

Akrep Avlanma Stratejisi Algoritması ile Güneş PV Modellerinin Parametre Tahmini

Yasin BEKTAŞ^{1*}

^{1*}Elektrik-Enerji Bölümü, Aksaray Üniversitesi, Aksaray

<https://orcid.org/0000-0002-3681-0123>

*yasinbektas@aksaray.edu.tr

(Received: 18 September 2025, Accepted: 21 September 2025)

(2nd International Conference on Pioneer and Academic Research ICPAR 2025, September 15-16, 2025)

ATIF/REFERENCE: Bektaş, Y. (2025). Akrep Avlanma Stratejisi Algoritması ile Güneş PV Modellerinin Parametre Tahmini, *International Journal of Advanced Natural Sciences and Engineering Researches*, 9(9), 83-93.

Özet –Bir fotovoltaik (PV) modülü veya güneş hücresi, belirli parametrelerle elektriksel olarak tanımlanan bir devre modeli ile karakterize edilir. Bir PV sisteminin simülasyonu ve işletmesi için, güneş hücresi parametrelerinin deneysel veriler kullanılarak hassas bir şekilde hesaplanması gerekmektedir. Güneş PV sistemi parametrelerinin bilinmeyenlerinin çıkarılması, değişken güneş radyasyonu ve sıcaklık gibi farklı çalışma koşullarında I-V karakteristikleri kullanılarak sistem performansının analiz edilmesini sağlar. Ancak, güneş PV modelinin çözümü doğası gereği oldukça doğrusal olmayan bir yapıya sahiptir. Bu problemi çözmek için verimli bir algoritmaya ihtiyaç vardır. Bu çalışmada, güneş PV model parametrelerinin çıkarılması sorununu çözmek amacıyla, daha önce geliştirilmiş olan Akrep Avlanma Stratejisi (AAS) algoritması uygulanmıştır. Bu yaklaşım, doğrusal olmayan bu sorunun çözümünde etkili bir yöntem olarak kullanılmıştır.

Anahtar Kelimeler – Meta-Sezgisel Algoritma, Akrep Avlanma Stratejisi Algoritması, Çift Diyot Modeli, Solar PV Sistemi.

I. GİRİŞ

Son yıllarda, yenilenebilir enerji kaynaklarının kullanımı, iklim değişikliği ve enerji krizi gibi bir dizi önemli faktör nedeniyle hızla artmaktadır [1]. Güneş enerjisi sistemleri, özellikle büyük ölçekli fotovoltaik (PV) [2] enerji santrallerinde yaygın olarak elektrik üretimi için kullanılmaktadır. Bu sistemler, genellikle açık alanlarda kurulur ve bu nedenle, şiddetli hava koşullarına, örneğin fırtınalar ve kasırgalar gibi olumsuz çevresel faktörlere karşı oldukça hassastır [3]. Bu sorunun çözülmesi için, güneş endüstrisindeki PV sistemlerinin temel özelliklerini doğru bir şekilde belirleyebilecek veri odaklı modellere ihtiyaç duyulmaktadır. Güneş model parametrelerinin ayrıntılı analizi, PV enerji santrallerinin performans değerlendirmeleri, verimlilik hesaplamaları, maksimum güç noktası takibi (MPPT) ve sistemin optimal enerji yönetimi için oldukça faydalıdır [4].

Güneş PV sistemlerinin doğru bir şekilde modellenmesi genel olarak iki aşamadan oluşur: ilk aşama, matematiksel modelin geliştirilmesi; ikinci aşama ise parametrelerin doğru bir şekilde belirlenmesidir. Bu modellerde, tek diyot modeli (SDM) [5] ve çift diyot modeli (DDM) [6] pratikte yaygın olarak kullanılmaktadır. Ancak, parametrelerin tam olarak belirlenmemesi, genellikle ekipman yaşlanmasıyla

