



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

DOKTORA TEZİ

**METASEZGİSEL OPTİMİZASYON ALGORİTMALARIYLA
FOTOVOLTAİK MODELLERDE PARAMETRE TAHMİNİ VE
PERFORMANS KARŞILAŞTIRILMASI**

Süleyman DAL

**Mart-2025
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİLİĞİ ANA BİLİM DALI**

DOKTORA TEZİ

**METASEZGİSEL OPTİMİZASYON ALGORİTMALARIYLA
FOTOVOLTAİK MODELLERDE PARAMETRE TAHMİNİ VE
PERFORMANS KARŞILAŞTIRILMASI**

Süleyman DAL

**Danışman
Prof. Dr. Necmettin SEZGİN**

Diğer Jüri Üyeleri

**Doç. Dr. Melih KUNCAN Doç. Dr. Yılmaz KAYA Doç. Dr. Fatma KUNCAN
Dr. Öğr. Abdülkerim ÖZTEKİN**

**Mart-2025
BATMAN**

TEZ KABUL VE ONAYI

Süleyman DAL tarafından hazırlanan “Metasezgisel Optimizasyon Algoritmalarıyla Fotovoltaik Modellerde Parametre Tahmini ve Performans Karşılaştırılması” adlı tez çalışması 21/03/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Melih KUNCAN

.....

Danışman

Prof. Dr. Necmettin SEZGİN

.....

Üye

Doç. Dr. Yılmaz KAYA

.....

Üye

Doç. Dr. Fatma KUNCAN

.....

Üye

Dr. Öğr. Üyesi Abdülkerim ÖZTEKİN

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

Süleyman DAL
21.03.2025

ÖZET

DOKTORA TEZİ

METASEZGİSEL OPTİMİZASYON ALGORİTMALARIYLA FOTOVOLTAİK MODELLERDE PARAMETRE TAHMİNİ VE PERFORMANS KARŞILAŞTIRILMASI

Süleyman DAL

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Prof. Dr. Necmettin SEZGİN

2025, 125 Sayfa

Güneş enerjisi, yenilenebilir enerji kaynakları arasında sürdürülebilirliği ve geniş uygulama potansiyeli nedeniyle önemli bir yer tutmaktadır. Bu enerji kaynağının en verimli şekilde kullanılabilmesi için fotovoltaik (PV) sistemlerin performansını etkileyen parametrelerin doğru ve güvenilir bir şekilde tahmin edilmesi kritik bir rol oynamaktadır. PV parametre tahmini, güneş panellerinin elektriksel karakteristiklerinin hassas bir şekilde belirlenmesini sağlayarak sistem verimliliğini artırmakta ve enerji üretim süreçlerini optimize etmektedir. Bu bağlamda, PV sistemlerde kullanılan elektriksel modellerin doğruluğu, sistem tasarımı ve performans iyileştirme açısından hayati bir öneme sahiptir. Bu tez çalışmasında, PV hücre parametrelerinin tahmini için yeni ve etkili meta-sezgisel optimizasyon algoritmaları önerilmiştir. Önerilen yaklaşımlar, vektörlerin ağırlıklı ortalaması (INFO), ikinci dereceden interpolasyon optimizasyonu (QIO) ve boyunlu kertenkele optimizasyonu (FLO) algoritmalarıdır. Ayrıca, bu algoritmalara, PV sistemlerin doğrusal olmayan akım-gerilim karakteristiklerini daha hassas bir şekilde belirlemek için Newton-Raphson (N-R) analitik yöntemi ile entegre edilerek optimizasyon performansları artırılmıştır.

Tez kapsamında, önerilen algoritmaların etkinliği ve doğruluğu, farklı veri setleri üzerinde test edilerek değerlendirilmiştir. R.T.C France, Photowatt-PWP201, STM6-40/36 ve STP6-120/36 veri setleri kullanılarak, tek diyot, çift diyot ve üç diyot elektriksel devre modelleriyle geniş kapsamda analizler gerçekleştirilmiştir. İlgili modellerin etkinliği, bireysel mutlak hata, bağlı hata, ortalama mutlak hata, ortalama yanlışlık hatası, normalleştirilmiş RMSE, normalleştirilmiş MBE, normalleştirilmiş MAE, belirleme katsayısı ve t-istatistiği gibi çeşitli hata metrikleri kullanılarak detaylı bir şekilde karşılaştırılmıştır. Ayrıca, elde edilen akım-gerilim ve güç-gerilim karakteristik eğrileri, yakınsama eğrileri, maksimum güç noktaları ve istatistiksel metrikler ile değerlendirilerek algoritmaların performansları derinlemesine incelenmiştir. Elde edilen bulgular, INFO, QIO ve FLO algoritmalarının literatürde önerilen meta-sezgisel optimizasyon yöntemlerine kıyasla belirgin avantajlar sunduğunu ortaya koymuştur. Bu algoritmalar, PV sistem performansını optimize etmede yüksek hassasiyet, hızlı yakınsama ve stabil sonuçlar sağlayarak endüstriyel ve akademik kullanım potansiyelini güçlendirmektedir. Özellikle, optimize edilen parametre tahmini sayesinde, PV sistemlerin enerji dönüşüm verimliliğinin artırılacağı ve gerçek dünya uygulamalarında daha etkili bir şekilde kullanılabileceği gösterilmiştir.

Anahtar Kelimeler: Yenilebilir Enerji, Fotovoltaik Sistemler, Parametre Tahmini, Metasezgisel Optimizasyon Algoritmaları.

ABSTRACT

DOCTORAL THESIS

PARAMETER ESTIMATION AND PERFORMANCE COMPARISON IN PHOTOVOLTAIC MODELS USING METAHEURISTIC OPTIMIZATION ALGORITHMS

Süleyman DAL

Batman University Graduate Education Institute

Department of Electrical and Electronics Engineering

Advisor: Prof. Dr. Necmettin SEZGİN

2025, 125 Pages

Solar energy has an important place among renewable energy sources due to its sustainability and wide application potential. For the most efficient utilisation of this energy source, accurate and reliable estimation of the parameters affecting the performance of photovoltaic (PV) systems plays a critical role. PV parameter estimation enables precise determination of the electrical characteristics of solar panels, improving system efficiency and optimising power generation processes. In this regard, electrical models used in PV systems have a vital importance in terms of accuracy, system design and performance improvement. In this thesis, new and efficient meta-heuristic optimisation algorithms are proposed for the estimation of PV cell parameters. The proposed approaches are the weighted mean of vectors (INFO), quadratic interpolation optimisation (QIO) and frilled lizard optimisation (FLO) algorithms. Furthermore, these algorithms are integrated with the Newton-Raphson (N-R) analytical method to determine the nonlinear current-voltage characteristics of PV systems more precisely, thus improving their optimisation performance.

In this thesis, the effectiveness and accuracy of the proposed algorithms are evaluated by testing them on different data sets. Using R.T.C France, Photowatt-PWP201, STM6-40/36 and STP6-120/36 data sets, a wide range of analyses were performed with single diode, double diode and three diode electrical circuit models. The effectiveness of the respective models was compared in detail using various error metrics such as individual absolute error, relative error, mean absolute error, mean bias error, normalised RMSE, normalised MBE, normalised MAE, coefficient of determination and t-statistic. In addition, the performance of the algorithms is analysed in depth by evaluating the obtained current-voltage and power-voltage characteristic slopes, convergence slopes, maximum power points and statistical metrics. The results show that INFO, QIO and FLO algorithms offer significant advantages compared to the meta-heuristic optimisation methods proposed in the literature. These algorithms provide high precision, fast convergence and stable results in optimising PV system performance, strengthening their potential for industrial and academic use. Especially, it is shown that by optimised parameter estimation, the energy conversion efficiency of PV systems can be improved and used more effectively in real world applications.

Keywords: Renewable Energy, Photovoltaic Systems, Parameter Estimation, Metaheuristic Optimization Algorithms.

ÖNSÖZ

Doktora öğrenim sürecim boyunca bilgi birikimi, akademik rehberliği ve samimi desteğiyle bana yol gösteren; araştırma ve çalışma azmimi daima teşvik eden, engin tecrübeleriyle akademik gelişimime büyük katkılar sunan çok değerli danışmanım Sayın Prof. Dr. Necmettin SEZGİN'e en içten teşekkürlerimi ve saygılarımı sunarım. Gerek akademik yönlendirmeleriyle gerekse anlayışlı yaklaşımıyla bu süreci daha verimli ve anlamlı kıldığı için kendisine minnettarım.

Bu süreçte doğrudan ya da dolaylı katkılarıyla yanımda olan, isimlerini tek tek anamasam da desteğini ve varlığını hissettiren kıymetli dostlarıma ve değerli hocalarıma gönülden teşekkür ederim. Akademik yolculuğumda bana eşlik eden bu değerli insanların katkıları, bu çalışmanın oluşumunda önemli bir yere sahiptir.

Bu akademik yolculukta, manevi destekleriyle her daim yanımda olan, sabırları, sevgileri ve dualarıyla bana güç veren değerli aileme; özellikle fedakârlıklarıyla bu sürecin her anında yanımda olduklarını hissettiren sevgili anne ve babama, kardeşlerime en derin şükranlarımı sunarım.

.

Süleyman DAL
BATMAN-2025

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
TABLolar LİSTESİ	ix
ŞEKİLLER LİSTESİ	xi
SİMGELER VE KISALTMALAR	xiv
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	8
3. FOTOVOLTAİK SİSTEMLER VE ÖZELLİKLERİ	15
3.1. PV Hücresi Malzemeleri ve Performansı Üzerindeki Etkisi	17
3.2. Fotovoltaik Hücrelerin Modelleme Yöntemleri	19
4. FOTOVOLTAİK MODÜLDE PARAMETRE TAHMİNİ	22
4.1. Matematiksel Formülasyon.....	24
4.1.1. Tek diyot modeli (1-D)	25
4.1.2. Çift diyot modeli (2-D)	26
4.1.3. Üç diyot modeli (3-D).....	28
4.2. Amaç Fonksiyonu ve Performans Metrikleri.....	29
4.3. Meta-Sezgisel Yöntem Tabanlı Güneş Fotovoltaik Parametre Tahmini	31
5. FOTOVOLTAİK HÜCREDE PARAMETRE TAHMİNİ İÇİN FARKLI META-SEZGİSEL ALGORTİMALAR	32
5.1 Vektörlerin Ağırlıklı Ortalaması (INFO) Algoritması.....	32
5.1.1. Güncelleme kuralı.....	33
5.1.2. Vektör birleştirme	35
5.1.3. Yerel arama.....	36
5.2 İkinci Dereceden Enterpolasyon Optimizasyonu (QIO).....	38
5.2.1. Güncelleme kuralı.....	40
5.2.2 Vektör birleştirme	41
5.2.3 Yerel arama.....	41
5.3 Boyunlu Kertenkele Optimizasyonu (FLO)	42
5.3.1 Keşif aşaması	43
5.3.2 Sömürü aşaması	44
5.4 Önerilen Algoritmalara Newton-Raphson Yönteminin Entegrasyonu	45
6. SİMÜLASYON SONUÇLARI VE TARTIŞMA	48

6.1 Simülasyon Sonuçları	48
6.1.1 R.T.C France veri setiyle elde edilen sonuçlar	49
6.1.2 Photowatt-PWP201 veri setiyle elde edilen sonuçlar	68
6.1.3 STM6-40/36 veri setiyle elde edilen sonuçlar	83
6.1.4 STP6-120/36 veri setiyle elde edilen sonuçlar	97
6.2 Tartışma	108
7. SONUÇ VE ÖNERİLER.....	110
7.1 Sonuç	110
7.2 Öneriler	111
KAYNAKLAR	112

TABLolar LİSTESİ

Tablo 2.1. Kaynak araştırması	13
Tablo 3.1. Güneş hücresi malzeme sınıflandırması (Makarova, 2017)	19
Tablo 6.1. Parametre sınır değerleri.....	49
Tablo 6.2. INFO, QIO ve FLO'dan elde edilen sonuçların RTC (1-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması	50
Tablo 6.3. RTC veri seti için 1-D modeline ait ölçülen ve tahmin edilen akım verileri	53
Tablo 6.4. RTC veri seti için 1-D modeline ait ölçülen ve tahmin edilen güç verileri...	54
Tablo 6.5. INFO, QIO ve FLO'dan elde edilen sonuçların RTC (2-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması	55
Tablo 6.6. RTC veri seti için 2-D modeline ait ölçülen ve tahmin edilen akım verileri	58
Tablo 6.7. RTC veri seti için 2-D modeline ait ölçülen ve tahmin edilen güç verileri...	59
Tablo 6.8. INFO, QIO ve FLO'dan elde edilen sonuçların RTC (3-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması	60
Tablo 6.9. RTC veri seti için 3-D modeline ait ölçülen ve tahmin edilen akım verileri	63
Tablo 6.10. RTC veri seti için 3-D modeline ait ölçülen ve tahmin edilen güç verileri.	64
Tablo 6.11. 1-D, 2-D ve 3-D modelleri için önerilen algoritmalarla elde edilen RMSE değerlerine ait istatistiksel sonuçlar (RTC)	66
Tablo 6.12. RTC veri setinde 1-D, 2-D ve 3-D için istatistiksel hata oranları	67
Tablo 6.13. INFO, QIO ve FLO'dan elde edilen sonuçların PWP201 (1-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması.	68
Tablo 6.14. PWP201 veri seti için 1-D modeline ait ölçülen ve tahmin edilen akım verileri.....	72
Tablo 6.15. PWP201 veri seti için 1-D modeline ait ölçülen ve tahmin edilen güç verileri.....	72
Tablo 6.16. INFO ve QIO'dan elde edilen sonuçların PWP201 (2-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması	73
Tablo 6.17. PWP201 veri seti için 2-D modeline ait ölçülen ve tahmin edilen akım verileri.....	76
Tablo 6.18. PWP201 veri seti için 2-D modeline ait ölçülen ve tahmin edilen güç verileri.....	76
Tablo 6.19. INFO'dan elde edilen sonuçların PWP201 (3-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması	77
Tablo 6.20. PWP201 veri seti için 3-D modeline ait ölçülen ve tahmin edilen akım verileri.....	80
Tablo 6.21. PWP201 veri seti için 3-D modeline ait ölçülen ve tahmin edilen güç verileri.....	80
Tablo 6.22. 1-D, 2-D ve 3-D modelleri için önerilen algoritmalarla elde edilen RMSE değerlerine ait istatistiksel sonuçlar (PWP201).....	81
Tablo 6.23. PWP201 veri setinde 1-D, 2-D ve 3-D için istatistiksel hata oranları.....	83
Tablo 6.24. INFO, QIO ve FLO'dan elde edilen sonuçların STM6-40/36 (1-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması.	83
Tablo 6.25. STM6 veri seti için 1-D modeline ait ölçülen ve tahmin edilen akım verileri	87
Tablo 6.26. STM6 veri seti için 1-D modeline ait ölçülen ve tahmin edilen güç verileri	87
Tablo 6.27. INFO ve QIO'dan elde edilen sonuçların STM6-40/36 (2-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması.	88

Tablo 6.28. STM6 veri seti için 2-D modeline ait ölçülen ve tahmin edilen akım verileri	90
Tablo 6.29. STM6 veri seti için 2-D modeline ait ölçülen ve tahmin edilen güç verileri	91
Tablo 6.30. INFO ve QIO'dan elde edilen sonuçların STM6-40/36 (3-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması	91
Tablo 6.31. STM6 veri seti için 3-D modeline ait ölçülen ve tahmin edilen akım verileri	94
Tablo 6.32. STM6 veri seti için 3-D modeline ait ölçülen ve tahmin edilen güç verileri	94
Tablo 6.33. 1-D, 2-D ve 3-D modelleri için önerilen algoritmalarla elde edilen RMSE değerlerine ait istatistiksel sonuçlar (STM6)	95
Tablo 6.34. STM40-36 veri setinde 1-D, 2-D ve 3-D için istatistiksel hata oranları	96
Tablo 6.35. INFO ve QIO'dan elde edilen sonuçların STP6-120/36 (1-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması	97
Tablo 6.36. INFO ve QIO'dan elde edilen sonuçların STP6-120/36 (2-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması	98
Tablo 6.37. INFO ve QIO'dan elde edilen sonuçların STP6-120/36 (3-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması	98
Tablo 6.38. STP veri seti için 1-D modeline ait ölçülen ve tahmin edilen akım verileri	104
Tablo 6.39. STP veri seti için 1-D modeline ait ölçülen ve tahmin edilen güç verileri	104
Tablo 6.40. STP veri seti için 2-D modeline ait ölçülen ve tahmin edilen akım verileri	105
Tablo 6.41. STP veri seti için 2-D modeline ait ölçülen ve tahmin edilen güç verileri	105
Tablo 6.42. STP veri seti için 3-D modeline ait ölçülen ve tahmin edilen akım verileri	106
Tablo 6.43. STP veri seti için 3-D modeline ait ölçülen ve tahmin edilen güç verileri	106
Tablo 6.44. 1-D, 2-D ve 3-D modelleri için önerilen algoritmalarla elde edilen RMSE değerlerine ait istatistiksel sonuçlar (STP)	107
Tablo 6.45. STP120-36 veri setinde 1-D, 2-D ve 3-D için istatistiksel hata oranları	108

ŞEKİLLER LİSTESİ

Şekil 3.1. PV hücrenin yapısı.....	16
Şekil 3.2. PV hücrenin çalışma ilkesi	16
Şekil 3.3. PV hücre, modül ve dizi	17
Şekil 3.4. 1-D, 2-D ve 3-D PV modelleri	21
Şekil 4.1. PV hücrede parametre tahmini	22
Şekil 4.2. PV Parametre Çıkarımında Kullanılan Bazı Meta-Sezgisel Algoritmaların Sınıflandırılması.....	24
Şekil 4.3. 1-D model	25
Şekil 4.4. 2-D model	27
Şekil 4.5. 3-D model	28
Şekil 5.1. INFO algoritmasının akış diyagramı	37
Şekil 5.2. Kuadratik enterpolasyonun şematik gösterimi (Zhao vd., 2023)	40
Şekil 5.3. QIO algoritmasının akış diyagramı	42
Şekil 5.4. FLO algoritmasının akış diyagramı	45
Şekil 5.5. Önerilen algoritmalar doğrultusunda Newton-Raphson yönteminin entegrasyonu ile RMSE hesaplama prosedürü	47
Şekil 6.1. INFO algoritmasıyla 1-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	50
Şekil 6.2. QIO algoritmasıyla 1-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	51
Şekil 6.3. FLO algoritmasıyla 1-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	51
Şekil 6.4. RTC veri seti için INFO algoritmasına ait 1-D modeli yakınsama eğrisi	52
Şekil 6.5. RTC veri seti için QIO algoritmasına ait 1-D modeli yakınsama eğrisi	52
Şekil 6.6. RTC veri seti için FLO algoritmasına ait 1-D modeli yakınsama eğrisi	53
Şekil 6.7. INFO algoritmasıyla 2-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	55
Şekil 6.8. QIO algoritmasıyla 2-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	56
Şekil 6.9. FLO algoritmasıyla 2-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	56
Şekil 6.10. RTC veri seti için INFO algoritmasına ait 2-D modeli yakınsama eğrisi	57
Şekil 6.11. RTC veri seti için QIO algoritmasına ait 2-D modeli yakınsama eğrisi	57
Şekil 6.12. RTC veri seti için FLO algoritmasına ait 2-D modeli yakınsama eğrisi	58
Şekil 6.13. INFO algoritmasıyla 3-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	60
Şekil 6.14. QIO algoritmasıyla 3-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	61
Şekil 6.15. FLO algoritmasıyla 3-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	61
Şekil 6.16. RTC veri seti için INFO algoritmasına ait 3-D modeli yakınsama eğrisi	62
Şekil 6.17. RTC veri seti için QIO algoritmasına ait 3-D modeli yakınsama eğrisi	62
Şekil 6.18. RTC veri seti için FLO algoritmasına ait 3-D modeli yakınsama eğrisi	63
Şekil 6.19. INFO algoritması ile tüm çalıştırmaların (30) istatistiksel RMSE dağılım grafikleri (RTC) : (a) 1-D, (b) 2-D, (c) 3-D	66
Şekil 6.20. QIO algoritması ile tüm çalıştırmaların (30) istatistiksel RMSE dağılım grafikleri (RTC) : (a) 1-D, (b) 2-D, (c) 3-D	66

Şekil 6.21. FLO algoritması ile tüm çalıştırmaların (30) istatistiksel RMSE dağılım grafikleri (RTC) : (a) 1-D, (b) 2-D, (c) 3-D.....	67
Şekil 6.22. INFO algoritmasıyla 1-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	69
Şekil 6.23. QIO algoritmasıyla 1-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	69
Şekil 6.24. FLO algoritmasıyla 1-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	70
Şekil 6.25. PWP201 veri seti için INFO algoritmasına ait 1-D modeli yakınsama eğrisi	70
Şekil 6.26. PWP201 veri seti için QIO algoritmasına ait 1-D modeli yakınsama eğrisi	71
Şekil 6.27. PWP201 veri seti için FLO algoritmasına ait 1-D modeli yakınsama eğrisi	71
Şekil 6.28. INFO algoritmasıyla 2-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	74
Şekil 6.29. QIO algoritmasıyla 2-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	74
Şekil 6.30. PWP201 veri seti için INFO algoritmasına ait 2-D modeli yakınsama eğrisi	75
Şekil 6.31. PWP201 veri seti için QIO algoritmasına ait 2-D modeli yakınsama eğrisi	75
Şekil 6.32. INFO algoritmasıyla 3-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	78
Şekil 6.33. QIO algoritmasıyla 3-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	78
Şekil 6.34. PWP201 veri seti için INFO algoritmasına ait 3-D modeli yakınsama eğrisi	79
Şekil 6.35. PWP201 veri seti için QIO algoritmasına ait 3-D modeli yakınsama eğrisi	79
Şekil 6.36. INFO algoritması ile tüm çalıştırmaların (30) istatistiksel RMSE dağılım grafikleri (PWP201) : (a) 1-D, (b) 2-D, (c) 3-D	82
Şekil 6.37. QIO algoritması ile tüm çalıştırmaların (30) istatistiksel RMSE dağılım grafikleri (PWP201) : (a) 1-D, (b) 2-D, (c) 3-D	82
Şekil 6.38. INFO algoritmasıyla 1-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	84
Şekil 6.39. QIO algoritmasıyla 1-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	84
Şekil 6.40. FLO algoritmasıyla 1-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	85
Şekil 6.41. STM6 veri seti için INFO algoritmasına ait 1-D modeli yakınsama eğrisi..	85
Şekil 6.42. STM6 veri seti için QIO algoritmasına ait 1-D modeli yakınsama eğrisi....	86
Şekil 6.43. STM6 veri seti için FLO algoritmasına ait 1-D modeli yakınsama eğrisi....	86
Şekil 6.44. INFO algoritmasıyla 2-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	89
Şekil 6.45. QIO algoritmasıyla 2-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	89
Şekil 6.46. STM6 veri seti için INFO algoritmasına ait 2-D modeli yakınsama eğrisi..	89
Şekil 6.47. STM6 veri seti için QIO algoritmasına ait 2-D modeli yakınsama eğrisi....	90
Şekil 6.48. INFO algoritmasıyla 3-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	92
Şekil 6.49. QIO algoritmasıyla 3-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	92
Şekil 6.50. STM6 veri seti için INFO algoritmasına ait 3-D modeli yakınsama eğrisi..	93

Şekil 6.51. STM6 veri seti için QIO algoritmasına ait 3-D modeli yakınsama eğrisi	93
Şekil 6.52. INFO algoritması ile tüm çalıştırmaların (30) istatistiksel RMSE dağılım grafikleri (STM6) : (a) 1-D, (b) 2-D, (c) 3-D	96
Şekil 6.53. QIO algoritması ile tüm çalıştırmaların (30) istatistiksel RMSE dağılım grafikleri (STM6) : (a) 1-D, (b) 2-D, (c) 3-D	96
Şekil 6.54. INFO algoritmasıyla 1-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	98
Şekil 6.55. QIO algoritmasıyla 1-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	98
Şekil 6.56. INFO algoritmasıyla 2-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	99
Şekil 6.57. QIO algoritmasıyla 2-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	99
Şekil 6.58. INFO algoritmasıyla 3-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	99
Şekil 6.59. QIO algoritmasıyla 3-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)	100
Şekil 6.60. STP veri seti için INFO algoritmasına ait 1-D modeli yakınsama eğrisi ...	100
Şekil 6.61. STP veri seti için QIO algoritmasına ait 1-D modeli yakınsama eğrisi	101
Şekil 6.62. STP veri seti için INFO algoritmasına ait 2-D modeli yakınsama eğrisi ...	101
Şekil 6.63. STP veri seti için QIO algoritmasına ait 2-D modeli yakınsama eğrisi	102
Şekil 6.64. STP veri seti için INFO algoritmasına ait 3-D modeli yakınsama eğrisi ...	102
Şekil 6.65. STP veri seti için QIO algoritmasına ait 3-D modeli yakınsama eğrisi	103
Şekil 6.66. INFO algoritması ile tüm çalıştırmaların (30) istatistiksel RMSE dağılım grafikleri (STP) : (a) 1-D, (b) 2-D, (c) 3-D.....	107
Şekil 6.67. QIO algoritması ile tüm çalıştırmaların (30) istatistiksel RMSE dağılım grafikleri (STP) : (a) 1-D, (b) 2-D, (c) 3-D.....	107

SİMGELER VE KISALTMALAR

Simgeler

a : Diyot ideallik faktörü
 c : Sabit sayı
 CA : Yakınsama hızlandırma
 D : Diyot
 ε : Sabit sayı
 F_l : Mevcut pozisyonun hedef fonksiyonu
 $F_{i,j}^*$: Yeni pozisyonun hedef fonksiyonu
 g^{th} : Popülasyon büyüklüğü
 I_0 : Doygunluk akımı
 I_d : Diyot akımı
 I_{ph} : Fotogenerik akım
 I_{sh} : Şönt direncin akımı
 I_t : Tahmin edilen akım
 $I_{\bar{o}}$: Ölçülen akım
 I_{sc} : Kısa devre akımı
 I_{mpp} : Maksimum güç noktası akımı
 $I_{i,j}$: Diğer bireylerin etkisini belirleyen faktör
 k : Boltzmann sabiti
 $L(x)$: İkinci dereceden interpolasyon polinomu
 L_{best} : Bulunan en kötü çözüm
MeanRule : Ortalama kuralı
 $maxg$: Maksimum jenerasyon sayısı
 N : Örnek sayısı
 N_p : Vektör popülasyonu
 p : Rastgele seçilen değer
 $P_{\bar{o}}$: Ölçülen güç
 P_t : Tahmin edilen güç
 q : Elektron yükü
 $randn$: Rastgele bir değer
 r : Rastgele seçilen sayı
 $r_{i,j}$: Rastgele bir faktör
 R_s : Seri direnç
 R_{sh} : Şönt direnç
 $SP_{i,j}$: Hedef pozisyon değeri
 T : Kelvin cinsinden hücre sıcaklığı
 U_{best} : Bulunan en iyi çözümü
 u_l^g : Vektör birleştirilerek elde edilen yeni vektör
 V : Çıkış gerilimi
 v_i : Oluşturulan yeni vektör
 V_{oc} : Açık devre gerilimi
 V_{mpp} : Maksimum güç noktası gerilimi
 V_t : Termal voltaj

w_1, w_2, w_3 : Vektörlerin ağırlıklı ortalamasını hesaplayan ağırlık çarpanları
 x_{bs}, x_{bt}, x_{ws} : Çözüm noktaları
 x_i : Enterpolasyonda kullanılan ilk nokta
 x_j : Popülasyonda seçilen ilk noktanın konumu
 x_k : Popülasyonda seçilen ikinci noktanın konumu
 x_{best} : Arama sürecindeki mevcut en iyi çözüm
 x_{local} : Yerel arama sırasında bulunan yeni konum
 x_{rand} : Popülasyondan rastgele seçilen bir nokta
 x_{rnd} : Yeni çözüm
 $X_{i,j}^*$: Güncellenmiş yeni pozisyon değeri
 $x_{i,j}$: Mevcut pozisyon değeri
 x_i^{new} : Güncelleme sonrasında noktanın yeni konumu
 $X_{i,j}^{(t+1)}$: İkinci aşamadaki güncellenmiş pozisyon
 $x_{i,j}$: Mevcut pozisyon değeri
 $z1_l^g, z2_l^g$: Yeni vektörler
 δ : Ortalama faktörü
 φ : Rastgele seçilen değer
 σ : Ölçeklendirme faktörü

Kısaltmalar

1-D : Tek diyot modeli
 2-D : Çift diyot modeli
 3-D : Üç diyot modeli
 ABC : Yapay arı kolonisi
 AGDE : Uyarlanabilir çoklu stratejili yönlendirme diferansiyel evrim
 AHA : Yapay sinek kuşu algoritması
 AISA : Ergen kimlik arama algoritması
 ALO : Karınca aslanı optimizasyonu
 AO : Kartal optimizasyonu
 AVOA : Afrika akbabası optimizasyon algoritması
 CIIWO : Kaos ilhamlı istilacı yabani ot optimizasyonu
 CGO-LS : Kaos oyunu optimizasyonu - En küçük kareler
 COA : Çakal optimizasyon algoritması
 CSCO : Kaotik kum kedisi optimizasyonu
 CSO : Guguk kuşu arama optimizasyonu
 CSO : Kedi sürüsü optimizasyonu
 DE : Diferansiyel evrim
 EAGT : Geliştirilmiş yapay goril sürüleri optimizasyonu
 EALO : Geliştirilmiş karınca aslanı optimizasyonu
 EJAYA : Geliştirilmiş JAYA
 EO : Denge optimizasyonu
 ER-WCA : Buharlaştırma hızına dayalı su döngüsü algoritması
 FCHHHO : Hibrit kesirli Henon kaotik Harris şahinleri optimizasyonu
 FADE : Bulanık uyarlanabilir diferansiyel evrim
 FDB : Uygunluk-mesafe dengesi
 FLO : Boyunlu kertenkele optimizasyonu
 GEO : Altın kartal optimizasyonu

GOA : Çekirge optimizasyon algoritması
HHO : Harris şahinleri optimizasyonu
IAE : Bireysel mutlak hata
IAOA : Geliştirilmiş aritmetik optimizasyon algoritması
I : Akım (A)
ICSO : Geliştirilmiş guguk kuşu arama optimizasyonu
INFO : Vektörlerin ağırlıklı ortalaması
LCS : Laplace'ın çapraz arama mekanizması
MAE : Ortalama mutlak hata
MBE : Ortalama yanlışlık hatası
MCSO : Modifiye guguk kuşu arama optimizasyonu
MPO : Deniz yırtıcıları optimizasyonu
NASA : National Aeronautics and Space Administration
NMs : Nelder-Mead simplex yöntemi
NMBE : Normalleştirilmiş MBE
NMAE : Normalleştirilmiş MAE
NRMSE : Normalleştirilmiş RMSE
N-R : Newton-Raphson
OBL : Karşıt tabanlı öğrenme
PWP-201 : Photowatt-PWP201
PSO : Parçacık sürü optimizasyonu
PV : Fotovoltaik
QIO : İkinci dereceden interpolasyon optimizasyonu
 R^2 : Belirleme katsayısı
RE : Bağlı hata
RMSE : Kök ortalama kare hata
RTLBO : Sıralama öğretme-öğrenme tabanlı optimizasyon
RSA : Sürünge arama algoritması
RTC : R.T.C France
SBLA : Yan benekli kertenkele algoritması
SCO : Tek adaylı optimizasyon
SDOA : Arz-talep tabanlı optimizasyon algoritması
SEDE : Kendi kendine uyarlanan takım tabanlı diferansiyel evrim
SMA : Yosun küfö algoritması
SNS : Sosyal ağ arama algoritması
SPGWO : Gaussian mutasyonu ve Lévy uçuşu ile gri kurt optimizasyonu
SSA : Salp sürüşü algoritması
STO : Sooty tern optimizasyon algoritması
STP6 : STP6-120/36
STM6 : STM6-40/36
TLABC : Öğretme-öğrenme tabanlı yapay arı kolonisi
TSO : Geçici arama optimizasyonu
t : t-istatistiği
V : Gerilim (V)
YE : Yenilenebilir enerji

1. GİRİŞ

Günümüzde hızla gelişen kalkınma, artan demografik büyüme ve buna paralel olarak tüketim seviyelerindeki istikrarlı yükseliş, özellikle enerji başta olmak üzere çeşitli kaynaklara yönelik talebin kayda değer ölçüde artmasına neden olmaktadır (Apergis ve Payne, 2012; Caetano vd., 2017; Navarro vd., 2023). Geleneksel enerji kaynakları olan petrol ve diğer fosil bazlı yakıtların aşırı kullanımı, tükenme riski, çevresel kirlilik, küresel ısınma, ozon tabakasının delinmesi gibi geri dönülemeyecek problemleri beraberinde getirmektedir (Guo vd., 2020; Imani vd., 2018; Liu vd., 2018; Lv vd., 2020; Wang vd., 2020; Yang vd., 2023). Mevcut küresel dinamikler çerçevesinde, söz konusu sorunların etkin bir şekilde yönetilebilmesi amacıyla yenilenebilir enerji (YE) kaynaklarının kullanımı dünya genelinde önemli bir ivme kazanmıştır (Azhdari vd., 2020; Yang vd., 2023). Bu bağlamda, hidroelektrik, rüzgâr, biyokütle, gelgit gibi YE kaynakları arasında erişilebilirliği yüksek, kurulumu kolay, teknolojik gelişmelere hızlı tepki vermesi ve modüler yapısıyla güneş enerjisi daha avantajlı konumdadır (Gallardo-Saavedra vd., 2019). Ayrıca, bakım maliyeti düşük, temiz, gürültüsüz, hafif ve esnek yapılarından dolayı güneş enerjisi dünyada en yaygın kullanılan üçüncü enerji kaynağıdır (Ebrahimi vd., 2019; Manoharan vd., 2020; Yang vd., 2023). Güneşten aldığı fotonları doğrudan elektrik enerjisine dönüştüren sistemler arasında fotovoltaik (PV) sistemler yaygın olarak kullanılmaktadır (Abd El-Mageed vd., 2023). Gerçek dünya uygulamalarında, PV sistemler genellikle açık hava ortamlarında ve zorlu iklim koşullarına maruz kalacak şekilde konumlandırılmaktadır. Bu durum, sıcaklık değişimleri, yoğun yağış, rüzgâr, nem ve toz gibi çevresel faktörlerin PV hücrelerinin performansı üzerindeki olumsuz etkilerini artırmaktadır (Chen vd., 2016). Bu bağlamda, PV sistemlerin ölçülen akım (I)-gerilim (V) değerlerine dayalı hassas ve etkili bir şekilde modelleyerek optimize etmek bu zorlukları minimize etmek için kritik bir öneme sahiptir (Chen vd., 2020).

PV hücrelerin optimizasyonu, tasarlanan modelin doğrusal olmayan I-V karakteristiklerinin matematiksel olarak formüle edilmesi ve sistem performansını en üst düzeye çıkaracak şekilde parametrelerin doğru bir şekilde tahmin edilmesi olarak tanımlanmaktadır. PV sistemlerin gerçek çalışma koşullarındaki verimliliği, temel elektriksel parametrelerin hassas bir şekilde çıkarılmasına ve bu parametrelerin çevresel değişkenlerle olan etkileşiminin doğru şekilde modellenmesine bağlıdır. Özellikle seri ve paralel dirençler, doyma akımı, ısınım duyarlılığı ve sıcaklık katsayısı gibi kritik

parametrelerin belirlenmesi, hücrelerin enerji dönüşüm verimliliğini doğrudan etkilemektedir. Bu nedenle, doğru modelleme tekniklerinin kullanılması ve ileri düzey analiz yöntemleri ile PV hücrelerinin performans kayıplarının minimize ederek sistemin uzun vadeli kararlılığının sağlanması önemlidir (Chen vd., 2019; Chen vd., 2020). PV hücre davranışını simüle eden mevcut modeller arasında, tek diyot modeli (1-D), çift diyot modeli (2-D) ve üç diyot modeli (3-D) olarak literatürde yaygın bir şekilde kullanılmaktadır (Chauhan vd., 2024; Kumar vd., 2020; Muhammad vd., 2019). 1-D model, yarı-nötr bölgedeki kayıpları temsil eden en sade ve basit elektriksel devredir (Yang vd., 2020). 2-D model ise, iki paralel diyot kullanarak PV hücrenin daha ayrıntılı bir şekilde modellenmesini sağlar. Bu model, hem uzay-yük bölgesindeki hem de yarı-nötr bölgedeki kayıpları temsil eder (Venkateswari ve Rajasekar, 2021). PV hücrelerin en detaylı ve karmaşık 3-D modeli ise uzay-yük bölgesi, yarı-nötr bölge ve üçüncü bir bölgedeki kayıpları temsil eder (Khanna vd., 2015; Premkumar vd., 2020; Sharma ve Raju, 2023). Burada, 1-D model beş (5), 2-D model yedi (7), 3-D model ise dokuz (9) bilinmeyen parametre içermektedir (Sharma ve Raju, 2023). PV hücrelerde, çevresel etkenlerden dolayı oluşan arızalar ve kararsız çalışma durumları ayrıca malzemenin kullanım ömrü gibi sorunlardan dolayı bilinmeyen parametreleri tutarlı bir şekilde tahmin etmek zor bir optimizasyon problemidir. Bu bağlamda, modelleri tasarlarken, parametreleri tahmin ederken ve optimizasyon sürecini yönetirken uygun bir amaç fonksiyonu kullanılması gerekmektedir (Zhang vd., 2020).

PV modül hücrelerinde parametre çıkarımı, değişken güneş ışığı yoğunluğu ve sıcaklık koşullarındaki dalgalanmalar nedeniyle, ayrıca geniş çözüm uzayına sahip ve doğrusal olmayan yapısıyla karmaşık bir optimizasyon problemi olarak değerlendirilmektedir (Lu vd., 2023; Nunes vd., 2018). Bu doğrultuda, literatürde bu karmaşık optimizasyon probleminin çözümü için deterministik ve meta-sezgisel olmak üzere iki temel yöntem önerilmektedir (Nunes vd., 2018; Nunes vd., 2020). Deterministik yöntemler, matematiksel ifadelerle dayalı analizler sunarak parametre çıkarım sürecinde doğruluk sağlamayı amaçlamaktadır. Bu kapsamda, en küçük kareler yöntemi, Newton-Raphson (N-R) algoritması, Lambert W-fonksiyonu ve Gauss-Seidel yöntemi gibi çeşitli teknikler parametre belirleme süreçlerinde yaygın olarak kullanılmaktadır (Abbassi vd., 2018; Batzelis ve Papathanassiou, 2015; Chaibi vd., 2020; Chen vd., 2018; Easwarakhanthan vd., 1986; Ortiz-Conde vd., 2006). Ancak, bu yöntemlerin hesaplama sürecinde bazı parametrelerin ihmal edilmesi, başlangıç değerlerinin yanlış seçilmesi nedeniyle hata oranının artması gibi faktörler doğrulukta sapmalara yol açabilmektedir.

Bunun yanı sıra, düşük yakınsama hızı ve sınırlı hesaplama verimliliği gibi dezavantajlar, deterministik yaklaşımların özellikle büyük ölçekli problemlerde optimal çözüme ulaşmasını kısıtlayan önemli unsurlar arasında yer almaktadır (Luu ve Nguyen, 2020; Nunes vd., 2020). Buna karşılık, meta-sezgisel yöntemler son yıllarda bu alanda ilgi görmeye başlamıştır. Meta-sezgisel optimizasyon algoritmaları, hızlı ve verimli bir arama ile yüksek doğrulukta çözümler üreterek önemli bir alternatif sunmaktadır (Chen vd., 2018; Yu, Chen, vd., 2017). Ayrıca, etkinlikleri ve uygulama kolaylıkları nedeniyle PV parametre tahmini gibi karmaşık ve çok değişkenli problemlerin çözümünde yaygın olarak kullanılmaktadır (Lu vd., 2023; Yu, Liang, vd., 2017).

Literatürde, PV modellerin parametre optimizasyonu için birçok meta-sezgisel algoritma önerilmiş olmasına rağmen, elde edilen sonuçların güvenilirlik ve doğruluk açısından tutarlı bir şekilde değerlendirmesi zordur (Abd El-Mageed vd., 2023). Meta-sezgisel optimizasyon algoritmalarının etkin bir şekilde uygulanabilirliği, parametre ayarlarının doğruluğu, başlangıç koşullarının uygunluğu, keşif ve sömürü dengesinin sağlanması ile erken yakınsamanın önlenmesine, adaptasyon ve öğrenme eğrisi, yerel minimumlara duyarlılık ve yüksek hesaplama maliyetleri gibi faktörlere bağlıdır (Abd El-Mageed vd., 2023; Long vd., 2021; Lu vd., 2023). Örneğin, Long ve diğerleri, yeni bir kelebek optimizasyon algoritması önermiştir. Bu algoritma ile keşif ve sömürü arasında denge sağlamaya çalışmışlardır (Long vd., 2021). Zhou ve diğerleri, parçacıkların keşif ve sömürü yeteneklerini artırmak için dinamik zıt öğrenme stratejisi ile uyarlamalı bir diferansiyel evrim algoritması önermiştir (Zhou vd., 2022). Jiao ve diğerleri, sömürü ve keşif oranları arasında denge sağlamak için ortogonal öğrenme ve genel zıt öğrenme kullanmıştır (Jiao vd., 2020). Ahmadianfar ve diğerleri, önerdikleri algoritmanın güvenilirliğini, doğruluğunu ve yakınsama hızını artırmak için sıralamaya dayalı bir mekanizma kullanan geliştirilmiş bir metafor içermeyen gradyan tabanlı optimizasyon önerisinde bulunmuşlardır (Ahmadianfar vd., 2021). Benkercha ve diğerleri, çiçek algoritmasını minimum iterasyon sayısı ve minimum yakınsama oranıyla iyi bir çözüm sağlayabilmesi için çiçek sabitliği ve değiştirme faktörlerini tanıtarak geliştirmişlerdir (Benkercha vd., 2019). Bu çalışmalarda algoritmanın performansı üzerinde önemli bir etkisi olan keşif ve sömürü dengesi, yakınsama hızı gibi etkenleri iyileştirmeye yönelik analizler yapmışlardır.

