1			
V_{THG_3} (p.u.)	0,9	1,1	i_d	0,05	1,00
V_{THG_6} (p.u.)	0,9	1,1			
V_{THG_8} (p.u.)	0,9	1,1			
V_{THG_9} (p.u.)	0,9	1,1			
$V_{THG_{12}}$ (p.u.)	0,9	1,1			
$T_1 \dots T_{NT}$ (p.u.)	0,9	1,1			
$P_{DG1} \dots P_{DGNDG}$ (MW)	0	30			
$loc_{DG1} \dots loc_{DGNDG}$	1	56			



Şekil 5.4. AA/DA ORGA probleminin optimizasyon süreci.

Dağıtılmış üretim üniteleri ve iki terminalli YGDA iletim sistemlerini içeren IEEE 30 ve IEEE 57-baralı güç sistemlerindeki simülasyon çalışmaları Çizelge 5.4'te tanımlanan çoklu test durumlarına göre gerçekleştirilmiştir.

Çizelge 5.4. Simülasyon çalışmalarının özeti.

Simülasyon Modeli	IEEE 30-Baralı Test Sistemi					
	P_{loss}	VD	$L - index$	3-DÜ	YGDA iletim hattı (2-14)	YGDA iletim hattı (2-16)
Durum-1	✓	-	-	-	✓	-
Durum-2	✓	-	-	-	-	✓
Durum-3	✓	-	-	✓	-	-
Durum-4	✓	-	-	✓	✓	-
Durum-5	✓	-	-	✓	-	✓
Durum-6	-	✓	-	✓	-	✓
Durum-7	-	-	✓	✓	-	✓
Simülasyon Modeli	IEEE 57-Baralı Test Sistemi					
	P_{loss}	VD	$L - index$	3-DÜ	YGDA iletim hattı (8-9)	
Durum-8	✓	-	-	-	✓	
Durum-9	✓	-	-	✓	-	
Durum-10	✓	-	-	✓	✓	
Durum-11	-	✓	-	✓	✓	
Durum-12	-	-	✓	✓	✓	


5.3.1. Modifiye IEEE 30 Baralı Test Sistemi

Bu alt bölümde, çoklu dağıtılmış üretim üniteleri ve iki terminalli YGDA iletim hattı ile modifiye edilmiş IEEE 30-baralı test sisteminde AA/DA ORGA probleminin optimizasyonu gerçekleştirilmiştir. Bu kapsamda yedi farklı simülasyon çalışması (Durum-1,...,Durum-7) için problemin çözümü araştırılmıştır.


Durum-1: İki terminalli YGDA iletim hattı (Bara 2 ve 14 arasında) içeren hibrit AA/DA güç sisteminde aktif güç kayıpları optimizasyonu

Durum-1’de, IEEE 30-baralı test sisteminin 2 ve 14 numaralı baraları arasına yerleştirilmiş iki terminalli YGDA iletim hattını içeren hibrit güç sisteminde aktif güç kayıpları (P_{loss}) optimizasyonu gerçekleştirilmiştir. Çizelge 5.5, önerilen FDBAGSK ve geleneksel AGSK algoritmaları ile elde edilen simülasyon sonuçlarını göstermektedir. İlgili çizelgeden, Durum-1 için FDBAGSK ve AGSK yöntemleri ile elde edilen aktif güç

kayıpları değerinin sırasıyla 11,4208 MW ve 11,5165 MW olduğu görülmektedir. Simülasyon sonuçlarından önerilen FDBAGSK algoritmasının AGSK'ya kıyasla %0,8379 daha düşük aktif güç kaybı değeri elde ettiği gözlemlenmiştir. Şekil 5.5 (a), iterasyon sayısına bağlı olarak aktif güç kaybı değişimini göstermektedir. Önerilen algoritmanın yakınsama hızı ve doğruluğu açısından AGSK'ya kıyasla üstün bir arama performansı sergilediği görülmektedir. Şekil 5.5 (b)'de verilen gerilim profili, optimizasyon sonunda her iki algoritma tarafından elde edilen yük bara gerilimlerinin kabul edilebilir sınırlar içinde olduğunu göstermiştir.



Şekil 5.5. Durum-1: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.




(b)


Şekil 5.5. (devam) Durum-1: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Durum-2: İki terminalli YGDA iletim hattı (Bara 2 ve 16 arasında) içeren hibrit AA/DA güç sisteminde aktif güç kayıpları optimizasyonu

Durum-2’de, 2 ve 16 numaralı baralar arasına entegre edilen iki terminalli YGDA iletim hattı ile modifiye edilmiş IEEE 30-baralı test sisteminin aktif güç kayıpları (P_{loss}) minimize edilmiştir. Çizelge 5.5’te verilen simülasyon sonuçları detaylı olarak incelendiğinde önerilen FDBAGSK yönteminin AGSK simülasyon sonucuna (11,1171 MW) kıyasla %0,2248 daha düşük olan 11,0921 MW değerini elde ettiği anlaşılmaktadır. Şekil 5.6 (a), Durum-2 için optimizasyon algoritmalarının yakınsama eğrilerini göstermektedir. Yakınsama eğrileri FDBAGSK algoritmasının optimal çözüme başarılı bir şekilde yakınsadığını göstermektedir. Şekil 5.6 (b), mevcut test durumu için optimizasyon süreci sonucunda yük baralarının gerilim profilini göstermektedir. Buna göre, algoritmaların yük baralarının gerilim büyüklüğünü kabul edilebilir sınırlar (0,95-1,05 p.u.) içinde tutmada başarılı olduğunu söylemek mümkündür.



(a)




(b)


Şekil 5.6. Durum-2: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Durum-3: Çoklu dağıtılmış üretim ünitelerini içeren güç sisteminde aktif güç kayıpları optimizasyonu

Dağıtılmış üretim birimlerini (3-DÜ) içeren IEEE 30-baralı güç sisteminin aktif güç kayıpları (P_{loss}) minimizasyonu Durum-3'te incelenmiştir. Mevcut simülasyon durumunda dağıtılmış üretim birimlerinin aktif güç değeri ve konumu kontrol değişkeni olarak kabul edilmiştir. Çizelge 5.5'te verilen simülasyon sonuçlarından Durum-3 için FDBAGSK ve AGSK algoritmaları ile elde edilen amaç fonksiyonu değerlerinin sırasıyla 9,3182 MW ve 9,2984 MW olduğu görülmektedir. Simülasyon sonuçları, incelenen problem için önerilen FDBAGSK algoritmasının AGSK'ya kıyasla amaç fonksiyonu değerinde %0,2124'lük bir azalma sağladığını göstermiştir. Optimizasyon algoritmalarının yakınsama eğrileri ve yük baralarının gerilim profili sırasıyla Şekil 5.7 (a) ve (b)'de gösterilmiştir. Şekil 5.7 (a), FDBAGSK algoritmasının yakınsama hızı ve doğruluğu açısından baz algoritmaya kıyasla üstün olduğunu göstermektedir. Şekil 5.7 (b)'de verilen eğrilerden optimizasyon sonunda PQ bara gerilimlerinin belirtilen sınırlar içinde tutulduğu anlaşılmaktadır.



Şekil 5.7. Durum-3: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.




(b)


Şekil 5.7. (devam) Durum-3: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Durum-4: İki terminalli YGDA iletim hattı (Bara 2 ve 14 arasında) ve çoklu DÜ ünitelerini içeren hibrit AA/DA güç sisteminde aktif güç kayıpları optimizasyonu

Durum-4'te, çoklu dağıtılmış üretim birimleri (3-DÜ) ve iki terminalli YGDA iletim hattını (Bara 2 ve 14 arasında) içeren hibrit AA/DA güç sisteminde aktif güç kayıpları (P_{loss}) optimizasyonu çalışılmıştır. Çizelge 5.5'te verilen simülasyon sonuçlarından FDBAGSK ve AGSK algoritmaları ile elde edilen aktif güç kayıpları değerinin sırasıyla 8,7366 MW ve 8,8093 MW olduğu görülmektedir. Durum-4 için simülasyon sonuçlarının karşılaştırmalı analizi önerilen FDBAGSK algoritmasının geleneksel AGSK'ya kıyasla amaç fonksiyonunda %0,8252'lik bir iyileşme sağladığını göstermiştir. Şekil 5.8 (a) ve (b), mevcut simülasyon durumu için optimizasyon algoritmalarının yakınsama eğrilerini ve simülasyon sonucunda elde edilen yük baralarının gerilim profilini göstermektedir. Yakınsama eğrileri (Şekil 5.8-a), önerilen FDBAGSK yönteminin yakınsama hızı ve doğruluğu açısından AGSK'dan daha iyi arama performansı sergilediğini göstermiştir. Şekil 5.8 (b)'den, yük baraları gerilim büyüklüklerinin belirtilen sınırlar içinde olduğu açıkça görülmektedir.



(a)




(b)


Şekil 5.8. Durum-4: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Durum-5: İki terminalli YGDA iletim hattı (Bara 2 ve 16 arasında) ve çoklu DÜ ünitelerini içeren hibrit AA/DA güç sisteminde aktif güç kayıpları optimizasyonu

Durum 5'te, iki terminalli YGDA iletim hattı (Bara 2 ve 16 arasında) ve çoklu DÜ ünitelerini (3-DG) içeren AA/DA güç sisteminde aktif güç kayıplarının (P_{loss}) optimizasyonu çalışılmıştır. Çizelge 5.5'te verilen simülasyon sonuçlarından önerilen FDBAGSK algoritması ile elde edilen simülasyon sonucunun (8,2344 MW) baz AGSK algoritmasının rapor edilen en iyi sonucuna (8,2391 MW) kıyasla daha iyi olduğu tespit edilmiştir. Şekil 5.9 (a), iterasyon sayısına bağlı olarak algoritmaların yakınsama eğrilerini göstermektedir. İlgili şekilden, önerilen FDBAGSK algoritmasının AGSK algoritmasına kıyasla optimal çözüme daha hızlı bir şekilde yakınsayabildiği görülmektedir. Şekil 5.9 (b)'de verilen gerilim profili grafiği, optimizasyon sonunda yük baraları gerilim değerlerinin belirtilen sınırlar içinde olduğunu göstermektedir.



Şekil 5.9. Durum-5: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.




(b)


Şekil 5.9. (devam) Durum-5: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Durum-6: İki terminalli YGDA iletim hattı (Bara 2 ve 16 arasında) ve çoklu DÜ ünitelerini içeren hibrit AA/DA güç sisteminde gerilim sapması optimizasyonu

Durum-6’da, çoklu DÜ üniteleri ve iki terminalli YGDA iletim hattı (2-16 numaralı baralar arasında) ile modifiye edilmiş hibrit AA/DA güç sisteminde gerilim sapması (VD) minimizasyonu incelenmiştir. Çizelge 5.5’te verilen simülasyon sonuçlarından, önerilen FDBAGSK yöntemi ile elde edilen gerilim sapması değerinin (0,1539 p.u.) AGSK algoritması simülasyon sonucuna kıyasla %0,5814 daha düşük olduğu gözlemlenmiştir. Şekil 5.10-(a) mevcut simülasyon durumu için algoritmaların yakınsama eğrilerini göstermektedir. Yakınsama grafiklerinden, FDB tabanlı AGSK ve geleneksel AGSK algoritmalarının gerilim sapması minimizasyonu optimizasyon problemi için benzer arama performansı sergilediğini söylemek mümkündür. Şekil 5.10-(b)’de verilen gerilim profili grafiği, iki algoritmanın da PQ bara gerilim büyüklüklerini belirtilen sınırlar içinde tutmada başarılı olduğunu göstermiştir.



(a)




(b)


Şekil 5.10. Durum-6: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Durum-7: İki terminalli YGDA iletim hattı (Bara 2 ve 16 arasında) ve çoklu DÜ ünitelerini içeren hibrit AA/DA güç sistemi gerilim kararlılığının iyileştirilmesi

Durum-7’de, iki terminalli YGDA iletim hattı (Bara 2 ve 16 arasında) ve çoklu DÜ birimlerini içeren AA/DA güç sisteminde *L-index* değerinin optimizasyonu gerçekleştirilmiştir. Mevcut simülasyon durumu için optimize edilmiş kontrol parametreleri ve amaç fonksiyonu değeri Çizelge 5.5’te verilmiştir. Buna göre önerilen FDBAGSK algoritması *L-index* optimizasyonunda AGSK yöntemine kıyasla daha başarılı bir performans sergilemiştir. Daha açık bir ifadeyle önerilen algoritma, baz AGSK yöntemi ile elde edilen simülasyon sonucundan %2,5761 daha düşük olan 0,0832 p.u. değerini elde etmiştir. Şekil 5.11-(a), Durum-7 için optimizasyon algoritmalarının yakınsama eğrilerini göstermektedir. Yakınsama eğrilerinden FDBAGSK algoritmasının yakınsama hızı ve doğruluğu açısından AGSK yöntemine ezici bir üstünlük sağladığı gözlemlenmiştir. Şekil 5.11-(b)’de verilen gerilim profili, FDBAGSK ve AGSK algoritmalarının optimizasyon sonucunda PQ bara gerilim büyüklüklerini kabul edilebilir sınırlar (0,95-1,05 p.u.) içinde tutmada başarılı olduğunu göstermiştir.



Şekil 5.11. Durum-7: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.



(b)

Şekil 5.11. (devam) Durum-7: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Çizelge 5.5. IEEE 30-baralı test sistemi simülasyon sonuçları.


Parametreler	Durum-1		Durum-2		Durum-3		Durum-4		Durum-5		Durum-6		Durum-7	
	AGSK	FDBAGSK	AGSK	FDBAGSK	AGSK	FDBAGSK	AGSK	FDBAGSK	AGSK	FDBAGSK	AGSK	FDBAGSK	AGSK	FDBAGSK
P_{THG1}	155,1764	154,8529	154,5713	154,5138	122,9623	122,7181	133,1428	122,3779	121,6531	121,6530	162,4578	167,3362	139,9377	145,4780
P_{THG2}	139,7581	139,9792	139,9596	139,9906	139,9846	139,9919	139,9146	139,9413	140	139,9952	111,0879	106,9425	132,0091	126,9718
Q_{THG1}	-4,8523	-1,52039	3,42176	-3,8792	-3,3560	-8,5582	-3,7745	9,8478	-5,4042	-2,3202	1,1118	20,2677	47,0746	99,7263
Q_{THG2}	30,5790	30,8157	30,7258	40,5468	23,1243	22,7326	30,7094	30,2389	31,0039	31,5211	35,0257	39,6685	12,3071	-5,1872
Q_{THG5}	32,2826	35,0480	32,2685	31,7673	30,8555	28,8578	31,4810	25,1780	29,6142	29,3328	39,0287	34,7530	13,5131	-8,9432
Q_{THG8}	37,1424	29,6735	34,6844	28,0358	32,0068	29,9490	26,9206	35,0002	30,4424	28,8048	39,5134	16,2684	32,8524	16,5622
Q_{THG11}	22,2749	11,1531	4,59555	23,4450	20,8151	22,3768	21,3298	5,1876	14,0537	19,8629	17,5664	18,3119	-4,6946	21,0597
Q_{THG13}	10,2787	17,1492	13,8808	9,0022	4,2341	12,3223	9,1224	7,8357	13,8104	9,1559	8,5202	1,6832	21,0203	2,1795
V_{THG1}	1,0796	1,0829	1,0852	1,0831	1,0806	1,0765	1,0782	1,0840	1,0752	1,0770	1,0453	1,0647	1,0634	1,1160
V_{THG2}	1,0668	1,0695	1,0700	1,0711	1,0719	1,0693	1,0675	1,0694	1,0656	1,0663	1,0290	1,0420	1,0301	1,0631
V_{THG5}	1,0332	1,0351	1,0322	1,0337	1,0360	1,0324	1,0319	1,0277	1,0309	1,0313	0,9998	1,0016	0,9694	0,9791
V_{THG8}	1,0395	1,0323	1,0336	1,0337	1,0379	1,0366	1,0344	1,0363	1,0368	1,0367	1,0010	0,9910	0,9892	1,0129
V_{THG11}	1,0748	1,0687	1,0567	1,0860	1,0648	1,0748	1,0805	1,0440	1,0693	1,0781	1,0357	1,0465	0,9957	1,0841
V_{THG13}	1,0417	1,0666	1,0671	1,0615	1,0482	1,0661	1,0388	1,0590	1,0681	1,0620	1,0276	1,0161	1,0409	1,0515
T_{11}	1,0118	0,9747	0,9919	1,0523	1,0877	1,0839	0,9993	1,0113	1,0375	1,0559	1,0592	1,0266	0,9809	1,0253
T_{12}	1,0992	1,0884	0,9513	0,9239	0,9123	0,9019	1,0940	0,9992	0,9201	0,9139	0,9003	0,9415	0,9353	0,9113
T_{15}	0,9813	0,9840	0,9760	0,9656	0,9687	0,9816	0,9858	0,9531	0,9795	0,9697	0,9433	0,9435	0,9904	0,9459
T_{36}	0,9900	0,9527	0,9872	0,9554	0,9696	0,9605	0,9781	0,9706	0,9665	0,9646	0,9390	0,9368	0,9141	0,9478
P_r	0,3144	0,2588	0,2724	0,2690	-	-	0,2474	0,2620	0,2958	0,2905	0,3063	0,2678	0,2948	0,2625
P_i	0,3142	0,2587	0,2723	0,2689	-	-	0,2473	0,2619	0,2957	0,2904	0,3061	0,2676	0,2946	0,2624
Q_r	0,1094	0,0741	0,0703	0,1154	-	-	0,0772	0,0962	0,1083	0,1234	0,1359	0,0954	0,0813	0,1007
Q_i	0,0633	0,0485	0,0543	0,0712	-	-	0,0502	0,0619	0,0545	0,0537	0,1346	0,0991	0,0589	0,0595
t_r	0,9960	1,0141	0,9606	1,0560	-	-	0,9359	1,0324	1,0986	1,0994	1,0311	0,9885	0,9129	1,0709
t_i	0,9921	1,0147	0,9702	1,0291	-	-	0,9470	1,0149	1,0654	1,0462	1,0543	1,0291	0,9155	1,0419
α_r (°)	17,1191	14,0506	11,9153	21,9110	-	-	15,3085	18,6686	18,5910	21,6996	22,2684	17,7794	12,2556	19,6266
γ_i (°)	9,2258	8,8751	9,3804	13,6003	-	-	9,6404	11,9340	8,6066	8,6152	22,7872	19,3298	8,7725	11,4145
v_{dr}	1,3551	1,4081	1,3442	1,4038	-	-	1,2880	1,3995	1,4845	1,4572	1,3098	1,3104	1,2244	1,4355
v_{di}	1,3544	1,4075	1,3435	1,4032	-	-	1,2874	1,3989	1,4839	1,4566	1,3090	1,3097	1,2236	1,4349
i_d	0,2320	0,1838	0,2027	0,1916	-	-	0,1921	0,1872	0,1993	0,1994	0,2338	0,2044	0,2408	0,1828
$P_{DG1}(loc_{DG1})$	-	-	-	-	9,9958 (7)	9,9921 (19)	9,9747(29)	9,9722 (21)	10 (7)	9,9999 (7)	1,4569(19)	8,4629 (24)	9,9159(29)	9,9992 (24)
$P_{DG2}(loc_{DG2})$	-	-	-	-	9,8338(24)	10 (7)	9,9877(29)	9,9103 (19)	10 (29)	9,9996 (19)	9,8340 (9)	2,1937 (12)	9,8752(25)	9,9775 (29)
$P_{DG3}(loc_{DG3})$	-	-	-	-	9,9417(19)	9,9963 (24)	9,9396(21)	9,9466 (7)	9,9993(24)	9,9999(29)	9,8045 (8)	9,6879(20)	2,2126(19)	2,3082 (3)
$P_{loss}(MW)$	11,5165	11,4208	11,1171	11,0921	9,3182	9,2984	8,8093	8,7366	8,2391	8,2344	11,2229	11,2093	10,5313	11,3236
$VD(p.u.)$	0,4033	0,6508	0,7182	0,8396	0,7320	0,8900	0,5053	0,6771	0,9253	0,9246	0,1548	0,1539	0,2939	0,8332
$L - index$	0,1419	0,1354	0,1390	0,1339	0,1276	0,1254	0,0840	0,1309	0,0815	0,0894	0,1386	0,1327	0,0854	0,0832

5.3.2. Modifiye IEEE 57 Baralı Test Sistemi


Bu alt bölümde, önerilen FDBAGSK algoritmasının büyük ölçekli güç sistemlerindeki etkinliğini test etmek amacıyla gerçekleştirilen simülasyon çalışmaları özetlenmiştir. Bu kapsamda önerilen algoritma IEEE 57-baralı test sisteminde AA/DA ORGA probleminin optimizasyonuna uygulanmıştır.

Durum-8: İki terminalli YGDA iletim hattı (Bara 8 ve 9 arasında) içeren hibrit AA/DA güç sisteminde aktif güç kayıpları optimizasyonu

Durum-8’de, iki terminalli YGDA iletim hattı (Bara 8 ve 9 arasında) ile modifiye edilmiş IEEE 57-baralı test sisteminde aktif güç kayıpları (P_{loss}) minimizasyonu gerçekleştirilmiştir. IEEE 57-baralı test sistemi simülasyon sonuçları Çizelge 5.6’da sunulmuştur. Buna göre, Durum-8 için önerilen FDBAGSK ve baz AGSK algoritmaları ile elde edilen amaç fonksiyonu değerleri sırasıyla 13,4340 MW ve 14,8919 MW’dır. Daha açık bir ifadeyle FDBAGSK ile elde edilen aktif güç kayıpları AGSK algoritmasının simülasyon sonucuna kıyasla %9,7898 daha düşüktür. Şekil 5.12-(a) ve (b), sırasıyla algoritmaların yakınsama eğrilerini ve yük baralarının gerilim profilini göstermektedir. Yakınsama eğrilerinden FDB tabanlı AGSK algoritmasının yakınsama hızı ve doğruluğu açısından baz algoritmaya kıyasla daha başarılı bir arama performansı sergilediği gözlemlenmiştir. Yük baraları gerilim profili, optimizasyon sonunda FDBAGSK ve AGSK algoritmalarının gerilim büyüklüklerini belirtilen limitler dahilinde tutmada başarılı olduklarını göstermiştir.



(a)




(b)


Şekil 5.12. Durum 8: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Durum-9: Çoklu dağıtılmış üretim ünitelerini içeren güç sisteminde aktif güç kayıpları optimizasyonu

Durum-9’da, çoklu dağıtılmış üretim üniteleri (3-DÜ) ile modifiye edilen IEEE 57-baralı test sisteminde aktif güç kayıpları (P_{loss}) optimizasyonu gerçekleştirilmiştir. Çizelge 5.6’da verilen simülasyon sonuçlarına göre, FDBAGSK ve AGSK yöntemleri ile elde edilen aktif güç kayıpları sırasıyla 9,5561 MW ve 10,2867 MW’dır. Simülasyon sonuçlarından önerilen algoritmanın geleneksel AGSK yöntemine kıyasla aktif güç kayıplarında %7,1023 değerinde bir azalma sağladığı gözlemlenmiştir. Şekil 5.13 (a), iterasyon sayısına bağlı olarak algoritmaların elde ettiği amaç fonksiyonu değerini göstermektedir. İlgili şekilden, önerilen FDBAGSK algoritmasının baz algoritmayla kıyasla daha hızlı bir şekilde optimal çözüme yakınsadığı görülmektedir. Durum-9 için verilen gerilim profili (Şekil 5.13-b), PQ baraların gerilim büyüklüklerinin limitler dahilinde olduğunu göstermektedir.





Şekil 5.13. Durum-9: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.



Şekil 5.13. (devam) Durum-9: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Durum-10: İki terminalli YGDA iletim hattı (Bara 8 ve 9 arasında) ve çoklu DÜ ünitelerini içeren hibrit AA/DA güç sisteminde aktif güç kayıpları optimizasyonu


Durum-10’da, iki terminalli YGDA iletim hattı (Bara 8 ve 9 arasında) ve çoklu dağıtılmış üretim birimlerini (3-DÜ) içeren IEEE 57-baralı güç sisteminde aktif güç kayıpları (P_{loss}) minimizasyonuna odaklanılmıştır. Çizelge 5.6’da verilen simülasyon sonuçlarından önerilen FDBAGSK (8,2632 MW) algoritmasının baz AGSK’ya (9,0513 MW) kıyasla amaç fonksiyonu değerinde %8,7070 değerinde bir iyileşme sağladığı gözlemlenmiştir. İki algoritma arasındaki dikkate değer fark FDB tabanlı AGSK yönteminin keşif ve dengeli arama yeteneklerinin baz algoritmaya kıyasla üstün olması ile açıklanabilir. Şekil 5.14-(a), algoritmaların iterasyon sayısına bağlı olarak elde ettiği amaç fonksiyonu değerlerini göstermektedir. İlgili şekilden, önerilen algoritmanın AGSK algoritmasına kıyasla global optimuma daha hızlı yakınsadığı görülmektedir. Durum-10 için verilen yük baraları gerilim profili (Şekil 5.14-b), optimizasyon sürecinin sonunda PQ bara gerilim büyüklüklerinin sınırlar içinde olduğunu açıkça göstermektedir.




Şekil 5.14. Durum-10: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Durum-11: İki terminalli YGDA iletim hattı (Bara 8 ve 9 arasında) ve çoklu DÜ ünitelerini içeren hibrit AA/DA güç sisteminde gerilim sapması optimizasyonu

Durum-11’de, iki terminalli YGDA iletim hattı (Bara 8 ve 9 arasında) ve çoklu dağıtılmış üretim üniteleri (3-DÜ) ile modifiye edilmiş IEEE 57-baralı test sisteminin gerilim sapması (VD) optimizasyonu ele alınmıştır. Çizelge 5.6’da verilen simülasyon sonuçları incelendiğinde, FDBAGSK yönteminin AGSK algoritmasına (0,7617) kıyasla %21,1500 daha düşük olan 0,6006 p.u. değerini elde ettiği görülmektedir. Durum-11 için algoritmaların yakınsama eğrileri Şekil 5.15-(a)’da gösterilmiştir. Yakınsama eğrilerinden önerilen algoritmanın arama performansının yakınsama hızı ve doğruluğu performans metriklerine dayalı olarak AGSK algoritmasına kıyasla daha iyi olduğu tespit edilmiştir. Durum-11 için yük baralarının simülasyon süreci sonundaki gerilim profilleri Şekil 5.15 (b)’de gösterilmiştir. Buna göre, PQ bara gerilimlerinin kabul edilebilir limitler dahilinde olduğunu söylemek mümkündür.



Şekil 5.15. Durum-11: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.





(b)

Şekil 5.15. (devam) Durum-11: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Durum 12: İki terminalli YGDA iletim hattı (Bara 2 ve 16 arasında) ve çoklu DÜ ünitelerini içeren hibrit AA/DA güç sisteminde gerilim kararlılığının iyileştirilmesi

Druum 12’de, iki terminalli YGDA iletim hattı (Bara 2 ve 16 arasında) ve çoklu DÜ (3-DÜ) üniteleri ile modifiye edilmiş AA/DA güç sisteminde gerilim kararlılığı iyileştirmesi (*L-index*) optimizasyonu gerçekleştirilmiştir. Çizelge 5.6’da verilen simülasyon sonuçlarına göre, önerilen FDBAGSK algoritması ile elde edilen *L-index* değeri 0,1266 p.u. olup, bu değer AGSK algoritması simülasyon sonucuna kıyasla %3,3587 daha düşüktür. Modern güç sistemlerinde daha düşük bir *L-index* değeri daha kararlı bir gerilim profiline işaret eder. Buna göre önerilen FDBAGSK algoritması ile elde edilen gerilim kararlılığı iyileştirmesi baz algoritmaya kıyasla daha iyidir. Şekil 5.16, algoritmaların yakınsama eğrilerini ve yük baralarının gerilim profilini göstermektedir. İlgili şekilden, önerilen yöntemin global optimuma daha hızlı ve başarılı bir yakınsama sağladığı görülmektedir. Ayrıca optimizasyon algoritmalarının PQ bara gerilimlerini belirtilen sınırlar içinde tutmada başarılı olduklarını söylemek mümkündür.



Şekil 5.16. Durum-12: (a) Yakınsama eğrileri, (b) Yük baraları gerilim profili.

Çizelge 5.6. IEEE 57-baralı test sistemi simülasyon sonuçları.

Parametreler	Durum-8		Durum-9		Durum-10		Durum-11		Durum-12	
	AGSK	FDBAGSK	AGSK	FDBAGSK	AGSK	FDBAGSK	AGSK	FDBAGSK	AGSK	FDBAGSK
P_{THG1}	26,9758	49,9457	25,4636	30,6104	43,0426	46,6089	24,5782	34,9153	28,7235	38,8512
P_{THG2}	54,6507	30,1602	63,1375	49,2122	30,3652	46,2379	82,5239	30,8265	67,5415	57,3783
P_{THG3}	236,9193	227,6800	149,2326	222,4564	195,1429	179,2892	361,3316	263,8426	316,7358	364,3883
P_{THG6}	49,5783	49,3309	49,7982	22,9807	48,4272	49,8695	34,6198	23,3795	42,3047	49,2948
P_{THG8}	49,8826	49,9930	48,7995	47,2963	49,8094	49,9925	30,8586	39,2736	32,1008	44,2012
P_{THG9}	333,2484	312,9041	340,4193	317,3585	333,5257	301,5697	233,5147	285,1528	211,3721	323,9477
P_{THG12}	514,4658	544,2258	511,1395	492,0636	481,2283	501,6299	446,1090	526,7780	519,4815	323,1576
Q_{THG1}	58,0473	37,9571	-9,1729	60,1995	43,2363	5,4075	36,7130	35,2204	0,4565	-4,0502
Q_{THG2}	25,8078	49,7940	33,0631	49,1866	45,7093	49,8226	12,8619	-12,9930	45,2149	19,8656
Q_{THG3}	31,5583	49,5377	50,6560	21,7291	25,3467	46,7983	58,8217	-6,1540	42,1675	35,6769
Q_{THG6}	0,1914	-0,5602	1,0844	11,5760	-2,1071	11,0537	3,1370	23,4644	23,5902	8,3586
Q_{THG8}	109,5847	89,2406	124,4702	39,3542	100,3277	63,9191	195,9794	199,7145	182,4718	193,5342
Q_{THG9}	8,9413	8,7863	1,2766	8,4496	6,9595	8,9787	8,6244	0,9809	6,7426	3,9631
Q_{THG12}	72,6754	51,5550	60,7012	68,5428	71,1931	83,7272	90,9796	153,6243	78,1393	135,6738
V_{THG1}	1,0540	1,0488	0,9943	1,0448	1,0443	1,0452	1,0084	0,9966	1,0400	1,0321
V_{THG2}	1,0474	1,0467	0,9950	1,0404	1,0395	1,0454	1,0051	0,9798	1,0427	1,0310
V_{THG3}	1,0576	1,0563	1,0204	1,0398	1,0447	1,0580	1,0330	1,0023	1,0629	1,0654
V_{THG6}	1,0376	1,0285	1,0283	1,0133	1,0290	1,0415	0,9964	1,0052	1,0427	1,0478
V_{THG8}	1,0504	1,0391	1,0534	1,0157	1,0421	1,0432	1,0146	1,0324	1,0521	1,0678
V_{THG9}	1,0487	1,0370	1,0340	1,0249	1,0388	1,0456	1,0020	1,0225	1,0392	1,0524
V_{THG12}	1,0642	1,0522	1,0272	1,0463	1,0539	1,0668	1,0263	1,0600	1,0628	1,0675
T_{19}	0,9588	1,0998	0,9858	1,0108	0,9797	0,9945	1,0110	0,9363	0,9599	1,0573
T_{20}	1,0496	0,9667	1,0996	1,0568	0,9576	0,9894	0,9282	0,9897	1,0393	1,0594
T_{31}	0,9204	1,0251	1,0176	1,0329	0,9979	0,9943	0,9552	0,9780	1,0827	0,9328
T_{35}	0,9178	0,9603	0,9017	0,9072	0,9087	0,9072	0,9532	0,9277	0,9194	0,9485
T_{36}	0,9729	0,9189	0,9019	1,0441	0,9061	0,9805	0,9271	0,9137	0,9866	1,0027

Çizelge 5.6. (devam) IEEE 57-baralı test sistemi simülasyon sonuçları.