birlikte PV modellerinin gerçek performansını olumsuz yönde etkileyebilir, bu da sistemin istikrarsız ve hata eğilimli hale gelmesine yol açar. Bu nedenle, PV hücre parametrelerinin doğru bir şekilde tahmin edilmesi, etkili bir simülasyon için kritik bir adımdır. Ayrıca, PV sistemlerinin kurulumu ve optimizasyonu da daha hassas bir şekilde yapılmalıdır. Ancak, PV modeli doğrusal olmayan ve konveks olmayan ilişkiler içeren bir sistem olarak kabul edilir. Bu modeli çözmek, bir dizi zorluk ve engel oluşturur. Son zamanlarda, araştırmacılar bu bilinmeyen parametrelerin doğru bir şekilde tahmin edilmesine yönelik çeşitli yöntemler geliştirmek için önemli çabalar sarf etmiştir. Bu bağlamda, üç ana yaklaşım geniş çapta tanımlanmıştır: analitik yöntemler, deterministik yöntemler ve meta-sezgisel yöntemler [7].

Analitik yöntemler [8], tedarikçiden alınan veriler, örneğin açık devre voltajı, kısa devre akımı, üreticinin sağladığı maksimum güç noktası ve I-V karakteristikleri gibi verilere dayanarak parametre tahminleri yapar. Bu yöntemlerde, I-V karakteristik eğrisindeki tüm veri noktaları, tahmin edilen ve ölçülen değerler arasındaki hatayı azaltan parametreleri tanımlamak için kullanılır. Ancak, analitik yöntemler genellikle varsayımlar temelinde türetilmiş matematiksel formüller kullandığından, sonuçlar tam anlamıyla doğru olmayabilir.

Deterministik yöntemler [9] ise, tüm sistem için gerçek ölçülen verilerin kullanılması stratejisini benimser. Bilinmeyen parametreler, birçok ölçümden elde edilen verilerle çıkarılır. Bu yöntemler, genellikle deneysel ve tahmin edilen veri noktaları arasındaki farkı temsil eden bir amaç fonksiyonuna dayanır. Ancak, bu algoritmalar gradyan bilgilerine dayandığı için, yerel optimum çözüme yakınsama eğilimindedir.

Meta-sezgisel yöntemler [10-13], deterministik yöntemlerle benzer bir stratejiye dayanır, ancak bunlar genellikle biyolojik süreçler ve ideolojik desenlerden ilham alır. Meta-sezgisel algoritmalar, global en iyi optimizasyon algoritmaları olarak kabul edilir çünkü sağlamlık, performans güvenilirliği, basitlik ve uygulanabilirlik gibi birçok avantaja sahiptir. Bu algoritmalar, çeşitli biyolojik toplulukların kolektif zekasından yararlanarak gerçek dünya problemlerine optimal çözümler bulur. Meta-sezgisel algoritmalar, evrimsel tabanlı algoritmalar, sürü tabanlı algoritmalar, fiziksel tabanlı algoritmalar ve insan davranışına dayalı algoritmalar gibi farklı kategorilere ayrılabilir [7].

PV hücrelerinin ve modüllerinin doğru modellenmesi için en yaygın yaklaşım, analog elektrik devrelerinin kullanılmasıdır. SDM ve DDM modelleri, genellikle fotovoltaiik araştırmalarda tercih edilen modellerdir. SDM modelinde beş parametre bulunur ve bu parametrelerin doğru bir şekilde belirlenmesi, tek diyot hücrelerinin ve modüllerinin simülasyonu için gereklidir. DDM modelinde ise yedi parametre bulunur ve bu parametreler çift diyot hücrelerinin simülasyonu için belirlenmelidir. PV hücresi ve modülünün beş veya yedi parametresinin doğru bir şekilde tahmin edilmesi, fiziksel sistemin I-V karakteristiklerini doğru bir şekilde simüle edebilmek için zorunludur. Bu tahminlerin doğruluğu, ölçülen ve tahmin edilen PV hücresinin/modülünün akımları arasındaki hatanın minimal olmasını sağlayacak şekilde sağlanmalıdır. Bununla birlikte, tek ve çift diyot modelleri, basitlikleri, daha az hesaplama süresi ve belirlenmesi gereken daha az parametre olmaları nedeniyle literatürde en yaygın kullanılan modellere sahiptir. Bu nedenle, bu çalışmada odaklanılan DDM yöntemi olmuştur.