Bununla birlikte, farklı yaklaşımların avantajlarını bir araya getirmek amacıyla literatürde çeşitli hibrit yöntemler önerilmiştir. Özellikle karmaşık problemlerde, hibrit meta-sezgisel optimizasyon yaklaşımları, algoritmalara özgü dezavantajları gidermede ve

özüm verimliliğini artırmada kritik bir rol oynamaktadır (Lu vd., 2023). Örneğın, Long ve diğerkleri gri kurt algoritmasını guguk kuşu algoritması ile birleřtirerek hibrit bir algoritma önermiřtir (Long vd., 2020), Chen ve arkadaşlarının yaptıkları alıřmada, guguk araması ve biyocoğrafya tabanlı optimizasyon algoritmalarını birleřtirerek yüksek doğrulukta sonuçlar elde etmeye alıřmıřlardır (Chen ve Yu, 2019). Elhammoudy ve arkadaşları karahindiba optimizasyon algoritmasını N-R sayısal yöntemiyle birleřtirerek hibrit bir yöntem geliřtirmiřtir (Elhammoudy vd., 2023). İzci ve arkadaşları, dağ ceylanı optimizasyonu ve desen arama algoritmasını N-R sayısal yöntemiyle entegre ederek hibrit bir yöntem geliřtirmiřlerdir (İzci, Ekinci, Altalhi, vd., 2024). Bir bařka alıřmada ise, N-R sayısal yöntemi kuantum tabanlı kuř navigasyon optimizasyon algoritmasına entegre edilerek hibrit bir yaklaşım sunulmuřtur. 1-D ve 2-D modelleri ile yapılan karřılařtırmalı analizde yüksek doğrulukta sonuçlar elde edildiğı bildirilmiřtir (Ayyarao, 2022). Sonuç olarak, PV hücrelerinde parametre ıkarımı yüksek hassasiyet gerektirdiğinden, bu alandaki optimizasyon algoritmaları sürekli olarak geliřtirilmektedir. Literatürde sunulan eřitli meta-sezgisel ve hibrit optimizasyon yaklaşımları, doğruluk, yakınsama hızı ve hesaplama verimliliğini artırmayı hedeflemektedir. Bu doğrultuda, farklı yöntemlerin avantajlarını birleřtiren hibrit stratejiler, algoritmalara özgü dezavantajları minimize ederek daha kararlı ve güvenilir özümler sunmakta, böylece PV hücrelerindeki parametre ıkarımı sürecinin daha etkin bir řekilde gerekleřtirilmesine olanak saėlamaktadır.

Bu tez alıřmasında, PV hücre parametrelerinin tahmini için yeni ve etkili meta-sezgisel yaklaşımlar olan vektörlerin ağırlıklı ortalaması (weighted mean of vectors, INFO) (Ahmadianfar vd., 2022) algoritması, ikinci dereceden enterpolasyon optimizasyonu (quadratic interpolation optimization, QIO) (Zhao vd., 2023) ve boyunlu kertenkele optimizasyonu (frilled lizard optimization, FLO) (Falahah vd., 2024) algoritmaları önerilmiřtir. INFO algoritması, keřif ve sömürü ařamalarında etkin bir řekilde alıřarak küresel optimum özümler bulmayı amalamaktadır. Ayrıca evresel kořullardaki deėiřkenliklere karřı dayanıklılığı korurken yakınsama hızını ve doğruluğı artırmak için tasarlanmıřtır. Bu algoritma, vektör tabanlı optimizasyon tekniklerinin avantajlarını kullanarak arama alanını etkin bir řekilde keřfeder ve optimal parametre deėerlerini belirler (Ahmadianfar vd., 2022). QIO algoritması ise, matematiksel bir tabanla geliřtirilmiř ve optimizasyon problemlerine yeniliki bir yaklaşım sunan bir meta-sezgisel algoritmadır. QIO, kuadratik enterpolasyon (parabolik enterpolasyon) prensiplerini kullanarak, üç kritik noktayı kullanarak bir kuadratik polinom oluřturur ve

bu polinomun minimum noktasını hesaplar. Bu yöntem, geleneksel kuadratik interpolasyon tekniklerinin ötesine geçerek, daha karmaşık ve yüksek boyutlu problemlerde güvenilir çözümler sunar. İki nokta yerine üç noktaya dayalı bu yaklaşım, fonksiyonun hem konveks hem de konkav bölgelerinde daha doğru sonuçlar sağlar (Zhao vd., 2023). Bu süreç, algoritmanın keşif ve sömürü yeteneklerini optimize eder. Keşif aşaması geniş bir arama alanını araştırırken, sömürü aşaması bulunan en iyi çözümü iyileştirir. Her iterasyonda seçilen üç noktadan bir kuadratik polinom oluşturularak, arama alanı daraltılır ve global optimuma daha hızlı ulaşılır. Bu sayede QIO, yerel minimumlara takılmadan, stabil ve hassas sonuçlar elde eder, mühendislik ve bilimsel problemlerde üstün performans gösterir (Zhao vd., 2023).

FLO algoritması ise, doğadaki boyunlu kertenkelenin avlanma ve savunma mekanizmalarından esinlenerek geliştirilmiş ve karmaşık optimizasyon problemlerinin çözümünde kullanılan popülasyon tabanlı bir yöntemdir. Algoritma, başlangıçta rastgele oluşturulan bir çözüm kümesi ile çalışmakta ve bireylerin problem uzayında en iyi çözüme ulaşmasını sağlamak için uyarlanabilir keşif ve sömürü mekanizmaları kullanmaktadır. Boyunlu kertenkelenin hızlı yön değiştirme, tehdit algılama ve savunma stratejilerinden ilham alan bu yaklaşım, küresel ve yerel arama süreçlerini dengeli bir şekilde yürüterek yüksek kaliteli çözümler üretmeyi amaçlamaktadır. Algoritmanın temel bileşenleri arasında, dinamik uyum yeteneği, çeşitliliğin korunması ve çok boyutlu optimizasyon yeteneği yer almakta olup, bu sayede geniş çaplı mühendislik ve bilimsel problemlere uygulanabilirliği artırılmaktadır. Ayrıca, FLO algoritması hızlı yakınsama özelliği ve düşük hesaplama maliyeti ile öne çıkmaktadır. (Abualigah vd., 2024; Falahah vd., 2024).

PV sistem parametrelerinin tahmini sürecinde, hedeflenen optimal değerlere ulaşırken elde edilen sonuçların uygunluğunu değerlendiren amaç fonksiyonu optimizasyon algoritmaları için kritik öneme sahiptir (Gnetchejo vd., 2021). Literatürde, amaç fonksiyonu olarak, kök ortalama kare hata (root mean square error, RMSE) istatistiksel terimi sıklıkla kullanılmaktadır (El-Sayed vd., 2016). Bu süreçte, her iterasyonda RMSE değerinin azalması, performansın iyileştiğinin bir göstergesidir. I-V arasındaki ilişkinin doğrusal olmaması nedeniyle, önerilen üç algoritma içinde RMSE'nin doğrusal olmayan denklemlerin çözüm noktalarını saptamak amacıyla N-R sayısal yöntemi entegre edilmiştir. Bu entegrasyon, PV modellerinde parametre tahmini gibi karmaşık problemlerin çözümünde daha yüksek doğruluk, hız ve güvenilirlik sağlayarak algoritmaların hesaplama verimliliğini önemli ölçüde artırmıştır. Ayrıca, önerilen


yöntemlerin etkinliğini kapsamlı bir şekilde değerlendirmek amacıyla bireysel mutlak hata (individual absolute error, IAE), bağıl hata (relative error, RE), ortalama mutlak hata (mean absolute error, MAE), ortalama yanlılık hatası (mean bias error, MBE), normalleştirilmiş kök ortalama kare hata (normalized root mean square error, NRMSE), normalleştirilmiş ortalama yanlılık hatası (normalized mean bias error, NMBE), normalleştirilmiş ortalama mutlak hata (normalized mean absolute error, NMAE), belirleme katsayısı (coefficient of determination, R^2) ve t-istatistiği (t-statistic, t) gibi farklı kıyaslama özelliklerine sahip amaç fonksiyonları ile ayrıntılı olarak analiz edilmiştir (Messaoud, 2020a, 2020b; Singh, Sharma, Rajput, Bose, vd., 2022). Bu amaç fonksiyonları, önerilen yöntemlerin PV parametre tahmin performansını çeşitli yönlerden değerlendirmek amacıyla kullanılmaktadır. Ayrıca, elde edilen sonuçların güvenilirliği, kararlılığı ve gerçek dünya uygulamalarıyla uyumluluğunu geniş bir perspektiften analiz etmeye olanak tanımaktadır. Bu tez çalışmasında, önerilen algoritmaların parametre çıkarımında etkinliğini test etmek amacıyla 1-D, 2-D ve 3-D elektriksel model devreleri kullanılmıştır. Gerçekleştirilen tüm analizler, her bir diyot modelinin performansını değerlendirmek ve doğrulamak amacıyla literatürde sıklıkla kullanılan I-V karakteristiklerinden ölçülen veri setleri kullanılmıştır. Bu çalışmada, çeşitli koşullar altında ölçülen, R.T.C France (RTC), Photowatt-PWP201 (PWP), STM6-40/36 (STM) ve STP6-120/36 (STP) olmak üzere dört farklı veri seti kullanılarak detaylı analizler yapılmıştır (Gu vd., 2023; Kullampalayam Murugaiyan vd., 2024; Yu, Duan, vd., 2023).

Bu tez çalışması, PV hücre parametrelerinin optimizasyonunda güncel ve etkili olan üç farklı algoritma önererek kapsamlı analizler yapılmıştır. Ayrıca, önerilen algoritmaların hesaplama verimliliğini artırmak ve deterministik yöntemlerin çeşitli avantajlarından faydalanmak amacıyla N-R sayısal yöntemi entegre edilmiştir. Yapılan bu çalışma literatürdeki önemli bir boşluğu doldurmakta ve gelecek çalışmalara ilham kaynağı olacak yeni kapılar açmaktadır. Bu bağlamda, tez çalışması hem teorik hem de pratik olarak yenilikçi bir bakış açısı sunmaktadır. Bu çalışmanın temel katkıları aşağıdaki şekilde sıralanabilir:

- PV hücrelerdeki bilinmeyen parametrelerin tahmini için yeni ve etkili meta-sezgisel algoritmalar önerilmiştir.
- Önerilen algoritmaların etkinliği, farklı çevresel koşullar altında kaydedilen dört farklı gerçek deneysel veri setleri kullanılarak 1-D, 2-D ve 3-D elektrik devre modelleri üzerinde kapsamlı bir şekilde analiz edilmiştir.

- RMSE'nin doğrusal olmayan denklemini daha etkin çözümlemek amacıyla özellikle N-R sayısal yöntemi entegre edilerek hesaplama verimliliği artırılmıştır.
- Önerilen algoritmaların performansı; IAE, RE, MAE, MBE, R^2 , t-istatistiği, NRMSE, NMBE ve NMAE gibi amaç fonksiyonları ile detaylı bir şekilde değerlendirilmiştir.
- Elde edilen sonuçlar literatürde bulunan farklı meta-sezgisel optimizasyon algoritmaları ile kapsamlı bir şekilde karşılaştırılmıştır.

Bu tez çalışmasında, sonraki bölümler Şekil 1.1'de sunulan yapıya uygun olarak organize edilmiştir.



Şekil 1.1 Tez çalışmasının organizasyonu

2. KAYNAK ARAŞTIRMASI

PV sistemlerin elektriksel devre parametrelerinin doğru ve hassas bir şekilde tahmin edilmesi, güneşten elde edilen enerjinin verimliliğinin artırılması açısından hayati bir öneme sahiptir. Ayrıca, yenilebilir teknolojilerin optimizasyon süreçleri sürdürülebilir bir enerji geleceği için vazgeçilmezdir. PV hücrede doğrusal olmayan I-V karakteristiklerinden dolayı, sistemin modellenmesi ve parametre tahmini için son yıllarda literatürde farklı meta-sezgisel optimizasyon algoritmaları önerilmiş ve uygulanmıştır. Bu bölümde, PV hücrelerde parametre çıkarımına yönelik gerçekleştirilen çalışmalar kapsamlı bir şekilde analiz edilerek, kullanılan yöntemlerin etkinliği ve elde edilen sonuçlar ayrıntılı olarak değerlendirilmiştir. Literatürde önerilen algoritmalar, doğruluk, yakınsama hızı, hesaplama maliyeti, keşif ve sömürü dengesi gibi temel performans ölçütleri doğrultusunda ele alınmış ve bu bağlamda mevcut yaklaşımlar incelenmiştir. Ek olarak, bölümün sonunda Tablo 2.1’de detaylı bir kaynak araştırması sunulmuştur.

Garip yaptığı çalışmada, harris şahinleri optimizasyonu (harris hawks optimization, HHO) algoritmasının arama performansını geliştirmek için fraktal haritalara dayalı yeni bir yaklaşım önerilmiştir. Burada, fraktal henon kaotik haritası avantajları kullanılarak av kuşatma sürecindeki rastgele parametreleri ayarlayarak hibrit kesirli henon kaotik harris şahinleri optimizasyonu (fractional chaotic henon harris hawks optimization, FCHHO) algoritmasını kullanılmıştır. Önerilen algoritma, 1-D, 2-D ve 3-D PV modelleri üzerinde analizler yapılmıştır. Algoritmanın etkinliği, unimodal, multimodal ve sabit boyutlu test fonksiyonları üzerinde doğrulanarak elde edilen sonuçların karşılaştırılan diğer meta-sezgisel algoritmalara göre daha üstün performansa sahip olduğunu göstermişlerdir (Garip, 2023).

Gude ve Jana yaptıkları çalışmada ise, PV modellerinin parametre tahmini için guguk kuşu arama (cuckoo search optimization, CSO) optimizasyonu ve varyantları olan geliştirilmiş guguk kuşu arama optimizasyonu (improved cuckoo search optimization, ICSO), modifiye guguk kuşu arama optimizasyonu (modified cuckoo search optimization, MCSO) kullanmışlardır. Burada, lévy uçuş mekanizmasıyla adım boyu uyarlamasını ICSO ile yaparken, bilgi paylaşımı yoluyla yakınsama oranını ise MCSO ile iyileştirmiştir. Tüm analizler 1-D ve 2-D elektriksel modelleri üzerinde test edilip, elde

edilen sonuçlara göre ICSO'nun doğruluk ve güvenilirlik açısından daha üstün olduğunu ortaya koymuşlardır (Gude ve Jana, 2020).

Liang ve diğerleri yaptıkları çalışmada, kendi kendine uyarlanan takım tabanlı diferansiyel evrim (self-adaptive team-based differential evolution, SEDE) algoritmasını kullanarak parametre tahmini yapmışlardır. Önerilen algoritma, farklı mutasyon stratejileriyle popülasyon çeşitliliğini ve yakınsama hızını optimize ederek karşılaştırılan diğer yöntemlere göre daha yüksek doğruluk saptamışlardır. Ayrıca, amaç fonksiyonu olarak kullandıkları RMSE dışında, ölçülen ve tahmin edilen akım değerleri için IAE hata metriği ile de sapmaları hesaplamışlardır (Liang, Qiao, vd., 2020).

Dang ve arkadaşları yaptıkları çalışmada ise, bulanık uyarlanabilir diferansiyel evrim (fuzzy adaptive differential evolution, FADE) algoritmasını PV modül parametrelerini doğru bir şekilde tespit etmek için kullanmışlardır. Çalışmada, polikristal ve monokristal panellerinden elde edilen gerçek veriler kullanılarak önerilen algoritmanın etkinliği test edilmiştir. Önerilen algoritma, daha hızlı yakınsama sağlamak ve yerel minimumlara takılmayı önlemek için adaptif ve bulanık stratejiler geliştirerek karşılaştırılan diğer algoritmalara göre daha optimal çözümler elde etmişlerdir. Ayrıca, performans ölçütü olarak RMSE fonksiyonu kullanmışlardır (Dang vd., 2022).

Wang ve diğerleri yaptıkları çalışmada parametre tahmini problemine yönelik geliştirilmiş karınca aslanı optimizasyonu (enhanced ant lion optimization, EALO) algoritmasını önermişlerdir. Burada, karınca aslanı optimizasyon (ant lion optimization, ALO) yönteminin dezavantajları olan küresel optimumu belirlerken karşılaştığı belirsizlik, erken yakınsama ve keşif ile sömürü eğilimleri arasındaki dengesizliklerle karşılaşmışlardır. Bu dezavantajları, karşıt tabanlı öğrenme mekanizması ve nelder-mead simplex tekniklerini adapte ederek minimize etmeye çalışmışlardır. Çalışmada, performans ölçütü olarak RMSE kullanılarak 1-D, 2-D ve PV hücre modellerini incelemişlerdir. Elde edilen sonuçların karşılaştırılan diğer algoritmalara göre umut verici potansiyele sahip olduğunu göstermişlerdir (Wang vd., 2020).

Premkumar ve diğerleri yaptıkları çalışmada ise, 1-D ve 2-D elektriksel modelde parametre optimizasyonu için geliştirilmiş kaotik JAYA algoritmasını ve varyantlarını önermişlerdir. Burada, en iyi çözüme ulaşma eğilimini artırarak en kötü çözümü önlemeyi amaçlayan kendinden uyarlamalı bir ağırlık mekanizması sunmuşlardır. Her bir çözüm adımında en iyi çıktının doğruluğunu optimize etmek için sinüs, lojistik ve çadır haritası olmak üzere üç kaotik süreçle kontrol etmişlerdir. Elde edilen sonuçlar, karşılaştırılan

diğer optimizasyon algoritmalarına kıyasla rekabetçi bir doğruluğa ulaştıklarını göstermişlerdir (Premkumar vd., 2021).

Weng ve diğerleri yaptıkları çalışmada, PV modelde optimal parametre çıkarımı için metafor içermeyen geliştirilmiş bir küresel evrim algoritması önermişlerdir. Burada, laplace'ın çapraz arama mekanizması ve nelder-mead simplex yöntemi algoritması (laplace crossover search and nelder-mead simplex algorithm, LCNMSE) birleştirmişlerdir. LCS'nin amacı çözüm alanlarını genişletmek, NMs ise yerel alanlarda sömürü yeteneğini artırmaktır. Önerilen bu yöntemle, keşif ve sömürü arasındaki dengenin etkin bir şekilde sağlanması hedeflenmiştir. Elde edilen sonuçların karşılaştırdıkları algoritmalara göre umut verici üstünlükler sağladığını ortaya koymuşlardır (Weng vd., 2021).

Abbassi ve arkadaşları yaptıkları çalışmada ise, problemin çözümüne yönelik geliştirilmiş aritmetik optimizasyon algoritması (improved arithmetic optimization algorithm, IAOA) önermişlerdir. Burada, 2-D elektriksel modeli kullanılarak çeşitli istatistiksel analizler ile kapsamlı bir şekilde incelemişlerdir. Deneysel sonuçlara göre karşılaştırılan algoritmalara göre düşük hata oranları sağladığını ortaya koymuşlardır (Abbassi vd., 2022).

Liu ve diğerleri yaptıkları çalışmada, uyarlanabilir çoklu stratejili yönlendirme diferansiyel evrim (adaptive multi-strategy guided differential evolution, AGDE) algoritmasının yerel arama yeteneğini artırmak ve algoritmanın parametre tahminini sürecini daha hızlı ve güvenilir bir şekilde belirlenmesini sağlamak amacıyla uygunluk-mesafe dengesi (FDB) ve karşıt tabanlı öğrenme (OBL) yeteneklerinden faydalanmışlardır. Burada, FDB ile mutasyon eşleme havuzu yeniden tasarlanmak ve OBL ise başlangıç popülasyonu çeşitliliğini artırmak için kullanmışlardır. Elde edilen sonuçlar kıyaslanan diğer algoritmalara göre yüksek performans sağladığını göstermişlerdir (Liu vd., 2024).

Oliva ve diğerleri güneş hücrelerinin I-V karakteristiklerini doğru modellemek ve sistemin performansını artırmak için yaptıkları çalışmada, bal arılarının besin arama davranışlarından esinlenmiş evrimsel yapay arı kolonisi (artificial bee colony, ABC) algoritmasını önermişlerdir. ABC algoritması, doğrusal olmayan karmaşık fonksiyonların çözümünde diğer evrimsel algoritmalara göre daha iyi arama kapasitesi gösterdiğini söylemişlerdir. Ayrıca, karşılaştırmalı analiz sonuçlarına göre de ABC algoritması sağlamlık ve hassasiyet açısından yüksek performans sergilediğini ortaya koymuşlardır (Oliva vd., 2014).

Qaraad ve arkadaşları yaptıkları çalışmada, güvenilir bir parametre optimizasyonu için yerel kaçış operatörleriyle geliştirilmiş güve-alev algoritmasını önermişlerdir. Burada yerel kaçış mekanizmaları ile popülasyon çeşitliliğini ve keşif performansını artırmışlardır. Keşif ve sömürü arasındaki sağladıkları denge ile yüksek doğrulukta parametre tahmini gerçekleştirmişlerdir (Qaraad vd., 2023).

Guo ve diğerleri yaptıkları bu çalışmada ise, 1-D ve 2-D elektriksel devre modellerinin bilinmeyen parametrelerini optimize etmek için CSO algoritmasını önermişlerdir. Algoritma, çözüm uzayının etkin bir şekilde keşfedilmesini sağlamak amacıyla arama modunu, mevcut çözümlerin yerel iyileştirilmesini gerçekleştirmek için ise izleme modunu kullanmaktadır. Bunun yanı sıra, popülasyon tabanlı bu yaklaşım ile keşif ve sömürü arasındaki denge etkin bir şekilde sağlanmıştır. Performans kriteri olarak RMSE fonksiyonunun kullanılmasıyla, ölçülen ve tahmin edilen parametreler arasındaki fark minimize edilmiş ve önerilen yöntemin karşılaştırılan diğer algoritmalara kıyasla güçlü bir alternatif sunduğu ortaya koymuşlardır (Guo vd., 2016).

Liang ve diğerleri yaptıkları çalışmada, PV modelde parametre tahmin problemini çözmek için yüksek hassasiyette alternatifler sunan algoritmaların sayısının artması gerektiğine vurgu yaparak, parçacık sürü optimizasyonu (particle swarm optimization, PSO) algoritmasını geliştirerek sınıflandırılmış bozucu mutasyon tabanlı bir PSO algoritmasını önermişlerdir. Bu algoritma, kendini sürekli güncelleyerek nesiller boyunca en iyi çözüme odaklanır. Tüm çözümleri iyi ve kötü kalite olarak sınıflandırarak, en iyi çözümler arasından en uygun pozisyonları belirlemek amacıyla yerel arama kapasitesini artıran küçük ölçekli bir bozucu mutasyon stratejisi geliştirmişlerdir. Ayrıca, keşif yeteneğini artırmak ve popülasyonu çeşitlendirmek için ise büyük ölçekli bozucu mutasyon stratejisi geliştirmişlerdir. Tüm bu analizler 1-D, 2-D ve PV diyot modelleri kullanılarak dört farklı veri seti üzerinde kapsamlı testler sunmuşlardır. Elde edilen sonuçlara göre doğruluk, kararlılık ve hız açısından karşılaştırılan algoritmalara göre üstünlük sağladığını vurgulamışlardır (Liang, Ge, vd., 2020).

Chenouard ve arkadaşları aralık tabanlı dallandırma ve sınırlandırma küresel optimizasyon algoritmasını, 1-D, 2-D ve 3-D diyot modelleri üzerinde parametre tahmini için test etmişlerdir. Yaptıkları bu çalışmada, hedef fonksiyonu olarak kullandıkları RMSE dışında maksimum mutlak hata (MAE)'i kullanarak ölçülen ve tahmin edilen parametre değeri arasındaki farkı minimize etmeyi amaçlamışlardır. Farklı sıcaklık ve koşullarda ölçülen veri setleri kullanarak yapılan analizler sonucunda elde edilen

parametre çıktıları literatürde bulunan ve karşılaştırılan diğer algoritmalar ile rekabet edebildiğini göstermişlerdir (Chenouard ve El-Sehiemy, 2020).

Li ve diğerleri yaptıkları çalışmada, diferansiyel evrim (differential evolution, DE) algoritmasını geliştirilmiş uyarlanabilir diferansiyel evrim algoritmasına güncelleyerek PV modülde parametrelerini daha hızlı, doğru ve güvenilir bir şekilde tahmin etmeyi amaçlamışlardır. Geliştirdikleri bu algoritma ile çaprazlama oranı sıralama mekanizması ile en iyi çözümlerin bir sonraki nesille aktarımını sağlarken, dinamik popülasyon azaltma stratejisiyle de yakınsama hızını artırarak keşif ve sömürü arasındaki dengeyi yüksek hassasiyetle optimize etmişlerdir. Tüm bu analizlerde, farklı ışınım ve sıcaklık koşullarında test edilen veri setleriyle 1-D, 2-D ve PV modül elektriksel devreleri kullanılarak yapılmıştır. Deneysel sonuçların diğer algoritmalar ile rekabet ettiğini doğrulamışlardır (Li vd., 2020).

Qais ve arkadaşları yaptıkları çalışmada ise, 3-D modeli kullanılarak endüktif ve kapasitif devrelerin geçici süreçlerinden esinlenerek yenilikçi bir algoritma olan geçici arama optimizasyonu (temporarily search optimization, TSO) algoritmasını önermişlerdir. Elde edilen deneysel sonuçlara göre önerilen algoritmanın 3-D modeli üzerinde optimal parametreleri etkili sonuçlar verdiğini göstermişlerdir (Qais vd., 2020). Lekouaghet ve arkadaşları yaptıkları çalışmada, PV sistem performansını artırmak için optimal parametreleri tahmin ederken yeni bir Rao-1 optimizasyon algoritmasına kaotik bir jeneratör yöntemini entegre ederek kullanmışlardır. 1-D ve 2-D diyot modelleri kullanılarak, farklı ışınım ve sıcaklık koşulları altında ölçülen beş veri seti ile analizler yapılmıştır. Önerilen algoritmanın, karşılaştırmalı sonuçlarına göre diğer yöntemlere göre üstün performans sergilediğini ortaya koyarken, 2-D modelin parametrelerini tahmin etmek için daha uygun olduğunu söylemişlerdir (Lekouaghet vd., 2021).

Navarro ve diğerleri yaptıkları çalışmada ise, PV modül parametrelerinin optimal değerlerini belirlemek için sekiz (8) farklı algoritma önermişlerdir. Bu algoritmalar, yapay sinek kuşu algoritması (artificial hummingbird algorithm, AHA), kartal optimizasyonu (eagle optimization, AO), afrika akbabası optimizasyon algoritması (african vulture optimization algorithm, AVOA), denge optimizasyonu (equilibrium optimization, EO), altın kartal optimizasyonu (golden eagle optimization, GEO), yan benekli kertenkele algoritması (side-blotched lizard algorithm, SBLA), sosyal ağ arama algoritması (social network search algorithm, SNS), sürüngen arama algoritması (reptile search algorithm, RSA)'dır. Çalışmada, R.T.C France güneş hücresi veri seti kullanılarak 1-D, 2-D ve 3-D modelleri üzerinde analizler yapılmıştır. Performans kriterleri olarak

RMSE dışında mutlak hata (AE), MAE ve NRMSE hata metrikleriyle istatistiksel olarak incelemişlerdir. Deney sonuçlarına göre en etkili yöntemin AHA algoritmasını olduğunu öne sürmüşlerdir (Navarro vd., 2023).

Messaoud ise yaptığı çalışmada, yenilenebilir güneş enerji sistemlerinin simülasyonu ve optimizasyonu için 1-D ve 2-D diyot modellerine salp sürüsü algoritması (salp swarm algorithm, SSA) önermişlerdir. Farklı ışınlım ve sıcaklık altında ölçülen veri setleri ile yaptıkları analizlerde, literatürde mevcut olan diğer önermelere göre yüksek performans gösterdiğini öne sürmüşlerdir (Messaoud, 2020b).

Jearsiripongkul ve arkadaşları yaptıkları çalışmada ise, PV sistemlerde bilinmeyen parametreleri çözümlmek için tek adaylı optimizasyon (single candidate optimization, SCO) ve kaotik kum kedisi optimizasyonu (chaotic sand cat optimization, CSCO) yöntemlerini birleştirerek yenilikçi bir hibrid optimizasyon algoritmasını önermişlerdir. Burada, SCO'ya kaotik bir entegrasyon ile keşif yeteneği güçlendirilerek erken yakınsama önlenmiştir, SCO ve CSCO algoritmalarının yerel arama yetenekleri birleştirince, hibrit CSCSC yöntemi daha hassas çözümler sunduğunu belirtmişlerdir. Ayrıca, 1-D, 2-D ve PV modülleri üzerinde analizler yapılarak, performans kriteri olarak RMSE kullanılmıştır. Deneysel sonuçlara, karşılaştırılan diğer algoritmalara göre daha başarılı olduğunu söylemişlerdir (Jearsiripongkul vd., 2023).

Tablo 2.1. Kaynak araştırması


Referanslar	Kullanılan Algoritma	Model	Veri seti	Performans Kriteri
(Shaheen vd., 2023)	Geliştirilmiş yapay goril sürüleri optimizasyonu (EAGT)	3-D	KC200GT, STM6, SP70	RMSE
(Duman vd., 2022)	Öğretme-öğrenme tabanlı yapay arı kolonisi (TLABC)	1-D, 2-D	RTC, PWP 201, STM6, STP6, KC200GT, SM55, ST40	RMSE
(Yu, Hu, vd., 2023)	Sıralama öğretme-öğrenme tabanlı optimizasyon (RTLBO)	1-D, 2-D, PV modül	RTC, STM6, STP6, PWP 201	RMSE
(Yu, Duan, vd., 2023)	Gaussian mutasyonu ve Lévy uçuşu ile Gri Kurt Optimizasyonu (SPGWO)	1-D, 2-D, PV modül	RTC, STM6, STP6, PWP 201	RMSE

(Chen vd., 2020)	Çeşitlendirme ile geliştirilmiş Harris Şahinleri Optimizasyonu (HHO)	1-D, 2-D, PV modül	RTC, KC200GT, SM55, ST40	RMSE
(Yang ve Gong, 2021)	Geliştirilmiş JAYA (EJAYA)	1-D, 2-D	RTC, STM6, STP6, PWP 201	RMSE
(Shaheen vd., 2022)	Arz-Talep Tabanlı Optimizasyon Algoritması (SDOA)	3-D	PVM_752	RMSE
(Bayoumi vd., 2022)	Deniz Yırtıcıları Optimizasyonu (MPO)	1-D, 2-D, 3-D	RTC, MCSSC	RMSE
(Diab vd., 2020)	Çakal Optimizasyon Algoritması (COA)	1-D, 2-D, 3-D	RTC, PWP 201, KC200GT, SM55, ST40	RMSE
(Abd El-Mageed vd., 2023)	Kuyruk Arama Optimizasyonu ve Diferansiyel Evrim	1-D,2-D, PV modül	RTC, STM6, STP6, PWP 201	RMSE
(Mostafa vd., 2020)	Yosun Küfü Algoritması (SMA)	1-D,2-D	PWP 201, LSM 20	RMSE
(Chauhan vd., 2024)	Kaos ilhamlı istilacı yabancı ot optimizasyonu (CIWO)	1-D, 2-D, 3-D	RTC	RMSE
(Kler vd., 2017)	Buharlaştırma Hızına Dayalı Su Döngüsü Algoritması (ER-WCA)	1-D, 2-D	RTC, PWP 201, KC200GT	RMSE, MAE, RE, PE
(Singh, Sharma, Rajput, Mondal, vd., 2022)	Sooty Tern Optimizasyon Algoritması (STO)	1-D	RTC, SS2018P	RMSE, IAE
(Montano vd., 2020)	Çekirge Optimizasyon Algoritması (GOA)	1-D	KC200GT, MSX60	RMSE
(Lekouaghet vd., 2022)	Ergen Kimlik Arama Algoritması (AISA)	1-D, 2-D, PV modül	RTC, STM6, STP6, PWP 201, KC200GT	RMSE, IAE, RE
(Bogar, 2023)	Kaos Oyunu Optimizasyonu-En Küçük Kareler (CGO-LS)	1-D, 2-D, 3-D PV modül	RTC, PWP 201	RMSE


3. FOTOVOLTAİK SİSTEMLER VE ÖZELLİKLERİ

1839 yılında Fransız fizikçi Alexandre Edmond Becquerel, gümüş ve platin elektrotlarla yaptığı deneyler sonucunda güneş ışığının bir PV etki oluşturduğunu ilk kez gözlemlemiştir (Marques Lameirinhas vd., 2022). 1877 yılında ise Adams ve öğrencileri tarafından selenyum kullanarak geliştirdikleri cihaz ile ilk güneş hücresi tasarımı modellenmiştir. Daha sonra, Charles Fritts tarafından iki ince metal tabaka arasına selenyum yerleştirip geliştirdikleri güneş hücresi modelinde verimliliği artırmayı başarmışlardır (Engana Carmo vd., 2021). 1905 yılında ise Albert Einstein tarafından Fotoelektrik teorisi önerilmiştir. 1939 yılında Russell Ohl silisyum kullanarak pozitif ve negatif bölgelerinde fotoelektrik etkiyi keşfetmiştir. Ayrıca 1940 yılında Ohl ilk silikon güneş hücresi cihazını geliştirmiştir. Hızla gelişmeye devam eden güneş hücre modelleri 1958 yılında National Aeronautics and Space Administration (NASA)'nın uzaya fırlattığı Vanguard-I adlı uyduya silikon güneş hücresinden oluşan sistem entegre edilerek uydunun enerji ihtiyacı karşılanmıştır. PV sistemler uzay projelerinde sıklıkla kullanılmaya devam ederek özellikle 1970'lerin başında ortaya çıkan petrol krizinden dolayı güneş hücresi modellerine verilen önem artmıştır (Engana Carmo vd., 2021; Marques Lameirinhas vd., 2022). Günümüzde ise PV hücre teknolojisi tahminlerin çok ötesinde bir ilerleme göstererek enerji üretiminin ana unsurlardan birisi haline gelmiştir. Sürdürülebilir enerji alt yapısının vazgeçilmez bir parçası olan PV paneller dünya genelinde kullanımı giderek artmaya devam etmektedir (Mottakin vd., 2021; Rahman vd., 2017).

PV modülünün temel işlevsel bileşeni olan ve Şekil 3.1'de görsel olarak temsil edilen güneş hücresi, üzerine düşen güneş ışığını doğrudan elektrik enerjisine dönüştürme kapasitesine sahip yarı iletken bir yapıdır. Şekil 3.2'de sunulduğu üzere, bu enerji dönüşüm süreci, PV sistemlerin verimliliğini ve sürdürülebilirliğini artıran kritik bir mekanizma olarak öne çıkmaktadır. Güneş hücreleri, belirli bir gerilim ve akım seviyesi elde etmek amacıyla seri ve paralel bağlantılarla bir araya getirilerek bir modül yapısı oluşturur (Ciulla vd., 2014). Yüksek enerji taleplerini karşılamak amacıyla, bu modüller birbirine entegre edilerek geniş ölçekli PV dizileri oluşturulmakta ve böylece daha büyük ölçekli enerji üretim sistemlerine olanak tanımaktadır. Hücre, modül ve dizi süreçlerine ilişkin detaylı görselleştirme ve açıklamalar Şekil 3.3'te sunulmaktadır (Rahideh vd., 2020).




Şekil 3.1. PV hücrenin yapısı



Şekil 3.2. PV hücrenin çalışma ilkesi

PV sistemlerin enerji üretim sürecinde, sınırlı erişilebilirlik, değişken güneş ışınlamı, ortam sıcaklığı, panel eğim açısı ve kullanılan malzeme özellikleri gibi çeşitli çevresel faktörlerden kaynaklanan dezavantajlı unsurlar mevcuttur. Bu faktörler, sistemin verimliliğini doğrudan etkileyerek enerji üretim kapasitesinde dalgalanmalara yol açmaktadır. Özellikle güneş ışınlamı ve ortam sıcaklığı, PV sistemlerin performansını belirleyen en kritik parametreler arasında yer almaktadır. Güneş ışınlamı, PV panelin kısa devre akımını doğrudan belirlerken, ortam sıcaklığı açık devre voltajı üzerinde önemli bir etkiye sahiptir. Bunun yanı sıra, yüksek sıcaklık değerleri yarı iletken malzemelerin

elektriksel özelliklerini değiştirerek verim kayıplarına neden olmakta, dolayısıyla PV sistemlerin tasarımında bu değişkenlerin dikkate alınması büyük önem taşımaktadır. (Karimi vd., 2020; Nadia vd., 2018; Venkateswari ve Rajasekar, 2021). Bu nedenle, PV hücrelerin enerji dönüşüm süreçlerini optimize ederken detaylı analizler yapılması gerekmektedir (Karimi vd., 2020; Nadia vd., 2018; Thangamani vd., 2020). Sonuç olarak, PV modül performansını artırmaya yönelik etkili tasarım, modelleme ve parametre optimizasyon süreçleri çevresel etkenlerin iyi yapılandırılmış bir şekilde değerlendirilmesi gerekmektedir. Bu bağlamda, PV sistemlerinin enerji üretim süreçlerini daha verimli hale getirmek ve çevresel koşullara olan duyarlılığını azaltmak, sürdürülebilir enerji üretimi hedefleri doğrultusunda önemli bir araştırma alanı olarak öne çıkmaktadır. Meta-sezgisel algoritmaların uygulanması, PV modüllerinin dönüşüm verimliliğini artırmanın yanı sıra, enerji üretimindeki dalgalanmaları minimize ederek şebeke entegrasyonunu optimize etmeye yönelik yenilikçi çözümler sunmaktadır. Bu çerçevede, parametre tahmini, sadece teorik bir araç değil, aynı zamanda PV teknolojilerinin uygulanabilirliğini ve sürdürülebilirliğini artıran stratejik bir yöntem olarak değerlendirilmelidir (Karimi vd., 2020; Venkateswari ve Rajasekar, 2021).



Şekil 3.3. PV hücre, modül ve dizi

3.1. PV Hücresi Malzemeleri ve Performansı Üzerindeki Etkisi

PV sistemlerin enerji üretiminde önemli bir noktaya gelmesiyle birlikte, hücre performansını artırmaya yönelik araştırmalara da çarpan etkisi yapmıştır. Güneş hücreleri genellikle üç nesil olacak şekilde sınıflandırılır. Bu nesiller, üretiminde kullanılan malzemeler ve tekniklere dayanmaktadır (Choubey vd., 2012; Simya vd., 2018; Srinivas vd., 2015). Her bir nesilde, güneş hücrelerinin daha kompakt, yüksek verimli ve ticari


anlamda uygulanabilir hale gelmesini sağlayan kapsamlı yenilikler ve ileri düzey teknolojik iyileştirmeler sunulmuştur. Bu yenilikler, yalnızca PV hücrelerin fiziksel boyutlarını ve enerji dönüşüm verimliliğini optimize etmekle kalmamış, aynı zamanda üretim maliyetlerini düşürerek geniş bir kullanım yelpazesine uygun hale getirilmesini sağlamıştır. Böylelikle, her nesil, PV teknolojilerin sürdürülebilir enerji üretimindeki rolünü güçlendiren önemli bir adım niteliği taşımıştır (Asim vd., 2012; Choubey vd., 2012). Birinci, ikinci ve üçüncü nesil güneş hücreleri sırasıyla tek silikon, ince film ve nanokristal organik polimer malzemelerden oluşmaktadır (Ghorannevis vd., 2016; Graetzel vd., 2012; Lepetit vd., 2016; Li vd., 2006; Lotfi ve Hatem, 2012; Moradi vd., 2013). Ayrıca, üretim teknolojisine dayalı olarak güneş hücresi malzeme sınıflandırması Tablo 3.1 'de detaylı bir şekilde sunulmuştur (Marques Lameirinhas vd., 2022; Venkateswari ve Rajasekar, 2021).