T_{37}	1,0302	0,9887	0,9941	0,9770	1,0082	1,0146	1,0546	1,0042	0,9727	1,0592
T_{41}	1,0046	0,9623	0,9931	0,9430	1,0162	1,0104	0,9530	0,9613	0,9601	1,0040
T_{46}	0,9308	0,9726	0,9797	0,9553	0,9440	0,9904	0,9638	0,9669	0,9622	0,9566
T_{54}	1,0188	1,0024	0,9571	0,9433	0,9559	0,9010	0,9171	0,9870	0,9571	0,9725
T_{58}	0,9785	0,9775	0,9606	0,9627	1,0030	1,0014	0,9339	0,9515	0,9748	0,9737
T_{59}	0,9570	0,9744	0,9540	0,9647	0,9819	0,9879	0,9512	0,9753	0,9586	1,0449
T_{65}	0,9953	0,9878	0,9527	1,0034	1,0114	1,0234	1,0235	1,0115	1,0002	0,9601
T_{66}	0,9113	0,9383	0,9208	0,9296	0,9734	0,9773	0,9570	0,9566	1,0540	1,0573
T_{71}	0,9876	0,9585	1,0278	0,9515	0,9952	0,9806	0,9703	0,9863	0,9722	1,0047
T_{73}	0,9889	0,9919	0,9596	1,0745	0,9861	1,0632	1,0260	0,9642	0,9505	0,9561
T_{76}	0,9210	1,0583	1,0561	0,9041	1,0356	0,9347	1,0451	1,0265	1,0096	1,0239
T_{80}	0,9874	0,9775	0,9682	0,9652	0,9927	1,0161	0,9796	0,9784	0,9918	1,0585
P_r	0,3837	0,1483	-	-	0,3118	0,2120	1,0569	1,1692	0,9936	1,1071
P_i	0,3834	0,1483	-	-	0,3116	0,2119	1,0543	1,1660	0,9915	1,1046
Q_r	0,2321	0,0852	-	-	0,1878	0,0886	0,5635	0,4827	0,5348	0,4220
Q_i	0,1019	0,0788	-	-	0,1790	0,1092	0,4201	0,4028	0,3686	0,5156
t_r	1,0735	0,9299	-	-	1,0013	1,0056	0,9893	0,9287	0,9930	0,9458
t_i	0,9512	0,9146	-	-	0,9915	1,0411	0,9492	0,9146	0,9423	0,9874
α_r (°)	29,6508	29,0628	-	-	29,6169	21,4632	21,9211	12,3876	23,0849	11,8598
γ_i (°)	12,7799	27,4965	-	-	29,0076	26,7058	16,9526	12,5222	15,9307	21,4155
v_{dr}	1,3030	1,1314	-	-	1,2071	1,3073	1,1961	1,1969	1,2423	1,2745
v_{di}	1,3020	1,1310	-	-	1,2062	1,3067	1,1932	1,1936	1,2396	1,2716
i_d	0,2945	0,1311	-	-	0,2583	0,1662	0,8836	0,9769	0,7999	0,8686
$P_{DG1}(loc_{DG1})$	-	-	22,5279 (30)	29,9009 (36)	28,1393 (35)	27,6960 (53)	20,6183 (7)	26,5791 (37)	23,7345 (31)	29,3885 (36)
$P_{DG2}(loc_{DG2})$	-	-	29,7615(56)	24,1305 (53)	26,9183 (53)	27,6424 (24)	12,6449 (24)	15,1361 (14)	3,9487 (37)	25,8985 (31)
$P_{DG3}(loc_{DG3})$	-	-	20,8071 (28)	24,3466 (24)	23,2746 (24)	28,5358 (36)	27,6998 (32)	26,9202 (34)	25,6087 (35)	19,0698 (26)
$P_{loss}(MW)$	14,8919	13,4340	10,2867	9,5561	9,0513	8,2632	23,4380	21,6850	20,5383	24,5240
$VD(p.u.)$	1,3751	1,3580	0,9935	1,1779	0,8773	0,9421	0,7617	0,6006	1,1477	1,1684
$L - index$	0,2919	0,2994	0,1661	0,2031	0,1913	0,1999	0,1628	0,2068	0,1310	0,1266

5.4. İSTATİSTİKSEL ANALİZ VE LİTERATÜR KARŞILAŞTIRMASI

Bu alt bölümde, IEEE 30 ve IEEE 57-baralı test sistemlerinde farklı çalışma koşullarında gerçekleştirilen simülasyon çalışmalarında kullanılan optimizasyon algoritmalarının 20 bağımsız çalışma sonucu elde ettikleri minimum, ortalama, maksimum ve standart sapma değerleri verilmiştir. Ardından, AA/DA ORGA probleminin çözümünde kullanılan FDBAGSK ve AGSK algoritmalarının elde ettikleri en iyi amaç fonksiyonu değerleri literatürde iyi bilinen algoritmaların sonuçları ile karşılaştırılmıştır.

Önerilen FDBAGSK ve geleneksel AGSK yöntemlerinin istatistiksel analiz sonuçları Çizelge 5.7’de özetlenmiştir. IEEE 30-baralı test sistemi simülasyon sonuçları detaylı olarak incelendiğinde FDBAGSK yönteminin tüm çalışma durumlarında (Durum-1, ..., Durum- 7) minimum değere yakınsadığı görülmektedir. Ortalama değer indeksine göre yapılan kıyaslama, FDBAGSK yönteminin Durum-5 dışındaki IEEE 30-baralı tüm simülasyon çalışmalarında AGSK’ya kıyasla daha iyi değer elde ettiğini göstermiştir. IEEE 57-baralı test sistemi simülasyon çalışmalarında (Durum-8, ..., Durum-12) önerilen FDBAGSK algoritmasının hem minimum hem de ortalama değer indeksleri açısından AGSK’yı geride bıraktığı tespit edilmiştir. Sonuç olarak, FDBAGSK yönteminin farklı çalışma koşullarında AGSK’ya kıyasla daha iyi simülasyon sonuçları elde etmesi, keşif ve dengeli arama yeteneklerinin FDB seçim yöntemi kullanılarak geliştirildiğinin önemli bir kanıtıdır.

Çizelge 5.7. 20 bağımsız deneme için elde edilen istatistiksel analiz sonuçları.

IEEE 30-Baralı Test Sistemi							
Yöntem	Durum-1	Durum-2	Durum-3	Durum-4	Durum-5	Durum-6	Durum-7
FDBAGSK							
Minimum	11,4208	11,0921	9,2984	8,7366	8,2344	0,1539	0,0832
Ortalama	12,0379	11,6414	9,4229	10,1059	8,2766	0,2495	0,1433
Maksimum	14,3864	12,9122	9,5521	13,6128	8,3650	0,5407	0,3794
Standart sapma	0,7591	0,5999	0,0688	1,1609	0,0319	0,1206	0,0740
AGSK							
Minimum	11,5165	11,1171	9,3182	8,8093	8,2391	0,1548	0,0854
Ortalama	12,1538	12,5290	9,4248	10,2461	8,2739	0,2947	0,1436
Maksimum	14,2305	20,1886	9,5283	12,9387	8,3943	0,7886	0,3860
Standart sapma	0,6253	2,5484	0,0578	0,9910	0,0348	0,1776	0,0745

Çizelge 5.7. (devam) 20 bağımsız deneme için elde edilen istatistiksel analiz sonuçları.

IEEE 57-Baralı Test Sistemi					
Yöntem	Durum-8	Durum-9	Durum-10	Durum-11	Durum-12
FDBAGSK					
Minimum	13,4340	9,5561	8,2632	0,6006	0,1266
Ortalama	17,0629	11,3552	10,0639	1,052	0,2580
Maksimum	19,4729	13,8341	12,2768	1,5083	0,7655
Standart Sapma	1,4734	1,0795	0,9755	0,2848	0,1729
AGSK					
Minimum	14,8919	10,2867	9,0513	0,7617	0,1310
Ortalama	17,5297	12,3759	10,4778	1,3096	0,4181
Maksimum	20,5611	16,2046	11,8339	2,6985	1,3138
Standart Sapma	1,6504	1,7442	0,8927	0,4616	0,2968

Çizelge 5.8, çoklu dağıtılmış üretim ve iki terminalli YGDA iletim hattı bağlantılarını içeren güç sistemlerinde AA/DA ORGA probleminin çözümü için tez çalışmasında kullanılan algoritmaların yanı sıra literatürde son zamanlarda rapor edilen LP [151], GA [152], ABC [153], SGA [154], BGA [154] ve BSA [53] optimizasyon algoritmalarının simülasyon sonuçlarını özetler. Çizelge 5.8’de, her bir test durumu için elde edilen en iyi sonuç koyu renk ile vurgulanmıştır. Karşılaştırmalı analiz, önerilen FDBAGSK yönteminin Durum-5 dışındaki simülasyon çalışmalarında optimal amaç fonksiyonu değerine yakınsamada rakiplerine kıyasla daha iyi performans sergilediğini göstermiştir. Durum-6, Durum-7, Durum-11 ve Durum-12 için literatür karşılaştırmasının verilmemesi ilgili simülasyon çalışmalarının tez çalışmasına özgün olmasından kaynaklanmaktadır.

Çizelge 5.8. Literatür karşılaştırması.

IEEE 30-Baralı Test Sistemi							
Algoritmalar	Durum-1	Algoritmalar	Durum-2	Algoritmalar	Durum-3	Algoritmalar	Durum-4
LP [151]	28,41 MW	LP [151]	12,01 MW	SGA [154]	14,1317 MW	ABC [153]	8,9172 MW
GA [152]	12,40 MW	GA [152]	12,01 MW	BGA [154]	13,9888 MW	BSA [53]	8,8525 MW
ABC [153]	11,6783 MW	ABC [153]	11,4767 MW	ABC [153]	9,4248 MW	AGSK	8,8093 MW
BSA [53]	11,5339 MW	BSA [53]	11,2483 MW	BSA [53]	9,3039 MW	FDBAGSK	8,7366 MW
AGSK	11,5165 MW	AGSK	11,1171 MW	AGSK	9,3182 MW		
FDBAGSK	11,4208 MW	FDBAGSK	11,0921 MW	FDBAGSK	9,2984 MW		
Algoritmalar	Durum-5	Algoritmalar	Durum-6	Algoritmalar	Durum-7		
ABC [153]	8,8032 MW	AGSK	0,1548 p.u.	AGSK	0,0854 p.u.		
AGSK	8,2391 MW	FDBAGSK	0,1539 p.u.	FDBAGSK	0,0832 p.u.		
FDBAGSK	8,2344 MW						
BSA [53]	8,2080 MW						
IEEE 57-Baralı Test Sistemi							
Algoritmalar	Durum-8	Algoritmalar	Durum-9	Algoritmalar	Durum-10	Algoritmalar	Durum-11
GA [152]	14,2370 MW	GA [152]	13,8188 MW	AGSK	9,0513 MW	AGSK	0,7614 p.u.
BSA [53]	14,0607 MW	BSA [53]	11,8235 MW	GA [152]	9,0152 MW	FDBAGSK	0,6006 p.u.
AGSK	14,8919 MW	AGSK	10,2867 MW	BSA [53]	8,4060 MW		
FDBAGSK	13,4340 MW	FDBAGSK	9,5561 MW	FDBAGSK	8,2632 MW		
Algoritmalar	Durum-12						
AGSK	0,1310 p.u.						
FDBAGSK	0,1266 p.u.						

5.5. SONUÇLAR: AA/DA OPTİMAL REAKTİF GÜÇ AKIŞI

- Bu bölümde, çoklu dağıtılmış üretim üniteleri ve iki terminalli yüksek gerilim doğru akım iletim bağlantılarını içeren güç sistemlerinde AA/DA ORGA probleminin çözümü üzerine kapsamlı bir çalışma gerçekleştirilmiştir.
- Geleneksel IEEE 30 ve IEEE 57-baralı güç sistemleri çoklu dağıtılmış üretim üniteleri ve iki terminalli yüksek gerilim doğru akım iletim hatları ile eş zamanlı olarak simüle edilmiş ve böylece incelenen güç sistemleri gerçek dünyaya en yakın şekilde modellenmiştir.
- Önerilen FDBAGSK ve baz AGSK algoritmalarının performansı farklı çalışma koşulları altında IEEE 30 ve IEEE 57-baralı test sistemlerinde gerçekleştirilen on iki simülasyon durumu için incelenmiştir.
- AA/DA ORGA probleminin çözümünde aktif güç kayıpları, gerilim sapması ve gerilim kararlılığı iyileştirilmesi amaç fonksiyonları dikkate alınmıştır.
- Aktif güç kayıplarının yüksek gerilim doğru akım iletim hattı bağlantı noktalarına göre değişimlerin oldukça küçük seviyelerde olduğu gözlemlenirken, dağıtılmış üretim ünitelerinin güç sistemine optimal yerleşimi ile güç kayıplarının önemli ölçüde azaltıldığı tespit edilmiştir.
- Önerilen FDBAGSK algoritması ile elde edilen simülasyon sonuçları, literatürde iyi bilinen optimizasyon algoritmalarının sonuçları ile karşılaştırılmıştır. Sonuçlar, önerilen FDBAGSK yönteminin AA/DA ORGA probleminin farklı konfigürasyonlarını verimli bir şekilde çözebildiğini göstermiştir.

6. OPTİMAL OTOMATİK GERİLİM REGÜLATÖRÜ TASARIMI


Otomatik Gerilim Regülatörü (OGR), güç sistemlerinin kontrollü ve güvenilir bir şekilde işletiminde kullanılan en önemli bileşenlerden biridir. Adından da anlaşılacağı gibi, senkron bir jeneratörün uyarım gerilimini ayarlayarak sabit bir gerilim seviyesini otomatik olarak kontrol etmek, ayarlamak veya korumak için tasarlanmıştır [59]. Elektrik güç sistemindeki ana kontrol sorunlarından biri olarak kabul edilen nominal olmayan çalışma koşulları altında kararlılığın artırılması ve nominal bir gerilim seviyesinin sürdürülmesi için OGR'nin kullanılması esastır. Çünkü; nominal gerilim seviyesi güç sistemine bağlı herhangi bir elektrikli cihaz için hayati önem taşır. Voltaj değişimlerinin kontrol edilmemesi ise bağlı cihazların arızalanmasına, çalışma ömürlerinin kısılmasına ve güç sisteminin arızalanmasına neden olabilir. Ayrıca, ani bir yük veya OGR'nin parametre değişimlerinden kaynaklanan voltaj büyüklüğündeki salınımların ve aşmaların herhangi bir güç sisteminde kaçınılmaz olduğunu belirtmekte fayda vardır. Bu durumun nedeni, bu tür koşullar altında sağlanan güç ile bağlı yük güç talebi arasında güç sisteminin denge konumunu bozan ve oldukça belirgin bir süre boyunca gerilim aşımalarına/azalmalarına neden olan bir uyumsuzluk olmasıdır. Bu salınımlar uygun bir kontrol mekanizması ile kontrol edilmezse, güç sisteminin arızalanmasına neden olabilir. Bu nedenle, herhangi bir güç sisteminin güvenli bir şekilde çalışması için sistem geriliminin uygun bir dinamik yanıtla nominal değerinde regüle edilmesi gerekmektedir. Belirtilen amaca ulaşmak için, OGR sisteminde kullanılan kontrolcülerin kazanç parametrelerini optimize etmek oldukça önemlidir [63]-[66]. OGR tasarımında yaygın olarak kullanılan denetleyiciler arasında orantılı-integral-türev (Proportional-Integral-Derivative, PID), filtreli orantılı-integral-türev (Proportional-Integral-Derivative with Filter, PIDF), kesir dereceli orantılı-integral-türev (Fractional Order Proportional-Integral-Derivative, FOPID) ve ikinci dereceden türevli orantılı-integral-türev (Proportional-Integral-Derivative plus Second-Order Derivative, PIDD²) yer almaktadır. Bu denetleyicilerin performansı yüksek oranda kazanç parametrelerinin uygun ayarlarının belirlenmesine bağlıdır. Bu çalışmada tez çalışmasının orijinal katkılarından biri olarak geliştirilen FDBLFD algoritmasını kullanarak OGR performansını iyileştirmek amacıyla PID, PIDF, FOPID ve PIDD² kontrolcü parametrelerinin

optimizasyonu gerçekleştirilmiştir.

Bu bölümün geri kalanı şu şekilde düzenlenmiştir: Bölüm 6.1’de otomatik voltaj regülatörünün matematiksel modeli sunulmuştur. OGR çalışma yapısı, bileşenleri ve transfer fonksiyonları detaylı olarak bu bölümde incelenmiştir. Bölüm 6.2, otomatik gerilim regülatörü tasarımında kullanılan kontrolcü yapıları hakkındadır. Bu kapsamda PID, PIDF, FOPID ve PIDD² kontrolcü yapıları, blok diyagramları ve transfer fonksiyonları detaylı olarak incelenmiştir. Bölüm 6.3’te, kontrolcü parametreleri optimizasyonunda kullanılan amaç fonksiyonları tanıtılmıştır. Bölüm 6.4, OGR tasarım probleminin simülasyon çalışmaları ve sonuçlarını detaylı olarak analiz eder. Bu amaçla beş alt bölüm hazırlanmıştır. İlk dört alt-bölümde sırasıyla PID, PIDF, FOPID ve PIDD² kontrolcülerini ile tasarlanan OGR’nin performansı analiz edilmiştir. Beşinci alt bölümde ise önerilen FDBLFD algoritması ile optimize edilen farklı tip kontrolcü performanslarının karşılaştırmalı analizi sunulmuştur. Bölüm 6.5, yükselme zamanı, yerleşme zamanı ve maksimum aşım performans göstergeleri açısından önerilen FDBLFD algoritması ile optimize edilen kontrolörlerin ve literatürde yakın zamanda rapor edilen diğer algoritmaların sonuçlarının karşılaştırmalı analizini sunar. Bölüm 6.6, optimal OGR tasarımı optimizasyon probleminin sonuçlarını özetler.

6.1. OGR SİSTEMİNİN MATEMATİKSEL MODELİ

Güç sistemlerinde senkron bir jeneratörün uyartım geriliminin gerilim düşüşüne veya artışına uygun şekilde düzenlenmesi güç sistemi kararlılığı ve üretilen elektrik gücünün kalitesi üzerinde önemli bir etkiye sahiptir. Bu nedenle bir elektrik santralindeki asıl görevi jeneratör gerilimi büyüklüğünü otomatik olarak belirli bir limit dahilinde tutmak olan OGR sistemi kullanılmaktadır [155]. Yükseltici, uyarıcı, jeneratör ve sensör olmak üzere dört bileşenden oluşan pratik bir OGR sisteminin şematik diyagramı Şekil 6.1’de gösterilmiştir [56]. İlgili şekil detaylı olarak incelendiğinde voltaj sensörü yardımıyla OGR’nin şebekeye bağlı olduğu noktadan terminal geriliminin sürekli bir şekilde ölçüldüğü görülmektedir. Ölçülen gerilim sinyali, doğrultma ve filtreleme işlemine tabi tutulduktan sonra karşılaştırmacıya gönderilir ve voltaj ayar değerinden çıkartılarak hata sinyali elde edilir. Gerilim hatası yükseltildikten sonra, görevi hata sinyaline göre gerilim değişimini kompanze etmek için uyarıcı vasıtasıyla jeneratörün alan sargı gerilimini veya akımını kontrol etmek olan uyartım sistemine iletilir.



Şekil 6.1. OGR sisteminin basitleştirilmiş modeli.

OGR sistemi performansını analiz etmek için sistem bileşenlerinin matematiksel modeline ihtiyaç vardır. Şekil 6.1'deki her bir bileşen, saniye cinsinden bir zaman sabiti (T) ve birimsiz kazanç sabitinden (K) oluşan birinci mertebeden transfer fonksiyonu ile temsil edilir. OGR sistem bileşenleri matematiksel olarak aşağıdaki gibi modellenir [63], [64]:

- Yükseltici

Yükseltici transfer fonksiyonu $G_A(s)$, yükseltici kazancı (K_A) ve zaman sabiti (T_A) ile temsil edilir.

$$G_A(s) = \frac{K_A}{1 + s T_A} \quad (6.1)$$

- Uyarıcı

Uyarıcı bileşeni matematiksel olarak, uyarıcı kazancı (K_E) ve zaman sabiti (T_E) ile modellenen birinci dereceden transfer fonksiyonu ile gösterilir.

$$G_E(s) = \frac{K_E}{1 + s T_E} \quad (6.2)$$

- Jeneratör

Jeneratör bileşeni, üreteç kazancı (K_G) ve zaman sabitinden (T_G) oluşan birinci dereceden bir transfer fonksiyonu ile modellenir.

$$G_G(s) = \frac{K_G}{1 + s T_G} \quad (6.3)$$

- Sensör

Sensör bileşeni, sensör kazancı (K_S) ve zaman sabitinden (T_S) oluşan birinci dereceden transfer fonksiyonu ile gösterilir.

$$G_S(s) = \frac{K_S}{1 + s T_S} \quad (6.4)$$


OGR bileşenlerinin matematiksel modelleri (Eşitlik 6.1-6.4) kullanılarak elde edilen kapalı çevrim transfer fonksiyonu Eşitlik (6.5)'te verilmiştir [62], [156].

$$G_{OGR}(s) = \frac{\Delta V_t(s)}{\Delta V_{ref}(s)} = \frac{K_A K_E K_G T_S s + K_A K_E K_G}{(1 + T_A s) + (1 + T_E s) + (1 + T_G s)(1 + T_S s) + K_A K_E K_G T_S} \quad (6.5)$$

OGR sistem bileşenleri zaman sabiti (T) ve kazanç (K) parametrelerinin tipik değerleri ve bu çalışmada seçilen değerler Çizelge 6.1'de özetlenmiştir [62]-[66]. Eşitlik (6.5)'te verilen kapalı çevrim transfer fonksiyonu ile tasarlanan OGR sisteminin birim basamak tepkisi Şekil 6.2'de gösterilmiştir.


Çizelge 6.1. OGR sisteminde kullanılan parametrelerin limitleri ve seçilen değerler.

OGR Bileşeni	Parametre limitleri	Seçilen parametre değerleri
Yükseltici	$10 \leq K_A \leq 40$, $0,02 \leq T_A \leq 0,1$	$K_A = 10$, $T_A = 0,1$
Uyarıcı	$1 \leq K_E \leq 10$, $0,4 \leq T_E \leq 1$	$K_E = 1$, $T_E = 0,4$
Jeneratör	$0,7 \leq K_G \leq 1$, $1 \leq T_G \leq 2$	$K_G = 1$, $T_G = 1$
Sensör	$1 \leq K_S \leq 2$, $0,001 \leq T_S \leq 0,06$	$K_S = 1$, $T_S = 0,01$



Şekil 6.2. Kontrolcü kullanılmadığında OGR sisteminin birim basamak tepkisi.

Şekil 6.2 detaylı olarak incelendiğinde, OGR sisteminin salınımları sönmülemeye ve arzu edilen gerilim seviyesini elde etmede yetersiz olduğu görülmektedir. Bu problemin üstesinden gelmek ve otomatik gerilim regülatörünün kararlı durum ve geçici tepki yanıtını iyileştirmek için OGR sistemine bir kontrolcü entegre edilmelidir. Şekil 6.3 kontrolcü ile modellenen OGR sisteminin kapalı çevrim transfer fonksiyonu blok diyagramını göstermektedir.



Şekil 6.3. Kontrolör ile modellenen OGR sisteminin transfer fonksiyon modeli.


Sonraki alt bölüm, tez çalışmasında optimal OGR tasarımı için kullanılan denetleyiciler hakkındadır. Bu kapsamda PID, PIDE, FOPID ve PIDD² kontrolcülerinin matematiksel modeli ve blok diyagramları tanıtılmıştır.

6.2. OGR TASARIMINDA KULLANILAN KONTROLÇÜLER

OGR sisteminin kalıcı durum ve geçici tepki özelliklerini iyileştirmek için PID, PIDF, FOPID ve PIDD² kontrolcöleri kullanılmıştır [66], [157].

- PID kontrolcünün (Şekil 6.4) transfer fonksiyonu Eşitlik (6.6)'da verilmiştir. PID kontrolcü optimize edilecek üç parametre içerir. Bunlar: K_p , K_i , K_d .


$$G_{PID}(s) = \frac{U(s)}{E(s)} = K_p + \frac{K_i}{s} + K_d s \quad (6.6)$$



Şekil 6.4. PID kontrolcü blok diyagramı.

- PIDF kontrolcü (Şekil 6.5), PID parametrelerine ek olarak filtre katsayısına (NN) sahiptir. PID denetleyicinin türev kısmında alçak geçiren filtre kullanılarak elde edilen transfer fonksiyonu aşağıdaki gibidir:


$$G_{PIDF}(s) = \frac{U(s)}{E(s)} = K_p + \frac{K_i}{s} + K_d s \frac{NN}{s + NN} \quad (6.7)$$



Şekil 6.5. PIDF kontrolcü blok diyagramı.

- FOPID denetleyici (Şekil 6.6) türev ve integralin kesirli derecelerini içerir. Bu çalışmada, kesir dereceli transfer fonksiyonlarının hesaplanmasında $w \in [10^{-5}, 10^5] \text{ rad/s}$ frekans aralığında 5. derece Oustaloup yaklaşımı kullanılmıştır. FOPID denetleyici $PI^\lambda D^\mu$ biçiminde ifade edilir, burada λ ve μ kesir derecelerini temsil eder. FOPID kontrolcünün optimize edilecek beş parametresi vardır. Bunlar: $K_p, K_i, K_d, \lambda, \mu$.


$$G_{FOPID}(s) = \frac{U(s)}{E(s)} = K_p + \frac{K_i}{s^\lambda} + K_d s^\mu \quad (6.8)$$



Şekil 6.6. FOPID kontrolcü blok diyagramı.

- PIDD² denetleyici (Şekil 6.7), orantısal-integral-türev ve ikinci dereceden türev terimlerinden oluşan dört terimli bir kontrolcüdür.

$$G_{PIDD^2}(s) = \frac{U(s)}{E(s)} = K_p + \frac{K_i}{s} + K_d s + K_{d2} s^2 \quad (6.9)$$



Şekil 6.7. PIDD² kontrolcü blok diyagramı.

6.3. AMAÇ FONKSİYONLARI

Optimal OGR tasarımı optimizasyon problemi seçilen amaç fonksiyonunun çeşitli sistem kısıtlarına tabi olarak minimizasyonu olarak tanımlanır. Bu çalışmada iki farklı amaç fonksiyonu (OF) kullanılmıştır. Geçici tepki (OS , t_s , t_r) ve kararlı durum (E_{ss}) özelliklerini içeren OF1, PID ve PIDF denetleyici kazanç parametreleri optimizasyonunda kullanılmıştır. OF1, Referans [57]'de sunulan Gaing fonksiyonunun modifiye versiyonudur:


$$OF1 = (1 - e^{-\beta})x \left(\frac{OS}{\alpha} + E_{ss} \right) + e^{-\beta} (t_s - t_r) \quad (6.10)$$

Eşitlik (6.10)'da OS maksimum aşım değeri (%), E_{ss} kalıcı durum hatası olarak tanımlanır. t_s ve t_r sırasıyla yerleşme zamanı ve yükselme zamanını gösterir. α ve β parametrelerinin nümerik değerleri sırasıyla 90 ve 1 olarak ayarlanmıştır.

FOPID ve PIDD² kontrolcü parametrelerinin optimal tasarımında Eşitlik (6.11)'de verilen OF2 amaç fonksiyonu kullanılmıştır [157]. Eşitlik (6.11)'de, w ağırlık katsayılarının nümerik değeri şu şekilde ayarlanmıştır: $w_1 = 1$, $w_2 = 0.02$, $w_3 = 1$, $w_4 = 5$.

$$OF2 = w_1 \int t|e(t)|dt + w_2 OS + w_3 |E_{ss}| + w_4 t_s \quad (6.11)$$

OGR sisteminin kontrol performansı büyük oranda kullanılan kontrolcü (PID, PIDF, FOPID ve PIDD²) parametrelerinin uygun bir şekilde ayarlanmasına bağlıdır. Şekil 6.8 önerilen FDBLFD algoritmasının optimal OGR tasarımı optimizasyon problemine uygulanma adımlarını göstermektedir.



Şekil 6.8. Optimal OGR tasarımı optimizasyon probleminin şematik diyagramı.

6.4. OPTİMAL OGR TASARIMI PROBLEMİNİN SİMÜLASYON ÇALIŞMALARI, SONUÇLARI VE KARŞILAŞTIRMALARI

Bu tez çalışmasında önerilen uygunluk-mesafe dengesi tabanlı Levy uçuş dağılımı (Fitness-Distance Balance Levy Flight Distribution, FDBLFD) algoritmasının yanı sıra diferansiyel evrim (Differential Evolution, DE [105]), barnacles çiftleşme optimize edici (Barnacles Mating Optimizer, BMO [106]), Harris şahinleri optimizasyon (Harris Hawks Optimization, HHO [107]) ve güve alevi optimizasyon (Moth-Flame Optimization, MFO [108]) algoritmaları, OGR sistemi optimal tasarım problemine uygulanmıştır. OGR sisteminin optimal tasarımında dört farklı kontrolcü kullanılmıştır: PID, PIDF, FOPID ve PIDD². Dört farklı kontrolcü ile modellenen OGR sisteminin performansı zaman domeni (time-domain) ve sağlamlık (robustness) analizleri ile test edilmiştir. Zaman domeni analizinde, OGR sisteminin birim basamak referansı için geçici tepki (transient-response) özellikleri (yükselme zamanı, yerleşme zamanı ve maksimum aşım) incelenirken, sağlamlık analizinde parametre belirsizliği durumunda sistem performansı araştırılmıştır. Parametre belirsizliği, OGR bileşenleri zaman sabitlerinin (T_A , T_E , T_G ve T_S) %25'lik

artışı ile -%50 ve +%50 arasında değişimi şeklinde simüle edilmiştir. OGR optimal tasarım probleminin çözümünde kullanılan algoritmalar için maksimum iterasyon sayısı 50, maksimum popülasyon büyüklüğü 30 olarak kabul edilmiştir. Optimize edilen kontrolcü kazanç parametrelerinin sınır değerleri Çizelge 6.2’de verilmiştir.

Çizelge 6.2. Kontrolcü parametrelerinin limit değerleri.

Kontrolcü	Kontrolcü Parametreleri						
	K_p	K_i	K_d	K_{d2}	λ	μ	NN
PID	[0,2-2]	[0,2- 2]	[0,2-2]	-	-	-	-
PIDF	[0,2- 2]	[0,2- 2]	[0,2-2]	-	-	-	[200, 1000]
FOPID	[1-2]	[0,1- 1]	[0,1-0,4]	-	[1, 2]	[1, 2]	-
PIDD ²	[0,0001-3]	[0,0001-3]	[0,0001-3]	[0,0001-3]	-	-	-

6.4.1. PID Kontrolcü ile OGR Tasarımı


OGR sistemi tasarımında kullanılan PID denetleyici, üç kontrol değişkeninin optimal ayarını gerektirir: orantısal kazanç sabiti K_p , integral kazanç sabiti K_i ve türev kazanç sabiti K_d . PID kazanç parametrelerinin optimizasyonunda Eşitlik (6.10)’da verilen amaç fonksiyonu kullanılmıştır. Daha iyi bir birim basamak tepkisi elde etmek için önerilen FDBLFD, DE, BMO, HHO ve MFO algoritmaları ile optimize edilmiş PID denetleyici tabanlı OGR sistemi tasarlanmıştır. Optimizasyon sonunda elde edilen kazanç parametreleri ve geçici yanıt özellikleri Çizelge 6.3’te sunulmuştur.

Çizelge 6.3. Önerilen FDBLFD ve rekabetçi algoritmalar ile optimize edilen PID kontrolcü parametreleri ve OGR sistemi geçici tepki özellikleri.

