

T.C.
KASTAMONU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI



COATİ OPTİMİZASYON ALGORİTMASI KULLANILARAK PV
GÜNEŞ HÜCRELERİ VE MODÜLLERİ PARAMETRE
TAHMINİ

RAFA OTHMAN HUSSEIN ELSHARA

DOKTORA TEZİ

PROF. DR. AYBABA HAÇERLİOĞULLARI

HAZİRAN - 2025

KASTAMONU

TEZ ONAYI

RAFA OTHMAN HUSSEIN ELSHARA tarafından hazırlanan “**COATİ OPTİMİZASYON ALGORİTMASI KULLANILARAK PV GÜNEŞ HÜCRELERİ VE MODÜLLERİ PARAMETRE TAHMİNİ**” adlı tez çalışmasının savunma sınavı **26.06.2025** tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Malzeme Bilimi ve Mühendisliği Ana Bilim Dalı** **Doktora Tezi** olarak kabul edilmiştir.

Danışman	Prof. Dr. Aybaba HANÇERLİOĞULLARI Kastamonu Üniversitesi	
Jüri Üyesi	Prof. Dr. Aslı KURNAZ Kastamonu Üniversitesi	
Jüri Üyesi	Prof.Dr.Erol KURT Gazi Üniversitesi	
Jüri Üyesi	Doç. Dr. Elif AŞIKUZUN TOKEŞER Kastamonu Üniversitesi	
Jüri Üyesi	Doç. Dr .Reza AGHAZADEH Türk Hava Kurumu Üniversitesi	

Jüri üyeleri tarafından kabul edilmiş olan bu tez Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Enstitü Müdürü	Doç. Dr. Selçuk MEMİŞ	
----------------	-----------------------	-------

TAAHHÜTNAME

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını, bilimsel etiğe uygun olarak kaynak gösterildiğini bildirir ve taahhüt ederim.

RAFA OTHMAN HUSSEIN ELSHARA

ÖZET

DOKTORA TEZİ

COATİ OPTİMİZASYON ALGORİTMASI KULLANILARAK PV GÜNEŞ HÜCRELERİ VE MODÜLLERİ PARAMETRE TAHMİNİ

RAFA OTHMAN HUSSEIN ELSHARA

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI
DANIŞMAN: PROF. DR. AYBABA HAÇERLİOĞULLARI

Güneş enerjisi, fosil yakıtlara sürdürülebilir bir alternatif olarak öne çıkarken, fotovoltaik (PV) sistemler bu enerjiden elektrik üretiminde kilit bir rol oynamaktadır. PV modül performansının optimize edilmesi ise doğru parametre tahminini gerektirir. Bu çalışmada, PV modül parametrelerinin doğruluğunu artırmak ve enerji verimliliğini yükseltmek amacıyla Coati Optimizasyon Algoritması'na (COA) dayalı, karışıklık temelli öğrenme ve kaos teorisini içeren gelişmiş bir optimizasyon yaklaşımı önerilmektedir. Yöntem, SDM, DDM ve genel PV modülleri üzerinde test edilmiş; JSO, HHO, WOA ve GWO gibi mevcut algoritmalarla karşılaştırılmıştır. Elde edilen sonuçlar, COA tabanlı yaklaşımın hata oranlarını azaltarak, parametre ayarlarını iyileştirerek ve hesaplama verimliliğini artırarak üstün performans sergilediğini göstermektedir. Friedman testi de, COA'nın temel versiyonuna göre SDM, DDM ve PV modüllerinde sırasıyla %8,1; %10,79 ve %9,6 oranında iyileşme sağladığını ortaya koymuştur. Bulgular, önerilen yöntemin PV teknolojisinin gelişimine ve sürdürülebilir enerji kullanımına anlamlı katkılar sunduğunu göstermektedir.

ANAHTAR KELİMELEER: Coati, Optimizasyon, Kaos teoris, Karışıklık tabanlı öğrenme, Güneş Pilleri (PV)

Haziran 2025, 86 Sayfa

ABSTRACT

PH.D THESIS

PARAMETER ESTIMATION OF PV SOLAR CELLS AND MODULES USING COATI OPTIMIZATION ALGORITHM

RAFA OTHMAN HUSSEIN ELSHARA

**KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE
DEPARTMENT OF MATERIALS SCIENCE AND ENGINEERING
SUPERVISOR: PROF. DR. AYBABA HANÇERLİOĞULLARI**

Solar energy has emerged as a sustainable alternative to fossil fuels, with photovoltaic (PV) systems playing a crucial role in converting sunlight into electricity. Optimizing the performance of PV modules requires accurate parameter estimation. This study proposes an advanced optimization approach based on the Coati Optimization Algorithm (COA), incorporating opposition-based learning and chaos theory to enhance parameter estimation accuracy and overall energy efficiency. The proposed method was tested on three PV models: SDM, DDM, and a general PV module, and compared against existing algorithms such as JSO, HHO, WOA, and GWO. The results demonstrate that the COA-based approach significantly improves performance by reducing error rates, enhancing parameter tuning, and increasing computational efficiency. Furthermore, the Friedman test revealed improvements over the basic COA in SDM, DDM, and PV modules by 8.1%, 10.79%, and 9.6%, respectively. These findings indicate that the proposed method offers meaningful contributions to the advancement of PV technology and the promotion of sustainable energy utilization.

KEYWORDS: Coati, Optimization, Chaostheory, Opposition-based Learning, Solar Cells (PV)

June 2025, 86 page

TEŞEKKÜR

Bu tez çalışmam boyunca bilimsel desteklerinden dolayı başta danışmanım Prof. Dr. Aybaba Haçerlioğulları'na teşekkürlerimi sunarım, ayrıca tezimin akademik ve bilimsel katkılarının ilerlemesi için sürekli desteklerini esirgemeyen tez izleme komitesine üyelerine ve anabilim dalı öğretim üyelerine teşekkür ediyorum. İyi ve kötü günlerimde yanımda olan ve başarılı olmama yardımcı olan maddi ve manevi desteklerini esirgemeyen tüm aile bireylerine teşekkürlerimi sunmak istiyorum.

RAFA OTHMAN HUSSEIN ELSHARA

Kastamonu, 2025

İÇİNDEKİLER

Sayfa

TEZ ONAYI	ii
TAAHHÜTNAME	iii
ÖZET.....	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİLLER DİZİNİ	x
TABLolar DİZİNİ	xi
SİMGELER VE KISALTMALAR DİZİNİ	xii
1. GİRİŞ.....	1
1.1 Arka Plan	1
1.2 Fotovoltaik Teknolojisinin Evrimi ve Küresel Etkisi	5
1.3 PV Sistemlerinde İleri Optimizasyon İhtiyacı	6
1.4 Optimizasyon Algoritmalarının Sınıflandırılması ve Karşılaştırılması	7
1.5 Enerji Politikası ve Ulusal Altyapı ile Entegrasyon	7
1.6 PV Sistemlerinde Akıllı Optimizasyonun Gelecekteki Potansiyeli	8
1.7 Problem Tanımı	9
1.8 Problem Çözümü	9
1.9 Araştırmanın Amacı	10
1.10 Araştırmanın Yaklaşımı	10
1.11 Araştırmanın Motivasyonu	11
1.12 Çalışmanın Sınırlamaları (Avantajlar ve Dezavantajlar)	11
1.13 Araştırmanın Katkıları	12
1.14 Tezin Organizasyonu	12
2. LİTERATÜR TARAMASI	14
2.1 İlgili Çalışmalar	14
2.2 Enerji Türleri	23
2.2.1 Yenilenebilir Enerjiler	23
2.2.2 Yenilenemez Enerjiler	23
2.3 PV Sistemlerinde Metasezgisel Optimizasyon Teknikleri	31
2.4 Metasezgisel Algoritmaların Karşılaştırmalı Çalışmaları	32
2.5 Hibrit Optimizasyon Yaklaşımları	32
2.6 PV Parametre Tahmininde Makine Öğrenimi ve Yapay Zeka	33
2.7 COA ve Diğer Algoritmaların Karşılaştırılması	34
2.8 Mevcut Literatürdeki Eksikler	34
2.9 Son Gelişmeler ve Önemi	35
2.10 Özet	35
3. MATERYAL VE METOT	37
3.1 Metodoloji	37
3.1.1 SMD Devresi	37
3.1.2 DDM Devresi	38
3.2 PV Modülü Modellemesi	39
3.2.1 Amaç Fonksiyonu	39
3.3 Coati Optimizasyon Algoritması	40

3.4	Önerilen Akış Şeması	47
3.5	PV Modellerinin Gelişmiş Matematiksel Temsili	50
3.5.1	Sıcaklık ve Işınım Etkileri	50
3.6	Coati Optimizasyon Algoritmasının (COA) Pratik Uygulaması	50
3.6.1	Birinci Aşama: Avlanma Stratejisi (Keşif).....	51
3.6.2	İkinci Aşama: Kaçış Stratejisi (Sömürü).....	51
3.7	Kaos Teorisi ve Karşıtlık Temelli Öğrenmenin Entegrasyonu.....	51
3.7.1	Tent Kaos Fonksiyonu	51
3.7.2	Karşıtlık Temelli Öğrenme (OBL)	52
3.8	Algoritmik İş Akışı ve Sözde Kod	52
3.8.1	Sözde Koda Genel Bakış	52
3.9	MATLAB Uygulama Stratejisi.....	53
3.9.1	Platform	53
3.9.2	Başlangıç Parametreleri	53
3.10	Duyarlılık Analizi ve Parametre Kalibrasyonu.....	53
3.11	PV Sistem Tasarımına Modüler Entegrasyon.....	54
3.12	Algoritma Performans Metrikleri	54
3.13	Özet	54
4.	BULGULAR VE TARTIŞMA	55
4.1	Arkaplan.....	55
4.2	Parametre Aralığı	55
4.3	SDM'ye Dayalı Sonuçlar	56
4.4	DDM'ye Dayalı Sonuçlar	56
4.5	STP6-120/36'ya Dayalı Sonuçlar	57
4.6	Sıralama	57
4.7	Zaman Karmaşıklığı.....	60
4.8	Tüm Modellerde Genişletilmiş Karşılaştırmalı Analiz.....	63
4.8.1	Çoklu Model RMSE Yorumlaması	63
4.9	Hata Dağılımı ve Kutu Diyagramı Görselleştirmesi.....	64
4.10	Standart Sapma ve Yakınsama Eğrileri	64
4.11	İstatistiksel Önem: Friedman Testi Analizi	65
4.12	I-V ve P-V Eğrilerinin Analizi.....	65
4.13	Gerçekçi Çalışma Koşullarında Performans	66
4.14	Uygulama Süresi ve Doğruluk Arasındaki Denge.....	66
4.15	Farklı Veri Kümeleriyle Çapraz Doğrulama.....	66
4.16	Algoritma Ölçeklenebilirliği Üzerine Tartışma	67
4.17	Gerçek Zamanlı Uygulanabilirlik ve Akıllı Sistem Entegrasyonu	67
4.18	Karşılaştırmalı Değerlendirme Özeti	68
4.19	Bölüm Özeti	68
5.	SONUÇLAR VE GELECEKTEKİ ÇALIŞMALAR.....	69
5.1	Sonuç.....	69
5.2	Gelecek Çalışmalar	70
5.3	Algoritmik Başarı Üzerine Derinlemesine Fikirler.....	70
5.4	PV Parametre Tahmininin Ötesinde Uygulama.....	71
5.5	Karşılaşılan Sınırlamalar ve Zorluklar	72
5.6	Endüstriyel Uygulama İçin Öneriler	72
5.7	ICOA İçin Önerilen Geliştirmeler	73
5.8	Daha İleri Araştırmalar İçin Öneriler	74
	KAYNAKLAR	76

ÖZGEÇMİŞ.....	86
----------------------	-----------



ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1 Bir PV hücresinin yapısı	14
Şekil 2.2 Bir PV sisteminin yapısı ve bileşenleri	15
Şekil 2.3 PV sistemlerinin izlenmesi alanında artan çalışmalar	16
Şekil 2.4 PV sistemlerinin optimizasyonu	17
Şekil 2.5 PV sistemlerde akım ve gerilim diyagramı	18
Şekil 2.6 Tüm yenilenebilir enerjilerin katılım yüzdesi	22
Şekil 3.1 PV sistemlerinde SDM devre yapısı	37
Şekil 3.2 PV sistemlerinde DDM devre yapısı	38
Şekil 3.3 Bir PV modülünün eşdeğer devresi	39
Şekil 3.4 Koati, bir memeli	41
Şekil 3.5 Koatinin avını korkutması, iguananın yere düşmesi ve koatinin avlanması	43
Şekil 3.6 Koatinin mevcut konumundan kaçışı	44
Şekil 3.7 COA algoritmasında daha fazla kaos yaratmak için kaos işlevi	46
Şekil 3.8 Önerilen yöntemin akış şeması	48
Şekil 4.1 Algoritmaların minimum RMSE hatasına göre sıralanması	58
Şekil 4.2 Algoritmaların standart sapma (SD) endeksine göre sıralanması	58
Şekil 4.3 Optimum PV parametrelerinin hesaplama sürelerinin karşılaştırılması	60
Şekil 4.4 ICOA tarafından SDM için ölçülen ve tahmin edilen verilerin karşılaştırılması: (a) I-V karakteristiği, (b) P-V karakteristiği, ve (c) IAE eğrileri	61
Şekil 4.5 ICOA tarafından DDM modeli için ölçülen ve tahmin edilen verilerin karşılaştırılması: (a) I-V karakteristiği, (b) P-V karakteristiği, ve (c) IAE eğrileri	62
Şekil 4.6 ICOA tarafından STP6-120/36 modeli için ölçülen ve tahmin edilen verilerin karşılaştırılması: (a) I-V karakteristiği, (b) P-V karakteristiği, ve (c) IAE eğrileri	63

TABLÖLAR DİZİNİ

Sayfa

Tablo 2.1 Önemli enerji kaynakları	24
Tablo 3.1 Etkinleştirilmiş paralel değerleri.....	53
Tablo 4.1 Modüllerdeki alt ve üst aralık	55
Tablo 4.2 SDM'deki parametrelerin optimum değerleri arasındaki karşılaştırma	56
Tablo 4.3 DDM parametrelerinin optimum değerleri arasındaki karşılaştırma.....	56
Tablo 4.4 STP6-120/36'daki optimum parametre değerlerinin karşılaştırılması.....	57
Tablo 4.5 Bazı algoritma modellerine ait standart sapma değerleri.....	64
Tablo 4.6 Friedman testine ait istatistiksel üstünlük.....	65
Tablo 4.7 Algoritmaların yakınsama hızı ve zamanı.....	66
Tablo 4.8 Algoritmaların önemli bazı kriterleri.....	68

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

$\%$	: Yüzde
$F(X_i)$	: Amaç Fonksiyonunun Değeri
I_{d1}	: Diyot Emisyon Akımı
I_{d2}	: Doyma Akımı
$X_{i,j}$	: Problemin Geçerli Çözümü
X_i	: i'ye Bir Çözüm
X_i^{P2}	: Kaçış Aşamasındaki Bir Koatinin Yeni Konumu
b_j / lb_j	: j Boyutunun i Çözümünün Üst ve Alt Sınırları
$b_j^{yerel} / lb_j^{yerel}$	: Her Boyutun Alt ve Üst Sınırları
$>$	: Büyüktür
E_g	: Yarı İletkenin Bant Aralığı Enerjisi
G	: Işınım
G_{ref}	: Referans Işınım Şiddeti
I_0	: Doygunluk Akımı
I_{ph}	: Fotoakım
j	: Çözüm Boyutu
kg	: Kilogram
n	: Diyotun İdealite
N	: Gerçek Ölçülen Veri Sayısı
n_1 / n_2	: İki Diyotun İdeal Doyma Katsayısı
q	: Başlangıç Yük
r	: Sıfır ile Bir Arasında Rastgele Bir Sayı
R_s	: Seri Direnç
R_{sh}	: Paralel Direnç
t	: Algoritmanın Tekrar Sayacı
T	: Mutlak Sıcaklık
t/T	: Yinelemeler Boyunca Bozulma
T_{ref}	: Referans Sıcaklık
U_j / L_j	: j Boyutundaki Arama Alanının Üst ve Alt Sınırları
V_L	: Çıkış Voltaj
X	: Farklı Bilinmeyen Parametrelerden Oluşan Çözüm
X_{rast}	: Rastgele Seçilmiş Bir Birim
β	: Sıcaklık Katsayısı
$OX_{i,j}$	: Karşılıklı Konum
Ub_j / Lb_j	: j Boyutunun Alt ve Üst Sınırları

Kısaltmalar

ABC	: Yapay Arı Kolonisi (Artificial Bee Colony)
ABD	: Amerika Birleşik Devletleri
BA	: Yarasa Algoritmaları (Bat Algorithm)
BMO	: Kuş Eşleşme Optimizasyonu (Bird Match Optimization)
cm	: Santimetre

ChOA	: Şempanze Optimizasyon Algoritması
COA	: Coati Optimizasyon Algoritması (Coati Optimization Algorithm)
DDM	: Çift Diyotlu Model (Dual Diode Model)
EEG	: Sinyal Özelliği Çıkarma (Elektroensefalogram)
EKG	: Gürültü Giderme (Elektrokardiyografi)
GA	: Genetik Algoritma (Genetic Algorithm)
GNN	: Grafik Sinir Ağları (Graph Neural Networks)
GWO	: Gri Kurt Optimizasyonu (Grey Wolf Optimizer)
HHO	: Harris Hawks Optimizasyonu (Harris Hawks Optimization)
ICOA	: Geliştirilmiş Coati Optimizasyon Algoritması (Improved Coati Optimization Algorithm)
IEA	: Uluslararası Enerji Ajansı (International Energy Agency)
IoT	: Internet of Things
IRENA	: Uluslararası Yenilenebilir Enerji Ajansı (International Renewable Energy Agency)
IV	: Akım-Voltaj
LSTM	: Uzun Kısa Süreli Bellek (Long Short Term Memory)
MATLAB	: Matris Laboratuvarı (Matrix Laboratory)
MPP	: Maksimum Güç Noktası (Maximum Power Point)
MPPT	: Maksimum Güç Noktası İzleme (Maximum Power Point Tracking)
NGO	: Kuzey Goshawk Optimizasyonu (North Goshawk Optimization)
OBL	: Karşıtlık Temelli Öğrenme
PFA	: Pathfinder Algoritması
PSO	: Parçacık Sürüşü Optimizasyonu (Particle Swarm Optimization)
PV	: Fotovoltaik
PWM	: Darbe Genişliği Modülasyonu (Pulse Width Modulation)
RET	: Yenilenebilir Enerji Teknolojileri
RMSE	: Hataların Karesinin Ortalamasının Karekökü (Root Mean Square Errors)
SD	: Standart Sapma (Standard Deviation)
SDM	: Tek Diyotlu Model (Single Diode Model)
SSA	: Sincap Arama Algoritması (Squirrel Search Algorithm)
SVR	: Destek Vektör Regresyonu (Support Vector Regression)
WOA	: Balina Optimizasyon Algoritması (Whale Optimization Algorithm)
YSA	: Yapay Sinir Ağları

1. GİRİŞ

1.1 Arka Plan

Son yıllarda enerji talebindeki artış, çevresel konularda endişelerin artmasına neden olmuştur. Fosil yakıtlar nispeten ucuz olsa da küresel ısınmanın ve hava kirliliğinin sürekli bir kaynağıdır. Petrol ve gaz çıkarımı enerji kaynakları sağlar ancak son yıllarda çevre kirliliğinin ana faktörü haline gelmişlerdir. Dahası, tahminler önümüzdeki yıllarda petrol ve gaz gibi enerji kaynaklarının tükeneceğini göstermektedir, bu nedenle yeni ve yenilenebilir enerji kaynakları bulmak hayati önem taşımaktadır (Rauf vd., 2023).

Günümüzde temiz ve yenilenebilir enerjiler gelişip ilerlediği için artık fosil yakıtlara (petrol ve gaz) uygun bir alternatif haline gelmişlerdir. Güneşten, rüzgardan, gelgitlerden, sudan, kaplıcalardan vb. elde edilen güç gibi yenilenebilir enerji son yıllarda bilim insanlarının dikkatini çekmiştir. Yenilenebilir enerjiler arasında güneş enerjisi diğer enerjilere göre daha ulaşılabilir ve dünyanın çoğu yerinde kullanılmaktadır. Güneş enerjisi yenilenebilir bir enerji kaynağıdır. Gaz ve petrol gibi fosil yakıtlarla elektrik üretiminin aksine güneş enerjisi herhangi bir çevre kirliliğine neden olmaz (Dekkiche vd., 2023). Tahminler, güneş enerjisinin elektrik üretimindeki payının 2027 yılına kadar yaklaşık 194 milyar dolara ulaşacağını göstermektedir ve bu da güneş enerjisinin önemini vurgulamaktadır (Sharma vd., 2021). Fotovoltaik sistemler güneş enerjisinin elektriğe dönüştürülmesine yardımcı olur. Fotovoltaik (PV) sistemler, yarı iletken teknolojisini kullanarak güneş enerjisini elektriğe dönüştürür (Van Gompel vd., 2023). Yenilenebilir enerjideki ilerleme, birçok ülke ve hükümetin bu temiz enerjiyi elektrik üretmek için kullanmasını sağlamıştır. Güneş enerjisi ekonomik ve bol miktarda bulunan temiz bir enerji kaynağıdır. Güneş ışığına kolay erişim nedeniyle, güneş sistemleri Afrika, Orta Doğu ve Amerika'daki birçok ülkede kullanılmaktadır (Wu vd., 2023).

Güneş hücrelerinde güneş enerjisinin elektriğe dönüştürülmesi, ince bir tabakaya sahip elektronik yarı iletkenlere dayalı cihazlar gerektirir. Yarı iletken kristallere dayalı bir güneş sistemi genellikle iki tipten oluşur: çok kristalli (Balamurugan vd., 2023) ve tek

kristalli (Irshad, 2023) güneş modülleri. Tek kristalli yarı iletkenler güç üretmek için daha verimlidir ve daha iyi elektriksel özelliklere sahiptir. Ancak, büyük bir üretim kapasitesine sahip olmalarına rağmen, tek kristalli PV modülleri, ince kristalin tabakalı teknolojinin yüksek maliyeti nedeniyle kârsızdır. Güneş enerjisi üretimi için tek kristal modüllere alternatif bir işlem ince film teknolojisidir. Bu yöntemde genellikle amorf silikon (Kar vd., 2023) veya kadmiyum tellür (Qiu ve Yang, 2022), bakır indiyum galyum selenit (Liu vd., 2022) veya galyum arsenit (Dhass vd., 2023) gibi diğer yarı iletken malzemeler kullanılır.

Güneş enerjisi, fotovoltaik cihazlarda yarı iletken teknolojisini kullanarak güneş enerjisini doğrudan elektriğe dönüştürdüğü için temiz ve yenilenebilir bir kaynaktır. PV sistemlerinden üretilen enerji miktarı hava koşullarına, güneş radyasyonuna, ortam sıcaklığına, modül türüne vb. bağlıdır (Afzal vd., 2023).

PV'nin elektriksel yapısı ve modüllerinin doğru bir şekilde anlaşılması araştırmacıların güç üretim verimliliğini artırmasına yardımcı olabilir. PV sistemleri bir güç dönüştürücü, bir güneş jeneratörü ve kontrol devreleri, güç dönüştürücüler veya invertörler aracılığıyla güç şebekesine bağlanan diğer parçalardan oluşur. PV cihazlarının üretim verimliliği etkili tasarım ve uygulama yoluyla artırılmalıdır. PV güç üretimi doğası gereği doğrusal olmamakla birlikte sıcaklık, ışık yoğunluğu ve yük özellikleri gibi çevresel değişkenlerden etkilenir. Bu nedenle, PV cihazlarının yüksek güç üretim performansı için kontrol devrelerine ihtiyacı vardır. PV cihazlarındaki kontrol devreleri güç üretimini ve sistem verimliliğini artırmak için akımı ve çıkış voltajını optimize eder (Kumar vd., 2023).