Günümüzde, mevcut PV hücrelerinin %90'ından fazlasını oluşturan ve %29'a kadar verimlilik sunabilen silikon bazlı birinci nesil güneş hücreleri, en yaygın kullanılan PV teknoloji olarak öne çıkmaktadır. (Sharma vd., 2015). Burada, tek kristalli (monokristal) PV panellerin %14 ile %17,5 aralığında verimliliğe sahipken, çok kristalli (polikristal) PV panelleri verimliliği ise, %12 ile %14 arasında değişmektedir (Sharma vd., 2015). Polikristal güneş hücreleri, monokristal türlere kıyasla maliyet açısından daha avantajlı olup daha dayanıklıdır. İkinci nesil ince film güneş hücreleri, gölgeleme etkilerine ve ortam sıcaklığındaki dalgalanmalara yüksek tolerans göstererek, değişken çevresel koşullar altında dahi etkin bir performans sergilemektedir (Liang vd., 2007). Yaygın olarak kullanılan, amorf silikon (a-Si), Kadmium Tellurit (Cd-Te), Bakır İndiyum Galium Selenit (CIS/CIGS) malzemeleri yaklaşık %9 ile %12 arasında verimlilik sunmaktadır. Üçüncü nesil güneş hücreleri, organik bileşenler ve perovskit gibi yenilikçi malzemeler kullanılarak geliştirilmiş olup, geleneksel yarı iletken bazlı hücrelere alternatif olarak sunulmaktadır. Bu hücreler, düşük üretim maliyetleriyle yüksek verimlilikte enerji dönüşümü sağlama potansiyeline sahip olup, esnek ve hafif yapıları sayesinde farklı uygulama alanlarına entegrasyon açısından önemli avantajlar sunmaktadır (Liang vd., 2007; Marques Lameirinhas vd., 2022; Sharma vd., 2015; Venkateswari ve Rajasekar, 2021). Ayrıca, tüm bu güneş hücresi malzemelerinin ayrıntılı özellikleri Tablo 3.1'de sunulmuştur. Tabloda görüldüğü üzere kullanılan tüm malzemeler PV hücre teknolojisinin büyümesine katkısı istikrarlı bir şekilde artmaktadır.

Bu tez çalışmasında, literatürde sıklıkla kullanılan farklı sıcaklık ve yapısal özelliklere sahip ticari fotovoltaiik hücrelerin performans analizine yönelik veri setleri

kullanılmıştır. Çalışmada, 33 °C sıcaklıkta ölçülen ve 57 mm çapında ticari bir silikon RTC France güneş hücresi, 45 °C sıcaklıkta ölçülen ve 36 seri bağlı polikristalin silikon hücrelerden oluşan Photowatt-PW201 veri seti, ayrıca sırasıyla 51 °C ve 55 °C sıcaklıklarında ölçülen 36 seri bağlı monokristalin hücrelerden oluşan STM6-40/36 ve STP6-120/36 veri setleri temel alınmıştır (Gu vd., 2023; Kullampalayam Murugaiyan vd., 2024; Yu, Duan, vd., 2023). Bu veri setleri, fotovoltaik hücrelerin çevresel koşullara bağlı olarak performans karakteristiklerini karşılaştırmalı olarak değerlendirmek ve modelleme çalışmalarına temel oluşturmak amacıyla seçilmiştir. Çeşitli sıcaklık ve farklı malzeme türlerini içeren bu veri setleri, tez çalışması kapsamında geniş bir analitik çerçeve sunmaktadır.

Tablo 3.1. Güneş hücresi malzeme sınıflandırması (Makarova, 2017)

PV Türü	Monokristalin Silikon (mono-Si):	Polikristalin Silikon (p-Si veya m-Si):	İnce Film Teknolojisi (TFSC):
			
Güçlü Yönler	-Verimlilik: %14-17,5 (maksimum %21,5) -Dayanıklılık: 25 yıla kadar -Alan verimliliği	-Basit, maliyet-etkin ve israf etmeyen imalat süreci -Yüksek ortam sıcaklıklarına karşı önemsiz duyarsızlık	-Maliyet-etkin ve basit imalat süreci -Farklı kurulumlara uygun esnek yapılandırmalar -Gölgeleme sorunlarına ve ortam sıcaklığı değişikliklerine yüksek tolerans
Zayıf Yönler	-Yüksek maliyet -Çevresel sıcaklığa duyarlılık (çevresel sıcaklık arttıkça performansı önemli ölçüde azalır) -Gölgeleme, kar ve kir duyarlılığı -İsrafçı imalat süreci	-Saf olmayan maddeler ve %12-14 verimlilik -Alan verimliliği düşüktür -Yüksek enerji tüketimli üretim süreci	-Düşük verimlilik: %9-12 -Düşük alan verimliliği -Yüksek bozulma oranı


3.2. Fotovoltaik Hücrelerin Modelleme Yöntemleri

Güneş PV hücresi genellikle, ideal bir diyot, seri ve paralel bağlı dirençler ve bir akım kaynağından oluşan elektriksel eşdeğer devre kullanılarak modellenir. Bu bağlamda, sistemin doğrusal olmayan yapısından kaynaklı, son zamanlarda çeşitli

modelleme yöntemleri geliştirilmiştir. PV hücre modelleri temelde, Şekil 3.4'te sunulduğu üzere 1-D, 2-D ve 3-D modelleri olarak sınıflandırılmaktadır (Kumar ve Kumar, 2017; Ram vd., 2018). Modellerde yer alan diyot sayısı, I-V eğrisinin tahmin doğruluğunu doğrudan etkileyen kritik bir parametredir (Gupta vd., 2012). Bu modeller arasında yaygın olarak kullanılan 1-D modeli, bir akım kaynağına paralel bağlı bir diyottan oluşmaktadır (Orioli ve Di Gangi, 2013). Söz konusu ideal eşdeğer devre, metal bağlantılardan kaynaklanan kayıpları dikkate almak amacıyla seri direnç (R_s) ve rekombinasyon kayıplarını hesaba katmak için şönt direnç (R_{sh}) eklenerek daha gelişmiş hali elde edilmiş olur (Gao vd., 2018; Kumar ve Kumar, 2019; Parida vd., 2011). Bu bağlamda 1-D modeli, doğruluğu ve yüksek güvenilirliği nedeniyle PV hücrede modelleme ve optimizasyon süreçlerinde yaygın bir şekilde kullanılmaktadır (Sheikh vd., 2011).

İkinci bir diyotun eklenmesiyle 2-D modeli elde edilmiş olur. Bu modelin geliştirilmesindeki temel amaç, 1-D modelde genellikle ihmal edilen rekombinasyon kayıplarını sisteme dahil ederek daha gerçekçi ve kapsamlı bir temsil sağlamaktır (Kumar vd., 2021). İkinci bir diyotun modele dahil edilmesi, düşük ışıyım koşullarında dahi yüksek doğrulukta performans elde edilmesini sağlamaktadır. Bununla birlikte, modele eklenen her diyot, sistemin doğruluğunu, hassasiyetini ve verimliliğini olumlu yönde etkilerken, aynı zamanda modelin karmaşıklığını ve tahmin edilmesi gereken parametre sayısını da artırmaktadır (Ishaque vd., 2011). Bu doğrultuda, PV hücre modelleri arasında en detaylı ve en karmaşık yapı 3-D modelidir. Bu modelde, üçüncü bir diyotun entegrasyonu ile sistemin doğruluğu, güvenilirliği ve karmaşıklığı daha da artırılmış olur (Diab vd., 2020).

Bu tez çalışmasında kullanılacak olan 1-D, 2-D ve 3-D modelleri ve her bir modelin tahmin edilmesi gereken parametre sayıları Şekil 3.4'te sunulmuştur. Diyot sayısındaki artış, modelin karmaşıklığını önemli ölçüde artırsa da, doğruluk ve güvenilirlik üzerinde olumlu bir etki sağlamaktadır. Bunun yanı sıra, geliştirilen her bir model, hassasiyet ile modelleme maliyeti arasında optimal bir denge kurmayı hedeflemektedir. Tablo 3.2'de, 1-D, 2-D ve 3-D modellerinin avantajlarını, dezavantajlarını ve kullanım alanlarını karşılaştırmaktadır. Daha basit ve düşük maliyetli 1-D'den, yüksek doğruluk ancak artan karmaşıklık ve maliyet sunan 3-D'ye doğru bir ilerleme sunarak, farklı ihtiyaçlar için uygun model seçiminde rehberlik etmektedir. Ayrıca modellere ait elektriksel devre şemaları ve matematiksel formülasyonu ilerleyen bölümlerde ayrıntılı bir şekilde incelenecektir.




Şekil 3.4. 1-D, 2-D ve 3-D PV modelleri

Tablo 3.2. 1-D, 2-D ve 3-D Modellerinin avantajları, dezavantajları ve uygulama alanları karşılaştırması

Model	Avantajları	Dezavantajları	Uygulama alanları
1-D	-Basit yapı, -Düşük karmaşıklık, -Düşük hesaplama yükü, -Laboratuvarda kolay uygulanabilir.	- Düşük doğruluk, - Kısmi gölgeleme altında PV modül performansını tahmin edememe, - I-V eğrisinin tahmininde düşük doğruluk.	-Basitliği nedeniyle en yaygın kullanılan modeldir, -Düşük üretim maliyetiyle hızlı tahmin gerektiren durumlar için uygundur.
2-D	-1-D'ye kıyasla daha yüksek doğruluk, -Daha doğru performans, -Laboratuvarda kolay uygulanabilir.	- Daha karmaşık yapı, - Yüksek uygulama maliyeti.	-Kesin I-V tahmininin gerektiği durumlar için uygundur, - Simülasyon sırasında çevresel koşulların değişkenliği göz önüne alınabilir.
3-D	-Önceki iki modele kıyasla en yüksek doğruluk, -Performans sırasında PV modülündeki birçok olguyu modelleyebilir.	-Diğer iki modele göre daha karmaşık, -Yüksek hesaplama süresi, -Donanım uygulaması karmaşık.	-Yüksek doğruluk gerektiren değerlerin tahmini için uygundur, -Farklı PV modül türlerinin karmaşık doğasını kolayca ele alabilir.

4. FOTOVOLTAİK MODÜLDE PARAMETRE TAHMİNİ

PV hücre modelinin belirlenmesinin ardından en kritik aşamalardan biri, bilinmeyen parametrelerin en uygun şekilde tahmin edilme sürecidir. PV sistemlerinin karmaşık doğası ve çevresel faktörlere duyarlılığı, parametre tahmin sürecinin hem hassas hem de kapsamlı bir şekilde ele alınmasını gerektirir. Bu bağlamda, PV modelleme sürecinin başarısı, her bir bilinmeyen parametrenin yüksek doğrulukla tahmin edilmesine bağlıdır. Doğru bir parametre tahmini, PV sistemlerinin gerçek çalışma koşullarında davranışlarını daha iyi anlamak, performansını optimize etmek ve enerji dönüşüm süreçlerindeki verimliliği artırmak için temel bir gereklilik olarak değerlendirilmektedir. Bu optimizasyon süreci, sistematik bir analizle birlikte ileri modelleme tekniklerinin uygulanmasını zorunlu kılarak, PV sistemlerin güvenilirliğini ve ticari uygulanabilirliğini güçlendirmektedir. Şekil 4.1’ da sunulduğu üzere PV hücrede parametre tahmini için literatürde sıklıkla kullanılan yöntemler sunulmuştur (Nunes vd., 2020; Ramadan vd., 2020).



Şekil 4.1. PV hücrede parametre tahmini


PV hücrede bilinmeyen parametrelerin belirlenmesinde literatürde yaygın olarak iki temel yöntem kullanılmaktadır. Bunlar, analitik yöntemler ve meta-sezgisel optimizasyon yöntemidir (Mohapatra vd., 2017; Valer vd., 2017). Analitik yöntemler, matematiksel modellemeye dayalı bir yaklaşımla, üretici veri tarafından sunulan mevcut değerleri ve farklı çalışma koşullarını kullanarak PV sistemlerinin doğrusal olmayan karakteristiklerini elde etmeye odaklanır. En küçük kareler yöntemi, newton-raphson yöntemi, gauss-seidel yöntemi ve parçalı yaklaşım yöntemi gibi bu yöntemler, doğrudan hesaplama ile parametrelerin tahmin edilmesini sağlar. Ancak, analitik yöntemler hesaplama yaparken bazı değerlerin ihmal edilmesi, ilk değer seçiminde yüksek hata riski

gibi faktörlerden dolayı sapmalara neden olmaktadır (Nguyen vd., 2022). Ayrıca, bu yöntemler düşük yakınsama hızı ve düşük verimlilik gibi dezavantajlara sahiptir (Luu ve Nguyen, 2020).

Bu tez çalışmasında da kullanılacak olan meta-sezgisel yöntemler ise, daha karmaşık problemlerde yüksek doğruluk sağlamak amacıyla geliştirilen algoritmik yaklaşımları içerir. Bu yöntemlerde, I-V eğrisini tahmin etmek için eğri uyum prosedürleri uygulanır ve tahmin edilen her bir veri noktası, gerçek ölçüm değerleriyle eşleştirilir. Bu bağlamda, hızlı ve verimli bir arama ile yüksek doğrulukta çözümler üretebilmektedir. Meta-sezgisel yöntemler, parametre tahmininde geleneksel yöntemlerin sınırlamalarını aşarak, özellikle karmaşık ve çok boyutlu problemlerde üstün performans göstermektedir (Chen vd., 2018; Yu, Chen, vd., 2017).

Ayrıca çalışmada önerilen INFO, QIO ve FLO optimizasyon yöntemlerinin doğrusal olmayan denklemlerin çözümünde N-R analitik yöntemi entegre edilmiştir. Bu bağlamda, analitik yöntemlerin hesaplama avantajlarıyla, önerilen algoritmaların güçlü global optimizasyon yetenekleri ve hızlı yakınsama özellikleriyle bir araya getirerek parametrelerin yüksek doğrulukla belirlenmesi amaçlanmıştır (Ayyarao, 2022; Gnetchejo vd., 2021). Şekil 4.2' de literatürde PV parametre tahmini sürecinde sıklıkla kullanılan meta-sezgisel algoritmaları evrim temelli, doğa temelli, insan temelli ve biyo-esinlenmiş yöntemler olarak kategorize ederek, farklı optimizasyon yaklaşımlarının kapsamlı bir sınıflandırmasını sunulmuştur.

Meta-sezgisel Algoritmalar



Şekil 4.2. PV Parametre Çıkarımında Kullanılan Bazı Meta-Sezgisel Algoritmaların Sınıflandırılması


4.1. Matematiksel Formülasyon

PV sistemler, yenilebilir enerji kaynakları açısından nispeten daha ekonomik ve sürdürülebilir çözümler sunarak ön plana çıkmaktadır. Bu sistemlerin mevcut potansiyelleri doğrultusunda güç üretim verimliliğini artırarak yüksek kârların elde edilmesi mümkündür. Bu bağlamda, PV sistemlerin performansının doğru bir şekilde simülasyonu ve analizi kritik önem taşımaktadır (Liu vd., 2020). Tasarımı yapılacak olan güneş hücrelerinin matematiksel modellerinin geliştirilmesi ve ayrıntılı bir şekilde çözümlenmesi önemli bir süreçtir. Önceki bölümlerde değindiğim ve literatürde yaygın

olarak kullanılan elektriksel devre modelleri bulunmaktadır. Bu tez çalışmasında 1-D, 2-D ve 3-D elektriksel devre modelleri kullanılarak analizler yapılmıştır (Oliva vd., 2014). Bu modeller, karakteristik I-V eğrilerini doğru bir şekilde temsil eden ve PV sistemlerin fiziksel davranışıyla beraber çeşitli çalışma koşullarında performansını analiz etmek için temel araçlardır. Her bir model, basit yapıdan karmaşık yapıya doğru analiz edilirken aynı zamanda güneş hücrelerinin fiziksel özelliklerini ve çalışma mekanizmalarını çeşitli düzeylerde doğruluk ve detay sağlamaktadır (Askarzadeh ve Rezazadeh, 2012). İzleyen bölümlerde, bu elektriksel devrelerin matematiksel temelleri ve karakteristik özellikleri analiz edilmiştir

4.1.1. Tek diyot modeli (1-D)

PV güneş hücrelerinin modelleri arasında, basit tasarımı ve uygulama kolaylığı gibi avantajlarından dolayı en yaygın kullanılan 1-D modelidir (Chenouard ve El-Sehiemy, 2020; Izci vd., 2022; Stornelli vd., 2019). Eşdeğer devresi Şekil 4.3'te sunulduğu üzere bir akım kaynağı, paralel bağlı bir diyot (D_1) şönt direnç (R_{sh}) ve seri direnç (R_s)'den oluşur (Chenouard ve El-Sehiemy, 2020; Duman vd., 2022). Devrenin çıkış akımı (I), kirchhoff akım yasası (KAY) ile denklem 4.1'de matematiksel olarak ifade edilmiştir. Burada, I_{ph} fotogenerik akımı ifade ederken, I_{d1} diyot akımı, I_{sh} ise şönt direncin akımını ifade eder (Duman vd., 2022; Stornelli vd., 2019).



Şekil 4.3. 1-D model

$$I = I_{ph} - I_{d1} - I_{sh} \quad (4.1)$$

$$I_{d1} = I_{01} \left(e^{\frac{V+(I \times R_s)}{a \times V_t}} - 1 \right) \quad (4.2)$$

Denklem 4.2’de, R_s , I_0 , V , a sırasıyla seri direnç, doygunluk akımı, çıkış gerilimi ve diyot ideallik faktörü olarak tanımlanmıştır (Stornelli vd., 2019).

$$V_t = \frac{k \times T}{q} \quad (4.3)$$

Denklem 4.3’ te, V_t termal voltajı matematiksel olarak ifade edilmiştir. Burada, k , T , ve q sırasıyla Boltzmann sabiti ($1.3806503 \times 10^{23} J/K$), kelvin cinsinden hücre sıcaklığı (K), ve elektron yükü ($1.60217646 \times 10^{-19} C$) olarak ifade edilmiştir. Ayrıca, şönt direnç akımı I_{sh} ise denklem 4.4’ te olduğu gibi matematiksel olarak ifade edilmiştir (Duman vd., 2022; Stornelli vd., 2019).

$$I_{sh} = \frac{V+(I \times R_s)}{R_{sh}} \quad (4.4)$$

Yukarda verilen tüm ifadelere dayanarak denklem 4.1 aşağıda matematiksel olarak belirtildiği gibi yeniden yazılabilir (Chenouard ve El-Sehiemy, 2020; Premkumar vd., 2021).


$$I = I_{ph} - I_{01} \left[e^{\left(\frac{V+I \times R_s}{a \times V_t} \right)} - 1 \right] - \left[\frac{V+I \times R_s}{R_{sh}} \right] \quad (4.5)$$

Denklem 4.5’te güneş hücresinin çıkış akımı ifade edilmiştir. Burada 1-D modelin I–V karakteristiğini doğru bir şekilde elde etmek için beş bilinmeyen parametrenin (I_{ph} , I_0 , a , R_s , R_{sh}) çıkarımı yapılmalıdır.

4.1.2. Çift diyot modeli (2-D)

PV güneş hücresi karakteristik özelliklerini daha yüksek doğrulukta analiz etmek ve 1-D modelin düşük ışıyım seviyesindeki dezavantajı nedeniyle Şekil 4.4’te eşdeğer devresi sunulan 2-D model geliştirilmiştir (Duman vd., 2022; Izci vd., 2022). Bu modelde, ikinci diyotun devreye paralel bağlanmasıyla elektriksel devrenin

karmaşıklığının artmasına rağmen, düşük ışıyım koşullarında hassas analizler yapılmasını sağlamaktadır (Askarzadeh ve Rezazadeh, 2012; Izci vd., 2022). 2-D elektriksel modelin çıkış akımı (I), KAY ile denklem 4.6’da matematiksel olarak ifade edilmiştir (Askarzadeh ve Rezazadeh, 2012; Izci vd., 2022).



Şekil 4.4. 2-D model

$$I = I_{ph} - I_{d1} - I_{d2} - I_{sh} \quad (4.6)$$

Burada I_{d1} ve I_{d2} , birinci ve ikinci diyot akımlarını ifade etmektedir. Ayrıca bu diyot akımları, denklem 4.7 ve 4.8’de matematiksel olarak ifade edilmiştir (Dal ve Sezgin, 2024).

$$I_{d1} = I_{01} \left(e^{\frac{V+(I \times R_s)}{a_1 \times V_t}} - 1 \right) \quad (4.7)$$

$$I_{d2} = I_{02} \left(e^{\frac{V+(I \times R_s)}{a_2 \times V_t}} - 1 \right) \quad (4.8)$$


Burada, birinci ve ikinci diyotların doygunluk akımlarını sırasıyla I_{01} ve I_{02} , ideallik faktörlerini ise sırasıyla a_1 ve a_2 olarak ifade edilmektedir. Daha önce denklem 4.3 ve 4.4’te sırasıyla V_t ve I_{sh} ifade edilmişti, dolayısıyla çıkış akımı matematiksel olarak denklem 4.9 ‘da sunulduğu üzere yeniden yazılabilir (Askarzadeh ve Rezazadeh, 2012; Dal ve Sezgin, 2024).

$$I = I_{ph} - I_{01} \left(e^{\frac{V+(I \times R_s)}{a_1 \times V_t}} - 1 \right) - I_{02} \left(e^{\frac{V+(I \times R_s)}{a_2 \times V_t}} - 1 \right) - \frac{V+(I \times R_s)}{R_{sh}} \quad (4.9)$$

2-D modelin optimal çalışma koşullarını belirlemek için yedi bilinmeyen parametrenin (I_{ph} , I_{01} , I_{02} , a_1 , a_2 , R_s , R_{sh}) çıkarımı yapılmalıdır.

4.1.3. Üç diyot modeli (3-D)

Şekil 4.5'te eşdeğer devresi sunulan, üçüncü bir diyotun paralel bağlanmasıyla elde edilen 3-D modeli, PV hücrelerin en detaylı ve karmaşık modelidir (Ali vd., 2023; Dal ve Sezgin, 2024). Uzay-yük bölgesi, yarı-nötr bölge ve üçüncü bir bölgedeki kayıpların analizini içeren ve düşük ışınım seviyesinde yüksek doğrulukta sonuçlar veren güneş hücre modellerinin en gelişmiş ve karmaşık elektriksel devresidir (Ali vd., 2023). Endüstriyel uygulamalarda daha yaygın kullanılan bu model, 1-D ve 2-D elektriksel devrelerine göre daha detaylı matematiksel analizler içermektedir (Dal ve Sezgin, 2024). 3-D'de çıkış akımı (I) KAY ile denklem 4.10'da matematiksel olarak ifade edilmiştir.



Şekil 4.5. 3-D model

$$I = I_{ph} - I_{d1} - I_{d2} - I_{d3} - I_{sh} \quad (4.10)$$

Burada I_{d1} , I_{d2} , I_{d3} sırasıyla birinci, ikinci ve üçüncü diyot akımlarını ifade etmektedir. Daha önce denklem 4.7 ve 4.8 sırasıyla I_{d1} ve I_{d2} akımları matematiksel olarak ifade edilmişti. Denklem 4.11'de I_{d3} diyot akımının matematiksel denklemi verilmiştir.

$$I_{d3} = I_{03} \left(e^{\frac{V + (I \times R_s)}{a_3 \times V_t}} - 1 \right) \quad (4.11)$$

Burada, I_{03} ve a_3 sırasıyla üçüncü diyotun doygunluk akımı ve ideallik faktörünü olarak tanımlanmaktadır. Daha önce denklem 4.3 ve 4.4'te sırasıyla V_t ve I_{sh} ifade edilmişti, dolayısıyla çıkış akımı matematiksel olarak denklem 4.12 'de sunulduğu üzere yeniden yazılabilir (Ali vd., 2023; Dal ve Sezgin, 2024).

$$I = I_{ph} - I_{01} \left(e^{\frac{V+(I \times R_s)}{a_1 \times V_t}} - 1 \right) - I_{02} \left(e^{\frac{V+(I \times R_s)}{a_2 \times V_t}} - 1 \right) - I_{03} \left(e^{\frac{V+(I \times R_s)}{a_3 \times V_t}} - 1 \right) - \frac{V+(I \times R_s)}{R_{sh}} \quad (4.12)$$

Denklem 4.12'de 3-D modelin çıkış akımı matematiksel olarak yeniden ifade edilmiştir. Burada optimal çalışma koşulları için dokuz bilinmeyen parametrenin (I_{ph} , I_{01} , I_{02} , I_{03} , a_1 , a_2 , a_3 , R_s , R_{sh}) çıkarımı yapılmalıdır.

4.2. Amaç Fonksiyonu ve Performans Metrikleri

PV güneş hücrelerinde parametre tahmini probleminde, optimizasyon sürecinin bir parçası olarak kullanılan algorithmadan bağımsız bir amaç fonksiyonuna ihtiyaç duyulmaktadır (Diab vd., 2020). Amaç fonksiyonu, önerilen algoritma için sayısal bir ölçüt sağlayarak doğruluk performansını adil bir şekilde karşılaştırılmasında ve yöntemin başarısında kritik rol oynamaktadır (Diab vd., 2022; Yang vd., 2020). PV hücrelerde parametre tahmini için kullanılan amaç fonksiyonlarının temel amacı ise, ölçülen ve tahmin edilen parametre değerleri arasındaki hata farkını görmemizi sağlayarak tahmin sürecinin genel kalitesini belirlemektir (Babu vd., 2016; Diab vd., 2022; Gao vd., 2016). Bu parametre tahmini sürecinde, RMSE literatürde yaygın olarak kullanılan bir amaç fonksiyonu olarak öne çıkmaktadır (Babu vd., 2016; Gao vd., 2016). Bu tez çalışmasında ana karşılaştırma kriteri olarak RMSE fonksiyonu kullanılmıştır. 1-D, 2-D ve 3-D modellerine ait RMSE amaç fonksiyonları ise sırasıyla denklem 4.13, 4.14 ve 4.15'te matematiksel olarak ifade edilmektedir (Ali vd., 2023).

$$J(V, I, x) = I_{ph} - I_{01} \left[e^{\left(\frac{V+(I \times R_s)}{a_1 \times V_t} \right)} - 1 \right] - \left[\frac{V+(I \times R_s)}{R_{sh}} \right] \quad (4.13)$$

$$J(V, I, x) = I_{ph} - I_{01} \left(e^{\frac{V+(I \times R_s)}{a_1 \times V_t}} - 1 \right) - I_{02} \left(e^{\frac{V+(I \times R_s)}{a_2 \times V_t}} - 1 \right) - \frac{V+(I \times R_s)}{R_{sh}} \quad (4.14)$$

$$J(V, I, x) = I_{ph} - I_{01} \left(e^{\frac{V+(I \times R_s)}{a_1 \times V_t}} - 1 \right) - I_{02} \left(e^{\frac{V+(I \times R_s)}{a_2 \times V_t}} - 1 \right) - I_{03} \left(e^{\frac{V+(I \times R_s)}{a_3 \times V_t}} - 1 \right) - \frac{V+(I \times R_s)}{R_{sh}} \quad (4.15)$$

x , kullanılan optimizasyon algoritmasında çıkarılması gereken parametreleri içeren çözüm vektörünü temsil etmektedir (Ali vd., 2023; Dal ve Sezgin, 2024).

$$RMSE(x) = \sqrt{\frac{1}{N} \sum_{i=1}^N J(I_i^{\text{ölçülen}} - I_i^{\text{tahmin edilen}})^2} \quad (4.16)$$

N , ölçülen toplam veri noktası sayısını temsil etmektedir. Amaç fonksiyonu (RMSE), denklem 4.16'da matematiksel olarak formülize edilmiştir (Izci vd., 2022). Tablo 4.1'de verilen farklı amaç fonksiyonları önerilen algoritmaların (INFO, QIO ve FLO) performansını ve doğruluğunu değerlendirmek amacıyla IAE, RE, MAE, MBE, NRMSE, NMBE, NMAE, R^2 ve t-istatistiği (t) gibi farklı kıyaslama özelliklerine sahip amaç fonksiyonları ile ayrıntılı olarak analiz edilmiştir (Messaoud, 2020a, 2020b; Singh, Sharma, Rajput, Bose, vd., 2022). Bu amaç fonksiyonları, önerilen algoritmaların PV parametre tahmin performansını çeşitli açılardan değerlendirmek amacıyla kullanılmaktadır. Ayrıca, elde edilen sonuçların güvenilirliğini, kararlılığını ve gerçek dünya uygulamalarıyla uyumluluğunu analiz etme imkânı sunmaktadır.

Tablo 4.1. Amaç fonksiyonları

Fonksiyon isimleri	Fonksiyon formülü
Bireysel mutlak hata (Akım)	$IAE_{akım} = \sum_{i=1}^N I_{\bar{o}} - I_t $
Bireysel mutlak hata (Güç)	$IAE_{güç} = \sum_{i=1}^N P_{\bar{o}} - P_t $
Bağıl hata	$RE = \frac{I_{\bar{o}} - I_t}{I_{\bar{o}}}$
Ortalama mutlak hata	$MAE = \frac{1}{N} \sum_{i=1}^N I_{\bar{o}} - I_t $
Ortalama yanlılık hatası	$MBE = \frac{1}{N} \sum_{i=1}^N (I_{\bar{o}} - I_t)$
Normalleştirilmiş MBE	$NMBE = \frac{MBE}{mean(I_{\bar{o}})}$
Normalleştirilmiş RMSE	$NRMSE = \frac{RMSE}{mean(I_{\bar{o}})}$
Normalleştirilmiş MAE	$NMAE = \frac{MAE}{mean(I_{\bar{o}})}$
t-istatistiği	$t = \sqrt{\frac{(N-1) * MBE^2}{RMSE^2 - MBE^2}}$
Belirleme katsayısı	$R^2 = 1 - \frac{\sum (I_{\bar{o}} - I_t)^2}{\sum (I_{\bar{o}} - mean(I_{\bar{o}}))^2}$

Burada, N örnek sayısını, I_0 ölçülen akımı, I_t tahmin edilen akımı, P_0 ölçülen gücü ve P_t tahmin edilen gücü temsil etmektedir.

4.3. Meta-Sezgisel Yöntem Tabanlı Güneş Fotovoltaik Parametre Tahmini

PV sistemlerde modelleme, çok sayıda bilinmeyen parametrenin varlığı, matematiksek formülasyondaki zorluklar ve doğrusal olmayan çok sayıda denklemin çözülmesi gibi kısıtlamalar ile karşı karşıyadır (Nunes vd., 2018). Ayrıca bu problemin çözümünde, açık devre gerilimi (V_{oc}), kısa devre akımı (I_{sc}), maksimum güç noktası gerilimi (V_{mpp}) ve maksimum güç noktası akımı (I_{mpp}) gibi karmaşık çalışma koşullarında belirli değişkenlere bağlı olmasından dolayı analitik yöntemlerin kullanımını kısıtlamaktadır (Feltrin ve Freundlich, 2008). PV güneş hücresi parametre tahmini probleminde analitik yöntemlerin kullanımı, karmaşık denklemlerin çözümü için zaman açısından ciddi maliyeti, ilk değer seçinde yüksek hata riski ve optimal sonuçlara ulaşmak için bir çok kez deneme girişi gibi dezavantajlarından dolayı önemli ölçüde sınırlıdır (Humada vd., 2016). Bu sınırlamaları aşmak ve daha etkili bir yaklaşım geliştirmek amacıyla, meta-sezgisel optimizasyon yöntemleri önemli bir alternatif olarak ön plana çıkmaktadır. Meta-sezgisel yöntemler, PV sistemlerde parametre tahmini problemine yönelik yapılan analizlerde gerçek karakteristik eğrileriyle neredeyse bire bir uyumlu olup düşük hata payı sunduğu gözlemlenmiştir (Abbassi vd., 2018; Humada vd., 2016). Ayrıca, bu algoritmalar, sadece statik koşullar altında değil, güneş ışıını ve sıcaklık gibi dinamik değişkenlerin etkisi altında da modelleme yapma kapasitesine sahiptir. Bu durum, meta-sezgisel algoritmaları PV modelleme sürecinde analitik yöntemlere kıyasla daha esnek ve uygulanabilir bir çözüm haline getirmiştir (Abbassi vd., 2018).

Meta-sezgisel algoritmalar, yerel ve global optimum çözüm noktalarını belirlemede yüksek keşif yetenekleri ve matematiksel modellerden bağımsız farklı problemlere kolayca uygulanabilmektedir. Şekil 4.2’de sunulduğu üzere bu algoritmalar, evrim temelli, doğa temelli, insan temelli ve biyolojik temelli olmak üzere dört ana kategoriye ayrılmaktadır. Bu yöntemler, zorlu mühendislik problemlerine etkili çözümlere sunarak PV parametre çıkarımında daha hassas ve güvenilir sonuçları ile analitik yöntemlere kıyasla etkili bir yöntem olarak fark yaratmaktadır.

5. FOTOVOLTAİK HÜCREDE PARAMETRE TAHMİNİ İÇİN FARKLI META-SEZGİSEL ALGORİTİMLER

PV hücrede parametre tahmin probleminde en yaygın kullanılan yöntem, daha önce vurguladığım üzere, gerçek karakteristik eğrilerine neredeyse bire bir uyumlu sonuçlar veren meta-sezgisel algoritmalarıdır. Literatürde, parametre tahmini için birçok algoritma önerilmiştir. Bu tez çalışmasında, INFO, QIO ve FLO algoritmaları seçilmiş ve ayrıntılı analiz edilmiştir. Ayrıca çalışmada önerilen optimizasyon algoritmalarının doğrusal olmayan denklemlerin çözümünde N-R analitik yöntemi entegre edilmiştir. Bu meta-sezgisel algoritmaların PV panel parametrelerini tahmin etmedeki etkinliğini belirlemek amacıyla adil ve kapsamlı bir karşılaştırma yapabilmek için her algoritmanın RMSE metriği dikkate alınmıştır. Bu bağlamda en düşük RMSE değerine sahip olan algoritma, PV parametre çıkarımı probleminde daha etkili yöntem olarak kabul edilmektedir.

5.1 Vektörlerin Ağırlıklı Ortalaması (INFO) Algoritması

Popülasyon tabanlı bir optimizasyon süreci olan vektörlerin ağırlıklı ortalaması (INFO) algoritması, keşif uzayını kapsayan bazı vektörlerin ağırlıklarının ortalamasını hesaplayan ve popülasyonda potansiyel en iyi çözümleri arayan bir dizi vektör grubudur. INFO, vektörlerin önceden belirlenmiş güncelleme kural aşamasına göre pozisyon alıp en iyi çözüme odaklanan, yeni ve en iyi çözümleri keşfetmek için ağırlıklı ortalama kullanarak vektörleri birleştirme ve en uygun çözüme doğru yakınsayarak çözümleri geliştiren yerel arama aşamaları olmak üzere üç ana aşamadan oluşur (Ahmadianfar vd., 2022).

INFO algoritması, $(X_{i,j}^{gen} = \{x_{i,1}^{gen}, x_{i,2}^{gen}, \dots, x_{i,A}^{gen}\}, i = 1, 2, \dots, N_p)$ A boyutlu arama alından ve N_p vektöründen oluşan bir popülasyondur. Algoritma başlangıçta nesiller boyunca değişkenlik gösterebilen ağırlıklı ortalama faktörü (δ) ve ölçeklendirme faktörü (σ) olmak üzere iki ana kontrol parametresinden oluşur. Ayrıca INFO, başlangıç vektörlerini rastgele üretim yöntemini kullanacak şekilde belirler (Ahmadianfar vd., 2022).

5.1.1. Güncelleme kuralı

Bu aşamada, vektörleri rastgele belirlemek için ağırlıklı ortalama tabanlı bir kural tanımlanır. Güncelleme kuralı aslında, rastgele belirlenmiş bir başlangıç çözümünü kullanır. Daha sonra rasgele belirlenen vektörlerin ağırlıklı ortama bilgisini temel alarak yeni çözümler üretilir. Bu bağlamda en iyi, iyi ve en kötü çözümlerin ortalama kuralı (MeanRule) belirlenir. Bu çözümler, aşağıda verilmiş olan matematiksel denklemlere göre tespit edilir (Ahmadianfar vd., 2022).

$$MeanRule = r * WM1_l^g + (1 - r) * WM2_l^g \quad (5.1)$$

$$WM1_l^g = \delta * \frac{W_1(x_{a1}-x_{a2})+W_2(x_{a1}-x_{a3})+W_3(x_{a2}-x_{a3})}{w_1+w_2+w_3+\varepsilon} + \varepsilon * rand \quad (5.2)$$

$$l = 1,2,3 \dots N_p$$

Burada,

$$W_1 = \cos((f(x_{a1}) - f(x_{a2})) + \pi) * e^{-\left|\frac{f(x_{a1})-f(x_{a2})}{w}\right|} \quad (5.3)$$

$$W_2 = \cos((f(x_{a1}) - f(x_{a3})) + \pi) * e^{-\left|\frac{f(x_{a1})-f(x_{a3})}{w}\right|} \quad (5.4)$$

$$W_3 = \cos((f(x_{a2}) - f(x_{a3})) + \pi) * e^{-\left|\frac{f(x_{a2})-f(x_{a3})}{w}\right|} \quad (5.5)$$

$$w = \max(f(x_{a1}), f(x_{a2}), f(x_{a3})) \quad (5.6)$$

$$WM2_l^g = \delta * \frac{W_1(x_{bs}-x_{bt})+W_2(x_{bs}-x_{ws})+W_3(x_{bt}-x_{ws})}{w_1+w_2+w_3+\varepsilon} + \varepsilon * rand \quad (5.7)$$

$$l = 1,2,3 \dots N_p$$

Burada,

$$W_1 = \cos((f(x_{bs}) - f(x_{bt})) + \pi) * e^{-\left|\frac{f(x_{bs})-f(x_{bt})}{w}\right|} \quad (5.8)$$

$$W_2 = \cos((f(x_{bs}) - f(x_{ws})) + \pi) * e^{-\left|\frac{f(x_{bs})-f(x_{ws})}{w}\right|} \quad (5.9)$$

$$W_3 = \cos((f(x_{bt}) - f(x_{ws})) + \pi) * e^{-\left|\frac{f(x_{bt})-f(x_{ws})}{w}\right|} \quad (5.10)$$

$$w = f(x_{ws}) \quad (5.11)$$

Burada $f(x)$ amaç fonksiyonunu temsil etmektedir. $[1, N_p]$ aralığında rastgele seçilen birbirinden farklı tam sayıları a_1, a_2, a_3 ve l olarak ifade edilmektedir. ε sabit sayıyı, $randn$ ise yine rastgele bir değerdir. g^{th} popülasyondaki tüm vektörler arasında en iyi, iyi, ve en kötü çözümleri sırasıyla x_{bs}, x_{bt}, x_{ws} olarak ifade edilmiştir. $r, [0,0.5]$ aralığında rastgele seçilen sayıdır. w_1, w_2, w_3 ise vektörlerin ağırlıklı ortalamasını hesaplayan ağırlık çarpanlarıdır (Ahmadianfar vd., 2022).

$$\delta = 2\beta * rand - \beta \quad (5.12)$$

$$\beta = 2e^{\left(-4 * \frac{g}{maxg}\right)} \quad (5.13)$$

Burada δ ölçekleme faktörü denklem 5.12’de verilmiştir. Ayrıca denklem 5.13’te verilen β eşitliği ile matematiksel olarak yeniden yazılabilir. $maxg$ ise maksimum jenerasyon sayısını ifade etmektedir. Yakınsama hızlandırma (CA) matematiksel olarak denklem 5.14’te verilmiştir. Yakınsama hızlandırma arama alanında en iyi çözümü ararken vektörlerin daha iyi yöne hareketine yardımcı olur.

$$CA = rand * \frac{(x_{bs} - x_{a1})}{(f(x_{bs}) - f(x_{a1}) + \varepsilon)} \quad (5.14)$$

Burada $rand [0,1]$ aralığında rastgele bir sayıdır. (CA)’nın bu aralıkta rastgele bir sayı ile çarpılmasının nedeni her jenerasyonda farklı adım boyutuna sahip olmasını sağlamaktır. Yeni vektörün son hali aşağıda verilmiştir.

$$z_l^g = x_l^g + \sigma * MeanRule + CA \quad (5.15)$$

Keşif aşamasında güncelleme kuralları aşağıdaki gibi ifade edilebilir.

if $rand < 0.5$

$$z1_l^g = x_l^g + \sigma * MeanRule + rand * \frac{(x_{bs} - x_{a1}^g)}{(f(x_{bs}) - f(x_{a1}^g) + 1)}$$

$$z2_l^g = x_{bs} + \sigma * MeanRule + rand * \frac{(x_{a1}^g - x_b^g)}{(f(x_{a1}^g) - f(x_{a2}^g) + 1)}$$

else (5.16)

$$z1_l^g = x_a^g + \sigma * MeanRule + rand * \frac{(x_{a2}^g - x_{a3}^g)}{(f(x_{a2}^g) - f(x_{a3}^g) + 1)}$$

$$z2_l^g = x_{bt} + \sigma * MeanRule + rand * \frac{(x_{a1}^g - x_{a2}^g)}{(f(x_{a1}^g) - f(x_{a2}^g) + 1)}$$

end

Burada, $z1_l^g$ ve $z2_l^g$ yeni vektörleri ifade etmektedir. σ , ölçeklendirme faktörüdür ve denklem 5.17’de matematiksel olarak tanımlanmıştır. Ayrıca, denklem 5.18’de a ifadesi ile üstel bir fonksiyon ile de yazılabilir. Ayrıca, c ve d sabit sayılardır.

$$\sigma = 2a * rand - a \quad (5.17)$$

$$a = c * e^{\left(-d * \frac{g}{maxg}\right)} \quad (5.18)$$

5.1.2. Vektör birleştirme

Bu aşamada daha iyi bir yerel arama ve güncel vektörler sağlamak amaçlanmaktadır. Bu bağlamda son olarak ifade edilen $z1_l^g$ ve $z2_l^g$ vektörlerini başka bir vektörle (x_l^g) kombine edilmesiyle yeni vektör (u_l^g) oluşturmaktır (Ahmadianfar vd., 2022).

$$if \ rand < 0.5$$

$$u_l^g = z1_l^g + \mu * |z1_l^g - z2_l^g|$$

$$else$$

$$u_l^g = z2_l^g + \mu * |z1_l^g - z2_l^g| \quad (5.19)$$

$$end$$

$$else$$

$$u_l^g = x_l^g$$

$$end$$

Burada u_l^g vektör birleştirilerek elde edilen yeni vektördür. Ayrıca $\mu = 0.5 * randn$ olarak ifade edilir.