Son yıllarda yapılan araştırmalar, güneş hücresi parametrelerinin tahmininde kullanılan meta-sezgisel ve analitik yöntemlerin çeşitli sorunlara sahip olduğunu ortaya koymuştur [14]. Çoğu meta-sezgisel algoritma, ağırlık parametrelerini iterasyonlar arasında uyumlu hale getiremez, bu da algoritmaların adaptif olmamasına neden olur. Ayrıca, bazı algoritmalar yerel optimumlara hapsolabilir, bu da küresel optimuma ulaşmalarını engeller [15]. Küresel optimuma ulaşmak için bazı algoritmaların fazla sayıda iterasyon gerektirdiği de bir diğer önemli sorundur [16]. Bunun yanı sıra, bazı meta-sezgisel algoritmalar karmaşık olup, daha fazla hesaplama gücü gerektirir [17]. Son olarak, çoğu algoritma tarafından elde edilen RMSE (Root Mean Square Error) değeri hala iyileştirilebilir, bu da mevcut yöntemlerin verimliliğini sınırlayan bir faktördür [7].


Bu çalışmada, DDM modeline dayalı PV sisteminin parametre tahmini, nispeten yeni bir algoritma olan AAS algoritması ile yapılmıştır.

II. GÜNEŞ PV SİSTEMİ MODELLEME

Bu bölüm, güneş PV hücrelerinin ve modüllerinin matematiksel modellerine odaklanmaktadır.

A. Tek Diyot Modeli

Tek diyot modeli, en yaygın kullanılan matematiksel modeldir ve adından da anlaşılacağı gibi, değişkenler arasındaki ilişkiyi belirlemek için tek diyot eşdeğeri kullanılır.



Şekil 1. Tek diyot modelinin eşdeğer devresi [7].

Şekil 1'de görselleştirilen eşdeğer devreden, yük akımı aşağıdaki gibi verilir:

$$I_L = I_{ph} - I_{sd} - I_{sh} \quad (1)$$

I_L , PV hücresinin çıkış akımı, I_{ph} foton akımı, I_d diyot akımı ve I_{sh} ise paralel direnç akımıdır. Diyot akımı (I_d) ve paralel direnç akımı (I_{sh}) için ifadeler şu şekilde verilmiştir:

$$I_d = I_{sd} \left(e^{\frac{q(V_L + I_L R_s)}{nkT}} - 1 \right) \quad (2)$$

$$I_{sh} = \frac{V_L + I_L R_s}{R_{sh}} \quad (3)$$

I_{sd} , diyotun ters doygunluk akımını ifade eder, q ise elektronun yüküdür ve değeri $1.6021764 \times 10^{-19}$ C'dir. k , Boltzmann sabitidir, V_L ise PV hücresinin çıkış gerilmesidir. R_s , seri dirençtir, n diyot ideallik faktörünü belirtir, T sıcaklık değeri olup Kelvin cinsinden ölçülür ve R_{sh} şönt dirençtir.


Mevcut ifadelerin (2) ve (3) yerine (1) ifadesi konduğunda, PV hücresinin çıkış akımı şu şekilde elde edilir:

$$I_L = I_{ph} - I_{sd} \left(e^{\frac{q(V_L + I_L R_s)}{nkT}} - 1 \right) - \frac{V_L + I_L R_s}{R_{sh}} \quad (4)$$

Bilinmeyen parametreler dışında, tahmin edilmesi gereken beş parametre vardır: I_{ph} , I_{sd} , R_{sh} , R_s , n .

B. Çift Diyot Modeli

Çift diyot modelinin eşdeğer devresi Şekil 2'de gösterilmektedir ve devreden, yük akımı şu şekilde verilmektedir:



Şekil 2. Çift diyot modelinin eşdeğer devresi [7].

$$I_L = I_{ph} - I_{sd1} - I_{sd2} - I_{sh} \quad (5)$$

Tek diyot modelindeki prosedürü takip ederek, PV hücresinin nihai çıkış akımı şu şekilde verilmektedir:

$$I_L = I_{ph} - I_{sd1} \left(e^{\frac{q(V_L + I_L R_s)}{n_1 k T}} - 1 \right) - I_{sd2} \left(e^{\frac{q(V_L + I_L R_s)}{n_2 k T}} - 1 \right) \frac{V_L + I_L R_s}{R_{sh}} \quad (6)$$

Burada, I_{sd1} ve I_{sd2} diyot ters doyma akımları ve n_1 , n_2 diyot ideallik faktörleridir. DDM durumunda, bilinen parametreler dışında, tahmin edilmesi gereken yedi bilinmeyen parametre I_{ph} , I_{sd1} , I_{sd2} , R_{sh} , R_s , n_1 , n_2 bulunmaktadır.