Algoritma	K_p	K_i	K_d	$t_r(0.1 \rightarrow 0.9)$	$t_s (\pm\%5)$	OS (%)
FDBLFD	0,6690	0,5753	0,2566	0,263	0,362	1,51
DE	0,6579	0,4466	0,2081	0,298	0,408	2,48
BMO	0,6614	0,5544	0,2498	0,269	0,370	1,31
HHO	0,6485	0,5028	0,2349	0,282	0,389	0,967
MFO	0,6587	0,5517	0,2487	0,270	0,372	1,31

Çizelge 6.3’te verilen simülasyon sonuçları detaylı olarak incelendiğinde algoritmaların PID denetleyici tabanlı OGR tasarımında rekabetçi performans sergiledikleri gözlemlenmiştir. FDBLFD algoritmasının yükselme zamanı t_r açısından rakip algoritmalara kıyasla daha iyi bir değer elde ettiği görülmektedir. Önerilen algoritma ile

elde edilen yerleşme zamanı t_s (0,362 s), DE, BMO, HHO ve MFO algoritmalarının simülasyon sonuçlarından sırasıyla %12,7071, %2,1621, %6,9408 ve %2,6881 daha düşüktür. Ayrıca, HHO algoritmasının en iyi aşma OS (%) değerini sunması dikkat çekicidir. Beş rakip algoritma arasında, PID denetleyici tasarımındaki en zayıf performans DE algoritmasına aittir. Bu çıkarım, geçici tepki parametrelerinin (t_r , t_s , OS) nümerik değerine dayanmaktadır. PID kontrolcü tabanlı OGR'nin birim basamak tepkisi Şekil 6.9'da gösterilmiştir.




Şekil 6.9. PID denetleyici tabanlı OGR sisteminin birim basamak tepkisi.

FDBLFD ile tasarlanan PID kontrolcü nominal koşullar altında başarılı bir performans sergilemiştir. Ancak, nominal olmayan koşullar altında FDBLFD algoritması ile optimize edilen PID denetleyicinin performansı merak konusudur. Bunun için OGR sistem bileşenleri zaman sabitleri nominal değer $\pm$ %50 aralığında %25 adım boyutunda değiştirilerek FDBLFD tabanlı PID denetleyicinin sağlamlık analizi gerçekleştirilmiştir. Sağlamlık analizi simülasyon sonuçları Çizelge 6.4'te verilmiştir.


Çizelge 6.4. FDBLFD tabanlı PID kontrolcü ile tasarlanan OGR sisteminin sağlamlık analizi sonuçları.

Parametre	Değişim oranı (%)	$t_r(0.1 \rightarrow 0.9)$	$t_s (\pm\%5)$	OS (%)
T_A	-50	0,179	0,248	0,25
	-25	0,222	0,306	1,13
	+25	0,297	0,410	1,78
	+50	0,337	0,465	1,76
T_E	-50	0,187	0,392	5,23
	-25	0,251	0,346	1,41
	+25	0,274	0,378	1,42
	+50	0,283	0,390	1,37
T_G	-50	0,169	0,495	12,7
	-25	0,251	0,346	1,85
	+25	0,262	0,361	1,65
	+50	0,262	0,361	1,75
T_S	-50	0,253	0,348	1,59
	-25	0,261	0,359	1,48
	+25	0,271	0,373	1,35
	+50	0,268	0,370	1,56

Çizelge 6.4’te rapor edilen simülasyon sonuçlarının anlaşılmasını ve yorumlanmasını kolaylaştırmak için birim basamak tepkisi eğrileri çizdirilmiştir. Şekil 6.10, parametre belirsizliği durumunda OGR sisteminin birim basamak tepkisi eğrilerini göstermektedir. FDBLFD tabanlı PID kontrolcü ile tasarlanmış OGR sistemi, nominal olmayan çalışma koşullarında makul minimum aşım ve hızlı yerleşme süresi ile sağlam bir kontrol performansı sergilemiştir.





(a)



(b)

Şekil 6.10. Zaman sabitlerinin nominal değer in $\pm 50\%$ aralığındaki değişimi için FDBLFD-PID ile tasarlanan OGR sistemi birim basamak tepkisi (a) T_A , (b) T_E , (c) T_G , (d) T_S .



Şekil 6.10. (devam) Zaman sabitlerinin nominal değerin -%50 ve +%50 aralığındaki değişimi için FDBLFD-PID ile tasarlanan OGR sistemi birim basamak tepkisi (a) T_A , (b) T_E , (c) T_G , (d) T_S .

6.4.2. PIDF Kontrolcü ile OGR Tasarımı

PIDF kontrolcü optimizasyonunda K_p , K_i , K_d kazanç katsayılarına ek olarak NN filtre parametresi optimal ayarının belirlenmesi gerekir. Kontrolcü parametrelerinin optimizasyonunda Eşitlik (6.10)'da verilen amaç fonksiyonu (OF_1) kullanılmıştır. FDBLFD, DE, BMO, HHO ve MFO algoritmaları ile optimize edilen PIDF kontrolcü parametrelerinin yanı sıra yükselme süresi (t_r), yerleşme süresi ($t_s \pm 5\%$) ve maksimum aşım ($OS\%$) gibi zaman alanı performans göstergeleri Çizelge 6.5'te sunulmuştur.


Çizelge 6.5. Önerilen FDBLFD ve rekabetçi algoritmalar ile optimize edilen PIDF kontrolcü parametreleri ve OGR sistemi geçici tepki özellikleri.

Algoritma	K_p	K_i	K_d	NN	$t_r(0.1 \rightarrow 0.9)$	$t_s (\pm 5\%)$	$OS\%$
FDBLFD	0,6558	0,5627	0,2502	548,7605	0,266	0,368	1,48
DE	0,5863	0,5051	0,2000	998,7587	0,321	0,443	1,78
BMO	0,6374	0,5122	0,2344	597,1834	0,281	0,390	1,03
HHO	0,6246	0,4344	0,2089	397,1185	0,302	0,419	1,08
MFO	0,6429	0,5116	0,2358	981,1123	0,281	0,388	0,95

Çizelge 6.5'te verilen simülasyon sonuçlarından en iyi yükselme zamanının FDBLFD ile tasarlanan PIDF kontrolcü ile elde edildiği görülmektedir. t_s değeri açısından yapılan karşılaştırmada FDBLFD daha optimal yerleşme zamanı elde etmede rakiplerine kıyasla üstündür ve onu MFO, BMO, HHO ve DE algoritmaları izlemiştir. Çizelgeden, MFO-PIDF denetleyici ile kontrol edilen OGR'nin rekabetçi algoritmalarla kıyasla daha iyi maksimum aşım ($OS\%$) değeri sunduğu anlaşılmaktadır. Meta-sezgisel arama algoritmaları ile optimize edilen kontrolcü parametreleri (Çizelge 6.5) kullanılarak PIDF ile tasarlanan OGR sisteminin birim basamak tepkisi Şekil 6.11'de gösterilmiştir. FDBLFD ayarlı PIDF kontrolcünün, referans gerilimini diğerlerinden daha sıkı takip eden kaliteli bir birim basamak yanıtı elde ettiği gözlemlenmiştir.

FDBLFD-PIDF tabanlı OGR sisteminin nominal olmayan çalışma koşullarında sağlamlığını araştırmak için yükseltici, uyarıcı, jeneratör ve sensör bileşenlerinin zaman sabitleri (T_A , T_E , T_G ve T_S) nominal değerlerin $\pm 50\%$ aralığında değiştirilmiştir. Sağlamlık analizi sonucu elde edilen geçici tepki özelliklerinin nümerik değeri Çizelge 6.6'da verilmiştir. İlgili çizelgede verilen nümerik değerlerin anlaşılmasını kolaylaştırmak için FDBLFD-PIDF kontrolcü ile tasarlanan OGR sisteminin nominal olmayan çalışma koşullarındaki birim basamak tepkisi grafikleri çizdirilmiştir. Şekil 6.12'de verilen


grafikler, OGR parametrelerinde ani bir deęişiklik olması durumunda sistem kararlılıęını saęlama ve yüksek kaliteli birim basamak tepkisi elde etmede FDBLFD tabanlı PIDF kontrolcünün başarılı bir performans sergiledięini göstermiştir.




Şekil 6.11. PIDF denetleyici tabanlı OGR sisteminin birim basamak tepkisi.

Çizelge 6.6. FDBLFD tabanlı PIDF kontrolcü ile tasarlanan OGR sisteminin saęamlık analizi sonuçları.

Parametre	Deęişim oranı (%)	$t_r(0.1 \rightarrow 0.9)$	$t_s (\pm\%5)$	OS (%)
T_A	-50	0,181	0,251	0,23
	-25	0,222	0,307	1,16
	+25	0,298	0,413	1,85
	+50	0,341	0,473	1,73
T_E	-50	0,185	0,415	5,93
	-25	0,249	0,345	1,51
	+25	0,274	0,379	1,49
	+50	0,280	0,387	1,54
T_G	-50	0,182	0,385	5,50
	-25	0,254	0,351	1,65
	+25	0,286	0,396	0,91
	+50	0,272	0,375	1,46
T_s	-50	0,253	0,349	1,65
	-25	0,279	0,387	0,89
	+25	0,273	0,377	1,31
	+50	0,270	0,373	1,68




(a)




(b)

Şekil 6.12. Zaman sabitlerinin nominal değer -%50 ve +%50 aralığındaki değişimi için FDBLFD-PIDF ile tasarlanan OGR sistemi birim basamak tepkisi (a) T_A , (b) T_E , (c) T_G , (d) T_S



(c)



(d)

Şekil 6.12. (devam) Zaman sabitlerinin nominal değer -%50 ve +%50 aralığındaki değişimi için FDBLFD-PIDF ile tasarlanan OGR sistemi birim basamak tepkisi (a) T_A ,

(b) T_E , (c) T_G , (d) T_S


6.4.3. FOPID Kontrolcü ile OGR Tasarımı

FOPID denetleyicinin kontrol performansı büyük ölçüde $K_p, K_i, K_d, \lambda, \mu$ kazanç parametrelerinin uygun değerlerinin belirlenmesine bağlıdır. FOPID kontrolcü parametrelerinin optimize edilmesinde Eşitlik (6.11)'de verilen amaç fonksiyonu (OF2) kullanılmıştır. Önerilen FDBLFD ve rekabetçi optimizasyon algoritmaları, FOPID denetleyici tabanlı OGR sistem tasarımı optimizasyon problemine uygulanmıştır. Optimizasyon sonucunda elde edilen FOPID denetleyici parametreleri ve karşılık gelen geçici tepki karakteristikleri Çizelge 6.7'de sunulmuştur.

Çizelge 6.7. Önerilen FDBLFD ve rekabetçi algoritmalar ile optimize edilen FOPID kontrolcü parametreleri ve OGR sistemi geçici tepki özellikleri.

Algoritma	K_p	K_i	K_d	λ	μ	$t_r(0.1 \rightarrow 0.9)$	$t_s(\pm\%5)$	OS (%)
FDBLFD	1,9922	0,7527	0,3227	1,3927	1,2957	0,140	0,187	2,53
DE	1,7428	0,6737	0,3016	1,3699	1,2664	0,156	0,209	2,15
BMO	1,8108	0,7276	0,3024	1,3495	1,2743	0,153	0,204	2,54
HHO	1,8336	0,7169	0,3044	1,4251	1,2730	0,152	0,203	2,81
MFO	1,7139	0,6850	0,3085	1,3124	1,2588	0,155	0,207	2,26

Çizelge 6.7'deki karşılaştırmalı analizden DE, BMO, HHO ve MFO kullanılarak elde edilen yükselme ve yerleşme zamanı sonuçlarının benzer olduğu görülmektedir. FDBLFD algoritması ile elde edilen t_r ve t_s değerleri rakiplerine kıyasla daha iyidir. Önerilen FDBLFD yöntemine en yakın performans HHO algoritmasına ait iken, yerleşme ve yükselme süresi performans göstergeleri açısından en kötü performans DE ve MFO algoritmalarına aittir. Farklı algoritmalar ile optimize edilen FOPID denetleyici ile tasarlanmış OGR sisteminin birim basamak tepkisi Şekil 6.13'te gösterilmiştir. Birim basamak tepkisi eğrilerinden, FDBLFD tabanlı FOPID denetleyicinin referans terminal gerilimini rakiplerine kıyasla daha başarılı bir şekilde takip ettiği gözlemlenmiştir.



Şekil 6.13. FOPID denetleyici tabanlı OGR sisteminin birim basamak tepkisi.

Sağlamlık analizi herhangi bir denetleyiciyi doğrulamak için önemli bir kriterdir. OGR sisteminin nominal çalışma koşullarında başarılı bir performans sergilediğinin gösterilmesinin ardından çalışmanın kapsamı parametre belirsizliği durumunda FDBLFD tabanlı FOPID kontrolcünün sağlamlık analizine odaklanılarak genişletilmiştir. Sağlamlık analizi, OGR sistemi bileşenleri zaman sabitindeki belirsizlikler dikkate alınarak gerçekleştirilmiştir. FDBLFD tabanlı FOPID denetleyici ile tasarlanmış OGR sisteminin sağlamlık analizi sonuçları Çizelge 6.8’de sunulmuştur.


Çizelge 6.8. FDBLFD tabanlı FOPID kontrolcü ile tasarlanan OGR sisteminin sağlamlık analizi sonuçları.

Parametre	Değişim oranı (%)	$t_r(0.1 \rightarrow 0.9)$	$t_s (\pm\%5)$	OS (%)
T_A	-50	0,113	0,153	2,20
	-25	0,130	0,173	2,35
	+25	0,164	0,219	2,36
	+50	0,170	0,225	2,52
T_E	-50	0,115	0,154	2,40
	-25	0,137	0,183	2,47
	+25	0,156	0,209	2,38
	+50	0,184	0,247	1,86

Çizelge 6.8. (devam) FDBLFD tabanlı FOPID kontrolcü ile tasarlanan OGR sisteminin sağlamlık analizi sonuçları.


T_G	-50	0,115	0,153	2,33
	-25	0,132	0,176	2,58
	+25	0,157	0,210	2,42
	+50	0,189	0,255	1,73
T_S	-50	0,149	0,198	2,31
	-25	0,151	0,201	2,35
	+25	0,156	0,209	2,19
	+50	0,147	0,196	2,42

FDBLFD algoritması ile optimize edilen FOPID tabanlı OGR sisteminin terminal gerilim değişimi, parametre belirsizliği durumları için incelenmiştir. Şekil 6.14, Çizelge 6.8'in ikinci sütununda belirtilen simülasyon durumlarına göre elde edilen terminal gerilimi değişim eğrilerini göstermektedir. İlgili şekilden, önerilen FDBLFD-FOPID kontrolcünün makul yükselme ve yerleşme süresinin yanı sıra minimum aşma değeri sunduğu gözlemlenmiştir. Özetle, önerilen FDBLFD-FOPID tabanlı OGR nominal olmayan koşullar altında sistem kararlılığını sağlamada başarılı bir performans sergilemiştir.




(a)

Şekil 6.14. Zaman sabitlerinin nominal değer -%50 ve +%50 aralığındaki değişimi için FDBLFD-FOPID ile tasarlanan OGR sistemi birim basamak tepkisi (a) T_A , (b) T_E , (c) T_G , (d) T_S .




(b)



(c)

Şekil 6.14. (devam) Zaman sabitlerinin nominal değerin -%50 ve +%50 aralığındaki değişimi için FDBLFD-FOPID ile tasarlanan OGR sistemi birim basamak tepkisi (a) T_A , (b) T_E , (c) T_G , (d) T_S .



(d)


Şekil 6.14. (devam) Zaman sabitlerinin nominal değer -%50 ve +%50 aralığındaki değişimi için FDBLFD-FOPID ile tasarlanan OGR sistemi birim basamak tepkisi (a) T_A , (b) T_E , (c) T_G , (d) T_S .

6.4.4. PIDD² Kontrolcü ile OGR Tasarımı

Dört terimli PIDD² denetleyicinin oransal (K_p), integral (K_i), türev (K_d) ve ikinci dereceden türev (K_{d2}) kazanç katsayıları önerilen FDBLFD, DE, BMO, HHO ve MFO algoritmaları kullanılarak optimize edilmiştir. PIDD² kontrolcü parametrelerinin optimizasyonunda Eşitlik (6.11)'de verilen amaç fonksiyonu ($OF2$) kullanılmıştır. Buna göre optimizasyon algoritmaları ile elde edilen denetleyici kazanç parametreleri ve karşılık gelen OGR sisteminin geçici adım tepkisi karakteristikleri Çizelge 6.9'da verilmiştir. Şekil 6.15, birim basamak tepki kalitesi açısından algoritmaların karşılaştırmalı analizini sunar.

Çizelge 6.9. Önerilen FDBLFD ve rekabetçi algoritmalar ile optimize edilen PIDD² kontrolcü parametreleri ve OGR sistemi geçici tepki özellikleri.

Algoritma	K_p	K_i	K_d	K_{d2}	$t_r(0.1 \rightarrow 0.9)$	$t_s (\%5)$	OS (%)
FDBLFD	3,0000	2,7469	1,4054	0,0851	0,063	0,081	1,70
DE	3,0000	2,0335	1,0737	0,0729	0,085	0,111	0,92
BMO	2,6912	1,7961	1,0850	0,0768	0,085	0,115	0,02
HHO	3,0000	2,8541	1,2122	0,0758	0,075	0,095	1,57
MFO	2,9999	2,0047	1,0747	0,0769	0,084	0,113	0,27




Şekil 6.15. PIDD² denetleyici tabanlı OGR sisteminin birim basamak tepkisi.

Önerilen FDBLFD algoritması ile optimize edilmiş PIDD² kontrolcünün nominal olmayan koşullar için sağlamlık analizi gerçekleştirilmiştir. Bu amaçla T_A , T_E , T_G ve T_S zaman sabitlerinin farklı değişim oranları için OGR sisteminin performansı incelenmiştir. Çizelge 6.10, FDBLFD-PIDD² kontrolcü tabanlı OGR'nin sağlamlık analizi sonuçlarını özetler. Sağlamlık analizi sonuçları, FDBLFD-PIDD² ile tasarlanan OGR sisteminin yükseltici, uyarıcı, jeneratör ve sensör zaman sabitlerindeki parametre belirsizliğine karşı gerilim seviyesini arzu edilen seviyede tutmak için kararlı ve sağlam bir performans sergilediğini göstermiştir.

Şekil 6.16, OGR sistem bileşeni zaman sabitlerinin nominal değerin -%50 ve +%50 aralığındaki değişimi için FDBLFD-PIDD² ile tasarlanan OGR sistemi birim basamak tepkisi eğrilerini gösterir. Birim basamak tepkisi eğrilerinden, önerilen algoritma ile tasarlanan OGR sisteminin nominal olmayan koşullarda terminal gerilimini arzu edilen seviyede tutmak için başarılı bir performans sergilediği gözlemlenmiştir.


Çizelge 6.10. FDBLFD tabanlı PIDD² kontrolcü ile tasarlanan OGR sisteminin sağlamlık analizi sonuçları.

Parametre	Değişim oranı (%)	$t_r(0.1 \rightarrow 0.9)$	$t_s (\pm\%5)$	OS (%)
T_A	-50	0,078	0,101	1,06
	-25	0,102	0,133	0,59
	+25	0,091	0,122	0,35
	+50	0,090	0,118	0,98
T_E	-50	0,064	0,085	0,00
	-25	0,076	0,103	0,16
	+25	0,097	0,130	0,34
	+50	0,100	0,131	0,87
T_G	-50	0,046	0,061	0,03
	-25	0,077	0,101	0,81
	+25	0,103	0,136	0,46
	+50	0,120	0,158	0,26
T_S	-50	0,098	0,128	0,91
	-25	0,091	0,121	0,55
	+25	0,072	0,095	0,00
	+50	0,070	0,092	0,22




(a)

Şekil 6.16. Zaman sabitlerinin nominal değer -%50 ve +%50 aralığındaki değişimi için FDBLFD-PIDD² ile tasarlanan OGR sistemi birim basamak tepkisi (a) T_A , (b) T_E , (c) T_G , (d) T_S .




(b)



(c)

Şekil 6.16. (devam) Zaman sabitlerinin nominal değerin -%50 ve +%50 aralığındaki değişimi için FDBLFD-PIDD² ile tasarlanan OGR sistemi birim basamak tepkisi (a) T_A , (b) T_E , (c) T_G , (d) T_S .



(d)

Şekil 6.16. (devam) Zaman sabitlerinin nominal değerin -%50 ve +%50 aralığındaki değişimi için FDBLFD-PIDD² ile tasarlanan OGR sistemi birim basamak tepkisi (a) T_A , (b) T_E , (c) T_G , (d) T_S .

6.4.5. FDBLFD Tabanlı Kontrolcü Performanslarının Karşılaştırılması


Bu alt bölüm, önerilen FDBLFD algoritması kullanılarak optimize edilen PID, PIDF, FOPID ve PIDD² kontrolcü performanslarının karşılaştırmalı analizini sunar. Dört farklı kontrolcü ile tasarlanan OGR sistemi için elde edilen geçici tepki parametreleri Çizelge 6.11’de verilmiştir.

Çizelge 6.11. FDBLFD tabanlı PID, PIDF, FOPID ve PIDD² kontrolcülerini ile tasarlanan OGR sisteminin geçici tepki parametreleri.

Algoritma	$t_r(0.1 \rightarrow 0.9)$	$t_s (\pm\%5)$	OS (%)
PID	0,263	0,362	1,51
PIDF	0,266	0,368	1,48
FOPID	0,140	0,187	2,53
PIDD ²	0,063	0,081	1,70

Çizelge 6.11’de verilen sonuçlardan, PIDD² denetleyicinin PID, PIDF ve FOPID denetleyicilerinin 0,263, 0,266 ve 0,140 saniye olarak rapor edilen simülasyon

sonuçlarına kıyasla %76,04, %76,31 ve %55 daha düşük olan minimum yükselme süresi (0,063 saniye) değerini elde ettiği görülmektedir. Yükselme süresi (t_r) açısından PIDD² kontrolcüye en yakın performans FOPID denetleyicisine aittir. Yerleşme zamanı (t_s) parametresi ile ilgili olarak, PIDD² denetleyici daha optimal bir yerleşme süresi elde etmede diğerlerine üstünlük sağlayan tek öncü olmuş ve bunu FOPID, PID ve PIDF denetleyicileri izlemiştir. Öte yandan PID ve PIDF denetleyicileri tarafından sunulan aşma (OS %) değeri, diğer iki kontrolcünden daha iyidir. Minimum aşım değeri elde etmede PID ve PIDF denetleyicilerine en yakın performansın PIDD² kontrolcüye ait olması dikkat çekicidir. PID, PIDF, FOPID ve PIDD² tarafından kontrol edilen OGR sistemi birim basamak tepkisi Şekil 6.17’de gösterilmiştir. İlgili şekilden, FDBLFD ile optimize edilen PIDD² denetleyicinin en iyi adım yanıtını sunduğu görülmektedir. Bu sonuca ulaşmada, PIDD² denetleyicinin en iyi yükselme ve yerleşme süresinin yanı sıra rekabetçi aşma değeri sunması etkili olmuştur.



Şekil 6.17. PID, PIDF, FOPID ve PIDD² kontrolcülerinin tasarlanan OGR sisteminin birim basamak tepkisi.

6.5. LİTERATÜR KARŞILAŞTIRMASI

Önerilen FDBLFD algoritması ile tasarlanan OGR sisteminin geçici zaman tepki parametreleri ve literatürde yakın zamanda rapor edilen rekabetçi algoritmaların simülasyon sonuçları Çizelge 6.12’de verilmiştir. Buna göre en iyi yükselme süresi (t_r), yerleşme süresi (t_s) ve minimum aşmayı ($OS\%$) aynı anda sunan tek bir algoritma yoktur. MSA algoritmaları kullanılarak optimize edilen PID denetleyici sonuçları incelendiğinde, SFS yönteminin [63] en iyi yükselme zamanı sunmasına rağmen, yerleşme süresi ve aşım değerlerinin oldukça yüksek olduğu görülmektedir. Ayrıca, en iyi yerleşme süresini sağlayan EO [64] yükselme süresi ve aşım açısından rakiplerinin çoğundan daha kötüdür. En iyi aşım değerine sahip olan FDBLFD yönteminin yükselme ve yerleşme zamanı parametrelerinin makul olduğu gözlemlenmiştir. SA-MRFO tabanlı PIDF denetleyici FDBLFD tabanlı sonuçtan sadece %2,98 daha az olan en iyi yerleşme süresi değerini sunmuştur. FOPID denetleyici sonuçları detaylı olarak incelendiğinde yerleşme süresi açısından en iyi sonucun MOEO algoritmasına [158] ait olduğu ve onu C-YSGA [159] ve FDBLFD algoritmalarının takip ettiği görülmektedir. PIDD² denetleyici tasarımında önerilen FDBLFD yöntemi, hibrit SA-MRFO [157] algoritması ile rekabetçi bir performans sergilemiştir.

Çizelge 6.12. Literatür karşılaştırması.

PID				FOPID			
Yöntem	$t_r(0,1 \rightarrow 0,9)$	$t_s (\pm\%5)$	OS (%)	Yöntem	$t_r(0,1 \rightarrow 0,9)$	$t_s (\pm\%5)$	OS (%)
FDBLFD	0,263	0,362	1,51	FDBLFD	0,140	0,187	2,53
TSA [160]	0,132	0,678	15,5	SCA [66]	0,1660	0,2260	2,4223
IKA [67]	0,128	0,670	15	SCA [65]	0,1549	0,2183	0,01
LUS [161]	0,150	0,696	15,6	PSO [157]	0,1592	0,2996	1,08
ABC [54]	0,156	0,920	25	SA [56]	0,2653	0,4057	0,5246
PSO [68]	0,161	1,000	30,1	CAS [63]	0,2223	0,3037	0,1678
DE [54]	0,152	0,951	32,9	PSO [171]	0,137	0,456	0,095
PSA [162]	0,144	0,710	16,8	GA [171]	0,129	0,339	9,260
BBO [62]	0,149	0,768	15,5	MOEO [158]	0,130	0,180	3,203
GOA [163]	0,130	0,622	20,5	NSGA [158]	0,320	1,270	38,78
SA-MRFO [157]	0,259	1,030	0	SA-MRFO [157]	0,130	0,190	1,976
PSO [57]	0,272	0,376	1,16	CS [172]	0,104	0,450	0,440
MOL [55]	0,343	0,471	1,95	PSO [173]	0,062	1,853	20,56
GA [165]	0,242	0,660	8,11	JAYA [174]	0,096	0,478	20
hSOS-SA [164]	0,319	0,442	0,301	SSA [69]	0,098	0,500	15,5
SOS [164]	0,318	0,441	0,301	C-YSGA [159]	0,134	0,184	2,9
TLBO [59]	0,373	0,523	0,638	NSGA-II [175]	0,954	1,190	1,99
SFS [63]	0,103	0,584	22,80	ALO [176]	0,069	0,335	7,1
WCO [166]	0,252	1,330	9,66	DLCSA [177]	0,246	0,346	0,138
HHO [167]	0,137	0,685	14,4	HGSO [178]	0,0907	0,374	3,35

Çizelge 6.12. (devam) Literatür karşılaştırması.

AEFA [168]	0,140	0,690	14,3	PIDD ²			
EO [64]	0,250	0,345	1,98	Yöntem	$t_r(0,1 \rightarrow 0,9)$	$t_s (\pm\%5)$	OS (%)
CS [169]	0,308	0,426	0,020	FDBLFD	0,063	0,081	1,70
PIDF				PSO [68]	0,092	0,127	0
Yöntem	$t_r(0,1 \rightarrow 0,9)$	$t_s (\pm\%5)$	OS (%)	SA-MRFO [157]	0,053	0,068	0,756
FDBLFD	0,266	0,368	1,48				
SA-MRFO [157]	0,257	0,357	1,728				
SCA [66]	0,260	0,361	1,431				
TLBO [59]	0,353	0,560	0,01				
CS [169]	0,308	0,426	0,020				
PSO [170]	0,240	0,520	2,60				


6.6. SONUÇLAR: OPTİMAL OGR TASARIMI

Bu bölümde, PID, PIDF, FOPID ve PIDD² denetleyici parametrelerinin meta-sezgisel optimizasyon algoritmaları kullanılarak ayarlanması yoluyla optimal OGR tasarım probleminin çözümü gerçekleştirilmiştir. Özetle, bu bölümün sonuçları aşağıdaki gibi listelenebilir:

- Önerilen FDBLFD algoritması, literatürdeki popüler gerçek dünya mühendislik problemlerinden biri olan kısıtlı optimal OGR tasarım problemine uygulanmıştır.
- Önerilen algoritmanın performansı, nominal ve nominal olmayan çalışma koşullarında (parametre belirsizliği) OGR tasarımı için kullanılan PID, PIDF, FOPID ve PIDD² denetleyici kazanç parametrelerinin optimum ayarı için test edilmiştir.
- Dört farklı kontrolcü ile tasarlanan OGR sisteminin performansı, zaman alanı ve sağlamlık analizi ile test edilmiştir.
- Zaman alanı analizinde, OGR sisteminin birim basamak referansı için geçici tepki özellikleri (yükselme zamanı, yerleşme zamanı ve maksimum aşım) incelenirken, sağlamlık analizinde parametre belirsizliği durumunda denetleyici performansı araştırılmıştır. Parametre belirsizliği, OGR bileşenleri zaman sabitlerinin (T_A , T_E , T_G ve T_S) %25'lik adım boyutunda -%50 ile +%50 arasındaki değişimi olarak simüle edilmiştir.
- Simülasyon sonuçları, FDBLFD yönteminin OGR sistemi için kararlı (minimum salınım ve aşım) birim adım yanıtını elde edebildiği ve rakip optimize edicilerle rekabetçi performans sergilediğini göstermiştir.
- FDBLFD ile optimize edilen kontrolcü performansları arasındaki karşılaştırmalı analiz PIDD² denetleyicinin diğer kontrolcülere kıyasla geçici tepki özellikleri açısından daha kaliteli çözümler elde edebildiğini göstermiştir.

7. YÖNLÜ AŞIRI AKIM RÖLELERİ KOORDİNASYON PROBLEMİNİN MODELLENMESİ VE OPTİMİZASYONU

Yönlü Aşırı Akım Röleleri (YAAR), elektrik üretim şebekelerinin iletim ve dağıtım sistemlerini korumak için yaygın olarak kullanılmaktadır. Bu rölelerin çeşitli çalışma koşullarına göre uygun ayarlarının belirlenmesi güç sistemindeki arızalı noktanın zamanında izolasyonunda önemli rol oynamaktadır. Yönlü aşırı akım röleleri, güç sistemlerinde birincil (primary) ve yedek (backup) koruma sağlayabildiğinden bu rölelerin optimal koordinasyonu güç sistemi güvenliği için kritik öneme sahiptir [72]. YAAR koordinasyonunda öncelikle birincil röleler ile korunan alandaki arızaların giderilmesi amaçlanır. Birincil rölelerin başarısız olması durumunda ilgili yedek röle belirli bir koordinasyon gecikmesi ile arızayı giderir. Yakın uç (near-end) hatası (F1) ve uzak uç (far-end) hatası (F2) için birincil/yedek röle çiftlerini içeren bir şebeke modeli Şekil 7.1’de gösterilmiştir. Şekilde gösterilen elektrik şebekesinde F1 ve F2 arızaları için birincil/yedek röle çiftleri R1/R5, R1/R4 ve R2/R8 olarak tanımlanmıştır [179], [180].



Şekil 7.1. Birincil/yedek röle çiftlerini içeren temsili bir elektrik şebekesi.

YAAR koordinasyonu lineer olmayan, yüksek boyutlu karmaşık bir optimizasyon problemidir ve koordinasyon marjı ve sınır limitleri gibi çeşitli kısıtlara tabi olarak çözülmelidir. Amaç fonksiyonu ve kısıtlar nedeniyle problemin tanımlandığı arama uzayının yüksek geometrik karmaşıklığa sahip olması YAAR koordinasyonu optimizasyon probleminin çözümü için güçlü algoritmaların kullanılmasını gerektirir. Bu kapsamda, tez çalışmasının orijinal katkılarından biri olarak geliştirilen hibrit $dFDB$ -MRFO algoritması yönlü aşırı akım röleleri koordinasyon problemi optimizasyonuna uygulanmıştır. Önerilen hibrit algoritmanın performansı farklı karmaşıklığa sahip test

sistemlerinde (IEEE 3-baralı, IEEE 4-baralı, Standart 8-baralı, Standart 9-baralı ve IEEE 30-baralı) değerlendirilmiştir.