5.1.3. Yerel arama

Bu aşama en uygun çözüme doğru yakınsayarak çözümleri geliştiren kapsamlı bir yerel arama gerçekleştirilir (Ahmadianfar vd., 2022).

if rand < 0.5

if rand < 0.5

$$u_l^g = x_{bs} * randn * (MeanRule + randn * (x_{bs}^g - x_{a1}^g))$$

else (5.20)

$$u_l^g = x_{rnd} * randn * (MeanRule + randn * (v_1 * x_{bs} - v_2 * x_{rnd}))$$

end

end

$$x_{rnd} = \varphi * x_{avg} + (1 - \varphi) * (\varphi * x_{bt} + (1 - \varphi) * x_{bs}) \quad (5.21)$$


$$x_{avg} = \frac{(x_a + x_b + x_3)}{3} \quad (5.22)$$

Burada φ [0,1] aralığından rastgele seçilen değerdir. x_{rnd} ise yeni çözümü ifade eder. Ayrıca v_1 ve v_2 matematiksel olarak denklem 5.23 ve 5.24'te tanımlandığı gibi rastgele sayılardır.

$$v_1 = \begin{cases} 2 * rand, & \text{if } p > 0.5 \\ 1, & \text{diğer} \end{cases} \quad (5.23)$$

$$v_2 = \begin{cases} rand, & \text{if } p < 0.5 \\ 1, & \text{diğer} \end{cases} \quad (5.24)$$

Burada p , [0,1] aralığında seçilen rastgele bir sayıdır. INFO algoritmasının akış diyagramı Şekil 5.1'de verilmiştir.



Şekil 5.1. INFO algoritmasının akış diyagramı

5.2 İkinci Dereceden Enterpolasyon Optimizasyonu (QIO)

İkinci dereceden enterpolasyon optimizasyonu (QIO) algoritması, doğrudan matematiksel kavramlardan türetilmiş ve optimizasyon problemlerine yeni bir bakış açısı sunan bir meta-sezgisel algoritmadır. QIO, optimizasyon süreçlerinde ikinci dereceden enterpolasyon prensiplerini kullanarak, belirli bir fonksiyonun minimum veya maksimum noktasını etkili bir şekilde bulmayı amaçlar. QIO algoritması, ikinci dereceden enterpolasyon temel prensiplerine dayanır. Bu bağlamda, üç veri noktasından bir parabola geçirerek fonksiyonun minimum veya maksimum noktasını bulmayı amaçlar. QIO, bu prensibi genişleterek, optimize edilecek bir fonksiyonun minimum noktasını belirlemek için genelleştirilmiş quadratic interpolasyon (GQI) yöntemini kullanır. GQI yöntemi, optimize edilmesi gereken bir fonksiyonun üç nokta üzerinden en uygun çözümünü bulmayı amaçlar. Bu yöntem, mevcut quadratic interpolasyon tekniklerinin sınırlarını genişleterek, daha karmaşık ve çok boyutlu problemlerde de etkili çözümler sunabilir (Zhao vd., 2023). GQI yöntemi şu şekilde işler:

1. Üç Nokta Seçimi: QIO algoritması, optimize edilecek fonksiyonun farklı noktalarından üç değer seçer. Bu noktalar, fonksiyonun davranışını temsil eden ve minimize edici noktayı belirlemeye yardımcı olan noktalardır.
2. Quadratic İnterpolasyon: Seçilen bu üç noktadan bir parabola geçecek şekilde quadratic interpolasyon yapılır. Bu parabola, fonksiyonun minimum noktasını belirlemekte kullanılır.
3. Minimize Edici Hesaplaması: Quadratic interpolasyon sonucunda elde edilen parabola, fonksiyonun minimum noktasını verir. Bu nokta, fonksiyonun optimize edilmesi gereken parametrelerinin yeni değerlerini belirlemek için kullanılır.

GQI yönteminin bu güçlü yapısı, QIO algoritmasının optimizasyon problemlerinde etkili ve verimli bir çözüm sunmasını sağlar. QIO algoritması, genelleştirilmiş bir ikinci dereceden interpolasyon (GQI) yöntemi üzerine kuruludur. Bu yöntem, herhangi üç noktadan oluşan bir kümeyle elde edilen parabolik interpolasyon fonksiyonunun minimum noktasını hesaplar. Bu sayede, arama alanında daha etkili bir şekilde arama yapılabilir. İkinci dereceden interpolasyon fonksiyonu denklem 5.25'te görüldüğü üzere şu şekilde ifade edilir (Zhao vd., 2023):

$$L(x) = \alpha x^2 + \beta x + \delta \quad (5.25)$$

Burada α , β ve δ belirsiz katsayıları üç noktaya bağlı olarak belirlenir. Bu katsayılar, $P_i(x_i, f(x_i))$, $P_j(x_j, f(x_j))$ ve $P_k(x_k, f(x_k))$ noktalarından hesaplanır. Burada $f(x)$ yaklaşık minimum noktası kuadratik interpolasyon polinomu $L(x)$ ile bulunur. x_i , x_j ve x_k enterpolasyonda kullanılan üç farklı noktanın veya bireyin konumlarını temsil etmektedir ve bu noktalar $\alpha \leq x_i < x_j < x_k < \beta$ koşulu ile sınırlandırılmıştır. Burada, α ve β sırasıyla alt ve üst sınırları ifade etmektedir (Zhao vd., 2023).


$$\begin{aligned} L(x_i) &= \alpha x_i^2 + \beta x_i + \delta = f(x_i) \\ L(x_j) &= \alpha x_j^2 + \beta x_j + \delta = f(x_j) \\ L(x_k) &= \alpha x_k^2 + \beta x_k + \delta = f(x_k) \end{aligned} \quad (5.26)$$

Minimum noktayı x^* bulmak için türev alınır ve sıfıra eşitlenir.

$$x^* = -\frac{\beta}{2\alpha} \quad (5.27)$$

Bu minimum nokta çözümlerin pozisyonlarının güncellenmesi için kullanılır. Daha sonra α ve β denklem 5.28’de sunulduğu üzere matematiksel olarak ifade edilmiştir (Zhao vd., 2023).

$$\begin{aligned} \alpha &= \frac{(x_j - x_k)f(x_i) + (x_k - x_i)f(x_j) + (x_i - x_j)f(x_k)}{(x_j - x_k)(x_k - x_i)(x_i - x_j)} \\ \beta &= -\frac{(x_j^2 - x_k^2)f(x_i) + (x_k^2 - x_i^2)f(x_j) + (x_i^2 - x_j^2)f(x_k)}{(x_j - x_k)(x_k - x_i)(x_i - x_j)} \end{aligned} \quad (5.28)$$



Şekil 5.2. Kuadratik enterpolasyonun şematik gösterimi (Zhao vd., 2023)

$L(x)$ Fonksiyonunun minimum noktası aşağıdaki gibi hesaplanmış olur (Zhao vd., 2023).

$$x^* = \frac{(x_j^2 - x_k^2)f(x_i) + (x_k^2 - x_i^2)f(x_j) + (x_i^2 - x_j^2)f(x_k)}{2((x_j - x_k)f(x_i) + (x_k - x_i)f(x_j) + (x_i - x_j)f(x_k))} \quad (5.29)$$

Bu arada, ikinci dereceden interpolasyon polinomu $L(x)$ denklem 5.30'da matematiksel olarak sunulduğu gibi elde edilir (Zhao vd., 2023):

$$L(x) = \frac{(x-x_j)(x-x_k)}{(x_i-x_j)(x_i-x_k)}f(x_i) + \frac{(x-x_i)(x-x_k)}{(x_j-x_i)(x_j-x_k)}f(x_j) + \frac{(x-x_i)(x-x_j)}{(x_k-x_i)(x_k-x_j)}f(x_k) \quad (5.30)$$

Daha önce tahmin edilen minimum nokta x^* baz alınarak arama aralığı daraltılır ve üç noktadan oluşan yeni bir arama aralığı oluşturulur. Kuadratik interpolasyon bu aralıkta tekrar uygulanır ve bu işlem istenen hassasiyet sağlanana kadar devam eder. Bu yinelemeli süreç, nihai yaklaşık minimum noktanın bulunmasını sağlar.

5.2.1. Güncelleme kuralı

QIO algoritması, her bireyin konumunu, elde edilen minimum nokta kullanarak günceller. Bu süreç, çözüme yakın bölgelerde yoğunlaşarak optimum sonuçları bulmayı hedefler. Matematiksel olarak denklem 5.31’de sunulan formülde, bir bireyin pozisyonunun nasıl güncellendiğini gösterir:

$$x_i^{new} = \frac{x_j + x_k}{2} - \frac{f(x_j) - f(x_k)}{x_j - x_k} \quad (5.31)$$

Burada; x_i^{new} güncelleme sonrasında noktanın yeni konumunu ifade eder. x_j popülasyonda seçilen ilk noktanın konumu, x_k ise popülasyonda seçilen ikinci noktanın konumudur. $f(x_j)$, x_j konumundaki fonksiyon değerini temsil eder ve bu noktada hesaplanan amaç fonksiyonunu gösterir. Benzer şekilde, $f(x_k)$, x_k konumundaki fonksiyon değerini ifade eder ve bu noktada değerlendirilen amaç fonksiyonunu temsil etmektedir (Zhao vd., 2023).

5.2.2 Vektör birleştirme

Vektör birleştirme, QIO algoritmasının arama kabiliyetini artırmak için kullandığı bir stratejidir. Seçilen bireylerin pozisyonları birleştirilerek daha iyi bir aday çözüm oluşturulur:

$$v_i = a \cdot p_j + b \cdot p_k + c \cdot p_l \quad (5.32)$$


v_i , oluşturulan yeni vektörü ifade etmekte olup, a , b ve c ise sırasıyla p_j , p_k ve p_l üzerine uygulanan ağırlıklardır.

5.2.3 Yerel arama

Yerel arama, QIO'nun çözüm yakınındaki bölgelerde daha ince ayar yaparak çözüm kalitesini artırdığı bir bileşendir. Bu süreçte, adım büyüklükleri küçültülerek daha hassas bir arama yapılır:

$$x_{local} = x_{best} - \gamma \cdot (x_{best} - x_{rand}) \quad (5.33)$$

Denklem 5.33’te, x_{local} yerel arama sırasında bulunan yeni konumu ifade eder ve en iyi nokta etrafında çözümü iyileştirmeye odaklanır. x_{best} , arama sürecindeki mevcut en iyi çözümü temsil eder ve yerel aramada referans olarak kullanılır. x_{rand} popülasyondan rastgele seçilen bir noktayı ifade eder ve aramaya çeşitlilik kazandırır (Zhao vd., 2023). QIO algoritmasının akış diyagramı Şekil 5.3’te verilmiştir.



Şekil 5.3. QIO algoritmasının akış diyagramı

5.3 Boyunlu Kertenkele Optimizasyonu (FLO)

Boyunlu kertenkele optimizasyonu (frilled lizard optimization, FLO), algoritması boyunlu kertenkelelerin avlanma, avına doğru hareket etme ve avcılara karşı korunma davranışlarından esinlenilerek tasarlanmış bir optimizasyon algoritmasıdır. Karmaşık problemleri çözmeyi hedefleyen bu algoritma iki birbirinden bağımsız temel kısımdan oluşmaktadır. Bunlar keşif (exploration) ve sömürü (exploitation) kısımlarıdır (Abualigah vd., 2024; Falahah vd., 2024).

5.3.1 Keşif aşaması

Bu kısım, boyunlu kertenkelelerin pusu kurması ve avına doğru hareketini taklit ederek başlar. Burada temel amaç problemi çözmek için çeşitli bölgelere bakarak daha iyi çözümler bulmaktır. Daha sonra boyunlu kertenkelelerin avlanma stratejisi kullanılarak, bireylerin konumlarını ve hedef fonksiyon değerlerini gözlemleyerek pozisyonları güncellenir. Yani bireyler kendi durumlarına göre en iyi performansı gösteren diğer bireyleri hedef alarak kendi pozisyonlarını güncellemiş olurlar. Bu tasarım sayesinde FLO algoritması, potansiyel av noktalarını denklem 5.34 doğrultusunda belirlemektedir (Abualigah vd., 2024; Falahah vd., 2024).

$$C_{FL_i} = \{X_i \mid F_k < F_i \text{ ve } k \neq i\} \quad (5.34)$$

Bu denklemde C_{FL_i} , i 'inci bireyin avlarının yerlerini temsil eder. Burada diğer bireylerin hedef fonksiyon değerleri dikkate alınarak en iyi değerden uzaklaşmamak amaçlanır. Sonraki adımda gerçekleşen pozisyon güncellemesi aşağıdaki denklem ile ifade edilir (Abualigah vd., 2024; Falahah vd., 2024).

$$X_{i,j}^* = x_{i,j} + r_{i,j} \cdot (SP_{i,j} - I_{i,j} \cdot x_{i,j}) \quad (5.35)$$

Bu denklemde $X_{i,j}^*$ güncellenmiş yeni pozisyon değerini, $x_{i,j}$ mevcut pozisyon değerini, $SP_{i,j}$ hedef pozisyon değerini, $r_{i,j}$ rastgele bir faktör, $I_{i,j}$ diğer bireylerin etkisini belirleyen bir faktörü ifade eder. Bulunan yeni pozisyon değerinin hangi koşullarda kabul edileceğini gösteren matematiksel olarak denklem 5.36'da ifade edilmiştir (Abualigah vd., 2024; Falahah vd., 2024).

$$X_i = \begin{cases} X_{i,j}^*, & F_{i,j}^* < F_i \\ X_i, & \text{diğer} \end{cases} \quad (5.36)$$

Denklemde 5.36'da, $F_{i,j}^*$ ve F_i sırasıyla yeni pozisyonun hedef fonksiyonu ve mevcut pozisyonun hedef fonksiyonu olarak ifade edilmektedir.


5.3.2 Sömürü aşaması

Bu kısım, avlandıktan sonra boyunlu kertenkelesinin güvenli bir alan bulmak için yakınlardaki bir ağaca tırmanma davranışını taklit eder. Bu kısmın temel amacı, keşif aşamasında bulunan parametreleri optimize etmektir. Bu amaçla önceden bulunan bölgeler derinlemesine incelenerek daha verimli çözümler elde etmek hedeflenir. Bu kısımda, her bir pozisyon güncellemeleri denklem 5.37’de matematiksel olarak sunulduğu şekilde gösterilir (Abualigah vd., 2024; Falahah vd., 2024).

$$X_{i,j}^{(t+1)} = x_{i,j} + (1 - 2r) \cdot (U_{\text{best}} - L_{\text{best}}) \quad (5.37)$$

Yukarıdaki denklemde $X_{i,j}^{(t+1)}$ ikinci aşamadaki güncellenmiş pozisyonu, $x_{i,j}$ mevcut pozisyonu, U_{best} bulunan en iyi çözümü, L_{best} bulunan en kötü çözümü ve r rastgele bir faktör ifade eder. Ardından, elde edilen yeni pozisyonun kabul edilip edilmeyeceği, Denklem 5.38 doğrultusunda belirlenmektedir (Abualigah vd., 2024; Falahah vd., 2024). FLO algoritmasının akış diyagramı Şekil 5.4’te verilmiştir.

$$X_i = \begin{cases} X_{i,j}^{(t+1)}, & F_{i,j}^{(t+1)} < F_i \\ X_i, & \text{diger} \end{cases} \quad (5.38)$$



Şekil 5.4. FLO algoritmasının akış diyagramı

5.4 Önerilen Algoritmalara Newton-Raphson Yönteminin Entegrasyonu

Güneş PV sistemlerinin doğru ve güvenilir bir şekilde analiz edilebilmesi için, PV modelinin farklı çalışma koşulları altındaki dinamik davranışını gerçekçi bir şekilde yansıtan güvenilir bir tasarım oluşturulması kritik bir gerekliliktir (Ridha vd., 2022). Bu tür hassas modellerin oluşturulması, karmaşık bir optimizasyon problemini beraberinde getirmektedir. Doğrusal olmayan bu problemlerin çözümünde kullanılan amaç fonksiyonu, model tarafından tahmin edilen değerler ile gerçek çalışma koşullarında ölçülen değerler arasındaki uyumu değerlendirmek amacıyla kullanılmaktadır. Bu


çalışmada temel karşılaştırmalar için RMSE fonksiyonundan yararlanılmış olup, ilgili matematiksel ifade Denklem 4.16'da sunulmuştur. Söz konusu karmaşık denklemlerin çözüm noktalarının etkin ve hassas bir şekilde belirlenebilmesi için çeşitli sayısal yöntemlerin entegrasyonu gerekmektedir (Ayyarao, 2022).

Bu tez çalışmasında, nispeten düşük hesaplama maliyeti ve parametre çıkarımında sağladığı yüksek doğruluk avantajları nedeniyle, doğrusal olmayan denklemlerin çözüm noktalarındaki RMSE değerini belirlemek amacıyla Newton-Raphson (N-R) sayısal yöntemi entegre edilmiştir (El-Sayed vd., 2016; Gnetchejo vd., 2021; Izci, Ekinci, ve Hussien, 2024). N-R yöntemi, bir başlangıç noktası x_0 ve belirli bir durdurma kriteri gerektirmektedir. k iterasyon sonrasında güncellenmiş çözüm, denklem 5.39'da ifade edildiği şekilde hesaplanmaktadır.

$$x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)} \quad (5.39)$$

$$|f(x)| < \varepsilon \quad (5.40)$$

Denklem 5.40'ta ifade edilen ε , önceden tanımlanmış bir tolerans değerini temsil etmekte olup, mutlak $f(x)$ değeri bu toleransın altına düştüğünde nihai çözüme ulaşılmaktadır. Bu süreçte, başlangıç noktasının seçimi elde edilen nihai çözüm üzerinde belirleyici bir etkiye sahiptir. Bu bağlamda, ölçülen akım başlangıç noktası olarak tercih edilmiştir, zira elde edilen sonucun tahmin edilen akım ile ölçülen akım arasında yüksek bir doğrulukla uyuşması beklenmektedir. Şekil 5.5'te sunulan görsel, N-R sayısal yöntemi ile önerilen algoritmaların parametre çıkarımındaki entegrasyon sürecini anlatmaktadır. Bu süreçte, PV hücre modeli üzerinden hesaplanan akım ile tahmin edilen akım arasındaki fark minimize edilerek, model parametrelerinin optimize edilmesi hedeflenmektedir. Entegrasyon süreci, hata fonksiyonlarının değerlendirilmesi ve model parametrelerinin güncellenmesi aşamalarını içeren iteratif bir yapı sunmaktadır.



Şekil 5.5. Önerilen algoritmalar doğrultusunda Newton-Raphson yönteminin entegrasyonu ile RMSE hesaplama prosedürü

6. SİMÜLASYON SONUÇLARI VE TARTIŞMA

6.1 Simülasyon Sonuçları

Bu tez çalışmasında, güneş PV hücrelerinin parametre tahmini için önerilen INFO, QIO ve FLO algoritmalarının performansı kapsamlı bir şekilde değerlendirilmiştir. Algoritmaların etkinliğini doğrulamak amacıyla, literatürde yer alan ve farklı sıcaklık ve ışıyım koşulları altında elde edilen gerçek akım-gerilim verileri kullanılmıştır. Analizlerde kullanılan veri setleri, PV modüllerinin karakteristiklerini adil ve tutarlı bir şekilde karşılaştırılmasını sağlamak üzere titizlikle seçilmiştir. Çalışmada kullanılan veri setleri, farklı bağlantı konfigürasyonlarına ve çeşitli malzeme teknolojilerine sahip panelleri içermektedir. Bu kapsamda, 57 mm çapında, 1000 W/m² ışıyım altında ve 33 °C sıcaklıkta ölçülen R.T.C. France ticari silikon güneş hücresine, sırasıyla 51 °C ve 55 °C'de ölçülen 36 seri bağlı monokristalin hücreden oluşan STM6-40/36 ve STP6-120/36 ve 45 °C sıcaklıkta ölçülen, seri bağlı 36 hücreden oluşan Photowatt-PWP201 modülüne ait veriler analiz edilmiştir (Abd El-Mageed vd., 2023; Gu vd., 2023; Kullampalayam Murugaiyan vd., 2024; Yu, Duan, vd., 2023). Bu tez kapsamında, 1-D, 2-D ve 3-D elektriksel modelleri üzerinde ayrı ayrı gerçekleştirilen analizlerde, RMSE, IAE, RE, MAE, MBE, t-istatistiği, R², NRMSE, NMBE ve NMAE gibi amaç fonksiyonları objektif değerlendirme kriterleri olarak kullanılmıştır. Bu doğrultuda, önerilen yöntemlerin doğruluğu ve etkinliği çok yönlü olarak incelenmiş ve elde edilen hesaplamalar detaylı bir şekilde sunulmuştur.

Tablo 6.1'de yer alan RTC France, Photowatt-PW201, STM6-40/36 ve STP6-120/36 modül verileri için belirlenen parametre sınırları verilmiştir. Bu sınırlar modüllerin performans ve verimlilik özelliklerini belirleyen kritik değerleri yansıtmaktadır (Gu vd., 2023; Kullampalayam Murugaiyan vd., 2024; Yu, Duan, vd., 2023). Üst sınırlar, modüllerin maksimum değerleri gösterirken, alt sınırlar ise minimum değerleri ifade eder. Bu sınırlar, modüllerin tasarımı ve performans analizi açısından kritik bilgiler sunar ve kullanıcıların modülleri çeşitli koşullar altında değerlendirmelerine yardımcı olur. Bu bilgiler, modüllerin etkinliğini değerlendirmek ve ihtiyaçlara göre en uygun çözümü belirlemek için temel teşkil eder. Çalışmada, önerilen algoritmalar kullanılarak tüm elektriksel devre modelleri (1-D, 2-D ve 3-D) için ölçülen ve tahmin edilen akım-gerilim (I-V) ve güç-gerilim (P-V) karakteristikleri, maksimum

güç noktası (MPP) konumları ve yakınsama eğrileri kapsamlı bir şekilde sunulmuştur. Ayrıca, algoritmaların performansını niceliksel olarak değerlendirmek amacıyla, maksimum, minimum, standart sapma, ortalama ve varyans gibi istatistiksel metrikler hesaplanmış ve sonuçların dağılımını görselleştirmek için ilgili grafikler detaylı olarak analiz edilmiştir. Önerilen algoritmalar, 1-D, 2-D ve 3-D elektriksel devre modelleri üzerinde kullanılan dört farklı veri setiyle gerçekleştirilen tüm analizlerde adil ve tutarlı bir karşılaştırma sağlamak amacıyla 30 çalıştırmada test edilmiştir. Deneylerde, 40 bireyden oluşan bir popülasyon büyüklüğü ve maksimum 800 iterasyon kullanılmıştır. Ayrıca çalışmanın simülasyonu Intel(R) Core (TM) i7-7500U CPU @ 2.70GHz 2.90 GHz 8 GB RAM donanımıyla MATLAB R2022a yazılımı kullanılarak analiz edilmiştir.

Tablo 6.1. Parametre sınır değerleri

Parametreler	R.T.C France Veri Seti		STM6-40/36 Veri Seti		STP6-120/36 Veri Seti		Photowatt-PWP201 Veri Seti	
	Üst Sınır	Alt Sınır	Üst Sınır	Alt Sınır	Üst Sınır	Alt Sınır	Üst Sınır	Alt Sınır
I_{ph} (A)	1	0	2	0	8	0	2	0
R_s (Ω)	0,5	0	0,36	0	0,36	0	2	0
R_{sh} (Ω)	100	0	1000	0	1500	0	2000	0
a_1, a_2, a_3	2	1	60	1	50	1	50	1
I_{01}, I_{01}, I_{02} (μA)	1	0	50	0	50	0	50	0


6.1.1 R.T.C France veri setiyle elde edilen sonuçlar

Bu alt bölüm, önerilen INFO, QIO ve FLO algoritmalarının R.T.C France modül verileri kullanılarak 1-D, 2-D ve 3-D modellerine ait analiz sonuçları detaylı bir şekilde sunulmuştur. Öncelikle, Tablo 2'de 1-D modeli için tahmin edilen beş bilinmeyen parametre (I_{ph} , I_{01} , a_1 , R_s , R_{sh}) değerleri sunulmuştur. Ayrıca, elde edilen parametrelerin hassasiyetini değerlendirmek amacıyla, amaç fonksiyonu olan RMSE hesaplanmıştır. Tahmin sonuçları literatürde raporlanan çoklu evren optimizasyonu (multi-verse optimization, MVO) (Wang vd., 2020), bakteriyel beslenme optimizasyonu (bacterial foraging optimization, BFO), genetik algoritma (genetic algorithm, GA) (Oliva vd., 2014), benzetilmiş tavlama (simulated annealing, SA) (El-Naggar vd., 2012), örüntü arama (pattern search, PS) (AlHajri vd., 2012), balina optimizasyon algoritması (whale optimization algorithm, WOA) (Oliva vd., 2017), kelebek optimizasyon algoritması (butterfly optimization algorithm, BOA), karşıt tabanlı sinüs kosinüs algoritması (opposition-based sine cosine algorithm, OBSCA) (Long vd., 2021) meta-sezgisel


algoritmalar ile karşılaştırılmıştır. Önerilen algoritmalar ile elde edilen en düşük RMSE değerleri (INFO: $7,7298 \times 10^{-4}$, QIO: $9,2865 \times 10^{-3}$, FLO: $3,0375 \times 10^{-3}$), karşılaştırılan meta-sezgisel yöntemleri geride bırakarak parametre tahmininde yüksek doğruluk sağlamıştır. INFO, QIO, FLO algoritmaları sırasıyla Şekil 6.1 (a), (b), Şekil 6.2 (a), (b) ve Şekil 6.3 (a), (b)'de sunulan 1-D modeli için elde edilen I-V ve P-V karakteristik eğrileri, ölçülen ve tahmin edilen parametrelerin yüksek uyum gösterdiğini ortaya koymaktadır. Ayrıca, belirlenen maksimum güç noktası (MPP) üzerinde elde edilen sonuçların da gerçek değerlerle tutarlı olduğu gözlemlenmiştir. 1-D modeli için yakınsama eğrileri sırasıyla Şekil 6.4, Şekil 6.5 ve Şekil 6.6'da sunulmuştur. En düşük RMSE değerinin erken aşamada elde edilmesi, önerilen algoritmaların yüksek doğrulukta parametre tahmin yeteneğini ve üstün yakınsama kapasitesini ortaya koymaktadır.

Tablo 6.2. INFO, QIO ve FLO'dan elde edilen sonuçların RTC (1-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması


Algoritma	I_{ph} (A)	I_{o1} (μ A)	R_s (Ω)	R_{sh} (Ω)	a_1	RMSE
INFO	0,760788	0,310691	0,0365468	52,8899	1,47727	$7,7298 \times 10^{-4}$
QIO	0,760767	0,312258	0,0365149	53,0493	1,47778	$9,2865 \times 10^{-3}$
FLO	0,761598	0,384977	0,0381659	68,8525	1,49892	$3,0375 \times 10^{-3}$
MVO	0,7616	0,32094	0,0365	59,5884	1,5252	$1,268 \times 10^{-1}$
BFA	0,7602	0,8000	0,0325	50,8691	1,6951	$2,9 \times 10^{-2}$
GA	0,7619	0,8087	0,0299	43,3729	1,5751	$1,9 \times 10^{-2}$
SA	0,762	0,4798	0,0345	43,1034	1,5172	$1,9 \times 10^{-2}$
PS	0,7617	0,998	0,0313	64,1026	1,6	$2,863 \times 10^{-1}$
WOA	0,76405	0,28588	0,0484	59,9940	1,4702	$1,32 \times 10^{-2}$
BOA	0,760234	0,80980	0,023287	30,53997	1,585917	$1,6641 \times 10^{-1}$
OBSCA	0,765120	1	0,03104	83,2518	1,596189	$2,5157 \times 10^{-2}$



Şekil 6.1. INFO algoritmasıyla 1-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




(a)




(b)

Şekil 6.2. QIO algoritmasıyla 1-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




(a)




(b)


Şekil 6.3. FLO algoritmasıyla 1-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.4. RTC veri seti için INFO algoritmasına ait 1-D modeli yakınsama eğrisi



Şekil 6.5. RTC veri seti için QIO algoritmasına ait 1-D modeli yakınsama eğrisi



Şekil 6.6. RTC veri seti için FLO algoritmasına ait 1-D modeli yakınsama eğrisi

1-D modeli için analizi yapılan IAE ve RE amaç fonksiyonları Tablo 6.3 ve 6.4’te verilmiştir. Burada, ölçülen her akım/voltaj noktası için önerilen algoritmalar aracılığıyla tahmin edilen akım ve güç değerleri yüksek doğrulukta gerçek değerleriyle uyumludur. Tablo 6.3’te 1-D modeli için önerilen INFO, QIO ve FLO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $1,76413 \times 10^{-2}$, $1,50732 \times 10^{-1}$, $6,18608 \times 10^{-2}$ ve Tablo 6.4’te ise toplam IAE (güç) değerleri sırasıyla $6,4714 \times 10^{-3}$, $8,0456 \times 10^{-2}$, $2,81055 \times 10^{-2}$ olarak hesaplanmıştır. Her veri satırı için hesaplanan IAE ve RE değerleri ise modelin doğruluğunu desteklemektedir.

Tablo 6.3. RTC veri seti için 1-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO			FLO		
		It	IAE	RE	It	IAE	RE	It	IAE	RE
1	0,764	0,76415	0,00015	-0,0001963	0,76411	1,10E-04	-1,44E-04	0,76416	1,60E-04	-2,09E-04
2	0,762	0,7627	0,0007	-0,0009186	0,76271	7,10E-04	-9,32E-04	0,76305	1,05E-03	-1,38E-03
3	0,7605	0,76137	0,00087	-0,001144	0,76143	9,30E-04	-1,22E-03	0,76203	1,53E-03	-2,01E-03
4	0,7605	0,76015	0,00035	0,00046022	0,76025	2,50E-04	3,29E-04	0,76109	5,90E-04	-7,76E-04
5	0,76	0,75904	0,00096	0,00126316	0,75917	8,30E-04	1,09E-03	0,76023	2,30E-04	-3,03E-04
6	0,759	0,75801	0,00099	0,00130435	0,75817	8,30E-04	1,09E-03	0,75944	4,40E-04	-5,80E-04
7	0,757	0,75705	5E-05	-6,605E-05	0,75724	2,40E-04	-3,17E-04	0,75868	1,68E-03	-2,22E-03
8	0,757	0,75608	0,00092	0,00121532	0,7563	7,00E-04	9,25E-04	0,75791	9,10E-04	-1,20E-03

9	0,7555	0,75502	0,00048	0,00063534	0,75526	2,40E-04	3,18E-04	0,75698	1,48E-03	-1,96E-03
10	0,754	0,7536	0,0004	0,0005305	0,75386	1,40E-04	1,86E-04	0,75563	1,63E-03	-2,16E-03
11	0,7505	0,75133	0,00083	-0,0011059	0,75162	1,12E-03	-1,49E-03	0,75333	2,83E-03	-3,77E-03
12	0,7465	0,74731	0,00081	-0,0010851	0,74767	1,17E-03	-1,57E-03	0,74911	2,61E-03	-3,50E-03
13	0,7385	0,74008	0,00158	-0,0021395	0,74061	2,11E-03	-2,86E-03	0,74145	2,95E-03	-3,99E-03
14	0,728	0,72743	0,00057	0,00078297	0,72829	2,90E-04	-3,98E-04	0,72802	2,00E-05	-2,75E-05
15	0,7065	0,70703	0,00053	-0,0007502	0,70853	2,03E-03	-2,87E-03	0,70653	3,00E-05	-4,25E-05
16	0,6755	0,6754	1E-04	0,00014804	0,67799	2,49E-03	-3,69E-03	0,67352	1,98E-03	2,93E-03
17	0,632	0,631	0,001	0,00158228	0,63515	3,15E-03	-4,98E-03	0,62768	4,32E-03	6,84E-03
18	0,573	0,57217	0,00083	0,00144852	0,57835	5,35E-03	-9,34E-03	0,5676	5,40E-03	9,42E-03
19	0,499	0,49954	0,00054	-0,0010822	0,50806	9,06E-03	-1,82E-02	0,49419	4,81E-03	9,64E-03
20	0,413	0,41348	0,00048	-0,0011622	0,4245	1,15E-02	-2,78E-02	0,40802	4,98E-03	1,21E-02
21	0,3165	0,31716	0,00066	-0,0020853	0,3306	1,41E-02	-4,45E-02	0,31235	4,15E-03	1,31E-02
22	0,212	0,21202	2E-05	-9,434E-05	0,2277	1,57E-02	-7,41E-02	0,20862	3,38E-03	1,59E-02
23	0,1035	0,10264	0,00086	0,00830918	0,12024	1,67E-02	-1,62E-01	0,1013	2,20E-03	2,13E-02
24	-0,01	-0,0092987	0,0007013	0,07013	0,009842	1,98E-02	1,98E+00	-0,0080592	1,94E-03	1,94E-01
25	-0,123	-0,12436	0,00136	-0,0110569	-0,10395	1,91E-02	1,55E-01	-0,12008	2,92E-03	2,37E-02
26	-0,21	-0,2091	0,0009	0,00428571	-0,18795	2,21E-02	1,05E-01	-0,20236	7,64E-03	3,64E-02
				0,0176413				0,150732		
									0,0618608	

Tablo 6.4. RTC veri seti için 1-D modeline ait ölçülen ve tahmin edilen güç verileri


S. NO	V	Pö	INFO		QIO		FLO	
			Pt	IAE	Pt	IAE	Pt	IAE
1	-0,2057	-0,15715	-0,15719	4,00E-05	-0,15718	3E-05	-0,15719	4E-05
2	-0,1291	-0,09837	-0,098465	9,50E-05	-0,098466	9,6E-05	-0,09851	0,00014
3	-0,0588	-0,04472	-0,044769	4,90E-05	-0,044772	5,2E-05	-0,044807	8,7E-05
4	0,0057	0,004335	0,0043329	2,10E-06	0,0043334	1,6E-06	0,0043382	3,2E-06
5	0,0646	0,049096	0,049034	6,20E-05	0,049042	5,4E-05	0,049111	1,5E-05
6	0,1185	0,089942	0,089824	1,18E-04	0,089844	9,8E-05	0,089994	5,2E-05
7	0,1678	0,127025	0,12703	5,00E-06	0,12706	3,5E-05	0,12731	0,000285
8	0,2132	0,161392	0,1612	1,92E-04	0,16124	0,000152	0,16159	0,000198
9	0,2545	0,192275	0,19215	1,25E-04	0,19221	6,5E-05	0,19265	0,000375
10	0,2924	0,22047	0,22035	1,20E-04	0,22043	4E-05	0,22095	0,00048
11	0,3269	0,245338	0,24561	2,72E-04	0,24571	0,000372	0,24626	0,000922
12	0,3585	0,26762	0,26791	2,90E-04	0,26804	0,00042	0,26856	0,00094
13	0,3873	0,286021	0,28663	6,09E-04	0,28684	0,000819	0,28716	0,001139
14	0,4137	0,301174	0,30094	2,34E-04	0,30129	0,000116	0,30118	6E-06
15	0,4373	0,308952	0,30918	2,28E-04	0,30984	0,000888	0,30896	8E-06
16	0,459	0,310055	0,31001	4,50E-05	0,3112	0,001145	0,30915	0,000905
17	0,4784	0,302349	0,30187	4,79E-04	0,30386	0,001511	0,30028	0,002069
18	0,496	0,284208	0,2838	4,08E-04	0,28686	0,002652	0,28153	0,002678
19	0,5119	0,255438	0,25571	2,72E-04	0,26007	0,004632	0,25298	0,002458
20	0,5265	0,217445	0,2177	2,55E-04	0,2235	0,006055	0,21482	0,002625
21	0,5398	0,170847	0,1712	3,53E-04	0,17846	0,007613	0,16861	0,002237
22	0,5521	0,117045	0,11705	5,00E-06	0,12571	0,008665	0,11518	0,001865
23	0,5633	0,058302	0,057815	4,87E-04	0,067734	0,009432	0,05706	0,001242
24	0,5736	-0,00574	-0,0053337	4,06E-04	0,0056454	0,0113854	-0,0046227	0,0011173
25	0,5833	-0,07175	-0,07254	7,90E-04	-0,060633	0,011117	-0,070041	0,001709
26	0,59	-0,1239	-0,12337	5,30E-04	-0,11089	0,01301	-0,11939	0,00451
			0,0064714		0,080456		0,0281055	

Tablo 6.5’te ise 2-D modeli için yedi bilinmeyen parametre (I_{ph} , I_{01} , I_{02} , a_1 , a_2 , R_s , R_{sh}) ve RMSE değerleri sunulmuştur. Burada, düşük RMSE (INFO: $7,4207 \times 10^{-4}$, QIO: $4,0894 \times 10^{-3}$, FLO: $1,1538 \times 10^{-2}$) değeriyle karşılaştırılan parçacık sürü optimizasyonu (particle swarm optimization, PSO) (Ye vd., 2009), OBSCA, GA, SA, PS,



WOA, BOA algoritmalarını geride bırakmayı başarmıştır. Şekil 6.7 (a), (b), Şekil 6.8 (a), (b) ve Şekil 6.9 (a), (b) 'de 2-D model için sunulan I-V ve P-V karakteristik eğrileri, ölçülen ve tahmin edilen parametrelerin uyumlu olduğu göstermektedir. Ayrıca, belirlenen MPP üzerinde elde edilen sonuçların gerçek değerlerle örtüştüğü gözlemlenmiştir. 2-D modeli için yakınsama eğrileri sırasıyla Şekil 6.10, Şekil 6.11 ve Şekil 6.12'de sunulmuştur. En düşük RMSE değerinin erken aşamada elde edilmesi, önerilen algoritmaların yüksek doğrulukta parametre tahmin yeteneğini desteklemektedir.

Tablo 6.5. INFO, QIO ve FLO'dan elde edilen sonuçların RTC (2-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması



Algoritma	I_{ph} (A)	I_{o1} (μ A)	R_s (Ω)	R_{sh} (Ω)	a_1	I_{o2} (μ A)	a_2	RMSE
INFO	0,760804	0,0862265	0,0376455	56,0562	1,37817	1	1,81957	$7,4207 \times 10^{-4}$
QIO	0,760737	0,534628	0,0372699	54,7932	1,74523	0,124942	1,40892	$4,0894 \times 10^{-3}$
FLO	0,752239	0,592485	0,0342579	38,0587	1,55789	0,646782	1,9019	$1,1538 \times 10^{-2}$
PSO	0,7623	0,4767	0,0325	43,1034	1,5172	0,01	2	$1,66 \times 10^{-2}$
GA	0,7608	0,0001	0,0364	53,7185	1,3355	0,0001	1,481	$3,604 \times 10^{-1}$
SA	0,7623	0,4767	0,0345	43,1034	1,5172	0,01	2	$1,664 \times 10^{-2}$
PS	0,7602	0,9889	0,032	81,3008	1,6	0,0001	1,192	$1,518 \times 10^{-2}$
WOA	0,7658	$2,99 \times 10^{-7}$	0,0493	59,0196	1,4795	$3,943 \times 10^{-7}$	1,9201	$1,54 \times 10^{-2}$
OBSCA	0,794380	0,528673	0,03468	23,9696	1,527530	0,04440	2	$2,4067 \times 10^{-2}$
BOA	0,78077	0,89987	0,03875	34,5559	1,47604	0,29385	1,99100	$1,3564 \times 10^{-2}$




Şekil 6.7. INFO algoritmasıyla 2-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




Şekil 6.8. QIO algoritmasıyla 2-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




Şekil 6.9. FLO algoritmasıyla 2-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.10. RTC veri seti için INFO algoritmasına ait 2-D modeli yakınsama eğrisi



Şekil 6.11. RTC veri seti için QIO algoritmasına ait 2-D modeli yakınsama eğrisi



Şekil 6.12. RTC veri seti için FLO algoritmasına ait 2-D modeli yakınsama eğrisi

2-D modeli için her veri satırına ait ölçülen ve önerilen algoritmalar ile tahmin edilen akım ve güç değerlerine ilişkin IAE ve RE hata metrikleri, Tablo 6.6 ve 6.7’de detaylı olarak sunulmuştur. Tablo 6.6’da önerilen INFO, QIO ve FLO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $1,70246 \times 10^{-2}$, $9,2797 \times 10^{-2}$, $2,773843 \times 10^{-1}$ ve Tablo 6.7’de ise toplam IAE (güç) değerleri sırasıyla $6,4793 \times 10^{-3}$, $3,90144 \times 10^{-2}$, $1,00322 \times 10^{-1}$ olarak hesaplanmıştır. Her veri satırı için hesaplanan IAE ve RE değerleri ise modellerin doğruluğunu desteklemektedir.