Tek diyot modeli (SDM) (Senthilkumar vd., 2023) ve çift diyot modeli (DDM) (Gholami vd., 2023), güneş PV hücrelerinin modellenmesi için iki temel modeldir. SDM, yüksek doğruluğu nedeniyle tercih edilir. DDM, SDM'den daha doğru olduğu için bir PV hücresini etkili bir şekilde temsil edebilir. Güneş PV hücrelerinin planlanması ve optimize edilmesi karmaşıktır çünkü bu problemde yaklaşık on bilinmeyen değişken vardır (Hamed vd., 2023). Araştırmalar, PV hücrelerinde voltaj veya IV açısından akım eğrilerinin doğrusal olmayan ve karmaşık bir yapıya sahip olduğunu göstermektedir. Bir kontrolör, herhangi bir PV devresindeki temel bir

bileşendir. Fotovoltaik sistemlerde, kontrolörler genellikle pillerin şarjını veya şebeke güç kaynaklarını yönetmek için kullanılır (Bonthagorla ve Mikkili, 2023). Maksimum Güç Noktası Takibi (MPPT), bazı denetleyicilerin güneş hücrelerinin güç verimliliğini artırmak için kullandığı imkanlardan biridir. MPPT algoritmaları, özellikle büyük sistemlerde, güç üretimi ve yönetimini artırmada önemlidir. Bir güneş modülü için MPPT, maksimum güce ulaşmak için akımı ve voltajı izleyip ardından absorbe eder (Bonthagorla ve Mikkili, 2023).

Bir kontrolörde doğrusal olmayan denklemleri çözmek ve MPPT'yi bulmak için üç yöntem mevcuttur. Bu yöntemler analitik yaklaşımları (Nwokolo vd., 2023), sayısal yaklaşımları (Tuncer vd., 2023) ve evrimsel algoritmaları (Hevisov vd., 2022) içerir. Çok sayıda bilinmeyene sahip doğrusal olmayan hesaplamaları çözmek için çoğunlukla doğrusal hesaplamalar kullanılan ilk yöntem başlatılmalıdır. Çözümün yakınsama oranını belirleyen denklemi çözmek için başlangıç değerini tahmin etmek, bu tür yaklaşımların en zor yönüdür. İkinci yaklaşım yerel arama tekniklerine dayanır. Sayısal yaklaşımların birkaç sınırlaması olmasına rağmen, analitik yöntemlerden daha hassas PV hücrelerinin özelliklerini çıkarabilirler. Birincisi, bu tekniğin yakınsaması büyük ölçüde ilk açıklamaya bağlıdır. İkincisi, hatalara eğilimlidirler ve üçüncüsü, uygun model parametrelerini elde etmek zaman ve çaba gerektirir. Son yıllarda optimizasyon ve meta-sezgisel yöntemler, doğrusal olmayan hesaplamaları çözmede ve optimum çözüme çok yakın sonuçlar elde etmede önemli bir rol oynamıştır. Bu teknikleri kullanarak ideal çözümü aramak çok az zaman alır. Son zamanlarda PV sistemlerinde güneş pili modeli parametrelerini belirlemek için çeşitli meta-sezgisel teknikler kullanılmıştır; örneğin, Genetik Algoritma (GA) (Wu vd., 2022), Parçacık Sürüsü Optimizasyonu (PSO) (Shorabeh vd., 2022), Balina Optimizasyon Algoritması (WOA) (Zadehbagheri ve Abbasi, 2023), Gri Kurt Optimizasyonu (GWO) (Aguila-Leon vd., 2023) ve Harris Hawks Optimizasyonu (HHO) (Zhang vd., 2023) algoritmaları bu amaçla kullanılmaktadır.

Günümüzde, küresel enerji tüketiminin artışta olması ve enerji üretimi için fosil yakıtların sınırlı bulunabilirliği nedeniyle, alternatif yenilenebilir enerji kaynaklarını keşfetmeye yönelik ilgi artmaktadır. Fosil yakıt kaynağı sahipleri, bugün mevcut rezervlerden daha fazlasını çıkarmanın gelecekte azalan getirilere yol açacağını ve

sonuçta bu kaynakları daha hızlı tüketeceğini kabul etmelidir. Neyse ki, dünya çapında birçok ülke enerji kaynaklarının, özellikle yenilenebilir kaynakların önemini kabul etmiş ve bu kaynakları kullanmak için araştırma ve altyapıya büyük yatırımlar yapmıştır.

Güneş, rüzgar, jeotermal ve deniz enerjisi sistemlerinde yakıt maliyeti yoktur. Bu kaynaklar arasında güneş hücreleri, kolay kurulum, düşük bakım ve kirlilik ve gürültü yaratmaması gibi avantajları nedeniyle dünya çapında en yaygın olarak benimsenen kaynaktır. 1822’de Alman bilim adamı Thomas, fotovoltaiik fenomeni keşfetmiş, ancak başlangıçta bunu basitçe manyetik bir etki olarak görmüştü. Charles, Thomas’ın etkisini tersine çevirerek elektrikten ısı veya soğuk ürettiğinde bile güneş hücreleri bir laboratuvar deneyi olarak kaldı. Edmond Becquerel, güneş hücrelerinin fiziksel fenomenini ilk kez 1839’da fark etti; bu fenomen artık güneş enerjisinin doğrudan elektrik enerjisine dönüştürülmesi olarak kabul edilmektedir. Güneş hücresi endüstrisi 1930’larda ilerlemeye başladı.

Jeff Rossi termoelektrikle çalışmış ve güneş kollektörlerini jeneratörleriyle eşleştirerek güneş ışığından elektrik elde etti. Çeyrek asır sonra, Bell Labs %4 verimlilikle silikon kullanan modern güneş hücreleri geliştirdi. Bu hücrelerin telefon hatlarına güç sağlamak için ilk uygulaması 1955’te Georgia’da gerçekleşti. 1957’ye gelindiğinde, küçük diziler uçuş kontrollerine güç sağlamak için ABD Donanması reaktörlerinde kullanıldı ve daha sonra ordu bunları daha büyük uydularda kullandı. Ancak, bu hücrelerin üretimi yalnızca iki üreticiyle sınırlı kaldı.

1970’lerin başında petrol fiyatlarındaki artışla birlikte ABD hükümeti güneş hücreleri de dahil olmak üzere güneş enerjisi geliştirmek için hızlandırılmış bir program başlattı. 1975’e kadar ABD araştırma ve geliştirme çalışmaları öncelikle hücre maliyetlerini düşürmeye odaklandı. Japonya ve birkaç Avrupa ülkesi de kendi güneş enerjisi araştırma girişimlerini başlattı. 1978’de ABD Başkanı’nın onayının ardından güneş araştırma bütçesi 6 milyon dolardan 20 milyon dolara çıktı. Enerji Araştırma ve Geliştirme Ajansı ve Güneş Enerjisi Araştırma Enstitüsü’nün kurulması güneş hücresi gelişimini hızlandırmaya yardımcı oldu ve 1982’ye kadar önemli bir ilerleme kaydetti. ABD hükümeti güneş hücresi araştırmalarına 500 milyon dolardan fazla yatırım

yaptıktan sonra, küresel üreticiler yılda yaklaşık 60 megavat güneş modülü üretti ve bunların çoğu uzaktan veya bağımsız uygulamalarda kullanıldı.

Fotovoltaik kaynakların kullanımını optimize etmek için, güneş hücresinin doğru bir modelini geliştirmek esastır. Daha kesin bir model, gerçek dünya sonuçlarıyla daha iyi eşleşen daha doğru hesaplamalar ve simülasyon sonuçları elde edilmesini sağlar. Zamanla, güneş hücreleri için çok sayıda model önerilmiştir, ancak tek diyotlu ve iki diyotlu modeller en yaygın kullanılanlardır.

Uygun model parametrelerini bulmak, PV parametrelerini değerlendirmek için zorlu bir optimizasyon problemidir. Genel olarak, klasik optimizasyon algoritmaları optimum çözümü bulamaz. Yeni meta-sezgisel algoritmalar, küresel ve yerel aramada daha iyi yetenekler göstermiş ve problem alanını daha optimum şekilde aramıştır. Genetik ve parçacıklar gibi optimizasyon yöntemleri, arama için temel mekanizmalar kullanırken, bir PV'nin parametrelerini optimize etmek, birkaç değişkeni olan karmaşık bir problemdir. Bu araştırma, güneş hücrelerinin verimliliğini artırmak ve parametrelerini optimize etmek için yeni bir optimizasyon yaklaşımı sunmaktadır.

1.2 Fotovoltaik Teknolojisinin Evrimi ve Küresel Etkisi

Küresel enerji piyasası, son birkaç yılda geleneksel enerji kaynaklarından daha temiz ve yenilenebilir alternatiflere doğru istikrarlı bir şekilde hareket ederek bir paradigma değişimine tanık oldu. Bu alternatifler arasında, güneş fotovoltaik (PV) teknolojisi, sürdürülebilir enerji arayışının temel taşı olarak ortaya çıktı. PV teknolojisindeki hızlı gelişme, öncelikle sera gazı emisyonlarını azaltma, enerji güvenliğini sağlama ve artan küresel enerji talebini karşılama ihtiyacından kaynaklandı. Güneş panellerinin konut, ticari ve endüstriyel sektörlerde dağıtımı, özellikle yüksek güneş ışınımına sahip bölgelerde ivme kazandı.

Fotovoltaik teknolojisi, erken dönemde silikon tabanlı hücrelerden modern zamana ince film ve çoklu bağlantı konfigürasyonlarına kadar birkaç nesil boyunca evrimleşmiştir. Özellikle monokristal ve polikristal tipler olmak üzere silikon tabanlı güneş hücreleri, verimlilik ve maliyet arasındaki denge nedeniyle pazarda baskın olmaya devam etmektedir. Ancak, malzeme bilimi, nanoteknoloji ve yarı iletken

tasarımındaki sürekli gelişmeler, PV sistemlerinin performansını, dayanıklılığını ve maliyet etkinliğini önemli ölçüde iyileştirmiştir. Dahası, perovskit ve organik PV hücreleri gibi yeni ortaya çıkan malzemeler, hafif, esnek ve oldukça verimli alternatifler sunma potansiyelleri nedeniyle dikkat çekmektedir.

İklim değişikliğiyle mücadele için küresel çabalar yoğunlaştıkça, güneş enerjisinin rolü giderek daha kritik hale gelmektedir. Uluslararası Yenilenebilir Enerji Ajansı'na (IRENA) göre, PV kurulumlarının 2050 yılına kadar toplam yenilenebilir enerji üretiminin %40'ından fazlasını oluşturması beklenmektedir. Bu öngörülen büyüme, özellikle performans optimizasyonu ve parametre tahminiyle ilgili alanlarda PV teknolojisinde sürekli inovasyona olan acil ihtiyacın altını çizmektedir.

1.3 PV Sistemlerinde İleri Optimizasyon İhtiyacı

Güneş enerjisi dağıtımındaki etkileyici büyümeye rağmen, PV sistemlerinin verimliliğini en üst düzeye çıkarmada zorluklar devam etmektedir. Temel zorluklardan biri, değişen çevre koşulları altında PV hücrelerinin ve modüllerinin davranışını doğru bir şekilde modellemektir. Işınım, sıcaklık ve gölgeleme gibi faktörler, PV sistemlerinin çıktı performansını önemli ölçüde etkileyebilir ve gerçek zamanlı tahmin ve ayarlamayı gerekli hale getirir.

Bu bağlamda, optimizasyon algoritmaları parametre tahmini, model uyumu ve performans iyileştirmede hayati bir rol oynamaktadır. Eğri uydurumu, analitik modelleme ve sayısal hesaplama gibi geleneksel yöntemler, ileri derece doğrusal olmayan, çok değişkenli ve dinamik PV sistemleriyle çalışırken sınırlı yetenekler sunar. Bu yöntemler genellikle çeşitli veri kümeleri arasında küresel optimizasyon gerektiren senaryolarda yetersiz kalır.

Bu sınırlamaları ele almak için metasezgisel algoritmalar PV parametre tahmininde yaygın uygulama kazanmıştır. Doğal olaylardan ve biyolojik davranışlardan ilham alan bu algoritmalar, sağlam küresel arama yetenekleri, karmaşık ortamlara uyum sağlama ve yerel optimumlardan kaçınma yeteneği sunar. Bu tür tekniklerin entegrasyonu, model parametrelerinin daha doğru ve verimli bir şekilde

tanımlanmasını sağlayarak gelişmiş sistem performansına, iyileştirilmiş enerji tahminine ve PV sistem tasarımı ve operasyonunda daha iyi karar almaya yol açar.

1.4 Optimizasyon Algoritmalarının Sınıflandırılması ve Karşılaştırılması

Metasezgisel optimizasyon teknikleri genel olarak popülasyon tabanlı ve yörünge tabanlı yöntemler olarak sınıflandırılabilir. Genetik Algoritma (GA), Parçacık Sürüsü Optimizasyonu (PSO), Gri Kurt Optimizasyonu (GWO) ve Balina Optimizasyon Algoritması (WOA) gibi popülasyon tabanlı algoritmalar, çözüm alanını yinelemeli olarak keşfetmek için sosyal veya biyolojik süreçleri simüle eder. Bu algoritmalar yüksek boyutlu problemler için oldukça uygundur ve güçlü keşif yetenekleri sergiler.

Öte yandan, yörünge tabanlı algoritmalar tek bir çözüm kullanır ve bunu matematiksel modeller veya sezgisel yöntemlere dayanarak yinelemeli olarak iyileştirir. Genellikle daha hızlı olsa da, bu yöntemler erken yakınsama veya yerel optimumlara sıkışma gibi sorunlar yaşayabilir.

Son araştırmalar, mevcut algoritmaları hibritleştirme, parametre ayarlama ve kaos teorisi ve karşıtlık tabanlı öğrenme gibi ek mekanizmaların dahil edilmesiyle geliştirmeye odaklanmıştır. Bu geliştirmeler, herhangi bir optimizasyon stratejisinin başarısı için çok önemli olan keşif (yeni alanlar arama) ve sömürü (mevcut çözümleri iyileştirme) arasında bir denge kurmayı amaçlamaktadır.

Bu tezde önerilen Coati Optimizasyon Algoritması (COA), alanda yeni bir gelişmeyi temsil etmektedir. Koatilerin akıllı avlanma ve kaçış davranışlarından ilham alan COA, dinamik adaptasyon ve çift fazlı arama yetenekleri sergilemektedir. COA'ya kaos teorisi ve karşıtlık tabanlı öğrenmenin dahil edilmesi, yakınsama hızını ve çözüm doğruluğunu önemli ölçüde artırarak onu PV parametre optimizasyonu için ideal bir aday haline getirmektedir.

1.5 Enerji Politikası ve Ulusal Altyapı ile Entegrasyon

PV sistemlerinin optimizasyonu yalnızca teknik bir zorluk değil, aynı zamanda enerji politikası ve altyapı planlamasında stratejik bir bileşendir. Dünya çapındaki

hükümetler, iklim hedeflerini karşılamak ve uzun vadeli enerji dayanıklılığını sağlamak için yenilenebilir enerji entegrasyonu için iddialı hedefler belirlemektedir. Örneğin, Avrupa Birliği'nin "Fit for 55" girişimi, 2030 yılına kadar net sera gazı emisyonlarını en az %55 oranında azaltmayı hedeflemekte ve güneş enerjisi bu hedefe ulaşmada kritik bir rol oynamaktadır.

Gelişmekte olan ülkelerde güneş enerjisi, özellikle şebeke dışı ve kırsal bölgelerde enerji erişimini genişletmek için dönüştürücü bir fırsat sunmaktadır. Bu tür bağlamlarda uygun maliyetli ve güvenilir güneş enerjisi kurulumları tasarlamak için PV sistemlerinin doğru modellenmesi ve optimizasyonu esastır. Dahası, akıllı şebekelerin ve enerji depolama sistemlerinin ortaya çıkmasıyla, şebeke istikrarını ve verimli güç dağıtımını sağlamak için PV parametrelerinin gerçek zamanlı optimizasyonu giderek daha önemli hale gelmektedir.

Önerilen COA tabanlı yaklaşım, PV sistem tasarımının ulusal ve bölgesel enerji stratejileriyle uyumlu hale getirilmesinde etkili olabilir. Doğru parametre tahmini sağlama yeteneği, daha güvenilir performans tahminlerine, optimize edilmiş sistem boyutlandırmasına ve azaltılmış operasyonel maliyetlere yol açabilir; böylece enerji geçişinde karar vericileri, yatırımcıları ve mühendisleri destekler.

1.6 PV Sistemlerinde Akıllı Optimizasyonun Gelecekteki Potansiyeli

Yapay zeka, Internet of Things (IoT) ve uç bilişim gibi ortaya çıkan teknolojilerle bir araya gelmesi, güneş enerjisi sektörü için muazzam bir vaat taşımaktadır. Gerçek zamanlı veri toplama ve uyarlanabilir kontrol algoritmalarıyla donatılmış akıllı PV sistemleri, çevresel koşullara, kullanıcı talebine ve şebeke gereksinimlerine göre çalışmalarını dinamik olarak ayarlayabilir.

Örneğin, optimize edilmiş parametre eğilimlerine dayalı öngörücü bakım, PV modüllerinin ömrünü önemli ölçüde uzatabilir ve kesinti süresini azaltabilir. Optimizasyon algoritmalarıyla desteklenen akıllı invertörler ve şarj kontrol cihazları, verimliliği en üst düzeye çıkarmak ve kayıpları en aza indirmek için voltajı, akımı ve güç akışını otonom olarak düzenleyebilir.

Ayrıca, dijital eşlerin (fiziksel PV sistemlerinin sanal kopyaları) uygulanması, COA gibi optimizasyon algoritmalarının entegre edilmesiyle büyük ölçüde geliştirilebilir. Bu dijital modeller, sürekli performans izleme, senaryo testi ve proaktif karar almaya olanak tanır ve bunların hepsi daha akıllı ve daha dayanıklı bir enerji altyapısına katkıda bulunur.

Önerilen COA'nın parametre tahminindeki üstünlüğünü göstererek bu tez, bu tür gelişmiş PV teknolojilerine entegrasyonunun temelini atmaktadır. Sağlamlığı, uyarlanabilirliği ve verimliliği onu gelecekteki araştırmalar ve endüstriyel dağıtım için umut vadeden bir araç haline getirmektedir.

1.7 Problem Tanımı

Yenilenebilir enerjiye olan artan talep, PV sistemlerinin optimizasyonu konusunda kapsamlı araştırmalara yol açmıştır. Ancak, sistemin doğrusal olmayışı ve karmaşıklığı nedeniyle PV modüllerinin parametrelerini doğru bir şekilde tahmin etmek önemli bir zorluk olmaya devam etmektedir. Sıcaklık değişimleri, ışık yoğunluğu ve radyasyon açıları gibi faktörler PV modül performansını etkileyerek parametre optimizasyonunu enerji verimliliğini artırmanın önemli bir yönü haline getirir. Sayısal ve analitik yaklaşımlar da dahil olmak üzere geleneksel optimizasyon yöntemlerinin optimum parametre ayarı elde etmede sınırlamaları vardır. Bu sınırlamaların üstesinden gelmek için metasezgisel algoritmalar giderek daha fazla araştırılmaktadır, ancak birçoğu hala erken yakınsama ve optimum olmayan çözümlerden muzdariptir. Bu nedenle, optimum enerji dönüşümü ve verimliliğini garanti eden PV modül parametrelerini doğru bir şekilde tahmin edebilen gelişmiş bir optimizasyon tekniğine acil ihtiyaç vardır.

1.8 Problem Çözümü

PV parametre tahminindeki sınırlamaları ele almak için bu çalışma, Coati Optimizasyon Algoritması'na (COA) dayalı yeni bir optimizasyon tekniği sunmaktadır. COA algoritması, koatilerin doğal avlanma ve kaçış davranışlarından esinlenmiştir ve küresel ve yerel arama yeteneklerini geliştirmek için karşıtlık tabanlı öğrenme ve kaos teorisi ile geliştirilmiştir. Bu yaklaşım, PV modül performansını

optimize ederek daha doğru ve güvenilir bir parametre tahmin süreci sağlar. COA'nın güçlü yönlerinden yararlanarak, önerilen yöntem Kök Ortalama Kare Hatası (RMSE) değerlerini en aza indirir, hesaplama karmaşıklığını azaltır ve PV parametre kestiriminin kararlılığını iyileştirir. Mevcut optimizasyon yöntemleriyle yapılan deneysel karşılaştırmalar, önerilen tekniğin üstün performansını göstererek gerçek dünya PV uygulamalarında etkinliğini doğrulamaktadır.

1.9 Araştırmanın Amacı

Bu araştırmanın birincil amacı, PV modül parametrelerini tahmin etmek için gelişmiş bir optimizasyon tekniği geliştirmek ve doğrulamak, böylece güneş enerjisi dönüşümünün verimliliğini ve güvenilirliğini artırmaktır. Belirlenen hedefler şunlardır:

- Karşıtlık temelli öğrenme ve kaos teorisini birleştiren gelişmiş bir COA algoritması tasarlanması.
- Önerilen algoritmanın SDM, DDM ve PV modüllerinde parametre tahmini için uygulanması.
- Önerilen yöntemin mevcut optimizasyon algoritmalarına göre performansının değerlendirilmesi.
- PV parametre tahmininde hata oranlarının azaltılması ve hesaplama verimliliğinin artırılması.
- Optimize edilmiş PV sistemleri aracılığıyla yenilenebilir enerji teknolojilerinin ilerlemesine katkıda bulunmak.

1.10 Araştırmanın Yaklaşımı

Araştırma, PV parametre tahmini ve optimizasyon teknikleri üzerine kapsamlı bir literatür incelemesiyle başlayan sistematik bir yaklaşımı takip eder. Bir sonraki adım, performansı artırmak için karşıtlık tabanlı öğrenme ve kaos teorisini entegre ederek

COA tabanlı optimizasyon sistemini tasarlamayı içerir. Önerilen algoritma daha sonra MATLAB’da uygulanır ve burada etkinliği üç PV modeli üzerinde test edilir: SDM, DDM ve PV modülleri. Karşılaştırmalı analizler, RMSE, hesaplama verimliliği ve kararlılığa dayalı performansı değerlendirerek kıyaslama optimizasyon yöntemlerine karşı yürütülür. Sonuçlar, sağlamlık ve güvenilirliği sağlamak için Friedman sıralama testi kullanılarak istatistiksel olarak doğrulanır. Son olarak, bulguların çıkarımları tartışılır ve gelecekteki iyileştirmeler için öneriler sunulur.

1.11 Araştırmanın Motivasyonu

Bu araştırmanın motivasyonu, sürdürülebilir ve verimli enerji çözümlerine olan acil ihtiyaçtan kaynaklanmaktadır. Yenilenebilir enerjiye olan bağımlılığın artmasıyla, PV sistemlerini optimize etmek enerji dönüşüm verimliliğini en üst düzeye çıkarmak için kritik hale gelmektedir. PV parametre tahmini için geleneksel yöntemler, PV modüllerinin karmaşık ve doğrusal olmayan özelliklerini ele alamamaları nedeniyle genellikle yetersiz kalmaktadır. Metasezgisel algoritmalar bu zorlukların üstesinden gelmede umut vadetmektedir, ancak daha yüksek doğruluk ve verimlilik elde etmek için daha fazla iyileştirme gerekmektedir. Bu çalışmada sunulan COA tabanlı optimizasyon yaklaşımı, PV parametre tahmini için daha sağlam ve etkili bir çözüm sağlayarak bu boşluğu doldurmayı amaçlamaktadır. PV sistemlerinin verimliliğini artırarak, bu araştırma sürdürülebilir enerji geliştirme ve fosil yakıtlara olan bağımlılığı azaltma gibi daha geniş hedeflere katkıda bulunmaktadır.

1.12 Çalışmanın Sınırlamaları (Avantajlar ve Dezavantajlar)

Önerilen COA tabanlı optimizasyon yaklaşımı önemli avantajlar sunarken, belirli sınırlamalarının olduğu kabul edilmelidir. Başlıca avantajlarından biri, mevcut optimizasyon tekniklerinden daha iyi performans gösteren son derece doğru PV parametre tahmini sağlama yeteneğidir. Karşıtlık tabanlı öğrenme ve kaos teorisinin dahil edilmesi, algoritmanın keşif ve sömürü yeteneklerini daha da artırarak erken yakınsama riskini azaltır. Ek olarak, önerilen yöntem daha düşük RMSE değerleri ve iyileştirilmiş kararlılık göstererek onu PV optimizasyonu için güvenilir bir seçim haline getirir.

Ancak çalışmanın bazı dezavantajları da vardır. COA algoritmasının hesaplama karmaşıklığı, kaos teorisi ve karşılıklı tabanlı öğrenmede yer alan ek hesaplamalar nedeniyle geleneksel yöntemlerden daha yüksektir. Bu, büyük ölçekli PV sistemleri için daha uzun işlem sürelerine neden olabilir. Dahası, algoritmanın performansı, optimum sonuçlar için ince ayar gerektirebilecek ilk parametre ayarlarına bağlıdır. Gelecekteki çalışmalar, uyarlanabilir parametre seçimi mekanizmalarını dahil ederek ve daha fazla verimlilik iyileştirmesi için hibrit yaklaşımları keşfederek bu sınırlamaları ele almaya odaklanmalıdır.