Bu bölümün geri kalanı şu şekilde düzenlenmiştir: Bölüm 7.1’de, yönlü aşırı akım röleleri koordinasyon probleminin matematiksel modeli sunulmuştur. Bölüm 7.2’de, *d*FDB seçim yöntemi kullanılarak geliştirilen hibrit *d*FDB-MRFO algoritmasının performansını test etmek için gerçekleştirilen simülasyon çalışmalarının sonuçları tartışılmıştır. Bölüm 7.3’te, istatistiksel analiz sonuçları ve yakınsama analizi verilmiştir. Bölüm 7.4, YAAR koordinasyon probleminin sonuçlarını özetler.

7.1. YAAR KOORDİNASYON PROBLEMİNİN MATEMATİKSEL MODELİ

Yönlü aşırı akım rölelerinin koruma bölgesi, ölçülen arıza akımının bir fonksiyonudur. Ölçülen arıza akımı önceden belirlenmiş başlatma akımı ayarından daha büyük olduğunda röle arızayı temizlemek için devreye girer. YAAR koordinasyonunda her röle kendi hattının (rölenin kurulduğu yer) birincil korumasını ve tüm bitişik hatların yedek korumasını sağlamalıdır. Bu çalışmada, YAAR optimal koordinasyonu ile ilgili literatürdeki güncel çalışmalarda rapor edilen varsayımlar dikkate alınmıştır. Bu varsayımlar aşağıdaki gibidir [180]:

- Her koruma bölgesi, hatlardan birine karşılık gelir.
- Yönlü aşırı akım röleleri her hattın iki ucuna da yerleştirilir.
- Birincil röle, yalnızca koruma bölgesindeki (hatta) bir arıza için açmalıdır.
- Birincil röle arızayı gideremezse, yedek röle koordinasyon zaman gecikmesinden sonra devreye girmelidir.
- Farklı konumlar ve karşılık gelen birincil/yedek röle çiftleri için arıza akımları önceden belirlenir.
- Yakın uç, uzak uç ve orta nokta arıza akımları kullanılır.
- Ağ topolojileri sabittir. Röle koordinasyonu sırasında sistemin geçici konfigürasyonu ihmal edilir ve hatların termal sınırları dikkate alınmaz.

YAAR koordinasyon problemi, çeşitli koordinasyon kriterleri ve problem değişkenleri kısıtlarına tabi olarak amaç fonksiyonunun (OF) minimizasyonu olarak tanımlanır. Arızayı gidermek için ilk önce çalışması gereken röleye birincil röle denir. Geleneksel

olarak koordinasyon çalışmalarında amaç fonksiyonu, tüm birincil rölelerin çalışma sürelerinin toplamı olarak ifade edilir. Eşitlik (7.1)'de verilen amaç fonksiyonu birincil rölelerin çalışma süresini en aza indirmede yaygın olarak kullanılmaktadır [179], [181].

$$\min_{TDS, PCS} OF = \sum_{i=1}^m T_{pr,i} \quad (7.1)$$

$$T_{pr,i} = \frac{\lambda \cdot TDS_i}{\left(\frac{I_i}{PCS_i}\right)^\psi - \varphi} \quad (7.2)$$

Eşitlik (7.1)'de m ve $T_{pr,i}$ sırasıyla birincil rölelerin toplam sayısını ve i . rölenin çalışma süresini gösterir. TDS (Time Dial Setting) ve PCS (Pickup Current Setting), YAAR koordinasyonu optimizasyon probleminin kontrol değişkenleridir. $\lambda = 0,14$, $\psi = 0,02$, ve $\varphi = 1$ röle karakteristiğini temsil eden nümerik değerlerdir. I_i , i . röle tarafından okunan arıza akımıdır. Her röle, akım seviyesini düşürmek için bir akım trafosu (CT- Current transformer) aracılığıyla hatta bağlanır. Buna göre I_i akımı, akım trafosu primer terminallerindeki arıza akımının ($I_{f,i}$) ve CT_{rating} değerinin bir oranı olarak hesaplanır [179].

$$I_i = \frac{I_{f,i}}{CT_{rating}} \quad (7.3)$$

Eşitlik (7.1)'de verilen OF amaç fonksiyonu, güç sistemi araştırmacıları tarafından optimum röle koordinasyonu sağlamak için yaygın olarak kullanılmaktadır. OF sadece birincil rölelerin çalışma süresini dikkate aldığından bu amaç fonksiyonunun en büyük dezavantajı birincil ve yedek röle arasındaki koordinasyon marjının yüksek olma ihtimalidir.

Yönlü aşırı akım röleleri optimal koordinasyonu optimizasyon probleminin kısıtları iki kategoriye ayrılmıştır. Bunlar; röle ayarları ve koordinasyon kısıtlarıdır.

i. Röle ayar kısıtları

Eşitlik (7.4) ve (7.5) kontrol değişkenlerinin sınırlarını tanımlar.

$$TDS_i^{min} \leq TDS_i \leq TDS_i^{max} \quad i = 1, \dots, m \quad (7.4)$$

$$PCS_i^{min} \leq PCS_i \leq PCS_i^{max} \quad i = 1, \dots, m \quad (7.5)$$

Röle çalışma süresi sınırları Eşitlik (7.6)'da verilmiştir.

$$T_{pr,i}^{min} \leq T_{pr} \leq T_{pr,i}^{max} \quad i = 1, \dots, m \quad (7.6)$$


ii. Koordinasyon kısıtları

YAAR optimal koordinasyonu, korunan alandaki arızaların ilgili birincil rölelerle ortadan kaldırılmasını sağlamak için uygun ayarları tanımlar. Bu durumun başarısız olması durumunda ilgili yedek rölelerin koordinasyon zaman gecikmesinden sonra arızayı gidermesi beklenir. Eşitlik (7.8)'de verilen koordinasyon zaman kısıtı birincil ve yedek rölelerin uygun olmayan (yanlış) koordinasyonunu önlemek için dikkate alınmalıdır [179], [180].

$$CTI = T_{br,j} - T_{pr,i} \quad i = 1, \dots, m \quad (7.7)$$

$$CTI \geq CTI_{min} \quad (7.8)$$

Eşitlik (7.7)'de T_{pr} ve T_{br} , sırasıyla birincil ve yedek röle çalışma sürelerini temsil eder. Eşitlik (7.8)'de kullanılan CTI_{min} minimum koordinasyon zaman aralığını gösterir. CTI_{min} tipik değeri 0,2-0,3 sn'dir. Şekil 7.2, F1 (yakın-uç) ve F2 (uzak-uç) arızaları için birincil ve yedek röleler için temsili CTI değerlerini gösterir.



Şekil 7.2. Birincil ve yedek röleler arasında koordinasyon.

Birbirine bağı güç sistemlerinde birincil/yedek (P/B) röle koordinasyon kısıtlarının sayısı oldukça fazladır. Bu tür güç sistemlerinde yedek rölelerin arızaya tepki süresi ve P/B röle çiftleri arasındaki zaman farkı (CTI) oldukça yüksek olabilir. Bu çalışmada olası koordinasyon problemlerini önlemek için Eşitlik (7.9)'da verilen modifiye amaç fonksiyonu (MOF) kullanılmıştır [179].

$$\min_{TDS, PCS} MOF = \alpha_1 \sum_{i=1}^m T_{pr,i} + \alpha_2 \sum_{p=1}^{mp} [\Delta T_{mbp} - \beta (\Delta T_{mbp} - |\Delta T_{mbp}|)]^2 \quad (7.9)$$

$$\Delta T_{mbp} = T_{br,j} - T_{pr,i} - CTI_{min} \quad (7.10)$$

Modifiye amaç fonksiyonunda kullanılan ΔT_{mbp} , p . röle çifti ile CTI_{min} arasındaki farkı temsil eder. α_1 ve α_2 , MOF amaç fonksiyonu terimlerinin etkisini kontrol eden ağırlık katsayılarıdır. β yanlış koordinasyonu önlemek için kullanılır.

7.2. YAAR KOORDİNASYON PROBLEMİNİN SİMÜLASYON ÇALIŞMALARI, SONUÇLARI VE KARŞILAŞTIRMALARI

Bu çalışmada, yönlü aşırı akım röleleri koordinasyon probleminin optimizasyonu için dinamik uygunluk-mesafe dengesi tabanlı manta ışını yiyecek arama optimizasyon (Dynamic Fitness-Distance Balance Manta Ray Foraging Optimization, *d*FDB-MRFO), atom arama optimizasyon (Atom Search Optimization, ASO [182]), yapay elektrik alan algoritması (Artificial Electric Field Algorithm, AEFA [183]), salp sürü algoritması (Salp Swarm Algorithm, SSA [119]) ve geleneksel manta ışını yiyecek arama optimizasyon (Manta Ray Foraging Optimization, MRFO [25]) algoritması kullanılmıştır. Optimizasyon algoritmalarının performansı IEEE 3-baralı, IEEE 4-baralı, Standart 8-baralı, Standart 9-baralı ve IEEE 30-baralı olmak üzere farklı karmaşıklığa sahip beş test sisteminde değerlendirilmiştir. YAAR koordinasyon probleminin çözümünde tüm algoritmalar için popülasyon büyüklüğü ve maksimum iterasyon sayısı sırasıyla 50 ve 10000 olarak ayarlanmıştır. Test sistemleri konfigürasyonu ve kısıtlar Çizelge 7.1 ve 7.2'de verilmiştir.

Çizelge 7.1. Simülasyon çalışmalarında kullanılan test sistemleri konfigürasyonu.


Test Sistemi	Röle sayısı	Kontrol değişkeni sayısı	Seçicilik kısıtları sayısı
IEEE 3-baralı	6	12	8
IEEE 4-baralı	8	16	9
Standart 8-baralı	14	28	20
Standart 9-baralı	24	48	32
IEEE 30-baralı	38	76	62

Çizelge 7.2. Farklı test sistemleri için kısıtlar.

Test Sistemi	$[TDS_i^{min}, TDS_i^{max}]$	$[PCS_i^{min}, PCS_i^{max}]$	$[T_{pr,i}^{min}, T_{pr,i}^{max}]$	CTI_{min}
IEEE 3-baralı	[0,05-1,1]	[1,25-1,5]	[0,1-1,1]	0,3
IEEE 4-baralı	0,05-1,1]	[1,25-1,5]	[0,1-1,1]	0,3
Standart 8-baralı	[0,1-1,1]	[0,5-2,5]	[0,1-1,1]	0,3
Standart 9-baralı	[0,01-1]	[0,5-2,5]	[0,1-1,1]	0,2
IEEE 30-baralı	[0,1-1,1]	[1,5-6]	[0,1-1,1]	0,3

Test Sistemi-1: IEEE 3-Baralı Test Sistemi

IEEE 3-baralı test sisteminin tek hat şeması ve röle konumları Şekil 7.3'te gösterilmiştir. Test sistemi konfigürasyonu 1 jeneratör, 3 hat, 6 YAAR ve 8 birincil/yedek röle çiftinden oluşmaktadır. TDS kontrol değişkeni için minimum ve maksimum limit değerleri sırasıyla 0,05 ve 1,1 olarak ayarlanmıştır. PCS kontrol değişkeni limitleri ise 1,25-1,50 aralığındadır. CTI_{min} değeri 0,3 sn olarak seçilmiştir. IEEE 3-baralı test sistemi röle koordinasyon probleminde 12 kontrol değişkeni (TDS1-TDS6 ve PCS1-PCS6) ve birincil/yedek röle çiftleri için 8 seçicilik kısıtı bulunmaktadır. Arıza akım değerleri (I_i) Çizelge 7.3 ve 7.4'te verilmiştir [74].



Şekil 7.3. IEEE 3-baralı test sistemi.

Çizelge 7.3. Test Sistemi-1 için röle tarafından okunan arıza akımı (I_f).

Röle	Arıza Akımı I_f (p.u.)		Hat
	Yakın-uç	Uzak-uç	
R1	9,46/2,06	14,08/2,06	1-2
R2	26,91/2,06	100,63/2,06	1-2
R3	8,81/2,23	12,07/2,23	1-3
R4	37,68/2,23	136,23/2,23	1-3
R5	17,93/0,80	25,90/0,80	2-3
R6	14,35/0,80	19,20/0,80	2-3

Çizelge 7.4. Birincil/yedek röle çiftleri için arıza akımı (I_f) değerleri (Test Sistemi-1).

Yedek Röle	Arıza Akımı (p.u.)		Birincil Röle	Arıza Akımı (p.u.)	
	Yakın-uç	Uzak-uç		Yakın-uç	Uzak-uç
R5	14,08/0,80	9,46/0,80	R1	14,08/2,06	9,46/2,06
R6	12,07/0,80	8,81/0,80	R3	12,07/2,23	8,81/2,23
R4	25,90/2,23	17,93/2,23	R5	25,90/0,80	17,93/0,80
R2	14,35/2,06	19,20/2,06	R6	14,35/0,80	19,20/0,80

Çizelge 7.5, önerilen $dFDB$ -MRFO ve rekabetçi optimizasyon algoritmaları ile elde edilen amaç fonksiyonu değerlerinin yanı sıra optimize edilen kontrol değişkenlerini özetler. Sonuçlar detaylı olarak analiz edildiğinde en iyi amaç fonksiyonu değeri (4,78057 s) elde etmede öne çıkan iki algoritmanın $dFDB$ -MRFO ve MRFO olduğu

gözlemlenmiştir. Diğer bir ifadeyle, bu iki algoritma ile elde edilen simülasyon sonucu ASO, AEFA ve SSA yöntemleri ile elde edilen simülasyon sonuçlarına kıyasla sırasıyla %6,88029, %1,01418 ve %0,73258 daha düşüktür. Çizelgeden, TDS ve PCS kontrol değişkeni değerlerinin kabul edilebilir limitler içinde olduğu görülmektedir.

Çizelge 7.5. Test Sistemi-1 simülasyon sonuçları.

Röle	ASO		AEFA		SSA		MRFO		dFDB-MRFO	
	TDS	PCS	TDS	PCS	TDS	PCS	TDS	PCS	TDS	PCS
R1	0,0500	1,2990	0,0500	1,2500	0,0500	1,2520	0,0500	1,2500	0,0500	1,2500
R2	0,2127	1,3840	0,2090	1,3640	0,2105	1,3390	0,1976	1,5000	0,1976	1,5000
R3	0,0500	1,3530	0,0500	1,2500	0,0500	1,2570	0,0500	1,2500	0,0500	1,2500
R4	0,2356	1,3970	0,2284	1,2510	0,2147	1,4280	0,2090	1,5000	0,2090	1,5000
R5	0,2147	1,3860	0,1845	1,4360	0,1853	1,4220	0,1812	1,5000	0,1812	1,5000
R6	0,1980	1,3210	0,1888	1,3550	0,1822	1,4780	0,1807	1,5000	0,1807	1,5000
OF(s)	5,13379		4,82955		4,81585		4,78037		4,78037	
MOF	53,25686		46,88991		46,64826		46,00785		46,00785	

Çizelge 7.6, yakın-uç ve uzak-uç arızaları durumunda R5/R1, R6/R3, R4/R5 ve R2/R6 yedek/birincil röle çiftleri için koordinasyon zaman aralığı (Coordination Time Interval, CTI) değerlerini özetler. CTI, yedek röle ve birincil röle arasındaki çalışma süresi farkı olarak tanımlanmıştır. Örneğin CTI1, R5 (yedek) ve R1 (birincil) röleleri arasındaki çalışma süresi farkını gösterir. Yönlü aşırı akım röleleri koordinasyonunda tüm röle çiftleri için yedek ve birincil röle arasındaki çalışma süresi farkının CTI_{min} değerine eşit veya daha büyük olması gerekmektedir. Çizelge 7.6’da verilen sonuçlardan, tüm algoritmalar ile elde edilen koordinasyon marjı değerinin kabul edilebilir limitler dahilinde olduğu görülmektedir. Daha açık bir ifadeyle, CTI1-CTI8 değerleri CTI_{min} değerinden büyük veya ona eşittir. Sistem kararlılığını sağlamak ve ekipman hasarını önlemek için röle çalışma sürelerinin belirli sınırlar içinde olması YAAR koordinasyon probleminin önemli kısıtlarından biridir. Çizelge 7.7’deki karşılaştırma sonuçları tüm algoritmaların röle çalışma süresi değerini limitler dahilinde tutmada başarılı olduğunu göstermiştir.

Çizelge 7.6. Test Sistemi-1 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.


Arıza	Röle		CTI	ASO	AEFA	SSA	MRFO	$dFDB-MRFO$
	Yedek	Birincil						
Yakın-uç	R5	R1	CTI1	0,369	0,300	0,300	0,300	0,300
	R6	R3	CTI2	0,306	0,300	0,300	0,300	0,300
	R4	R5	CTI3	0,300	0,300	0,300	0,300	0,300
	R2	R6	CTI4	0,389	0,384	0,381	0,390	0,390
Uzak-uç	R5	R1	CTI5	0,412	0,334	0,334	0,336	0,336
	R6	R3	CTI6	0,317	0,317	0,320	0,321	0,321
	R4	R5	CTI7	0,401	0,386	0,397	0,400	0,400
	R2	R6	CTI8	0,302	0,300	0,300	0,300	0,300

Çizelge 7.7. Test Sistemi-1 için birincil rölelerin çalışma süresi.

Röle	Çalışma Süresi (s)	ASO		AEFA		SSA		MRFO		$dFDB-MRFO$	
		Yakın uç	Uzak uç	Yakın uç	Uzak uç	Yakın uç	Uzak uç	Yakın uç	Uzak uç	Yakın uç	Uzak uç
R1	$T_{pr,1}$	0,274	0,207	0,265	0,203	0,266	0,203	0,265	0,203	0,265	0,203
R2	$T_{pr,2}$	0,648	0,403	0,633	0,394	0,632	0,395	0,625	0,383	0,625	0,384
R3	$T_{pr,3}$	0,323	0,249	0,301	0,235	0,302	0,236	0,301	0,235	0,301	0,235
R4	$T_{pr,4}$	0,645	0,420	0,598	0,395	0,593	0,385	0,590	0,380	0,590	0,380
R5	$T_{pr,5}$	0,525	0,462	0,457	0,402	0,458	0,402	0,456	0,400	0,456	0,400
R6	$T_{pr,6}$	0,518	0,464	0,499	0,447	0,498	0,445	0,497	0,444	0,497	0,444

Test Sistemi-2: IEEE 4-Baralı Test Sistemi

IEEE 4-baralı test sisteminin tek hat şeması ve röle konumları Şekil 7.4’te gösterilmiştir. Test sistemi; 2 jeneratör, 4 iletim hattı, 8 YAAR ve 9 birincil/yedek röle çiftinden oluşur. IEEE 4-baralı test sistemi için röle koordinasyon problemi 9 seçicilik kısıtına (birincil/yedek röle çiftleri için koordinasyon zaman kriteri) tabi olarak 16 kontrol değişkeninin (TDS1-TDS8 ve PCS1-PCS8) optimal değerinin belirlenmesi olarak tanımlanmıştır. TDS kontrol değişkeni alt ve üst limitleri sırasıyla 0,05 ve 1,1, PCS değeri ise 1,25 ve 1,50 olarak ayarlanmıştır. CTI_{min} değeri 0.3 sn olarak seçilmiştir. Çizelge 7.8 ve 7.9, röle tarafından görülen arıza akımı değerlerini özetler [74].



Şekil 7.4. IEEE 4-baralı test sistemi.

Çizelge 7.8. Test Sistemi-2 için röle tarafından okunan arıza akımı (I_i).

Röle	Arıza akımı (p.u.)		Hat	Röle	Arıza akımı (p.u.)		Hat
	Yakın-uç	Uzak-uç			Yakın-uç	Uzak-uç	
R1	20,32/0,48	12,48/0,48	1-2	R5	116,70/1,5259	31,92/1,5259	2-4
R2	88,85/0,48	23,75/0,48	1-2	R6	16,67/1,5259	12,07/1,5259	2-4
R3	13,61/1,1789	10,38/1,1789	1-3	R7	71,70/1,2018	18,91/1,2018	3-4
R4	116,81/1,1789	31,92/1,1789	1-3	R8	19,27/1,2018	11,00/1,2018	3-4

Çizelge 7.9. Birincil/yedek röle çiftleri için arıza akımı (I_i) değerleri (Test Sistemi-2).

Yedek Röle	Arıza Akımı (p.u.)		Birincil Röle	Arıza Akımı (p.u.)	
	Yakın-uç	Uzak-uç		Yakın-uç	Uzak-uç
R5	20,32/1,5259	12,48/1,5259	R1	20,32/0,48	12,48/0,48
R7	13,61/1,2018	10,38/1,2018	R3	13,61/1,1789	10,38/1,1789
R1	1,16/0,48	-	R4	116,81/1,1789	-
R2	12,07/0,48	16,67/0,48	R6	12,07/1,5259	16,67/1,5259
R4	11,00/1,1789	19,27/1,1789	R8	11,00/1,2018	19,27/1,2018

*d*FDB-MRFO ve rekabetçi algoritmalar ile optimize edilen kontrol değişkeni değerleri Çizelge 7.10’da verilmiştir. Buna göre, *d*FDB-MRFO, MRFO, AEFA, SSA ve ASO algoritmalarının amaç fonksiyonu değerleri sırasıyla 3,66934 s, 3,66934 s, 3,71191 s, 3,72290 s ve 3,92797 s’dir. Test Sistemi-2 için verilen simülasyon sonuçları karşılaştırıldığında *d*FDB-MRFO ve MRFO algoritmalarının en iyi amaç fonksiyonu değerini elde ettiği tespit edilmiştir. Daha açık bir ifadeyle, bu iki algoritma toplam birincil röle çalışma süresini AEFA, SSA ve ASO yöntemlerinin sonuçlarına kıyasla 0,04257 s, 0,05356 s ve 0,25863 s azaltmıştır.

Çizelge 7.10. Test Sistemi-2 simülasyon sonuçları.

Röle	ASO		AEFA		SSA		MRFO		<i>d</i> FDB-MRFO	
	TDS	PCS	TDS	PCS	TDS	PCS	TDS	PCS	TDS	PCS
R1	0,0500	1,284	0,0500	1,354	0,0500	1,341	0,0500	1,273	0,0500	1,273
R2	0,2671	1,313	0,2185	1,371	0,2187	1,380	0,2122	1,500	0,2122	1,500
R3	0,0500	1,301	0,0500	1,255	0,0500	1,250	0,0500	1,250	0,0500	1,250
R4	0,1588	1,368	0,1634	1,250	0,1572	1,403	0,1516	1,500	0,1516	1,500
R5	0,1318	1,456	0,1352	1,307	0,1374	1,258	0,1264	1,500	0,1264	1,500
R6	0,0540	1,300	0,0500	1,252	0,0500	1,274	0,0500	1,250	0,0500	1,250
R7	0,1441	1,375	0,1415	1,340	0,1406	1355	0,1338	1,500	0,1338	1,500
R8	0,0500	1,320	0,0500	1,252	0,0500	1,333	0,0500	1,250	0,0500	1,250
OF(s)	3,92797		3,71191		3,72290		3,66934		3,66934	
MOF	214952,84		214949,22		214949,38		214948,61		214948,61	

Çizelge 7.10’da verilen sonuçlar tüm algoritmaların optimizasyon sonunda kontrol değişkeni değerlerini belirtilen limitler dahilinde tutmada başarılı olduğunu göstermiştir. Önerilen *d*FDB-MRFO ve rekabetçi algoritmaların kısıtları sağlayıp sağlamadığını kontrol etmek amacıyla Çizelge 7.11 ve 7.12 hazırlanmıştır. Bu çizelgelerde sırasıyla birincil/yedek röle çiftleri için koordinasyon zaman aralığı (CTI) ve röle çalışma süresi kısıtları incelenmiştir. Çizelge 7.11 detaylı olarak analiz edildiğinde, yönlü aşırı akım rölelerinin herhangi bir yanlış koordinasyon olmadan çalıştığı görülmektedir. Bu çıkarım, yedek/birincil röle çiftleri için hesaplanan CTI1-CTI9 değerlerinin koordinasyon marjı kısıtını sağlaması gerçeğine dayandırılmıştır. Çizelge 7.12’de verilen sonuçlar, birincil röle çalışma sürelerinin kabul edilebilir aralıkta (0,1-1,1) olduğunu göstermiştir.

Çizelge 7.11. Test Sistemi-2 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.

Arıza	Röle		CTI	ASO	AEFA	SSA	MRFO	$dFDB-MRFO$
	Yedek	Birincil						
Yakın uç	R5	R1	CTI1	0,311	0,300	0,300	0,300	0,300
	R7	R3	CTI2	0,312	0,300	0,300	0,300	0,300
	R2	R6	CTI3	0,409	0,324	0,324	0,326	0,326
	R4	R8	CTI4	0,391	0,385	0,392	0,398	0,398
	R1	R4	CTI5	0,301	0,350	0,343	0,300	0,300
Uzak uç	R5	R1	CTI6	0,412	0,392	0,389	0,400	0,400
	R7	R3	CTI7	0,359	0,346	0,346	0,350	0,350
	R2	R6	CTI8	0,378	0,300	0,300	0,300	0,300
	R4	R8	CTI9	0,300	0,300	0,300	0,300	0,300

Çizelge 7.12. Test Sistemi-2 için birincil rölelerin çalışma süresi.

Röle	Çalışma süresi (s)	ASO		AEFA		SSA		MRFO		$dFDB-MRFO$	
		Yakın uç	Uzak uç	Yakın uç	Uzak uç	Yakın uç	Uzak uç	Yakın uç	Uzak uç	Yakın uç	Uzak uç
R1	$T_{pr,1}$	0,097	0,113	0,098	0,115	0,098	0,115	0,096	0,113	0,096	0,113
R2	$T_{pr,2}$	0,359	0,497	0,297	0,411	0,297	0,412	0,294	0,410	0,294	0,410
R3	$T_{pr,3}$	0,157	0,180	0,154	0,176	0,154	0,176	0,154	0,176	0,154	0,176
R4	$T_{pr,4}$	0,249	0,361	0,250	0,361	0,248	0,361	0,243	0,356	0,243	0,356
R5	$T_{pr,5}$	0,224	0,337	0,223	0,332	0,225	0,332	0,216	0,327	0,216	0,327
R6	$T_{pr,6}$	0,174	0,206	0,158	0,186	0,159	0,188	0,158	0,186	0,158	0,186
R7	$T_{pr,7}$	0,258	0,404	0,251	0,392	0,250	0,392	0,245	0,389	0,245	0,389
R8	$T_{pr,8}$	0,137	0,177	0,134	0,172	0,137	0,178	0,134	0,172	0,134	0,172

Test Sistemi-3: Standart 8-Baralı Test Sistemi

Standart 8-baralı test sisteminin tek hat şeması ve röle konumları Şekil 7.5'te gösterilmiştir. Test sistemi konfigürasyonu şu şekildedir: 2 jeneratör, 2 transformatör, 7 iletim hattı, 14 YAAR ve 20 birincil/yedek röle çifti. Her bir röle için optimize edilmesi gereken iki parametre (TDS ve PCS) vardır. TDS ve PCS kontrol değişkeni limitleri sırasıyla [0,1-1,1] ve [0,5-2,5] olarak ayarlanmıştır. 8-baralı test sisteminde röle koordinasyon problemi için CTI_{min} değeri 0,3 s'dir. Akım trafosu primer/sekonder dönüştürme oranı (CT_{rating}) R3, R7, R9 ve R14 röleleri için 800/5 iken diğer röleler için 1200/5'tir. Çizelge 7.13, 8-baralı test sistemindeki birincil/yedek röle çiftlerini ve akım trafosu primer terminallerinde okunan arıza akımı (I_f) değerlerini özetler [184].

Çizelge 7.13. (devam) Birincil/yedek röle çiftleri ve arıza akımı (I_f) (Test Sistemi-3).

R12	5899	R13	987
R12	5899	R14	1874
R13	2991	R8	2991
R14	5199	R1	996
R14	5199	R9	1165

Çizelge 7.14, Standart 8-baralı test sistemi için röle koordinasyon problemi simülasyon sonuçlarını özetler. Buna göre $dFDB$ -MRFO, ASO, MRFO, SSA ve AEFA algoritmalarının amaç fonksiyonu değerleri sırasıyla 8,54785 s, 10,67216 s, 10,75494 s, 11,26083 s ve 12,13057 s'dir. Daha açık bir ifadeyle, $dFDB$ -MRFO yönteminin simülasyon sonucu sırasıyla ASO, MRFO, SSA ve AEFA algoritmaları ile elde edilen simülasyon sonuçlarına kıyasla %19,9051, %20,5216, %24,9218 ve %29,5346 daha düşüktür. Simülasyon sonuçları, önerilen $dFDB$ -MRFO algoritmasının 8-baralı test sisteminde YAAR koordinasyon problemine optimum çözümler üretmede rakiplerine kıyasla daha başarı olduğunu göstermiştir.

Çizelge 7.14. Test Sistemi-3 simülasyon sonuçları.

Röle	ASO		AEFA		SSA		MRFO		$dFDB$ -MRFO	
	TDS	PCS	TDS	PCS	TDS	PCS	TDS	PCS	TDS	PCS
R1	0,2238	1,1510	0,2929	0,8450	0,1645	1,7820	0,1000	2,4910	0,1000	2,390
R2	0,3787	1,4350	0,3642	1,8950	0,4235	1,5630	0,4389	1,4920	0,2594	2,500
R3	0,2762	2,1540	0,3294	1,8990	0,3956	1,4560	0,4587	1,0130	0,2241	2,499
R4	0,2614	1,2900	0,2700	1,7010	0,4468	0,5380	0,3270	1,2850	0,1592	2,499
R5	0,1218	2,3220	0,2365	1,1470	0,1977	1,5920	0,2825	0,8760	0,1000	2,463
R6	0,3493	1,0140	0,3152	1,6210	0,4314	0,9780	0,2702	0,9970	0,3188	0,607
R7	0,3739	1,4110	0,3422	1,8490	0,4145	1,4290	0,3085	2,4880	0,2878	1,876
R8	0,2696	1,7140	0,3242	1,7300	0,2873	1,4950	0,1702	2,4440	0,1628	2,500
R9	0,2501	1,5400	0,4594	0,5030	0,1765	2,4820	0,1907	2,3910	0,1499	2,499
R10	0,2413	2,0940	0,2914	1,9600	0,2291	2,0060	0,4047	0,6620	0,1800	2,458
R11	0,2773	1,7480	0,2903	1,9630	0,3221	1,1990	0,2349	2,4090	0,2163	2,055
R12	0,3747	1,7290	0,3711	2,0640	0,3742	1,6960	0,4295	1,2570	0,2746	2,496
R13	0,2076	1,3170	0,3668	0,6120	0,1296	2,0050	0,1000	2,3960	0,1000	2,211
R14	0,3450	1,7920	0,3915	1,5380	0,3847	1,4290	0,4421	1,1090	0,2535	2,466
OF(s)	10,67216		12,13057		11,26083		10,75494		8,54785	
MOF	230,1577		296,4023		257,9658		242,9288		151,1337	

Çizelge 7.15’te, birincil ve yedek rölelerin uygun olmayan koordinasyonunu önlemek için dikkate alınan koordinasyon zaman aralığı kısıtı analiz edilmiştir. Çizelgeden yedek/birincil röle çiftleri için seçicilik kısıtının (CT1-CT20) başarılı bir şekilde ($CTI \geq 0,3$ s) yerine getirildiği görülmektedir. Çizelge 7.16’dan tüm birincil röleler için çalışma süresi değerinin kabul edilebilir limitler (0,1-1,1 s) dahilinde olduğu anlaşılmaktadır.

Çizelge 7.15. Test Sistemi-3 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.