Tablo 6.6. RTC veri seti için 2-D modeline ait ölçülen ve tahmin edilen akım verileri

S. NO	İö	INFO			QIO			FLO		
		It	IAE	RE	It	IAE	RE	It	IAE	RE
1	0,764	0,76396	4E-05	5,2356E-05	0,76647	0,00247	-0,003233	0,75696	0,00704	0,0092147
2	0,762	0,7626	0,0006	-0,0007874	0,7651	0,0031	-0,0040682	0,75495	0,00705	0,009252
3	0,7605	0,76134	0,00084	-0,0011045	0,76385	0,00335	-0,004405	0,75311	0,00739	0,0097173
4	0,7605	0,76019	0,00031	0,00040763	0,7627	0,0022	-0,0028928	0,75141	0,00909	0,0119527
5	0,76	0,75913	0,00087	0,00114474	0,76164	0,00164	-0,0021579	0,74986	0,01014	0,0133421
6	0,759	0,75816	0,00084	0,00110672	0,76067	0,00167	-0,0022003	0,74842	0,01058	0,0139394
7	0,757	0,75722	0,00022	-0,0002906	0,75975	0,00275	-0,0036328	0,74706	0,00994	0,0131308
8	0,757	0,75627	0,00073	0,00096433	0,75882	0,00182	-0,0024042	0,74569	0,01131	0,0149406
9	0,7555	0,75519	0,00031	0,00041032	0,75777	0,00227	-0,0030046	0,74417	0,01133	0,0149967
10	0,754	0,7537	0,0003	0,00039788	0,7563	0,0023	-0,0030504	0,74217	0,01183	0,0156897
11	0,7505	0,75133	0,00083	-0,0011059	0,75389	0,00339	-0,004517	0,73914	0,01136	0,0151366

12	0,7465	0,74718	0,00068	-0,0009109	0,74958	0,00308	-0,0041259	0,7341	0,0124	0,0166109
13	0,7385	0,73986	0,00136	-0,0018416	0,74185	0,00335	-0,0045362	0,7256	0,0129	0,0174678
14	0,728	0,72715	0,00085	0,00116758	0,72839	0,00039	-0,0005357	0,71151	0,01649	0,0226511
15	0,7065	0,70681	0,00031	-0,0004388	0,70688	0,00038	-0,0005379	0,68985	0,01665	0,0235669
16	0,6755	0,67532	0,00018	0,00026647	0,67384	0,00166	0,0024574	0,6575	0,018	0,0266469
17	0,632	0,63108	0,00092	0,0014557	0,62788	0,00412	0,006519	0,61339	0,01861	0,0294462
18	0,573	0,57237	0,00063	0,00109948	0,56755	0,00545	0,0095113	0,55608	0,01692	0,0295288
19	0,499	0,49975	0,00075	-0,001503	0,49366	0,00534	0,0107014	0,48617	0,01283	0,0257114
20	0,413	0,41361	0,00061	-0,001477	0,40672	0,00628	0,0152058	0,40379	0,00921	0,0223002
21	0,3165	0,31716	0,00066	-0,0020853	0,30998	0,00652	0,0206003	0,31167	0,00483	0,0152607
22	0,212	0,21188	0,00012	0,00056604	0,20487	0,00713	0,0336321	0,21087	0,00113	0,0053302
23	0,1035	0,10244	0,00106	0,01024155	0,095937	0,007563	0,0730725	0,10558	0,00208	- 0,0200966
24	-0,01	- 0,009455	0,0005446	0,05446	- 0,015234	0,005234	-0,5234	- 0,002705	0,0072943	0,72943
25	-0,123	-0,12436	0,00136	-0,0110569	-0,12925	0,00625	-0,050813	-0,11462	0,00838	0,0681301
26	-0,21	-0,2089	0,0011	0,0052381	-0,21309	0,00309	-0,0147143	-0,1974	0,0126	0,06
		0,0170246			0,092797			0,2773843		

Tablo 6.7. RTC veri seti için 2-D modeline ait ölçülen ve tahmin edilen güç verileri


S. NO	V	Pö	INFO		QIO		FLO	
			Pt	IAE	Pt	IAE	Pt	IAE
1	-0,2057	-0,15715	-0,15715	0	-0,15766	0,00051	-0,15571	0,00144
2	-0,1291	-0,09837	-0,098451	8,1E-05	-0,098775	0,000405	-0,097464	0,000906
3	-0,0588	-0,04472	-0,044767	4,7E-05	-0,044914	0,000194	-0,044283	0,000437
4	0,0057	0,004335	0,0043331	1,9E-06	0,0043474	1,24E-05	0,004283	0,000052
5	0,0646	0,049096	0,04904	5,6E-05	0,049202	0,000106	0,048441	0,000655
6	0,1185	0,089942	0,089841	0,000101	0,09014	0,000198	0,088688	0,001254
7	0,1678	0,127025	0,12706	3,5E-05	0,12749	0,000465	0,12536	0,001665
8	0,2132	0,161392	0,16124	0,000152	0,16178	0,000388	0,15898	0,002412
9	0,2545	0,192275	0,1922	7,5E-05	0,19285	0,000575	0,18939	0,002885
10	0,2924	0,22047	0,22038	9E-05	0,22114	0,00067	0,21701	0,00346
11	0,3269	0,245338	0,24561	0,000272	0,24645	0,001112	0,24162	0,003718
12	0,3585	0,26762	0,26786	0,00024	0,26872	0,0011	0,26317	0,00445
13	0,3873	0,286021	0,28655	0,000529	0,28732	0,001299	0,28103	0,004991
14	0,4137	0,301174	0,30082	0,000354	0,30133	0,000156	0,29435	0,006824
15	0,4373	0,308952	0,30909	0,000138	0,30912	0,000168	0,30167	0,007282
16	0,459	0,310055	0,30997	8,5E-05	0,30929	0,000765	0,30179	0,008265
17	0,4784	0,302349	0,30191	0,000439	0,30038	0,001969	0,29344	0,008909
18	0,496	0,284208	0,2839	0,000308	0,28151	0,002698	0,27582	0,008388
19	0,5119	0,255438	0,25582	0,000382	0,2527	0,002738	0,24887	0,006568
20	0,5265	0,217445	0,21777	0,000325	0,21414	0,003305	0,2126	0,004845
21	0,5398	0,170847	0,1712	0,000353	0,16733	0,003517	0,16824	0,002607
22	0,5521	0,117045	0,11698	6,5E-05	0,11311	0,003935	0,11642	0,000625
23	0,5633	0,058302	0,057705	0,000597	0,054041	0,004261	0,059473	0,001171
24	0,5736	-0,00574	-0,0054236	0,0003164	-0,008738	0,002998	-0,001552	0,004188
25	0,5833	-0,07175	-0,072537	0,000787	-0,07539	0,00364	-0,066855	0,004895
26	0,59	-0,1239	-0,12325	0,00065	-0,12573	0,00183	-0,11647	0,00743
			0,0064793		0,0390144		0,100322	

Tablo 6.8’de, 3-D modeli için dokuz bilinmeyen parametreye (I_{ph} , I_{01} , I_{02} , I_{03} a_1 , a_2 , a_3 R_s , R_{sh}) ve RMSE değerleri sunulmuştur. Burada, en düşük RMSE (INFO: $7,3655 \times 10^{-4}$, QIO: $4,0449 \times 10^{-3}$, FLO: $7,3024 \times 10^{-3}$) değeriyle karşılaştırılan harris şahinleri optimizasyonu (harris hawks optimization, HHO (Izci, Ekinci, ve Ma'arif, 2024), PSO, sinüs kosinüs algoritması (sine cosine algorithm, SCA), MVO, gri kurt


optimizasyonu (grey wolf optimization, GWO), helikopter böceği algoritması (dragonfly algorithm, DA) (Singla vd., 2022) algoritmaları geride bırakmayı başarmıştır. Şekil 6.13 (a), (b), Şekil 6.14 (a), (b) ve Şekil 6.15 (a), (b)'de 3-D modeli için, I-V ve P-V karakteristik eğrilerinde anlaşılabileceği üzere ölçülen ve tahmin edilen parametre değerleri yüksek oranda eşleşmektedir. Ayrıca, işaretlenen MPP noktasında aynı uyum devam etmektedir. 3-D modeli için yakınsama eğrileri sırasıyla Şekil 6.16, Şekil 6.17 ve Şekil 6.18'de sunulmuştur. En düşük RMSE değerine erken aşamada elde edilmesi, önerilen algoritmaların yüksek doğrulukta parametre tahmin yeteneğini ortaya koymaktadır.

Tablo 6.8. INFO, QIO ve FLO'dan elde edilen sonuçların RTC (3-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması


Algoritma	I_{ph} (A)	I_{o1} (μ A)	R_s (Ω)	R_{sh} (Ω)	α_1	I_{o2} (μ A)	I_{o3} (μ A)	a_2	a_3	RMSE
INFO	0,760835	0,091787	0,0378	56,573	1,3789	0,5369	0,591342	1,9713	1,9093	$7,3655 \times 10^{-4}$
QIO	0,760851	0,130909	0,0373	54,678	1,4075	0,6523	0,42864	1,9210	1,8837	$4,0449 \times 10^{-3}$
FLO	0,766774	0,723519	0,0386	77,221	1,9311	0,0559	0,765415	1,3970	1,6528	$7,3024 \times 10^{-3}$
HHO	0,764769	3,82	0,0183	992,25	1,8823	2,71	1,28	1,8916	1,8916	$7,721 \times 10^{-3}$
PSO	0,8301	0,065	0,001	0,9894	0,5	0,027	0,093	0,5	0,5	$5,123 \times 10^{-1}$
SCA	0,8348	0,4267	0,0002	57,352	1,382	0,5283	0,3439	1,337	1,001	$5,004 \times 10^{-1}$
MVO	0,8358	0,1632	0,001	71,585	1,297	0,6298	0,5692	1,141	1	$4,337 \times 10^{-1}$
GWO	0,8405	0,1853	0,0000	99,939	1,128	0,2505	0,3429	1	1,207	$3,879 \times 10^{-1}$
DA	0,8424	0,3226	0,0002	65,243	1,4	0,3477	0,1252	1,510	1,652	$3,818 \times 10^{-1}$




Şekil 6.13. INFO algoritmasıyla 3-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




Şekil 6.14. QIO algoritmasıyla 3-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




Şekil 6.15. FLO algoritmasıyla 3-D (RTC) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.16. RTC veri seti için INFO algoritmasına ait 3-D modeli yakınsama eğrisi



Şekil 6.17. RTC veri seti için QIO algoritmasına ait 3-D modeli yakınsama eğrisi



Şekil 6.18. RTC veri seti için FLO algoritmasına ait 3-D modeli yakınsama eğrisi

Tablo 6.9’da önerilen INFO, QIO ve FLO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $1,68677 \times 10^{-2}$, $7,5769 \times 10^{-2}$, $1,737542 \times 10^{-1}$ ve Tablo 6.10’da ise toplam IAE (güç) değerleri sırasıyla $6,4702 \times 10^{-3}$, $3,73005 \times 10^{-2}$, $6,53652 \times 10^{-2}$ olarak hesaplanmıştır. Her veri satırı için hesaplanan IAE ve RE değerleri ise modellerin doğruluğunu desteklemektedir.

Tablo 6.9. RTC veri seti için 3-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO			FLO		
		İt	IAE	RE	İt	IAE	RE	İt	IAE	RE
1	0,764	0,76396	4E-05	5,2356E-05	0,76272	0,00128	0,0016754	0,76905	0,00505	-0,0066099
2	0,762	0,76261	0,00061	-0,0008005	0,76184	0,00016	0,00021	0,76806	0,00606	-0,0079528
3	0,7605	0,76137	0,00087	-0,001144	0,76103	0,00053	-0,0006969	0,76715	0,00665	-0,0087442
4	0,7605	0,76022	0,00028	0,00036818	0,76029	0,00021	0,0002761	0,76631	0,00581	-0,0076397
5	0,76	0,75918	0,00082	0,00107895	0,7596	0,0004	0,0005263	0,76554	0,00554	-0,0072895
6	0,759	0,7582	0,0008	0,00105402	0,75897	3E-05	3,953E-05	0,76482	0,00582	-0,007668
7	0,757	0,75727	0,00027	-0,0003567	0,75834	0,00134	-0,0017701	0,7641	0,0071	-0,0093791
8	0,757	0,75631	0,00069	0,00091149	0,75766	0,00066	-0,0008719	0,76331	0,00631	-0,0083355
9	0,7555	0,75521	0,00029	0,00038385	0,75676	0,00126	-0,0016678	0,76227	0,00677	-0,008961
10	0,754	0,7537	0,0003	0,00039788	0,75535	0,00135	-0,0017905	0,76063	0,00663	-0,0087931
11	0,7505	0,7513	0,0008	-0,001066	0,75285	0,00235	-0,0031312	0,75779	0,00729	-0,0097135
12	0,7465	0,74712	0,00062	-0,0008305	0,74828	0,00178	-0,0023845	0,75268	0,00618	-0,0082786
13	0,7385	0,73978	0,00128	-0,0017332	0,74015	0,00165	-0,0022343	0,7437	0,0052	-0,0070413
14	0,728	0,72709	0,00091	0,00125	0,72626	0,00174	0,0023901	0,72854	0,00054	-0,0007418
15	0,7065	0,70677	0,00027	-0,0003822	0,70453	0,00197	0,0027884	0,70504	0,00146	0,0020665

16	0,6755	0,67533	0,00017	0,00025167	0,67174	0,00376	0,0055662	0,66997	0,00553	0,0081865
17	0,632	0,63113	0,00087	0,00137658	0,62666	0,00534	0,0084494	0,62238	0,00962	0,0152215
18	0,573	0,57244	0,00056	0,00097731	0,56775	0,00525	0,0091623	0,56114	0,01186	0,0206981
19	0,499	0,49982	0,00082	-0,0016433	0,49551	0,00349	0,006994	0,48732	0,01168	0,0234068
20	0,413	0,41365	0,00065	-0,0015738	0,41002	0,00298	0,0072155	0,40153	0,01147	0,0277724
21	0,3165	0,31715	0,00065	-0,0020537	0,31403	0,00247	0,0078041	0,30692	0,00958	0,0302686
22	0,212	0,21184	0,00016	0,00075472	0,20864	0,00336	0,0158491	0,20481	0,00719	0,0339151
23	0,1035	0,10238	0,00112	0,01082126	0,098215	0,005285	0,0510628	0,099478	0,004022	0,0388599
24	-0,01	-0,0095023	0,0004977	0,04977	-0,015644	0,005644	-0,5644	-0,0076478	0,0023522	0,23522
25	-0,123	-0,12436	0,00136	-0,0110569	-0,13355	0,01055	-0,0857724	-0,11725	0,00575	0,046748
26	-0,21	-0,20884	0,00116	0,00552381	-0,22093	0,01093	-0,0520476	-0,19771	0,01229	0,0585238
		0,0168677			0,075769			0,1737542		

Tablo 6.10. RTC veri seti için 3-D modeline ait ölçülen ve tahmin edilen güç verileri

S. NO	V	Pö	INFO		QIO		FLO	
			Pt	IAE	Pt	IAE	Pt	IAE
1	-0,2057	-0,15715	-0,15715	0	-0,15689	0,00026	-0,15819	0,00104
2	-0,1291	-0,09837	-0,098453	8,3E-05	-0,098353	1,7E-05	-0,099157	0,000787
3	-0,0588	-0,04472	-0,044768	4,8E-05	-0,044749	2,9E-05	-0,045109	0,000389
4	0,0057	0,004335	0,0043333	1,7E-06	0,0043336	1,4E-06	0,004368	0,000033
5	0,0646	0,049096	0,049043	5,3E-05	0,04907	2,6E-05	0,049454	0,000358
6	0,1185	0,089942	0,089847	9,5E-05	0,089937	5E-06	0,090631	0,000689
7	0,1678	0,127025	0,12707	4,5E-05	0,12725	0,000225	0,12822	0,001195
8	0,2132	0,161392	0,16125	0,000142	0,16153	0,000138	0,16274	0,001348
9	0,2545	0,192275	0,1922	7,5E-05	0,1926	0,000325	0,194	0,001725
10	0,2924	0,22047	0,22038	9E-05	0,22086	0,00039	0,22241	0,00194
11	0,3269	0,245338	0,2456	0,000262	0,24611	0,000772	0,24772	0,002382
12	0,3585	0,26762	0,26784	0,00022	0,26826	0,00064	0,26984	0,00222
13	0,3873	0,286021	0,28652	0,000499	0,28666	0,000639	0,28804	0,002019
14	0,4137	0,301174	0,3008	0,000374	0,30045	0,000724	0,3014	0,000226
15	0,4373	0,308952	0,30907	0,000118	0,30809	0,000862	0,30832	0,000632
16	0,459	0,310055	0,30998	7,5E-05	0,30833	0,001725	0,30752	0,002535
17	0,4784	0,302349	0,30193	0,000419	0,29979	0,002559	0,29775	0,004599
18	0,496	0,284208	0,28393	0,000278	0,2816	0,002608	0,27833	0,005878
19	0,5119	0,255438	0,25586	0,000422	0,25365	0,001788	0,24946	0,005978
20	0,5265	0,217445	0,21779	0,000345	0,21588	0,001565	0,21141	0,006035
21	0,5398	0,170847	0,1712	0,000353	0,16951	0,001337	0,16568	0,005167
22	0,5521	0,117045	0,11696	8,5E-05	0,11519	0,001855	0,11308	0,003965
23	0,5633	0,058302	0,057671	0,000631	0,055324	0,002978	0,056036	0,002266
24	0,5736	-0,00574	-0,0054505	0,0002895	-0,0089731	0,0032331	-0,0043868	0,0013532
25	0,5833	-0,07175	-0,072537	0,000787	-0,077899	0,006149	-0,068394	0,003356
26	0,59	-0,1239	-0,12322	0,00068	-0,13035	0,00645	-0,11665	0,00725
			0,0064702		0,0373005		0,0653652	

Tablo 6.11’de, 1-D, 2-D ve 3-D elektriksel modelleri için önerilen INFO, QIO ve FLO algoritmalarının RMSE değerlerine ilişkin detaylı istatistiksel analiz sonuçları sunulmaktadır. Her algoritma için minimum, maksimum, ortalama, standart sapma ve varyans değerleri hesaplanarak karşılaştırmalı bir performans analizi yapılmıştır. Bu performans ölçütlerinin dağılım grafiği Şekil 6.19, Şekil 6.20 ve Şekil 6.21’de sunulmuştur.

INFO algoritması, tüm modeller için en düşük hata değerlerini sağlamaktadır. Minimum RMSE değerleri 1-D modelinde $7,72983 \times 10^{-4}$, 2-D modelinde $7,4207 \times 10^{-4}$ ve


3-D modelinde $7,36551 \times 10^{-4}$ olarak hesaplanmıştır. Maksimum RMSE değerleri ise sırasıyla $7,72988 \times 10^{-4}$, $7,7299 \times 10^{-4}$ ve $7,72976 \times 10^{-4}$ olup, minimum değerlerle oldukça yakın seviyelerdedir. Ortalama RMSE değerleri ise 1-D’de $7,72985 \times 10^{-4}$, 2-D’de $7,5747 \times 10^{-4}$ ve 3-D’de $7,57188 \times 10^{-4}$ olarak hesaplanmıştır. Standart sapma ve varyans değerlerinin düşük olması, INFO algoritmasının hata dağılımının istikrarlı olduğunu göstermektedir.

QIO algoritması, INFO algoritmasına kıyasla daha geniş bir hata dağılımına sahiptir. Minimum RMSE değerleri, 1-D modelinde $7,73365 \times 10^{-4}$, 2-D modelinde $7,55657 \times 10^{-4}$ ve 3-D modelinde $7,45585 \times 10^{-4}$ olarak belirlenmiştir. Maksimum RMSE değerleri ise sırasıyla $8,99163 \times 10^{-4}$, $1,58083 \times 10^{-3}$ ve $1,97928 \times 10^{-3}$ olup, minimum değerlerden daha yüksek seviyededir. Ortalama RMSE değerleri 1-D modeli için $7,86236 \times 10^{-4}$, 2-D için $8,57167 \times 10^{-4}$ ve 3-D için $1,11351 \times 10^{-3}$ olarak hesaplanmıştır. Standart sapma ve varyans değerleri, özellikle 3-D modelinde daha yüksek olup, hata dağılımının karmaşık modellerde değişkenlik gösterebildiğini ortaya koymaktadır.


FLO algoritması, daha geniş bir hata aralığına sahip olup, minimum RMSE değerleri 1-D modelinde $3,03749 \times 10^{-3}$, 2-D modelinde $1,15380 \times 10^{-3}$ ve 3-D modelinde $7,30240 \times 10^{-3}$ olarak hesaplanmıştır. Maksimum RMSE değerleri, sırasıyla $1,28764 \times 10^{-1}$, $1,30100 \times 10^{-1}$ ve $1,80918 \times 10^{-1}$ olup, hata seviyelerinin farklı elektriksel devre modellerinde değişkenlik gösterebildiğini ortaya koymaktadır. Ortalama RMSE değerleri, 1-D için $1,16881 \times 10^{-2}$, 2-D için $9,25428 \times 10^{-3}$ ve 3-D için $9,74426 \times 10^{-2}$ olarak hesaplanmıştır. Standart sapma ve varyans değerleri diğer algoritmalara kıyasla daha yüksek seviyede olup, modelin hata dağılımında çeşitliliğin fazla olduğunu göstermektedir. Genel olarak değerlendirildiğinde, INFO algoritması en düşük RMSE değerleriyle istikrarlı sonuçlar sunarken, QIO algoritması hata dağılımında belirli bir genişlik sergilemekte, FLO algoritması ise hata seviyelerinde daha fazla değişkenlik göstermektedir. Her algoritma farklı modelleme ihtiyaçlarına yönelik avantajlar sunmakta olup, INFO algoritması tutarlı ve düşük hata değerleriyle dikkat çekerken, QIO algoritması belirli bir hata dağılımı içinde genişleyen bir yapı sergilemekte, FLO algoritması ise esnek ancak değişken hata değerleri ile öne çıkmaktadır. Genel olarak, önerilen algoritmaların elde edilen bu sonuçları, PV parametre tahmin süreçlerinde uygulanabilir ve etkili yaklaşımlar sunduğunu göstermektedir.

Tablo 6.11. 1-D, 2-D ve 3-D modelleri için önerilen algoritmalarla elde edilen RMSE değerlerine ait istatistiksel sonuçlar (RTC)


Önerilen Algoritmalar	İstatistiksel skorlar (RMSE)	1-D	2-D	3-D
INFO	Minimum	$7,72983 \times 10^{-4}$	$7,4207 \times 10^{-4}$	$7,36551 \times 10^{-4}$
	Maksimum	$7,72988 \times 10^{-4}$	$7,7299 \times 10^{-4}$	$7,72976 \times 10^{-4}$
	Ortalama	$7,72985 \times 10^{-4}$	$7,5747 \times 10^{-4}$	$7,57188 \times 10^{-4}$
	Standart sapma	$1,4496 \times 10^{-16}$	$1,0271 \times 10^{-5}$	$1,2297 \times 10^{-5}$
	Varyans	$2,1014 \times 10^{-32}$	$1,0549 \times 10^{-10}$	$1,1148 \times 10^{-10}$
QIO	Minimum	$7,73365 \times 10^{-4}$	$7,55657 \times 10^{-4}$	$7,45585 \times 10^{-4}$
	Maksimum	$8,99163 \times 10^{-4}$	$1,58083 \times 10^{-3}$	$1,97928 \times 10^{-3}$
	Ortalama	$7,86236 \times 10^{-4}$	$8,57167 \times 10^{-4}$	$1,11351 \times 10^{-3}$
	Standart sapma	$2,3069 \times 10^{-5}$	$1,8172 \times 10^{-4}$	$3,6219 \times 10^{-4}$
	Varyans	$5,3217 \times 10^{-10}$	$3,3023 \times 10^{-8}$	$1,3118 \times 10^{-7}$
FLO	Minimum	$3,03749 \times 10^{-3}$	$1,15380 \times 10^{-2}$	$7,30240 \times 10^{-3}$
	Maksimum	$1,28764 \times 10^{-1}$	$1,35010 \times 10^{-1}$	$1,80918 \times 10^{-1}$
	Ortalama	$8,16881 \times 10^{-2}$	$8,52945 \times 10^{-2}$	$9,74426 \times 10^{-2}$
	Standart sapma	$3,582 \times 10^{-2}$	$3,0906 \times 10^{-2}$	$3,867 \times 10^{-2}$
	Varyans	$1,2831 \times 10^{-3}$	$9,5516 \times 10^{-4}$	$1,4954 \times 10^{-3}$



Şekil 6.19. INFO algoritması ile tüm çalışmaların (30) istatistiksel RMSE dağılım grafikleri (RTC) : (a) 1-D, (b) 2-D, (c) 3-D



Şekil 6.20. QIO algoritması ile tüm çalışmaların (30) istatistiksel RMSE dağılım grafikleri (RTC) : (a) 1-D, (b) 2-D, (c) 3-D



Şekil 6.21. FLO algoritması ile tüm çalışmaların (30) istatistiksel RMSE dağılım grafikleri (RTC) : (a) 1-D, (b) 2-D, (c) 3-D

1-D, 2-D ve 3-D modellerinin performansını kapsamlı bir şekilde analiz etmek amacıyla IAE, RMSE, MAE, MBE, T-istatistiği, R^2 , NRMSE, NMBE ve NMAE gibi istatistiksel hata metrikleri Tablo 6.12'de sunulmuştur.

Tablo 6.12. RTC veri setinde 1-D, 2-D ve 3-D için istatistiksel hata oranları

	Model	IAE	RMSE	MAE	MBE	t- istatistik	R^2	NRMSE	NMBE	NMAE
INFO	1-D	0,0176413	0,000773	0,0006785	-5E-08	0,0003234	0,9999934	0,0014014	-9,065E-08	0,00123
	2-D	0,0170246	0,0007421	0,0006548	5,9231E-07	0,0039909	0,9999939	0,0013454	1,074E-06	0,00118
	3-D	0,0168677	0,0007366	0,0006488	-4,912E-06	0,0333423	0,999994	0,0013354	-8,905E-06	0,00117
QIO	1-D	0,150732	0,0092865	0,0057974	-0,0055674	3,7452549	0,9990515	0,0168363	-0,0100936	0,01051
	2-D	0,092797	0,0040894	0,0035691	0,00094142	1,1828224	0,999816	0,007414	0,0017068	0,00647
	3-D	0,075769	0,0040449	0,0029142	0,00207419	2,986513	0,9998201	0,0073333	0,0037605	0,00528
FLO	1-D	0,0618608	0,003075	0,0023793	2,2277E-05	0,0362236	0,9998985	0,0055749	4,039E-05	0,00431
	2-D	0,2773843	0,011538	0,0106686	0,00833368	5,2218173	0,9985355	0,0209182	0,0151088	0,01934
	3-D	0,1737542	0,0073024	0,0066829	-0,0011127	0,7708745	0,9994134	0,0132391	-0,0020173	0,01211

INFO, QIO ve FLO algoritmaları ile analiz edilen modellerde elde edilen hata oranları, önerilen algoritmaların sağlam yapısını ortaya koymaktadır. INFO algoritması kapsamında yapılan değerlendirmede, 3-D modeli en düşük RMSE (0,0007366) ve IAE (0,0168677) değerleriyle en iyi performansı sergilemiştir. QIO algoritması ile yapılan analizlerde, hata oranlarında artış gözlemlenmesine rağmen, 3-D modeli en düşük RMSE (0,0040449) ve IAE (0,075769) değerlerine sahip olarak en başarılı sonuçları elde etmiştir. FLO algoritması kapsamında yapılan değerlendirmelerde ise 1-D modeli, 0,003075 RMSE ve 0,0618608 IAE değerleriyle en düşük hata oranlarını sunarak en iyi performansı sergilemiştir. Ancak, 2-D modeli 0,2773843 IAE ve 0,011538 RMSE gibi yüksek hata değerleriyle diğer modellere kıyasla daha düşük doğruluk oranına sahip olmuştur. Genel olarak değerlendirildiğinde, INFO ve QIO algoritmalarında 3-D modeli en düşük hata oranlarıyla öne çıkarken, FLO algoritması kapsamında 1-D modeli daha başarılı bir performans göstermektedir. 1-D, 2-D ve 3-D modellerinin genel doğruluğu

incelendiğinde, R^2 değerleri tüm modellerde oldukça yüksek olup, ayrıca düşük MAE, MBE, NRMSE, NMBE ve NMAE değerleriyle önerilen algoritmaların yüksek doğrulukta parametre tahmini yapabildiğini açıkça ortaya koymaktadır. Tüm bu bulgular, önerilen algoritmaların güvenilir ve etkili olduğunu ve gerçek değerleriyle uyumlu sonuçlar ortaya koyduğunu göstermektedir.


6.1.2 Photowatt-PWP201 veri setiyle elde edilen sonuçlar

Bu alt bölüm, önerilen INFO, QIO ve FLO algoritmalarının Photowatt-PWP201 modül verileri kullanılarak 1-D, 2-D ve 3-D modellerine ait analiz sonuçları detaylı bir şekilde sunulmuştur. Tablo 6.13'te 1-D modeline ait tahmin edilen parametreler sunulmuştur. Tahmin sonuçları literatürde raporlanan WOA (Oliva vd., 2017), SCA (Abdel-Basset vd., 2021), ateşböceği algoritması (firefly algorithm, FA) (Yaghoubi vd., 2022), atom arama optimizasyonu (atom search optimization, ASO) (Tefek, 2021), newton (Beigi ve Maroosi, 2018), rüzgar güdümlü optimizasyon (wind driven optimization, WDO) (Mathew vd., 2017) meta-sezgisel algoritmalar ile karşılaştırılmıştır. Önerilen algoritmalar ile elde edilen en düşük RMSE değerleri (INFO: $2,05282 \times 10^{-3}$, QIO: $5,7876 \times 10^{-3}$, FLO: $9,7545 \times 10^{-3}$), karşılaştırılan meta-sezgisel yöntemleri geride bırakarak parametre tahmininde yüksek doğruluk elde edilmiştir. INFO, QIO, FLO algoritmaları sırasıyla Şekil 6.22 (a), (b), Şekil 6.23 (a), (b) ve Şekil 6.24 (a), (b)'de sunulan 1-D modeli için elde edilen I-V ve P-V karakteristik eğrileri, ölçülen ve tahmin edilen parametrelerin gerçek değerleriyle uyum içinde olduğunu göstermektedir. Ayrıca, belirlenen MPP üzerinde elde edilen sonuçlarda oldukça tutarlıdır. 1-D modeli için yakınsama eğrileri (INFO, QIO ve FLO) sırasıyla Şekil 6.25, Şekil 6.26 ve Şekil 6.27'de sunulmuştur. En düşük RMSE değerinin erken aşamada elde edilmesi, önerilen algoritmaların yüksek doğrulukta parametre tahmin yeteneğini ve üstün yakınsama yeteneğini bir kez daha ortaya koymaktadır.


Tablo 6.13. INFO, QIO ve FLO'dan elde edilen sonuçların PWP201 (1-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması.

Algoritma	I_{ph} (A)	I_{o1} (μ A)	R_s (Ω)	R_{sh} (Ω)	a_1	RMSE
INFO	1,031434	2,637962	1,23564	821,6099	49,46379	$2,05282 \times 10^{-3}$
QIO	1,031443	0,2627419	1,236323	821,0363	49,44832	$5,7876 \times 10^{-3}$
FLO	1,0308692	2,5494649	1,2662524	1408,5111	49,181231	$9,7545 \times 10^{-3}$
WOA	1,3135	0	0,0622	16,229	49,4231	$2,838 \times 10^{-1}$
SCA	1,03364	0,118	0,930711	1268,463	53,72168	$1,17780 \times 10^{-2}$

FA	1,0424	4,6816	1,2042	1204,0547	497875	$1,03 \times 10^{-2}$
ASO	1,2145	1,0826	0,2298	59,6881	44,3904	$1,6898 \times 10^{-1}$
Newton	1,0318	3,2875	1,2057	555,5556	48,45	$7,805 \times 10^{-1}$
WDO	0,31735	3,682679	0,978698	184,19173	8,215487	$1,04839 \times 10^{-1}$




(a)




(b)

Şekil 6.22. INFO algoritmasıyla 1-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




(a)




(b)


Şekil 6.23. QIO algoritmasıyla 1-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




Şekil 6.24. FLO algoritmasıyla 1-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.25. PWP201 veri seti için INFO algoritmasına ait 1-D modeli yakınsama eğrisi



Şekil 6.26. PWP201 veri seti için QIO algoritmasına ait 1-D modeli yakınsama eğrisi



Şekil 6.27. PWP201 veri seti için FLO algoritmasına ait 1-D modeli yakınsama eğrisi

1-D modeli için analizi yapılan IAE ve RE amaç fonksiyonları ölçülen her akım/voltaj noktası için önerilen algoritmalar aracılığıyla tahmin edilen akım ve güç değerleri Tablo 6.14 ve 6.15'te verilmiştir. Tablo 6.14'te 1-D modeli için önerilen INFO, QIO ve FLO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $4,24557 \times 10^{-2}$, $1,17177 \times 10^{-1}$, $1,85608 \times 10^{-1}$ ve Tablo 6.15'te ise toplam IAE (güç) değerleri sırasıyla $4,52793 \times 10^{-1}$, 1,6835219, $1,85608 \times 10^{-1}$ olarak hesaplanmıştır. Her veri satırı için hesaplanan IAE ve RE değerleri ise modelin doğruluğunu desteklemektedir.

Tablo 6.14. PWP201 veri seti için 1-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO			FLO		
		It	IAE	RE	It	IAE	RE	It	IAE	RE
1	1,0315	1,0297	0,0018	0,001745	1,0301	0,0014	0,0013572	1,0298	0,0017	0,0016481
2	1,03	1,0277	0,0023	0,002233	1,0279	0,0021	0,0020388	1,0286	0,0014	0,0013592
3	1,026	1,0257	0,0003	0,0002924	1,0258	0,0002	0,0001949	1,0275	0,0015	-0,001462
4	1,022	1,0238	0,0018	-0,0017613	1,0239	0,0019	-0,0018591	1,0263	0,0043	-0,0042074
5	1,018	1,0218	0,0038	-0,0037328	1,0218	0,0038	-0,0037328	1,0249	0,0069	-0,006778
6	1,0155	1,0193	0,0038	-0,003742	1,0192	0,0037	-0,0036435	1,023	0,0075	-0,0073855
7	1,014	1,0157	0,0017	-0,0016765	1,0156	0,0016	-0,0015779	1,0198	0,0058	-0,0057199
8	1,01	1,01	0	0	1,01	0	0	1,0144	0,0044	-0,0043564
9	1,0035	1,0004	0,0031	0,0030892	1,0006	0,0029	0,0028899	1,0049	0,0014	-0,0013951
10	0,988	0,98474	0,00326	0,0032996	0,98526	0,00274	0,0027733	0,98884	0,00084	-0,0008502
11	0,963	0,96019	0,00281	0,002918	0,96119	0,00181	0,0018795	0,96341	0,00041	-0,0004258
12	0,9255	0,92387	0,00163	0,0017612	0,92552	2E-05	-2,161E-05	0,9256	1E-04	-0,000108
13	0,8725	0,87357	0,00107	-0,0012264	0,87598	0,00348	-0,0039885	0,87318	0,00068	-0,0007794
14	0,8075	0,8082	0,0007	-0,0008669	0,81146	0,00396	-0,004904	0,80525	0,00225	0,0027864
15	0,7265	0,72855	0,00205	-0,0028217	0,73268	0,00618	-0,0085065	0,72283	0,00367	0,0050516
16	0,6345	0,63663	0,00213	-0,003357	0,64162	0,00712	-0,0112214	0,62823	0,00627	0,0098818
17	0,5345	0,53543	0,00093	-0,0017399	0,54122	0,00672	-0,0125725	0,52465	0,00985	0,0184284
18	0,4275	0,4282	0,0007	-0,0016374	0,43476	0,00726	-0,0169825	0,41547	0,01203	0,0281404
19	0,3185	0,31785	0,00065	0,0020408	0,32513	0,00663	-0,0208163	0,30363	0,01487	0,0466876
20	0,2085	0,20701	0,00149	0,0071463	0,21497	0,00647	-0,0310312	0,19168	0,01682	0,0806715
21	0,101	0,097645	0,003355	0,0332178	0,10624	0,00524	-0,0518812	0,081626	0,019374	0,1918218
22	-0,008	-0,0085907	0,0005907	-0,0738375	0,000607	0,008607	1,0758763	-0,024974	0,016974	-2,12175
23	-0,111	-0,11097	3E-05	0,0002703	-0,10121	0,00979	0,0881982	-0,12747	0,01647	-0,1483784
24	-0,209	-0,20861	0,00039	0,001866	-0,19832	0,01068	0,0511005	-0,22501	0,01601	-0,0766029
25	-0,303	-0,30093	0,00207	0,0068317	-0,29013	0,01287	0,0424752	-0,31709	0,01409	-0,0465017
		0,0424557			0,117177			0,185608		

Tablo 6.15. PWP201 veri seti için 1-D modeline ait ölçülen ve tahmin edilen güç verileri


S. NO	V	Pö	INFO		QIO		FLO	
			Pt	IAE	Pt	IAE	Pt	IAE
1	0,1248	0,128731	0,12851	0,000221	0,128556	0,000175	0,128525	0,000206
2	1,8093	1,86358	1,85935	0,00423	1,85978	0,0038	1,86111	0,00247
3	3,3511	3,43823	3,43731	0,00092	3,43772	0,00051	3,44318	0,00495
4	4,7622	4,86697	4,8757	0,00873	4,87582	0,00885	4,88742	0,02045
5	6,0538	6,16277	6,18586	0,02309	6,18555	0,02278	6,20464	0,04187
6	7,2364	7,34856	7,37623	0,02767	7,37555	0,02699	7,40273	0,05417
7	8,3189	8,43536	8,44978	0,01442	8,44906	0,0137	8,48403	0,04867
8	9,3097	9,4028	9,4026	0,0002	9,40256	0,00024	9,44363	0,04083

9	10,2163	10,2521	10,2205	0,0316	10,2224	0,0297	10,2659	0,0138
10	11,0449	10,9124	10,8764	0,036	10,8821	0,0303	10,9216	0,0092
11	11,8018	11,3651	11,332	0,0331	11,3438	0,0213	11,37	0,0049
12	12,4929	11,5622	11,5419	0,0203	11,5624	0,0002	11,5634	0,0012
13	13,1231	11,4499	11,4639	0,014	11,4956	0,0457	11,4588	0,0089
14	13,6983	11,0614	11,071	0,0096	11,1156	0,0542	11,0305	0,0309
15	14,2221	10,3324	10,3615	0,0291	10,4202	0,0878	10,2802	0,0522
16	14,6995	9,32683	9,35819	0,03136	9,43143	0,1046	9,23473	0,0921
17	15,1346	8,08944	8,10348	0,01404	8,19122	0,10178	7,94044	0,149
18	15,5311	6,63955	6,65039	0,01084	6,75238	0,11283	6,45275	0,1868
19	15,8929	5,06189	5,05154	0,01035	5,16733	0,10544	4,82563	0,23626
20	16,2229	3,38247	3,35826	0,02421	3,4874	0,10493	3,10956	0,27291
21	16,5241	1,66893	1,6135	0,05543	1,75544	0,08651	1,3488	0,32013
22	16,7987	-0,13439	-0,144312	0,009922	0,0101969	0,1445869	-0,419524	0,285134
23	17,0499	-1,89254	-1,89209	0,00045	-1,72563	0,16691	-2,1733	0,28076
24	17,2793	-3,61137	-3,60461	0,00676	-3,42676	0,18461	-3,88806	0,27669
25	17,4885	-5,29902	-5,26277	0,03625	-5,07394	0,22508	-5,5455	0,24648
			0,452793		1,6835219		2,68098	


Tablo 6.16’da 2-D modeline ait tahmin edilen parametreler değerleri sunulmuştur. Tahmin sonuçları literatürde raporlanan WOA (Oliva vd., 2017), SCA (Mirjalili, 2016), MVO (Mirjalili vd., 2016), karınca aslanı optimizasyonu (ant lion optimization, ALO), lider ve av optimizasyonu (leader and prey optimization, LAPO), kuş çiftleşme optimizasyonu (bird mating optimization, BMA) (Rizk-Allah ve El-Fergany, 2020) meta-sezgisel algoritmalar ile karşılaştırılmıştır. Önerilen algoritmalar ile elde edilen en düşük RMSE değerleri (INFO: $1,3251 \times 10^{-3}$, QIO: $9,2769 \times 10^{-3}$), karşılaştırılan diğer meta-sezgisel yöntemleri geride bırakmayı başarmıştır. INFO ve QIO algoritmaları sırasıyla Şekil 6.28 (a), (b), ve Şekil 6.29 (a), (b)’de sunulan 2-D modeli için elde edilen I-V ve P-V karakteristik eğrileri, ölçülen ve tahmin edilen parametrelerin gerçek değerleriyle uyum içinde olduğunu göstermektedir. Ayrıca, belirlenen MPP üzerinde elde edilen sonuçlarda oldukça tutarlıdır. Yakınsama eğrileri (INFO ve QIO) sırasıyla Şekil 6.30 ve Şekil 6.31 sunulmuştur.