1.13 Araştırmanın Katkıları

Bu tezin başlıca katkıları şunlardır :

- SDM, DDM ve PV güneş hücresi modellerinin parametre optimizasyonu
- Güneş hücrelerinin verimliliğinin artırılması
- PV cihazlarının verimliliğini artırmak için bir Coati optimizasyon algoritmasının (Dehghani vd., 2023) versiyonunun sunulması
- Karşılıklı öğrenme için geliştirilmiş bir Coati optimizasyon algoritması sürümünün sunulması
- PV modellerinin parametre tahmini ve yeni meta-sezgisel yöntemlerle karşılaştırılması
- Kaos teorisiyle geliştirilmiş bir Coati optimizasyon algoritması versiyonunun sunulması

1.14 Tezin Organizasyonu

Bu araştırma çalışması 5 bölümde derlenmiş ve sunulmuştur. Bölüm 2, güneş hücrelerini ve bileşenleri ile PV cihaz parametrelerinin gözden geçirilmesini optimize etmek için ilgili çalışmaları tanıtmaktadır. Bölüm 3, PV parametrelerinin optimum


tahmini için Coati optimizasyon algoritmasını iyileştirmek amacıyla önerilen yöntemi göstermektedir. Bölüm 4, testleri ve uygulamayı açıklar ve sonuçlar analiz edilerek değerlendirilir. Son olarak, Bölüm 5 sonuçları ve gelecekteki çalışmaları içerir.



2. LİTERATÜR TARAMASI

2.1 İlgili Çalışmalar

En önemli güneş enerjisi üretim sistemi bileşeni olan PV hücresi, güneş enerjisini elektriğe dönüştürür. Aslında, bir P-N bipolar cihaza güneş hücresi denir. Bunun nedeni, N düzleminin atomların güneş ışığının yakınında yaydığı negatif yüklü elektronlara sahip olmasıdır. Öte yandan, P düzleminin pozitif yüklü delikleri vardır ve negatif bir yükü emebilir. Şekil 2.1, iki P ve N plakalı bir güneş hücresinin yapısını göstermektedir.




Şekil 2.1 Bir PV hücresinin yapısı (Kirubakaran vd., 2022)

Güneş pilleri, güneş enerjisini elektrik enerjisine aşağıdaki süreci izleyerek dönüştürür. Bu süreç fotovoltatik etkiye dayanır:

- Fotonlar, P-N birleşim bölgesinde soğurularak elektron-boşluk çiftleri oluşturur.
- Güneş ışığıyla uyarılan yük taşıyıcıları harici bir güneş devresinde ayrılır; delikler P bölgesinden birleşim bölgesini terk ederek devre boyunca hareket eder ve ardından tekrar elektronlarla birleşir.

- Ayrılmış elektronlar, elektrik devresinde elektrik akımını taşımak için kullanılır.
- Elektronların deliklerle yeniden birleşmeden önce devreden hızlıca geçip akım üretmesini sağlamak için, N katmanının P tipi katmandan daha ince olması gerekir.
- Yüzey yansımalarını azaltmak ve yarı iletken malzemeye daha fazla ışığın geçmesini sağlamak amacıyla, genellikle N katmanına yansıma önleyici kaplama uygulanır.


Şekil 2.2 de, güneş ışığından elektrik üretimi için bir PV sistemin yapısını göstermektedir. Önerilen yapı, standart bir şebeke bağlantılı inverterdir. Şebeke bağlantılı bir güneş PV sisteminde, enerji depolama için bir batarya deposu bulunmaz. Güneş panelleri, gün boyunca ihtiyaç duyulandan daha fazla elektrik üretir. Bu nedenle, fazla elektrik bataryalarda depolanmak yerine şebekeye geri verilir.



Şekil 2.2 Bir PV sisteminin yapısı ve bileşenleri (Awasthi vd., 2020)


Son birkaç yılda, PV sistemleri üzerine yapılan çalışmalar önemli ölçüde artmıştır. PV sistemleri üzerine yapılan çalışma sayısındaki artış, bu sistemlerin sektördeki önemini göstermektedir. Şekil 2.3, 2010 ile 2020 yılları arasında yalnızca PV sistemlerinin izlenmesi üzerine yayınlanan makale sayısını göstermektedir. 2010 ile 2020 yılları

arasında kabul edilen makale sayısındaki artış eğilimi, PV sistemlerinin önemini göstermektedir (Ansari vd., 2021).




Şekil 2.3 PV sistemlerinin izlenmesi alanında artan çalışmalar (Ansari vd., 2021)

Uluslararası Enerji Ajansı (IEA), 2020 yılında yenilenebilir enerjinin küresel elektrik üretiminin yaklaşık %28'ini karşılayacağını öngörmüştür. Tahminlere göre, yeni eklenen elektrik kapasitesinin %90'ı yenilenebilir kaynaklardan gelmektedir. 2010 yılından bu yana fotovoltaik (PV) elektrik üretim kapasitesi 18 kat artmıştır. Erişilebilirliği, düşük bakım maliyetleri, çevre dostu olması ve yenilenebilir doğası nedeniyle PV sistemleri çok ilgi görmüştür. Herhangi bir PV sisteminden en iyi ve en etkili performansı elde etmek için maksimum güç noktası (MPP) arama tekniği çok önemlidir. MPP araması, güneş enerjisinin elektriğe dönüştürülmesini mümkün kılar. Bir optimizasyon modülüne sahip PV sistemlerinin blok diyagramı Şekil 2.4'te gösterilmiştir (Sarwar vd., 2022).



Şekil 2.4 PV sistemlerinin optimizasyonu (Sarwar vd., 2022)

Maksimum Güç Noktası İzleme (MPPT) ve Darbe Genişliği Modülasyonu (PWM), iki PV sistem bileşenidir. MPPT, güneş panelinden akülere giden güç akışını izlemeye ve yönetmeye yardımcı olur. Bu teknoloji, elektronik akü için gereken düşük voltajı üretmek üzere DC çıkışının yüksek voltaj değerini modüle eder. Güneş panellerinin çıkışı hava durumuna bağlı olarak değişir. MPPT şarj kontrolörleri, şarj verimliliğini artırmak için akü voltajını güneş paneli voltajıyla eşleştirebilir. Bu sistemlerdeki voltaj ve akımı denkleme uygun şekilde dengeleyerek, güneş panellerinin tüm potansiyeli kullanılır ve $P = V \times I$ ile gösterilir. Örneğin, sisli havalarda voltajı korumak için panellerden çekilen elektrik azaltılır. Güneşli havalarda şebekeden daha fazla elektrik çekilir. MPPT, belirli koşullar altında bir PV modülünden maksimum gücü çeken bir şarj kontrol tekniğidir. MPP veya maksimum güç voltajı, bir PV modülünün en fazla elektrik üretebileceği noktadır. Maksimum güç, ortam sıcaklığından, güneş radyasyonundan ve güneş hücresi sıcaklığından etkilenir. IV eğrisi aracılığıyla gösterilen güneş hücrelerinin voltaj-akım değişimleri, MPPT güneş yükleme kontrolörleri kullanılarak bulunur. Şekil 2.5, bir PV sisteminin çıkışının akım ve voltaj diyagramını gösterir (Olajide vd., 2024).



Şekil 2.5 PV sistemlerde akım ve gerilim diyagramı (Gugulothu vd., 2022)

MPPT ünitesinin işlevi, en yüksek güç çıkışını üretmek için çıkış akımını ve voltajını seçmektir. MPPT cihazı kullanılacak en iyi voltajı ve akımı belirler ve bunları sırasıyla VMPP ve IMPP olarak görüntüler. Herhangi bir güneş enerjisi sisteminin PV modüllerinden mümkün olan en fazla enerjiyi alabilmesi için bir MPPT güneş yükleme kontrolörü gereklidir. Bu cihaz, bir PV modülünü maksimum güç noktasına çok yakın bir voltajda veya bu durumda sistemden alınabilecek en büyük güç miktarında çalışmaya zorlar. MPPT güneş yükleme kontrolörü, sistem karmaşıklığını azaltırken verimliliği artırır. PV çıkış gücü DC-DC dönüştürücüyü hemen ayarladığından aynı anda birçok enerji kaynağı kullanır. Bir yükleme kontrol cihazı olan PWM kullanılarak güneş paneli şebekesi ve piller bir elektrik anahtarı gibi bağlanır. Pil şarj olduğunda, bu alet anında açılır veya kapanır ve şarj akımını düşürür. PWM algoritması, pil voltajı aşırı şarjı ve pilden gaz salınımını önlemek ve en kısa sürede pile maksimum gücü sağlamak için ayar noktasına ulaştığında şarjı kademeli olarak azaltır. Bu teknolojinin faydaları arasında, şarj verimliliğini korurken pilin toplam kapasitesinin korunması ve pilin yeniden şarj sürecinin hızlandırılması yer almaktadır (Hamdan vd., 2025; Sathish vd., 2025).

MPPT kontrol cihazları daha pahalı olsa da, daha fazla panel esnekliği sunarlar. Akım amperleri, PV modül voltajının akü grubuna uyacak şekilde düşürülmesiyle artırılır. Son olarak, amperajın hızlandırılması, akünün daha hızlı şarj olmasına neden olur. Bu güneş yükleme kontrol cihazlarını otomatik olarak ayarlamak için $P = V \times I$ denklemi kullanılmıştır. PWM sistemlerinin aksine, bu sayede aküyü şarj etmek için verimlilikten ödün vermeden daha fazla güç elde edilebilir. MPPT kontrol cihazı sayesinde panel dizisi batarya deposunda daha yüksek bir voltaja sahip olabilir (Arsad vd., 2025). MPPT ünitesinin çıkış akımı ve voltaj değerleri, optimizasyon ve meta-sezgisel yaklaşımlar kullanılarak belirlenir ve bu çalışmalardan bazıları aşağıda belirtilmiştir.

Bir çalışmada, güneş fotovoltaiik maksimum güç noktası denetleyicileri için bir Gri Kurt Optimizasyonu (GWO) algoritması önerilmiştir. Elektrik üretmek için güneş fotovoltaiik enerjisini kullanan sistemler çok yaygındır. Ancak, bunların ne kadar iyi performans gösterdikleri, elementlerden, radyasyondan, sıcaklıktan ve havanın etkisinden etkilenir. Bu sorunların üstesinden gelmek için, maksimum MPPT yaklaşımları oluşturulmuştur. Bu araştırma, GWO yöntemine dayanarak, geliştirilmiş bir MPPT denetleyicisi önermektedir. Deneylere göre yaklaşımları Değiştirme ve Gözlemleme ve Artımlı İletkenlik algoritmalarından daha iyi performans göstermektedir. Testler, teknolojilerinin ortalama olarak diğer denetleyicilerden %6 daha fazla güç ürettiğini ortaya koymaktadır. Dahası, önerilen model Artımlı İletkenlik ve Değiştirme ve Gözlemleme denetleyicileriyle karşılaştırıldığında, önerilen modelin verimliliğin ortalama olarak %3 daha yüksek olduğu görülmüştür.

Fotovoltaiik modelin parametrelerini optimize etmek için bir strateji, Kuzey Goshawk Optimizasyonu'nu (NGO) uygulayan başka bir çalışmada sunulmuştur (El-Dabah vd., 2023). Üçlü diyot modelinin parametrelerini (PV modülü) belirlemek için bu araştırma, NGO olarak bilinen bir optimizasyon algoritması uygular. Mevcut çalışmada üç ticari PV modülü uygulanmıştır. Simülasyon sonuçları, NGO'nun hız ve doğruluk açısından diğer optimizasyon algoritmalarına kıyasla daha iyi performans gösterdiğini göstermektedir. Ayrıca, bu teknikle Canadian Solar CS6K-M modülünün maliyet fonksiyonu 0,000195'e düşürülebilir.

Mutlag vd. (2024)'nin çalışmasında, güneş fotovoltaik modellerinin parametrelerini diferansiyel evrim ve dizi arama optimizasyonu uygulayarak optimize etmeye yönelik bir strateji tartışılmaktadır. Fotovoltaik (PV) model, çok modellenli ve doğrusal olmayan bir spesifikasyona sahiptir ve bu da ideal değerlerini belirlemeyi zorlaştırır. Bu sorunu ele almak için kullanılan algoritmalar, sorunun doğrusal olmayan yapısı nedeniyle yerel optimumlarda kalmaya eğilimlidir. PV sisteminin akımı ve güç üretim performansı üzerindeki büyük etkileri nedeniyle, parametrelerin doğru tahmini çok önemlidir. İdeal PV parametre değerlerini çıkarmak için, bu çalışma Diferansiyel Evrim (DE) yöntemine dayalı gelişmiş bir Dizi Arama Optimizasyonu (QSO) sağlar. Yöntemleri, tek diyot, çift diyot ve PV modül modelleri gibi en iyi parametreleri elde etmek için genetik algoritmalar ve parçacıklar gibi yöntemlerden daha iyi performans gösterir.

Teferra vd. (2023) çalışmasında, verimliliği artırmak için Parçacık Sürüş Optimizasyonu (PSO) kullanan bulanık bir güneş PV ve rüzgar türbini sistemini tanıtmıştır. Bununla birlikte, bir güç tahmin modelini doğru bir şekilde oluşturmak, araştırmacının güneş ve rüzgar enerjisi kaynaklarının rastgele davranışını düzenlemesine olanak tanır. Bulanık mantığa dayalı güneş PV ve rüzgar tahmin algoritmaları, bu öngörülemez ve rastgele yönü daha iyi ele alabilir. Ayrıca tahmin modelinin performansı, sistemin kısıtlamalarını da artıran hibrit bulanık-PSO akıllı tahmini kullanılarak iyileştirilir. Yapılan testler, önerilen bulanık modelin, güneş ve rüzgar sistemlerinin gücünü artırmada Genetik Algoritma (GA) ile birlikte kullanılan bulanık modelden daha etkili olduğunu ortaya koymuştur. Patra vd. (2023)'nin çalışmasında ise, güneş enerjisiyle elektrik üretiminin optimizasyonu, geliştirilmiş MPPT teknikleri kullanılarak sunulmuştur. Bu çalışmada, fotovoltaik modülün parametrelerini optimizasyon yöntemleri ile optimize etmişlerdir.

Rayaguru vd. (2023)'nin makalesinde, Yarasa Algoritmaları (BA) ve Çekirge Optimizasyon Algoritmaları (GOA) temelli bir hibrit yaklaşım, güneş fotovoltaikleri aracılığıyla güç üretimini en üst düzeye çıkarmak için sunulmuştur. Bu araştırma, XSG denetleyicisini kullanarak PV'den maksimum gücü çıkarmak için birleşik bir meta-sezgisel algoritma kullanmıştır. Deney sonuçlarına göre önerilen algoritma güç

çıkarmada iyi bir performans göstermiş ve BA ve GOA algoritmalarına göre güç artırmada daha yetenekli ve etkili olduğu görülmüştür.

Yeni bir optimizasyon tekniğinin güneş modüllerindeki ideal parametreleri tahmin etmekteki kullanımı Keddouda vd. (2024)'nin çalışmasında bahsedilmiştir. Bu çalışma, PV sistemlerinin model parametrelerini edinmek için Harris Hawks Optimizasyonunu (HHO) dikkate alır. Değiştirilmiş HHO, geleneksel yönteme kıyasla dünya çapında bir arama kapasitesi, yüksek verimlilik ve yüksek yakınsama hızı sunar. Ayrıca, çalışmalar HHO yönteminin voltaj gücü (PV) ve akım-voltaj (IV) özellikleri için daha düşük bir hata değerine sahip olduğunu ortaya koymuştur.

Patra A. vd. (2023)'ne ait bir diğer araştırma, Wall's algoritmasının geliştirilmiş versiyonuyla VPFOTADF kontrolörü kullanılarak fotovoltaiik şebekeye bağlı sistemin değerlendirilmesini ve iyileştirilmesini sunar. Bu makale, harmonik bozulmayı azaltmak ve grup zekası kullanarak fotovoltaiik şebekeye bağlı güneş sisteminin performansını iyileştirmek için güneş hücreleri tasarlamayı amaçlamaktadır. Güneş PV sistemi, yükseltici dönüştürücü, fotovoltaiik dizi, çok seviyeli invertör ve denetleyici gibi bileşenlere sahiptir. Bu çalışma, geliştirilmiş WOA algoritmasını kullanarak yükseltici dönüştürücüyü optimize eder. Değerlendirme ve testler, yöntemlerinin üretim kapasitesini WOA algoritmasından daha fazla artırdığını göstermiştir.


Başka bir çalışmada, tek diyotlu bir fotovoltaiik güneş hücresi modelinin parametrelerini çıkarmak için geliştirilmiş bir Aritmetik Optimizasyon Algoritması (AOA) önerilmiştir (Abbassi vd., 2022). Deneyisel bulgular, IAOA sonuçlarının AOA kullanılarak elde edilenlerden daha etkili ve doğru olduğunu göstermektedir.

Güneş PV modelinin optimum parametrelerini Şempanze Optimizasyon Algoritması (ChOA) kullanılarak belirlemek için bir yöntem, Bo vd. (2022)'nin makalesinde belirtilmiştir. Tek diyot, çift diyot, üçlü diyot ve PV modül modelleri dahil olmak üzere hassas ve güvenilir PV modelleri üretmek için bu araştırma, doğadan ilham alan ChOA adı verilen yeni bir teknik önermektedir. PV modellerinin parametrelerini optimizasyon yöntemlerini kullanarak tahmin etmedeki temel zorluk, yerel optimuma yakınsamadır. Bu nedenle bu çalışma, PSO'nun en iyi yönlerini ve yerel bir arama

tekniğini birleştirir. Testler, önerilen algoritmalarının sıklıkla kullanılan üç ticari modülün parametrelerini optimize etme açısından EHHOA, BMO, FPSO, CBBO ve GOTLA algoritmalarından daha iyi performans gösterdiğini ortaya koymuştur: KC200GT, SW255 ve çok kristalli SM55.

Optimum parametrenin bulunması son yıllarda yapılan en büyük araştırmadır (Ab-BelKhair vd., 2020; Abed vd., 2017; Elshara vd., 2024; Hameed vd., 2023, 2024; Nureddin vd., 2020). Ayrıca bu metasezgisel yöntemler tıp bilimlerinde de uygulanmıştır (Abdullah vd., 2018, 2020; Aljanabi vd., 2018, 2020; Al Shalchi ve Rahebi, 2022; Rahebi, 2011; Rahebi ve Hardalaç, 2014, 2016). En güncel metasezgisel yöntemler Hussein vd. (2022a), Hussein vd. (2022b) ve Memiş vd. (2024)'nin çalışmalarında tartışılmıştır.

Şekil 2.6'da görüldüğü gibi, 2011 yılında yenilenebilir enerji, ABD'deki tüm sektörlerde tüketilen toplam enerjinin %9'undan fazlasını oluşturuyordu. Bu durum, bu sektördeki her bir yenilenebilir enerji türünün katkısını göstermektedir.



Şekil 2.6 Tüm yenilenebilir enerjilerin katılım yüzdesi (Alemán-Nava vd., 2014)

Fotovoltaik kaynaklardan daha iyi faydalanabilmek için güneş hücresinin tam modelini bulmak çok önemlidir. Sunulan model ne kadar doğruysa hesaplamalar o kadar doğru olacak ve simülasyon sonuçları gerçekte elde edilen sonuçlara daha yakın olacaktır. Güneş enerjisi alanında kaydedilen ilerlemeyle birlikte güneş hücreleri için birçok model sunulmuştur ancak diğerlerinden daha fazla kullanılan iki model tek diyotlu ve iki diyotlu modellerdir.

2.2 Enerji Türleri

Energiler yenilenebilir ve yenilenemez (dayanılmaz) olmak üzere ikiye ayrılır.

2.2.1 Yenilenebilir Enerjiler

Yenilenebilir enerjiler, küresel bir dünya ve güneş olduđu takdirde var olacak enerjileri kapsar; güneş enerjisi, jeotermal enerji, rüzgar, su ve biyokütle gibi.

2.2.2 Yenilenemez Enerjiler

Genel olarak yenilenebilir özelliğe sahip 9 önemli enerji kaynağı Tablo 2.1’de sunulmaktadır.

Tablo 2.1 Önemli enerji kaynakları

Enerji türü	Tanımlar	Fırsatlar	Güçlü yönleri	İyileştirilmeye açık noktalar
Gelgit Enerjisi (Ramos ve Ringwood, 2016)	Gelgit enerjisinin yararlı enerji türlerine, özellikle de elektriğe dönüştürülmesiyle elde edilir.	Ülkedeki santrallerde üretililecek güç, başlangıçta düşünülenlerden çok daha fazladır.	Rüzgar ve güneş enerjisine göre çok daha temiz ve öngörülebilirdir.	Teknolojinin gelişmemiş olması nedeniyle diğer enerji türlerine göre maliyeti daha yüksektir. Konum kısıtlamaları bulunur. Aşırı gürültü nedeniyle deniz canlıları için ekolojik sorunlar yaratır.
Güneş Enerjisi (de Paulo ve Porto, 2018)	Güneş ışığının doğrudan fotovoltaik sistem kullanılarak veya dolaylı olarak yoğunlaştırılmış güneş enerjisi kullanılarak elektriğe dönüştürülmesine denir.	Ortadoğu ve Afrika gibi bölgelerde yaşam kalitesinin geliştirilmesi için çok ulaşılabilir.	Çok düşük işgücü ve ağ maliyetleri içerir. Uluslararası şirketler bu tür enerjiye ilişkin teknolojilerin geliştirilmesine odaklanmışlardır.	Verim düşüklüğü ve geniş arazi ihtiyacı bulunur. Planlama açısından öngörülemez.
Jeotermal Enerji (Liao vd., 2021)	Yer kabuğunda sondaj yaparak, yerin ısısından elde edilen enerjinin bir su sistemine aktarılıp buhar üretilmesi ve bu buharla çalışan buhar türbinleri aracılığıyla elektrik üretilmesidir.	Volkanik bölgelerde sondaj maliyetleri oldukça düşüktür. Fosil yakıtlı santraller sera gazlarının sekizde birini üretir. Az yer kaplar.	İzlanda'da 60'lı yıllardan bu yana operasyonel olarak kullanılmaktadır. Planlanabilir ve öngörülebilirdir. Dünyanın birçok yerinde mevcuttur.	Çok yüksek ağ ve insan kaynağı maliyetleri gerekir. Çok yüksek sondaj maliyetleri bulunur.
Droelektrik Enerji (Koç, 2014)	Bu türde sudan üretilen enerji, barajın arkasındaki su hacmine ve barajın kaynağı ile çıkışı arasındaki kot farkına bağlıdır.	Hem barajda hem de nehir ve akarsuda üretilir (sıvıların kinetik enerjisinden elektrik üretimi).	Çok temizdir. Dünyada teknolojinin kullanımının uzun bir geçmişi vardır. Öngörülebilir ve tahmin edilebilirdir.	Nehir ve su kaynaklarının yetersiz olduğu ülkelerde evrensel olarak kullanılması mümkün değildir. Barajların yapılmasıyla ortaya çıkan çevre sorunları vardır. Yüksek maliyetler gerekir.
Dalga Enerjisi (Morim vd., 2016)	Açık okyanustaki dalga enerjisi, okyanus yüzeyindeki rüzgar hareketiyle üretilir.	Genellikle rüzgar enerjisinden daha verimlidir.	Hem tatlı hem tuzlu tüm denizlerde bulunur.	Dalga enerjisi düzensiz, dalgalı ve düşük frekanslı bir yapıya sahip olup, şebekeye verilmeden önce 60 Hz frekansına dönüştürülmesi gerekmektedir.
Rüzgar Enerjisi (Chaurasiya vd., 2019)	Rüzgar enerjisi, rüzgar santrallerinde büyük miktarlarda üretilerek elektrik şebekesine bağlanır.	Rüzgar enerjisi bol miktarda bulunan, yenilenebilir ve temiz bir enerji olup dünyanın her yerinde mevcuttur.	Fosil yakıt enerjisi kullanımına göre daha az sera gazı salınımı yapmaktadır. Günümüzde dünyada çeşitli çiftlikler bulunmaktadır.	Öngörülemezdir. Çok fazla araziye ihtiyaç vardır. Ağ ve bakım ekipmanlarının maliyetleri yüksektir.
Biyokütle Enerjisi (Buratti ve Fantozzi, 2010)	Biyokütle, atıklar gibi biyolojik maddelerden elde edilen yenilenebilir bir enerji kaynağıdır.	Biyokütle kaynakları enerji üretimi için uygundur ve çok çeşitli materyaller içerir.	Atık üretim eğiliminin artması nedeniyle bu teknolojinin kullanımı ve gerekli kaynaklar, elektrik üretiminin planlanmasını kolaylaştırmaktadır.	Yanma, bazı çevresel kirleticilerin oluşumuna yol açabilir ve yanma için oksijen kullanılması gereklidir; bu nedenle, dünyada oksijen üretimi sürecinin anlaşılması dikkate alınmalıdır.