Röle		CTI	ASO	AEFA	SSA	MRFO	$dFDB-MRFO$
Yedek	Birincil						
R6	R1	CTI1	0,3000	0,3000	0,5630	0,3000	0,3000
R1	R2	CTI2	0,3000	0,3000	0,3050	0,3000	0,4860
R7	R2	CTI3	0,3000	0,3000	0,3000	0,3000	0,3000
R2	R3	CTI4	0,3000	0,3000	0,3000	0,3000	0,3000
R3	R4	CTI5	0,3000	0,3000	0,3000	0,3000	0,3000
R4	R5	CTI6	0,3000	0,3000	0,3000	0,3000	0,3000
R5	R6	CTI7	0,3720	0,3300	0,3010	0,5510	0,4090
R1	R6	CTI8	0,5270	0,5430	0,3560	0,7170	0,5460
R5	R7	CTI9	0,3000	0,3000	0,3000	0,3000	0,3000
R13	R7	CTI10	0,4550	0,5120	0,3550	0,4720	0,4360
R7	R8	CTI11	0,5240	0,4450	0,6540	0,8670	0,5940
R9	R8	CTI12	0,4280	0,3480	0,4450	0,6880	0,4900
R10	R9	CTI13	0,3000	0,3000	0,3000	0,3020	0,3000
R11	R10	CTI14	0,3000	0,3000	0,3000	0,3000	0,3000
R12	R11	CTI15	0,3000	0,3000	0,3000	0,3000	0,3000
R13	R12	CTI16	0,3000	0,3000	0,3000	0,3070	0,3000
R14	R12	CTI17	0,3000	0,3000	0,3000	0,3000	0,3000
R8	R13	CTI18	0,3000	0,3000	0,4400	0,3020	0,3000
R1	R14	CTI19	0,3960	0,3960	0,5150	0,4790	0,5900
R9	R14	CTI20	0,3000	0,3000	0,3000	0,3000	0,3000

Çizelge 7.16. Test Sistemi-3 için birincil rölelerin çalışma süresi.


Röle	Çalışma süresi (s)	ASO	AEFA	SSA	MRFO	$dFDB-MRFO$
R1	$T_{pr,1}$	0,621	0,720	0,558	0,408	0,398
R2	$T_{pr,2}$	0,906	0,968	1,045	1,065	0,775
R3	$T_{pr,3}$	0,809	0,914	0,989	1,008	0,702
R4	$T_{pr,4}$	0,713	0,830	0,895	0,890	0,594
R5	$T_{pr,5}$	0,575	0,748	0,739	0,792	0,492
R6	$T_{pr,6}$	0,735	0,779	0,897	0,565	0,575
R7	$T_{pr,7}$	0,807	0,810	0,898	0,817	0,685

Çizelge 7.16. (devam) Test Sistemi-3 için birincil rölelerin çalışma süresi.

R8	$T_{pr,8}$	0,681	0,822	0,690	0,497	0,480
R9	$T_{pr,9}$	0,740	0,906	0,662	0,701	0,564
R10	$T_{pr,10}$	0,809	0,946	0,752	0,858	0,656
R11	$T_{pr,11}$	0,872	0,965	0,860	0,869	0,736
R12	$T_{pr,12}$	0,962	1,023	0,954	0,982	0,821
R13	$T_{pr,13}$	0,632	0,827	0,487	0,418	0,398
R14	$T_{pr,14}$	0,809	0,871	0,835	0,886	0,671

Test Sistemi-4: Standart 9-Baralı Test Sistemi

Standart 9-baralı test sisteminin tek hat şeması ve röle konumları Şekil 7.6’da gösterilmiştir. Test sistemi; 1 jeneratör, 12 iletim hattı, 24 YAAR ve 32 birincil/yedek röle çiftinden oluşur. Her bir röle için akım trafosu dönüştürme oranı CT_{rating} 500/1 olarak seçilmiştir. CTI_{min} değeri 0,2 s olarak ayarlanmıştır. Birincil/yedek röle çiftleri ve akım trafosu primer terminallerinde okunan arıza akımları gibi test sistemi detayları Çizelge 7.17’de özetlenmiştir [185]. Standart 9-baralı test sisteminde YAAR koordinasyonu arızaların ilgili birincil rölelerle temizlenmesi için optimal röle ayarlarını (TDS1-TDS24, PCS1-PCS24) belirlemeyi amaçlamaktadır. Bu durumun başarısız olması durumunda ilgili yedek rölelerin koordinasyon zaman gecikmesinden sonra arızayı gidermesi beklenir.



Şekil 7.6. Standart 9-baralı test sistemi.

Çizelge 7.17. Birincil/yedek röle çiftleri ve arıza akımı (I_f) (Test Sistemi-4).

Konum	Birincil röle	Yedek röle	$I_{f, pr}$ (A)	$I_{f, br}$ (A)	Konum	Birincil röle	Yedek röle	$I_{f, pr}$ (A)	$I_{f, br}$ (A)
A	R1	R15	24779	9150	G	R13	R11	16087	3088
	R1	R17	24779	15632		R13	R21	16087	13000
	R2	R4	8327	8327		R14	R16	18213	6285
B	R3	R1	16390	16390		R14	R19	18213	11934
	R4	R6	14671	14671	H	R15	R13	18213	6285
C	R5	R3	9454	9454		R15	R19	18213	11935
	R6	R8	23280	4777		R16	R2	16087	3088
	R6	R23	23280	18507		R16	R17	16087	13000
D	R7	R5	23280	4777	I	R18	R2	8161	2426
	R7	R23	23280	18507		R18	R15	8161	5736
	R8	R10	9454	9454	J	R20	R13	9286	4644
E	R9	R7	15304	15304		R20	R16	9286	4644
	R10	R12	16490	16490	K	R22	R11	8161	2426
F	R11	R9	8326	8327		R22	R14	8161	5736
	R12	R14	24779	9150	L	R24	R5	6149	3075
	R12	R21	24779	15631		R24	R8	6149	3075

Çizelge 7.18, Standart 9-baralı test sistemi YAAR koordinasyon probleminde optimizasyon algoritmaları ile elde edilen TDS ve PCS kontrol değişkeni değerlerinin yanı sıra amaç fonksiyonu (OF) değerlerini özetler. OF performans metriğine göre yapılan kıyaslamada, önerilen *d*FDB-MRFO'nun minimum amaç fonksiyonu değeri elde etmede en başarılı yöntem olduğu ve onu MRFO, ASO, SSA ve AEFA algoritmalarının izlediği gözlemlenmiştir. Daha açık bir ifadeyle, *d*FDB-MRFO algoritmasının simülasyon sonucu (9,92824 s), MRFO, ASO, SSA ve AEFA optimizasyon algoritmalarının simülasyon sonuçlarına kıyasla %4,3033, %12,1044, %13,2137 ve %20,0718 daha düşüktür.

Çizelge 7.18. Test Sistemi-4 simülasyon sonuçları.

Röle	ASO		AEFA		SSA		MRFO		<i>d</i> FDB-MRFO	
	TDS	PCS	TDS	PCS	TDS	PCS	TDS	PCS	TDS	PCS
R1	0,5276	0,565	0,3825	2,326	0,3639	1,760	0,3303	2,158	0,3294	1,940
R2	0,1370	2,092	0,2295	1,204	0,1285	2,177	0,2136	1,004	0,1147	2,236
R3	0,3151	1,325	0,3515	1,499	0,2450	2,353	0,2337	2,474	0,2278	2,286
R4	0,2325	1,462	0,2448	2,023	0,2716	0,901	0,2467	1,588	0,2062	1,541
R5	0,2014	1,959	0,3178	1,045	0,2132	1,708	0,2425	1,143	0,1698	2,183
R6	0,2945	1,857	0,3396	1,774	0,3577	1,050	0,2892	2,300	0,3046	1,375
R7	0,3715	1,144	0,3656	1,963	0,3202	1,675	0,2748	1,905	0,3089	1,383
R8	0,2674	1,024	0,2797	1,146	0,2434	1,295	0,1758	2,305	0,1732	2,085
R9	0,3356	0,565	0,3179	1,443	0,2347	1,655	0,1924	1,927	0,2412	0,998
R10	0,4211	0,595	0,3216	1,556	0,2785	1,846	0,2447	2,160	0,2362	2,111
R11	0,1444	2,037	0,3565	0,501	0,1506	1,842	0,1249	2,074	0,1049	2,470
R12	0,4441	1,191	0,3649	2,180	0,4777	0,775	0,3164	2,311	0,3502	1,596
R13	0,3626	0,977	0,4224	0,792	0,3413	0,981	0,2309	2,258	0,2624	1,602
R14	0,5193	0,553	0,4783	0,699	0,3760	1,307	0,3071	1,779	0,2848	2,042
R15	0,3592	1,533	0,4431	1,034	0,3081	1,933	0,3655	1,205	0,2868	2,010
R16	0,2758	2,005	0,4536	0,603	0,2861	1,645	0,2709	1,562	0,2470	1,800
R17	0,4222	1,716	0,4525	1,665	0,7979	1,140	0,3627	2,100	0,4278	1,204
R18	0,0868	1,094	0,0795	0,874	0,2057	2,205	0,0562	0,933	0,0661	2,201
R19	0,4623	1,142	0,3686	2,357	0,5013	1,812	0,3731	1,538	0,3275	1,936
R20	0,0991	0,822	0,0426	1,947	0,0124	2,246	0,0773	1,312	0,0638	1,608
R21	0,5022	1,057	0,4089	1,893	0,4434	2,285	0,5166	0,658	0,4103	1,368
R22	0,0868	0,990	0,0307	1,684	0,1562	1,864	0,0756	0,918	0,0659	2,318
R23	0,3648	2,176	0,4051	2,307	0,4995	2,008	0,3820	1,773	0,3686	1,602
R24	0,0489	1,631	0,0548	1,359	0,0438	1,040	0,0563	2,281	0,0987	0,814
OF(s)	11,29550		12,42146		11,43988		10,37470		9,92824	
MOF	324,9641		390,2518		339,0981		274,1420		251,0414	

*d*FDB-MRFO, ASO, AEFA, SSA ve MRFO algoritmaları ile elde edilen CTI değerlerinin karşılaştırmalı analizi Çizelge 7.19’da verilmiştir. İlgili çizelgede verilen sonuçlardan SSA algoritmasının R10/R8 röle çifti için koordinasyon (CTI1) kısıtını ihlal ettiği görülmektedir. Çizelge 7.20, 9-baralı test sisteminde kullanılan birincil rölelerin (R1-R24) çalışma süresi hakkında bilgi sunar. Çizelgede verilen sonuçlar derinlemesine analiz edildiğinde, AEFA (OT22) ve SSA (OT20) algoritmalarının birincil röle çalışma süresi kısıtını ihlal ettiği gözlemlenmiştir. Sonuçlar, AEFA ve SSA algoritmalarının Test Sistemi-4 için YAAR koordinasyonunu sağlamada yetersiz olduğunu göstermiştir.

Çizelge 7.19. Test sistemi-4 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.

Röle		CTI	ASO	AEFA	SSA	MRFO	<i>d</i> FDB-MRFO
Yedek	Birincil						
R15	R1	CTI1	0,200	0,200	0,200	0,200	0,200
R7	R1	CTI2	0,200	0,200	0,894	0,200	0,201
R4	R2	CTI3	0,200	0,200	0,200	0,200	0,200
R1	R3	CTI4	0,200	0,200	0,202	0,200	0,200
R6	R4	CTI5	0,200	0,200	0,200	0,200	0,200
R3	R5	CTI6	0,200	0,200	0,200	0,200	0,200
R8	R6	CTI7	0,200	0,200	0,200	0,200	0,200
R23	R6	CTI8	0,256	0,290	0,530	0,201	0,212
R5	R7	CTI9	0,200	0,200	0,200	0,200	0,200
R23	R7	CTI10	0,200	0,211	0,513	0,271	0,203
R10	R8	CTI11	0,200	0,200	0,199	0,200	0,200
R7	R9	CTI12	0,200	0,200	0,202	0,200	0,200
R12	R10	CTI13	0,200	0,200	0,202	0,200	0,200
R9	R11	CTI14	0,200	0,200	0,227	0,200	0,206
R14	R12	CTI15	0,200	0,200	0,200	0,200	0,200
R21	R12	CTI16	0,200	0,200	0,384	0,200	0,200
R11	R13	CTI17	0,200	0,200	0,200	0,200	0,200
R21	R13	CTI18	0,361	0,295	0,585	0,355	0,353
R16	R14	CTI19	0,200	0,200	0,200	0,200	0,200
R19	R14	CTI20	0,200	0,275	0,561	0,236	0,218
R13	R15	CTI21	0,200	0,200	0,200	0,200	0,200
R19	R15	CTI22	0,264	0,249	0,613	0,201	0,217
R2	R16	CTI23	0,200	0,200	0,200	0,200	0,200
R17	R16	CTI24	0,382	0,354	1,077	0,376	0,363
R2	R18	CTI25	0,912	0,953	0,409	0,801	0,802

Çizelge 7.19. (devam) Test sistemi-4 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.


R15	R18	CTI26	1,005	1,073	0,485	0,976	0,906
R13	R20	CTI27	0,887	1,042	0,999	0,928	0,849
R16	R20	CTI28	1,024	1,000	1,097	0,846	0,858
R11	R22	CTI29	0,944	0,982	0,585	0,841	0,849
R14	R22	CTI30	0,952	1,071	0,692	0,953	0,904
R5	R24	CTI31	1,052	1,062	1,029	0,762	0,888
R8	R24	CTI32	0,859	0,976	0,956	1,011	0,861

Çizelge 7.20. Test sistemi-4 için birincil rölelerin çalışma süresi.

Röle	Çalışma süresi (s)	ASO	AEFA	SSA	MRFO	dFDB-MRFO
R1	$T_{pr,1}$	0,789	0,849	0,738	0,715	0,689
R2	$T_{pr,2}$	0,453	0,596	0,433	0,518	0,392
R3	$T_{pr,3}$	0,666	0,773	0,634	0,617	0,583
R4	$T_{pr,4}$	0,527	0,624	0,527	0,575	0,476
R5	$T_{pr,5}$	0,608	0,746	0,606	0,588	0,539
R6	$T_{pr,6}$	0,620	0,704	0,636	0,653	0,584
R7	$T_{pr,7}$	0,676	0,783	0,652	0,583	0,593
R8	$T_{pr,8}$	0,623	0,679	0,619	0,572	0,538
R9	$T_{pr,9}$	0,565	0,706	0,547	0,474	0,477
R10	$T_{pr,10}$	0,705	0,715	0,657	0,611	0,585
R11	$T_{pr,11}$	0,471	0,688	0,468	0,411	0,378
R12	$T_{pr,12}$	0,803	0,792	0,771	0,701	0,689
R13	$T_{pr,13}$	0,701	0,769	0,661	0,592	0,594
R14	$T_{pr,14}$	0,832	0,814	0,765	0,691	0,672
R15	$T_{pr,15}$	0,769	0,840	0,713	0,725	0,673
R16	$T_{pr,16}$	0,676	0,767	0,654	0,608	0,582
R17	$T_{pr,17}$	-	-	-	-	-
R18	$T_{pr,18}$	0,219	0,185	0,705	0,133	0,226
R19	$T_{pr,19}$	-	-	-	-	-
R20	$T_{pr,20}$	0,216	0,129	0,040	0,199	0,178
R21	$T_{pr,21}$	-	-	-	-	-
R22	$T_{pr,22}$	0,211	0,092	0,493	0,179	0,232
R23	$T_{pr,23}$	-	-	-	-	-
R24	$T_{pr,24}$	0,166	0,170	0,121	0,230	0,248

Test Sistemi-5: IEEE 30-Baralı Test Sistemi

Önerilen *d*FDB-MRFO algoritmasının büyük ölçekli güç sistemlerinde etkinliğini test etmek için diğer test sistemlerine göre daha karmaşık bir yapıya sahip olan IEEE 30-baralı test sistemi kullanılmıştır. Test sisteminin tek hat şeması ve röle konumları Şekil 7.7’de gösterilmiştir. IEEE 30-baralı test sisteminde 38 YAAR ve 62 birincil/yedek röle çifti vardır. *d*FDB-MRFO, ASO, AEFA, SSA ve MRFO algoritmaları röle parametrelerinin (TDS1-TDS38/PCS1-PCS38) optimizasyonuna uygulanmıştır. TDS ve PCS kontrol değişkeni limitleri sırasıyla [0,1-1,1] ve [1,5-6] olarak ayarlanmıştır. Her röle için akım trafosu dönüştürme oranı (CT_{rating}) 1000/5’e eşittir. CTI_{min} değeri 0,3 s olarak ayarlanmıştır. Röle çiftleri arasındaki birincil/yedek röle ilişkisi ve arıza akımları Çizelge 7.21’de özetlenmiştir [186].



Şekil 7.7. IEEE 30-baralı test sistemi.

Çizelge 7.21. Birincil/yedek röle çiftleri ve arıza akımı (I_f) (Test Sistemi-5).

Birincil röle	Yedek röle	$I_{f, pr}$ (A)	$I_{f, br}$ (A)	Birincil röle	Yedek röle	$I_{f, pr}$ (A)	$I_{f, br}$ (A)
R3	R1	4086,7	4086,7	R9	R20	7212,6	1103,5
R4	R2	5411,2	2138,8	R10	R20	7339,3	1095,8
R22	R2	4333	2147	R1	R21	7665,3	698,8
R4	R3	5411,2	3272,5	R9	R21	7212,6	721,2
R21	R3	5411,8	3243,6	R10	R21	7339,3	716,1
R5	R4	4960,8	3001,3	R20	R22	3481,5	3481,5
R18	R4	4719,4	3002,1	R21	R23	5411,8	2193,5
R6	R5	2416	2416	R22	R23	4333	2204,6
R7	R6	5669	1790,9	R18	R24	4719,4	1717,7
R8	R6	5607,7	1774,8	R23	R24	3689,7	1724,2
R27	R7	1472,3	1472,3	R24	R25	2695	2695
R26	R8	1026,8	1026,8	R1	R28	7665,3	1552
R12	R9	5034,9	5034,9	R2	R28	7985,7	1545,8
R11	R10	3457,1	3457,1	R10	R28	7339,3	1538
R13	R11	3727,3	2875	R1	R29	7665,3	1380,6
R14	R12	2906,5	2906,5	R2	R29	7985,7	1375,2
R15	R13	2660,5	2660,5	R9	R29	7212,6	1379
R16	R14	6185,6	1668,1	R29	R30	2518,9	2518,9
R17	R14	7492,9	1641,1	R28	R31	2036,8	2036,8
R19	R15	5445,2	1527,3	R30	R32	2998,8	2149
R35	R15	4222	1533,2	R31	R33	3263,6	3263,6
R36	R15	6420,2	1509,7	R32	R34	2930,4	2930,4
R19	R16	5445,2	1527,3	R17	R35	7492,9	1885,4
R34	R16	5796,6	3123,9	R33	R35	6456,2	1954,5
R36	R16	6420,2	3052,4	R16	R36	6185,6	490,9
R19	R17	5445,2	801,3	R33	R36	6456,2	500,6
R34	R17	5796,6	800,1	R5	R37	4960,8	1961
R35	R17	4222	794	R23	R37	3689,7	1968,5
R38	R18	3133,2	2292,2	R34	R38	5796,6	1886,8
R37	R19	3788,9	2940,9	R35	R38	4222	1896,7
R2	R20	7958,7	1053,9	R36	R38	6420,2	1867,7

Çizelge 7.22, Test sistemi-5 için optimizasyon algoritmaları kullanılarak elde edilen kontrol değişkeni ve amaç fonksiyonu değerlerini özetler. $dFDB$ -MRFO, MRFO, SSA, AEFA ve ASO optimizasyon algoritmaları ile elde edilen amaç fonksiyonu (OF) değerleri 25,94583 s, 26,45235 s, 32,94089 s, 48,72887 s ve 86,88706 s'dir. Simülasyon

sonuçlarından önerilen d FDB-MRFO algoritmasının IEEE 30-baralı test sisteminde amaç fonksiyonu minimizasyonu için en iyi değeri sunduğu görülmektedir. Daha açık bir ifadeyle, önerilen algoritmanın simülasyon sonucu, MRFO, SSA, AEFA ve ASO yöntemleri ile elde edilen simülasyon sonuçlarından sırasıyla %1,9148, %21,2351, %46,7547 ve %70,1384 daha düşüktür. Simülasyon sonuçları, önerilen algoritmanın büyük ölçekli güç sistemlerinde YAAR koordinasyon problemini çözmek için etkili bir yöntem olduğunu ortaya koymuştur.

Çizelge 7.22. Test sistemi-5 simülasyon sonuçları.

Röle	ASO		AEFA		SSA		MRFO		d FDB-MRFO	
	TDS	PCS	TDS	PCS	TDS	PCS	TDS	PCS	TDS	PCS
R1	0,6255	4,697	0,3971	3,115	0,3082	5,555	0,3669	2,430	0,3594	2,563
R2	0,7545	3,422	0,3333	4,446	0,5548	1,500	0,2040	3,018	0,2397	2,467
R3	0,6515	3,490	0,3725	2,360	0,5003	1,500	0,2529	2,846	0,2493	2,965
R4	0,6482	3,997	0,2409	5,505	0,3141	3,632	0,2123	3,329	0,2454	2,500
R5	0,7333	3,533	0,2876	3,715	0,4751	1,557	0,2059	2,220	0,1277	3,961
R6	0,5646	3,730	0,3922	1,799	0,2432	1,500	0,1630	1,505	0,1237	2,149
R7	0,6387	4,695	0,4001	3,926	0,1192	2,389	0,1184	2,406	0,1000	2,859
R8	0,6450	3,625	0,5083	2,377	0,1000	2,479	0,1039	2,224	0,1000	2,294
R9	0,7690	3,671	0,3962	3,711	0,3213	4,881	0,2671	5,008	0,3071	3,771
R10	0,6764	3,283	0,3321	4,470	0,3477	5,047	0,2693	4,232	0,2472	4,793
R11	0,5992	3,293	0,2667	4,719	0,5915	1,500	0,3057	2,217	0,2670	2,917
R12	0,6551	3,976	0,3538	2,964	0,2270	3,313	0,2694	2,796	0,2772	2,432
R13	0,4989	2,970	0,2865	4,430	0,1628	5,337	0,1928	3,716	0,2479	2,539
R14	0,5596	3,447	0,2032	4,676	0,1514	3,499	0,2275	2,186	0,2216	1,997
R15	0,4799	2,497	0,4830	1,500	0,2734	1,526	0,2214	1,731	0,1981	2,065
R16	0,6803	3,495	0,1000	5,835	0,3584	2,111	0,3313	2,328	0,2432	3,552
R17	0,4498	2,776	0,8579	2,683	0,1605	1,655	0,1417	1,757	0,1346	1,753
R18	0,6106	3,861	0,3026	5,179	0,4525	1,572	0,1588	4,635	0,1803	3,424
R19	0,6845	4,667	0,1345	5,949	0,3318	1,669	0,1855	4,158	0,2815	2,078
R20	0,5921	3,166	0,2487	2,231	0,2892	1,500	0,1972	1,816	0,2304	1,513
R21	0,1881	2,272	0,4077	1,652	0,1696	1,636	0,1553	1,500	0,1552	1,503
R22	0,6621	4,721	0,2767	3,202	0,3227	2,461	0,2764	2,106	0,2094	3,776
R23	0,7057	4,046	0,3730	1,500	0,2138	3,580	0,2057	3,066	0,1987	3,247
R24	0,5819	3,972	0,9537	3,931	0,3719	1,509	0,1131	4,188	0,1289	3,784
R25	0,8080	3,768	0,8396	5,189	0,6223	2,098	0,2423	2,414	0,1655	4,297
R26	0,4814	2,203	0,5395	2,144	0,1000	1,500	0,1000	1,500	0,1000	1,500
R27	0,4726	2,753	0,3177	2,022	0,1000	1,500	0,1000	1,500	0,1000	1,500

Çizelge 7.22. (devam) Test sistemi-5 simülasyon sonuçları.

R28	0,4650	3,059	0,3021	1,624	0,1722	3,471	0,1441	3,385	0,1846	2,658
R29	0,3024	3,525	0,1000	4,300	0,2212	2,382	0,1628	2,751	0,2129	2,084
R30	0,6641	3,478	0,2616	1,582	0,1389	5,691	0,2569	2,292	0,2215	3,190
R31	0,5097	3,169	0,1000	6,000	0,3846	1,583	0,2872	1,974	0,1805	3,764
R32	0,4975	3,939	0,2539	1,899	0,3726	1,500	0,2458	2,733	0,2525	2,770
R33	0,5173	3,853	0,1000	4,032	0,3841	2,586	0,3565	2,240	0,2852	2,957
R34	0,7011	2,838	0,1348	6,000	0,2707	3,922	0,2872	3,223	0,2195	4,729
R35	0,6693	3,607	0,4749	3,248	0,2806	2,300	0,2059	3,013	0,1793	3,213
R36	0,3322	1,652	0,1000	6,000	0,1000	1,501	0,1000	1,500	0,1000	1,500
R37	0,4740	4,235	0,2433	2,665	0,1318	5,251	0,2014	2,739	0,1803	3,124
R38	0,4530	3,853	0,4910	3,706	0,3418	1,502	0,2964	1,712	0,1537	3,680
OF(s)	86,88706		48,72887		32,94089		26,45235		25,94583	
MOF	36178,6895		942123230,2518		2470,8590		1553,2687		1492,0680	

Optimizasyon sonunda elde edilen röle parametreleri kullanılarak hesaplanan CTI değerleri Çizelge 7.23'te verilmiştir. İlgili çizelgedeki nümerik değerler incelendiğinde AEFA yönteminin $CTI \geq CTI_{min}$ kısıtını ihlal ettiği gözlemlenmiştir. Çizelge 7.24 birincil rölelerin (R1-R38) çalışma süreleri hakkında detaylı bilgi sunar. ASO, AEFA ve SSA algoritmaları ile elde edilen röle çalışma sürelerinin kabul edilebilir (0,1-1 s) sınırlar içinde olmadığı gözlemlenmiştir. ASO, AEFA ve SSA algoritmaları büyük-ölçekli güç sisteminde YAAR koordinasyon problemini çözmek için yetersizdir. Bu çıkarım ilgili algoritmaların kısıtları ihlal etmesine dayandırılmıştır.

Çizelge 7.23. Test sistemi-5 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.

Röle		CTI	ASO	AEFA	SSA	MRFO	$dFDB$ - MRFO	Röle		CTI	ASO	AEFA	SSA	MRFO	$dFDB$ - MRFO
Yedek	Birincil							Yedek	Birincil						
R1	R3	CTI1	0,399	0,268	0,329	0,300	0.300	R20	R9	CTI32	5,117	0,713	0,432	0,300	0,300
R2	R4	CTI2	2,254	1,593	0,866	0,419	0.423	R20	R10	CTI33	5,600	0,839	0,340	0,382	0,404
R2	R22	CTI3	1,571	1,630	0,919	0,300	0.300	R21	R1	CTI34	1,003	2,702	0,457	0,369	0,372
R3	R4	CTI4	0,579	0,278	0,358	0,300	0.300	R21	R9	CTI35	0,534	2,436	0,388	0,300	0,300
R3	R21	CTI5	2,405	0,334	1,025	0,634	0.644	R21	R10	CTI36	0,966	2,581	0,301	0,384	0,407
R4	R5	CTI6	0,802	0,624	0,359	0,389	0.462	R22	R20	CTI37	1,115	0,295	0,327	0,300	0,300
R4	R18	CTI7	1,066	0,289	0,390	0,300	0.300	R23	R21	CTI38	4,386	0,294	0,911	0,750	0,763
R5	R6	CTI8	0,800	0,273	0,791	0,300	0.300	R23	R22	CTI39	1,884	0,289	0,300	0,300	0,300
R6	R7	CTI9	2,031	0,294	0,607	0,300	0.300	R24	R18	CTI40	2,922	7,101	0,334	0,421	0,450
R6	R8	CTI10	2,358	0,287	0,659	0,351	0.329	R24	R23	CTI41	2,008	7,421	0,570	0,300	0,300
R7	R27	CTI11	6,563	2,728	0,300	0,300	0.300	R25	R24	CTI42	1,089	0,747	1,136	0,300	0,300
R8	R26	CTI12	8,982	0,298	0,393	0,300	0.300	R28	R1	CTI43	1,422	0,251	0,390	0,300	0,300
R9	R12	CTI13	0,303	0,288	0,581	0,300	0.300	R28	R2	CTI44	1,382	0,295	0,348	0,672	0,623
R10	R11	CTI14	0,315	0,276	0,300	0,300	0.300	R28	R10	CTI45	1,584	0,258	0,300	0,365	0,382
R11	R13	CTI15	0,938	0,282	0,891	0,300	0.300	R29	R1	CTI46	1,086	0,392	0,344	0,321	0,324
R12	R14	CTI16	0,809	0,293	0,325	0,300	0.300	R29	R2	CTI47	1,049	0,444	0,300	0,693	0,647
R13	R15	CTI17	0,320	0,288	0,372	0,300	0.300	R29	R9	CTI48	0,831	0,283	0,339	0,300	0,300
R14	R16	CTI18	2,258	2,031	0,300	0,300	0.300	R30	R29	CTI49	1,925	0,220	0,300	0,300	0,300
R14	R17	CTI19	3,299	0,297	0,884	0,873	0.783	R31	R28	CTI50	0,347	0,185	0,312	0,300	0,300

Çizelge 7.23. (devam) Test sistemi-5 için CTI ($T_{br} - T_{pr}$) değerlerinin karşılaştırılması.

R15	R19	CTI20	0,303	1,434	0,361	0,350	0,300	R32	R30	CTI51	0,300	0,212	0,305	0,300	0,300
R15	R35	CTI21	0,356	0,296	0,300	0,300	0,389	R33	R31	CTI52	0,331	-0,199	0,306	0,300	0,300
R15	R36	CTI22	2,243	1,648	0,957	0,815	0,834	R34	R32	CTI53	0,325	0,195	0,300	0,300	0,300
R16	R19	CTI23	0,461	0,093	0,419	0,516	0,384	R35	R17	CTI54	3,652	0,868	1,024	0,935	0,854
R16	R34	CTI24	1,070	0,114	0,300	0,300	0,300	R35	R33	CTI55	2,987	2,655	0,300	0,300	0,300
R16	R36	CTI25	2,423	0,311	1,021	0,988	0,929	R36	R16	CTI56	3,710	-1,203	0,507	0,540	0,644
R17	R19	CTI26	3,959	5,443	0,344	0,494	0,665	R36	R33	CTI57	3,903	-1,137	0,324	0,449	0,544
R17	R34	CTI27	6,521	14,378	0,333	0,300	0,300	R37	R5	CTI58	1,337	0,250	0,300	0,508	0,612
R17	R35	CTI28	6,163	13,519	0,406	0,480	0,488	R37	R23	CTI59	0,695	0,272	0,561	0,300	0,300
R18	R38	CTI29	1,656	0,295	0,566	0,300	0,300	R38	R34	CTI60	1,446	3,054	0,350	0,300	0,300
R19	R37	CTI30	1,945	0,179	0,335	0,300	0,300	R38	R35	CTI61	0,883	1,880	0,408	0,465	0,471
R20	R2	CTI31	5,995	0,969	0,446	0,743	0,690	R38	R36	CTI62	2,789	3,274	1,064	0,981	0,923

Çizelge 7.24. Test sistemi-5 için birincil rölelerin çalışma süresi.