Tablo 6.16. INFO ve QIO’dan elde edilen sonuçların PWP201 (2-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması

Algori tma	I_{ph} (A)	I_{o1} (μ A)	R_s (Ω)	R_{sh} (Ω)	a_1	I_{o2} (μ A)	a_2	RMSE
INFO	1,0336	0,68481	1,5973	624,655	45,110	$8,629 \times 10^{-21}$	11,027	$1,3251 \times 10^{-3}$
QIO	1,0315	0,91949	1,2392	809,935	49,148	1,647569	49,483	$9,2769 \times 10^{-3}$
LAPO	0,9801	0,0084	0,0396	73,0393	1	0,0809	1,2	$3,2734 \times 10^{-2}$
BMA	0,9801	0,0111	0,0377	5	1	0,1110	1,2	$5,383 \times 10^{-2}$
WOA	1,0439	2,1386	1,7256	639,029	48,771	0	48,460	$2,87 \times 10^{-2}$
SCA	1,0459	3,0721	1,3961	654,163	50	0	1	$1,32 \times 10^{-2}$
MVO	1,0485	0	15382	363,324	11,739	0,63312	44,581	$1,14 \times 10^{-2}$
ALO	1,0267	2,7924	1,0805	863,075	50	0,21348	49,581	$9,7 \times 10^{-3}$




(a)




(b)

Şekil 6.28. INFO algoritmasıyla 2-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




(a)




(b)

Şekil 6.29. QIO algoritmasıyla 2-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.30. PWP201 veri seti için INFO algoritmasına ait 2-D modeli yakınsama eğrisi



Şekil 6.31. PWP201 veri seti için QIO algoritmasına ait 2-D modeli yakınsama eğrisi

Tablo 6.17’de 2-D modeli için önerilen INFO ve QIO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $2,42349 \times 10^{-2}$, $1,87419 \times 10^{-1}$ ve Tablo 6.18’de ise toplam IAE (güç) değerleri sırasıyla $2,30838 \times 10^{-1}$, 2,709204 olarak hesaplanmıştır. Her veri satırı için hesaplanan IAE ve RE değerleri ise modelin doğruluğunu desteklemektedir.

Tablo 6.17. PWP201 veri seti için 2-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO		
		It	IAE	RE	It	IAE	RE
1	1,0315	1,0308	0,0007	0,0006786	1,0278	0,0037	0,003587
2	1,03	1,0281	0,0019	0,0018447	1,0255	0,0045	0,0043689
3	1,026	1,0256	0,0004	0,0003899	1,0234	0,0026	0,0025341
4	1,022	1,0233	0,0013	-0,001272	1,0213	0,0007	0,0006849
5	1,018	1,0209	0,0029	-0,0028487	1,0191	0,0011	-0,0010806
6	1,0155	1,0183	0,0028	-0,0027573	1,0165	0,001	-0,0009847
7	1,014	1,0149	0,0009	-0,0008876	1,0128	0,0012	0,0011834
8	1,01	1,0096	0,0004	0,000396	1,007	0,003	0,0029703
9	1,0035	1,0007	0,0028	0,0027902	0,99735	0,00615	0,0061286
10	0,988	0,98587	0,00213	0,0021559	0,98157	0,00643	0,0065081
11	0,963	0,96185	0,00115	0,0011942	0,95679	0,00621	0,0064486
12	0,9255	0,9254	1E-04	0,000108	0,92006	0,00544	0,0058779
13	0,8725	0,87421	0,00171	-0,0019599	0,86908	0,00342	0,0039198
14	0,8075	0,80756	6E-05	-7,43E-05	0,80275	0,00475	0,0058824
15	0,7265	0,72688	0,00038	-0,0005231	0,7219	0,0046	0,0063317
16	0,6345	0,63471	0,00021	-0,000331	0,62864	0,00586	0,0092356
17	0,5345	0,5341	0,0004	0,0007484	0,52604	0,00846	0,0158279
18	0,4275	0,42797	0,00047	-0,0010994	0,41745	0,01005	0,0235088
19	0,3185	0,31871	0,00021	-0,0006593	0,30582	0,01268	0,0398116
20	0,2085	0,20853	3E-05	-0,0001439	0,19383	0,01467	0,0703597
21	0,101	0,099252	0,001748	0,0173069	0,083371	0,017629	0,1745446
22	-0,008	-0,0074431	0,0005569	0,0696125	-0,02378	0,01578	-1,9725
23	-0,111	-0,11066	0,00034	0,0030631	-0,12697	0,01597	-0,1438739
24	-0,209	-0,20931	0,00031	-0,0014833	-0,2253	0,0163	-0,0779904
25	-0,303	-0,30267	0,00033	0,0010891	-0,31822	0,01522	-0,050231
		0,0242349			0,187419		

Tablo 6.18. PWP201 veri seti için 2-D modeline ait ölçülen ve tahmin edilen güç verileri


S. NO	V	Pö	INFO		QIO	
			Pt	IAE	Pt	IAE
1	0,1248	0,128731	0,128648	8,3E-05	0,128268	0,000463
2	1,8093	1,86358	1,8602	0,00338	1,85544	0,00814
3	3,3511	3,43823	3,43701	0,00122	3,42941	0,00882
4	4,7622	4,86697	4,87307	0,0061	4,86364	0,00333
5	6,0538	6,16277	6,18051	0,01774	6,1696	0,00683
6	7,2364	7,34856	7,36887	0,02031	7,35588	0,00732
7	8,3189	8,43536	8,44246	0,0071	8,42557	0,00979
8	9,3097	9,4028	9,39866	0,00414	9,37479	0,02801
9	10,2163	10,2521	10,2237	0,0284	10,1892	0,0629
10	11,0449	10,9124	10,8889	0,0235	10,8414	0,071
11	11,8018	11,3651	11,3515	0,0136	11,2919	0,0732
12	12,4929	11,5622	11,5609	0,0013	11,4942	0,068
13	13,1231	11,4499	11,4723	0,0224	11,405	0,0449

14	13,6983	11,0614	11,0622	0,0008	10,9964	0,065
15	14,2221	10,3324	10,3377	0,0053	10,267	0,0654
16	14,6995	9,32683	9,32989	0,00306	9,24072	0,08611
17	15,1346	8,08944	8,08337	0,00607	7,96143	0,12801
18	15,5311	6,63955	6,64683	0,00728	6,48343	0,15612
19	15,8929	5,06189	5,06518	0,00329	4,86044	0,20145
20	16,2229	3,38247	3,38301	0,00054	3,14442	0,23805
21	16,5241	1,66893	1,64004	0,02889	1,37764	0,29129
22	16,7987	-0,13439	-0,125035	0,009355	-0,399481	0,265091
23	17,0499	-1,89254	-1,88676	0,00578	-2,16476	0,27222
24	17,2793	-3,61137	-3,6168	0,00543	-3,89298	0,28161
25	17,4885	-5,29902	-5,29325	0,00577	-5,56517	0,26615
				0,230838	2,709204	


Tablo 6.19’da 3-D modeline ait tahmin edilen parametreler değerleri sunulmuştur. Tahmin sonuçları literatürde raporlanan WOA, SCA, MVO, ALO, GWO (Yu vd., 2018), güve alevi optimizasyonu (moth flame optimization, MFO) (Allam vd., 2016), vatoz beslenme optimizasyonu (manta ray foraging optimization, MRFO) (Houssein vd., 2021) meta-sezgisel algoritmalar ile karşılaştırılmıştır. Önerilen algoritmalar ile elde edilen en düşük RMSE değerleri (INFO: $1,459 \times 10^{-3}$, QIO: $2,083 \times 10^{-3}$), karşılaştırılan diğer meta-sezgisel yöntemleri geride bırakmayı başarmıştır. INFO ve QIO algoritmaları sırasıyla Şekil 6.32 (a), (b), ve Şekil 6.33 (a), (b)’de sunulan 3-D modeli için elde edilen I-V ve P-V karakteristik eğrileri, ölçülen ve tahmin edilen parametrelerin gerçek değerleriyle uyum içinde olduğunu göstermektedir. Ayrıca, belirlenen MPP üzerinde elde edilen sonuçlarda oldukça tutarlıdır. Yakınsama eğrileri (INFO ve QIO) sırasıyla Şekil 6.34 ve Şekil 6.35 sunulmuştur.

Tablo 6.19. INFO ve QIO’dan elde edilen sonuçların PWP201 (3-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması

Algoritma	I_{ph} (A)	I_{o1} (μA)	R_s (Ω)	R_{sh} (Ω)	α_1	I_{o2} (μA)	I_{o3} (μA)	a_2	a_3	RMSE
INFO	1,0341	$4,74 \times 10^{-20}$	1,6015	592,83	21,777	0,6774	$9,4 \times 10^{-19}$	45,109	11,981	$1,459 \times 10^{-3}$
QIO	1,0314	1,184133	1,2382	815,87	49,227	0,8492	0,552416	49,628	49,383	$2,083 \times 10^{-3}$
MRFO	1,0326	1,4319	1,2674	694,45	48,870	0,0910	0,51877	49,922	47,521	$2,099 \times 10^{-3}$
WOA	1,0254	0	1,6753	1912,0	23,817	0,2282	0	41,540	41,866	$1,18 \times 10^{-2}$
SCA	1,0506	0,2	1,1733	528,39	50	0,6505	0,2	50	50	$1,43 \times 10^{-2}$
MVO	1,0285	1,2276	1,5533	1994,7	49,405	0,1227	0	43,081	21,133	$1,21 \times 10^{-2}$
ALO	1,0288	0,20021	1,4543	836,87	42,139	0,3075	0,25439	49,222	47,367	$4,9 \times 10^{-3}$
GWO	1,0359	1,6649	1,2448	454,12	49,945	0,3818	0,006744	45,656	45,289	$3,3 \times 10^{-3}$
MFO	1,0374	2,1291	2	2000	50	0,2001	0,20011	41,647	50	$3,05 \times 10^{-2}$




(a)




(b)

Şekil 6.32. INFO algoritmasıyla 3-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




(a)




(b)

Şekil 6.33. QIO algoritmasıyla 3-D (PWP201) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.34. PWP201 veri seti için INFO algoritmasına ait 3-D modeli yakınsama eğrisi



Şekil 6.35. PWP201 veri seti için QIO algoritmasına ait 3-D modeli yakınsama eğrisi

Tablo 6.20’de önerilen INFO ve QIO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $2,75351 \times 10^{-2}$, $4,38874 \times 10^{-2}$ ve Tablo 6.21’de ise toplam IAE (güç) değerleri sırasıyla $2,9113 \times 10^{-1}$, $4,99149 \times 10^{-1}$ olarak hesaplanmıştır. Her veri satırı için hesaplanan IAE ve RE değerleri ise modellerin doğruluğunu desteklemektedir.

Tablo 6.20. PWP201 veri seti için 3-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO		
		It	IAE	RE	It	IAE	RE
1	1,0315	1,0312	0,0003	0,0002908	1,0305	0,001	0,0009695
2	1,03	1,0283	0,0017	0,0016505	1,0281	0,0019	0,0018447
3	1,026	1,0257	0,0003	0,0002924	1,0259	1E-04	9,747E-05
4	1,022	1,0232	0,0012	-0,0011742	1,0238	0,0018	-0,0017613
5	1,018	1,0208	0,0028	-0,0027505	1,0216	0,0036	-0,0035363
6	1,0155	1,0181	0,0026	-0,0025603	1,019	0,0035	-0,0034466
7	1,014	1,0145	0,0005	-0,0004931	1,0153	0,0013	-0,0012821
8	1,01	1,0092	0,0008	0,0007921	1,0096	0,0004	0,000396
9	1,0035	1,0003	0,0032	0,0031888	1,0001	0,0034	0,0033881
10	0,988	0,9855	0,0025	0,0025304	0,98456	0,00344	0,0034818
11	0,963	0,96159	0,00141	0,0014642	0,96021	0,00279	0,0028972
12	0,9255	0,92534	0,00016	0,0001729	0,9241	0,0014	0,0015127
13	0,8725	0,87441	0,00191	-0,0021891	0,87394	0,00144	-0,0016504
14	0,8075	0,80805	0,00055	-0,0006811	0,80863	0,00113	-0,0013994
15	0,7265	0,72756	0,00106	-0,0014591	0,72894	0,00244	-0,0033586
16	0,6345	0,63539	0,00089	-0,0014027	0,63692	0,00242	-0,003814
17	0,5345	0,53455	5E-05	-9,355E-05	0,53558	0,00108	-0,0020206
18	0,4275	0,42802	0,00052	-0,0012164	0,42825	0,00075	-0,0017544
19	0,3185	0,31831	0,00019	0,0005965	0,31783	0,00067	0,0021036
20	0,2085	0,20782	0,00068	0,0032614	0,20699	0,00151	0,0072422
21	0,101	0,098454	0,002546	0,0252079	0,097687	0,003313	0,032802
22	-0,008	-0,0080691	6,91E-05	-0,0086375	-0,0084344	0,0004344	-0,0543
23	-0,111	-0,11088	0,00012	0,0010811	-0,11066	0,00034	0,0030631
24	-0,209	-0,20894	6E-05	0,0002871	-0,20809	0,00091	0,0043541
25	-0,303	-0,30158	0,00142	0,0046865	-0,30018	0,00282	0,0093069
		0,0275351			0,0438874		

Tablo 6.21. PWP201 veri seti için 3-D modeline ait ölçülen ve tahmin edilen güç verileri

S. NO	V	Pö	INFO		QIO	
			Pt	IAE	Pt	IAE
1	0,1248	0,128731	0,128691	4E-05	0,1286	0,000131
2	1,8093	1,86358	1,86056	0,00302	1,86017	0,00341
3	3,3511	3,43823	3,43725	0,00098	3,43802	0,00021
4	4,7622	4,86697	4,87283	0,00586	4,87569	0,00872
5	6,0538	6,16277	6,17955	0,01678	6,18475	0,02198
6	7,2364	7,34856	7,36704	0,01848	7,37391	0,02535
7	8,3189	8,43536	8,4397	0,00434	8,44644	0,01108
8	9,3097	9,4028	9,39505	0,00775	9,39876	0,00404
9	10,2163	10,2521	10,2195	0,0326	10,217	0,0351
10	11,0449	10,9124	10,8848	0,0276	10,8743	0,0381
11	11,8018	11,3651	11,3484	0,0167	11,3322	0,0329
12	12,4929	11,5622	11,5601	0,0021	11,5446	0,0176
13	13,1231	11,4499	11,475	0,0251	11,4688	0,0189
14	13,6983	11,0614	11,0689	0,0075	11,0769	0,0155
15	14,2221	10,3324	10,3474	0,015	10,3671	0,0347


16	14,6995	9,32683	9,33998	0,01315	9,36237	0,03554
17	15,1346	8,08944	8,09026	0,00082	8,10585	0,01641
18	15,5311	6,63955	6,64757	0,00802	6,65114	0,01159
19	15,8929	5,06189	5,05891	0,00298	5,05132	0,01057
20	16,2229	3,38247	3,37145	0,01102	3,35799	0,02448
21	16,5241	1,66893	1,62686	0,04207	1,6142	0,05473
22	16,7987	-0,13439	-0,13555	0,00116	-0,141688	0,007298
23	17,0499	-1,89254	-1,89042	0,00212	-1,88667	0,00587
24	17,2793	-3,61137	-3,61027	0,0011	-3,59568	0,01569
25	17,4885	-5,29902	-5,27418	0,02484	-5,24977	0,04925
			0,29113		0,499149	

Tablo 6.22’de sunulan veriler, 1-D, 2-D ve 3-D elektriksel devre modelleri için önerilen INFO, QIO ve FLO algoritmalarının RMSE değerlerine ilişkin istatistiksel analizleri içermektedir. Bu performans ölçütlerinin dağılım grafiği Şekil 6.36 ve Şekil 6.37’de sunulmuştur. Elde edilen sonuçlar doğrultusunda, INFO algoritması tüm modeller için en düşük hata oranlarını sağlarken, özellikle 1-D modelinde minimum, maksimum ve ortalama RMSE değerlerinin $2,05284 \times 10^{-3}$ ile sabit olduğu ve varyansın $6,9248 \times 10^{-32}$ gibi son derece düşük bir seviyede olduğu görülmektedir. 2-D ve 3-D modellerinde ise INFO algoritmasının hata oranları artmakla birlikte, diğer algoritmalara kıyasla daha düşük seviyelerde kalmaktadır. QIO algoritması, 1-D modelinde INFO’ya kıyasla daha yüksek RMSE değerleri üretmiş olsa da, 2-D ve 3-D modellerinde nispeten daha iyi sonuçlar elde edebilmiştir. FLO algoritması ise özellikle 1-D modelinde diğer algoritmalara kıyasla belirgin şekilde daha yüksek hata oranları göstermiş olup, maksimum RMSE değeri $4,37314 \times 10^{-1}$ olarak kaydedilmiştir. FLO’nun yüksek varyans değeri ($2,22 \times 10^{-2}$) ve standart sapması ($1,49 \times 10^{-1}$), hata dağılımındaki dengesizliği ve modelin güvenilirlik açısından zayıf performans sergilediğini ortaya koymaktadır. Genel olarak, INFO algoritmasının özellikle düşük boyutlu modellerde en stabil ve güvenilir sonuçları sağladığı, FLO’nun ise önemli ölçüde daha yüksek hata oranlarıyla düşük performans sergilediği söylenebilir.


Tablo 6.22. 1-D, 2-D ve 3-D modelleri için önerilen algoritmalarla elde edilen RMSE değerlerine ait istatistiksel sonuçlar (PWP201)

Önerilen algoritmalar	İstatistiksel skorlar (RMSE)	1-D	2-D	3-D
INFO	Minimum	$2,05284 \times 10^{-3}$	$1,325 \times 10^{-3}$	$1,5059 \times 10^{-3}$
	Maksimum	$2,05284 \times 10^{-3}$	$2,4353 \times 10^{-3}$	$2,0638 \times 10^{-3}$
	Ortalama	$2,052849 \times 10^{-3}$	$8,5843 \times 10^{-3}$	$1,9539 \times 10^{-3}$
	Standart sapma	$2,6315 \times 10^{-16}$	$7,3459 \times 10^{-3}$	$1,5776 \times 10^{-4}$
	Varyans	$6,9248 \times 10^{-32}$	$5,3962 \times 10^{-3}$	$2,4889 \times 10^{-8}$
QIO	Minimum	$2,05291 \times 10^{-3}$	$2,05395 \times 10^{-3}$	$2,05379 \times 10^{-3}$
	Maksimum	$2,08209 \times 10^{-3}$	$2,35236 \times 10^{-3}$	$2,35937 \times 10^{-3}$
	Ortalama	$2,05832 \times 10^{-3}$	$2,09210 \times 10^{-3}$	$2,09605 \times 10^{-3}$
	Standart sapma	$7,7062 \times 10^{-6}$	$6,0899 \times 10^{-6}$	$5,6869 \times 10^{-5}$

FLO	Varyans	$5,9385 \times 10^{-11}$	$3,7087 \times 10^{-9}$	$3,234 \times 10^{-9}$
	Minimum	$9,75447 \times 10^{-3}$	-	-
	Maksimum	$4,37314 \times 10^{-1}$	-	-
	Ortalama	$2,19881 \times 10^{-1}$	-	-
	Standart sapma	$1,49 \times 10^{-1}$	-	-
	Varyans	$2,22 \times 10^{-2}$	-	-



Şekil 6.36. INFO algoritması ile tüm çalışmaların (30) istatistiksel RMSE dağılım grafikleri (PWP201) : (a) 1-D, (b) 2-D, (c) 3-D



Şekil 6.37. QIO algoritması ile tüm çalışmaların (30) istatistiksel RMSE dağılım grafikleri (PWP201) : (a) 1-D, (b) 2-D, (c) 3-D

1-D, 2-D ve 3-D modellerinin performansını kapsamlı bir şekilde değerlendirmek amacıyla, Photowatt-PWP201 veri seti kullanılarak INFO, QIO ve FLO algoritmaları ile gerçekleştirilen analizlerde IAE, RMSE, MAE, MBE, T-istatistiği, R^2 , NRMSE, NMBE ve NMAE gibi temel istatistiksel hata metrikleri Tablo 6.23'te sunulmuştur. Elde edilen hata oranları, önerilen algoritmaların sağlamlığını ve güvenilirliğini açıkça ortaya koymaktadır. Modellerin genel doğruluğu incelendiğinde, tüm modellerde R^2 değerlerinin oldukça yüksek olduğu gözlemlenmekte olup, düşük MAE, MBE, NRMSE, NMBE ve NMAE değerleri, önerilen algoritmaların yüksek doğrulukla tahmin yapabildiğini kanıtlamaktadır. Bu analizler, önerilen algoritmaların yalnızca güvenilir ve istikrarlı sonuçlar üretmekle kalmayıp, aynı zamanda gerçek değerlerle yüksek oranda uyumlu tahminler sağladığını ortaya koymaktadır

Tablo 6.23. PWP201 veri setinde 1-D, 2-D ve 3-D için istatistiksel hata oranları

	Model	IAE	RMSE	MAE	MBE	t- istatistik	R ²	NRMSE	NMBE	NMAE
INFO	1-D	0,042455	0,0020528	0,001698	4,628E-06	0,01104	0,999978	0,003198	7,21E-06	0,002645
	2-D	0,024234	0,0013251	0,000969	-6,356E-06	0,02349	0,999991	0,002064	-9,902E-06	0,001510
	3-D	0,027535	0,001459	0,001101	7,004E-06	0,02351	0,999989	0,002273	1,091E-05	0,001715
QIO	1-D	0,117177	0,0057876	0,004687	-0,0037951	4,25482	0,999829	0,009016	-0,0059124	0,007302
	2-D	0,187419	0,0092769	0,007496	0,0073288	6,31245	0,999562	0,014452	0,0114176	0,011679
	3-D	0,043887	0,002083	0,001755	-0,0001269	0,29901	0,999978	0,003245	-0,0001977	0,002734
FLO	1-D	0,185608	0,0097545	0,007424	0,0047179	2,70718	0,999516	0,015196	0,0073502	0,011566



6.1.3 STM6-40/36 veri setiyle elde edilen sonuçlar

Bu alt bölüm, önerilen INFO, QIO ve FLO algoritmalarının STM6-40/36 modül verileri kullanılarak 1-D, 2-D ve 3-D modellerine ait analiz sonuçları detaylı bir şekilde sunulmuştur. Tablo 6.24'te 1-D modeline ait tahmin edilen parametreler sunulmuştur. Tahmin sonuçları literatürde raporlanan üçlü arşivli parçacık sürü optimizasyonu (triple archives particle swarm optimization, TAPSO) (Yang ve Gong, 2021), yapay arı kolonisi (artificial bee colony, ABC), kaotik geliştirilmiş yapay arı kolonisi (chaotic improved artificial bee colony, CIABC) (Beigi ve Maroosi, 2018), PSO, SCA (Issa vd., 2024), WDO (Mathew vd., 2017) meta-sezgisel algoritmalar ile karşılaştırılmıştır. Önerilen algoritmalar ile elde edilen en düşük RMSE değerleri (INFO: $1,72190 \times 10^{-3}$, QIO: $9,8474 \times 10^{-3}$, FLO: $1,2036 \times 10^{-2}$), karşılaştırılan meta-sezgisel yöntemleri geride bırakarak parametre tahmininde yüksek doğruluk tahminleme yeteneğini ortaya koymuştur. INFO, QIO, FLO algoritmaları sırasıyla Şekil 6.38 (a), (b), Şekil 6.39 (a), (b) ve Şekil 6.40 (a), (b)'de sunulan 1-D modeli için elde edilen I-V ve P-V karakteristik eğrileri, ölçülen ve tahmin edilen parametrelerin gerçek değerleriyle uyum içinde olduğunu göstermektedir. Ayrıca, belirlenen MPP üzerinde elde edilen sonuçlarda oldukça tutarlıdır. 1-D modeli için yakınsama eğrileri (INFO, QIO ve FLO) sırasıyla Şekil 6.41, Şekil 6.42 ve Şekil 6.43'de sunulmuştur. En düşük RMSE değerinin erken aşamada elde edilmesi, önerilen algoritmaların yüksek doğrulukta parametre tahmin yeteneğini desteklemektedir.



Tablo 6.24. INFO, QIO ve FLO'dan elde edilen sonuçların STM6-40/36 (1-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması

Algoritma	I_{ph} (A)	I_{o1} (μ A)	R_s (Ω)	R_{sh} (Ω)	a_1	RMSE
INFO	1,663903	1,741247	0,1536401	573,5339	57,95511	$1,72190 \times 10^{-3}$
QIO	1,663906	1,735349	0,1539675	572,8437	57,94096	$9,8474 \times 10^{-3}$
FLO	1,664394	1,955187	0,1534515	950,3287	58,27311	$1,2036 \times 10^{-2}$


TAPSO	1,66180	12,8424	0,00053	190,1861	1,77407	$1,3423 \times 10^{-2}$
ABC	1,5	1,6644	0,1796	547,416	53,5176	$1,9253 \times 10^{-1}$
CIABC	1,6642	1,676	0,1584	562,212	53,9136	$2,518 \times 10^{-2}$
PSO	1,64	0,151	0,28	200,94	55,82	$2,41 \times 10^{-2}$
SCA	1,74	0,252	0,86	100,52	54,51	$2,95 \times 10^{-2}$
WDO	0,827900	42,22415	0,312870	772,4239	28,6336	$9,34228 \times 10^{-2}$




Şekil 6.38. INFO algoritmasıyla 1-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




Şekil 6.39. QIO algoritmasıyla 1-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




Şekil 6.40. FLO algoritmasıyla 1-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.41. STM6 veri seti için INFO algoritmasına ait 1-D modeli yakınsama eğrisi



Şekil 6.42. STM6 veri seti için QIO algoritmasına ait 1-D modeli yakınsama eğrisi



Şekil 6.43. STM6 veri seti için FLO algoritmasına ait 1-D modeli yakınsama eğrisi

1-D modeli için analizi yapılan IAE ve RE amaç fonksiyonları ölçülen her veri noktası için önerilen algoritmalar aracılığıyla tahmin edilen akım ve güç değerleri Tablo 6.25 ve 6.26'da verilmiştir. Tablo 6.25'te 1-D modeli için önerilen INFO, QIO ve FLO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $2,19259 \times 10^{-2}$, $9,6384 \times 10^{-2}$, $1,52921 \times 10^{-1}$ ve Tablo 6.26'da ise toplam IAE (güç) değerleri sırasıyla $2,821951 \times 10^{-1}$, 1,740567, 2,410642 olarak hesaplanmıştır. Her veri satırı için hesaplanan IAE ve RE değerleri ise modelin doğruluğunu desteklemektedir.

Tablo 6.25. STM6 veri seti için 1-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO			FLO		
		It	IAE	RE	It	IAE	RE	It	IAE	RE
1	1,663	1,6635	0,0005	-0,0003007	1,6634	0,0004	-0,0002405	1,6641	0,0011	-0,0006615
2	1,663	1,6633	0,0003	-0,0001804	1,6632	0,0002	-0,0001203	1,664	0,001	-0,0006013
3	1,661	1,6596	0,0014	0,0008429	1,6595	0,0015	0,0009031	1,6618	0,0008	-0,0004816
4	1,653	1,6539	0,0009	-0,0005445	1,6539	0,0009	-0,0005445	1,6583	0,0053	-0,0032063
5	1,65	1,6506	0,0006	-0,0003636	1,6506	0,0006	-0,0003636	1,6562	0,0062	-0,0037576
6	1,645	1,6454	0,0004	-0,0002432	1,6455	0,0005	-0,000304	1,6527	0,0077	-0,0046809
7	1,64	1,6392	0,0008	0,0004878	1,6392	0,0008	0,0004878	1,6476	0,0076	-0,0046341
8	1,636	1,6337	0,0023	0,0014059	1,6336	0,0024	0,001467	1,6425	0,0065	-0,0039731
9	1,629	1,6273	0,0017	0,0010436	1,627	0,002	0,0012277	1,6363	0,0073	-0,0044813
10	1,619	1,6183	0,0007	0,0004324	1,6179	0,0011	0,0006794	1,6273	0,0083	-0,0051266
11	1,597	1,6031	0,0061	-0,0038197	1,6022	0,0052	-0,0032561	1,6118	0,0148	-0,0092674
12	1,581	1,5816	0,0006	-0,0003795	1,5801	0,0009	0,0005693	1,5896	0,0086	-0,0054396
13	1,542	1,5423	0,0003	-0,0001946	1,5398	0,0022	0,0014267	1,5489	0,0069	-0,0044747
14	1,524	1,5212	0,0028	0,0018373	1,5182	0,0058	0,0038058	1,5269	0,0029	-0,0019029
15	1,5	1,4992	0,0008	0,0005333	1,4956	0,0044	0,0029333	1,504	0,004	-0,0026667
16	1,485	1,4853	0,0003	-0,000202	1,4813	0,0037	0,0024916	1,4895	0,0045	-0,0030303
17	1,465	1,4656	0,0006	-0,0004096	1,4611	0,0039	0,0026621	1,4691	0,0041	-0,0027986
18	1,388	1,3876	0,0004	0,0002882	1,381	0,007	0,0050432	1,3878	0,0002	0,0001441
19	1,118	1,1184	0,0004	-0,0003578	1,105	0,013	0,0116279	1,1081	0,0099	0,0088551
20	0	-2,593E-05	2,593E-05	-	-0,039884	0,039884	-	-0,045221	0,045221	-
		0,0219259			0,096384			0,152921		

Tablo 6.26. STM6 veri seti için 1-D modeline ait ölçülen ve tahmin edilen güç verileri


S. NO	V	Pö	INFO		QIO		FLO	
			Pt	IAE	Pt	IAE	Pt	IAE
1	0	0	0	0	0	0	0	0
2	0,118	0,196234	0,196264	3E-05	0,196252	1,8E-05	0,196352	0,000118
3	2,237	3,71566	3,71242	0,00324	3,71229	0,00337	3,71737	0,00171
4	5,434	8,9824	8,98738	0,00498	8,98742	0,00502	9,01137	0,02897
5	7,26	11,979	11,9831	0,0041	11,9834	0,0044	12,0242	0,0452
6	9,68	15,9236	15,9278	0,0042	15,9283	0,0047	15,9981	0,0745
7	11,59	19,0076	18,9987	0,0089	18,9988	0,0088	19,0957	0,0881
8	12,6	20,6136	20,5848	0,0288	20,5836	0,03	20,6957	0,0821
9	13,37	21,7797	21,7568	0,0229	21,7536	0,0261	21,8772	0,0975
10	14,09	22,8117	22,802	0,0097	22,7955	0,0162	22,929	0,1173
11	14,88	23,7634	23,8536	0,0902	23,8408	0,0774	23,9834	0,22
12	15,59	24,6478	24,6569	0,0091	24,6345	0,0133	24,7824	0,1346
13	16,4	25,2888	25,2941	0,0053	25,2533	0,0355	25,4018	0,113
14	16,71	25,466	25,4196	0,0464	25,3686	0,0974	25,515	0,049
15	16,98	25,47	25,4565	0,0135	25,3947	0,0753	25,5381	0,0681

16	17,13	25,4381	25,4426	0,0045	25,374	0,0641	25,5151	0,077
17	17,32	25,3738	25,3849	0,0111	25,3065	0,0673	25,4441	0,0703
18	17,91	24,8591	24,8519	0,0072	24,7342	0,1249	24,8556	0,0035
19	19,08	21,3314	21,3389	0,0075	21,083	0,2484	21,1423	0,1891
20	21,02	0	-0,0005451	0,0005451	-0,838359	0,838359	-0,950544	0,950544
			0,2821951		1,740567		2,410642	


Tablo 6.27’de 2-D modeline ait tahmin edilen parametreler değerleri sunulmuştur. Tahmin sonuçları literatürde son zamanlarda raporlanan kedi sürüsü optimizasyonu (cat swarm optimization, CSO), BSA, geri izlemeli arama diferansiyel evrim (backtracking search differential evolution, BSDE) (Ginidi vd., 2021), GWO (Yu vd., 2018) meta-sezgisel algoritmalar ile karşılaştırılmıştır. Önerilen algoritmalar ile elde edilen en düşük RMSE değerleri (INFO: $1,6895 \times 10^{-3}$, QIO: $2,67 \times 10^{-3}$ RMSE değerlerini buraya yaz), karşılaştırılan diğer meta-sezgisel yöntemleri geride bırakmayı başarmıştır. INFO ve QIO algoritmaları sırasıyla Şekil 6.44 (a), (b), ve Şekil 6.45 (a), (b)’de sunulan 2-D modeli için elde edilen I-V ve P-V karakteristik eğrileri, ölçülen ve tahmin edilen parametrelerin gerçek değerleriyle uyum içinde olduğunu göstermektedir. Ayrıca, belirlenen MPP üzerinde elde edilen sonuçlarda oldukça tutarlıdır. Yakınsama eğrileri (INFO ve QIO) sırasıyla Şekil 6.46 ve Şekil 6.47 sunulmuştur.

Tablo 6.27. INFO ve QIO’den elde edilen sonuçların STM6-40/36 (2-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması

Algoritma	I_{ph} (A)	I_{o1} (μA)	R_s (Ω)	R_{sh} (Ω)	a_1	I_{o2} (μA)	a_2	RMSE
INFO	1,66397	$1,79744 \times 10^{-4}$	0,236423	5918573	37,42514	2,242764	60	$1,6895 \times 10^{-3}$
QIO	1,66387	1,635216	0,1535256	576,8297	58,68181	0,1864666	55,28489	$2,67 \times 10^{-3}$
CSO	1,66275	$8,10129 \times 10^{-5}$	0,0009937	22,866926	1,999995	4,71427	1,638598	$3,083 \times 10^{-3}$
GWO	1,65672	0	0,00000009	77,060503	1,131698	7,62072	1,701683	$4,7499 \times 10^{-3}$
BSA	1,659384	2,79872	0,0024318	29,078693	1,720983	1,47648	1,544659	$2,94174 \times 10^{-3}$
BSDE	1,661502	$4,0916 \times 10^{-2}$	0,00123632	23,491324	1,834918	4,23344	1,624981	$2,78120 \times 10^{-3}$




(a)




(b)


Şekil 6.44. INFO algoritmasıyla 2-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.45. QIO algoritmasıyla 2-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.46. STM6 veri seti için INFO algoritmasına ait 2-D modeli yakınsama eğrisi



Şekil 6.47. STM6 veri seti için QIO algoritmasına ait 2-D modeli yakınsama eğrisi

Tablo 6.28’de 2-D modeli için önerilen INFO ve QIO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $2,11205 \times 10^{-2}$, $3,92208 \times 10^{-2}$ ve Tablo 6.29’da ise toplam IAE (güç) değerleri sırasıyla $2,717431 \times 10^{-1}$, $5,79317 \times 10^{-1}$ olarak hesaplanmıştır. Her veri satırı için hesaplanan IAE ve RE değerleri ise modelin doğruluğunu desteklemektedir.

Tablo 6.28. STM6 veri seti için 2-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO		
		It	IAE	RE	It	IAE	RE
1	1,663	1,6633	0,0003	-0,0001804	1,6642	0,0012	-0,0007216
2	1,663	1,6631	1E-04	-6,013E-05	1,664	0,001	-0,0006013
3	1,661	1,6595	0,0015	0,0009031	1,6599	0,0011	0,0006623
4	1,653	1,654	0,001	-0,000605	1,6536	0,0006	-0,000363
5	1,65	1,6508	0,0008	-0,0004848	1,6499	1E-04	6,061E-05
6	1,645	1,6457	0,0007	-0,0004255	1,6444	0,0006	0,0003647
7	1,64	1,6394	0,0006	0,0003659	1,6381	0,0019	0,0011585
8	1,636	1,6337	0,0023	0,0014059	1,6327	0,0033	0,0020171
9	1,629	1,6272	0,0018	0,001105	1,6265	0,0025	0,0015347
10	1,619	1,6181	0,0009	0,0005559	1,6179	0,0011	0,0006794
11	1,597	1,6028	0,0058	-0,0036318	1,6031	0,0061	-0,0038197
12	1,581	1,5813	0,0003	-0,0001898	1,5822	0,0012	-0,000759
13	1,542	1,5422	0,0002	-0,0001297	1,5436	0,0016	-0,0010376
14	1,524	1,5212	0,0028	0,0018373	1,5227	0,0013	0,000853
15	1,5	1,4993	0,0007	0,0004667	1,5009	0,0009	-0,0006

16	1,485	1,4854	0,0004	-0,0002694	1,4871	0,0021	-0,0014141
17	1,465	1,4658	0,0008	-0,0005461	1,4675	0,0025	-0,0017065
18	1,388	1,388	0	0	1,3895	0,0015	-0,0010807
19	1,118	1,1181	1E-04	-8,945E-05	1,1189	0,0009	-0,000805
20	0	-2,046E-05	2,046E-05	-	0,0077208	0,0077208	-
				0,0211205	0,0392208		


Tablo 6.29. STM6 veri seti için 2-D modeline ait ölçülen ve tahmin edilen güç verileri

S. NO	V	Pö	INFO		QIO	
			Pt	IAE	Pt	IAE
1	0	0	0	0	0	0
2	0,118	0,196234	0,196247	1,3E-05	0,196351	0,000117
3	2,237	3,71566	3,71236	0,0033	3,71312	0,00254
4	5,434	8,9824	8,9881	0,0057	8,98567	0,00327
5	7,26	11,979	11,9846	0,0056	11,9784	0,0006
6	9,68	15,9236	15,93	0,0064	15,918	0,0056
7	11,59	19,0076	19,0003	0,0073	18,9861	0,0215
8	12,6	20,6136	20,5852	0,0284	20,5726	0,041
9	13,37	21,7797	21,7559	0,0238	21,7467	0,033
10	14,09	22,8117	22,7996	0,0121	22,7958	0,0159
11	14,88	23,7634	23,8499	0,0865	23,8542	0,0908
12	15,59	24,6478	24,6529	0,0051	24,6662	0,0184
13	16,4	25,2888	25,2921	0,0033	25,3152	0,0264
14	16,71	25,466	25,419	0,047	25,4451	0,0209
15	16,98	25,47	25,4574	0,0126	25,4854	0,0154
16	17,13	25,4381	25,4446	0,0065	25,4732	0,0351
17	17,32	25,3738	25,3881	0,0143	25,4172	0,0434
18	17,91	24,8591	24,8583	0,0008	24,8855	0,0264
19	19,08	21,3314	21,334	0,0026	21,3481	0,0167
20	21,02	0	-0,0004301	0,0004301	0,16229	0,16229
			0,2717431		0,579317	


Tablo 6.30’da 3-D modeline ait tahmin edilen parametreler değerleri sunulmuştur. Tahmin sonuçları literatürde raporlanan; CSO, BSA, GWO meta-sezgisel algoritmalar ile karşılaştırılmıştır. Önerilen algoritmalar ile elde edilen en düşük RMSE değerleri (INFO: $1,7032 \times 10^{-3}$, QIO: $2,0461 \times 10^{-3}$), karşılaştırılan diğer meta-sezgisel yöntemleri geride bırakmayı başarmıştır. INFO ve QIO algoritmaları sırasıyla Şekil 6.48 (a), (b), ve Şekil 6.49 (a), (b)’de sunulan 3-D modeli için elde edilen I-V ve P-V karakteristik eğrileri, ölçülen ve tahmin edilen parametrelerin gerçek değerleriyle uyum içinde olduğunu göstermektedir. Ayrıca, belirlenen MPP üzerinde elde edilen sonuçlarda oldukça tutarlıdır. Yakınsama eğrileri (INFO ve QIO) sırasıyla Şekil 6.50 ve Şekil 6.51 sunulmuştur. En düşük RMSE değerinin erken aşamada elde edilmesi, önerilen algoritmaların yüksek doğrulukta parametre tahmin yeteneğini desteklemektedir.

Tablo 6.30. INFO ve QIO'dan elde edilen sonuçların STM6-40/36 (3-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması

Algoritma	I_{ph} (A)	I_{o1} (μ A)	R_s (Ω)	R_{sh} (Ω)	α_1	I_{o2} (μ A)	I_{o3} (μ A)	a_2	a_3	RMSE
INFO	1,6639	0,01080	0,1862	581,86	60	0,00766	2,209243	45,360	59,988	$1,7032 \times 10^{-3}$
QIO	1,6638	0,116469	0,1547	580,37	53,696	0,751575	1,051411	58,397	59,609	$2,0461 \times 10^{-3}$
CSO	1,6080	5,35457	0,0001	25,495	1,6572	0,045389	0,35643	1,9996	1,8501	$3,3207 \times 10^{-3}$
GWO	1,6549	2,32362	0,0007	202,52	1,5843	4,44265	7,04756	1,9921	1,9996	$4,9739 \times 10^{-3}$
BSA	1,6576	0,350696	0,0046	43,382	1,3927	0,218898	11,4165	1,8232	1,9698	$3,6546 \times 10^{-3}$




(a)




(b)

Şekil 6.48. INFO algoritmasıyla 3-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




(a)




(b)

Şekil 6.49. QIO algoritmasıyla 3-D (STM6) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.50. STM6 veri seti için INFO algoritmasına ait 3-D modeli yakınsama eğrisi



Şekil 6.51. STM6 veri seti için QIO algoritmasına ait 3-D modeli yakınsama eğrisi

Tablo 6.31’de 3-D modeli için önerilen INFO ve QIO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $2,15067 \times 10^{-2}$, $2,9744 \times 10^{-2}$ ve Tablo 6.32’de ise toplam IAE (güç) değerleri sırasıyla $2,775843 \times 10^{-1}$, $4,054016 \times 10^{-1}$ olarak hesaplanmıştır. Her veri satırı için hesaplanan IAE ve RE değerleri ise modelin doğruluğunu desteklemektedir.