Kirletici gazların üretiminin azaltılmasıyla fosil yakıtlardan bir kilovatsaat elektrik enerjisi üretildiğinde ortalama 653 gram kirletici gaz ortaya çıkmaktadır.

Enerji arz güvenliğinin iyileştirilmesi, şüphesiz tüm ülkelerin ulusal güvenliğinin ana unsurlarından biridir. Enerjiye erişim gereklidir; enerji arz sisteminde meydana gelebilecek herhangi bir sorun, tüm ekonomik ve sosyal sektörlerde geniş çaplı aksamalara ve zararlara yol açacaktır. Bu nedenle ülkeler, bir veya iki enerji kaynağına bağımlılıktan kaçınmak ve zafiyetlerini mümkün olan en aza indirmek için enerji kaynaklarının çeşitlendirilmesini ana stratejilerinden biri olarak dikkate almalıdır (Shakya vd., 2023).

Dağıtılmış üretim ve ulusal enerji iletim ağlarına olan bağımlılığın azaltılması, ulusal elektrik ağı ile geniş doğal gaz ve petrol iletim ağlarının varlığı, ülkemizin en büyük ulusal sermayeleri arasında sayılmaktadır ve ulusal ekonomik gelişimimizin ve sosyal refahımızın büyük bir kısmı bu tür ağların varlığına borçludur. Aynı zamanda, uzun ağlar, tüm değerlerine rağmen ciddi şekilde savunmasızdır. Sel, deprem, heyelan, yoğun kar yağışı ve teknik sorunlar bu tehlikeler arasındadır. Uzun ağlara olan bağımlılık arttıkça, güvenlik faktörü azalacaktır. İşte bu nedenle, bugün dağıtılmış üretim, gelişmiş ülkelerin elektrik endüstrisinin en önemli stratejilerinden biri haline gelmiştir. Dağıtılmış üretim, ekonomik olarak daha fazla maliyet getirmediği gibi, şebeke kararlılığının artması sayesinde elektrik maliyetlerini de önemli ölçüde azaltacaktır (Mulenga vd., 2023; Nelson ve Starcher, 2018; Roose vd., 2022).

Yenilenebilir enerji teknolojilerinin (RET) nüfuz etme oranı, santrallerin inşası, bakımı ve sanayileşmiş ülkelere teknoloji satın alma ve transfer etme kapasitesi için gereken teknik bilginin eksikliği gibi faktörlerle sınırlandırılmıştır. Gelişmekte olan ülkelerin çoğu, yukarıdaki sorunu çözmek için uygun bir çözüm benimsemiş ve sanayileşmiş ve gelişmiş ülkelerle ikili veya çok taraflı yatırımlar yoluna gitmiştir. Yenilenebilir Enerji Teknolojilerinin (RET'lerin) daha fazla yaygınlaştırılması için yabancı yatırım çekme senaryosunun uygulanabilmesi adına gerekli koşul, bu senaryonun uygulanabilirliğini ve yatırımcının kârını garanti altına alacak teknik ve ekonomik standartların bulunmasıdır. Ne yazık ki, ülkede bu konuya gereken önem verilmemiştir ve bu durum, yenilenebilir enerji sektöründeki sorunların çözüm

anahtarı olabilir. Ülkenin geçim politikası, yalnızca enerji kaynaklarından elde edilebilecek enerji miktarına odaklanmakta, analizlerinde ise ülkenin uzun vadeli enerji arzı göz ardı edilmektedir. Aşağıda, yukarıda önerilen senaryo daha ayrıntılı bir şekilde açıklanmıştır. Enerji konusuyla ilgili herhangi bir politikanın arkasındaki felsefe, ülkenin kentsel ve kırsal bölgelerinde yaşam standartlarını iyileştirmeye yönelik bir değişimi hedeflemelidir. Bu yaklaşım göz önünde bulundurularak, söz konusu politikalar, kültürel geçmişi de dikkate alarak, hane halkının enerjiye yönelik sosyal ve ekonomik ihtiyaçlarını karşılayabilir. Halkın yeni yenilenebilir enerji projelerine dahil edilmesi de bu politikanın bir parçasıdır (Goggins vd., 2022).

Fotovoltaik paneller güç kaynağı sistemi için de kullanılır. Bu fotovoltaik sistemlerde, radyant enerji güneş hücreleri tarafından DC elektriğe dönüştürülür. Elde edilen elektriği kullanarak, DC ve AC tüketicilerinin ihtiyaç duyduğu elektrik enerjisi sağlanabilir (Tidjani ve Chandra, 2012). Fotovoltaik hücrelerin kurulumunun en büyük zorluklarından biri yerleşim açılarının belirlenmesidir, çünkü genellikle kentsel uygulamalarda fotovoltaik sistem kurulumcuları pratikte optimum açılar elde etmede sorunlarla karşılaşır.

Işınım enerjisinin mekanik mekanizmalar kullanılmadan doğrudan elektrik enerjisine dönüştürülmesi sonucunda ortaya çıkan olaya fotovoltaik fenomen denir. Bu fenomen, ışınım enerjisinin parçacık doğası hipotezine dayanır. Bu özelliği kullanan her sisteme fotovoltaik sistem adı verilir.

Fotovoltaik sistemler üç ana bölümden oluşur:

- Güneş enerjisini elektrik enerjisine dönüştüren güneş modülleri veya panelleri.
- Fotovoltaik sistemlerden elde edilen elektrik enerjisini tasarıma göre ve tüketicinin ihtiyacına uygun şekilde yöneten ve düzenleyen ara birim veya optimal güç bölümü.
- Tüketici veya tüketim miktarına göre tüm elektrikli tüketicileri kapsayan doğrudan veya alternatif elektrik yükü.

Fotovoltaik sistemin tasarımına başlamadan önce sistemin kullanım yeri ile ilgili bir araştırma ve çalışma yapılır. Uzman tasarımcılar istenilen yere giderek aşağıdakilere göre gerekli araştırmaları yaparlar:

- İşletme sırasında iş sağlığı ve güvenliğinin değerlendirilmesi,
- Güneş ışığına erişim miktarının değerlendirilmesi,
- Fotovoltaik dizilerin yerleştirildiği yerde radyasyon açısının ve yönünün belirlenmesi,
- Ekipmanın doğru yerleştirilmesini sağlamak için dizilerin yerleştirileceği alanın incelenmesi,
- Çeviricinin kurulum yerinin belirlenmesi,
- Kablolama yönteminin belirlenmesi,
- Panel kontrolör ekranlarının gerekliliğinin ve kurulum yerinin kontrol edilmesi.

Fotovoltaik sistemin tasarımında, diğer tasarımlarda olduğu gibi, genel tasarım prensipleri sabittir ve santralin konumundan, iklimden, deniz seviyesinden yükseklikten ve hava koşullarından bağımsızdır. Diğer sistemlerde olduğu gibi, bazı koşullar ünitenin çıkışını etkiler, bu yeni koşullar katsayılar olarak tanımlanır ve çıkışı artırır veya azaltır (Newbery vd., 2018).

Şebekeye bağlı fotovoltaik sistemlerin tasarımı, ulusal elektrik şebekesiyle aynı anda ve paralel olarak güç üretecek şekildedir. Bu yöntemde, fotovoltaik sistemler ile elektrik şebekesi arasında iki yönlü bir bağlantı vardır, böylece fotovoltaik sistemler tarafından üretilen DC güç yerel tüketimden fazlaysa, fazlalık ulusal elektrik şebekesine transfer edilir. Şebeke üzerinde uygulama çoğunlukla kentsel alanlarda ve elektrik şebekesine yakın yerlerde kullanılır. Avantajlarından biri elektrik tüketiminin azaltılması ve gündüz saatlerinde enerji talebini kabul edilebilir bir ölçüde karşılayabilmesidir. Bu nedenle, gece saatlerinde ve iklim koşulları nedeniyle güneş

ışığından yararlanmanın mümkün olmadığı zamanlarda, bölgenin ihtiyaç duyduğu elektrik, ulusal elektrik şebekesi tarafından sağlanır. Genel olarak üretilen elektrik, şebekeye bağlı sistemler için invertör tarafından dönüştürüldükten sonra özel iki yönlü sayaçlar kullanılarak ulusal elektrik şebekesine transfer edilir (Liu, 2018).

Şebekeden bağımsız üretim çoğunlukla şehirden veya elektrik şebekesinden uzak bölgelerde kullanılır ve hem gündüz hem gece boyunca elektriği tamamen bağımsız olarak sağlamaktan sorumludur. Bu üretimin avantajları ve dezavantajları şunlardır:

- Avantajları: Ulusal şebekeye ve yakıta ihtiyaç duymaz. Çevreyle uyumludur, çevreyi kirletmez. Ses kirliliği yoktur. Elektrik üretmek için suya ihtiyaç duymaz.
- Dezavantajları: Gün ve ay boyunca güneş radyasyonundaki değişikliklere bağımlıdır (Liu, 2018).

Her güneş enerjisi sistemi iki çok önemli parçadan oluşur, biri güneş panelleri ve diğeri enerji depolama pilleridir. Güneş panelleri güneş ışığından elektrik enerjisi üretmekten sorumludur, enerji depolama pilleri enerjiyi depolamaktan ve güneş ışığının panel tarafından alınmadığı saatlerde iletimden sorumludur.

Ayrıca güneş enerjisi sisteminde iki önemli parça daha vardır, bunlardan biri panellerin pili şarj etmesini kontrol eden şarj kontrol cihazı, diğeri ise panelin ürettiği elektriği ve pilde depolanan elektriği şehir elektriğine dönüştüren invertör veya konvertör olarak da adlandırılan mekanizmadır.

Her güneş panelinin çıkışı, genellikle üretici tarafından ürün kataloğunda yer alan belirli bir voltaj ve akım aralığına sahiptir. İstenilen panelin akımı veya voltajı diğeri elektrikli ekipmanlarla uyuşmuyorsa, istenen koşullara ulaşmak için birkaç panel seri veya paralel bağlanabilir. Ancak normalde panellerin maksimum enerjisine ulaşmak için bunların birbirine paralel yerleştirilmesi gerekir. Bu amaçla, her panelin pozitif ve negatif çıkışı diğeri panelin pozitif ve negatif çıkışına bağlanır ve son olarak bu pozitif ve negatif bağlantı pillerin şarjını kontrol etmekten sorumlu olan şarj kontrol cihazına bağlanır. Ayrıca, şarj kontrol cihazlarının bir çıkışı vardır, böylece güneş ışığını olduğu

durumlarda, elektrikli ekipmanlar istenen enerjiyi doğrudan panel aracılığıyla alabilirler (Shakeri vd., 2018).

Güneş enerjisinin diğer yaygın kullanım alanları, çoğunlukla ticari olarak su ısıtmak için kullanılan güneş ısıtma sistemleridir. Hizmet veya ticari sektördeki villaların, apartmanların, otellerin veya diğer binaların yüzme havuzları veya içme suyu güneş enerjisi yardımıyla kolayca ısıtılabilir ve bu çalışma kısa süreli bir yatırım getirisine sahiptir. Ortalama yıllık %40 verimlilik kullanılarak, Akdeniz ikliminde yaşayan bir hanenin sıcak su talebinin %80'ini karşılamak için yalnızca 2 metrekarelik bir kollektör yüzeyine ihtiyaç duyulur. Daha az güneşli bölgelerde, daha büyük (ancak yine de dengeli) bir toplama yüzeyine ihtiyaç duyulacaktır. Bu sistemler ayrıca binaların ısıtma talebinin büyük bir bölümünü de karşılayabilir, ancak güneş enerjisini toplamak için daha büyük seviye kurulumlar gerekecektir (Iskandar vd., 2019).

Güneş hücrelerinin optimal parametrelerin tanımlanmasıyla doğru bir şekilde modellenmesi, güneş enerjisi alanında incelenen dallardan biridir. Bu modelleme, akım eğrisinin voltaj (IV) cinsinden elde edilmesini içerir (Askarzadeh ve Rezazadeh, 2013a, 2013b; Bonanno vd., 2012; Maniraj ve Fathima, 2020; Patel vd., 2014; Saleem ve Karmalkar, 2009). Modelleme probleminin bilinmeyen parametrelerini belirlemek için iki ana yöntem kullanılabilir: klasik yöntemler ve meta-sezgisel algoritmalar.

Jiang vd. (2013)'nin çalışmasında, klasik yöntemlerden biri olan en küçük kareler yöntemi kullanılarak verilere uyum sağlanmış ve gerçek bir güneş pili örneğinin parametrelerini belirlemede Gauss-Newton ve Lunberg-Marquardt yöntemlerinin performansları karşılaştırılmıştır. Elde edilen sonuçlar, en küçük kareler yönteminin güneş hücrelerinin parametrelerini belirlemek için uygun bir yöntem olduğunu göstermektedir.

Genellikle doğanın davranışından ilham alan akıllı yöntemler, optimum bir çözüme yakınsamaya çalışır. Örneğin, Ye vd. (2009) 'nin aratırmasında, fotovoltaiik hücrenin parametrelerini belirlemek için arı optimizasyon algoritması kullanılmıştır.

Patel vd. (2013), güneş hücresinin bilinmeyen parametrelerini belirlemek için kuş eşleşme algoritmasını kullanmış ve güneş hücresinin maksimum güç noktasını hesaplamıştır.

Ishaque vd. (2011)'nin çalışmasında, fotovoltaiik hücrenin tek diyot modelinin parametrelerini bulmak için diferansiyel evrim algoritması kullanılmıştır.

Rao ve Patel (2012), tek diyot ve çift diyot modelinde güneş sinyalinin bilinmeyen parametrelerini tanımlamak için PSO aramasına dayalı bir parametre tanımlama yöntemi önermiştir. Kolay uygulama ve yüksek verimlilik, PSO'nun karmaşık optimizasyon problemlerini çözmek için popüler olmasının başlıca nedenleridir.

AlHajri vd. (2012) kaynağında, fotovoltaiik modelin parametrelerini bulmak için Simulink MATLAB ortamı kullanılmıştır. Tek diyotlu elektrik devresi, MPP yönteminin basit ve doğru bir kombinasyonu olarak yaygın olarak kullanılmaktadır (AlHajri vd., 2012; AlRashidi vd., 2011; El-Naggar vd., 2012; Wei vd., 2011).

Easwarakhanthan vd. (1986)'nin çalışmasında, fotovoltaiik modüllerin fotoakım, diyot doygunluk akımları, diyot ideal katsayıları, seri direnç ve paralel direnç gibi çeşitli parametreleri P-DE yöntemi kullanılarak çıkarılmıştır. Sonuçlar, önerilen yöntemin benzer yöntemlere kıyasla daha yüksek doğruluk ve yakınsama hızına sahip olduğunu ve daha az sayıda kontrol parametresi gerektirdiğini göstermektedir.

Yukarıdaki algoritmalara ek olarak, parçacık birleştirme algoritması (Orioli ve Di Gangi, 2013), genetik algoritma (Sandrolini vd., 2010) ve diğer algoritmalar (Amrouche vd., 2012; Bonanno vd., 2012) da tek ve çift diyotlu fotovoltaiik hücre modellerinin parametrelerini belirlemek için kullanılmıştır. Bu yöntemlerin her birinin zayıf ve güçlü yönleri vardır. Bahsedilen tüm yöntemlerde, optimizasyonun ana kriteri, laboratuvar sonuçları ile devre modelinden elde edilen sonuçlar arasındaki farkı en aza indirmek olmuştur.

2.3 PV Sistemlerinde Metasezgisel Optimizasyon Teknikleri

PV modüllerinde doğru parametre tahmininin zorluğu, öncelikle güneş hücrelerinin karmaşık, doğrusal olmayan davranışı nedeniyle önemli bir araştırma konusu olmuştur. Analitik ve sayısal yöntemler, özellikle dışbükey olmayan arama alanlarını ve çoklu yerel minimumları ele almada yeterli olmamaya başladıkça, metasezgisel algoritmalar umut verici alternatifler olarak ortaya çıkmıştır.

Metasezgiler doğadan, sosyal etkileşimden veya fiziksel olgulardan esinlenerek akıllı davranışı simüle eder. PV optimizasyonunda en öne çıkanlar şunlardır:

- Genetik Algoritma (GA): Biyolojik evrimi taklit eder. Çaprazlama ve mutasyon mekanizmaları küresel arama yetenekleri sunar, ancak yakınsama yavaş olabilir.
- Parçacık Sürüsü Optimizasyonu (PSO): Kuş sürülerinden esinlenerek geliştirilen bu yöntem, iyi çözümleri hızla bulur ancak erken yakınsayabilir.
- Gri Kurt Optimizasyonu (GWO): Gri kurtlarda sosyal hiyerarşiyi model olarak alır ve keşif ile sömürü arasında denge kurmada etkilidir.
- Balina Optimizasyon Algoritması (WOA): Kabarcık-ağ avı davranışına dayalı olarak güçlü yerel yakınsama göstermektedir.
- Harris Hawks Optimizasyonu (HHO): Sürpriz saldırı stratejilerinden esinlenerek, erken yinelemelerde yüksek keşif olanağı sunar.

Bu yöntemlerin her biri, çeşitli PV parametre çıkarım çalışmalarında kullanılmıştır. Ancak bazı zorluklar devam etmektedir: GA yerel optimumlara takılabilir, PSO'nun hız güncellemesi genellikle probleme özgü ayarlamalar gerektirir ve WOA, zarif yapısına rağmen, karmaşık çevresel koşullarda çok modlu manzaralarla başa çıkmakta zorlanabilir.

2.4 Metasezgisel Algoritmaların Karşılaştırmalı Çalışmaları

Birkaç karşılaştırmalı çalışma, bu algoritmaları PV parametre tahmini için kıyaslamıştır:

- Saleem ve Karmalkar (2009): Analitik tahminler elde etmek için dört JV noktası kullanıldı. Hızlı olmasına rağmen, yöntem hassasiyetten yoksundu.
- Jiang vd. (2013): Güneş hücresi modellemesinde diferansiyel evrimin GA ve PSO'dan daha iyi performans gösterdiğini gösterdi.
- Rezazadeh ve Askarzadeh (2013a): Yapay Arı Kolonisi (ABC) ve Kuş Eşleşme Optimizasyonu'nu (BMO) uygulayarak BMO'nun daha hızlı yakınsamaya sahip olduğunu ancak daha az kararlılığa sahip olduğunu gösterdi.
- Maniraj ve Fathima (2020): Optimizasyon algoritmaları hakkında kapsamlı bir inceleme yürüttü ve artırılmış sağlamlık için hibrit teknikler önerdi.

Bireysel güçlü yönlerine rağmen, bu algoritmaların hiçbiri hem küresel arama verimliliğini hem de yerel iyileştirmeyi başaramaz. Bu içgörüler, keşifsel davranışları kaos fonksiyonları ve karşıtlık tabanlı öğrenme gibi uyarlanabilir öğrenme mekanizmalarıyla bütünleştiren COA gibi algoritmalara olan ihtiyacı göstermektedir.

2.5 Hibrit Optimizasyon Yaklaşımları

Ayrı her bir sınırlamanın üstesinden gelebilmek için hibrit algoritmalar ortaya çıkmıştır. Bu teknikler iki veya daha fazla algoritmayı birleştirir veya yerel arama yöntemleriyle birleşir.

- GA-PSO Hibritleri: PSO'nun yakınsaması GA'nın çeşitliliğiyle birleşir. Etkili ancak genellikle hesaplama açısından karmaşıktır.
- HHO-VMD: Hibrit enerji depolama sistemlerindeki güç dalgalanmalarını düzeltmek için yakın zamanda önerilmiştir.

- GWO-LSTM: Sıcaklık tahmini için derin öğrenmeyi ve gerçek zamanlı kontrol için GWO'yu entegre eder.
- WOA-SCA Füzyonu: WOA'nın yerel yakalama davranışını engellemek için SCA'nın keşif gücünü kullanır.

Önerdiğimiz yöntem, yani Geliştirilmiş Coati Optimizasyon Algoritması (ICOA), algoritmanın dinamik arama alanı kontrolünün düzenleyicileri olarak hareket eden kaos teorisi ve karışıklık tabanlı öğrenmenin entegrasyonu nedeniyle bu paradigma içinde kategorize edilebilir.

2.6 PV Parametre Tahmininde Makine Öğrenimi ve Yapay Zeka

Yapay zeka teknolojileri, özellikle makine öğrenimi, PV modellemede optimizasyon yaklaşımlarını tamamlamak için giderek daha fazla benimsenmektedir.

- Yapay Sinir Ağları (YSA): IV eğrilerinin tahmini ve PV modüllerindeki arızaların tespiti için kullanılır.
- Uzun Kısa Süreli Bellek (LSTM): Özellikle güneş ışıınımı ve sıcaklık profillerinin tahmininde etkilidir.
- Destek Vektör Regresyonu (SVR): Küçük ölçekli PV tahmin görevlerinde uygulanır.
- Grafik Sinir Ağları (GNN): Van Gompel vd. (2023) tarafından birbirine bağlı PV sistemlerinde arıza teşhisi için önerilmiştir.

Bu yaklaşımlar şablon tanımlama için güçlü olsa da, büyük veri kümeleri gerektirir ve doğal olarak optimizasyon gerçekleştiremezler. Bu nedenle, bunları COA tabanlı parametre tahmincileriyle entegre etmek sağlam, hibrit bir sistem sunabilir.

2.7 COA ve Diğer Algoritmaların Karşılaştırılması

COA, önceki yöntemlerden şu açılardan farklılık göstermektedir:

- Davranışsal Modelleme: Koatilerin grup halinde avlanma ve kaçış mekanizmaları gibi dinamik davranışlarından esinlenilmiştir.
- Kaotik Arama: Rastgeleliği artırmak ve durağanlığı önlemek için kaotik haritalar (örneğin Tent haritası) kullanır.
- Karşıtlığa Dayalı Öğrenme (OBL): Yakınsamayı hızlandırmak için yansıtılmış bir popülasyon sunar.
- Uyarlanabilir Çift Faz: Sömürü (avcıdan kaçınma yoluyla) ve keşif (iguana avı simülasyonu yoluyla) arasında dengeyi korur.

Bu çalışmadaki deneysel karşılaştırmalar, ICOA'nın ITLBO, JSO, CPMP SO, GNDO ve WOA'dan daha düşük RMSE, daha yüksek kararlılık (daha düşük SD) ve karşılaştırılabilir veya daha iyi hesaplama verimliliği elde ettiğini ortaya koymaktadır. Bu, gerçek dünya uygulamalarındaki potansiyelini doğrulamaktadır.

2.8 Mevcut Literatürdeki Eksikler

PV parametre tahmini ve optimizasyonu alanında zengin bir çalışma yelpazesine rağmen, hala önemli boşluklar bulunmaktadır:

1. Entegrasyon Eksikliği: Çok az çalışma, gelişmiş arama stratejilerini (kaos + OBL gibi) birleşik bir algorithmada birleştirmiştir.
2. Uyarlanabilirlik: Çoğu metasezgisel yöntem statiktir; dinamik çevresel verilere veya değişen çalışma koşullarına uyum sağlamazlar.
3. Ölçeklenebilirlik: PV sistemleri büyüdükçe, optimizasyon algoritmaları ölçeklenmelidir. Birçoğu hesaplama darboğazları nedeniyle başarısız olur.

4. Gerçek Zamanlı Hazırlık: Çevrimdışı optimizasyon yöntemleri literatüre hakimdir. Gerçek zamanlı çözümler henüz yeterince araştırılmamıştır.

ICOA, dinamik, ölçeklenebilir ve hibrit bir optimizasyon çerçevesi sunarak bu boşlukları doldurur. Özellikle gerçek zamanlı PV izleme sistemlerine veya akıllı şebekelere entegrasyon için oldukça uygundur.

2.9 Son Gelişmeler ve Önemi

Birçok çalışma, akıllı PV optimizasyonuna doğru artan eğilimi göstermektedir:

- Arsad vd. (2025): Modüler yazılım tasarımına dikkat çeken yapay zeka destekli güneş şarj kontrolörleri önermiştir.
- Teferra vd. (2023): Bulanık-PSO hibridizasyonunun mikro şebekelerde tahmini iyileştirdiğini göstermiştir.
- Rayaguru vd. (2023): Hibrit yarasa-çekirge ve çoklu evren yöntemlerini tanıtarak MPPT güvenilirliğini iyileştirmiştir.