Röle	Çalışma süresi (s)	ASO	AEFA	SSA	MRFO	dFDB-MRFO	Röle	Çalışma süresi (s)	ASO	AEFA	SSA	MRFO	dFDB-MRFO
R1	$T_{pr,1}$	2,042	1,080	1,096	0,906	0,905	R20	$T_{pr,20}$	2,390	0,830	0,806	0,597	0,644
R2	$T_{pr,2}$	2,097	1,040	1,145	0,539	0,586	R21	$T_{pr,21}$	0,518	0,993	0,411	0,365	0,365
R3	$T_{pr,3}$	2,535	1,182	1,306	0,881	0,887	R22	$T_{pr,22}$	2,996	0,994	1,016	0,811	0,824
R4	$T_{pr,4}$	2,328	1,042	1,073	0,695	0,704	R23	$T_{pr,23}$	3,207	1,015	0,898	0,788	0,787
R5	$T_{pr,5}$	2,583	1,040	1,168	0,583	0,479	R24	$T_{pr,24}$	3,293	5,353	1,163	0,669	0,702
R6	$T_{pr,6}$	3,324	1,415	0,799	0,536	0,493	R25	$T_{pr,25}$	-	-	-	-	-
R7	$T_{pr,7}$	2,442	1,389	0,329	0,328	0,298	R26	$T_{pr,26}$	3,949	4,287	0,562	0,562	0,562
R8	$T_{pr,8}$	2,162	1,406	0,282	0,280	0,273	R27	$T_{pr,27}$	3,331	1,699	0,433	0,433	0,433
R9	$T_{pr,9}$	2,302	1,192	1,102	0,928	0,931	R28	$T_{pr,28}$	2,674	1,131	1,107	0,906	0,957
R10	$T_{pr,10}$	1,914	1,081	1,203	0,854	0,833	R29	$T_{pr,29}$	1,641	0,644	0,914	0,738	0,814
R11	$T_{pr,11}$	2,488	1,420	1,653	1,021	1,032	R30	$T_{pr,30}$	3,135	0,796	0,994	0,940	0,986
R12	$T_{pr,12}$	2,439	1,133	0,768	0,839	0,811	R31	$T_{pr,31}$	2,141	0,693	1,127	0,932	0,849
R13	$T_{pr,13}$	1,867	1,376	0,900	0,823	0,853	R32	$T_{pr,32}$	2,616	0,852	1,119	1,007	1,044
R14	$T_{pr,14}$	2,684	1,240	0,734	0,825	0,766	R33	$T_{pr,33}$	1,668	0,330	1,039	0,911	0,816
R15	$T_{pr,15}$	1,975	1,516	0,865	0,745	0,731	R34	$T_{pr,34}$	2,063	0,590	0,928	0,895	0,832
R16	$T_{pr,16}$	2,137	0,413	0,910	0,874	0,770	R35	$T_{pr,35}$	2,605	1,743	0,867	0,726	0,654
R17	$T_{pr,17}$	1,179	2,218	0,349	0,314	0,298	R36	$T_{pr,36}$	0,761	0,410	0,222	0,222	0,222
R18	$T_{pr,18}$	2,319	1,375	1,138	0,672	0,641	R37	$T_{pr,37}$	2,182	0,852	0,710	0,715	0,688
R19	$T_{pr,19}$	2,669	0,610	0,809	0,678	0,746	R38	$T_{pr,38}$	2,229	2,350	0,997	0,917	0,732

Özetle, IEEE 3-baralı, IEEE 4-baralı, Standart 8-baralı, Standart 9-baralı ve IEEE 30-baralı test sistemlerinde gerçekleştirilen simülasyon çalışmaları önerilen *d*FDB-MRFO yönteminin YAAR koordinasyon problemine optimum çözümler üretmede ASO, AEFA, SSA ve geleneksel MRFO algoritmalarına kıyasla daha başarılı olduğunu göstermiştir. Özellikle 8-baralı, 9-baralı ve IEEE 30-baralı test sistemleri için elde edilen amaç fonksiyonu değerleri, önerilen algoritmanın performansının ayırt edilmesinde önemli gösterge olmuştur. Öte yandan AEFA ve SSA algoritmalarının 9-baralı test sisteminde röle çalışma süresi kısıtını ihlal ettiği gözlemlenmiştir. IEEE 30-baralı test sisteminde ASO, AEFA ve SSA algoritmaları kısıtların ihlali nedeniyle YAAR koordinasyon problemine optimal çözümler üretmede başarısız olmuştur. Tüm test durumları için YAAR koordinasyon problemini başarıyla (kısıt ihlali olmadan) çözebilen sadece iki algoritma vardır: MRFO ve *d*FDB-MRFO. Bu iki algoritma arasındaki karşılaştırma MRFO algoritmasının erken yakınsama problemi nedeniyle optimum çözümler üretmede yetersiz olduğunu göstermiştir. Erken yakınsama probleminin temel nedeni, baz algoritmanın zayıf keşif yeteneği ile açıklanabilir. Öte yandan, *d*FDB-MRFO algoritması güçlü keşif ve dengeli arama yetenekleri ile optimal değere yakınsama konusunda rakibine ezici bir üstünlük sağlamıştır.

7.3. İSTATİSTİKSEL ANALİZ VE YAKINSAMA ANALİZİ

Optimizasyon algoritmalarının 30 bağımsız çalışması sonucu elde edilen minimum, ortalama, maksimum ve standart sapma değerleri Çizelge 7.25’te verilmiştir. Beş farklı test sisteminde YAAR koordinasyon probleminin çözümü için algoritmaların arama performansının anlaşılmasını ve yorumlanmasını kolaylaştırmak için 30 denemeden elde edilen veriler kullanılarak box-plot grafikleri çizdirilmiştir. Şekil 7.8, minimum, maksimum ve ortalama/standart sapma marjlarını içeren box-plot grafiklerini gösterir. Önerilen *d*FDB-MRFO ile rekabetçi optimizasyon algoritmaları arasında ikili karşılaştırma yapmak için Wilcoxon istatistiksel analiz yöntemi kullanılmıştır. Wilcoxon işaretli sıra testi sonuçları Çizelge 7.26’da sunulmuştur.

Wilcoxon işaretli sıra testini uygulamak için “X” ve “Y” olarak adlandırılan iki algoritma seçilmiştir. Wilcoxon işaretli sıra testinin uygulama prosedürü aşağıdaki gibidir [134]:

- Seçilen her iki algoritmanın her bir simülasyon çalışması için 30 deneme boyunca elde ettikleri fitness değerlerini topla.


- R+ hesapla: ‘X’ algoritmasının ‘Y’ algoritmasından daha iyi performans gösterdiği çalıştırmalar için ilgili çalışma sayısının toplamıdır.
- R- hesapla: ‘Y’ algoritmasının ‘X’ algoritmasından daha iyi performans gösterdiği çalıştırmalar için ilgili çalışma sayısının toplamıdır.
- İstatistiksel hipotez testine dayalı sonuçların önemini belirtmek için p değeri hesaplanır.

Çizelge 7.25. 30 deneme için elde edilen minimum, ortalama, maksimum ve standart sapma değerleri.



Algoritma	Test Sistemi-1	Test Sistemi-2	Test Sistemi-3	Test Sistemi-4	Test Sistemi-5
ASO					
Minimum	53,25686	214952,84	230,1577	324,9641	36178,689
Ortalama	64,23509	214961,40	284,7799	380,4825	2230946
Maksimum	85,69570	214971,90	351,3214	424,1936	45393906
Standart Sapma	7,47791	5,26935	30,7673	23,05435	8198807
AEFA					
Minimum	46,88991	214949,22	296,4023	390,2518	9.42E+08
Ortalama	47,25651	214949,50	379,3708	445,8023	2.93E+09
Maksimum	47,82490	214949,90	436,4400	486,5847	6.26E+09
Standart Sapma	0,19723	0,17931	34,5272	22,7017	1.17E+09
SSA					
Minimum	46,64826	214949,38	257,9658	339,0981	2470,859
Ortalama	47,96288	214950	333,3128	454,198	4650,662
Maksimum	50,434	214950,7	387,3683	563,1821	7553,426
Standart Sapma	0,86854	0,36621	35,50345	54,75835	1392,751
MRFO					
Minimum	46,00785	214948,61	242,9288	274,1420	1553,268
Ortalama	46,01146	214948,60	316,4743	346,8121	1994,982
Maksimum	46,04740	214948,64	471,2668	471,2668	2296,825
Standart sapma	0,00890	0,00082	36,9091	48,65744	191,6367
dFDB-MRFO					
Minimum	46,00785	214948,61	151,1337	251,0414	1492,068
Ortalama	46,00829	214948,60	212,9988	341,6082	1896,711
Maksimum	46,01340	214948,64	293,0195	428,0358	2189,408
Standart Sapma	0,00139	0,00082	34,75019	42,02937	154,5468

Çizelge 7.26. Wilcoxon ikili işaret testi sonuçları.



Test Sistemi	ASO vs dFDB-MRFO			AEFA vs dFDB-MRFO			SSA vs dFDB-MRFO			MRFO vs dFDB-MRFO		
	R+	R-	p-value	R+	R-	p-value	R+	R-	p-value	R+	R-	p-value
Test Sistemi-1	0	465	2×10^{-6}	0	465	2×10^{-6}	0	465	2×10^{-6}	40	113	$83,843 \times 10^{-3}$
Test Sistemi-2	0	465	2×10^{-6}	0	465	2×10^{-6}	0	465	2×10^{-6}	14	217	$41,6 \times 10^{-5}$
Test Sistemi-3	4	461	3×10^{-6}	0	465	2×10^{-6}	1	464	2×10^{-6}	9	456	4×10^{-6}
Test Sistemi-4	72	393	9.63×10^{-4}	0	465	2×10^{-6}	4	461	3×10^{-6}	217	248	0,749871
Test Sistemi-5	0	465	2×10^{-6}	0	465	2×10^{-6}	0	465	2×10^{-6}	134	331	$4,2767 \times 10^{-2}$



Şekil 7.8. Box-plot grafikleri (a) Test Sistemi-1, (b) Test Sistemi-2, (c) Test Sistemi-3, (d) Test Sistemi-4, (e) Test Sistemi-5.



Şekil 7.8. (devam) Box-plot grafikleri (a) Test Sistemi-1, (b) Test Sistemi-2, (c) Test Sistemi-3, (d) Test Sistemi-4, (e) Test Sistemi-5.



Şekil 7.8. (devam) Box-plot grafikleri (a) Test Sistemi-1, (b) Test Sistemi-2, (c) Test Sistemi-3, (d) Test Sistemi-4, (e) Test Sistemi-5.

Test Sistemi-1: Çizelge 7.25’de verilen 30 deneme sonuçlarından Test Sistemi-1 için ASO dışındaki algoritmaların benzer sonuçlar elde ettiği anlaşılmaktadır. ASO algoritması yerel çözüm tuzaklarına takılmış ve global optimuma yakınsamada başarısız olmuştur. Ortalama ve standart sapma değerlerine göre yapılan kıyaslama, önerilen *dFDB-MRFO* yönteminin rakiplerine kıyasla daha kararlı ve sağlam bir arama performansı sergilediğini ortaya koymuştur. Wilcoxon işaretli sıra testi sonuçları (Çizelge 7.26) mevcut test modeli için önerilen yöntemin ASO, AEFA, SSA ve MRFO yöntemlerine kıyasla küresel optimuma yakınsamada rakiplerinden daha iyi olduğunu doğrulamıştır. Şekil 7.8 (a)’da verilen box-plot grafiklerinden, ASO dışındaki optimizasyon algoritmaları için minimum, maksimum ve ortalama/standart sapma marjlarının makul olduğu görülmektedir.


Test Sistemi-2: Çizelge 7.25’de verilen ortalama ve standart sapma değerleri Test Sistemi-2 için *dFDB-MRFO* ve MRFO algoritmalarının istikrarlı bir şekilde global optimum değere yakınsayabildiğini göstermiştir. Wilcoxon ikili karşılaştırma analizi sonuçları önerilen algoritmanın rakiplerine kıyasla daha iyi bir arama performansı sergilediğini ortaya koymuştur. Şekil 7.8 (b)’de gösterilen box-plot grafiklerinden ASO yönteminin keşif-sömürü dengesini sağlamada yetersiz olduğu gözlemlenmiştir.

Test Sistemi-3: Algoritmaların 30 bağımsız çalıştırılması sonucu elde edilen minimum ve ortalama değer indeksleri, *dFDB-MRFO* yönteminin Test Sistemi-3 için rakiplerinden daha kararlı ve sağlam bir arama performansı sergilediğini göstermiştir. Çizelge 7.26’da verilen Wilcoxon ikili karşılaştırma sonuçlarından, önerilen algoritmanın 30 deneme boyunca rakiplerinden daha iyi çözümler elde ettiği gözlemlenmiştir. Test sistemi-3 için verilen box-plot grafikleri (Şekil 7.8-c) *dFDB-MRFO* yönteminin minimum, maksimum ve ortalama/standart sapma marjlarının makul olduğunu göstermektedir.


Test Sistemi-4: Mevcut test sistemi için 30 deneme sonucu elde edilen minimum, ortalama, maksimum ve standart sapma indeksleri önerilen *dFDB-MRFO* yönteminin tüm indeksler için en iyi değeri sunan tek öncü olduğunu göstermiştir. Wilcoxon ikili karşılaştırma sonuçları (Çizelge 7.26), önerilen algoritmanın tüm kıyaslamalarda rakiplerine üstünlük kurduğunu göstermiştir. Şekil 7.8 (d)’de verilen box-plot grafiklerinden, önerilen yöntemin rakiplerine kıyasla daha kararlı ve sağlam bir arama performansı sergilediği anlaşılmaktadır.

Test Sistemi-5: IEEE 30-baralı test sisteminde ASO, AEFA ve SSA algoritmalarının erken yakınsama problemi sebebiyle YAAR koordinasyonu problemine optimum çözümler üretmede yetersiz olduğu gözlemlenmiştir. Erken yakınsama probleminin temel nedeni olarak bu algoritmaların zayıf keşif yeteneği gösterilebilir. Öte yandan, MRFO ve *d*FDB-MRFO yöntemleri kararlı ve sağlam arama performansı sergilemiştir. Çizelge 7.26'nın son satırında verilen Wilcoxon istatistiksel analiz sonuçları *d*FDB-MRFO yönteminin rakiplerine ezici üstünlük sağladığını ortaya koymuştur. Şekil 7.8 (e-f)'de verilen box-plot grafikleri, önerilen algoritmanın büyük ölçekli güç sistemlerinde yönlü aşırı akım röleleri koordinasyon problemini çözmek için kullanılabilecek güçlü bir algoritma olduğunu göstermiştir.

Şekil 7.9, Test Sistemi 1-5 için önerilen *d*FDB-MRFO ve rakip algoritmaların yakınsama eğrilerini göstermektedir. Test Sistemi-1 için algoritmaların yakınsama eğrileri detaylı olarak incelendiğinde, ASO dışındaki algoritmaların başarılı bir şekilde global optimuma yakınsadığı gözlemlenmiştir. *d*FDB-MRFO algoritması rakiplerine kıyasla daha hızlı yakınsamıştır. Şekil 7.9 (b)'de verilen yakınsama eğrilerinden Test Sistemi-2 için optimizasyon algoritmalarının benzer arama performansına sahip oldukları anlaşılmaktadır. Bu durum, arama uzayının sınırlı sayıda yerel çözüm tuzağına sahip olduğuna işaret etmektedir. Test Sistemi-3 için verilen yakınsama eğrileri (Şekil 7.9-c), *d*FDB-MRFO yönteminin yakınsama doğruluğu açısından rakiplerinden daha iyi olduğunu göstermektedir. Buna göre önerilen algoritma güçlü keşif ve dengeli arama yetenekleri ile başarılı bir arama performansı sergilemiştir. Öte yandan, MRFO algoritmasının erken yakınsadığı ve yakınsama doğruluğu açısından ASO ve *d*FDB-MRFO yöntemlerinin gerisinde olduğu gözlemlenmiştir. Test Sistemi-4 için algoritmaların yakınsama eğrileri (Şekil 7.9-d), önerilen *d*FDB-MRFO yönteminin sömürü-keşif dengesini güçlü bir şekilde sağlayabildiğini göstermektedir. Ayrıca önerilen yöntem, rekabetçi algoritmalara kıyasla global optimuma daha hızlı yakınsamıştır. Şekil 7.9 (e)'de verilen eğriler, Test Sistemi-5 için algoritmaların yakınsama performansını gösterir. Yakınsama eğrilerinden ASO, AEFA ve SSA algoritmalarının erken yakınsama problemi nedeniyle optimum değere ulaşmada başarısız oldukları görülmektedir. Öte yandan MRFO tabanlı algoritmaların başarılı bir yakınsama performansı sergiledikleri görülmektedir. Grafiğin dikey ekseninde verilen en iyi fitness değeri (MOF) performans kriterinden önerilen *d*FDB-MRFO yönteminin yakınsama doğruluğu açısından geleneksel MRFO algoritmasına kıyasla üstün olduğu anlaşılmaktadır.





(a)



(b)


Şekil 7.9. Optimizasyon algoritmalarının yakınsama eğrileri

a) Test Sistemi-1, b) Test Sistemi-2, c) Test Sistemi-3, d) Test Sistemi-4, e) Test Sistemi-5.



Şekil 7.9. (devam) Optimizasyon algoritmalarının yakınsama eğrileri

a) Test Sistemi-1, b) Test Sistemi-2, c) Test Sistemi-3, d) Test Sistemi-4, e) Test Sistemi-5.



Şekil 7.9. (devam) Optimizasyon algoritmalarının yakınsama eğrileri

a) Test Sistemi-1, b) Test Sistemi-2, c) Test Sistemi-3, d) Test Sistemi-4, e) Test Sistemi-5.

7.4. SONUÇLAR: YAAR KOORDİNASYON PROBLEMİ

- Tez çalışmasının orijinal katkılarından biri olarak geliştirilen *dFDB-MRFO* algoritması popüler gerçek-dünya mühendislik problemlerinden biri olan kısıtlı YAAR koordinasyonu probleminin optimizasyonuna uygulanmıştır.
- YAAR koordinasyon probleminin çözümü için önerilen algoritmanın performansı, IEEE 3-baralı, IEEE 4-baralı, Standart 8-baralı, Standart 9-baralı ve IEEE 30-baralı test sistemleri olmak üzere farklı karmaşıklığa sahip beş test sisteminde değerlendirilmiştir.
- Özellikle yüksek karmaşıklığa sahip Standart 8-baralı, Standart 9-baralı ve IEEE 30-baralı güç sistemlerinde gerçekleştirilen simülasyon çalışmalarından elde edilen bulgular *dFDB-MRFO* yönteminin arama performansı açısından ayırt edici olmuştur.

- 8-baralı, 9-baralı ve IEEE 30-baralı test sistemlerinde geleneksel MRFO'ya kıyasla d FDB-MRFO yöntemi ile birincil rölelerin toplam çalışma süresinin sırasıyla %20,5216, %4,3033 ve %1,9148 oranında azaltıldığı tespit edilmiştir.
- Simülasyon sonuçları, önerilen d FDB-MRFO algoritmasının YAAR koordinasyonu problemi için optimal çözümler elde etmede rakiplerine kıyasla daha başarılı olduğunu göstermiştir.



8. SONUÇLAR

Bu tez çalışması, modern güç sistemlerinin ekonomik ve güvenli işletimi için kritik öneme sahip kısıtlı optimizasyon problemlerini ve bu problemleri çözmek için önerilen hibrit meta-sezgisel algoritmaların uygulamalarını içermektedir.

Bu kapsamda ilk olarak rüzgar, güneş, hidro ve gelgit enerji kaynaklarını içeren hibrit alternatif akım-çok terminalli yüksek gerilim doğru akım elektrik şebekelerinde çok-amaçlı optimal güç akışı probleminin modellenmesi ve optimizasyonu gerçekleştirilmiştir. Bu tez kapsamı boyunca, yazar tarafından yapılan literatür taramasında hem çoklu yenilenebilir enerji kaynaklarını hem de gerilim kaynağı dönüştürücü tabanlı çok terminalli yüksek gerilim doğru akım iletim bağlantılarını eş zamanlı olarak içeren güç sistemlerinde optimal güç akışı problemini ele alan bir çalışmaya rastlanmamıştır. Mevcut çalışma bu anlamda literatüre yeni bir çözüm önerisi getirmiştir. Çalışmada, yenilenebilir enerji kaynaklarının belirsizliği ve stokastik doğası, olasılık yoğunluk fonksiyonları (Weibull, Lognormal ve Gumbel) ile modellenmiştir. Güneş ve hidro enerji ünitelerinin birleşimi aktif güç üretim birimi olarak tasarlanmıştır. Benzer şekilde rüzgâr ve gelgit enerji kaynaklarının birleşimi aktif güç üretim birimi olarak modellenmiştir. IEEE 30-baralı test sisteminde Bara 8, Bara 11 ve Bara 13'teki termal jeneratörler, rüzgâr, kombine güneş-hidro ve kombine rüzgâr-gelgit yenilenebilir enerji üniteleri ile değiştirilmiştir. Önerilen çok-amaçlı optimal güç akışı probleminde, toplam maliyet, valf noktası etkisi ile toplam maliyet, emisyonlar ve karbon vergisi ile toplam maliyet, gerilim saptması ve aktif güç kayıpları amaç fonksiyonlarının ikili ve üçlü konfigürasyonlarının eş zamanlı olarak optimize edilmiştir. ÇAOGA problemini çözmek için MOGOA algoritması uygulanmıştır. MOGOA yönteminin performansı modifiye IEEE 30-baralı test sisteminde farklı çalışma koşulları altında gerçekleştirilen simülasyon çalışmaları ile doğrulanmıştır. MOGOA yöntemi ile elde edilen simülasyon sonuçları MSSA, MODA, MOALO ve MO_Ring_PSO_SCD yöntemlerinin sonuçları ile karşılaştırılmıştır. Buna göre simülasyon çalışmalarından elde edilen bulgular kısaca aşağıda verilmiştir.

- Toplam üretim maliyeti ve gerilim saptması amaç fonksiyonlarının eş zamanlı optimizasyonunda en iyi simülasyon sonucu (790,8614 \$/h / 0,022467 p.u.) MOGOA yöntemi ile elde edilmiştir. MOGOA algoritması ile toplam üretim

maliyetinde MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmalarına kıyasla %4,9679, %6,0004, %4,0875 ve %3,0016 oranında düşüş elde edilmiştir. Gerilim saptması amaç fonksiyonu açısından MOGOA ile elde edilen değer rakiplerine kıyasla sırasıyla 0,0217 p.u., 0,0449 p.u., 0,0168 p.u. ve 0,0231 p.u. daha iyidir.

- Toplam üretim maliyeti ve emisyon-karbon vergisi ile toplam üretim maliyeti amaç fonksiyonlarının eş zamanlı minimizasyonunda MOGOA ile elde edilen simülasyon sonucu (793,2147 \$/h / 828,6416 \$/h) rekabetçi optimizasyon algoritmalarının simülasyon sonuçlarına kıyasla %2,7835 / %3,6189, %2,7999 / %2,0248, %1,2706 / %0,6131 ve %0,6293 / %0,7582 oranında daha düşüktür.
- MOGOA ve rekabetçi optimizasyon algoritmaları kullanılarak toplam üretim maliyeti ve aktif güç kayıpları amaç fonksiyonları eş zamanlı olarak optimize edilmiştir. Buna göre, MOGOA algoritması ile elde edilen toplam üretim maliyeti değeri MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmalarının rapor edilen en iyi sonuçlarına kıyasla 30,1971 \$/h, 13,4401 \$/h, 11,0379 \$/h ve 19,7191 \$/h daha düşüktür. MOGOA yöntemi ile aktif güç kayıpları değeri rakiplerine kıyasla %27,0501, %3,1968, %4,7852 ve %14,1943 oranında azaltılmıştır.
- Valf noktası etkisi ile toplam maliyet, gerilim saptması ve aktif güç kayıpları amaç fonksiyonlarının eş zamanlı minimizasyonu gerçekleştirilmiştir. Buna göre MOGOA yöntemi ile elde edilen valf nokta etkisi ile toplam maliyet ve aktif güç kayıpları (828,0918 \$/h / 13,3912 MW) MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmalarının simülasyon sonuçlarına kıyasla 28,0929 \$/h / 6,4694 MW, 30,1121 \$/h / 2,9412 MW, 2,5287 \$/h / 0,3340 MW ve 3,6469 \$/h / 2,5735 MW daha düşüktür. Ayrıca gerilim saptması amaç fonksiyonu optimizasyonunda en iyi sonucu (0,018828 p.u.) MSSA algoritması elde etmiştir.
- Valf noktası ile toplam üretim maliyeti, emisyon-karbon vergisi ile toplam üretim maliyeti ve gerilim saptması amaç fonksiyonlarının eş zamanlı optimizasyonunda MOGOA ve MODA algoritmaları ile amaç fonksiyonu değerlerinde önemli iyileşmeler elde edilmiştir. Valf nokta etkisi ve emisyon-karbon vergisini dikkate alan toplam üretim maliyeti değerlerinde, MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmalarının rapor edilen en iyi sonuçlarına kıyasla MOGOA yöntemi ile %3,301, %3,724, %3,244 ve %1,5812 oranında bir iyileşme

elde edilmiştir. Ayrıca MODA algoritması en iyi gerilim sapması (0,0106 p.u.) değerini sunmuştur.

- Valf nokta etkisi ile toplam üretim maliyeti, emisyon ve karbon vergisi ile toplam üretim maliyeti ve aktif güç kayıpları amaç fonksiyonlarının eş zamanlı optimizasyonunda MOGOA algoritması ile elde edilen simülasyon sonucu 828,6813 \$/h / 831,5754 \$/h / 13,8972 MW, MSSA, MODA, MOALO ve MO_Ring_PSO_SCD algoritmalarının rapor edilen en iyi sonuçlarına kıyasla sırasıyla %2,4508 / %2,4653 / 2,9013 MW, %2,2421 / %2,3400 / 2,5667 MW, %1,8409 / %1,8294 / 0,4530 MW, ve %0,7001 / %1,0228 / 3,0521 MW daha düşüktür.
- Analiz sonuçlarından, MOGOA yönteminin çok amaçlı optimal güç akışı probleminin çözümünde rekabetçi bir performans sergilediği ve rakiplerine kıyasla daha iyi çözümler sunduğu gözlemlenmiştir.

Tez çalışmasında AGSK algoritmasının arama performansını iyileştirmek için FDB seçim yöntemi uygulanmıştır. Bu kapsamda FDB seçim yönteminin AGSK algoritmasının arama performansı üzerindeki etkisinin tartışılabilmesi için kapsamlı bir deneysel çalışma ortaya konulmuştur. Ayrıca, deneysel çalışmalarda AGSK algoritmasının keşif ve sömürü yetenekleri detaylı olarak incelenmiştir. Bu amaçla CEC 2017 ve CEC 2020 test takımlarında yer alan dört farklı problem tipinin (tek-modlu, çok-modlu, hibrit ve kompozisyon) çözümüne odaklanılmıştır. Deneysel çalışma sonuçlarından AGSK algoritmasının erken yakınsama problemleri yaşadığı tespit edilmiştir. Bu durum, çok sayıda yerel çözüm içeren çok-modlu, hibrit ve kompozisyon test fonksiyonlarıyla desteklenmiştir. Tespit edilen erken yakınsama sorununun ana nedeninin AGSK algoritmasının zayıf keşif yeteneğinden kaynaklandığı düşünülmektedir. Hibrit ve kompozisyon tip problemlerin arama uzaylarında başarılı bir arama performansı sergilemek için, sömürü ve keşif yeteneklerinin dengeli bir şekilde yürütülmesi gerektiği fark edilmiştir. Deneysel çalışmalardan elde edilen veriler, AGSK algoritmasının bu dengeyi kurmada yetersiz olduğunu göstermiştir. Böylelikle, AGSK algoritması için performansın kötüleşmesine sebep olan eksik yönler de tespit edilmiştir. Bu tespiti dayalı olarak AGSK algoritmasında sömürü ve keşif görevlerini gerçekleştiren operatörlerin güçlendirilmesi gerektiği kararlaştırılmıştır. AGSK algoritmasındaki sömürü ve keşif işlemi, genç ve kıdemli bilgi-edinme paylaşma aşamalarında gerçekleştirilmektedir. Bu nedenle, AGSK algoritmasında bu iki aşamaya FDB yöntemi

uygulanmıştır. Deneysel çalışmalar sonucunda FDB yönteminin AGSK algoritmasının handikaplarını büyük ölçüde ortadan kaldırdığı görülmüştür. FDBAGSK algoritması tek-modlu problemlerde daha düşük hata değerlerine yakınsamıştır. Benzer şekilde, önerilen algoritma çok-modlu tip problemlerde daha güçlü bir çeşitlilik yeteneği sergilemiştir. Bu durum, erken yakınsama probleminin elimine edilmesinde oldukça etkin bir rol oynamıştır. Önerilen FDBAGSK algoritması, hibrit ve kompozisyon tip test fonksiyonların optimizasyonunda geleneksel AGSK yöntemine kıyasla daha başarılı arama performansı sergilemiştir.

Hibrit FDBAGSK algoritmasının kısıtlı gerçek dünya problemleri üzerindeki performansını test etmek için kapsamlı ve bağımsız bir çalışma yürütülmüştür. Bu bağlamda, literatürde optimal çözümü araştırılan popüler gerçek dünya mühendislik problemlerinden biri olan optimal reaktif güç akışı optimizasyonu çalışılmıştır. Tez çalışması kapsamında geliştirilen FDBAGSK yöntemi dağıtılmış üretim ve iki terminalli yüksek gerilim doğru akım iletim hattı ile modifiye edilmiş büyük ölçekli (IEEE 30 ve IEEE 57-baralı) güç sistemlerinde optimal reaktif güç akışı probleminin çözümüne uygulanmıştır. Önerilen algoritmanın etkinliği aktif güç kayıpları (P_{loss}), gerilim saptması (VD) ve gerilim kararlılığı iyileştirilmesi ($L-index$) amaç fonksiyonları minimizasyonunu içeren çeşitli simülasyon çalışmaları ile tartışılmıştır. Simülasyon çalışmalarından elde edilen bulgular kısaca aşağıda listelenmiştir:

- IEEE 30-baralı test sisteminde gerçekleştirilen simülasyon çalışmalarında baz algoritmaya kıyasla FDBAGSK yöntemi ile aktif güç kayıplarında sırasıyla %0,8379, %0,2248, %0,2124, %0,8252 ve %0,0573 oranında düşüş elde edilmiştir. Ayrıca voltaj saptması ve gerilim kararlılığı iyileştirilmesi amaç fonksiyonları açısından sırasıyla %0,0584 ve %2,5761'lik iyileşme gözlemlenmiştir.
- Büyük-ölçekli IEEE 57-baralı güç sisteminde gerçekleştirilen simülasyon çalışmalarında baz algoritmaya kıyasla FDBAGSK yöntemi ile aktif güç kayıplarında sırasıyla %9,7898, %7,1020 ve %8,7070 oranında azalma gözlemlenmiştir. Gerilim saptması ve gerilim kararlılığı indeksi minimizasyonunda ise sırasıyla %21,15 ve %3,3587 oranında iyileşme sağlanmıştır. Simülasyon sonuçlarından elde edilen bulgular, geliştirilen algoritmanın büyük ölçekli güç sistemlerinde optimal reaktif güç akışı probleminin farklı konfigürasyonlarını verimli bir şekilde çözebildiğini

göstermiştir.

- Aktif güç kayıplarının iki terminalli yüksek gerilim doğru akım iletim hattı bağlantı noktalarına göre değişimlerin oldukça küçük seviyelerde olduğu gözlemlenirken, dağıtılmış üretim ünitelerinin güç sistemine optimal yerleşimi ile güç kayıplarının önemli ölçüde azaltıldığı tespit edilmiştir.

Popülasyon tabanlı LFD algoritmasının farklı karmaşıklığa sahip kıyaslama problemlerindeki (CEC2017 ve CEC 2020) analizi algoritmanın erken yakınsadığını ve özellikle çok-modlu tip problemlerin arama uzaylarındaki yerel çözüm tuzaklarına takıldığını göstermiştir. Bu durum, LFD algoritmasının keşif ve dengeli arama yeteneklerinin yetersizliğine işaret etmiştir. Bu iki yeteneği güçlendirmek ve arama performansını iyileştirmek için LFD'nin tasarımı doğa ile uyumlu olmalıdır. LFD'de göç sürecinin tasarımı incelendiğinde, sürüyü yönlendiren iki ajandan birinin seçim sürecinin doğanın işleyişine uygun tasarlanmadığı fark edilmiştir. Bu uyumsuzluğu ortadan kaldırmak ve algoritmanın doğayı taklit etme yeteneğini geliştirmek için LFD'de rehber seçim süreci yeniden tasarlanmıştır. Bu süreçte, arama sürecine yön veren ajanlardan biri geleneksel LFD'de olduğu gibi sürünün lideri iken, ikinci arama ajanı FDB yöntemi ile seçilen göç yolunu takip etmede sürünün liderine en fazla katkı sağlama potansiyeli olan arama ajanıdır. Bu bağlamda, önerilen hibrit FDBLFD algoritmasının performansını test etmek ve doğrulamak için kapsamlı bir deneysel çalışma gerçekleştirilmiştir. İlk deneysel çalışmada FDB tabanlı algoritmaların üç farklı versiyonunun performansı incelenmiştir. Bu amaçla geleneksel LFD algoritması ile FDBLFD versiyonları (Versiyon-1, Versiyon-2, Versiyon-3) arasında istatistiksel karşılaştırmalar yapılmıştır. Deneysel çalışmalardan elde edilen veriler Friedman yöntemi ile analiz edilmiş ve en etkili FDB tabanlı algoritmanın Versiyon-1 olduğu saptanmıştır. Versiyon-1, tez çalışmasında FDBLFD olarak isimlendirilmiştir. İkinci deneysel çalışmada ise önerilen FDBLFD algoritması ile literatürdeki güçlü 11 MSA algoritmasının performansları karşılaştırılmıştır. Friedman istatistiksel test sonuçlarına göre, önerilen FDBLFD algoritması ilk sırada yer alırken, geleneksel LFD algoritması on birinci sırada yer almıştır. Bu sonuç, LFD algoritmasının tasarımındaki değişikliklerin başarılı olduğunun bir göstergesi olarak kabul edilmiştir.