Tablo 6.31. STM6 veri seti için 3-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO		
		It	IAE	RE	It	IAE	RE
1	1,663	1,6634	0,0004	-0,0002405	1,6644	0,0014	-0,0008419
2	1,663	1,6632	0,0002	-0,0001203	1,6642	0,0012	-0,0007216
3	1,661	1,6596	0,0014	0,0008429	1,6604	0,0006	0,0003612
4	1,653	1,654	0,001	-0,000605	1,6546	0,0016	-0,0009679
5	1,65	1,6507	0,0007	-0,0004242	1,6511	0,0011	-0,0006667
6	1,645	1,6455	0,0005	-0,000304	1,6459	0,0009	-0,0005471
7	1,64	1,6393	0,0007	0,0004268	1,6396	0,0004	0,0002439
8	1,636	1,6337	0,0023	0,0014059	1,6341	0,0019	0,0011614
9	1,629	1,6272	0,0018	0,001105	1,6277	0,0013	0,000798
10	1,619	1,6182	0,0008	0,0004941	1,6187	0,0003	0,0001853
11	1,597	1,6029	0,0059	-0,0036944	1,6035	0,0065	-0,0040701
12	1,581	1,5814	0,0004	-0,000253	1,5822	0,0012	-0,000759
13	1,542	1,5423	0,0003	-0,0001946	1,543	0,001	-0,0006485
14	1,524	1,5212	0,0028	0,0018373	1,522	0,002	0,0013123
15	1,5	1,4993	0,0007	0,0004667	1,5	0	0
16	1,485	1,4854	0,0004	-0,0002694	1,4861	0,0011	-0,0007407
17	1,465	1,4658	0,0008	-0,0005461	1,4665	0,0015	-0,0010239
18	1,388	1,3878	0,0002	0,0001441	1,3885	0,0005	-0,0003602
19	1,118	1,1182	0,0002	-0,0001789	1,1194	0,0014	-0,0012522
20	0	-6,672E-06	6,672E-06	-	0,003844	0,003844	-
		0,0215067			0,029744		

Tablo 6.32. STM6 veri seti için 3-D modeline ait ölçülen ve tahmin edilen güç verileri


S. NO	V	Pö	INFO		QIO	
			Pt	IAE	Pt	IAE
1	0	0	0	0	0	0
2	0,118	0,196234	0,196258	2,4E-05	0,196374	0,00014
3	2,237	3,71566	3,71243	0,00323	3,71424	0,00142
4	5,434	8,9824	8,98779	0,00539	8,99084	0,00844
5	7,26	11,979	11,9839	0,0049	11,987	0,008
6	9,68	15,9236	15,9287	0,0051	15,9319	0,0083
7	11,59	19,0076	18,999	0,0086	19,0029	0,0047
8	12,6	20,6136	20,5844	0,0292	20,5893	0,0243
9	13,37	21,7797	21,7556	0,0241	21,7618	0,0179
10	14,09	22,8117	22,8001	0,0116	22,8078	0,0039
11	14,88	23,7634	23,8512	0,0878	23,8607	0,0973
12	15,59	24,6478	24,6547	0,0069	24,6657	0,0179
13	16,4	25,2888	25,2934	0,0046	25,3056	0,0168
14	16,71	25,466	25,4198	0,0462	25,4322	0,0338
15	16,98	25,47	25,4576	0,0124	25,4701	1E-04
16	17,13	25,4381	25,4443	0,0062	25,4568	0,0187
17	17,32	25,3738	25,3872	0,0134	25,3998	0,026
18	17,91	24,8591	24,8557	0,0034	24,8688	0,0097
19	19,08	21,3314	21,3358	0,0044	21,3586	0,0272

20	21,02	0	-0,0001403	0,0001403	0,0808016	0,0808016
				0,2775843		0,4054016


Tablo 6.33'te sunulan istatistiksel sonuçlar, STM6-40/36 veri seti kullanılarak 1-D, 2-D ve 3-D modelleri için önerilen INFO, QIO ve FLO algoritmalarının RMSE performanslarını kapsamlı bir şekilde ortaya koymaktadır. Bu performans ölçütlerinin dağılım grafiği Şekil 6.52 ve Şekil 6.53'de sunulmuştur. INFO algoritmasının tüm modellerde minimum, maksimum ve ortalama RMSE değerlerinde istikrarlı ve düşük hata oranları sağladığı, ayrıca varyans ve standart sapma değerlerinin oldukça küçük olması nedeniyle hata dağılımının dengeli olduğu görülmektedir. QIO algoritması, INFO ile benzer doğruluk seviyelerine sahip olmakla birlikte, standart sapma ve varyans değerleri biraz daha yüksektir, bu da hata dağılımında nispeten daha fazla değişkenlik olduğunu göstermektedir. FLO algoritması ise 1-D modelinde INFO ve QIO algoritmalarına kıyasla nispeten yüksek maksimum RMSE değeri ($1,54332 \times 10^{-1}$) ve ortalama hata oranı ($6,92115 \times 10^{-2}$) ile düşük doğruluk sergilemekte, ayrıca yüksek standart sapma ($3,3856 \times 10^{-2}$) ve varyans ($1,1462 \times 10^{-3}$) değerleri ile hata dağılımının dengesiz olduğunu ortaya koymaktadır. Bu sonuçlar, INFO ve QIO algoritmalarının genel olarak daha güvenilir ve kararlı tahminleme sağladığını, FLO algoritmasının ise özellikle 1-D modelinde düşük performans sergileyerek diğer iki algoritmaya göre yüksek hata oranları ürettiğini göstermektedir.

Tablo 6.33. 1-D, 2-D ve 3-D modelleri için önerilen algoritmalarla elde edilen RMSE değerlerine ait istatistiksel sonuçlar (STM6)

Önerilen algoritmalar	İstatistiksel skorlar (RMSE)	1-D	2-D	3-D
INFO	Minimum	$1,72192 \times 10^{-3}$	$1,6895 \times 10^{-3}$	$1,7032 \times 10^{-3}$
	Maksimum	$1,72192 \times 10^{-3}$	$1,7219 \times 10^{-3}$	$1,725 \times 10^{-3}$
	Ortalama	$1,72192 \times 10^{-3}$	$1,7157 \times 10^{-3}$	$1,7186 \times 10^{-3}$
	Standart sapma	$5,9352 \times 10^{-17}$	$8,5074 \times 10^{-6}$	$5,5577 \times 10^{-6}$
	Varyans	$3,5226 \times 10^{-33}$	$7,2376 \times 10^{-11}$	$3,0888 \times 10^{-11}$
QIO	Minimum	$1,72195 \times 10^{-3}$	$1,72094 \times 10^{-3}$	$1,71975 \times 10^{-3}$
	Maksimum	$1,75230 \times 10^{-3}$	$1,98216 \times 10^{-3}$	$1,78818 \times 10^{-3}$
	Ortalama	$1,72728 \times 10^{-3}$	$1,758189 \times 10^{-3}$	$1,73320 \times 10^{-3}$
	Standart sapma	$7,33 \times 10^{-6}$	$6,0796 \times 10^{-5}$	$1,5498 \times 10^{-5}$
	Varyans	$5,3729 \times 10^{-11}$	$3,6962 \times 10^{-9}$	$2,4018 \times 10^{-10}$
FLO	Minimum	$1,20357 \times 10^{-2}$	-	-
	Maksimum	$1,54332 \times 10^{-1}$	-	-
	Ortalama	$6,92115 \times 10^{-1}$	-	-
	Standart sapma	$3,3856 \times 10^{-1}$	-	-
	Varyans	$1,1462 \times 10^{-1}$	-	-



Şekil 6.52. INFO algoritması ile tüm çalışmaların (30) istatistiksel RMSE dağılım grafikleri (STM6) : (a) 1-D, (b) 2-D, (c) 3-D



Şekil 6.53. QIO algoritması ile tüm çalışmaların (30) istatistiksel RMSE dağılım grafikleri (STM6) : (a) 1-D, (b) 2-D, (c) 3-D

1-D, 2-D ve 3-D modellerinin performansını kapsamlı bir şekilde değerlendirmek amacıyla, Photowatt-PWP201 veri seti kullanılarak INFO, QIO ve FLO algoritmaları ile gerçekleştirilen analizlerde IAE, RMSE, MAE, MBE, T-istatistiği, R^2 , NRMSE, NMBE ve NMAE gibi temel istatistiksel hata metrikleri Tablo 6.34’te sunulmuştur.

Modellerin genel doğruluğu incelendiğinde, tüm modellerde R^2 değerlerinin oldukça yüksek olduğu gözlemlenmekte olup, düşük MAE, MBE, NRMSE, NMBE ve NMAE değerleri, önerilen algoritmaların yüksek doğrulukla PV parametre tahmini yapabildiğini kanıtlamaktadır.

Tablo 6.34. STM40-36 veri setinde 1-D, 2-D ve 3-D için istatistiksel hata oranları

	Model	IAE	RMSE	MAE	MBE	t- istatistik	R^2	NRMSE	NMBE	NMAE
INFO	1-D	0,02192	0,0017219	0,00109	-3,703E-06	0,009375	0,999977	0,0011611	-2,497E-06	0,0007393
	2-D	0,02112	0,0016895	0,00105	6,023E-06	0,0155398	0,999978	0,0011393	4,062E-06	0,0007121
	3-D	0,02150	0,0017032	0,00107	-4,666E-06	0,0119424	0,999978	0,0011485	-3,147E-06	0,0007251
QIO	1-D	0,09638	0,0098474	0,00481	0,0040392	1,9604394	0,999264	0,0066404	0,0027238	0,0032497
	2-D	0,03922	0,00267	0,00196	-0,000771	1,3147735	0,999945	0,0018005	-0,0005199	0,0013224
	3-D	0,02974	0,0020461	0,00148	-0,0008372	1,9546361	0,999968	0,0013797	-0,0005646	0,0010029
FLO	1-D	0,15292	0,012036	0,00764	-0,0021139	0,7776664	0,998901	0,0081163	-0,0014255	0,005156

6.1.4 STP6-120/36 veri setiyle elde edilen sonuçlar

Bu alt bölüm, önerilen INFO ve QIO algoritmalarının STP6-120/36 modül verileri kullanılarak 1-D, 2-D ve 3-D modellerine ait analiz sonuçları sırasıyla Tablo 6.35, Tablo 6.36 ve Tablo 6.37’de detaylı bir şekilde sunulmuştur. Tahmin sonuçları literatürde son zamanlarda raporlanan uyarlanabilir yönlendirmeli diferansiyel evrim algoritması (adaptive guided differential evolution algorithm, AGDE) (Mohamed ve Mohamed, 2019), denizsalyangozu sürüsü algoritması (tunicate swarm algorithm, TSA) (Sharma vd., 2021), fiçıkuyruk kuşu optimizasyon algoritması (coot bird optimization algorithm, COOT) (Rushdi ve Al-Naima, 2022), başarı geçmişine dayalı doğrusal popülasyon azaltmalı uyarlanabilir diferansiyel evrim (success-history based adaptive differential evolution with linear population size reduction, L-SHADE) (Tanabe ve Fukunaga, 2014), GWO, MLBSA (Yu vd., 2018), öğretme-öğrenme tabanlı optimizasyon (teaching-learning-based optimization, TLBO) (Li vd., 2019), WDO (Mathew vd., 2017), WOA (Oliva vd., 2017) meta-sezgisel algoritmalar ile karşılaştırılmıştır. Önerilen algoritmalar ile elde edilen en düşük RMSE değerleri, karşılaştırılan meta-sezgisel yöntemleri geride bırakarak parametre tahmininde yüksek doğruluk tahminleme yeteneğini ortaya koymuştur. Şekil 6.54 (a), (b), Şekil 6.55 (a), (b), Şekil 6.56 (a), (b)’de, Şekil 6.57 (a), (b), Şekil 6.58 (a), (b) ve Şekil 6.59 (a), (b) sunulan 1-D, 2-D ve 3-D modelleri için elde edilen I-V ve P-V karakteristik eğrileri, ölçülen ve tahmin edilen parametrelerin gerçek değerleriyle uyum içinde olduğunu göstermektedir. Ayrıca, belirlenen MPP üzerinde elde edilen sonuçlarda oldukça tutarlıdır. 1-D, 2-D ve 3-D modelleri için yakınsama eğrileri (INFO ve QIO) sırasıyla Şekil 6.60, Şekil 6.61, Şekil 6.62, Şekil 6.63, Şekil 6.64, Şekil 6.65 sırasıyla sunulmuştur. En düşük RMSE değerinin erken aşamada elde edilmesi, önerilen algoritmaların yüksek doğrulukta parametre tahmin yeteneğini desteklemektedir.

Tablo 6.35. INFO ve QIO’dan elde edilen sonuçların STP6-120/36 (1-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması


Algoritma	I_{ph} (A)	I_{o1} (μ A)	R_s (Ω)	R_{sh} (Ω)	a_1	RMSE
INFO	7,477453	2,196074	0,1625534	488,6655	48,42755	$3,8553 \times 10^{-2}$
QIO	7,477073	2,194467	0,1625605	494,2543	48,42503	$1,2355 \times 10^{-1}$
GWO	6,428618	17,34990	0,1099655	634,89393	12,33488	$2,169633 \times 10^{-1}$
WDO	3,030178	7,191235	0,1283243	630,04266	29,45527	$7,135944 \times 10^{-1}$
TLBO	6,135339	36,9900	0,0000000	268,65396	6,713416	1,7151355

Tablo 6.36. INFO ve QIO'dan elde edilen sonuçların STP6-120/36 (2-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması


Algoritma	I_{ph} (A)	I_{o1} (μ A)	R_s (Ω)	R_{sh} (Ω)	a_1	I_{o2} (μ A)	a_2	RMSE
INFO	7,474551	1,129453	0,2166218	488,3419	47,09679	$6,3582 \times 10^{-13}$	17,19018	$3,8356 \times 10^{-2}$
QIO	7,478344	1,779104	0,1626575	469,7598	48,47465	0,4007166	48,1101	$5,2804 \times 10^{-2}$
COOT	7,6544	0,9984	0,0020	576,2383	99,8109	0,9984	34,4618	$1,00589 \times 10^{-1}$
TSA	7,9677	0,7773	0,0410	23,7543	59,5221	0,7773	69,2741	$5,86471 \times 10^{-2}$

Tablo 6.37. INFO ve QIO'dan elde edilen sonuçların STP6-120/36 (3-D) için literatürdeki diğer optimizasyon teknikleriyle karşılaştırılması


Algoritma	I_{ph} (A)	I_{o1} (μ A)	R_s (Ω)	R_{sh} (Ω)	α_1	I_{o2} (μ A)	I_{o3} (μ A)	a_2	a_3	RMSE
INFO	7,46307	0,725867	0,27049	1498,9	46,481	$2,6 \times 10^{-8}$	$1,4 \times 10^{-19}$	50	12,500	$3,7741 \times 10^{-2}$
QIO	7,47751	0,93068	0,16256	489,91	48,192	0,369236	0,911652	48,00	48,961	$3,8734 \times 10^{-2}$
WOA	7,459	6,553	0,00504	20,90	2,442	11,586	0,93	48,39	1,273	$4,2964 \times 10^{-2}$
AGDE	7,50399	5,432	0,00249	1434,0	5,037	25,63	47,85	8,955	1,576	$6,1411 \times 10^{-2}$
MLBSA	7,49644	16,16	0,00353	583,91	17,520	22,51	13,34	21,00	1,424	$1,9733 \times 10^{-1}$
L-SHADE	6,90477	49,93	0,00006	997,41	22,434	19,17	24,99	1,463	39,588	$4,3310 \times 10^{-1}$




Şekil 6.54. INFO algoritmasıyla 1-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)



Şekil 6.55. QIO algoritmasıyla 1-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




(a)




(b)

Şekil 6.56. INFO algoritmasıyla 2-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




(a)




(b)

Şekil 6.57. QIO algoritmasıyla 2-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




(a)




(b)


Şekil 6.58. INFO algoritmasıyla 3-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




Şekil 6.59. QIO algoritmasıyla 3-D (STP) için ölçülen ve tahmin edilen veriler: I-V eğrisi (a) ve P-V eğrisi (b)




Şekil 6.60. STP veri seti için INFO algoritmasına ait 1-D modeli yakınsama eğrisi




Şekil 6.61. STP veri seti için QIO algoritmasına ait 1-D modeli yakınsama eğrisi




Şekil 6.62. STP veri seti için INFO algoritmasına ait 2-D modeli yakınsama eğrisi



Şekil 6.63. STP veri seti için QIO algoritmasına ait 2-D modeli yakınsama eğrisi



Şekil 6.64. STP veri seti için INFO algoritmasına ait 3-D modeli yakınsama eğrisi



Şekil 6.65. STP veri seti için QIO algoritmasına ait 3-D modeli yakınsama eğrisi

1-D, 2-D ve 3-D modelleri için analizi yapılan IAE ve RE amaç fonksiyonları ölçülen her akım/voltaj noktası için önerilen algoritmalar aracılığıyla tahmin edilen akım ve güç değerleri Tablo 6.38, Tablo 6.39, Tablo 6.40, Tablo 6.41, Tablo 6.42 ve 6.43'te ayrıntılı bir şekilde sunulmuştur. Tablo 6.38'de 1-D modeli için önerilen INFO ve QIO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $4,753658 \times 10^{-1}$, 1,94839 ve Tablo 6.39'te ise toplam IAE (güç) değerleri sırasıyla 7,3963288, 32,949532 olarak hesaplanmıştır.

Tablo 6.40'ta 2-D modeli için önerilen algoritmalar ile elde edilen toplam IAE (akım) değeri sırasıyla $4,673628 \times 10^{-1}$, $7,3976 \times 10^{-1}$ ve Tablo 6.41'de ise toplam IAE (güç) değerleri sırasıyla 7,2009859, 11,912098 olarak hesaplanmıştır. Tablo 6.42'de 3-D modeli için önerilen INFO ve QIO algoritmalarıyla elde edilen toplam IAE (akım) değeri sırasıyla $4,924025 \times 10^{-1}$, $4,69022 \times 10^{-1}$ ve Tablo 6.43'te ise toplam IAE (güç) değerleri sırasıyla 7,4434802, 7,2376836 olarak hesaplanmıştır. Her veri satırına karşılık hesaplanan IAE ve RE değerleri ise modelin doğruluğunu destekleyici nitelikte sonuçlar sunmaktadır.

Tablo 6.38. STP veri seti için 1-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO		
		It	IAE	RE	It	IAE	RE
1	7,48	7,475	0,005	0,0006684	7,4754	0,0046	0,000615
2	7,45	7,4496	0,0004	5,369E-05	7,45	0	0
3	7,42	7,4435	0,0235	-0,0031671	7,4442	0,0242	-0,0032615
4	7,44	7,4356	0,0044	0,0005914	7,4369	0,0031	0,0004167
5	7,41	7,4168	0,0068	-0,0009177	7,4194	0,0094	-0,0012686
6	7,38	7,3927	0,0127	-0,0017209	7,3972	0,0172	-0,0023306
7	7,37	7,3606	0,0094	0,0012754	7,3677	0,0023	0,0003121
8	7,34	7,3295	0,0105	0,0014305	7,339	0,001	0,0001362
9	7,29	7,2831	0,0069	0,0009465	7,2963	0,0063	-0,0008642
10	7,23	7,2181	0,0119	0,0016459	7,2365	0,0065	-0,000899
11	7,1	7,0911	0,0089	0,0012535	7,1193	0,0193	-0,0027183
12	6,97	6,9638	0,0062	0,0008895	7,0017	0,0317	-0,0045481
13	6,83	6,8227	0,0073	0,0010688	6,8709	0,0409	-0,0059883
14	6,58	6,5795	0,0005	7,599E-05	6,6448	0,0648	-0,009848
15	6,36	6,363	0,003	-0,0004717	6,4429	0,0829	-0,0130346
16	6	6,055	0,055	-0,0091667	6,1544	0,1544	-0,0257333
17	5,75	5,7965	0,0465	-0,008087	5,9113	0,1613	-0,0280522
18	5,27	5,2962	0,0262	-0,0049715	5,4389	0,1689	-0,0320493
19	5,27	5,1051	0,1649	0,0312903	5,2577	0,0123	0,002334
20	4,79	4,8097	0,0197	-0,0041127	4,9769	0,1869	-0,0390188
21	4,56	4,5704	0,0104	-0,0022807	4,749	0,189	-0,0414474
22	4,29	4,298	0,008	-0,0018648	4,4889	0,1989	-0,0463636
23	3,83	3,8558	0,0258	-0,0067363	4,0654	0,2354	-0,0614621
24	0	-0,0014658	0,0014658	-	0,32709	0,32709	-
		0,4753658			1,94839		

Tablo 6.39. STP veri seti için 1-D modeline ait ölçülen ve tahmin edilen güç verileri

S. NO	V	Pö	INFO		QIO	
			Pt	IAE	Pt	IAE
1	0	0	0	0,00E+00	0	0
2	9,06	67,497	67,49363	3,37E-03	67,49711	0,00011
3	9,74	72,2708	72,49934	2,29E-01	72,50659	0,23579
4	10,32	76,7808	76,73583	4,50E-02	76,74893	0,03187
5	11,17	82,7697	82,84537	7,57E-02	82,87509	0,10539
6	11,81	87,1578	87,30734	1,50E-01	87,36085	0,20305
7	12,36	91,0932	90,97723	1,16E-01	91,06458	0,02862
8	12,74	93,5116	93,37735	1,34E-01	93,49899	0,01261
9	13,16	95,9364	95,84547	9,09E-02	96,01965	0,08325
10	13,59	98,2557	98,0941	1,62E-01	98,34369	0,08799
11	14,17	100,607	100,4809	1,26E-01	100,8807	0,2737
12	14,58	101,6226	101,5327	8,99E-02	102,0844	0,4618
13	14,93	101,9719	101,8629	1,09E-01	102,5826	0,6107
14	15,39	101,2662	101,2579	8,30E-03	102,2636	0,9974
15	15,71	99,9156	99,96327	4,77E-02	101,2182	1,3026
16	16,08	96,48	97,36511	8,85E-01	98,96267	2,48267
17	16,34	93,955	94,71448	7,59E-01	96,59093	2,63593
18	16,76	88,3252	88,76495	4,40E-01	91,15563	2,83043
19	16,9	89,063	86,27595	2,79E+00	88,85464	0,20836
20	17,1	81,909	82,2456	3,37E-01	85,10547	3,19647
21	17,25	78,66	78,83933	1,79E-01	81,91951	3,25951
22	17,41	74,6889	74,82876	1,40E-01	78,15168	3,46278
23	17,65	67,5995	68,05468	4,55E-01	71,75452	4,15502
24	19,21	0	-0,0281588	2,82E-02	6,283482	6,283482
			7,3963288		32,949532	

Tablo 6.40. STP veri seti için 2-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO		
		It	IAE	RE	It	IAE	RE
1	7,48	7,4712	0,0088	0,0011765	7,4693	0,0107	0,0014305
2	7,45	7,4466	0,0034	0,0004564	7,4504	0,0004	-5,369E-05
3	7,42	7,4408	0,0208	-0,0028032	7,4445	0,0245	-0,0033019
4	7,44	7,4334	0,0066	0,0008871	7,4367	0,0033	0,0004435
5	7,41	7,4154	0,0054	-0,0007287	7,4176	0,0076	-0,0010256
6	7,38	7,3921	0,0121	-0,0016396	7,3929	0,0129	-0,001748
7	7,37	7,3608	0,0092	0,0012483	7,3599	0,0101	0,0013704
8	7,34	7,3301	0,0099	0,0013488	7,3278	0,0122	0,0016621
9	7,29	7,2842	0,0058	0,0007956	7,28	0,01	0,0013717
10	7,23	7,2196	0,0104	0,0014385	7,213	0,017	0,0023513
11	7,1	7,0927	0,0073	0,0010282	7,0824	0,0176	0,0024789
12	6,97	6,9653	0,0047	0,0006743	6,9517	0,0183	0,0026255
13	6,83	6,8238	0,0062	0,0009078	6,8071	0,0229	0,0033529
14	6,58	6,5802	0,0002	-3,04E-05	6,5583	0,0217	0,0032979
15	6,36	6,3636	0,0036	-0,000566	6,3374	0,0226	0,0035535
16	6	6,0556	0,0556	-0,0092667	6,0236	0,0236	-0,0039333
17	5,75	5,7971	0,0471	-0,0081913	5,7605	0,0105	-0,0018261
18	5,27	5,2969	0,0269	-0,0051044	5,2524	0,0176	0,0033397
19	5,27	5,1056	0,1644	0,0311954	5,0585	0,2115	0,0401328
20	4,79	4,8097	0,0197	-0,0041127	4,759	0,031	0,0064718
21	4,56	4,5699	0,0099	-0,0021711	4,5165	0,0435	0,0095395
22	4,29	4,2966	0,0066	-0,0015385	4,2407	0,0493	0,0114918
23	3,83	3,8527	0,0227	-0,0059269	3,793	0,037	0,0096606
24	0	-6,277E-05	6,277E-05	-	-0,10396	0,10396	-
		0,4673628			0,73976		

Tablo 6.41. STP veri seti için 2-D modeline ait ölçülen ve tahmin edilen güç verileri

S. NO	V	Pö	INFO		QIO	
			Pt	IAE	Pt	IAE
1	0	0	0	0	0	0
2	9,06	67,497	67,4664	0,0306	67,50077	0,00377
3	9,74	72,2708	72,47357	0,20277	72,50923	0,23843
4	10,32	76,7808	76,71286	0,06794	76,74697	0,03383
5	11,17	82,7697	82,82982	0,06012	82,85467	0,08497
6	11,81	87,1578	87,30028	0,14248	87,31007	0,15227
7	12,36	91,0932	90,97911	0,11409	90,96845	0,12475
8	12,74	93,5116	93,38579	0,12581	93,35609	0,15551
9	13,16	95,9364	95,86071	0,07569	95,80464	0,13176
10	13,59	98,2557	98,11475	0,14095	98,02521	0,23049
11	14,17	100,607	100,5042	0,1028	100,3574	0,2496
12	14,58	101,6226	101,5539	0,0687	101,3563	0,2663
13	14,93	101,9719	101,88	0,0919	101,6299	0,342
14	15,39	101,2662	101,269	0,0028	100,9327	0,3335
15	15,71	99,9156	99,97169	0,05609	99,56088	0,35472
16	16,08	96,48	97,37422	0,89422	96,85915	0,37915
17	16,34	93,955	94,72526	0,77026	94,12701	0,17201
18	16,76	88,3252	88,77579	0,45059	88,03046	0,29474
19	16,9	89,063	86,28407	2,77893	85,48824	3,57476
20	17,1	81,909	82,24613	0,33713	81,37829	0,53071
21	17,25	78,66	78,82994	0,16994	77,90983	0,75017
22	17,41	74,6889	74,80451	0,11561	73,83018	0,85872
23	17,65	67,5995	67,99986	0,40036	66,9467	0,6528
24	19,21	0	-0,0012059	0,0012059	-1,997138	1,997138
			7,2009859		11,912098	

Tablo 6.42. STP veri seti için 3-D modeline ait ölçülen ve tahmin edilen akım verileri

S.NO	İö	INFO			QIO		
		It	IAE	RE	It	IAE	RE
1	7,48	7,4617	0,0183	0,0024465	7,4718	0,0082	0,0010963
2	7,45	7,4496	0,0004	5,369E-05	7,4496	0,0004	5,369E-05
3	7,42	7,4447	0,0247	-0,0033288	7,4436	0,0236	-0,0031806
4	7,44	7,4379	0,0021	0,0002823	7,4358	0,0042	0,0005645
5	7,41	7,4206	0,0106	-0,0014305	7,417	0,007	-0,0009447
6	7,38	7,3973	0,0173	-0,0023442	7,3928	0,0128	-0,0017344
7	7,37	7,3656	0,0044	0,000597	7,3606	0,0094	0,0012754
8	7,34	7,3343	0,0057	0,0007766	7,3293	0,0107	0,0014578
9	7,29	7,2871	0,0029	0,0003978	7,2826	0,0074	0,0010151
10	7,23	7,2206	0,0094	0,0013001	7,2173	0,0127	0,0017566
11	7,1	7,0902	0,0098	0,0013803	7,0897	0,0103	0,0014507
12	6,97	6,9601	0,0099	0,0014204	6,962	0,008	0,0011478
13	6,83	6,8169	0,0131	0,001918	6,8204	0,0096	0,0014056
14	6,58	6,5727	0,0073	0,0011094	6,5766	0,0034	0,0005167
15	6,36	6,3577	0,0023	0,0003616	6,3598	0,0002	3,145E-05
16	6	6,0537	0,0537	-0,00895	6,0514	0,0514	-0,0085667
17	5,75	5,7989	0,0489	-0,0085043	5,7925	0,0425	-0,0073913
18	5,27	5,3035	0,0335	-0,0063567	5,2919	0,0219	-0,0041556
19	5,27	5,1126	0,1574	0,0298672	5,1006	0,1694	0,0321442
20	4,79	4,8157	0,0257	-0,0053653	4,8049	0,0149	-0,0031106
21	4,56	4,5734	0,0134	-0,0029386	4,5655	0,0055	-0,0012061
22	4,29	4,2963	0,0063	-0,0014685	4,2929	0,0029	-0,000676
23	3,83	3,844	0,014	-0,0036554	3,8503	0,0203	-0,0053003
24	0	-0,0013025	0,0013025	-	-0,012322	0,012322	-
		0,4924025			0,469022		


Tablo 6.43. STP veri seti için 3-D modeline ait ölçülen ve tahmin edilen güç verileri

S.NO	V	Pö	INFO		QIO	
			Pt	IAE	Pt	IAE
1	0	0	0	0	0	0
2	9,06	67,497	67,49353	0,00347	67,49335	0,00365
3	9,74	72,2708	72,51115	0,24035	72,50046	0,22966
4	10,32	76,7808	76,75944	0,02136	76,7379	0,0429
5	11,17	82,7697	82,88784	0,11814	82,84791	0,07821
6	11,81	87,1578	87,36264	0,20484	87,30901	0,15121
7	12,36	91,0932	91,03896	0,05424	90,97687	0,11633
8	12,74	93,5116	93,43848	0,07312	93,3747	0,1369
9	13,16	95,9364	95,89839	0,03801	95,83927	0,09713
10	13,59	98,2557	98,12766	0,12804	98,08303	0,17267
11	14,17	100,607	100,4686	0,1384	100,4611	0,1459
12	14,58	101,6226	101,4789	0,1437	101,5055	0,1171
13	14,93	101,9719	101,7766	0,1953	101,8287	0,1432
14	15,39	101,2662	101,154	0,1122	101,2138	0,0524
15	15,71	99,9156	99,87901	0,03659	99,91219	0,00341
16	16,08	96,48	97,34322	0,86322	97,30604	0,82604
17	16,34	93,955	94,75458	0,79958	94,64996	0,69496
18	16,76	88,3252	88,88621	0,56101	88,69164	0,36644
19	16,9	89,063	86,40262	2,66038	86,19964	2,86336
20	17,1	81,909	82,34784	0,43884	82,16464	0,25564
21	17,25	78,66	78,89185	0,23185	78,75465	0,09465
22	17,41	74,6889	74,79808	0,10918	74,73969	0,05079
23	17,65	67,5995	67,84614	0,24664	67,95792	0,35842
24	19,21	0	-0,0250202	0,0250202	-0,2367136	0,2367136
			7,4434802		7,2376836	


Tablo 6.44'te sunulan istatistiksel sonuçlar, STP6-120/36 veri seti kullanılarak 1-D, 2-D ve 3-D modelleri için önerilen INFO ve QIO algoritmalarının RMSE (minimum, maksimum, ortalama standart sapma ve varyans) istatistiksel performanslarını kapsamlı bir şekilde ortaya koymaktadır. Bu performans ölçütlerinin dağılım grafiği Şekil 6.66 ve Şekil 6.67'de sunulmuştur. Bu sonuçlar, önerilen algoritmaları genel olarak daha güvenilir ve kararlı tahminleme sağladığını güçlü bir şekilde desteklemektedir.

Tablo 6.44. 1-D, 2-D ve 3-D modelleri için önerilen algoritmalarla elde edilen RMSE değerlerine ait istatistiksel sonuçlar (STP)

Önerilen algoritmalar	İstatistiksel skorlar (RMSE)	1-D	2-D	3-D
INFO	Minimum	$3,85531 \times 10^{-2}$	$3,8356 \times 10^{-2}$	$3,7741 \times 10^{-2}$
	Maksimum	$3,85531 \times 10^{-2}$	$3,8649 \times 10^{-2}$	$3,8605 \times 10^{-2}$
	Ortalama	$3,85531 \times 10^{-2}$	$3,8562 \times 10^{-2}$	$3,8532 \times 10^{-2}$
	Standart sapma	$3,6607 \times 10^{-15}$	$4,8289 \times 10^{-5}$	$1,4997 \times 10^{-4}$
	Varyans	$1,3401 \times 10^{-29}$	$2,3318 \times 10^{-9}$	$2,249 \times 10^{-8}$
QIO	Minimum	$3,85532 \times 10^{-2}$	$3,85537 \times 10^{-2}$	$3,85537 \times 10^{-2}$
	Maksimum	$3,85764 \times 10^{-2}$	$3,87038 \times 10^{-2}$	$3,89438 \times 10^{-2}$
	Ortalama	$3,85567 \times 10^{-2}$	$3,85713 \times 10^{-2}$	$3,85819 \times 10^{-2}$
	Standart sapma	$5,1748 \times 10^{-6}$	$3,516 \times 10^{-5}$	$7,1519 \times 10^{-5}$
	Varyans	$2,6779 \times 10^{-11}$	$1,2363 \times 10^{-9}$	$5,115 \times 10^{-9}$



Şekil 6.66. INFO algoritması ile tüm çalışmaların (30) istatistiksel RMSE dağılım grafikleri (STP) : (a) 1-D, (b) 2-D, (c) 3-D



Şekil 6.67. QIO algoritması ile tüm çalışmaların (30) istatistiksel RMSE dağılım grafikleri (STP) : (a) 1-D, (b) 2-D, (c) 3-D

1-D, 2-D ve 3-D modellerinin performansını kapsamlı bir şekilde değerlendirmek amacıyla, Photowatt-PWP201 veri seti kullanılarak INFO ve QIO algoritmaları ile gerçekleştirilen analizlerde IAE, RMSE, MAE, MBE, T-istatistiği, R^2 , NRMSE, NMBE ve NMAE gibi temel istatistiksel hata metrikleri Tablo 6.45'te sunulmuştur. Modellerin genel doğruluğu incelendiğinde, tüm modellerde R^2 değerlerinin oldukça yüksek olduğu gözlemlenmekte olup, düşük MAE, MBE, NRMSE, NMBE ve NMAE değerleri, önerilen algoritmaların yüksek doğrulukla PV parametre tahmini yapabildiğini bir başka kanıttır.

Tablo 6.45. STP120-36 veri setinde 1-D, 2-D ve 3-D için istatistiksel hata oranları

	Model	IAE	RMSE	MAE	MBE	t- istatistik	R^2	NRMSE	NMBE	NMAE
INFO	1-D	0,4753658	0,038553	0,0198069	6,908E-06	0,0008594	0,9994923	0,0062769	1,125E-06	0,0032248
	2-D	0,4673628	0,038356	0,0194734	0,0002568	0,0321074	0,9994975	0,0062448	4,181E-05	0,0031705
	3-D	0,4924025	0,037741	0,0205168	-0,0001582	0,0201067	0,9995134	0,0061447	-2,576E-05	0,0033404
QIO	1-D	1,94839	0,12355	0,0811829	-0,0792413	4,0090907	0,9947845	0,0201153	-0,0129014	0,0132175
	2-D	0,73976	0,052804	0,0308233	0,0241983	2,4726998	0,9990475	0,0085971	0,0039398	0,0050184
	3-D	0,469022	0,038734	0,0195426	0,0026426	0,3279543	0,9994876	0,0063063	0,0004302	0,0031818

6.2 Tartışma

Bu tez çalışmasında, PV parametre tahmini problemine yönelik önerilen meta-sezgisel optimizasyon algoritmalarının performansını değerlendirmek amacıyla, dört farklı standart PV panel veri setleri (RTC, PWP-201, STM6 ve STP6) kullanılarak 1-D, 2-D ve 3-D elektriksel devre modelleri üzerinde kapsamlı bir karşılaştırma analizi gerçekleştirilmiştir. Önerilen algoritmalar (INFO, QIO ve FLO) elde edilen sonuçlar, tüm RMSE indekslerinde karşılaştırılan diğer meta-sezgisel algoritmaları geride bırakarak, çok yönlü bir optimizasyon doğruluğu ve hassasiyeti sergilemişlerdir.

INFO algoritmasıyla, tablo 6.12'de RTC panel verileri kullanılarak yapılan analizlerde 3-D modeli 1-D ve 2-D modellerini geride bırakarak en düşük RMSE ($7,366 \times 10^{-4}$) değeri ile öne çıkmaktadır. Toplam IAE (akım) değeri üç model için genel olarak düşük seviyede olsa da yine 3-D modelinde ($1,68677 \times 10^{-2}$) modelde en düşük değere ulaşmıştır. Elde edilen bu sonuçlar önerilen INFO algoritmasıyla 3-D modelin RTC panel verileri için en iyi performansı sağladığını göstermektedir. Tablo 6.23'te PWP-201 panel verileri kullanılarak yapılan analizde, 2-D modeli en düşük RMSE ($1,3251 \times 10^{-3}$) ve toplam IAE (akım: $2,42349 \times 10^{-2}$) değeri ile en iyi performansı sağlamıştır. Tablo 6.34'te STM6 panel verileri kullanılarak yapılan analizde, yine 2-D modeli en düşük RMSE ($1,6895 \times 10^{-3}$) ve toplam IAE (akım: $2,11205 \times 10^{-2}$) değeri ile en

iyi performansı sağlamıştır. Tablo 6.45'te STP6 panel verileri kullanılarak yapılan analizde ise, en düşük RMSE ($3,7741 \times 10^{-2}$) değeri 3-D modelinde elde edilmiştir.

QIO algoritmasıyla, tablo 6.12'de RTC panel verileri kullanılarak yapılan analizde 3-D modeli en düşük RMSE ($4,0449 \times 10^{-3}$) ve toplam IAE (akım: $1,68677 \times 10^{-2}$) değeri ile en iyi performansı sağlamıştır. Tablo 6.23'te PWP-201 panel verileri kullanılarak yapılan analizde, 3-D modeli en düşük RMSE ($2,083 \times 10^{-3}$) ve toplam IAE (akım: $4,38874 \times 10^{-2}$) değeri ile diğer modellerden daha iyi performans göstermiştir. Tablo 6.34'te STM6 panel verileri kullanılarak yapılan analizde, 3-D modeli en düşük RMSE ($2,0461 \times 10^{-3}$) ve toplam IAE (akım: $2,9744 \times 10^{-2}$) değerleriyle 1-D ve 2-D modellerini geride bırakmıştır. Tablo 6.45'te STP6 panel verileri kullanılarak yapılan analizde ise, yine 3-D modeli en düşük RMSE ($3,8734 \times 10^{-2}$) ve toplam IAE (akım: $4,69022 \times 10^{-1}$) değerleriyle en iyi performansı sağlamıştır.

FLO algoritmasıyla tablo 6.12'de RTC panel verileri kullanılarak yapılan analizde 1-D modeli en düşük RMSE ($3,075 \times 10^{-3}$) ve toplam IAE (akım: $6,18608 \times 10^{-2}$) değeri 1-D ve 2-D modellerini geride bırakmayı başarmıştır. Tablo 6.23 ve tablo 6.34'te 1-D modeli üzerinde PWP-201 ve STM6 panel verileri kullanılarak yapılan değerlendirmede sırasıyla $9,7545 \times 10^{-3}$ ve $1,2036 \times 10^{-2}$ RMSE değeri elde edilmiştir. Ek olarak, önerilen algoritmalar kullanılarak dört farklı panel verisi ile gerçekleştirilen analizlerde elde edilen IAE, MAE, MBE, R^2 , t-istatistik, NRMSE, NMBE ve NMAE amaç fonksiyonlarına ilişkin sonuçlar, tablo 6.12, 6.23, 6.34 ve 6.45'te detaylı şekilde sunulmuştur. İlaveten, ölçülen ve tahmin edilen I-V ve P-V karakteristik eğrileri arasındaki güçlü uyum, önerilen algoritmaların rekabetçi bir performans sunduğunu desteklemektedir.

7. SONUÇ VE ÖNERİLER

7.1 Sonuç

Bu tez çalışmasında, PV sistemlerin performansını iyileştirmek amacıyla doğru ve hassas parametre tahmini için yenilikçi bir yaklaşımlar sunulmuştur. INFO, QIO ve FLO algoritmalarının N-R sayısal yöntemiyle çıktı çözümlerinin doğruluğunu artırmak için entegre edilmiştir. Önerilen algoritmaların etkinliği, 1-D, 2-D ve 3-D modelleri üzerinde dört farklı panel verileriyle (RTC, PWP-201, STM6 ve STP6) kapsamlı ve yenilikçi bir yaklaşım sunarak detaylı analizler yapılmıştır. Bu panel verileriyle yapılan analizlerde her model için elde edilen sonuçlar güncel algoritmalar ile karşılaştırmalı olarak değerlendirilmiştir. INFO algoritmasıyla yapılan analiz sonuçları, R.T.C France (1-D: $7,7298 \times 10^{-4}$, 2-D: $7,4207 \times 10^{-4}$, 3-D: $7,3655 \times 10^{-4}$), photowatt-PWP201 (1-D: $2,0528 \times 10^{-3}$, 2-D: $1,3251 \times 10^{-3}$, 3-D: $1,459 \times 10^{-3}$), STM6-40/36 (1-D: $1,72190 \times 10^{-3}$, 2-D: $1,6895 \times 10^{-3}$, 3-D: $1,7032 \times 10^{-3}$) ve STP6-120/36 (1-D: $3,8553 \times 10^{-2}$, 2-D: $3,8356 \times 10^{-2}$, 3-D: $3,7741 \times 10^{-2}$) RMSE değeri elde edilmiştir.