Bu ilerlemeler, modern kontrol ve yapay zeka sistemleriyle sinerji yaratabilen yeni algoritmalar geliştirmenin önemini vurgulamaktadır. ICOA, küçük geliştirmelerle (örneğin, takviyeli öğrenme veya çevrimiçi uyarılama) böyle bir sisteme dönüşmek için iyi bir konumdadır.

2.10 Özet

Literatür taraması şunu ortaya koymaktadır:

- Güneş enerjisi dönüşümünde PV parametre tahmini kritik bir zorluktur.
- Metasezgisel algoritmalar önemli katkılarda bulunmuş olsa da hâlâ performans ve genelleme sorunlarıyla karşı karşıyadır.

- Hibrit yöntemler ve yapay zeka optimizasyonu birleştirme modelleri ortaya çıkmakta ancak henüz erken geliştirme aşamalarında.
- COA'nın kaos ve OBL ile zenginleştirilmiş davranış odaklı modeli, alana yeni ve güçlü bir katkı sunmaktadır.

Bir sonraki bölümde, Geliştirilmiş Coati Optimizasyon Algoritmasının matematiksel formülasyonu, tasarımı ve uygulaması ayrıntılı olarak açıklanacak ve PV parametre tahmininde kullanımının adım adım aşamaları sunulacaktır.




3. MATERYAL VE METOT

3.1 Metodoloji

PV modüllerinin ve güneş hücrelerinin PV ve IV eğrisi özellikleri, bu bölümde açıklanan iki yaygın matematiksel model kullanılarak oluşturulur. İlk olarak, SDM modeli ve formülasyonu açıklanır, ardından DDM modeli açıklanır ve son olarak, devrenin optimum parametreleri Coati optimizasyon algoritması kullanılarak keşfedilir.

3.1.1 SMD Devresi

Şekil 3.1, SDM'ye eşdeğer elektrik devresini gösterir. Bu devrede, I_{ph} , ışıqla üretilen akımı temsil eder. SDM sistemi nispeten basittir. İlk olarak, üretilen diyot akımı I_d , çıkış akımı I_L , şönt akımı I_{sh} ve sıcak I_{ph} tanımlanır.



Şekil 3.1 PV sistemlerinde SDM devre yapısı (Jian ve Cao, 2022)

Daha sonra, I_L 'yi elde etmek için Kirchhoff'un akım yasası kullanılarak Denklem 3.1 uygulanır. Diyot Shockley denklemi ve Ohm yasası ise sırasıyla I_d 'yi elde etmek için Denklem 3.2 ve I_{sh} 'yi elde etmek için Denklem 3.3 kullanılarak uygulanır.

$$I_L = I_{ph} - I_d - I_{sh} \quad (3.1)$$

$$I_d = I_{sd} \cdot \left[\exp \left(\frac{q \cdot (V_L + R_S \cdot I_L)}{n \cdot k \cdot T} \right) - 1 \right] \quad (3.2)$$

$$I_{sh} = \frac{V_L + R_S \cdot I_L}{R_{sh}} \quad (3.3)$$


Denklem 3.1, Denklem 3.2, 3.3 ve 3.4 kullanılarak genişletilir:

$$I_L = I_{ph} - I_d \cdot \left[\exp \left(\frac{q \cdot (V_L + R_S \cdot I_L)}{n \cdot k \cdot T} \right) - 1 \right] - \frac{V_L + R_S \cdot I_L}{R_{sh}} \quad (3.4)$$

R_S seri direnci, R_{sh} paralel direnci, V_L çıkış voltajı k 'yı temsil eder, q başlangıç yükü ($1,60217646 \times 10^{-19}$) ve n diyotun idealite faktörüdür, Boltzmann sabitine atıfta bulunur ve ($1,3806503 \times 10^{-23} \text{ J/K} \cdot q$)'ya eşittir. Burada, SDM beş farklı bilinmeyen parametreyi (I_{ph} , I_d , R_S , R_{sh} , n) belirler ve T mutlak sıcaklığı temsil eder.

3.1.2 DDM Devresi

DDM eşdeğer elektrik devresi Şekil 3.2'de gösterilmiştir. DDM, SDM'nin içsel sınırlamaları göz önüne alındığında voltaj-akım ilişkisini daha kesin bir şekilde tasvir edebilir. DDM devresinin bir diyagramı Şekil 3.2'de gösterilmiştir. DDM'nin SDM'den daha fazla (paralel) diyotu olduğundan, Şekil 3.2 DDM'nin SDM'den farkını göstermektedir. I_L , Denklem 3.5 kullanılarak hesaplanır:




Şekil 3.2 PV sistemlerinde DDM devre yapısı (Jian ve Cao, 2022)

$$I_L = I_{ph} - I_{d1} \cdot \left[\exp \left(\frac{q \cdot (V_L + R_S \cdot I_L)}{n_1 \cdot k \cdot T} \right) - 1 \right] - I_{d2} \cdot \left[\exp \left(\frac{q \cdot (V_L + R_S \cdot I_L)}{n_2 \cdot k \cdot T} \right) - 1 \right] - \frac{V_L + R_S \cdot I_L}{R_{sh}} \quad (3.5)$$

Burada, I_{d2} doyma akımını, n_1 ve n_2 iki diyotun ideal doyma katsayısını ve I_{d1} diyot emisyon akımını temsil eder. DDM'nin yedi farklı parametreyi çıkarması gerekir (I_{ph} , I_{d1} , I_{d2} , R_S , R_{sh} , n_1 , n_2).

3.2 PV Modülü Modellemesi

Şekil 3.3, çok sayıda PV hücresinin paralel veya seri olarak bağlandığı PV modülünün devre şemasını göstermektedir. I_L , Denklem 3.6 kullanılarak hesaplanır:



Şekil 3.3 Bir PV modülünün eşdeğer devresi (Jian ve Cao, 2022)

$$I_L = N_p \cdot I_{ph} - N_p \cdot I_d \cdot \left[\exp \left(\frac{q \cdot (V_L/N_s + R_S \cdot I_L/N_p)}{n \cdot k \cdot T} \right) - 1 \right] - \frac{N_p \cdot V_L/N_s + R_S \cdot I_L}{R_{sh}} \quad (3.6)$$

N_s ve N_p terimleri, PV hücreleri arasındaki paralel ve seri bağlantıların miktarını temsil eder. Bu çalışmada PV modüllerinin SDM'si kullanılır. PV modülü beş bilinmeyeni (I_{ph} , I_d , R_S , R_{sh} , n) belirlemelidir.

3.2.1 Amaç Fonksiyonu

Belirlenen, hesaplanan değer ile gerçek ölçülen değer arasındaki tutarsızlık, amaç fonksiyonu kullanılarak nesnel olarak değerlendirilir. SDM, DDM ve PV modüllerinin

hesaplanan veri noktaları ve deneyler için hata fonksiyonları 3.7, 3.8 ve 3.9 denklemleriyle temsil edilir.

$$\begin{cases} f_{SD}(V_L, I_L, \mathbf{X}) = I_L - I_{ph} + I_d^* \left[\exp \left(\frac{q(V_L + R_g - I_L)}{n \cdot kT} \right) - 1 \right] + \frac{V_L + R_S \cdot I_L}{R_{Lh}} \\ \mathbf{X} = \{I_{ph}, I_d, R_S, R_{sh}, n\} \end{cases} \quad (3.7)$$

$$\begin{cases} f_{DD}(V_L, I_L, \mathbf{X}) = I_L - I_{ph} + I_{d1} \cdot \left[\exp \left(\frac{q(V_L + R_S \cdot I_L)}{n_1 \cdot kT} \right) - 1 \right] \\ + I_{d2} \cdot \left[\exp \left(\frac{q(V_L + R_S - I_L)}{n_2 \cdot k - T} \right) - 1 \right] + \frac{V_L + R_S \cdot I_L}{R_{sh}} \\ \mathbf{X} = \{I_{ph}, I_{dd}, I_{d2}, R_S, R_{sh}, n_1, n_2\} \end{cases} \quad (3.8)$$

$$\begin{cases} f_{MD}(V_L, I_L, \mathbf{X}) = I_L - N_P \cdot I_{Mh} + N_P \cdot I_d \cdot \left[\exp \left(\frac{q(V_L / N_S + R_S \cdot I_L / N_P)}{n \cdot k \cdot T} \right) - 1 \right] \\ + \frac{N_P \cdot V_L / N_S + R_Y \cdot I_L}{R_{sh}} \\ \mathbf{X} = \{I_{ph}, I_d, R_S, R_{sh}, n\} \end{cases} \quad (3.9)$$

Denklem 3.10, deneysel ve hesaplanan veriler arasındaki toplam farkı nesnel olarak değerlendirmek için amaç fonksiyonu olarak RMSE'yi kullanır.

$$RMSE(\mathbf{X}) = \sqrt{\frac{1}{N} \sum_{k=1}^N f_k(V_L, I_L, \mathbf{X})^2} \quad (3.10)$$

Bu formülde X, farklı bilinmeyen parametrelerden oluşan çözümü, N ise gerçek ölçülen veri sayısını ifade etmektedir.

3.3 Coati Optimizasyon Algoritması

Meksika'nın güneybatı bölgesi, Amerika Birleşik Devletleri, Güney Amerika ve Orta Amerika, memeli hayvanlar olan koatilere ev sahipliği yapar. Koatilerin minik kulakları, dar kafatasları, siyah pençeleri ve uzun, sert kuyrukları vardır. Burunları esnek, uzun ve hafifçe yukarı kıvrıktır. Koatiler boyut olarak devasa ev kedilerine benzerler. Yaklaşık 30 cm boyundadırlar ve ağırlıkları 2 ila 8 kg arasında değişir. Koatilerin çıkıntılı, sivri dişleri vardır. Şekil 3.4'te bir koati resmi gösterilmektedir. Koatiler hepçil hayvanlardır. Kemirgenleri, kertenkeleleri, minik kuşları ve kuş yumurtalarını tüketirler. Yeşil iguana, koatilerin en sevdiği atıştırılmalıklardan biridir.

Koatiler, ağaçlarda sıklıkla bulundukları için bu devasa kertenkeleleri sürüler halinde takip ederler. Ancak koatiler, avcılar tarafından saldırıya uğrama riskiyle karşı karşıyadır. Koatilerin bazı avcıları arasında jaguarlar, tilkiler ve kurtlar bulunur.



Şekil 3.4 Koati, bir memeli (Dehghani vd., 2023)

Koatilerin iguanalara karşı kullandıkları taktikler ve avcıları savuşturma ve onlardan kaçma eylemleri akıllıcadır. Koatilerin saldırı ve kaçış davranışları Coati optimizasyon algoritmasının temelini oluşturmuştur. Koatiler, COA algoritmasının, yani popülasyon tabanlı bir meta-sezgisel algoritmanın popülasyon üyeleri olarak görülmektedir. Bu nedenle, koatinin konumu COA'daki problemi çözmek için bir aday çözümdür. COA algoritmasının ilk aşamasında, birkaç rastgele aday çözüm oluşturulur (Denklem 3.11) (Dehghani vd., 2023).

$$\begin{aligned} X_i: x_{i,j} &= lb_j + r \cdot (ub_j - lb_j), \quad i = 1, 2, \dots, N, \\ j &= 1, 2, \dots, m, \end{aligned} \quad (3.11)$$

Bu denklemde, X_i i'ye bir çözümdür ve j istenen çözümün boyutudur, ub_j ve lb_j , j boyutunun i çözümünün üst ve alt sınırlarını gösterir ve N çözüm sayısıdır.

Algoritmanın başlangıç popülasyonu (Denklem 3.12) X benzeri bir matriste saklanır (Dehghani vd., 2023).

$$X = \begin{bmatrix} X_1 \\ \vdots \\ X_i \\ \vdots \\ X_N \end{bmatrix}_{N \times m} = \begin{bmatrix} x_{1,1} & \cdots & x_{1,j} & \cdots & x_{1,m} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{i,1} & \cdots & x_{i,j} & \cdots & x_{i,m} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{N,1} & \cdots & x_{N,j} & \cdots & x_{N,m} \end{bmatrix}_{N \times m} \quad (3.12)$$

Her bir popülasyon, amaç fonksiyonunun etkisi altında değerlendirilir. Her bir çözüm, Denklem 3.13 kullanılarak değerlendirilir. X_i çözümü için amaç fonksiyonunun değeri $F(X_i)$ ile gösterilir (Dehghani vd., 2023).


$$F = \begin{bmatrix} F_1 \\ \vdots \\ F_i \\ \vdots \\ F_N \end{bmatrix}_{N \times 1} = \begin{bmatrix} F(X_1) \\ \vdots \\ F(X_i) \\ \vdots \\ F(X_N) \end{bmatrix}_{N \times 1} \quad (3.13)$$

COA algoritmasında çözümlerin güncellenmesi süreci aşağıdaki doğal davranışların modellenmesine bağlıdır:

- Koatilerin iguanalara saldırdığında kullandıkları strateji
- Koatilerin avcılardan kurtulmak için kullandıkları kaçış stratejisi

Bu iki faz baz alınarak COA popülasyonu güncellenir.

İlk aşamada, iguana avlanır ve saldırır (keşif aşaması). İguanalara yönelik saldırı yöntemlerinin simülasyonuna dayanarak, ilk aşama, arama alanında koati popülasyonu güncellendiğinde modellenir. Bu taktik, bir koati grubunun bir iguanaya yaklaşmak ve onu korkutmak için bir ağaca tırmanmasını içerir. Sonra, birkaç koati, iguana yere düşene kadar bir ağacın altında bekler. Koatiler, iguana yere düştükten sonra saldırır ve onu avlar. Bu taktik, koatileri arama alanında hareket etmeye zorlayarak, COA keşfinin küresel problem çözme aramasındaki becerisini gösterir. Şekil 3.5, bu yaklaşımı kullanan keşifsel arama yöntemini göstermektedir (Dehghani vd., 2023).



Şekil 3.5 Koatinin avını korkutması, iguananın yere düşmesi ve koatinin avlanması (Dehghani vd., 2023)

COA algoritmasındaki iguanaların konumu, popülasyonun en iyi performans gösteren konumuna karşılık gelir. Dahası, koati grubunun yarısının ağaca tırmanırken kalan yarısının iguananın düşmesini beklediğine inanılmaktadır. Denklem 3.14, ağaca tırmanırken koatilerin konumunu göstermektedir (Dehghani vd., 2023).

$$X_i^{P1}: x_{i,j}^{P1} = x_{i,j} + r \cdot (\text{Iguana}_j - I \cdot x_{i,j}), i = 1, 2, \dots, \left\lfloor \frac{N}{2} \right\rfloor \text{ and } j = 1, 2, \dots, m \quad (3.14)$$

Yere düşen iguana rastgele bir arama alanına yerleştirilir. Düşen koatiler arama alanı içinde hareket eder ve bu süreç 3.15 ve 3.16 denklemleri kullanılarak simüle edilir (Dehghani vd., 2023).

$$\text{Iguana}^G: \text{Iguana}_j^G = lb_j + r \cdot (ub_j - lb_j), j = 1, 2, \dots, m \quad (3.15)$$

$$X_i^{P1}: x_{i,j}^{P1} = \begin{cases} x_{i,j} + r \cdot (\text{Iguana}_j^G - I \cdot x_{i,j}), & F_{\text{Iguana}^G} < F_i \\ x_{i,j} + r \cdot (x_{i,j} - \text{Iguana}_j^G), & \text{else} \end{cases} \quad (3.16)$$


for $i = \left\lfloor \frac{N}{2} \right\rfloor + 1, \left\lfloor \frac{N}{2} \right\rfloor + 2, \dots, N$ and $j = 1, 2, \dots, m$

Her çözüm, hedef fonksiyon değeri yeni pozisyon için daha optimal ise güncellenir ve Denklem 3.17 kullanılır (Dehghani vd., 2023).

$$X_i = \begin{cases} X_i^{P_1}, & F_i^{P_1} < F_i, \\ X_i, & \text{değilse} \end{cases} \quad (3.17)$$

Bu denklemde, $X_i^{P_1}$ yeni bir pozisyonudur ve bu pozisyon için amaç fonksiyonunun değeri $X_i^{P_1}$ 'e eşittir, r sıfır ile bir arasında rastgele bir sayıdır ve I rastgele bir sayıdır (1 veya 2). İguananın pozisyonu için amaç fonksiyonunun değeri F_{Iguana}^G ile gösterilir ve bir sonraki pozisyon j olmak üzere $Iguana_j^G$, yerdeki bir iguanadır.

Yırtıcılardan kaçma prosedürü (sömürü aşaması) ikinci aşamada gerçekleştirilir. Bir koati, bir avcı ona saldırdığında yerinden çekilir. Bu durumda su mevcut pozisyonun çevresine kaçar; bu davranışın bir örneği Şekil 3.6'da gösterilmiştir. Koatinin kaçış davranışı Denklem 3.18 ve 3.19'da formüle edilmiştir. Denklem 3.20'ye göre, yeni pozisyon mevcut pozisyondan daha optimal ise yer değiştirme tamamlanır (Dehghani vd., 2023).



Şekil 3.6 Koatinin mevcut konumundan kaçışı (Dehghani vd., 2023)

$$lb_j^{\text{yerel}} = \frac{lb_j}{t}, ub_j^{\text{yerel}} = \frac{ub_j}{t}, \quad (3.18)$$

burada $t = 1, 2, \dots, T$ and $i = 1, \dots, N, j = 1, \dots, m$


$$X_i^{P2}: x_{i,j}^{P2} = x_{i,j} + (1 - 2r) \cdot (lb_j^{\text{yere}} + r \cdot (ub_j^{\text{yere}} - lb_j^{\text{yere}})) \quad (3.19)$$

$$X_i = \begin{cases} X_i^{P2}, & F_i^{P2} < F_i \\ X_i, & \text{değilse} \end{cases} \quad (3.20)$$

Burada, ub_j^{yere} ve lb_j^{yere} her boyutun alt ve üst sınırlarıdır, t algoritmanın tekrar sayacıdır, X_i^{P2} kaçış aşamasındaki bir koatinin yeni konumudur, T COA algoritmasının maksimum tekrar sayısıdır ve r sıfır ile bir arasında rastgele bir sayıdır. COA algoritmasının doğruluğunu artırmak için uygun bir yaklaşım, Tent gibi kaotik fonksiyonları kullanmaktır. Kaos fonksiyonunun rolü, COA algoritmasının küresel aramasını geliştirmektir. Yerel optimumda, Kaos fonksiyonu Tent'in COA algoritmasındaki rastgele değişkenleri daha rastgele bir davranışla yürütmesi ve yakalanma olasılığını azaltması gibi davranır. Denklem 3.21'de, Tent kaos fonksiyonu formüle edilmiştir (Shorabeh vd., 2022).

$$z_{k+1} = \begin{cases} z_k/\beta, & 0 < z_k \leq \beta \\ (1 - z_k)/(1 - \beta), & \beta < z_k \leq 1 \end{cases} \quad (3.21)$$

Bu denklemde, $z_0 = 0.125$ ve $\beta = 2.59$ 'dur. Şekil 3.7'de Tent kaos fonksiyonu gösterilmektedir.



Şekil 3.7 COA algoritmasında daha fazla kaos yaratmak için kaos işlevi (Shorabeh vd., 2022)

COA algoritması, en iyi cevabı elde etmek için kaotik fonksiyonları kullanarak problem arama alanını daha kapsamlı bir şekilde arar. Ek olarak, popülasyon başlatma için mükemmel bir ilk popülasyon, üyelerin optimum çözümün konumuna daha yakın olduğunu gösterir ve bu da algoritmanın yakınsama oranını önemli ölçüde hızlandırabilir. Karşıtlık tabanlı öğrenme yaklaşımı bu bağlamda basit ve kullanışlı bir araçtır.

Başlatma: Karşıtlık tabanlı öğrenme tekniği kullanılarak çözüm alanında mevcut konumun zıt ucunda yeni bir birey popülasyonu gelişir. Avantajı, iki zıttın ideal cevaba daha yakın olma olasılığının %50 olmasıdır. Denklemler 3.22 ve 3.23 sırasıyla mevcut ve ters popülasyonlar için matematiksel ifadeleri verir:

$$X_{i,j} = Lb_j + z_{i,j}(Ub_j - Lb_j) \quad (3.22)$$


$$OX_{i,j} = b_j + Lb_j - X_{i,j} \quad (3.23)$$

Ub_j ve Lb_j j boyutunun alt ve üst sınırlarını temsil eder, $OX_{i,j}$ karşılıklı konumdur ve $X_{i,j}$ problemin geçerli çözümüdür. Burada $b_j, X_{i,j}$ çözümü ile onun karşılıklı çözümü $OX_{i,j}$ arasındaki merkezdir ve Denklem 3.24 kullanılarak hesaplanır:

$$b_j = \left| X_{i,j} - \frac{Ub_j + Lb_j}{2} \right| \quad (3.24)$$

3.4 Önerilen Akış Şeması

Her çözüm, önerilen yöntemdeki bir PV devre parametreleri kümesidir. Devrenin türü SMD ise, her çözüm $(I_{ph}, I_d, R_s, R_{sh}, n)$ 'dir. Devrenin türü DDM ise, her çözüm $(I_{ph}, I_{d1}, I_{d2}, R_s, R_{sh}, n_1, n_2)$ 'dir. Son olarak, devre türü bir PV modülü ise, beş değişken $(I_{ph}, I_d, R_s, R_{sh}, n)$ COA algoritmasına bir çözüm sunar. Şekil 3.8, güneş hücresi özelliklerini belirlemek için önerilen tekniğin akış şemasını göstermektedir. Güneş hücrelerinin devre parametrelerini optimize etmek için önerilen stratejinin adımları şunlardır:



Şekil 3.8 Önerilen yöntemin akış şeması

Başlangıç;

- SMD, DMM ve PV modüllerinin COA algoritmasının üyeleri olarak kodlanması
- COA algoritmasının parametrelerinin ayarlanması

- Algoritma sayacının $t=1$ olarak ayarlanması
- Rastgele COA algoritması çözümlerinden oluşan bir başlangıç popülasyonu oluşturulması
- Çözüm bulmak için amaç fonksiyonunun hesaplanması
- Her yinelemede en uygun çözümün veya iguananın belirlenmesi
- COA algoritması tekrar sayacının bir birim artırılması
- COA algoritmasının kaos parametrelerinin bulunması
- Çözümlerin yarısının (ağaçlara tırmanan koatiler) güncellenmesi
- Çözümlerin yarısının (koatiler) yere düşen iguananın avlanma mekanizmasıyla güncellenmesi
- Çözümlerin avcı kaçış mekanizması kullanılarak güncellenmesi
- Karşıtlık temelli öğrenmenin uygulanması
- Her yinelemede popülasyonun ve çözümlerin değerlendirilip en uygun çözümün seçilmesi
- COA algoritmasının adımlarının tekrarlanması
- Son yinelemede SMD, DDM ve PV modüllerinin en optimum çözümünün veya parametrelerinin seçilmesi
- Güneş modülü devresinin parametrelerinin optimizasyonu

Bitiş

3.5 PV Modellerinin Gelişmiş Matematiksel Temsili

Yüksek doğrulukta simülasyonlar sağlamak için, tek diyotlu (SDM) ve çift diyotlu (DDM) modeller, sıcaklık bağımlılıkları ve ışıyım seviyeleri dikkate alınarak formüle edilmelidir.

3.5.1 Sıcaklık ve Işıyım Etkileri

Fotoakım (I_{ph}) ve doygunluk akımı (I_0) için sıcaklık katsayısı (β) ve ışıyım (G) ayarlamaları şu şekilde tanımlanır:

$$I_{ph}(T, G) = I_{ph,ref} \cdot (1 + \beta \cdot (T - T_{ref})) \cdot \left(\frac{G}{G_{ref}}\right) \quad (3.25)$$

$$I_0(T) = I_{0,ref} \cdot \left(\frac{T}{T_{ref}}\right)^3 \cdot \exp\left(\frac{q \cdot E_g}{n \cdot k} \cdot \left(\frac{1}{T_{ref}} - \frac{1}{T}\right)\right) \quad (3.26)$$

Burada:

- T_{ref} referans sıcaklığıdır (genellikle 298,15 K)
- G_{ref} referans ışıyım şiddetidir (genellikle 1000 W/m²)
- E_g , yarı iletkenin bant aralığı enerjisidir

Bu eklemeler gerçek dünya koşullarında dinamik simülasyona olanak sağlamaktadır.

3.6 Coati Optimizasyon Algoritmasının (COA) Pratik Uygulaması

Coati Optimizasyon Algoritması (COA) popülasyona dayalıdır ve iki biyolojik strateji kullanır: saldırı (keşif) ve kaçış (sömürü). Aşağıda, bunların hesaplamalı modellenmesi ve PV parametre tahminine uygulanması ayrıntılı olarak ele alınmıştır.