Tez çalışması kapsamında geliştirilen FDBLFD algoritması otomatik gerilim regülatörü sistemi için PID, PIDF, FOPID ve PIDD² kontrolcü kazanç parametrelerinin optimizasyonuna uygulanmıştır. Ayrıca, FDBLFD ve rekabetçi optimizasyon algoritmaları arasındaki kıyaslamada Friedman analizine göre en iyi performans gösteren

algoritmalar (DE, BMO, HHO ve MFO) da güç sistemi problemine optimum çözümler üretmek için kullanılmıştır. Optimizasyon sonuçları, önerilen hibrit FDBLFD yönteminin rakip optimize edicilere kıyasla OGR sistemi için daha kaliteli birim basamak tepkisi elde ettiğini göstermiştir. Optimizasyon sürecinde FDBLFD algoritması kullanılarak yapılan iyileştirmeler, OGR sisteminin nominal koşullar altında adım tepkilerinin karşılaştırılmasının yanı sıra sağlamlık analizi gerçekleştirilerek vurgulanmıştır. Ayrıca, FDBLFD algoritması ile optimize edilen dört farklı tip kontrolcünün birim basamak tepkisi karşılaştırılmıştır. Buna göre FDBLFD ile ayarlanan PIDD² denetleyici dikkate alınan diğer kontrolcülere (PIF, PIDF ve FOPID) kıyasla OGR sistemi için daha kaliteli birim basamak tepkisi elde etmiştir. Literatürde PIDD² kontrolcünün ele alındığı çalışma sayısının sınırlı olmasına rağmen, bu tez çalışmasında dikkate alınan PIDD² denetleyicinin üstün performansı optimal OGR tasarımında kullanılabilecek etkili bir denetleyici olduğuna işaret etmiştir.

Meta-sezgisel arama süreci yaşam döngüsünün ilk adımlarında erken yakınsama problemini önlemek için daha fazla çeşitliliğe ihtiyaç duyulurken, sonlara doğru umut vadeden çözüm adaylarının etrafında hassas arama yapmaya ihtiyaç duyulmaktadır. FDB seçim yönteminde bu mekanizmanın etkili bir şekilde yerine getirilemediği tespit edilmiştir. FDB seçim yöntemindeki bu eksikliğin giderilmesi amacı ile *d*FDB isimli yeni bir seçim yöntemi önerilmiştir. Önerilen *d*FDB seçim yönteminde FDB skor hesabında kullanılan *w* ağırlık katsayısı (sömürü ve keşif arasındaki dengeyi kontrol eder), arama süreci yaşam döngüsünün ihtiyaçlarına göre dinamik olarak ayarlanabilen bir parametreye dönüştürülmüştür.

Önerilen *d*FDB seçim yöntemi kullanılarak meta-sezgisel arama algoritmalarının optimizasyon sürecine uyum sağlama yeteneği geliştirilmiştir. Bu gelişme, yakın zamanda geliştirilmiş bir meta-sezgisel arama algoritması olan MRFO kullanılarak kanıtlanmıştır. Bu kapsamda FDB ve *d*FDB yöntemi uygulanarak geliştirilen MRFO versiyonlarının (Versiyon-1,...,Versiyon-5) performansı analiz edilmiştir. Deneysel verilerin elde edildiği çalışmada 90 test problemi (Klasik, CEC 2017, CEC 2020), 3 farklı problem boyutu (30, 50 ve 100), 6 rekabetçi algoritma (geleneksel MRFO ve FDB-*d*FDB tabanlı MRFO versiyonları) kullanılmıştır. Friedman istatistiksel analiz sonuçlarına göre Versiyon-3 altı rekabetçi algoritma arasında en başarılı performansı gösterirken, Versiyon-5 ikinci sırada yer almıştır. Her iki algoritma da MRFO'nun *d*FDB ile tasarlanmış versiyonlarıdır. MRFO algoritmasının geleneksel versiyonu, 6 algoritma

arasında performans açısından en kötü sonucu vermiştir. Bu durum, FDB ve d FDB seçim yöntemlerinin algoritmaların arama performansı üzerindeki etkin rolünü açıkça ortaya koymuştur.

Geliştirilen d FDB-MRFO algoritması kısıtlı yönlü aşırı akım röleleri koordinasyonu optimizasyon problemine uygulanmıştır. Önerilen algoritmanın performansı, IEEE 3-baralı, IEEE 4-baralı, 8-baralı, 9-baralı ve IEEE 30-baralı test sistemleri olmak üzere beş test sisteminde değerlendirilmiştir. Bu kapsamda elde edilen bulgular kısaca aşağıda verilmiştir:

- Özellikle yüksek karmaşıklığa sahip 8-baralı, 9-baralı ve IEEE 30-baralı güç sistemlerinde gerçekleştirilen simülasyon çalışmalarından elde edilen bulgular d FDB-MRFO yönteminin arama performansı açısından ayırt edici olmuştur.
- 8-baralı, 9-baralı ve IEEE 30-baralı test sistemlerinde geleneksel MRFO'ya kıyasla d FDB-MRFO yöntemi ile birincil rölelerin toplam çalışma süresinin sırasıyla % 20,5216, % 4,3033 ve % 1,9148 oranında azaltıldığı tespit edilmiştir.

Özetle, bu tez çalışmasında optimizasyon alanında iki önemli konu üzerinde araştırma yapılmış ve önemli kazanımlar elde edilmiştir. Bu konulardan ilki, optimizasyon sürecinin en önemli unsuru olarak hibrit meta-sezgisel arama algoritmalarının geliştirilmesidir. Bunun için baz algoritmaların meta-sezgisel arama süreci FDB ve d FDB seçim yöntemleri kullanılarak yeniden tasarlanmıştır. Deneysel çalışmalardan elde edilen bulgular her iki seçim yönteminin de algoritmaların arama performansında önemli ölçüde iyileşme sağladığını ortaya koymuştur. Tez çalışması kapsamında çalışılan ikinci konu ise geliştirilen hibrit algoritmalar kullanılarak kısıtlı güç sistemi problemlerinin optimizasyonudur. Tez çalışması kapsamında geliştirilen algoritmaların başarılı bir şekilde optimal reaktif güç akışı, optimal otomatik gerilim regülatörü tasarımı ve yönlü aşırı akım röleleri koordinasyonu problemlerinde uygulanabilir olduğu kanıtlanmıştır. Bu bağlamda, araştırmacılar aynı ya da farklı tip optimizasyon problemlerinin çözümünde bu çalışmada geliştirilen hibrit algoritmaları kullanabilecekleri gibi FDB ve d FDB seçim yöntemlerini kullanarak yeni metodlar geliştirebilirler. Ayrıca, tez çalışması boyunca savunulan hibrit algoritmaların doğrulanması ve performansının daha da iyileştirilebilmesi için üçüncü bir algoritma kullanımı ile de yeni hibrit modeller oluşturarak algoritmaların daha düşük hata ile çözüme ulaşması sağlanabilir.

9. KAYNAKLAR

- [1] B. Akay ve D. Karaboga, "A survey on the applications of artificial bee colony in signal, image, and video processing," *Signal, Image and Video Processing*, c. 9 sayı 4, ss. 967-990, 2015.
- [2] G. D'Angelo ve F. Palmieri, "GGA: A modified genetic algorithm with gradient-based local search for solving constrained optimization problems," *Information Sciences*, sayı 547, ss. 136-162, 2021.
- [3] M. Khajehzadeh, M. R. Taha, A. El-Shafie, ve M. Eslami, "A survey on meta-heuristic global optimization algorithms," *Research Journal of Applied Sciences, Engineering and Technology*, c. 3, sayı 6, ss. 569-578, 2011.
- [4] K. Hussain, M. N. M. Salleh, S. Cheng, ve Y. Shi, "Metaheuristic research: a comprehensive survey," *Artificial Intelligence Review*, c. 52, sayı 4, ss. 2191-2233, 2019.
- [5] K. Sörensen, "Metaheuristics—the metaphor exposed," *International Transactions in Operational Research*, c. 22, sayı 1, ss. 3-18, 2015.
- [6] S. Aras, E. Gedikli, ve H. T. Kahraman, "A novel stochastic fractal search algorithm with fitness-distance balance for global numerical optimization," *Swarm and Evolutionary Computation*, c. 61, 2021.
- [7] M. Črepinšek, S. H. Liu, ve M. Mernik, "Exploration and exploitation in evolutionary algorithms: A survey," *Association Computing Machinery Computing Surveys*, c. 45, sayı 3, ss. 1-33, 2013.
- [8] X. S. Yang, S. Deb, ve S. Fong, "Metaheuristic algorithms: optimal balance of intensification and diversification," *Applied Mathematics Information Sciences*, c. 8, sayı 3, ss. 977-983, 2014.
- [9] J. Del Ser, E. Osaba, D. Molina, X. S. Yang, S. Salcedo-Sanz, D. Camacho, ve F. Herrera, "Bio-inspired computation: Where we stand and what's next," *Swarm and Evolutionary Computation*, c. 48, ss. 220-250, 2019.
- [10] S. C. Satapathy, X. S. Yang, ve V. Bhateja, "Evolutionary intelligence techniques for humanized computing," *Evolutionary Intelligence*, c. 14, sayı 2, ss. 203-203, 2021.
- [11] K. K. H. Ng, C. K. Lee, F. T. Chan, ve Y. Lv, "Review on meta-heuristics approaches for airside operation research," *Applied Soft Computing*, c. 66, ss. 104-133, 2018.
- [12] M. Jain, V. Singh, ve A. Rani, "A novel nature-inspired algorithm for optimization: Squirrel search algorithm," *Swarm and Evolutionary Computation*, c. 44, ss. 148-175, 2019.
- [13] A. Zhang, G. Sun, J. Ren, X. Li, Z. Wang, ve X. Jia, "A dynamic neighborhood learning-based gravitational search algorithm," *IEEE Transactions on Cybernetics*, c. 48, sayı 1, ss. 436-447, 2016.

- [14] X. Han, Q. Liu, H. Wang, ve L. Wang, "Novel fruit fly optimization algorithm with trend search and co-evolution," *Knowledge Based System*, c. 141, ss. 1–17, 2018.
- [15] D. Tian ve Z. Shi, "MPSO: Modified particle swarm optimization and its applications," *Swarm and Evolutionary Computation*, c. 41, ss. 49-68, 2018.
- [16] A. Sadollah, H. Sayyaadi, H. M. Lee, ve J. H. Kim, "Mine blast harmony search: a new hybrid optimization method for improving exploration and exploitation capabilities," *Applied Soft Computing*, c. 68, ss. 548-564, 2018.
- [17] A. P. Piotrowski ve J. J. Napiorkowski, "Step-by-step improvement of JADE and SHADE-based algorithms: Success or failure?," *Swarm and Evolutionary Computation*, c. 43, ss. 88-108, 2018.
- [18] L. Cui, G. Li, Z. Zhu, Q. Lin, K. C. Wong, J. Chen, N. Lu, ve J. Lu, "Adaptive multiple-elites-guided composite differential evolution algorithm with a shift mechanism," *Information Sciences*, c. 422, ss. 122–143, 2018.
- [19] H. T. Kahraman, S. Aras, ve E. Gedikli, "Fitness-distance balance (FDB): a new selection method for meta-heuristic search algorithms," *Knowledge-Based Systems*, c. 190, 2020.
- [20] H. T. Kahraman, H. Bakir, S. Duman, M. Katı, S. Aras, ve U. Guvenc, "Dynamic FDB selection method and its application: modeling and optimizing of directional overcurrent relays coordination," *Applied Intelligence*, ss. 1-36, 2021.
- [21] W. Ongsakul, ve V. N. Dieu, *Artificial Intelligence in Power System Optimization*, Florida, ABD: CRC Press, 2019.
- [22] U. Guvenc, S. Duman, H. T. Kahraman, S. Aras, ve M. Katı, "Fitness–Distance Balance based adaptive guided differential evolution algorithm for security-constrained optimal power flow problem incorporating renewable energy sources," *Applied Soft Computing*, c. 108, 2021.
- [23] A. W. Mohamed, A. A. Hadi, A. K. Mohamed, and N. H. Awad, "Evaluating the performance of adaptive GainingSharing knowledge based algorithm on CEC 2020 benchmark problems," *IEEE Congress on Evolutionary Computation (CEC)*, Glasgow, United Kingdom, 2020, ss. 1-8.
- [24] E. H. Houssein, M. R. Saad, F. A. Hashim, H. Shaban, ve M. Hassaballah, "Lévy flight distribution: A new metaheuristic algorithm for solving engineering optimization problems," *Engineering Applications of Artificial Intelligence*, c. 94, 2020.
- [25] W. Zhao, Z. Zhang, ve L. Wang, "Manta ray foraging optimization: An effective bio-inspired optimizer for engineering applications," *Engineering Applications of Artificial Intelligence*, c. 87, 2020.
- [26] A. Tharwat, E. H. Houssein, M. M. Ahmed, A. E. Hassanien, ve T. Gabel, "MOGOA algorithm for constrained and unconstrained multi-objective optimization problems," *Applied Intelligence*, c. 48, sayı 8, ss. 2268-2283, 2018.
- [27] S. Duman, U. Güvenç, Y. Sönmez, ve N. Yörükeren, "Optimal power flow using gravitational search algorithm," *Energy Conversion and Management*, c. 59, ss. 86-95, 2012.

- [28] N. Sinsuphan, U. Leeton, ve T. Kulworawanichpong, "Optimal power flow solution using improved harmony search method," *Applied Soft Computing*, c. 13, sayı 5, ss. 2364-2374, 2013.
- [29] H. R. E. H. Boucekara, M. A. Abido, ve M. J. E. P. S. R. Boucherma, "Optimal power flow using teaching-learning-based optimization technique," *Electric Power Systems Research*, c. 114, ss. 49-59, 2014.
- [30] U. Kılıç, "Backtracking search algorithm-based optimal power flow with valve point effect and prohibited zones," *Electrical Engineering*, c. 97, sayı 2, ss. 101-110, 2015.
- [31] A. F. Attia, R. A. El Sehiemy, ve H. M. Hasanien, "Optimal power flow solution in power systems using a novel Sine-Cosine algorithm," *International Journal of Electrical Power & Energy Systems*, c. 99, ss. 331-343, 2018.
- [32] U. Guvenc, H. Bakir, S. Duman, and B. Ozkaya, "Optimal power flow using manta ray foraging optimization," *The International Conference on Artificial Intelligence and Applied Mathematics in Engineering*, Antalya, Türkiye, 2020, ss. 136-149.
- [33] D. T. Abdul-hamied, A. M. Shaheen, W. A. Salem, W. I. Gabr, ve R. A. El-sehiemy, "Equilibrium optimizer based multi dimensions operation of hybrid AC/DC grids," *Alexandria Engineering Journal*, c. 59, sayı 6, ss. 4787-4803, 2020.
- [34] E. E. Elattar, A. M. Shaheen, A. M. Elsayed, ve R. A. El-Sehiemy, "Optimal power flow with emerged technologies of voltage source converter stations in meshed power systems," *IEEE Access*, c. 8, ss. 166963-166979, 2020.
- [35] A. M. Shaheen, R. A. El-Sehiemy, A. M. Elsayed, ve E. E. Elattar, "Multi-objective manta ray foraging algorithm for efficient operation of hybrid AC/DC power grids with emission minimisation," *IET Generation, Transmission & Distribution*, c. 15, sayı 8, ss. 1314-1336, 2021.
- [36] W. Feng, L. B. Tjernberg, A. Mannikoff, ve A. Bergman, "A new approach for benefit evaluation of multiterminal VSC-HVDC using a proposed mixed AC/DC optimal power flow," *IEEE Transactions on Power Delivery*, c. 29, sayı 1, ss. 432-443, 2013.
- [37] Q. Zhao, J. García-González, O. Gomis-Bellmunt, E. Prieto-Araujo, ve F. M. Echavarren, "Impact of converter losses on the optimal power flow solution of hybrid networks based on VSC-MTDC," *Electric Power Systems Research*, c. 151, ss. 395-403, 2017.
- [38] A. M. Elsayed, A. M. Shaheen, M. M. Alharthi, S. S. Ghoneim, ve R. A. El-Sehiemy, "Adequate operation of Hybrid AC/MT-HVDC power systems using an improved Multi-Objective Marine Predators Optimizer," *IEEE Access*, c. 9, ss. 51065-51087, 2021.
- [39] P. P. Biswas, P. N. Suganthan, ve G. A. Amaratunga, "Optimal power flow solutions incorporating stochastic wind and solar power," *Energy Conversion and Management*, c. 148, ss. 1194-1207, 2017.
- [40] I. U. Khan, N. Javaid, K. A. Gamage, C. J. Taylor, S. Baig, ve X. Ma, "Heuristic algorithm based optimal power flow model incorporating stochastic renewable energy sources," *IEEE Access*, c. 8, ss. 148622-148643, 2020.

- [41] S. Duman, J. Li, L. Wu, ve N. Yorukeren, "Symbiotic organisms search algorithm-based security-constrained AC–DC OPF regarding uncertainty of wind, PV and PEV systems," *Soft Computing*, c. 25, sayı 14, ss. 9389-9426, 2021.
- [42] M. H. Sulaiman ve Z. Mustaffa, "Solving optimal power flow problem with stochastic wind–solar–small hydro power using barnacles mating optimizer," *Control Engineering Practice*, c. 106, 2021.
- [43] E. Kaymaz, S. Duman, ve U. Guvenc, "Optimal power flow solution with stochastic wind power using the Lévy coyote optimization algorithm," *Neural Computing and Applications*, c. 33, sayı 12, ss. 6775-6804, 2021.
- [44] I. U. Khan, N. Javaid, C. J. Taylor, K. A. Gamage, ve M. A. Xiandong, "Optimal Power Flow Solution with Uncertain RES using Augmented Grey Wolf Optimzation," *IEEE International Conference on Power Systems Technology*, Bangalore, Hindistan, 2020, ss. 1-6.
- [45] K. Ayan, ve U. Kılıç, "Artificial bee colony algorithm solution for optimal reactive power flow," *Applied Soft Computing*, c. 12, sayı 5, ss. 1477-1482, 2012.
- [46] J. Cao, F. Wang, ve P. Li, "An improved biogeography-based optimization algorithm for optimal reactive power flow," *International Journal of Control and Automation*, c. 7, sayı 3, ss. 161-176, 2014.
- [47] A. Moghadam ve A. R. Seifi, "Fuzzy-TLBO optimal reactive power control variables planning for energy loss minimization," *Energy Conversion and Management*, c. 77, ss. 208-215. 2014.
- [48] M. H. Sulaiman, Z. Mustaffa, M. R. Mohamed, ve O. Aliman, "Using the gray wolf optimizer for solving optimal reactive power dispatch problem," *Applied Soft Computing*, c. 32, ss. 286-292, 2015.
- [49] M. Mehdinejad, B. Mohammadi-Ivatloo, R. Dadashzadeh-Bonab, ve K. Zare, "Solution of optimal reactive power dispatch of power systems using hybrid particle swarm optimization and imperialist competitive algorithms," *International Journal of Electrical Power & Energy Systems*, c. 83, ss. 104-116, 2016.
- [50] K. Lenin, B. R. Reddy, ve M. Suryakalavathi, "Hybrid Tabu search-simulated annealing method to solve optimal reactive power problem," *International Journal of Electrical Power & Energy Systems*, c. 82, ss 87-91, 2016.
- [51] R. N. S. Mei, M. H. Sulaiman, Z. Mustaffa, ve H. Daniyal, "Optimal reactive power dispatch solution by loss minimization using moth-flame optimization technique," *Applied Soft Computing*, c. 59, ss. 210-222, 2017.
- [52] W. S. Sakr, R. A. El-Sehiemy, ve A. M. Azmy, "Adaptive differential evolution algorithm for efficient reactive power management," *Applied Soft Computing*, c. 53, ss. 336-351, 2017.
- [53] W. Fadel, U. Kilic, ve K. Ayan, "Optimal reactive power flow of power systems with two-terminal HVDC and multi distributed generations using backtracking search algorithm," *International Journal of Electrical Power & Energy Systems*, c. 127, 2021.
- [54] H. Gozde ve M. C. Taplamacioglu, "Comparative performance analysis of artificial bee colony algorithm for automatic voltage regulator (AVR) system," *Journal of the Franklin Institute*, c. 348, sayı 8, ss. 1927-1946, 2011.

- [55] S. Panda, B. K. Sahu, ve P. K. Mohanty, "Design and performance analysis of PID controller for an automatic voltage regulator system using simplified particle swarm optimization," *Journal of the Franklin Institute*, c. 349, sayı 8, ss. 2609-2625, 2012.
- [56] E. Çelik ve R. Durgut, "Performance enhancement of automatic voltage regulator by modified cost function and symbiotic organisms search algorithm," *Engineering Science and Technology, an International Journal*, c. 21, sayı 5, ss. 1104-1111, 2018.
- [57] Z. L. Gaing, "A particle swarm optimization approach for optimum design of PID controller in AVR system," *IEEE Transactions on Energy Conversion*, c. 19, sayı 2, ss. 384-391, 2004.
- [58] R. K. Sahu, S. Panda, ve U. K. Rout, "DE optimized parallel 2-DOF PID controller for load frequency control of power system with governor dead-band nonlinearity," *International Journal of Electrical Power & Energy Systems*, c. 49, ss. 19-33, 2013.
- [59] S. Chatterjee ve V. Mukherjee, "PID controller for automatic voltage regulator using teaching-learning based optimization technique," *International Journal of Electrical Power & Energy Systems*, c. 77, ss. 418-429, 2016.
- [60] N. Paliwal, L. Srivastava, ve M. Pandit, "Equilibrium optimizer tuned novel FOPID-DN controller for automatic voltage regulator system," *International Transactions on Electrical Energy Systems*, c. 31, sayı 8, ss. 1-28, 2021.
- [61] Z. Bingul ve O. Karahan, "Comparison of PID and FOPID controllers tuned by PSO and ABC algorithms for unstable and integrating systems with time delay," *Optimal Control Applications and Methods*, c. 39, sayı 4, ss. 1431-1450, 2018.
- [62] U. Guvenc, A. H. Isik, T. Yigit, ve I. Akkaya, "Performance analysis of biogeography-based optimization for automatic voltage regulator system," *Turkish Journal of Electrical Engineering & Computer Sciences*, c. 24, sayı 3, ss. 1150-1162, 2016.
- [63] E. Çelik, "Incorporation of stochastic fractal search algorithm into efficient design of PID controller for an automatic voltage regulator system," *Neural Computing and Applications*, c. 30, sayı 6, ss. 1991-2002, 2018.
- [64] M. Micev, M. Čalasan, ve D. Oliva, "Design and robustness analysis of an Automatic Voltage Regulator system controller by using equilibrium optimizer algorithm," *Computers & Electrical Engineering*, c. 89, 2021.
- [65] J. Bhokya ve R. K. Jatoh, "Optimal FOPID/PID controller parameters tuning for the AVR system based on sine-cosine-algorithm," *Evolutionary Intelligence*, c. 12, sayı 4, ss. 725-733, 2019.
- [66] M. S. Ayas ve E. Sahin, "FOPID controller with fractional filter for an automatic voltage regulator," *Computers & Electrical Engineering*, c. 90, 2021.
- [67] S. Ekinçi ve B. Hekimoğlu, "Improved kidney-inspired algorithm approach for tuning of PID controller in AVR system," *IEEE Access*, c. 7, ss. 39935-39947, 2019.
- [68] M. A. Sahib, "A novel optimal PID plus second order derivative controller for AVR system," *Engineering Science and Technology, an International Journal*, c. 18, sayı 2, ss. 194-206, 2015.

- [69] I. A. Khan, A. S. Alghamdi, T. A. Juman, A. Alamgir, A. B. Awan, ve A. Khidrani, "Salp swarm optimization algorithm-based fractional order PID controller for dynamic response and stability enhancement of an automatic voltage regulator system," *Electronics*, c. 8, sayı 12, 2019.
- [70] D. Mokeddem ve S. Mirjalili, "Improved Whale Optimization Algorithm applied to design PID plus second-order derivative controller for automatic voltage regulator system," *Journal of the Chinese Institute of Engineers*, c. 43, sayı 6, ss. 541-552, 2020.
- [71] D. H. Wolpert ve W. G. Macready, "No free lunch theorems for optimization," *IEEE Transactions on Evolutionary Computation*, c.1, sayı 1, ss. 67-82, 1997.
- [72] O. Akdag ve C. Yeroglu, "Optimal directional overcurrent relay coordination using MRFO algorithm: A case study of adaptive protection of the distribution network of the Hatay province of Turkey," *Electric Power Systems Research*, c. 192, 2021.
- [73] T. Khurshaid, A. Wadood, S. G. Farkoush, C. H. Kim, N. Cho, ve S. B. Rhee, "Modified particle swarm optimizer as optimization of time dial settings for coordination of directional overcurrent relay," *Journal of Electrical Engineering & Technology*, c. 14, sayı 1, ss. 55-68, 2019.
- [74] R. Thangaraj, M. Pant, ve K. Deep, "Optimal coordination of over-current relays using modified differential evolution algorithms," *Engineering Applications of Artificial Intelligence*, c. 23, sayı 5, ss. 820-829, 2010.
- [75] M. Irfan, A. Wadood, T. Khurshaid, B. M. Khan, K. C. Kim, S. R. Oh, ve S. B. Rhee, "An optimized adaptive protection scheme for numerical and directional overcurrent relay coordination using Harris hawk optimization," *Energies*, c. 14, sayı 18, 2021.
- [76] C. H. Kim, T. Khurshaid, A. Wadood, S. G. Farkoush, ve S. B. Rhee, "Gray wolf optimizer for the optimal coordination of directional overcurrent relay," *Journal of Electrical Engineering and Technology*, c. 13, sayı 3, ss. 1043-1051, 2018.
- [77] M. Singh, B. K. Panigrahi, ve A. R. Abhyankar, "Optimal coordination of directional over-current relays using Teaching Learning-Based Optimization (TLBO) algorithm," *International Journal of Electrical Power & Energy Systems*, c. 50, ss. 33-41, 2013.
- [78] M. H. Sadeghi, A. Dastfan, ve Y. Damchi, "Robust and adaptive coordination approaches for co-optimization of voltage dip and directional overcurrent relays coordination," *International Journal of Electrical Power & Energy Systems*, c. 129, 2021.
- [79] S. A. Ahmadi, H. Karami, ve B. Gharehpetian, "Comprehensive coordination of combined directional overcurrent and distance relays considering miscoordination reduction," *International Journal of Electrical Power & Energy Systems*, c. 92, ss. 42-52, 2017.
- [80] H. R. E. H. Boucekara, M. Zellagui, ve M. A. Abido, "Optimal coordination of directional overcurrent relays using a modified electromagnetic field optimization algorithm," *Applied Soft Computing*, c. 54, ss. 267-283, 2017.

- [81] M. Y. Shih, A. C. Enríquez, T. Y. Hsiao, ve L. M. T. Treviño, “Enhanced differential evolution algorithm for coordination of directional overcurrent relays,” *Electric Power Systems Research*, c. 143, ss. 365-375, 2017.
- [82] A. Srivastava, J. M. Tripathi, R. Krishan, ve S. K. Parida, “Optimal coordination of overcurrent relays using gravitational search algorithm with DG penetration,” *IEEE Transactions on Industry Applications*, c. 54, sayı 2, ss. 1155-1165, 2017.
- [83] R. M. Rizk-Allah ve A. A. El-Fergany, “Effective coordination settings for directional overcurrent relay using hybrid Gradient-based optimizer,” *Applied Soft Computing*, c. 112, 2021.
- [84] A. Korashy, S. Kamel, A. R. Youssef, ve F. Jurado, “Modified water cycle algorithm for optimal direction overcurrent relays coordination,” *Applied Soft Computing*, c. 74, ss. 10-25, 2019.
- [85] A. Faramarzi, M. Heidarinejad, S. Mirjalili, ve A. H. Gandomi, “Marine Predators Algorithm: A nature-inspired metaheuristic,” *Expert Systems with Applications*, c. 152, 2020.
- [86] S. Boyd ve L. Vandenberghe, *Convex Optimization*, 1. Baskı, Cambridge, Birleşik Krallık: Cambridge University Press, 2004.
- [87] A. Faramarzi ve M. H. Afshar, “A novel hybrid cellular automata–linear programming approach for the optimal sizing of planar truss structures,” *Civil Engineering and Environmental Systems*, c. 31, sayı 3, ss. 209-228, 2014.
- [88] S. Mirjalili, S. M. Mirjalili, ve A. Lewis, “Grey wolf optimizer,” *Advances in Engineering Software*, c. 69, ss. 46-61, 2014.
- [89] S. Duman, H. T. Kahraman, U. Guvenc, ve S. Aras, “Development of a Lévy flight and FDB-based coyote optimization algorithm for global optimization and real-world ACOPF problems,” *Soft Computing*, c. 25, sayı 8, ss. 6577-6617, 2021.
- [90] A. Özkış ve A. Babalık, “A novel metaheuristic for multi-objective optimization problems: The multi-objective vortex search algorithm,” *Information Sciences*, c. 402, ss. 124-148, 2017.
- [91] A. Babalik, A. Ozkis, S. A. Uymaz, ve M. S. Kiran, “A multi-objective artificial algae algorithm,” *Applied Soft Computing*, c. 68, ss. 377-395, 2018.
- [92] M. Akbel, ve H. Kahraman, “Çok amaçlı Meta-Sezgisel optimizasyon algoritmalarının performanslarının karşılaştırılması,” *Mühendislik Bilimleri ve Tasarım Dergisi*, c. 8, sayı 5, ss. 185-199, 2020.
- [93] S. Duman, M. Akbel, ve H. T. Kahraman, “Development of the Multi-Objective Adaptive Guided Differential Evolution and optimization of the MO-ACOPF for wind/PV/tidal energy sources,” *Applied Soft Computing*, c. 112, 2021.
- [94] A. Özkış, “Sayısal optimizasyon problemlerinin çözümü için yapay arı kolonisi algoritmasının iyileştirilmesi,” Doktora tezi, Bilgisayar Mühendisliği, Fen Bilimleri Enstitüsü, Selçuk Üniversitesi, Konya, Türkiye, 2013.
- [95] C. A. C. Coello, G. B. Lamont, ve D. A. Van Veldhuizen, *Evolutionary Algorithms for Solving Multi-Objective Problems*, 2. Baskı, Boston, ABD: Springer, 2007, ss. 79-104.
- [96] M. Karakoyun, A. Ozkis, ve H. Kodaz, “A new algorithm based on gray wolf optimizer and shuffled frog leaping algorithm to solve the multi-objective

- optimization problems,” *Applied Soft Computing*, c. 96, 2020.
- [97] H. T. Kahraman, M. Akbel, ve S. Duman, “Optimization of optimal power flow problem using Multi-Objective Manta Ray Foraging optimizer,” *Applied Soft Computing*, c. 116, 2021.
 - [98] B. Abdollahzadeh, , F. Soleimanian Gharehchopogh, ve S. Mirjalili, “Artificial gorilla troops optimizer: A new nature-inspired metaheuristic algorithm for global optimization problems,” *International Journal of Intelligent Systems*, c. 36, sayı 10, ss. 5887-5958, 2021.
 - [99] S. K. Sahoo, A. K. Saha, S. Sharma, S. Mirjalili, ve S. Chakraborty, “An enhanced moth flame optimization with mutualism scheme for function optimization,” *Soft Computing*, ss. 1-28, 2022.
 - [100] W. Zhao, L. Wang, ve S. Mirjalili, “Artificial hummingbird algorithm: A new bio-inspired optimizer with its engineering applications,” *Computer Methods in Applied Mechanics and Engineering*, c. 388, 2022.
 - [101] K. Hussain, M. N. M. Salleh, S. Cheng, ve Y. Shi, “On the exploration and exploitation in popular swarm-based metaheuristic algorithms,” *Neural Computing and Applications*, c. 31, sayı 11, ss. 7665-7683, 2019.
 - [102] N. H. Awad, M. Z. Ali, J. J. Liang, B. Y. Qu, ve P. N. Suganthan, “Problem definitions and evaluation criteria for the CEC 2017 special session and competition on single objective real-parameter numerical optimization,” *Technical Report*, 2016.
 - [103] C. T. Yue, K. V. Price, P. N. Suganthan, J. J. Liang1 M. Z. Ali, B. Y. Qu, N. H. Awad, ve P.P Biswas, “Problem Definitions and Evaluation Criteria for the CEC 2020 Special Session and Competition on Single Objective Bound Constrained Numerical Optimization,” Zhengzhou University and Nanyang Technological University, *Technical Report*, 2019.
 - [104] J. J. Liang, B. Y. Qu, ve P. N. Suganthan, “Problem definitions and evaluation criteria for the CEC 2014 special session and competition on single objective real-parameter numerical optimization,” Zhengzhou University, Zhengzhou, China, *Technical Report*, 2013.
 - [105] R. Storn ve K. Price, “Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces,” *Journal of Global Optimization*, c. 11, sayı 4, ss. 341-359, 1997.
 - [106] M. H. Sulaiman, Z. Mustaffa, M. M. Saari, ve H. Daniyal, “Barnacles mating optimizer: a new bio-inspired algorithm for solving engineering optimization problems,” *Engineering Applications of Artificial Intelligence*, c. 87, 2020.
 - [107] A. A. Heidari, S. Mirjalili, H. Faris, I. Aljarah, M. Mafarja, ve H. Chen, “Harris hawks optimization: Algorithm and applications,” *Future Generation Computer Systems*, c. 97, ss. 849-872, 2019.
 - [108] S. Mirjalili, “Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm,” *Knowledge Based Systems*, c. 89, ss. 228-249, 2015.
 - [109] E. Rashedi, H. Nezamabadi-Pour, ve S. Saryazdi, “GSA: A gravitational search algorithm,” *Information Sciences*, c. 179, sayı 13, ss. 2232-2248, 2009.