QIO algoritmasıyla yapılan analiz sonuçları, R.T.C France (1-D: $9,2865 \times 10^{-3}$, 2-D: $4,0894 \times 10^{-3}$, 3-D: $4,0449 \times 10^{-3}$), photowatt-PWP201 (1-D: $5,7876 \times 10^{-3}$, 2-D: $9,2769 \times 10^{-3}$, 3-D: $2,083 \times 10^{-3}$), STM6-40/36 (1-D: $9,8474 \times 10^{-3}$, 2-D: $2,67 \times 10^{-3}$, 3-D: $2,0461 \times 10^{-3}$) ve STP6-120/36 (1-D: $1,2355 \times 10^{-1}$, 2-D: $5,2804 \times 10^{-2}$, 3-D: $3,8734 \times 10^{-2}$) RMSE değeri elde edilmiştir. FLO algoritmasıyla yapılan analiz sonuçları, R.T.C France (1-D: $3,075 \times 10^{-3}$, 2-D: $1,1538 \times 10^{-2}$, 3-D: $7,3024 \times 10^{-3}$), photowatt-PWP201 (1-D: $9,7545 \times 10^{-3}$), STM6-40/36 (1-D: $1,2036 \times 10^{-2}$) RMSE değeri elde edilmiştir.

Bu veri kümeleri üzerinde elde edilen RMSE değerleri dikkate alındığında, önerilen algoritmaların, karşılaştırılan diğer algoritmalarla kıyasla daha düşük hata oranları ile üstün bir doğruluk sağlamış ve rekabetçi bir performans sergilemiştir. Elde edilen sonuçlar, algoritmanın parametre tahmini süreçlerinde yüksek güvenilirlik sunduğunu ve farklı PV panel verileri üzerinde genel geçerliliğe sahip bir yaklaşım sunduğunu göstermektedir. Bu bağlamda, algoritmanın optimizasyon doğruluğu, kararlılığı ve hesaplama verimliliği açısından mevcut yöntemlere kıyasla önemli avantajlar sağladığı görülmektedir. Özellikle, 3-D modeli gibi daha karmaşık ve hesaplama açısından yoğun modeller üzerinde de yüksek doğruluk sağlaması, önerilen

algoritmaların geniş ölçekli ve gerçek dünya uygulamalarında etkin bir şekilde kullanılabilirliğini ortaya koymaktadır.

7.2 Öneriler

Gelecekteki çalışmalar, önerilen algoritmaların performansını artırmaya ve mevcut sınırlamaları aşmaya yönelik çeşitli iyileştirme stratejilerine odaklanılacaktır. Öncelikle, algoritmaların popülasyon boyutu, iterasyon sayısı ve diğer dinamik parametrelere olan duyarlılığı daha ayrıntılı incelenip ve adaptif mekanizmalar geliştirilecektir. Özellikle, keşif (exploration) ve sömürü (exploitation) arasındaki dengeyi optimize eden uyarlanabilir parametre ayarlama teknikleri üzerine yoğunlaşıp, algoritmaların daha kararlı ve verimli çalışmasını sağlanacaktır.

Bunun yanı sıra, yerel ve küresel arama süreçlerinin etkinliğini artırmak amacıyla hibrit optimizasyon yaklaşımlarının araştırılması büyük önem taşımaktadır. Farklı meta-sezgisel algoritmaların birleştirilmesi veya makine öğrenmesi tabanlı optimizasyon yöntemleri ile desteklenmesi, algoritmaların yerel minimumlara sıkışma riskini azaltarak daha yüksek doğrulukta çözümler üretmesine katkı sağlayabilir. Ayrıca, hesaplama maliyetini düşürmeye yönelik hızlandırma teknikleri, örneğin paralel işleme, GPU tabanlı hesaplama veya algoritma hafifletme yöntemleri, büyük ölçekli problemlerde daha verimli çözümler sunabilir.

Son olarak, algoritmaların geniş çaplı test senaryoları ile değerlendirilmesi ve gerçek dünya uygulamalarına entegrasyonunun sağlanması gerekmektedir. Farklı çevresel koşullara sahip PV sistemleri üzerinde algoritmaların uygulanarak karşılaştırmalı analizler yapılması, pratik kullanımları açısından önemli veriler sağlayacaktır. Bu doğrultuda, çoklu hedefli optimizasyon yaklaşımlarının incelenmesi ve farklı panel tipleri ile genişletilmiş veri setleri üzerinde test edilmesi, algoritmaların genel geçerliliğini artırmak adına önemli bir araştırma alanı olarak öne çıkmaktadır.

KAYNAKLAR

- Abbassi, A., Mehrez, R. B., Touaiti, B., Abualigah, L., ve Touti, E. (2022). Parameterization of photovoltaic solar cell double-diode model based on improved arithmetic optimization algorithm. *Optik*, 253, 168600.
- Abbassi, R., Abbassi, A., Jemli, M., ve Chebbi, S. (2018). Identification of unknown parameters of solar cell models: A comprehensive overview of available approaches. *Renewable and Sustainable Energy Reviews*, 90, 453-474.
- Abd El-Mageed, A. A., Abohany, A. A., Saad, H. M., ve Sallam, K. M. (2023). Parameter extraction of solar photovoltaic models using queuing search optimization and differential evolution. *Applied Soft Computing*, 134, 110032.
- Abdel-Basset, M., Mohamed, R., Chakraborty, R. K., Ryan, M. J., ve El-Fergany, A. (2021). An improved artificial jellyfish search optimizer for parameter identification of photovoltaic models. *Energies*, 14(7), 1867.
- Abualigah, L., Oliva, D., Mzili, T., Sabo, A., ve Shehadeh, H. A. (2024). Frilled Lizard Optimization to optimize parameters Proportional Integral Derivative of DC Motor. *Vokasi Unesa Bulletin of Engineering, Technology and Applied Science*, 14-21.
- Ahmadianfar, I., Gong, W., Heidari, A. A., Golilarz, N. A., Samadi-Kouchehsaraee, A., ve Chen, H. (2021). Gradient-based optimization with ranking mechanisms for parameter identification of photovoltaic systems. *Energy Reports*, 7, 3979-3997.
- Ahmadianfar, I., Heidari, A. A., Noshadian, S., Chen, H., ve Gandomi, A. H. (2022). INFO: An efficient optimization algorithm based on weighted mean of vectors. *Expert Systems with Applications*, 195, 116516.
- AlHajri, M., El-Naggar, K., AlRashidi, M., ve Al-Othman, A. (2012). Optimal extraction of solar cell parameters using pattern search. *Renewable Energy*, 44, 238-245.
- Ali, F., Sarwar, A., Bakhsh, F. I., Ahmad, S., Shah, A. A., ve Ahmed, H. (2023). Parameter extraction of photovoltaic models using atomic orbital search algorithm on a decent basis for novel accurate RMSE calculation. *Energy Conversion and Management*, 277, 116613.
- Allam, D., Yousri, D., ve Eteiba, M. (2016). Parameters extraction of the three diode model for the multi-crystalline solar cell/module using Moth-Flame Optimization Algorithm. *Energy Conversion and Management*, 123, 535-548.
- Apergis, N., ve Payne, J. E. (2012). Renewable and non-renewable energy consumption-growth nexus: Evidence from a panel error correction model. *Energy economics*, 34(3), 733-738.

- Asim, N., Sopian, K., Ahmadi, S., Saeedfar, K., Alghoul, M., Saadatian, O., ve Zaidi, S. H. (2012). A review on the role of materials science in solar cells. *Renewable and Sustainable Energy Reviews*, 16(8), 5834-5847.
- Askarzadeh, A., ve Rezazadeh, A. (2012). Parameter identification for solar cell models using harmony search-based algorithms. *Solar Energy*, 86(11), 3241-3249.
- Ayyarao, T. S. (2022). Parameter estimation of solar PV models with quantum-based avian navigation optimizer and Newton–Raphson method. *Journal of Computational Electronics*, 21(6), 1338-1356.
- Azhdari, M., Mahmoodzadeh, A., ve Khishe, M. (2020). Power consumption optimization in underwater wireless sensor networks based on EECRU clustering algorithm for routing. *Iranian Journal of Marine Science and Technology*, 24(95), 1-10.
- Babu, T. S., Ram, J. P., Sangeetha, K., Laudani, A., ve Rajasekar, N. (2016). Parameter extraction of two diode solar PV model using Fireworks algorithm. *Solar Energy*, 140, 265-276.
- Batzelis, E. I., ve Papathanassiou, S. A. (2015). A method for the analytical extraction of the single-diode PV model parameters. *IEEE Transactions on Sustainable Energy*, 7(2), 504-512.
- Bayoumi, A. S. A., El-Sehiemy, R. A., ve Abaza, A. (2022). Effective PV parameter estimation algorithm based on marine predators optimizer considering normal and low radiation operating conditions. *Arabian Journal for Science and Engineering*, 47(3), 3089-3104.
- Beigi, A. M., ve Maroosi, A. (2018). Parameter identification for solar cells and module using a hybrid firefly and pattern search algorithms. *Solar Energy*, 171, 435-446.
- Benkercha, R., Moulahoum, S., ve Taghezouit, B. (2019). Extraction of the PV modules parameters with MPP estimation using the modified flower algorithm. *Renewable Energy*, 143, 1698-1709.
- Bogar, E. (2023). Chaos game optimization-least squares algorithm for photovoltaic parameter estimation. *Arabian Journal for Science and Engineering*, 48(5), 6321-6340.
- Caetano, N. S., Mata, T. M., Martins, A. A., ve Felgueiras, M. C. (2017). New trends in energy production and utilization. *Energy Procedia*, 107, 7-14.
- Chaibi, Y., Allouhi, A., ve Salhi, M. (2020). A simple iterative method to determine the electrical parameters of photovoltaic cell. *Journal of Cleaner Production*, 269, 122363.
- Chauhan, U., Chhabra, H., Jain, P., Dev, A., Chauhan, N., ve Kumar, B. (2024). Chaos inspired invasive weed optimization algorithm for parameter estimation of solar PV models. *IFAC Journal of Systems and Control*, 27, 100239.

- Chen, H., Jiao, S., Heidari, A. A., Wang, M., Chen, X., ve Zhao, X. (2019). An opposition-based sine cosine approach with local search for parameter estimation of photovoltaic models. *Energy Conversion and Management*, 195, 927-942.
- Chen, H., Jiao, S., Wang, M., Heidari, A. A., ve Zhao, X. (2020). Parameters identification of photovoltaic cells and modules using diversification-enriched Harris hawks optimization with chaotic drifts. *Journal of Cleaner Production*, 244, 118778.
- Chen, X., Xu, B., Mei, C., Ding, Y., ve Li, K. (2018). Teaching-learning-based artificial bee colony for solar photovoltaic parameter estimation. *Applied energy*, 212, 1578-1588.
- Chen, X., ve Yu, K. (2019). Hybridizing cuckoo search algorithm with biogeography-based optimization for estimating photovoltaic model parameters. *Solar Energy*, 180, 192-206.
- Chen, Z., Wu, L., Lin, P., Wu, Y., ve Cheng, S. (2016). Parameters identification of photovoltaic models using hybrid adaptive Nelder-Mead simplex algorithm based on eagle strategy. *Applied energy*, 182, 47-57.
- Chenouard, R., ve El-Sehiemy, R. A. (2020). An interval branch and bound global optimization algorithm for parameter estimation of three photovoltaic models. *Energy Conversion and Management*, 205, 112400.
- Choubey, P., Oudhia, A., ve Dewangan, R. (2012). A review: Solar cell current scenario and future trends. *Recent Research in Science and Technology*, 4(8).
- Ciulla, G., Brano, V. L., Di Dio, V., ve Cipriani, G. (2014). A comparison of different one-diode models for the representation of I-V characteristic of a PV cell. *Renewable and Sustainable Energy Reviews*, 32, 684-696.
- Dal, S., ve Sezgin, N. (2024). Estimation of Uncertain Parameters in Single and Double Diode Models of Photovoltaic Panels Using Frilled Lizard Optimization.
- Dal, S., ve Sezgin, N. (2024). Optimal Parameter Extraction of Triple-Diode Photovoltaic Model Using Frilled Lizard Optimization. 2024 Global Energy Conference (GEC),
- Dang, J., Wang, G., Xia, C., Jia, R., ve Li, P. (2022). Research on the parameter identification of PV module based on fuzzy adaptive differential evolution algorithm. *Energy Reports*, 8, 12081-12091.
- Diab, A. A. Z., Sultan, H. M., Do, T. D., Kamel, O. M., ve Mossa, M. A. (2020). Coyote optimization algorithm for parameters estimation of various models of solar cells and PV modules. *IEEE Access*, 8, 111102-111140.
- Diab, A. A. Z., Tolba, M. A., El-Rifaie, A. M., ve Denis, K. A. (2022). Photovoltaic parameter estimation using honey badger algorithm and African vulture optimization algorithm. *Energy Reports*, 8, 384-393.

- Duman, S., Kahraman, H. T., Sonmez, Y., Guvenc, U., Kati, M., ve Aras, S. (2022). A powerful meta-heuristic search algorithm for solving global optimization and real-world solar photovoltaic parameter estimation problems. *Engineering Applications of Artificial Intelligence*, 111, 104763.
- Easwarakhanthan, T., Bottin, J., Bouhouch, I., ve Boutrit, C. (1986). Nonlinear minimization algorithm for determining the solar cell parameters with microcomputers. *International journal of solar energy*, 4(1), 1-12.
- Ebrahimi, S. M., Salahshour, E., Malekzadeh, M., ve Gordillo, F. (2019). Parameters identification of PV solar cells and modules using flexible particle swarm optimization algorithm. *Energy*, 179, 358-372.
- El-Naggar, K. M., AlRashidi, M., AlHajri, M., ve Al-Othman, A. (2012). Simulated annealing algorithm for photovoltaic parameters identification. *Solar Energy*, 86(1), 266-274.
- El-Sayed, M. I., Mohamed, M. A.-E.-H., ve Osman, M. H. (2016). A novel parameter estimation of a PV model. 2016 IEEE 43rd Photovoltaic Specialists Conference (PVSC),
- Elhammoudy, A., Elyaqouti, M., Hmamou, D. B., Lidaighbi, S., Saadaoui, D., Choulli, I., ve Abazine, I. (2023). Dandelion Optimizer algorithm-based method for accurate photovoltaic model parameter identification. *Energy Conversion and Management: X*, 19, 100405.
- Engana Carmo, J., Neto Torres, J. P., Cruz, G., ve Marques Lameirinhas, R. A. (2021). Effect of the inclusion of photovoltaic solar panels in the autonomy of uav time of flight. *Energies*, 14(4), 876.
- Falahah, I. A., Al-Baik, O., Alomari, S., Bektemyssova, G., Gochhait, S., Leonova, I., Malik, O. P., Werner, F., ve Dehghani, M. (2024). Frilled Lizard Optimization: A Novel Bio-Inspired Optimizer for Solving Engineering Applications. *Computers, Materials & Continua*, 79(3).
- Feltrin, A., ve Freundlich, A. (2008). Material considerations for terawatt level deployment of photovoltaics. *Renewable Energy*, 33(2), 180-185.
- Gallardo-Saavedra, S., Hernández-Callejo, L., ve Duque-Pérez, O. (2019). Quantitative failure rates and modes analysis in photovoltaic plants. *Energy*, 183, 825-836.
- Gao, X., Cui, Y., Hu, J., Xu, G., Wang, Z., Qu, J., ve Wang, H. (2018). Parameter extraction of solar cell models using improved shuffled complex evolution algorithm. *Energy Conversion and Management*, 157, 460-479.
- Gao, X., Cui, Y., Hu, J., Xu, G., ve Yu, Y. (2016). Lambert W-function based exact representation for double diode model of solar cells: Comparison on fitness and parameter extraction. *Energy Conversion and Management*, 127, 443-460.

- Garip, Z. (2023). Parameters estimation of three-diode photovoltaic model using fractional-order Harris Hawks optimization algorithm. *Optik*, 272, 170391.
- Ghorannevis, Z., Akbarnejad, E., ve Ghoranneviss, M. (2016). Effects of various deposition times and RF powers on CdTe thin film growth using magnetron sputtering. *Journal of Theoretical and Applied Physics*, 10, 225-231.
- Ginidi, A. R., Shaheen, A. M., El-Sehiemy, R. A., ve Elattar, E. (2021). Supply demand optimization algorithm for parameter extraction of various solar cell models. *Energy Reports*, 7, 5772-5794.
- Gnetchejo, P. J., Essiane, S. N., Dadjé, A., ve Ele, P. (2021). A combination of Newton-Raphson method and heuristics algorithms for parameter estimation in photovoltaic modules. *Heliyon*, 7(4).
- Graetzel, M., Janssen, R. A., Mitzi, D. B., ve Sargent, E. H. (2012). Materials interface engineering for solution-processed photovoltaics. *Nature*, 488(7411), 304-312.
- Gu, Z., Xiong, G., Fu, X., Mohamed, A. W., Al-Betar, M. A., Chen, H., ve Chen, J. (2023). Extracting accurate parameters of photovoltaic cell models via elite learning adaptive differential evolution. *Energy Conversion and Management*, 285, 116994.
- Gude, S., ve Jana, K. C. (2020). Parameter extraction of photovoltaic cell using an improved cuckoo search optimization. *Solar Energy*, 204, 280-293.
- Guo, J., Zhang, X., Gu, F., Zhang, H., ve Fan, Y. (2020). Does air pollution stimulate electric vehicle sales? Empirical evidence from twenty major cities in China. *Journal of Cleaner Production*, 249, 119372.
- Guo, L., Meng, Z., Sun, Y., ve Wang, L. (2016). Parameter identification and sensitivity analysis of solar cell models with cat swarm optimization algorithm. *Energy Conversion and Management*, 108, 520-528.
- Gupta, S., Tiwari, H., Fozdar, M., ve Chandna, V. (2012). Development of a two diode model for photovoltaic modules suitable for use in simulation studies. 2012 Asia-Pacific Power and Energy Engineering Conference,
- Houssein, E. H., Zaki, G. N., Diab, A. A. Z., ve Younis, E. M. (2021). An efficient Manta Ray Foraging Optimization algorithm for parameter extraction of three-diode photovoltaic model. *Computers & Electrical Engineering*, 94, 107304.
- Humada, A. M., Hojabri, M., Mekhilef, S., ve Hamada, H. M. (2016). Solar cell parameters extraction based on single and double-diode models: A review. *Renewable and Sustainable Energy Reviews*, 56, 494-509.
- Imani, M. H., Niknejad, P., ve Barzegaran, M. (2018). The impact of customers' participation level and various incentive values on implementing emergency demand response program in microgrid operation. *International Journal of Electrical Power & Energy Systems*, 96, 114-125.

- Ishaque, K., Salam, Z., ve Taheri, H. (2011). Simple, fast and accurate two-diode model for photovoltaic modules. *Solar Energy Materials and Solar Cells*, 95(2), 586-594.
- Issa, M., Helmi, A. M., ve Ghetas, M. (2024). Estimation of solar cell parameters through utilization of adaptive sine–cosine particle swarm optimization algorithm. *Neural Computing and Applications*, 36(15), 8757-8773.
- Izci, D., Ekinci, S., Altalhi, M., Daoud, M. S., Migdady, H., ve Abualigah, L. (2024). A new modified version of mountain gazelle optimization for parameter extraction of photovoltaic models. *Electrical Engineering*, 106(5), 6565-6585.
- Izci, D., Ekinci, S., Dal, S., ve Sezgin, N. (2022). Parameter estimation of solar cells via weighted mean of vectors algorithm. 2022 global energy conference (GEC),
- Izci, D., Ekinci, S., ve Hussien, A. G. (2024). Efficient parameter extraction of photovoltaic models with a novel enhanced prairie dog optimization algorithm. *Scientific Reports*, 14(1), 7945.
- Izci, D., Ekinci, S., ve Ma'arif, A. (2024). Parameter Extraction of Triple-diode Photovoltaic Model via RIME Optimizer with Neighborhood Centroid Opposite Solution. *Journal of Robotics and Control (JRC)*, 5(4), 1098-1103.
- Jearsiripongkul, T., Prempraneerach, P., Eslami, M., ve Moarrefi, M. A. (2023). A novel hybrid metaheuristic approach to parameter estimation of photovoltaic solar cells and modules. *Engineered Science*, 27, 979.
- Jiao, S., Chong, G., Huang, C., Hu, H., Wang, M., Heidari, A. A., Chen, H., ve Zhao, X. (2020). Orthogonally adapted Harris hawks optimization for parameter estimation of photovoltaic models. *Energy*, 203, 117804.
- Karimi, M., Samet, H., Ghanbari, T., ve Moshksar, E. (2020). A current based approach for hotspot detection in photovoltaic strings. *International Transactions on Electrical Energy Systems*, 30(9), e12517.
- Khanna, V., Das, B., Bisht, D., ve Singh, P. (2015). A three diode model for industrial solar cells and estimation of solar cell parameters using PSO algorithm. *Renewable Energy*, 78, 105-113.
- Kler, D., Sharma, P., Banerjee, A., Rana, K., ve Kumar, V. (2017). PV cell and module efficient parameters estimation using Evaporation Rate based Water Cycle Algorithm. *Swarm and evolutionary computation*, 35, 93-110.
- Kullampalayam Murugaiyan, N., Chandrasekaran, K., Manoharan, P., ve Derebew, B. (2024). Leveraging opposition-based learning for solar photovoltaic model parameter estimation with exponential distribution optimization algorithm. *Scientific Reports*, 14(1), 528.

- Kumar, C., Raj, T. D., Premkumar, M., ve Raj, T. D. (2020). A new stochastic slime mould optimization algorithm for the estimation of solar photovoltaic cell parameters. *Optik*, 223, 165277.
- Kumar, M., ve Kumar, A. (2017). An efficient parameters extraction technique of photovoltaic models for performance assessment. *Solar Energy*, 158, 192-206.
- Kumar, M., ve Kumar, A. (2019). Experimental validation of performance and degradation study of canal-top photovoltaic system. *Applied energy*, 243, 102-118.
- Kumar, M., Kumar, A., ve Gupta, R. (2021). Comparative degradation analysis of different photovoltaic technologies on experimentally simulated water bodies and estimation of evaporation loss reduction. *Progress in Photovoltaics: Research and Applications*, 29(3), 357-378.
- Lekouaghet, B., Boukabou, A., ve Boubakir, C. (2021). Estimation of the photovoltaic cells/modules parameters using an improved Rao-based chaotic optimization technique. *Energy Conversion and Management*, 229, 113722.
- Lekouaghet, B., Khelifa, M. A., ve Boukabou, A. (2022). Adolescent identity search algorithm for parameter extraction in photovoltaic solar cells and modules. *Journal of Computational Electronics*, 21(4), 859-881.
- Lepetit, T., Harel, S., Arzel, L., Ouvrard, G., ve Barreau, N. (2016). Coevaporated KInSe 2: a fast alternative to KF postdeposition treatment in high-efficiency Cu (In, Ga) Se 2 thin film solar cells. *IEEE Journal of Photovoltaics*, 6(5), 1316-1320.
- Li, B., Wang, L., Kang, B., Wang, P., ve Qiu, Y. (2006). Review of recent progress in solid-state dye-sensitized solar cells. *Solar Energy Materials and Solar Cells*, 90(5), 549-573.
- Li, S., Gong, W., Yan, X., Hu, C., Bai, D., Wang, L., ve Gao, L. (2019). Parameter extraction of photovoltaic models using an improved teaching-learning-based optimization. *Energy Conversion and Management*, 186, 293-305.
- Li, S., Gu, Q., Gong, W., ve Ning, B. (2020). An enhanced adaptive differential evolution algorithm for parameter extraction of photovoltaic models. *Energy Conversion and Management*, 205, 112443.
- Liang, J., Ge, S., Qu, B., Yu, K., Liu, F., Yang, H., Wei, P., ve Li, Z. (2020). Classified perturbation mutation based particle swarm optimization algorithm for parameters extraction of photovoltaic models. *Energy Conversion and Management*, 203, 112138.
- Liang, J., Qiao, K., Yu, K., Ge, S., Qu, B., Xu, R., ve Li, K. (2020). Parameters estimation of solar photovoltaic models via a self-adaptive ensemble-based differential evolution. *Solar Energy*, 207, 336-346.

- Liang, M., Xu, W., Cai, F., Chen, P., Peng, B., Chen, J., ve Li, Z. (2007). New triphenylamine-based organic dyes for efficient dye-sensitized solar cells. *The Journal of Physical Chemistry C*, 111(11), 4465-4472.
- Liu, E., Li, W., Cai, H., ve Peng, S. (2018). Formation mechanism of trailing oil in product oil pipeline. *Processes*, 7(1), 7.
- Liu, Q., Zhang, C., Li, Z., Peng, T., Zhang, Z., Du, D., ve Nazir, M. S. (2024). Multi-strategy adaptive guidance differential evolution algorithm using fitness-distance balance and opposition-based learning for constrained global optimization of photovoltaic cells and modules. *Applied energy*, 353, 122032.
- Liu, Y., Chong, G., Heidari, A. A., Chen, H., Liang, G., Ye, X., Cai, Z., ve Wang, M. (2020). Horizontal and vertical crossover of Harris hawk optimizer with Nelder-Mead simplex for parameter estimation of photovoltaic models. *Energy Conversion and Management*, 223, 113211.
- Long, W., Cai, S., Jiao, J., Xu, M., ve Wu, T. (2020). A new hybrid algorithm based on grey wolf optimizer and cuckoo search for parameter extraction of solar photovoltaic models. *Energy Conversion and Management*, 203, 112243.
- Long, W., Wu, T., Xu, M., Tang, M., ve Cai, S. (2021). Parameters identification of photovoltaic models by using an enhanced adaptive butterfly optimization algorithm. *Energy*, 229, 120750.
- Lotfi, D., ve Hatem, E. (2012). Phosphorus diffusion gettering process of multicrystalline silicon using a sacrificial porous silicon layer. *Nanoscale research letters*, 7, 1-7.
- Lu, Y., Liang, S., Ouyang, H., Li, S., ve Wang, G.-g. (2023). Hybrid multi-group stochastic cooperative particle swarm optimization algorithm and its application to the photovoltaic parameter identification problem. *Energy Reports*, 9, 4654-4681.
- Luu, T. V., ve Nguyen, N. S. (2020). Parameters extraction of solar cells using modified JAYA algorithm. *Optik*, 203, 164034.
- Lv, Q., Liu, H., Wang, J., Liu, H., ve Shang, Y. (2020). Multiscale analysis on spatiotemporal dynamics of energy consumption CO2 emissions in China: Utilizing the integrated of DMSP-OLS and NPP-VIIRS nighttime light datasets. *Science of the Total Environment*, 703, 134394.
- Makarova, A. (2017). Study, Design and Performance Analysis of a Grid-Connected Photovoltaic System: Case study: 5 MW Grid-Connected PV System in Namibia.
- Manoharan, P., Subramaniam, U., Babu, T. S., Padmanaban, S., Holm-Nielsen, J. B., Mitolo, M., ve Ravichandran, S. (2020). Improved perturb and observation maximum power point tracking technique for solar photovoltaic power generation systems. *IEEE Systems Journal*, 15(2), 3024-3035.

- Marques Lameirinhas, R. A., Torres, J. P. N., ve de Melo Cunha, J. P. (2022). A photovoltaic technology review: History, fundamentals and applications. *Energies*, 15(5), 1823.
- Mathew, D., Rani, C., Kumar, M. R., Wang, Y., Binns, R., ve Busawon, K. (2017). Wind-driven optimization technique for estimation of solar photovoltaic parameters. *IEEE Journal of Photovoltaics*, 8(1), 248-256.
- Messaoud, R. B. (2020a). Extraction of uncertain parameters of single-diode model of a photovoltaic panel using simulated annealing optimization. *Energy Reports*, 6, 350-357.
- Messaoud, R. B. (2020b). Extraction of uncertain parameters of single and double diode model of a photovoltaic panel using Salp Swarm algorithm. *Measurement*, 154, 107446.
- Mirjalili, S. (2016). SCA: a sine cosine algorithm for solving optimization problems. *Knowledge-based systems*, 96, 120-133.
- Mirjalili, S., Mirjalili, S. M., ve Hatamlou, A. (2016). Multi-verse optimizer: a nature-inspired algorithm for global optimization. *Neural Computing and Applications*, 27, 495-513.
- Mohamed, A. W., ve Mohamed, A. K. (2019). Adaptive guided differential evolution algorithm with novel mutation for numerical optimization. *International journal of machine learning and cybernetics*, 10, 253-277.
- Mohapatra, A., Nayak, B., Das, P., ve Mohanty, K. B. (2017). A review on MPPT techniques of PV system under partial shading condition. *Renewable and Sustainable Energy Reviews*, 80, 854-867.
- Montano, J., Tobón, A., Villegas, J., ve Durango, M. (2020). Grasshopper optimization algorithm for parameter estimation of photovoltaic modules based on the single diode model. *International Journal of Energy and Environmental Engineering*, 11(3), 367-375.
- Moradi, K., Ebadian, M. A., ve Lin, C.-X. (2013). A review of PV/T technologies: Effects of control parameters. *International journal of heat and mass transfer*, 64, 483-500.
- Mostafa, M., Rezk, H., Aly, M., ve Ahmed, E. M. (2020). A new strategy based on slime mould algorithm to extract the optimal model parameters of solar PV panel. *Sustainable Energy Technologies and Assessments*, 42, 100849.
- Mottakin, M., Sobayel, K., Sarkar, D., Alkhamash, H., Alharthi, S., Techato, K., Shahiduzzaman, M., Amin, N., Sopian, K., ve Akhtaruzzaman, M. (2021). Design and modelling of eco-friendly CH₃NH₃SnI₃-based perovskite solar cells with suitable transport layers. *Energies*, 14(21), 7200.

- Muhammad, F. F., Karim Sangawi, A. W., Hashim, S., Ghoshal, S., Abdullah, I. K., ve Hameed, S. S. (2019). Simple and efficient estimation of photovoltaic cells and modules parameters using approximation and correction technique. *PLoS One*, 14(5), e0216201.
- Nadia, A.-R., Isa, N. A. M., ve Desa, M. K. M. (2018). Advances in solar photovoltaic tracking systems: A review. *Renewable and Sustainable Energy Reviews*, 82, 2548-2569.
- Navarro, M. A., Oliva, D., Ramos-Michel, A., ve Haro, E. H. (2023). An analysis on the performance of metaheuristic algorithms for the estimation of parameters in solar cell models. *Energy Conversion and Management*, 276, 116523.
- Nguyen, T. T., Nguyen, T. T., ve Tran, T. N. (2022). Parameter estimation of photovoltaic cell and module models relied on metaheuristic algorithms including artificial ecosystem optimization. *Neural Computing and Applications*, 34(15), 12819-12844.
- Nunes, H., Pombo, J., Mariano, S., Calado, M., ve De Souza, J. F. (2018). A new high performance method for determining the parameters of PV cells and modules based on guaranteed convergence particle swarm optimization. *Applied energy*, 211, 774-791.
- Nunes, H., Silva, P., Pombo, J., Mariano, S., ve Calado, M. (2020). Multiswarm spiral leader particle swarm optimisation algorithm for PV parameter identification. *Energy Conversion and Management*, 225, 113388.
- Oliva, D., Abd El Aziz, M., ve Hassanien, A. E. (2017). Parameter estimation of photovoltaic cells using an improved chaotic whale optimization algorithm. *Applied energy*, 200, 141-154.
- Oliva, D., Cuevas, E., ve Pajares, G. (2014). Parameter identification of solar cells using artificial bee colony optimization. *Energy*, 72, 93-102.
- Orioli, A., ve Di Gangi, A. (2013). A procedure to calculate the five-parameter model of crystalline silicon photovoltaic modules on the basis of the tabular performance data. *Applied energy*, 102, 1160-1177.
- Ortiz-Conde, A., Sánchez, F. J. G., ve Muci, J. (2006). New method to extract the model parameters of solar cells from the explicit analytic solutions of their illuminated I–V characteristics. *Solar Energy Materials and Solar Cells*, 90(3), 352-361.
- Parida, B., Iniyan, S., ve Goic, R. (2011). A review of solar photovoltaic technologies. *Renewable and Sustainable Energy Reviews*, 15(3), 1625-1636.
- Premkumar, M., Chandrasekaran, K., ve Sowmya, R. (2020). Mathematical modelling of solar photovoltaic cell/panel/array based on the physical parameters from the manufacturer's datasheet. *International Journal of Renewable energy development*, 9(1), 7.

- Premkumar, M., Jangir, P., Sowmya, R., Elavarasan, R. M., ve Kumar, B. S. (2021). Enhanced chaotic JAYA algorithm for parameter estimation of photovoltaic cell/modules. *ISA transactions*, 116, 139-166.
- Qais, M. H., Hasanien, H. M., ve Alghuwainem, S. (2020). Transient search optimization for electrical parameters estimation of photovoltaic module based on datasheet values. *Energy Conversion and Management*, 214, 112904.
- Qaraad, M., Amjad, S., Hussein, N. K., Badawy, M., Mirjalili, S., ve Elhosseini, M. A. (2023). Photovoltaic parameter estimation using improved moth flame algorithms with local escape operators. *Computers and Electrical Engineering*, 106, 108603.
- Rahideh, M., Ketabi, A., ve Halvaei Niasar, A. (2020). State-dependent Riccati equation-based MRAC and fuzzy sliding mode control for maximum power point tracking in partially shaded conditions in PV systems. *International Transactions on Electrical Energy Systems*, 30(2), e12184.
- Rahman, M., Salehin, S., Ahmed, S., ve Islam, A. S. (2017). Environmental impact assessment of different renewable energy resources: a recent development. In *Clean Energy for Sustainable Development* (pp. 29-71). Elsevier.
- Ram, J. P., Manghani, H., Pillai, D. S., Babu, T. S., Miyatake, M., ve Rajasekar, N. (2018). Analysis on solar PV emulators: A review. *Renewable and Sustainable Energy Reviews*, 81, 149-160.
- Ramadan, A., Kamel, S., Korashy, A., ve Yu, J. (2020). Photovoltaic cells parameter estimation using an enhanced teaching-learning-based optimization algorithm. *Iranian Journal of Science and Technology, Transactions of Electrical Engineering*, 44, 767-779.
- Ridha, H. M., Hizam, H., Mirjalili, S., Othman, M. L., ve Ya'acob, M. E. (2022). Zero root-mean-square error for single-and double-diode photovoltaic models parameter determination. *Neural Computing and Applications*, 34(14), 11603-11624.
- Rizk-Allah, R. M., ve El-Fergany, A. A. (2020). Conscious neighborhood scheme-based Laplacian barnacles mating algorithm for parameters optimization of photovoltaic single-and double-diode models. *Energy Conversion and Management*, 226, 113522.
- Rushdi, H. K., ve Al-Naima, F. M. (2022). Coot optimization algorithm for parameter estimation of photovoltaic model. *MEST Journal*, 10(2), 177-185.
- Shaheen, A. M., El-Seheimy, R. A., Xiong, G., Elattar, E., ve Ginidi, A. R. (2022). Parameter identification of solar photovoltaic cell and module models via supply demand optimizer. *Ain Shams Engineering Journal*, 13(4), 101705.
- Shaheen, A. M., Ginidi, A. R., El-Sehiemy, R. A., El-Fergany, A., ve Elsayed, A. M. (2023). Optimal parameters extraction of photovoltaic triple diode model using an enhanced artificial gorilla troops optimizer. *Energy*, 283, 129034.

- Sharma, A., Dasgotra, A., Tiwari, S. K., Sharma, A., Jatly, V., ve Azzopardi, B. (2021). Parameter extraction of photovoltaic module using tunicate swarm algorithm. *Electronics*, 10(8), 878.
- Sharma, P., ve Raju, S. (2023). Efficient estimation of PV parameters for existing datasets by using an intelligent algorithm. *Optik*, 295, 171467.
- Sharma, S., Jain, K. K., ve Sharma, A. (2015). Solar cells: in research and applications—a review. *Materials Sciences and Applications*, 6(12), 1145-1155.
- Sheikh, N., Daim, T., ve Kocaoglu, D. F. (2011). Use of multiple perspectives and decision modeling for PV technology assessment. 2011 Proceedings of PICMET'11: Technology Management in the Energy Smart World (PICMET),
- Simya, O., Radhakrishnan, P., Ashok, A., Kavitha, K., ve Althaf, R. (2018). Engineered nanomaterials for energy applications. *Handbook of Nanomaterials for Industrial Applications*, 751-767.
- Singh, A., Sharma, A., Rajput, S., Bose, A., ve Hu, X. (2022). An investigation on hybrid particle swarm optimization algorithms for parameter optimization of PV cells. *Electronics*, 11(6), 909.
- Singh, A., Sharma, A., Rajput, S., Mondal, A. K., Bose, A., ve Ram, M. (2022). Parameter extraction of solar module using the sooty tern optimization algorithm. *Electronics*, 11(4), 564.
- Singla, M. K., Nijhawan, P., ve Oberoi, A. S. (2022). Parameter estimation of three diode solar PV cell using chaotic dragonfly algorithm. *Soft Computing*, 26(21), 11567-11598.
- Srinivas, B., Balaji, S., Nagendra Babu, M., ve Reddy, Y. (2015). Review on present and advance materials for solar cells. *International Journal of Engineering Research-Online*, 3(2015), 178-182.
- Stornelli, V., Muttillio, M., De Rubeis, T., ve Nardi, I. (2019). A new simplified five-parameter estimation method for single-diode model of photovoltaic panels. *Energies*, 12(22), 4271.
- Tanabe, R., ve Fukunaga, A. S. (2014). Improving the search performance of SHADE using linear population size reduction. 2014 IEEE congress on evolutionary computation (CEC),
- Tefek, M. F. (2021). Artificial bee colony algorithm based on a new local search approach for parameter estimation of photovoltaic systems. *Journal of Computational Electronics*, 20(6), 2530-2562.
- Thangamani, K., Manickam, M. L., ve Chellaiah, C. (2020). An experimental study on photovoltaic module with optimum power point tracking method. *International Transactions on Electrical Energy Systems*, 30(1), e12175.

- Valer, L. R., Manito, A. R., Ribeiro, T. B. S., Zilles, R., ve Pinho, J. T. (2017). Issues in PV systems applied to rural electrification in Brazil. *Renewable and Sustainable Energy Reviews*, 78, 1033-1043.
- Venkateswari, R., ve Rajasekar, N. (2021). Review on parameter estimation techniques of solar photovoltaic systems. *International Transactions on Electrical Energy Systems*, 31(11), e13113.
- Wang, M., Zhao, X., Heidari, A. A., ve Chen, H. (2020). Evaluation of constraint in photovoltaic models by exploiting an enhanced ant lion optimizer. *Solar Energy*, 211, 503-521.
- Weng, X., Heidari, A. A., Liang, G., Chen, H., Ma, X., Mafarja, M., ve Turabieh, H. (2021). Laplacian Nelder-Mead spherical evolution for parameter estimation of photovoltaic models. *Energy Conversion and Management*, 243, 114223.
- Yaghoubi, M., Eslami, M., Noroozi, M., Mohammadi, H., Kamari, O., ve Palani, S. (2022). Modified salp swarm optimization for parameter estimation of solar PV models. *IEEE Access*, 10, 110181-110194.
- Yang, B., Wang, J., Zhang, X., Yu, T., Yao, W., Shu, H., Zeng, F., ve Sun, L. (2020). Comprehensive overview of meta-heuristic algorithm applications on PV cell parameter identification. *Energy Conversion and Management*, 208, 112595.
- Yang, C., Su, C., Hu, H., Habibi, M., Safarpour, H., ve Khadimallah, M. A. (2023). Performance optimization of photovoltaic and solar cells via a hybrid and efficient chimp algorithm. *Solar Energy*, 253, 343-359.
- Yang, X., ve Gong, W. (2021). Opposition-based JAYA with population reduction for parameter estimation of photovoltaic solar cells and modules. *Applied Soft Computing*, 104, 107218.
- Ye, M., Wang, X., ve Xu, Y. (2009). Parameter extraction of solar cells using particle swarm optimization. *Journal of Applied Physics*, 105(9).
- Yu, K., Chen, X., Wang, X., ve Wang, Z. (2017). Parameters identification of photovoltaic models using self-adaptive teaching-learning-based optimization. *Energy Conversion and Management*, 145, 233-246.
- Yu, K., Liang, J., Qu, B., Chen, X., ve Wang, H. (2017). Parameters identification of photovoltaic models using an improved JAYA optimization algorithm. *Energy Conversion and Management*, 150, 742-753.
- Yu, K., Liang, J., Qu, B., Cheng, Z., ve Wang, H. (2018). Multiple learning backtracking search algorithm for estimating parameters of photovoltaic models. *Applied energy*, 226, 408-422.
- Yu, X., Duan, Y., ve Cai, Z. (2023). Sub-population improved grey wolf optimizer with Gaussian mutation and Lévy flight for parameters identification of photovoltaic models. *Expert Systems with Applications*, 232, 120827.

- Yu, X., Hu, Z., Wang, X., ve Luo, W. (2023). Ranking teaching-learning-based optimization algorithm to estimate the parameters of solar models. *Engineering Applications of Artificial Intelligence*, 123, 106225.
- Zhang, H., Heidari, A. A., Wang, M., Zhang, L., Chen, H., ve Li, C. (2020). Orthogonal Nelder-Mead moth flame method for parameters identification of photovoltaic modules. *Energy Conversion and Management*, 211, 112764.
- Zhao, W., Wang, L., Zhang, Z., Mirjalili, S., Khodadadi, N., ve Ge, Q. (2023). Quadratic Interpolation Optimization (QIO): A new optimization algorithm based on generalized quadratic interpolation and its applications to real-world engineering problems. *Computer Methods in Applied Mechanics and Engineering*, 417, 116446.
- Zhou, J., Zhang, Y., Zhang, Y., Shang, W.-L., Yang, Z., ve Feng, W. (2022). Parameters identification of photovoltaic models using a differential evolution algorithm based on elite and obsolete dynamic learning. *Applied energy*, 314, 118877.