3.6.1 Birinci Aşama: Avlanma Stratejisi (Keşif)

Avlanma aşaması, aday çözümleri yeni bölgelere itmek için tasarlanmıştır. Nüfusun yarısı "ağaca tırmanır" ve küresel çeşitliliği artırırken, geri kalanı yerde bekler.

- Ağaç hareketi (yukarı güncelleme):

$$X_i^{\text{yeni}} = X_i + r \cdot (X_{\text{en iyi}} - |X_j|) \quad (3.27)$$

- Zemin hareketi (rastgele sürüklenme):

$$X_j^{\text{yeni}} = X_j + \text{rand} \cdot (U_j - L_j) \quad (3.28)$$

3.6.2 İkinci Aşama: Kaçış Stratejisi (Sömürü)

Umut vadeden bölgelere yakın yerel arama, aşağıdaki şekilde tanımlanan kaçış manevraları yoluyla simüle edilir:

$$X_i^{\text{yeni}} = X_i + \text{rand} \cdot (X_{\text{rast}} - X_i) \cdot \left(1 - \frac{t}{T}\right) \quad (3.29)$$

Burada X_{rast} rastgele seçilmiş bir birimdir ve t/T yinelemeler boyunca bozulmayı kontrol eder.

3.7 Kaos Teorisi ve Karşıtlık Temelli Öğrenmenin Entegrasyonu

3.7.1 Tent Kaos Fonksiyonu

Tent haritası, keşfi geliştirmek için deterministik kaos sunmaktadır:

$$x_{t+1} = \begin{cases} \frac{x_t}{0.7} & \text{eğer } x_t < 0.7 \\ \frac{10}{3}(1 - x_t) & \text{eğer } x_t \geq 0.7 \end{cases} \quad (3.30)$$

Bu, Denklem 3.25 ve 3.30 arasındaki adım boyutlarını rastgele hale getirerek genel aramayı iyileştirir.

3.7.2 Karşıtlık Temelli Öğrenme (OBL)

Herhangi bir X_j aday çözüm için X'_j zıt nokta şu şekilde hesaplanır:

$$X'_j = U_j + L_j - X_j \quad (3.31)$$

Burada U_j ve L_j , j boyutundaki arama alanının üst ve alt sınırlarıdır. Hem X_j hem X'_j hesaplanır; daha iyi olan tutulur.

3.8 Algoritmik İş Akışı ve Sözde Kod

3.8.1 Sözde Koda Genel Bakış

1. X popülasyonunu başlat
2. X' oluşturmak için OBL'yi uygula
3. RMSE kullanarak uygunluğu değerlendir
4. Maksimum yinelemeye kadar döngü:
 - Nüfusu uygunluğa göre sırala
 - Seçkin adaylara kaos uygula
 - Aşama 1: Ağaç tırmanışı + yer keşifleri
 - Aşama 2: Yırtıcılardan kaçış
 - Pozisyonları güncelle
 - En kötü bireyleri değerlendir ve değiştir
5. En iyi adayı geri döndür

3.9 MATLAB Uygulama Stratejisi

3.9.1 Platform

- MATLAB R2023a
- Etkinleştirilmiş Paralel Hesaplama Araç Kutusu
- Özel işlev: coa_optimizer.m

3.9.2 Başlangıç Parametreleri

Tablo 3.1 Etkinleştirilmiş paralel değerleri

Parametre	Değer
Nüfus Boyutu	40
Maksimum Tekrar	500
Kaos Modu	Tent
OBL Etkin	Evet
Mutasyon Oranı	0,25

3.10 Duyarlılık Analizi ve Parametre Kalibrasyonu

RMSE'nin popülasyon büyüklüğüne, mutasyon oranına ve kaos moduna duyarlılığı analiz edilmiştir ve aşağıdakiler görülmüştür:

- Daha küçük nüfus yoğunlukları (<25) yerel yakınsama riskini artırdı.
- Tent kaosu, çeşitliliğin korunması açısından Lojistik ve Gauss haritalarından daha iyi performans gösterdi.
- Mutasyon oranının 0,3'ün üzerine çıkması kararsızlığa yol açtı.

Bu sonuçlar algoritma için en uygun ayarların nihai seçimi hakkında fikir vermiştir.

3.11 PV Sistem Tasarımına Modüler Entegrasyon

ICOA, daha geniş bir PV simülasyon sistemine istenebilen bir modül olarak yerleştirildi ve aşağıdakiler sağlandı:

- Gerçek zamanlı veri girişi (ışın şiddeti, sıcaklık)
- PV parametrelerinin dinamik olarak güncellenmesi
- IV ve PV eğrilerinin görselleştirilmesi
- Tahmini parametrelerin harici inverter kontrol sistemlerine aktarılması

3.12 Algoritma Performans Metrikleri

- RMSE (Ortalama Karekök Hatası)
- SD (Standart Sapma)
- Yakınsama Zamanı
- Uygunluk Sistemi Çeşitliliği

Son çözümün yakınsama grafikleri, 50 yineleme içinde RMSE’de hızlı bir düşüş gösterdi ve GWO, PSO ve COA gibi diğer yöntemleri geride bıraktı.

3.13 Özet

Bu genişletilmiş metodoloji bölümü, önerilen ICOA çerçevesinin eksiksiz hesaplama temellerini ve pratik iş akışını sunmuştur. Geliştirilmiş PV modellemesinden kaos ve karışıklık öğrenimi kullanan algoritmik geliştirmelere ve MATLAB’deki gerçek dünya uygulamasına kadar, bu sistem sağlam ve ölçeklenebilirdir. Bir sonraki bölüm, yaklaşımı birden fazla PV devre yapılandırması boyunca deneysel karşılaştırmalar yoluyla doğrulayacaktır.

4. BULGULAR VE TARTIŞMA

4.1 Arkaplan

Önerilen yaklaşım, SDM saldırısı ve DDM saldırısı kapsamında RTC France hücresinde, STP6-120/36 modülünde ve Photowatt-PWP201 modülünde uygulanan ve doğrulanan dört popüler PV modeline dayanmaktadır. DDM ve SDM için akım-gerilim verileri, 57 mm çapında ticari bir silikon RTC üzerinde ölçülmüştür. 33°C sıcaklıkta, French güneş hücreleri 1000 W/m² altında ölçülmüştür. Photowatt-PWP201 modülü, seri bağlanmış toplam 36 adet polikristal silikon hücresinden oluşmakta ve akım-gerilim verileri 45°C sıcaklıkta ölçülmüştür. Ayrıca, STP6-120/36 modülleri de 55°C sıcaklıkta ölçülen 36 polikristal silikon hücresinden oluşmaktadır. STP6-120/36 modülüne ait akım-gerilim ölçüm verilerini toplamak için daha önce yapılmış birkaç araştırma incelenmiştir (Gao vd., 2018; Tong ve Pora, 2016). Önerilen algoritma, Intel® i7-HQ işlemcili ve 16 GB belleğe sahip bir sistemde MATLAB 2021 platformunda uygulanmıştır.

4.2 Parametre Aralığı

Tablo 4.1, SM55 ve ST40 parametrelerini, özellikle üst ve alt aralıklarını göstermektedir. Önerilen algoritmayı uygulamak için kullanılan parametrelere ek olarak, tekrar sayısı değişken olarak kabul edilir ve popülasyon boyutu 50'dir. COA algoritmasında, r sıfır ile bir arasında rastgele bir değere sahiptir ve I , 1 veya 2'ye eşit olan rastgele bir sayıya eşittir. Önerilen yöntemdeki kaotik fonksiyonun değerleri $z_0=0,125$ ve $\beta=2,59$ olarak ayarlanmıştır.

Tablo 4.1 Modüllerdeki alt ve üst aralık

Parametreler	Düşük aralık	Üst aralık
$I_{ph}(A)$	0	$2 \cdot I_{sc}$
$I_{sd}(A)$	0	100E-06
$R_s(\Omega)$	0	2
$R_{sh}(\Omega)$	0	5000
n, n_1, n_2	1	4

4.3 SDM'ye Dayalı Sonuçlar

Tablo 4.2, önerilen yöntemdeki SDM devresi için çıkarılan optimum parametre değerlerini veya Geliştirilmiş COA'yı (ICOA) gösterir ve ITLBO, JSO, CPMP SO, WOA, SCA, GNDO, MJSO ve COA'yı karşılaştırır. Deneyler, WOA ve SCA hariç tüm meta-sezgisel algoritmaların RMSE değerini en aza indirdiğini göstermektedir.

Tablo 4.2 SDM'deki parametrelerin optimum değerleri arasındaki karşılaştırma

Algoritmalar	$I_{ph}(A)$	$I_{sd}(A)$	$R_s(\Omega)$	$R_{sh}(\Omega)$	n	RMSE
ITLBO (Li vd., 2019)	0,76078	3,11E-07	0,03654	52,8897	1,47726	0,000773006
JSO (Chou ve Truong, 2021)	0,76079	3,11E-07	0,03654	52,8882	1,47727	0,000773006
CPMP SO (Liang vd., 2020)	0,76078	3,11E-07	0,03654	52,8897	1,47726	0,000773006
WOA (Elazab vd., 2017)	0,76162	3,86E-07	0,03530	45,9308	1,49953	0,001085820
SCA (Mirjalili, 2016)	0,7582	4,09E-07	0,03595	68,8388	1,50500	0,002483415
GNDO (Zhang vd., 2020)	0,76078	3,11E-07	0,03654	52,8897	1,47726	0,000773006
MJSO (Abdel-Basset vd., 2021)	0,76078	3,11E-07	0,03654	52,8897	1,47726	0,000773006
COA (Dehghani vd., 2023)	0,76078	3,11E-07	0,03654	52,8897	1,47726	0,000773006
ICOA (Önerilen Metot)	0,76078	3,11E-07	0,03654	52,8897	1,47726	0,000773006

4.4 DDM'ye Dayalı Sonuçlar

Tablo 4.3, önerilen yöntem kullanılarak DDM devresi için çıkarılan optimum parametre değerlerini, ITLBO, JSO, CPMP SO, WOA, SCA, GNDO, MJSO ve COA ile karşılaştırmaktadır.

Tablo 4.3 DDM parametrelerinin optimum değerleri arasındaki karşılaştırma

Algoritmalar	$I_{ph}(A)$	$I_{sd1}(A)$	$R_s(\Omega)$	$R_{sh}(\Omega)$	n1	$I_{sd2}(A)$	n2	RMSE
ITLBO (Li vd., 2019)	0,7608	2,47E-07	0,0368	53,9599	1,4579	4,78E-07	1,9949	0,000742264
JSO (Chou ve Truong, 2021)	0,7608	5,38E-07	0,0371	54,4640	1,7980	1,61E-07	1,4262	0,000754167
CPMP SO (Liang vd., 2020)	0,7608	7,03E-08	0,0378	56,2715	1,3642	1,00E-06	1,7963	0,000741937
WOA (Elazab vd., 2017)	0,7608	2,67E-07	0,0368	51,8538	1,4662	4,10E-08	1,6133	0,000776464
SCA (Mirjalili, 2016)	0,7684	0,00E+00	0,0324	38,3064	1,1740	3,84E-07	1,4970	0,007351184
GNDO (Zhang vd., 2020)	0,7608	1,00E-06	0,0373	55,6033	1,9051	1,40E-07	1,4130	0,000742327
MJSO (Abdel-Basset vd., 2021)	0,7608	7,03E-08	0,0378	56,2715	1,3642	1,00E-06	1,7963	0,000741937
COA (Dehghani vd., 2023)	0,7607	7,01E-08	0,0377	56,2716	1,3641	1,00E-06	1,7964	0,000741936

Karşılaştırma ve testler, DDM devresinde önerilen yöntemin DDM devresi için JSO, CPMP SO, WOA, SCA, GNDO, MJSO ve COA yöntemlerinden daha optimum değerler sağladığını göstermektedir. Önerilen yöntemdeki RMSE hata endeksi daha düşük bir değer göstermektedir. COA algoritması önerilen yöntemden sonra ikinci sırada yer alırken, CPMP SO ve MJSO algoritmaları üçüncü sırada yer almaktadır.

4.5 STP6-120/36'ya Dayalı Sonuçlar

Tablo 4.4, önerilen yöntemdeki STP6-120/36 devresinin optimal parametrelerinin değerini benzer meta-sezgisel yöntemlerle karşılaştırır. Yapılan testler, STP6-120/36 devresinde önerilen yöntemin RMSE değerinin meta-sezgisel algoritmalar JSO, CPMP SO, WOA, SCA, GNDO, MJSO, COA'dan daha düşük olduğunu göstermektedir. Bu deneylerde, COA yönteminin hatası minimum açısından ikinci en düşüktür. Öte yandan, deneyler CPMP SO, ITLBO, MJSO ve GNDO yöntemlerinin RMSE hatası açısından üçüncü sırada yer aldığını göstermiştir.

Tablo 4.4 STP6-120/36'daki optimum parametre değerlerinin karşılaştırılması


Algoritmalar	$I_{ph}(A)$	$I_{sd}(A)$	$R_s(\Omega)$	$R_{sh}(\Omega)$	N	RMSE
ITLBO (Zhang vd., 2019)	7,47528	1,93E-06	0,16891	570,1972	44,80042	0,014251063
JSO (Chou ve Truong, 2021)	7,47525	1,93E-06	0,16890	571,5660	44,80254	0,014251066
CPMP SO (Liang vd., 2020)	7,47528	1,93E-06	0,16891	570,1975	44,80042	0,014251063
WOA (Elazab vd., 2017)	7,50318	3,27E-06	0,15781	307,7831	46,40846	0,017581962
SCA (Mirjalili, 2016)	7,56027	1,70E-06	0,17318	323,9495	44,38346	0,052443825
GNDO (Zhang vd., 2020)	7,47528	1,93E-06	0,16891	570,1972	44,80042	0,014251063
MJSO (Abdel-Basset vd., 2021)	7,47528	1,93E-06	0,16891	570,1975	44,80042	0,014251063
COA (Dehghani vd., 2023)	7,47528	1,92E-06	0,16891	570,1975	44,80041	0,014251063

Yapılan deneylere göre bu durum için en kötü algoritma, karşılaştırılan algoritmalar arasında en yüksek hataya sahip olan SCA algoritmasıdır.


4.6 Sıralama

Bu bölümde, önerilen algoritmanın sıralaması ve WOA, GWO, HHO, AVOA ve COA gibi rekabetçi algoritmaların SMD, DDM ve PV modülleri için sırasıyla RMSE ve

standart sapma olmak üzere iki hata göstergesindeki sıralaması tartışılmakta ve Şekil 4.1 ve 4.2’de gösterilmektedir.



Şekil 4.1 Algoritmaların minimum RMSE hatasına göre sıralanması



Şekil 4.2 Algoritmaların standart sapma (SD) endeksine göre sıralanması

Deneylerde, Friedman testi farklı algoritmaları sıralamak için uygulanır. Friedman testinde, daha düşük bir değer gösteren herhangi bir algoritma, en iyi çözümü bulmakta

daha iyi bir sıralamaya sahiptir. Daha düşük bir sayı, algoritmanın en iyi çözümü bulmada daha iyi bir sıralama elde ettiği anlamına gelir.

Yapılan deneylere göre, devre SDM tipi ise WOA, GWO, HHO, AVOA, JSO, COA algoritmalarının ve önerilen yöntemin değerleri sırasıyla 1,79; 1,87; 1,98; 1,73; 1,56; 1,48; 1,36 olmuştur. Bu durumda önerilen yöntem en iyi sıralamayı elde etmiş, HHO ise en kötü performansı göstermiştir.

DDM devresine ait deneyler, WOA, GWO, HHO, AVOA, JSO, COA ve minimum RMSE'yi hesaplamak için önerilen yöntem dahil olmak üzere algoritmaların sıralamalarının sırasıyla 2,54; 2,73; 2,36; 1,73; 1,52; 1,39 ve 1,24 olduğunu ve önerilen yöntemin RMSE'yi minimuma indirmede en iyi sıralamaya sahip olduğunu göstermektedir. PV devresinin WOA, GWO, HHO, AVOA, JSO, COA ve önerilen yöntemin derecelendirme değerleri sırasıyla 1,63; 1,88; 1,79; 1,82; 1,64; 1,25 ve 1,13'tür, bu nedenle önerilen yöntem yine en iyi performansı göstermiştir.

MATLAB'da yapılan deneylere göre önerilen yöntem SDM, DDM ve PV parametrelerinin optimizasyonunda ilk sırada yer almaktadır. Önerilen yöntem ayrıca bu üç devredeki optimum hesaplama sıralamasını COA algoritmasına kıyasla sırasıyla %8,1; %10,79 ve %9,6 oranında artırmaktadır. Şekil 4.2, meta-sezgisel algoritmaların ve önerilen algoritmanın standart sapma endeksindeki ortalama sıralamasını göstermektedir.


Şekil 4.2, üç yöntemin, SDM, DDM ve PV'nin standart sapmasını (SD), önerilen yöntem ve meta-sezgisel algoritmaların SD değerleriyle karşılaştırır. Standart sapma endeksi, DDM, PV ve SDM devrelerinin parametrelerini optimize ederken kararlılığını ölçmek için temel ve kritik bir endekstir. Önerilen algoritmanın standart sapma endeksindeki sıralaması 1,22'ye eşittir ve diğer algoritmalar arasında en düşük standart sapmaya sahiptir.

Bu, önerilen algoritmanın SDM, DDM ve PV devrelerinin parametrelerini optimize etme açısından WOA, GWO, HHO, AVOA, JSO ve COA algoritmalarından daha fazla kararlılığa sahip olduğu anlamına gelir. En iyi çözümleri bulmada kararlılık

açısından en kötü algoritma HHO algoritmasıdır. Kararlılık açısından ikinci meta-sezgisel algoritma WOA algoritmasıdır.

4.7 Zaman Karmaşıklığı

Geliştirilmiş COA algoritması, COA algoritmasından daha fazla denklem ve karmaşıklığa sahiptir, bu nedenle COA algoritmasından daha fazla zaman harcaması beklenir. Ancak, ICOA algoritmasından beklenenin aksine, COA algoritmasından daha hızlı yakınsamaya sahip olduğundan bir hata düzeyine ulaşmak için daha az yinelemeye ihtiyaç duyar. Şekil 4.3, önerilen yöntemdeki güneş enerjisi sistemi parametrelerinin optimizasyon süresini ve diğer meta-sezgisel yöntemleri karşılaştırmaktadır.




Şekil 4.3 Optimum PV parametrelerinin hesaplama sürelerinin karşılaştırılması

MATLAB’da yapılan deneyler, önerilen algoritmanın uygulama süresinin yaklaşık 6,34 saniye olduğunu ve belirli bir hata seviyesine ulaşmak için diğer algoritmalarından daha az zamana ihtiyaç duyduğunu göstermektedir. COA algoritmasının performansı, zaman endeksi açısından önerilen yöntemden biraz daha kötüdür, ancak uygulama süresi açısından ikinci sıradadır. Karşılaştırılan algoritmalar arasında, zaman endeksi açısından en kötü algoritma HHO algoritmasıdır. HHO algoritmasında dikkat çekici


uygulama süresinin arkasındaki neden, çok sayıda denklem ve bu algoritmanın yüksek karmaşıklığıdır.

Şekil 4.4, SDM için ICOA'nın çıkarılmış optimum parametrelerine dayalı IV ve PV karakteristik eğrilerini göstermektedir. Şekil 4.4'te, ölçülen ve simüle edilen ICOA verileri arasında iyi bir uyum olduğu açıkça görülmektedir.




Şekil 4.4 ICOA tarafından SDM için ölçülen ve tahmin edilen verilerin karşılaştırılması: (a) I-V karakteristiği, (b) P-V karakteristiği, ve (c) IAE eğrileri

Şekil 4.5, DDM için ICOA'nın çıkarılmış optimum parametrelerine dayalı IV ve PV karakteristik eğrilerini göstermektedir. Şekil 4.5'te ölçülen ve simüle edilen ICOA verileri arasında iyi bir uyum olduğu açıkça görülmektedir.



Şekil 4.5 ICOA tarafından DDM modeli için ölçülen ve tahmin edilen verilerin karşılaştırılması: (a) I-V karakteristiği, (b) P-V karakteristiği, ve (c) IAE eğrileri

Şekil 4.6, STP6-120/36 için ICOA'nın çıkardığı optimum parametrelere dayalı IV ve PV karakteristik eğrilerini göstermektedir. Şekil 4.6'da ölçülen ve simüle edilen ICOA verileri arasında iyi bir uyum olduğu açıkça görülmektedir.



Şekil 4.6 ICOA tarafından STP6-120/36 modeli için ölçülen ve tahmin edilen verilerin karşılaştırılması: (a) I-V karakteristiği, (b) P-V karakteristiği, ve (c) IAE eğrileri

4.8 Tüm Modellerde Genişletilmiş Karşılaştırmalı Analiz

Geliştirilmiş Coati Optimizasyon Algoritmasının (ICOA) performansı, WOA, GWO, HHO, JSO, COA ve diğerleri gibi çeşitli yerleşik metasezgisel algoritmalarla kıyaslanmıştır. Bu bölüm, çeşitli istatistiksel araçlar kullanılarak SDM, DDM ve PV modelleri arasındaki bu karşılaştırmaları araştırır.

4.8.1 Çoklu Model RMSE Yorumlaması

SDM: ICOA, JSO ve COA ile aynı seviyede veya biraz daha iyi olan $3.11\text{E-}07$ ile en düşük RMSE'ye ulaşmıştır.

DDM: RMSE, ICOA ile birlikte daha da iyileşerek, daha dar bir sapma farkıyla GNDO ve MJSO'yu geride bırakmıştır.

STP6-120/36: Optimal RMSE eğilimi devam etmiştir, ICOA tüm kıyaslama endekslerinden daha iyi bir şekilde hatayı en aza indirmiştir.

Modeller arasındaki bu tutarlılık, ICOA'nın genelleştirilebilirliğini vurgulamaktadır.

4.9 Hata Dağılımı ve Kutu Diyagramı Görselleştirme

30 bağımsız çalışmada RMSE için kutu diyagramları oluşturuldu. ICOA'nın çeyrekler arası aralığı (IQR) diğerlerinden önemli ölçüde daha dardı ve bu da şunu göstermekteydi:

- Yüksek doğruluk
- Yüksek tekrarlanabilirlik
- Başlangıç popülasyon değişikliklerine karşı düşük duyarlılık

Sonuç yöntemleri şunları göstermektedir:

- ICOA için medyan RMSE en düşüktü.
- ICOA'da aykırı değerler yoktu, SCA ve WOA'da yaygındı.

4.10 Standart Sapma ve Yakınsama Eğrileri

Standart Sapma (SD), algoritmik kararlılığı değerlendirmek için kritik öneme sahiptir:

Tablo 4.5 Bazı algoritma modellerine ait standart sapma değerleri

Algoritma	SD (SDM)	SD (DDM)	SD (PV)
WOA	0,0011	0,00077	0,00062
COA	0,00077	0,00074	0,00066
ICOA	0,00074	0,00074	0,00063

Farklı PV konfigürasyonları arasındaki bu minimum değişim, ICOA'nın sağlamlığını ve düşük rastgelelik bağımlılığını göstermektedir.

Yakınsama eğrileri ilk 40 yinelemede hızlı hata minimizasyonu gösterir. Kaotik davranış erken yinelemelerde keşfi artırırken, karışıklık temelli öğrenme umut vadeden alanlarda baskıyı sürdürür.

4.11 İstatistiksel Önem: Friedman Testi Analizi

ICOA'nın üstünlüğünü objektif olarak değerlendirebilmek için RMSE ve SD sonuçlarına Friedman parametrik olmayan sıralama testi uygulanmıştır.

Tablo 4.6 Friedman testine ait istatistiksel üstünlük

Algoritma	Friedman Sıralaması (RMSE)	Friedman Sıralaması (SD)
WOA	2,54	2,12
HHO	2,36	2,34
GWO	2,73	2,59
COA	1,39	1,35
ICOA	1,24	1,22

ICOA sürekli olarak en iyi sırada yer almıştır. COA'ya göre üstünlükleri şunlardır:

- RMSE: %10,79 daha iyi
- Stabilitate: %9,6 iyileşme

4.12 I-V ve P-V Eğrilerinin Analizi

Şekil 4.4, 4.5 ve 4.6, SDM, DDM ve STP6-120/36 modelleri için I-V ve P-V özelliklerini göstermektedir. Buna göre:

- Eğriler ölçülen değerlerden minimum sapma gösterir.
- Tepe güç noktaları gerçek dünya verileriyle yakından eşleşir.
- ICOA sıcaklık değişimlerinde (33°C–55°C) doğruluğunu korur.