- [110] S. Mirjalili ve A. Lewis, "The whale optimization algorithm," *Advances in Engineering Software*, c. 95, ss. 51-67, 2016.
- [111] A. Askarzadeh, "A novel metaheuristic method for solving constrained engineering optimization problems: Crow search algorithm," *Computers & Structures*, c. 169, ss. 1-12, 2016.
- [112] F. A. Hashim, E. H. Houssein, M. S. Mabrouk, W. Al-Atabany, ve S. Mirjalili, "Henry gas solubility optimization: A novel physics-based algorithm," *Future Generation Computer Systems*, c. 101, ss. 646-667, 2019.
- [113] S. Mirjalili, "SCA: A sine cosine algorithm for solving optimization problems," *Knowledge Based Systems*, c. 96, ss. 120-133, 2016.
- [114] H. N. Ghafil, ve K. Jármai, "Dynamic differential annealed optimization: New metaheuristic optimization algorithm for engineering applications," *Applied Soft Computing*, c. 93, 2020.
- [115] A. W. Mohamed, A. A. Hadi, ve A. K. Mohamed, "Gaining-sharing knowledge based algorithm for solving optimization problems: A novel nature-inspired algorithm," *International Journal of Machine Learning and Cybernetics*, c. 11, sayı 7, ss. 1501-1529, 2020.
- [116] S. Z. Mirjalili, S. Mirjalili, S. Saremi, H. Faris, ve I. Aljarah, "Grasshopper optimization algorithm for multi-objective optimization problems," *Applied Intelligence*, c. 48, sayı 4, ss. 805-820, 2018.
- [117] S. Arora ve P. Anand, "Chaotic grasshopper optimization algorithm for global optimization," *Neural Computing and Applications*, c. 31, sayı 8, ss. 4385-4405, 2019.
- [118] A. A. El-Fergany ve H. M. Hasanien, "Tree-seed algorithm for solving optimal power flow problem in large-scale power systems incorporating validations and comparisons," *Applied Soft Computing*, c. 64, ss. 307-316, 2018.
- [119] S. Mirjalili, A. H. Gandomi, S. Z. Mirjalili, S. Saremi, H. Faris, ve S. M. Mirjalili, "Salp Swarm Algorithm: A bio-inspired optimizer for engineering design problems," *Advances in Engineering Software*, c. 114, ss. 163-191, 2017.
- [120] S. Mirjalili, "Dragonfly algorithm: A new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems," *Neural Computing and Applications*, c. 27, sayı 4, ss. 1053-1073, 2016.
- [121] S. Mirjalili, P. Jangir, ve S. Saremi, "Multi-objective ant lion optimizer: A multi-objective optimization algorithm for solving engineering problems," *Applied Intelligence*, c. 46, sayı 1, ss. 79-95, 2017.
- [122] C. Yue, B. Qu, ve J. Liang, "A multiobjective particle swarm optimizer using ring topology for solving multimodal multiobjective problems," *IEEE Transactions on Evolutionary Computation*, c. 22, sayı 5, ss. 805-817, 2017.
- [123] N. Karthik, A. K. Parvathy, R. Arul, ve K. Padmanathan, "Multi-objective optimal power flow using a new heuristic optimization algorithm with the incorporation of renewable energy sources," *International Journal of Energy and Environmental Engineering*, ss. 1-38, 2021.
- [124] S. Birolgul, "Hybrid harris hawk optimization based on differential evolution (HHODE) algorithm for optimal power flow problem," *IEEE Access*, c. 7, ss.

184468-184488, 2019.

- [125] S. Duman, J. Li, ve L. Wu, “AC optimal power flow with thermal–wind–solar–tidal systems using the symbiotic organisms search algorithm,” *IET Renewable Power Generation*, c. 15, sayı 2, ss. 278-296. 2021.
- [126] P. P. Biswas, P. N. Suganthan, B. Y. Qu, ve G. A. Amaratunga, “Multiobjective economic-environmental power dispatch with stochastic wind-solar-small hydro power,” *Energy*, c. 150, ss. 1039-1057, 2018.
- [127] R. Roy, ve H. T. Jadhav, “Optimal power flow solution of power system incorporating stochastic wind power using Gbest guided artificial bee colony algorithm,” *International Journal of Electrical Power & Energy Systems*, c. 64, ss. 562-578, 2015.
- [128] A. Panda ve M. Tripathy, “Optimal power flow solution of wind integrated power system using modified bacteria foraging algorithm,” *International Journal of Electrical Power & Energy Systems*, c. 54, ss. 306-314, 2014.
- [129] A. Panda, ve M. Tripathy, “Security constrained optimal power flow solution of wind-thermal generation system using modified bacteria foraging algorithm,” *Energy*, c. 93, ss. 816-827, 2015.
- [130] S. S. Reddy, P. R. Bijwe, ve A. R. Abhyankar, “Real-time economic dispatch considering renewable power generation variability and uncertainty over scheduling period,” *IEEE Systems Journal*, c. 9, sayı 4, ss. 1440-1451, 2014.
- [131] T. P. Chang, “Investigation on frequency distribution of global radiation using different probability density functions,” *International Journal of Applied Science and Engineering*, c. 8, sayı 2, ss. 99-107, 2010.
- [132] N. Mujere, “Flood frequency analysis using the Gumbel distribution,” *International Journal on Computer Science and Engineering*, c. 3, sayı 7, ss. 2774-2778, 2011.
- [133] P. Cabus, “River flow prediction through rainfall–runoff modelling with a probability-distributed model (PDM) in Flanders, Belgium,” *Agricultural Water Management*, c. 95, sayı 7, ss. 859-868, 2008.
- [134] S. Duman, J. Li, L. Wu, ve U. Guvenc, “Optimal power flow with stochastic wind power and FACTS devices: a modified hybrid PSOGSA with chaotic maps approach,” *Neural Computing and Applications*, c. 32, sayı 12, ss. 8463-8492, 2020.
- [135] S. Vidyasagar, K. Vijayakumar, D. Sattianadan, ve S. G. Fernandez, “Optimal placement of DG based on voltage stability index and voltage deviation index,” *Indian Journal of Science and Technology*, c. 9, sayı 38, 2016.
- [136] A. M. Shaheen, S. M. Farrag, ve R. A. El-Sehiemy, “MOPF solution methodology,” *IET Generation, Transmission & Distribution*, c. 11, sayı 2, ss. 570-581, 2017.
- [137] P. P. Biswas, P. N. Suganthan, R. Mallipeddi, ve G. A. Amaratunga, “Optimal power flow solutions using differential evolution algorithm integrated with effective constraint handling techniques,” *Engineering Applications of Artificial Intelligence*, c. 68, ss. 81-100, 2018.
- [138] J. Renedo, A. A. Ibrahim, B. Kazemtabrizi, A. Garcia-Cerrada, L. Rouco, Q. Zhao,

- ve J. Garcia-Gonzalez, "A simplified algorithm to solve optimal power flows in hybrid VSC-based AC/DC systems," *International Journal of Electrical Power & Energy Systems*, c. 110, ss. 781-794, 2019.
- [139] Power Systems Test Case Archive. (2021, 10 Haziran). *30 Bus Power Flow Test Case*. [Online]. Erişim: http://labs.ece.uw.edu/pstca/pf30/pg_tca30bus.htm
- [140] A. E. Chaib, H. R. E. H. Boucekara, R. Mehasni, ve M. A. Abido, "Optimal power flow with emission and non-smooth cost functions using backtracking search optimization algorithm," *International Journal of Electrical Power & Energy Systems*, c. 81, ss. 64-77, 2016.
- [141] University of Leuven. (2021, 14 Aralık). *MATACDC*. [Online]. Erişim: <https://www.esat.kuleuven.be/electa/teaching/matacdc>
- [142] A. Bhattacharya, ve P. K. Chattopadhyay, "Solution of optimal reactive power flow using biogeography-based optimization," *International Journal of Electrical Electronic Engineering*, c. 4, sayı 8, ss. 568-576, 2010.
- [143] M. M. Aman, G. B. Jasmon, H. Mokhlis, ve A. H. A. Bakar, "Optimal placement and sizing of a DG based on a new power stability index and line losses," *International Journal of Electrical Power & Energy Systems*, c. 43, sayı 1, ss. 1296-1304, 2012.
- [144] S. Kansal, V. Kumar, ve B. Tyagi, "Hybrid approach for optimal placement of multiple DGs of multiple types in distribution networks," *International Journal of Electrical Power & Energy Systems*, c. 75, ss. 226-235, 2016.
- [145] H. Yang, W. Zhang, J. Chen, ve J. Xie, "Optimal coordinated voltage control of AC/DC power systems for voltage stability enhancement," *International Journal of Electrical Power & Energy Systems*, c. 108, ss. 252-262, 2019.
- [146] S. Duman, "A modified moth swarm algorithm based on an arithmetic crossover for constrained optimization and optimal power flow problems," *IEEE Access*, c. 6, ss. 45394-45416, 2018.
- [147] K. Ayan ve U. Kılıç, "Optimal power flow of two-terminal HVDC systems using backtracking search algorithm," *International Journal of Electrical Power & Energy Systems*, c. 78, ss. 326-335, 2016.
- [148] U. Kılıç ve K. Ayan, "Optimizing power flow of AC-DC power systems using artificial bee colony algorithm," *International Journal of Electrical Power & Energy Systems*, c. 53, ss. 592-602, 2013.
- [149] MATPOWER. (2021, 25 Kasım). [Online]. Erişim: <http://www.pserc.cornell.edu/matpower/>.
- [150] Power Systems Test Case Archive. (2021, 17 Temmuz). *57 Bus Power Flow Test Case*. [Online]. Erişim: http://labs.ece.uw.edu/pstca/pf57/pg_tca57bus.htm
- [151] R. Taghavi ve A. Seifi, "Optimal reactive power control in hybrid power systems," *Electric Power Components and Systems*, c. 40, sayı 7, ss. 741-758, 2012.
- [152] U. Kılıç, K. Ayan, ve U. Arifoğlu, "Optimizing reactive power flow of HVDC systems using genetic algorithm," *International Journal of Electrical Power & Energy Systems*, c. 55, ss. 1-12, 2014.
- [153] U. Kılıç ve K. Ayan, "Artificial bee colony algorithm based optimal reactive power flow of two-terminal HVDC systems," *Turkish Journal of Electrical Engineering*

& *Computer Sciences*, c. 24, sayı 3, ss. 1075-1090, 2016.

- [154] Y. Yusran, “Electrical network power quality improvement through distributed generation optimum placement based on Breeder Genetic Algorithm method,” *International Conference on Electrical Engineering and Informatics*, Macassar, Endonezya, 2014, ss. 20-22.
- [155] H. Shayeghi, A. Younesi, ve Y. Hashemi, “Optimal design of a robust discrete parallel FP+ FI+ FD controller for the automatic voltage regulator system,” *International Journal of Electrical Power & Energy Systems*, c. 67, ss. 66-75, 2015.
- [156] S. Duman, N. Yörükeren, ve İ. H. Altaş, “Gravitational search algorithm for determining controller parameters in an automatic voltage regulator system,” *Turkish Journal of Electrical Engineering & Computer Sciences*, c. 24, sayı 4, ss. 2387-2400, 2016.
- [157] M. Micev, M. Čalasan, Z. M. Ali, H. M. Hasanien, ve S. H. A. Aleem, “Optimal design of automatic voltage regulation controller using hybrid simulated annealing–Manta ray foraging optimization algorithm,” *Ain Shams Engineering Journal*, c. 12, sayı 1, ss. 641-657, 2021.
- [158] G. Q. Zeng, J. Chen, Y. X. Dai, L. M. Li, C. W. Zheng, ve M. R. Chen, “Design of fractional order PID controller for automatic regulator voltage system based on multi-objective extremal optimization,” *Neurocomputing*, c. 160, ss. 173-184, 2015.
- [159] M. Micev, M. Čalasan, ve D. Oliva, “Fractional order PID controller design for an AVR system using Chaotic Yellow Saddle Goatfish Algorithm,” *Mathematics*, c. 8, sayı 7, 2020.
- [160] E. Köse, “Optimal control of AVR system with Tree Seed Algorithm-Based PID controller,” *IEEE Access*, c. 8, ss. 89457-89467, 2020.
- [161] P. K. Mohanty, B. K. Sahu, ve S. Panda, “Tuning and assessment of proportional–integral–derivative controller for an automatic voltage regulator system employing local unimodal sampling algorithm,” *Electric Power Components and Systems*, c. 42, sayı 9, ss. 959-969, 2014.
- [162] B. K. Sahu, S. Panda, P. K. Mohanty, ve N. Mishra, “Robust analysis and design of PID controlled AVR system using Pattern Search algorithm,” *IEEE International Conference on Power Electronics, Drives and Energy Systems*, Bengaluru, Hindistan, 2012, ss. 1-6.
- [163] B. Hekimoğlu, ve S. Ekinçi “Grasshopper optimization algorithm for automatic voltage regulator system,” *5th International Conference on Electrical and Electronic Engineering*, İstanbul, Türkiye, 2018, ss. 152-156.
- [164] E. Çelik ve N. Öztürk, “A hybrid symbiotic organisms search and simulated annealing technique applied to efficient design of PID controller for automatic voltage regulator,” *Soft Computing*, c. 22, sayı 23, ss. 8011-8024, 2018.
- [165] H. M. Hasanien, “Design optimization of PID controller in automatic voltage regulator system using Taguchi combined genetic algorithm method,” *IEEE Systems Journal*, c. 7, sayı 4, ss. 825-831, 2012.
- [166] N. Razmjooy, M. Khalilpour, ve M. Ramezani, “A new meta-heuristic optimization algorithm inspired by FIFA world cup competitions: Theory and its

- application in PID designing for AVR system,” *Journal of Control, Automation and Electrical Systems*, c. 27, sayı 4, ss. 419-440, 2016.
- [167] S. Ekinçi, B. Hekimoğlu, ve E. Eker, “Optimum design of PID controller in AVR system using Harris hawks optimization,” *3rd International Symposium on Multidisciplinary Studies and Innovative Technologies*, Ankara, Türkiye, 2019, ss. 1-6.
- [168] A. Demirören, B. Hekimoğlu, S.Ekinçi, ve S. Kaya, “Artificial electric field algorithm for determining controller parameters in AVR system,” *International Artificial Intelligence and Data Processing Symposium*, Malatya, Türkiye, 2019, ss. 1-7.
- [169] Z. Bingul ve O. Karahan, “A novel performance criterion approach to optimum design of PID controller using cuckoo search algorithm for AVR system,” *Journal of the Franklin Institute*, c. 355, sayı 13, ss. 5534-5559, 2018.
- [170] M. A. Sahib ve B. S. Ahmed, “A new multiobjective performance criterion used in PID tuning optimization algorithms,” *Journal of Advanced Research*, c. 7, sayı 1, ss. 125-134, 2016.
- [171] Y. Tang, M. Cui, C. Li L. Hua, ve Y. Yang, “Optimum design of fractional order PI λ D μ controller for AVR system using chaotic ant swarm,” *Expert Systems with Applications*, c. 39, sayı 8, ss. 6887-6896, 2012.
- [172] A. Sikander, P. Thakur, R. C. Bansal ve S. Rajasekar, “A novel technique to design cuckoo search based FOPID controller for AVR in power systems,” *Computers & Electrical Engineering*, c. 70, ss. 261-274, 2018.
- [173] M. E. Ortiz-Quisbert, M. A. Duarte-Mermoud, F. Milla, R. Castro-Linares ve G. Lefranc, “Optimal fractional order adaptive controllers for AVR applications,” *Electrical Engineering*, c. 100, sayı 1, ss. 267-283, 2018.
- [174] T. A. Jumani, M. W. Mustafa, Z. Hussain, M. M. Rasid, M. S. Saeed, M. M. Memon ve K. S. Nisar, “Jaya optimization algorithm for transient response and stability enhancement of a fractional-order PID based automatic voltage regulator system,” *Alexandria Engineering Journal*, c. 59, sayı 4, ss. 2429-2440, 2020.
- [175] I. Pan ve S. Das, “Frequency domain design of fractional order PID controller for AVR system using chaotic multi-objective optimization,” *International Journal of Electrical Power & Energy Systems*, c. 51, ss. 106-118. 2013.
- [176] B. Bourouba, S. Ladaci ve H. Schulte, “Optimal design of fractional order PI λ D μ controller for an AVR system using Ant Lion Optimizer,” *IFAC-PapersOnLine*, c. 52, sayı 13, ss. 200-205, 2019.
- [177] A. K. Bhullar, R. Kaur ve S.Sondhi. “Optimization of fractional order controllers for AVR system using distance and Levy-Flight Based Crow Search Algorithm,” *IETE Journal of Research*, ss. 1-18, 2020.
- [178] S. Ekinçi, D. Izci, ve B. Hekimoğlu, “Henry gas solubility optimization algorithm based FOPID controller design for automatic voltage regulator,” *International Conference on Electrical, Communication, and Computer Engineering (ICECCE)*, İstanbul, Türkiye, 2020, ss. 1-6.
- [179] J. Radosavljević, “Metaheuristic optimization in power engineering,” *Institution of Engineering and Technology*, 2018.

- [180] J. Radosavljević ve M. Jevtić, “Hybrid GSA-SQP algorithm for optimal coordination of directional overcurrent relays,” *IET Generation, Transmission & Distribution*, c. 10, sayı 8, ss. 1928-1937, 2016.
- [181] R. Corrêa, Jr. G. Cardoso, O. C. de Araújo ve L. Mariotto, “Online coordination of directional overcurrent relays using binary integer programming,” *Electric Power Systems Research*, c. 127, ss. 118-125, 2015.
- [182] W. Zhao, L. Wang ve Z. Zhang , “Atom search optimization and its application to solve a hydrogeologic parameter estimation problem,” *Knowledge Based System*, c. 163, ss. 283–304, 2019.
- [183] A. Yadav, “AEFA: Artificial electric field algorithm for global optimization,” *Swarm and Evolutionary Computation*, c. 48, ss. 93-108, 2019.
- [184] T. Amraee, “Coordination of directional overcurrent relays using seeker algorithm,” *IEEE Transactions on Power Delivery*, c.27, sayı 3, ss. 1415–1422, 2012.
- [185] M. Singh, B. K. Panigrahi, A. R. Abhyankar ve S. Das, “Optimal coordination of directional over-current relays using informative differential evolution algorithm,” *Journal of Computational Science*, c. 5, sayı 2, ss. 269–276, 2014.
- [186] R. Mohammadi, H. A. Abyaneh, H. M. Rudsari, S. H. Fathi ve H. Rastegar, “Overcurrent relays coordination considering the priority of constraints,” *IEEE Transactions on Power Delivery*, c. 26, sayı 3, ss. 1927-1938, 2011.



10.EKLER

10.1. EK 1 KLASİK TEST PROBLEMLERİ

Çizelge 10.1. Klasik test fonksiyonları[19].

Fonksiyon Tipi	Fonksiyon	Arama Uzayı	Minimum
Çok-modlu	Ackley	$[-100, 100]$	0
Çok-modlu	Alpine	$[-100, 100]$	0
Tek-modlu	Cigar	$[-100, 100]$	0
Tek-modlu	DixonPrice	$[-10, 10]$	0
Tek-modlu	Elliptic	$[-100, 100]$	0
Çok-modlu	Exponential	$[-10, 10]$	0
Çok-modlu	Griewank	$[-600, 600]$	0
Çok-modlu	I.C.M.	$[-100, 100]$	0
Çok-modlu	Levy	$[-10, 10]$	0
Çok-modlu	Michalewicz	$[0, \pi]$	0
Çok-modlu	Penalized-1	$[-50, 50]$	0
Çok-modlu	Penalized-1	$[-50, 50]$	0
Tek-modlu	Powell	$[-4, 5]$	0
Çok-modlu	Rastrigin	$[-100, 100]$	0
Çok-modlu	Rosenbrock	$[-10, 10]$	0
Tek-modlu	R.H.E.	$[-100, 100]$	0
Çok-modlu	Salomon	$[-100, 100]$	0
Çok-modlu	Schaffer	$[-100, 100]$	0
Tek-modlu	Schwefel	$[-500, 500]$	0
Tek-modlu	Schwefel 1.20	$[-100, 100]$	0
Tek-modlu	Schwefel 2.21	$[-100, 100]$	0
Tek-modlu	Schwefel 2.22	$[-10, 10]$	0
Tek-modlu	Sphere	$[-100, 100]$	0
Tek-modlu	Step	$[-100, 100]$	0
Çok-modlu	Styblinski-Tang	$[-5, 5]$	0
Çok-modlu	SumPower	$[-10, 10]$	0
Tek-modlu	SumSquares	$[-10, 10]$	0
Tek-modlu	Quartic	$[-10, 10]$	0
Çok-modlu	Weierstrass	$[-1, 1]$	0
Çok-modlu	Zakharov	$[-5, 10]$	0

10.2. EK 2 IEEE CEC 2014

Çizelge 10.2. CEC 2014 test fonksiyonları [104].

Fonksiyon Tipi	Fonksiyon No	Fonksiyon	Global Optimum
Tek-modlu	1	Döndürülmüş Yüksek Koşullu Elliptic Fonksiyon	100
	2	Döndürülmüş Bent Cigar Fonksiyonu	200
	3	Döndürülmüş Discus Fonksiyonu	300
Çok-modlu	4	Kaydırılmış ve Döndürülmüş Rosenbrock Fonksiyonu	400
	5	Kaydırılmış ve Döndürülmüş Ackley Fonksiyonu	500
	6	Kaydırılmış ve Döndürülmüş Weierstrass Fonksiyonu	600
	7	Kaydırılmış ve Döndürülmüş Griewank Fonksiyonu	700
	8	Kaydırılmış Rastrigin Fonksiyonu	800
	9	Kaydırılmış ve Döndürülmüş Rastrigin Fonksiyonu	900
	10	Kaydırılmış Schwefel Fonksiyonu	1000
	11	Kaydırılmış ve Döndürülmüş Schwefel Fonksiyonu	1100
	12	Kaydırılmış ve Döndürülmüş Katsuura Fonksiyonu	1200
	13	Kaydırılmış ve Döndürülmüş HappyCat Fonksiyonu	1300
	14	Kaydırılmış ve Döndürülmüş HGBat Fonksiyonu	1400
	15	Kaydırılmış ve Döndürülmüş Genişletilmiş Griewank+ Rosenbrock Fonksiyonu	1500
	16	Kaydırılmış ve Döndürülmüş Genişletilmiş Scaffer F6 Fonksiyonu	1600
Hibrit	17	Hibrit Fonksiyon 1 (N=3)	1700
	18	Hibrit Fonksiyon 2 (N=3)	1800
	19	Hibrit Fonksiyon 3 (N=4)	1900
	20	Hibrit Fonksiyon 4 (N=4)	2000
	21	Hibrit Fonksiyon 5 (N=5)	2100
	22	Hibrit Fonksiyon 6 (N=5)	2200
Kompozisyon	23	Kompozisyon Fonksiyon 1 (N=5)	2300
	24	Kompozisyon Fonksiyon 2 (N=3)	2400
	25	Kompozisyon Fonksiyon 3 (N=3)	2500
	26	Kompozisyon Fonksiyon 4 (N=5)	2600
	27	Kompozisyon Fonksiyon 5 (N=5)	2700
	28	Kompozisyon Fonksiyon 6 (N=5)	2800
	29	Kompozisyon Fonksiyon 7 (N=3)	2900
	30	Kompozisyon Fonksiyon 8 (N=3)	3000
Arama Uzayı: [-100, 100] ^P			

10.3. EK 3 IEEE CEC 2017

Çizelge 10.3. CEC 2017 test fonksiyonları [85, 102].

Fonksiyon Tipi	Fonksiyon No	Fonksiyon	Global Optimum
Tek-modlu	1	Kaydırılmış ve Döndürülmüş Bent Cigar Fonksiyonu	100
	2	Farklı Güç Fonksiyonunun Kaydırılmış ve Döndürülmüş Toplamı	200
	3	Kaydırılmış ve Döndürülmüş Zakharov Fonksiyonu	300
Çok-modlu	4	Kaydırılmış ve Döndürülmüş Rosenbrock Fonksiyonu	400
	5	Kaydırılmış ve Döndürülmüş Rastrigin Fonksiyonu	500
	6	Kaydırılmış ve Döndürülmüş Genişletilmiş Scaffer F6 Fonksiyonu	600
	7	Kaydırılmış ve Döndürülmüş Lunacek Bi_Rastrigin Fonksiyonu	700
	8	Kaydırılmış ve Döndürülmüş Sürekli Olmayan Rastrigin Fonksiyonu	800
	9	Kaydırılmış ve Döndürülmüş Levy Fonksiyonu	900
	10	Kaydırılmış ve Döndürülmüş Schwefel Fonksiyonu	1000
Hibrit	11	Zakharov, Rosenbrock ve Rastrigin Hibrit Fonksiyonu	1100
	12	Yüksek Koşullu Elliptic, Modifiye Schwefel ve Bent Cigar Hibrit Fonksiyonu	1200
	13	Bent Cigar, Rosenbrock ve Lunache Bi-Rastrigin Hibrit Fonksiyonu	1300
	14	Elliptic, Ackley, Schaffer ve Rastrigin Hibrit Fonksiyonu	1400
	15	Bent Cigar, HGBat, Rastrigin ve Rosenbrock Hibrit Fonksiyonu	1500
	16	Genişletilmiş Schaffer, HGBat, Rosenbrock ve Modifiye Schwefel Hibrit Fonksiyonu	1600
	17	Katsuura, Ackley, Genişletilmiş Griewank ve Rosenbrock, Modifiye Schwefel ve Rastrigin Hibrit Fonksiyonu	1700
	18	Yüksek koşullu Elliptic, Ackley, Rastrigin, HGBat ve Discus Hibrit Fonksiyonu	1800
	19	Bent Cigar, Rastrigin, Genişletilmiş Griewank ve Rosenbrock, Weierstrass ve genişletilmiş Schaffer Hibrit Fonksiyonu	1900
	20	Happycat, Katsuura, Ackley, Rastrigin, Modifiye Schwefel ve Schaffer Hibrit Fonksiyonu	2000

Çizelge 10.3. (devam) CEC 2017 test fonksiyonları [85, 102].

Kompozisyon	21	Rosenbrock, Yüksek Koşullu Elliptic ve Rastrigin Kompozisyon Fonksiyonu	2100
	22	Rastrigin, Griewank ve Modifiye Schwefel Kompozisyon Fonksiyonu	2200
	23	Rosenbrock, Ackley, Modifiye Schwefel ve Rastrigin Kompozisyon Fonksiyonu	2300
	24	Ackley, Yüksek Koşullu Elliptic, Griewank ve Rastrigin Kompozisyon Fonksiyonu	2400
	25	Rastrigin, HappyCat, Ackley, Discus ve Rosenbrock Kompozisyon Fonksiyonu	2500
	26	Genişletilmiş Scaffer, Modifiye Schwefel, Griewank, Rosenbrock ve Rastrigin Kompozisyon Fonksiyonu	2600
	27	HGBat, Rastrigin, Modifiye Schwefel, Bent Cigar, Yüksek Koşullu Elliptic ve Genişletilmiş Scaffer Kompozisyon Fonksiyonu	2700
	28	Ackley, Griewank, Discus, Rosenbrock, HappyCat, Genişletilmiş Scaffer Kompozisyon Fonksiyonu	2800
	29	Kaydırılmış ve Döndürülmüş Rastrigin, Genişletilmiş Schaffer ve Lunacek Bi_Rastrigin Kompozisyon Fonksiyonu	2900
	30	Kaydırılmış ve döndürülmüş Rastrigin, Sürekli Olmayan Rastrigin ve Levy Kompozisyon Fonksiyonu	3000
Arama Uzayı: [-100, 100] ^D			

10.4. EK 4 IEEE CEC 2020

Çizelge 10.4. CEC 2020 test fonksiyonları [103].

Fonksiyon Tipi	Fonksiyon No	Fonksiyon	Global Optimum
Tek-modlu	1	Kaydırılmış ve Döndürülmüş Bent Cigar Fonksiyonu	100
Çok-modlu	2	Kaydırılmış ve Döndürülmüş Schwefel Fonksiyonu	1100
	3	Kaydırılmış ve Döndürülmüş Lunacek Bi-Rastrigin Fonksiyonu	700
	4	Genişletilmiş Rosenbrock ve Griewangk Fonksiyonu	1900
Hibrit	5	Hibrit Fonksiyon 1 (N=3)	1700
	6	Hibrit Fonksiyon 2 (N=4)	1600
	7	Hibrit Fonksiyon 3 (N=5)	2100
Kompozisyon	8	Kompozisyon Fonksiyon 1 (N=3)	2200
	9	Kompozisyon Fonksiyon 2 (N=4)	2400
	10	Kompozisyon Fonksiyon 3 (N=5)	2500
Arama Uzayı: [-100, 100] ^P			

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Hüseyin BAKIR

Yabancı Dili : İngilizce

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Doktora	Elektrik-Elektronik Müh.	Düzce Üniversitesi	2022
Y. Lisans	Elektrik Elektronik Müh.	Düzce Üniversitesi	2017
Lisans	Elektrik Elektronik Müh.	Düzce Üniversitesi	2015
Lise	Matematik-Fen	Bingöl Erdem Lisesi	2009

YAYINLAR

- 1) Kahraman, H. T., **Bakir, H.**, Duman, S., Katı, M., Aras, S., & Guvenc, U. (2021). Dynamic FDB selection method and its application: modeling and optimizing of directional overcurrent relays coordination. *Applied Intelligence*, 1-36.