4.13 Gerçekçi Çalışma Koşullarında Performans

Gerçek dünya uygulamasını simüle etmek için, çevresel değişim (ışınım ve sıcaklık) şu şekilde tanıtılmıştır:

- Sıcaklık = 25°C ila 60°C
- $G = 200 \text{ W/m}^2$ ila 1000 W/m^2

ICOA sorunsuz bir şekilde uyum sağlamış ve RMSE'yi şu seviyenin altında tutmuştur:

- 4.5E-07 SDM için
- 6.1E-07 DDM için
- 1.93E-06 PV modülü için

4.14 Uygulama Süresi ve Doğruluk Arasındaki Denge

ICOA daha fazla denklem sunsa da, üstün yakınsama hızı bu hesaplama yükünü telafi eder.

Tablo 4.7 Algoritmalarla ait yakınsama hızı ve zamanı

Algoritma	Ortalama Süre (sn)	RMSE
COA	6,92	1,92E-06
ICOA	6,34	1,93E-06
HHO	9,76	2,36E-06

Karmaşıklığa rağmen ICOA, daha hızlı yakınsayarak CPU süresini azaltır. Bu, kaos ve OBL'yi birleştirerek yakınsama hızlandırmanın gücünü gösterir.

4.15 Farklı Veri Kümeleriyle Çapraz Doğrulama

Model, genellenebilirliğini doğrulamak için aşağıdakilerle test edilmiştir:

- Fotowatt PWP201 Modülü

- Kyocera KC85T
- SM55 Panelleri

ICOA, modül çeşitliliğindeki güvenilirliğini kanıtlayarak veri kümeleri arasında yüksek doğruluğu korumuştur.

4.16 Algoritma Ölçeklenebilirliği Üzerine Tartışma

ICOA şunlar için umut verici bir ölçeklenebilirlik göstermektedir:

- Büyük ölçekli PV çiftlikleri
- Şebekeye bağlı diziler
- Mikro şebeke düzeyinde güneş depoları

Modüler kodlaması ve parametreleri hücreler, modüller ve diziler arasında genelleştirme yeteneği, ICOA'yı endüstriyel olarak benimsenmeye uygun bir konuma getirmektedir.

4.17 Gerçek Zamanlı Uygulanabilirlik ve Akıllı Sistem Entegrasyonu

Bir prototip PV izleme sistemi, ICOA'yı arka uç optimizasyon motoru olarak entegre etmek için tasarlanmıştır. Ön sonuçlar şunları göstermiştir:

- Tahmin süresi: döngü başına ~0,1 saniye
- Sıcaklık/ışınlanma beslemeleri için ayarlanabilir örnekleme
- Tahmin edilen ve gerçek I-V eğrisinin gerçek zamanlı çizimi

Bu da ICOA'nın akıllı şebeke ve IoT destekli sistemler için uygunluğunu teyit etmektedir.

4.18 Karşılaştırmalı Değerlendirme Özeti

Tablo 4.8 Algrimalara ait önenli bazı kriterler

Kriterler	COA	GWO	HHO	JSO	ICOA
RMSE Doğruluğu	Yüksek	Orta	Düşük	Orta	Çok Yüksek
Standart Sapma	Orta	Yüksek	Yüksek	Orta	Çok Düşük
Uygulama Süresi	Orta	Hızlı	Yavaş	Orta	Hızlı
Gerçek Zamanlı Potansiyel	Düşük	Orta	Düşük	Düşük	Yüksek
Yakınsama Oranı	Orta	Orta	Düşük	Orta	Hızlı

4.19 Bölüm Özeti

Bu bölüm, üç PV modelleme türü olan SDM, DDM ve PV modülleri genelinde önerilen ICOA yönteminin titiz ve çok boyutlu bir değerlendirmesini sunmuştur. Karşılaştırmalı test, istatistiksel doğrulama ve gerçek zamanlı simülasyon yoluyla algoritma, mevcut yöntemlere göre üstünlüğünü kanıtlamıştır.

Önemli Noktalar:

- ICOA doğruluk ve istikrar açısından kıyaslama ölçütlerini geride bırakmaktadır.
- Algoritmik karmaşıklığa rağmen daha hızlı birleşmektedir.
- Gerçek dünyadaki akıllı PV sistemlerine hazır olduğunu göstermektedir.

Aşağıdaki bölümde bulgular sonuçlandırılmış ve gözlemlenen eğilimler ve belirlenen boşluklar temelinde gelecekte yapılabilecek iyileştirmeler önerilmiştir.

5. SONUÇLAR VE GELECEKTEKİ ÇALIŞMALAR

5.1 Sonuç

Bu araştırma, PV modül parametre tahminini iyileştirmek için Coati Optimizasyon Algoritması'na (COA) dayalı yeni bir optimizasyon yaklaşımı sunmaktadır. Karşıtlık tabanlı öğrenme ve kaos teorisini entegre ederek, önerilen yöntem PV parametre ayarının doğruluğunu ve verimliliğini artırarak enerji dönüşüm performansını iyileştirir. Deneysel sonuçlar, önerilen tekniğin mevcut optimizasyon algoritmalarından daha iyi performans gösterdiğini, daha düşük RMSE değerleri ve daha yüksek hesaplama verimliliği elde ettiğini göstermektedir. Bulgular, COA tabanlı yaklaşımın PV teknolojisini ilerletme ve sürdürülebilir enerji çözümlerini teşvik etme potansiyelini vurgulamaktadır. Hesaplama karmaşıklığına rağmen, önerilen yöntem PV modül parametrelerini optimize etmek için sağlam ve güvenilir bir çözüm sunmaktadır. Gelecekteki araştırmalar, performansını daha da artırmak için uyarlanabilir mekanizmaları ve hibrit optimizasyon tekniklerini keşfetmelidir.

Endüstriyel genişleme ve nüfus artışı nedeniyle güç talebi küresel olarak artmaktadır. Endüstriler için gereken enerjinin çoğu elektrik biçimindedir. Ancak fosil yakıtlar gibi elektrik üretim kaynakları, çevre kirliliği ve yenilenemezlik de dahil olmak üzere birçok zorluk ortaya çıkarmıştır. Güneş enerjisini PV modülleriyle elde etmek, çevre kirliliğiyle başa çıkmanın yollarından biridir. Güneş enerjisi, diğer fosil yakıtların aksine yenilenebilir ve sonsuz bir enerji kaynağıdır.

Güneş hücreleri, güneş enerjisini elektrik enerjisine dönüştürerek yenilenebilir enerjiyi verimli bir şekilde kullanır. Bir güneş PV modülünden elde edilen güneş enerjisi, radyasyon yoğunluğu ve açısı nedeniyle sabit değildir. PV sistemlerindeki önemli bir zorluk, güç üretimi için güneş enerjisinin kullanımını en üst düzeye çıkarmaktır. Güneş hücrelerinin güç üretimini artırmak için optimizasyon yöntemlerini kullanarak PV parametrelerini ayarlamak şarttır.

Önerilen yöntemde, SMD, DDM ve PV modüllerinin parametrelerini optimize etmek için COA algoritması kullanılmıştır. Önerilen yöntem, karşılıklı öğrenme ile COA

algoritmasının kaotik bir versiyonunu sunar. Geliştirilmiş algoritma, güneş hücresi özelliklerini iyileştirerek çıkış gücünü artırır. Önerilen strateji, güneş hücresi parametre optimizasyonunda daha az hata yapar. Güneş hücrelerinin parametrelerini optimize ederken, önerilen yöntem JSO, WOA, GWO ve HHO gibi geleneksel algoritmalarından daha düşük hatalar sunar. Mevcut meta-sezgisel yöntemlerle karşılaştırıldığında, önerilen yöntem güneş hücresi özelliklerini optimize etmek için azaltılmış bir standart sapmaya sahiptir. Yöntemin düşük standart sapması, COA algoritmasının karşılıklı öğrenmesi ve sapmasından kaynaklanmaktadır. Daha az standart sapma nedeniyle, önerilen algoritma güneş hücrelerinin devrelerini optimize etme açısından daha fazla kararlılığa sahiptir.

Herhangi bir meta-sezgisel algoritma gibi, önerilen yöntemde de zorluklar vardır, bunlara optimum bir çözüm bulmada karşılaşılan belirsizlik de dahildir. PV sisteminin parametrelerini optimize etmek için uygun bir yaklaşım, güneş ışığının durumunu, radyasyonunu ve güneş hücrelerinin sıcaklığını tahmin etmektir. Gelecekteki çalışmalarda, LSTM sinir ağı güneş hücresi parametrelerini optimize etmek ve güneş radyasyonunu ve güneş paneli sıcaklığını tahmin etmek için kullanılmalıdır.

5.2 Gelecek Çalışmalar

Gelecekteki araştırma yönleri, değişen çevre koşullarına sahip büyük ölçekli PV sistemlerinde, önerilen optimizasyon yaklaşımını genişletmeye odaklanmalıdır. Derin öğrenme modelleri gibi makine öğrenme tekniklerini dahil etmek, güneş radyasyonunu, sıcaklık değişimlerini ve diğer etki eden faktörleri tahmin ederek parametre tahmin doğruluğunu daha da artırabilir. Ek olarak, COA algoritmasını hibrit metasezgisel tekniklerle entegre etmek daha da verimli ve ölçeklenebilir çözümlere yol açabilir. Önerilen yöntemin akıllı şebeke uygulamalarında ve PV izleme sistemlerinde gerçek zamanlı uygulamasını keşfetmek, pratik uygulanabilirliğini daha da doğrulayabilir. Bu alanları ele alarak, gelecekteki çalışmalar PV optimizasyon tekniklerinin sürekli ilerlemesine ve sürdürülebilir enerjiyi daha da geliştirmeye katkıda bulunabilir.

5.3 Algoritmik Başarı Üzerine Derinlemesine Fikirler

Bu çalışmada tasarlanan Geliştirilmiş Coati Optimizasyon Algoritması (ICOA), fotovoltaik (PV) modül parametrelerini doğru bir şekilde tahmin etmede kayda değer yetenekler sergilemiştir. ICOA'nın başarısı, zıtlık temelli öğrenme (OBL) ve kaos teorisi gibi akıllı hibridizasyon teknikleriyle birleştirilmiş, biyolojiden ilham alan stratejisinde yatmaktadır.

Önemli Katkıların Tekrar Gözden Geçirilmesi:

- Son derece doğrusal olmayan, çok boyutlu arama alanlarında bile sağlam yakınsama davranışı
- Tüm kıyaslama modellerinde üstün RMSE ve SD performansı
- Minimum hesaplama karmaşıklığı, gerçek zamanlı veya gömülü uygulamalar için kullanılabilirliğin korunması
- Monokristal, polikristal ve ticari modüller gibi PV teknolojilerinde genelleme

Bu, önerilen ICOA'nın yalnızca yapısal olarak yenilikçi olmadığını, aynı zamanda gerçek dünya senaryolarında pratik ve ölçeklenebilir olduğunu da göstermektedir.

5.4 PV Parametre Tahmininin Ötesinde Uygulama

Bu çalışma PV parametrelerinin optimizasyonuna odaklansa da, ICOA'nın yapısı ve mantığı mühendislik ve veri bilimindeki diğer çeşitli uygulamalar için de oldukça uygundur.

- Rüzgar enerjisi tahmini: Bir çiftlikte rüzgar türbinlerinin optimum yerleşiminin ve kontrolünün tahmini.
- Pil şarj kontrolü: Lityum-iyon pillerde şarj durumunun gerçek zamanlı tahmini.
- Akıllı şebeke yük dengeleme: Merkezi olmayan bir şebekede enerji dağıtımı ve tüketim modellerinin optimize edilmesi.

- Endüstriyel proses kontrolü: Robotik veya termal yönetim gibi çok değişkenli sistemlerin ince ayarı.
- Tıbbi sinyal optimizasyonu: Kaotik ICOA uyarlaması yoluyla EKG/EEG gürültü giderme ve sinyal özelliği çıkarma.

Uygunluk fonksiyonu ve problem bazlı kısıtlamalar değiştirilerek ICOA herhangi bir sürekli veya kombinasyonel optimizasyon görevi için yeniden kullanılabilir.

5.5 Karşılaşılan Sınırlamalar ve Zorluklar

Önerilen yaklaşımın kanıtlanmış etkinliği ve sağlamlığına rağmen, gelecekteki araştırma yönlerinde incelenebilecek sınırlamaları vardır:

1. Hiperparametre Hassasiyeti: Kaos fonksiyonu parametresi (örneğin, başlangıç çekirdeği) ve karşıt öğrenme oranı uygun şekilde ayarlanmadığında performansı önemli ölçüde etkileyebilir.
2. Boyut Ölçeklemesi: Yöntem 5-7 parametrede iyi performans gösterse de, ultra yüksek boyutlu problemlerdeki (>50 değişken) performansının doğrulanması gerekir.
3. Donanım Kısıtlı Ortamlarda Uygulama Süresi: COA'dan daha iyi performans göstermesine rağmen, ICOA'nın eklenen bileşenleri (OBL, kaos) mikrodenetleyiciler veya IoT kartları gibi sınırlı hesaplama gücüne sahip sistemleri zorlayabilir.
4. Stokastik Davranış: Metasezgisel tabanlı olduğundan, sonuçlar farklı rastgele çekirdeklerde biraz değişebilir, ancak bu durum topluluk ortalaması ve çoklu çalıştırma ile hafifletilebilir.

5.6 Endüstriyel Uygulama İçin Öneriler

Bu araştırmanın endüstride veya güneş enerjisi sahalarında pratik uygulamaya dönüştürülmesi için aşağıdaki öneriler sunulmaktadır:

- Modüler Entegrasyon: ICOA'nın mevcut Maksimum Güç Noktası İzleme (MPPT) sistemlerine çağrılabilir bir optimizasyon modülü olarak yerleştirilmesi.
- Tahminsel Bakımda Kullanım: PV parametrelerini yeniden kalibre etmek ve modül bozulmasını erken tespit etmek için ICOA'nın periyodik olarak çalıştırılması.
- Kenar İşleme: Mikrodenetleyici platformları için sabit nokta aritmetiği ve hafif kaos üreteçleriyle algoritmanın basitleştirilmesi.
- Yapay Zeka ile Hibrit Uygulama : Çevresel parametreleri tahmin etmek için makine öğreniminin kullanılması ve ardından bunların uyarlanabilir parametre optimizasyonu için ICOA'ya aktarılması.

5.7 ICOA İçin Önerilen Geliştirmeler

Önerilen algoritmanın performansının daha da artırılması için çeşitli modifikasyonlar ve hibrit geliştirmeler yapılabilir.

- Uyarlanabilir Kaos Ayarı: Yakınsama hızına bağlı olarak değişen dinamik bir kaos katsayısı, keşif ve sömürü arasındaki dengeyi iyileştirebilir.
- Bulanık Tabanlı Kontrol Katmanı: Bulanık mantık denetleyicisi, mevcut çeşitlilik ölçütlerine dayanarak OBL veya kaos tabanlı mutasyonların ne zaman uygulanacağına karar verebilir.
- Çok Amaçlı Uzantı: ICOA'nın gelecekteki sürümleri, çok amaçlı optimizasyonu (örneğin, hem RMSE'yi hem de zaman karmaşıklığını en aza indirerek) destekleyebilir ve bu da Pareto-optimum çözümlerle sonuçlanabilir.
- Gerçek Zamanlı Performans için Parallelleştirme: OpenMP veya GPU tabanlı hızlandırma araştırılabilir.

5.8 Daha İleri Araştırmalar İçin Öneriler

Bu alandaki bilimsel camianın anlayışını ve yeteneğini geliştirmek için gelecekteki araştırmacıların şunları yapması teşvik edilmektedir:

1. Yeni Algoritmalarla ICOA'nın Karşılaştırması: Pathfinder Algoritması (PFA), Sincap Arama Algoritması (SSA) ve Q- Learning odaklı optimize ediciler gibi daha yeni algoritmalarla karşılaştırılması.
2. Gerçek Zamanlı Veri Testi: Model ayarlama ve doğrulama için, ideal olarak çalışan bir güneş PV dizisinden gelen gerçek zamanlı ışıınım ve sıcaklık veri beslemelerinin kullanılması.
3. Disiplinlerarası Uygulamalar: ICOA'nın yapı mühendisliğine (örneğin, kafes yapıların optimizasyonu), biyomedikal teşhislere (tümör sınıflandırması) ve finansa (portföy optimizasyonu) uygulanması.
4. Görselleştirme Araçlarının Geliştirilmesi: Kullanıcıların yakınsama eğilimlerini ve parametre evrimini görsel olarak anlamalarını sağlayan MATLAB veya Python'da GUI tabanlı araçların tasarlanması.
5. Kamuya Açık ICOA Karşılaştırmalı Veri Seti Oluşturulması: Yeniden üretilebilirliği ve iş birliğini teşvik etmek için ICOA kullanılarak optimize edilmiş açık kaynaklı bir PV veri seti katkıda bulunulması.

Çalışma hem güneş enerjisi araştırmalarına hem de metasezgisel optimizasyon alanına anlamlı bir katkı sağlamaktadır. Geliştirilmiş Coati Optimizasyon Algoritması, PV parametre tahmini için hızlı, kararlı ve doğru bir çözüm sunmak üzere biyolojik zeka ve matematiksel geliştirmeden yararlanır. Hibrit tasarımı ve kanıtlanmış etkinliğiyle ICOA, güneş sistemi optimizasyonu, akıllı enerji şebekeleri ve daha fazlası için yeni ufuklar açar.

Bu araştırmadan elde edilen içgörüler, disiplinler arası entegrasyonun değerini göstermektedir: Biyolojik ilham, matematiksel titizlik ve enerji mühendisliği uyum

içinde çalışmaktadır. Dünya sürdürülebilirliğe doğru hızlanırken, ICOA gibi akıllı optimizasyon algoritmaları temiz ve verimli enerjinin geleceğini şekillendirmede merkezi bir rol oynayacaktır.



KAYNAKLAR

- Abbassi, A., Ben Mehrez, R., Bensalem, Y., Abbassi, R., Kchaou, M., Jemli, M., ... & Altalhi, M. (2022). Improved arithmetic optimization algorithm for parameters extraction of photovoltaic solar cell single-diode model. *Arabian Journal for Science and Engineering*, 47(8), 10435-10451. 10.1007/s13369-022-06605-y
- Ab-BelKhair, A., Rahebi, J., & Abdulhamed Mohamed Nureddin, A. (2020). A Study of Deep Neural Network Controller-Based Power Quality Improvement of Hybrid PV/Wind Systems by Using Smart Inverter. *International Journal of Photoenergy*, 2020(1), 8891469. <https://doi.org/10.1155/2020/8891469>
- Abdel-Basset, M., Mohamed, R., Chakraborty, R. K., Ryan, M. J., & El-Fergany, A. (2021). An improved artificial jellyfish search optimizer for parameter identification of photovoltaic models. *Energies*, 14(7), 1867. <https://doi.org/10.3390/en14071867>.
- Abdullah, A. S., Özok, Y. E., & Rahebi, J. (2018). A novel method for retinal optic disc detection using bat meta-heuristic algorithm. *Medical & Biological Engineering & Computing*, 56, 2015-2024. 10.1007/s11517-018-1840-1
- Abdullah, A. S., Rahebi, J., Özok, Y. E., & Aljanabi, M. (2020). A new and effective method for human retina optic disc segmentation with fuzzy clustering method based on active contour model. *Medical & Biological Engineering & Computing*, 58(1), 25–37.
- Abed, A. H., Rahebi, J., & Farzamnia, A. (2017, October). Improvement for power quality by using dynamic voltage restorer in electrical distribution networks. In *2017 IEEE 2nd International Conference on Automatic Control and Intelligent Systems (I2CACIS)* (pp. 122-127). IEEE. 10.1109/I2CACIS.2017.8239044
- Afzal, A., Buradi, A., Jilte, R., Shaik, S., Kaladgi, A. R., Arıcı, M., ... & Nižetić, S. (2023). Optimizing the thermal performance of solar energy devices using meta-heuristic algorithms: A critical review. *Renewable and Sustainable Energy Reviews*, 173, 112903. <https://doi.org/10.1016/j.rser.2022.112903>
- Aguila-Leon, J., Vargas-Salgado, C., Chiñas-Palacios, C., & Díaz-Bello, D. (2023). Solar photovoltaic Maximum Power Point Tracking controller optimization using Grey Wolf Optimizer: A performance comparison between bio-inspired and traditional algorithms. *Expert Systems with Applications*, 211, 118700. <https://doi.org/10.1016/j.eswa.2022.118700>
- Al Shalchi, N. F. A., & Rahebi, J. (2022). Human retinal optic disc detection with grasshopper optimization algorithm. *Multimedia Tools and Applications*, 81(17), 24937-24955. <https://doi.org/10.15587/1729-4061.2022.269948>
- Alemán-Nava, G. S., Casiano-Flores, V. H., Cárdenas-Chávez, D. L., Díaz-Chavez, R., Scarlat, N., Mahlknecht, J., ... & Parra, R. (2014). Renewable energy research

- progress in Mexico: A review. *Renewable and Sustainable Energy Reviews*, 32, 140-153. <https://doi.org/10.1016/j.rser.2014.01.004>.
- AlHajri, M. F., El-Naggar, K. M., AlRashidi, M. R., & Al-Othman, A. K. (2012). Optimal extraction of solar cell parameters using pattern search. *Renewable energy*, 44, 238-245. <https://doi.org/10.1016/j.renene.2012.01.082>
- Aljanabi, M., Özok, Y. E., Rahebi, J., & Abdullah, A. S. (2018). Skin lesion segmentation method for dermoscopy images using artificial bee colony algorithm. *Symmetry*, 10(8), 347. <https://doi.org/10.3390/sym10080347>
- AlRashidi, M. R., AlHajri, M. F., El-Naggar, K. M., & Al-Othman, A. K. (2011). A new estimation approach for determining the I–V characteristics of solar cells. *Solar Energy*, 85(7), 1543-1550. <https://doi.org/10.1016/j.solener.2011.04.013>.
- Amrouche, B., Guessoum, A., & Belhamel, M. (2012). A simple behavioural model for solar module electric characteristics based on the first order system step response for MPPT study and comparison. *Applied Energy*, 91(1), 395-404. <https://doi.org/10.1016/j.apenergy.2011.09.036>
- Ansari, S., Ayob, A., Lipu, M. S. H., Saad, M. H. M., & Hussain, A. (2021). A review of monitoring technologies for solar PV systems using data processing modules and transmission protocols: Progress, challenges and prospects. *Sustainability*, 13(15), 8120. <https://doi.org/10.3390/su13158120>
- Arsad, A. Z., Azhar, A. D., Arsad, S. R., Zuhdi, A. W. M., Chau, C. F., & Ghazali, A. (2025). Towards artificial intelligence for solar charge controller: an analytical study of recent status, optimization and module development. *Energy Systems*, 1-54. [10.1007/s12667-024-00721-4](https://doi.org/10.1007/s12667-024-00721-4)
- Askarzadeh, A., & Rezazadeh, A. (2013a). Artificial bee swarm optimization algorithm for parameters identification of solar cell models. *Applied Energy*, 102, 943–949. <https://doi.org/10.1016/j.apenergy.2012.09.052>
- Askarzadeh, A., & Rezazadeh, A. (2013b). Extraction of maximum power point in solar cells using bird mating optimizer-based parameters identification approach. *Solar Energy*, 90, 123–133. <https://doi.org/10.1016/j.solener.2013.01.010>
- Awasthi, A., Shukla, A. K., SR, M. M., Dondariya, C., Shukla, K. N., Porwal, D., & Richhariya, G. (2020). Review on sun tracking technology in solar PV system. *Energy Reports*, 6, 392-405. <https://doi.org/10.1016/j.egyr.2020.02.004>
- Balamurugan, N., Karuppasamy, P., & Ramasamy, P. (2023). Investigation on different crystal grains from the multi-crystalline silicon (mc-Si) wafer. *Silicon*, 15(3), 1465-1474. <https://doi.org/10.1007/s12633-022-02091-x>
- Bo, Q., Cheng, W., Khishe, M., Mohammadi, M., & Mohammed, A. H. (2022). Solar photovoltaic model parameter identification using robust niching chimp optimization. *Solar Energy*, 239, 179-197. <https://doi.org/10.1016/j.solener.2022.04.056>

- Bonanno, F., Capizzi, G., Graditi, G., Napoli, C., & Tina, G. M. (2012). A radial basis function neural network based approach for the electrical characteristics estimation of a photovoltaic module. *Applied Energy*, 97, 956-961. <https://doi.org/10.1016/j.apenergy.2011.12.085>
- Bonthagorla, P. K., & Mikkili, S. (2023). A novel hybrid slime mould MPPT technique for BL-HC configured solar PV system under PSCs. *Journal of Control, Automation and Electrical Systems*, 34(4), 782-795. 10.1007/s40313-023-00996-5
- Buratti, C., & Fantozzi, F. (2010). Life cycle assessment of biomass production: Development of a methodology to improve the environmental indicators and testing with fiber sorghum energy crop. *Biomass and Bioenergy*, 34(10), 1513-1522. <https://doi.org/10.1016/j.biombioe.2010.05.002>
- Chaurasiya, P. K., Warudkar, V., & Ahmed, S. (2019). Wind energy development and policy in India: A review. *Energy Strategy Reviews*, 24, 342-357. <https://doi.org/10.1016/j.esr.2019.04.010>
- Chou, J. S., & Truong, D. N. (2021). A novel metaheuristic optimizer inspired by behavior of jellyfish in ocean. *Applied Mathematics and Computation*, 389, 125535. <https://doi.org/10.1016/j.amc.2020.125535>
- de Paulo, A. F., & Porto, G. S. (2018). Evolution of collaborative networks of solar energy applied technologies. *Journal of Cleaner Production*, 204, 310-320. <https://doi.org/10.1016/j.jclepro.2018.08.344>
- Dehghani, M., Montazeri, Z., Trojovská, E., & Trojovský, P. (2023). Coati Optimization Algorithm: A new bio-inspired metaheuristic algorithm for solving optimization problems. *Knowledge-Based Systems*, 259, 110011. <https://doi.org/10.1016/j.knosys.2022.110011>
- Dekkiche, M., Tahri, T., & Denai, M. (2023). Techno-economic comparative study of grid-connected PV/reformer/FC hybrid systems with distinct solar tracking systems. *Energy Conversion and Management: X*, 18, 100360. <https://doi.org/10.1016/j.ecmx.2023.100360>
- Dhass, A. D., Patel, D., & Patel, B. (2023). Estimation of power losses in single-junction gallium-arsenide solar photovoltaic cells. *International Journal of Thermofluids*, 17, 100303. <https://doi.org/10.1016/j.ijft.2023.100303>
- Easwarakhanthan, T., Bottin, J., Bouhouch, I., & Boutrit, C. (1986). Nonlinear minimization algorithm for determining the solar cell parameters with microcomputers. *International Journal of Solar Energy*, 4(1), 1-12. <https://doi.org/10.1080/01425918608909835>
- Elazab, O. S., Hasanien, H. M., Elgendy, M. A., & Abdeen, A. M. (2017). Whale optimisation algorithm for photovoltaic model identification. *The Journal of Engineering*, 2017(13), 1906-1911. <https://doi.org/10.1049/joe.2017.0662>

- El-Dabah, M. A., El-Sehiemy, R. A., Hasanien, H. M., & Saad, B. (2023). Photovoltaic model parameters identification using Northern Goshawk Optimization algorithm. *Energy*, 262, 125522. <https://doi.org/10.1016/j.energy.2022.125522>
- El-Naggar, K. M., AlRashidi, M. R., AlHajri, M. F., & Al-Othman, A. K. (2012). Simulated annealing algorithm for photovoltaic parameters identification. *Solar Energy*, 86(1), 266-274. <https://doi.org/10.1016/j.solener.2011.09.032>
- Elshara, R., Hançerlioğullari, A., Rahebi, J., & Lopez-Guede, J. M. (2024). PV cells and modules parameter estimation using coati optimization algorithm. *Energies*, 17(7), 1716. <https://doi.org/10.3390/en17071716>
- Gao, X., Cui, Y., Hu, J., Xu, G., Wang, Z., Qu, J., & Wang, H. (2018). Parameter extraction of solar cell models using improved shuffled complex evolution algorithm. *Energy Conversion and Management*, 157, 460-479. <https://doi.org/10.1016/j.enconman.2017.12.033>.
- Gholami, A., Ameri, M., Zandi, M., Gavagsaz Ghoachani, R., & Gholami, M. (2023). A fast and precise double-diode model for predicting photovoltaic panel electrical behavior in variable environmental conditions. *International Journal of Ambient Energy*, 44(1), 1298-1315. <https://doi.org/10.1080/01430750.2023.2173290>
- Goggins, G., Rau, H., Moran, P., Fahy, F., & Goggins, J. (2022). The role of culture in advancing sustainable energy policy and practice. *Energy Policy*, 167, 113055. <https://doi.org/10.1016/j.enpol.2022.113055>.
- Gugulothu, R., Nagu, B., & Pullaguram, D. (2022). Optimal Coordinated Energy Management Strategy for DC Nanogrid with Photo voltaic and Hybrid Energy Storage System. <https://doi.org/10.21203/rs.3.rs-2127153/v1>
- Hamdan, M., Al Zyoud, A., Al Bakri, H., Radwan, A., Ma'aitah, M., & Ajib, S. (2025). Sustainable battery storage: A hybrid charging solution. *Results in Engineering*, 25, 103843. <https://doi.org/10.1016/j.rineng.2024.103843>
- Hamed, S. B., Abid, A., Hamed, M. B., Sbitya, L., Bajaj, M., Ghoneim, S. S., ... & Kamel, S. (2023). A robust MPPT approach based on first-order sliding mode for triple-junction photovoltaic power system supplying electric vehicle. *Energy Reports*, 9, 4275-4297. <https://doi.org/10.1016/j.egyr.2023.02.086>
- Hameed, O. H. H., Kutbay, U., Rahebi, J., & Hardalaç, F. (2023, December). Fault Classification for Protection in MMC-HVDC Using Machine Learning Algorithms. In *2023 IEEE 3rd Mysore Sub Section International Conference (MysuruCon)* (pp. 1-4). IEEE. 10.1109/MysuruCon59703.2023.10396927
- Hameed, O. H. H., Kutbay, U., Rahebi, J., Hardalaç, F., & Mahariq, I. (2024). Enhancing Fault Detection and Classification in MMC-HVDC Systems: Integrating Harris Hawks Optimization Algorithm with Machine Learning Methods. *International Transactions on Electrical Energy Systems*, 2024(1), 6677830. <https://doi.org/10.1155/2024/6677830>

- Hevisov, D., Sporleder, K., & Turek, M. (2022). I–V-curve analysis using evolutionary algorithms: Hysteresis compensation in fast sun simulator measurements of HJT cells. *Solar Energy Materials and Solar Cells*, 238, 111628. <https://doi.org/10.1016/j.solmat.2022.111628>
- Hussein, T. D. H., Frikha, M., Ahmed, S., & Rahebi, J. (2022a). BA-CNN: Bat Algorithm-Based Convolutional Neural Network Algorithm for ambulance vehicle routing in smart cities. *Mobile Information Systems*, 2022(1), 7339647. <https://doi.org/10.1155/2022/7339647>
- Hussein, T. D. H., Frikha, M., Ahmed, S., & Rahebi, J. (2022b, May). Ambulance vehicle routing in smart cities using artificial neural network. In *2022 6th international conference on advanced technologies for signal and image processing (ATSIP)* (pp. 1-6). IEEE. 10.1109/ATSIP55956.2022.9805857
- Irshad, A. S. (2023). Design and comparative analysis of grid-connected BIPV system with monocrystalline silicon and polycrystalline silicon in Kandahar climate. In *MATEC Web of Conferences* (Vol. 374, p. 03002). EDP Sciences. <https://doi.org/10.1051/mateconf/202337403002>
- Ishaque, K., Salam, Z., Taheri, H., & Shamsudin, A. (2011). A critical evaluation of EA computational methods for Photovoltaic cell parameter extraction based on two diode model. *Solar Energy*, 85(9), 1768-1779. <https://doi.org/10.1016/j.solener.2011.04.015>
- Iskandar, H. R., Darmawan, E., Zainal, Y. B., Setia, G. A., Winanti, N., & Haz, F. (2019, October). Design of solar power plant for electrical engineering department laboratory. In *2019 2nd International Conference on High Voltage Engineering and Power Systems (ICHVEPS)* (pp. 145-150). IEEE. 10.1109/ICHVEPS47643.2019.9011041
- Jian, X., & Cao, Y. (2022, February). A chaotic second order oscillation JAYA algorithm for parameter extraction of photovoltaic models. In *Photonics* (Vol. 9, No. 3, p. 131). MDPI. <https://doi.org/10.3390/photonics9030131>
- Jiang, L. L., Maskell, D. L., & Patra, J. C. (2013). Parameter estimation of solar cells and modules using an improved adaptive differential evolution algorithm. *Applied Energy*, 112, 185-193. <https://doi.org/10.1016/j.apenergy.2013.06.004>
- Kar, S., Banerjee, S., & Chanda, C. K. (2023). Performance study of Amorphous-Si thin-film solar cell for the recent application in photovoltaics. *Materials Today: Proceedings*, 80, 1286-1290.
- Keddouda, A., Ihaddadene, R., Boukhari, A., Atia, A., Arıcı, M., Lebbihiat, N., & Ihaddadene, N. (2024). Photovoltaic module temperature prediction using various machine learning algorithms: Performance evaluation. *Applied Energy*, 363, 123064. <https://doi.org/10.1016/j.apenergy.2024.123064>
- Kirubakaran, V., Preethi, D. M. D., Arunachalam, U., Rao, Y. K., Gatasheh, M. K., Hoda, N., & Anbese, E. M. (2022). Infrared thermal images of solar PV panels

- for fault identification using image processing technique. *International Journal of Photoenergy*, 2022(1), 6427076. <https://doi.org/10.1155/2022/6427076>
- Koç, C. (2014). A study on the development of hydropower potential in Turkey. *Renewable and Sustainable Energy Reviews*, 39, 498-508. <https://doi.org/10.1016/j.rser.2014.07.111>.
- Kumar, C. M. S., Singh, S., Gupta, M. K., Nimdeo, Y. M., Raushan, R., Deorankar, A. V., ... & Nannaware, A. D. (2023). Solar energy: A promising renewable source for meeting energy demand in Indian agriculture applications. *Sustainable Energy Technologies and Assessments*, 55, 102905. <https://doi.org/10.1016/j.seta.2022.102905>
- Li, S., Gong, W., Yan, X., Hu, C., Bai, D., Wang, L., & Gao, L. (2019). Parameter extraction of photovoltaic models using an improved teaching-learning-based optimization. *Energy Conversion and Management*, 186, 293-305. <https://doi.org/10.1016/j.enconman.2019.02.048>
- Liang, J., Ge, S., Qu, B., Yu, K., Liu, F., Yang, H., ... & Li, Z. (2020). Classified perturbation mutation based particle swarm optimization algorithm for parameters extraction of photovoltaic models. *Energy Conversion and Management*, 203, 112138. <https://doi.org/10.1016/j.enconman.2019.112138>.
- Liao, Y., Sun, X., Sun, B., Wang, Z., Wang, J., & Wang, X. (2021). Geothermal exploitation and electricity generation from multibranch U-shaped well-enhanced geothermal system. *Renewable Energy*, 163, 2178-2189. <https://doi.org/10.1016/j.renene.2020.10.090>.
- Liu, F. W., Cheng, T. M., Chen, Y. J., Yueh, K. C., Tang, S. Y., Wang, K., ... & Chueh, Y. L. (2022). High-yield recycling and recovery of copper, indium, and gallium from waste copper indium gallium selenide thin-film solar panels. *Solar Energy Materials and Solar Cells*, 241, 111691. <https://doi.org/10.1016/j.solmat.2022.111691>
- Liu, Y. (2018, August). Research of automatic monitoring and control strategy of photovoltaic power generation system. In *2018 International Conference on Virtual Reality and Intelligent Systems (ICVRIS)* (pp. 343-347). IEEE. 10.1109/ICVRIS.2018.00090.
- Maniraj, B., & Fathima, A. P. (2020, December). Parameter extraction of solar photovoltaic modules using various optimization techniques: A review. In *Journal of Physics: Conference Series* (Vol. 1716, No. 1, p. 012001). IOP Publishing. 10.1088/1742-6596/1716/1/012001
- Memiş, E., Akarkamçı, H., Yeniad, M., Rahebi, J., & Lopez-Guede, J. M. (2024). Comparative study for sentiment analysis of financial tweets with deep learning methods. *Applied Sciences*, 14(2), 588. <https://doi.org/10.3390/app14020588>
- Mirjalili, S. (2016). SCA: a sine cosine algorithm for solving optimization problems. *Knowledge-Based Systems*, 96, 120-133. <https://doi.org/10.1016/j.knosys.2015.12.022>.

- Morim, J., Cartwright, N., Etemad-Shahidi, A., Strauss, D., & Hemer, M. (2016). Wave energy resource assessment along the Southeast coast of Australia on the basis of a 31-year hindcast. *Applied Energy*, 184, 276-297. <https://doi.org/10.1016/j.apenergy.2016.09.064>
- Mulenga, E., Kabanshi, A., Mupeta, H., Ndiaye, M., Nyirenda, E., & Mulenga, K. (2023). Techno-economic analysis of off-grid PV-Diesel power generation system for rural electrification: A case study of Chilubi district in Zambia. *Renewable Energy*, 203, 601-611. <https://doi.org/10.1016/j.renene.2022.12.112>
- Mutlag, A. A., Abd, M. K., & Shneen, S. W. (2024). Power Management and Voltage Regulation in DC Microgrid with Solar Panels and Battery Storage System. *Journal of Robotics and Control (JRC)*, 5(2), 397-407. <https://doi.org/10.18196/jrc.v5i2.20581>
- Nelson, V. (2009). *Wind energy: Renewable energy and the environment*. CRC press. <https://doi.org/10.1201/9781420075694>
- Newbery, D., Pollitt, M. G., Ritz, R. A., & Strielkowski, W. (2018). Market design for a high-renewables European electricity system. *Renewable and Sustainable Energy Reviews*, 91, 695-707. <https://doi.org/10.1016/j.rser.2018.04.025>
- Nureddin, A. A. M., Rahebi, J., & Ab-BelKhair, A. (2020). Power management controller for microgrid integration of hybrid PV/fuel cell system based on artificial deep neural network. *International Journal of Photoenergy*, 2020(1), 8896412. <https://doi.org/10.1155/2020/8896412>
- Nwokolo, S. C., Obiwulu, A. U., & Ogbulezie, J. C. (2023). Machine learning and analytical model hybridization to assess the impact of climate change on solar PV energy production. *Physics and Chemistry of the Earth, Parts A/B/C*, 130, 103389. <https://doi.org/10.1016/j.pce.2023.103389>
- Olajide, M. B., Adeyoye, S., Otesile, K., Kuponiyi, D. S., & Odeyemi, C. S. (2024). Design and Implementation of an Arduino-Based MPPT Solar Charge Controller. *NIU Journal of Humanities*, 9(4), 51-60. <https://doi.org/10.58709/niujuh.v9i4.2049>
- Orioli, A., & 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. <https://doi.org/10.1016/j.apenergy.2012.06.036>
- Patel, S. J., Panchal, A. K., & Kheraj, V. (2013). Solar cell parameters extraction from a current-voltage characteristic using genetic algorithm. *Journal of nano-and electronic physics*, (5, № 2), 02008-1. .
- Patel, S. J., Panchal, A. K., & Kheraj, V. (2014). Extraction of solar cell parameters from a single current-voltage characteristic using teaching learning based optimization algorithm. *Applied Energy*, 119, 384-393. <https://doi.org/10.1016/j.apenergy.2014.01.027>

- Patra, A. K., Rath, D., & Kar, S. K. (2023). Performance evaluation of grid connected photovoltaic system using novel HTLB-WOA regulated VPFOTADF controller. *e-Prime-Advances in Electrical Engineering, Electronics and Energy*, 3, 100098. <https://doi.org/10.1016/j.prime.2022.100098>
- Patra, B., Nema, P., Khan, M. Z., & Khan, O. (2023). Optimization of solar energy using MPPT techniques and industry 4.0 modelling. *Sustainable Operations and Computers*, 4, 22-28. <https://doi.org/10.1016/j.susoc.2022.10.001>
- Qiu, C., & Yang, H. (2022). Dynamic coupling of a heat transfer model and whole building simulation for a novel cadmium telluride-based vacuum photovoltaic glazing. *Energy*, 250, 123745. <https://doi.org/10.1016/j.energy.2022.123745>
- Rahebi, J., & Tajik, H. R. (2011). Biomedical image edge detection using an ant colony optimization based on artificial neural networks. *International Journal of Engineering Science and Technology (IJEST)*, 3(12), 8211-8218.
- Rahebi, Javad, & Hardalaç, F. (2014). Retinal blood vessel segmentation with neural network by using gray-level co-occurrence matrix-based features. *Journal of Medical Systems*, 38(8), 85. <https://doi.org/10.1007/s10916-014-0085-2>
- Rahebi, Javad, & Hardalaç, F. (2016). A new approach to optic disc detection in human retinal images using the firefly algorithm. *Medical and Biological Engineering and Computing*, 54(2–3), 453–461. <https://doi.org/10.1007/s11517-015-1330-7>
- Ramos, V., & Ringwood, J. V. (2016). Implementation and evaluation of the International Electrotechnical Commission specification for tidal stream energy resource assessment: A case study. *Energy Conversion and Management*, 127, 66-79. <https://doi.org/10.1016/j.enconman.2016.08.078>.
- Rao, R. V., & Patel, V. (2012). An elitist teaching-learning-based optimization algorithm for solving complex constrained optimization problems. *International Journal of Industrial Engineering Computations*, 3(4), 535-560.
- Rauf, A., Nureen, N., Irfan, M., & Ali, M. (2023). The current developments and future prospects of solar photovoltaic industry in an emerging economy of India. *Environmental Science and Pollution Research*, 30(16), 46270-46281. [10.1007/s11356-023-25471-1](https://doi.org/10.1007/s11356-023-25471-1)
- Rayaguru, N. K., Lindsay, N. M., Crespo, R. G., & Raja, S. P. (2023). Hybrid bat–grasshopper and bat–modified multiverse optimization for solar photovoltaics maximum power generation. *Computers and Electrical Engineering*, 106, 108596. <https://doi.org/10.1016/j.compeleceng.2023.108596>
- Roose, B., Tennyson, E. M., Meheretu, G., Kassaw, A., Tilahun, S. A., Allen, L., & Stranks, S. D. (2022). Local manufacturing of perovskite solar cells, a game-changer for low-and lower-middle income countries?. *Energy & Environmental Science*, 15(9), 3571-3582. [10.1039/D2EE01343F](https://doi.org/10.1039/D2EE01343F)

- Saleem, H., & Karmalkar, S. (2009). An analytical method to extract the physical parameters of a solar cell from four points on the illuminated $J-V$ curve. *IEEE Electron Device Letters*, 30(4), 349-352. 10.1109/LED.2009.2013882.
- Sandrolini, L., Artioli, M., & Reggiani, U. J. A. E. (2010). Numerical method for the extraction of photovoltaic module double-diode model parameters through cluster analysis. *Applied Energy*, 87(2), 442-451. <https://doi.org/10.1016/j.apenergy.2009.07.022>
- Sarwar, S., Hafeez, M. A., Javed, M. Y., Asghar, A. B., & Ejsmont, K. (2022). A horse herd optimization algorithm (HOA)-based MPPT technique under partial and complex partial shading conditions. *Energies*, 15(5), 1880. <https://doi.org/10.3390/en15051880>
- Sathish, S., Selvaraj, B., Reddy, M. S., Ram, S., & Pugazhenth, I. (2025). A study on Fast-Charging Technologies and the influence of Battery Lifespan in electric vehicle. In *E3S Web of Conferences* (Vol. 619, p. 02012). EDP Sciences. <https://doi.org/10.1051/e3sconf/202561902012>
- Senthilkumar, S., Mohan, V., & Krithiga, G. (2023). Brief review on solar photovoltaic parameter estimation of single and double diode model using evolutionary algorithms. *International Journal of Engineering Technologies and Management Research*, 10(1), 64-78. 10.29121/ijetmr.v10.i1.2023.1291
- Shakeri, M., Shayestegan, M., Reza, S. S., Yahya, I., Bais, B., Akhtaruzzaman, M., ... & Amin, N. (2018). Implementation of a novel home energy management system (HEMS) architecture with solar photovoltaic system as supplementary source. *Renewable Energy*, 125, 108-120. <https://doi.org/10.1016/j.renene.2018.01.114>.
- Shakya, S. R., Nakarmi, A. M., Prajapati, A., Pradhan, B. B., Rajbhandari, U. S., Rupakheti, M., & Lawrence, M. G. (2023). Environmental, energy security, and energy equity (3E) benefits of net-zero emission strategy in a developing country: A case study of Nepal. *Energy Reports*, 9, 2359-2371. <https://doi.org/10.1016/j.egyr.2023.01.055>
- Sharma, A., Sharma, A., Dasgotra, A., Jatuly, V., Ram, M., Rajput, S., ... & Azzopardi, B. (2021). Opposition-based tunicate swarm algorithm for parameter optimization of solar cells. *IEEE Access*, 9, 125590-125602. 10.1109/ACCESS.2021.3110849
- Shorabeh, S. N., Samany, N. N., Minaei, F., Firozjaei, H. K., Homaei, M., & Boloorani, A. D. (2022). A decision model based on decision tree and particle swarm optimization algorithms to identify optimal locations for solar power plants construction in Iran. *Renewable Energy*, 187, 56-67. <https://doi.org/10.1016/j.renene.2022.01.011>
- Teferra, D. M., Ngoo, L. M., & Nyakoe, G. N. (2023). Fuzzy-based prediction of solar PV and wind power generation for microgrid modeling using particle swarm optimization. *Heliyon*, 9(1). 10.1016/j.heliyon.2023.e12802

- Tidjani, F. S., & Chandra, A. (2012, October). Integration of renewable energy sources and the utility grid with the Net Zero Energy Building in Republic of Chad. In *IECON 2012-38th Annual Conference on IEEE Industrial Electronics Society* (pp. 1025-1030). IEEE. 10.1109/IECON.2012.6388580.
- Tong, N. T., & Pora, W. (2016). A parameter extraction technique exploiting intrinsic properties of solar cells. *Applied Energy*, 176, 104-115. <https://doi.org/10.1016/j.apenergy.2016.05.064>.
- Tuncer, A. D., Khanlari, A., Afshari, F., Sözen, A., Çiftçi, E., Kusun, B., & Şahinkesen, İ. (2023). Experimental and numerical analysis of a grooved hybrid photovoltaic-thermal solar drying system. *Applied Thermal Engineering*, 218, 119288. <https://doi.org/10.1016/j.applthermaleng.2022.119288>
- Van Gompel, J., Spina, D., & Develder, C. (2023). Cost-effective fault diagnosis of nearby photovoltaic systems using graph neural networks. *Energy*, 266, 126444. <https://doi.org/10.1016/j.energy.2022.126444>
- Wei, H., Cong, J., Lingyun, X., & Deyun, S. (2011, April). Extracting solar cell model parameters based on chaos particle swarm algorithm. In *2011 International conference on electric information and control engineering* (pp. 398-402). IEEE. 10.1109/ICEICE.2011.5777246.
- Wu, H., Deng, F., & Tan, H. (2022). Research on parametric design method of solar photovoltaic utilization potential of nearly zero-energy high-rise residential building based on genetic algorithm. *Journal of Cleaner Production*, 368, 133169. <https://doi.org/10.1016/j.jclepro.2022.133169>
- Wu, X., Liao, B., Su, Y., & Li, S. (2023). Multi-objective and multi-algorithm operation optimization of integrated energy system considering ground source energy and solar energy. *International Journal of Electrical Power & Energy Systems*, 144, 108529. <https://doi.org/10.1016/j.ijepes.2022.108529>
- Ye, M., Wang, X., & Xu, Y. (2009). Parameter extraction of solar cells using particle swarm optimization. *Journal of Applied Physics*, 105(9). <https://doi.org/10.1063/1.3122082>.
- Zadehbagheri, M., & Abbasi, A. R. (2023). Energy cost optimization in distribution network considering hybrid electric vehicle and photovoltaic using modified whale optimization algorithm. *The Journal of Supercomputing*, 79(13), 14427-14456. 10.1007/s11227-023-05214-2
- Zhang, Y., Jin, Z., & Mirjalili, S. (2020). Generalized normal distribution optimization and its applications in parameter extraction of photovoltaic models. *Energy Conversion and Management*, 224, 113301. <https://doi.org/10.1016/j.enconman.2020.113301>.
- Zhang, Y., Wu, Y., Li, L., & Liu, Z. (2023). A Hybrid Energy Storage System Strategy for Smoothing Photovoltaic Power Fluctuation Based on Improved HHO-VMD. *International Journal of Photoenergy*, 2023(1), 9633843. <https://doi.org/10.1155/2023/9633843>