III. AMAÇ FONKSİYONU

Ana hedef, güneş PV hücre parametrelerinin simüle edilmiş ve deneysel sonuçlar arasındaki hatayı azaltmaktır. Kök ortalama kare hata (RMSE), güneş PV model parametreleri için optimal değerlerin elde edilebileceği şekilde oluşturulabilecek bir amaç fonksiyonudur.

Bu çalışmanın amacı, güneş PV sisteminin parametrelerini, akım ve gerilim ölçümleri kullanarak tahmin etmek için meta-sezgisel optimizasyon tekniklerini kullanmaktır. Amaç fonksiyonu, ölçülen ve beklenen akım değerleri arasındaki RMSE değerlerine dayanmaktadır. Bu makalede, güneş hücresi parametrelerini tahmin etmek için (7) ve (8) numaralı iki amaç fonksiyonu dikkate alınmaktadır [7].

$$F_1 = \sqrt{\frac{1}{N} \sum_{i=1}^N \left[f(I_{ph}, I_{sd}, R_{sh}, R_s, n) \right]^2} \quad (7)$$

$$F_2 = \sqrt{\frac{1}{N} \sum_{i=1}^N [I_{L.mes} - I_{L.calc}]^2} \quad (8)$$


N , örnek sayısını, $I_{L.mes}$ ölçülen akımı ve $I_{L.calc}$ hesaplanan akımı temsil etmektedir.

Deneysel verilerden güneş PV modelinin parametrelerini çıkarma için temel yaklaşım, F_2 hedef fonksiyonu ile RMSE hesaplamaktır. Tahmin edilen akım, Denklem (7) ile (8) arasındaki doğrusal olmayan denklemleri sıfıra eşitleyerek hesaplanabilir.

IV. AKREP AVLANMA STRATEJİSİ ALGORİTMASI

Akrep Avlanma Stratejisi (AAS) [18] algoritması, akrelerin avlanma stratejisinden ilham almıştır. Diğer yaratıkların avı bulmak için görme duyularını kullandığı bir ortamda, akreler özel bir nörosensör sistemine sahiptir ve bu sistem, karmaşık duyuları etkin bir şekilde entegre ederek avı bulmak ve saldırmak için iyi koordine edilmiş hareketler üretir. Akreler, avın konumunu hassas bir şekilde bulmak için, avın yarattığı titreşimi hissetmek amacıyla bacak kısmında bulunan özel bir organını kullanır. Brownell'in (kum-çöl akreleriyle yapılan deneyler) deneylerine göre, 15 cm mesafedeki bir av tek bir hareketle yakalanabilirken, 30 cm mesafedeki bir avın bulunabilmesi için bir dizi yön değiştirme hareketi gereklidir [19]. Titreşim, akrep avına doğru hareket ettikçe daha güçlü hale gelir. Akreler, 50 cm uzaklıktaki avlarını hassas bir şekilde bulabilecek yeteneklere sahiptir [19]. Ancak, daha uzak mesafelerde, yalnızca avın yönünü hassas bir şekilde tespit edebilirler [19]. Akrep avını bulduğunda, genellikle avı etkisiz hale getirmek için iğnesini, pençesini ve ön bacağı kullanır (Şekil 3a).

Akrebin avlanma ve yutma süreci yedi adıma ayrılabilir (Şekil 3b). İlk adım, titreşimi hissederek avı bulmak ve vücut yönünü, avla hizalanacak şekilde ayarlamaktır. İkinci ve üçüncü adımlarda, akrep pençelerini uzatarak avı yakalar ve ele geçirir. Avın büyüklüğüne veya direnç gücüne bağlı olarak, dördüncü adımda akrep, avı bir ya da iki kez sokabilir. Akrep, avı pençesiyle ezer ve avın başını yiyerek yutma sürecine başlar. Kesintisiz bir yutma süreci için, akreler bazen avlarını yuvalarına daha güvenli bir yere taşıır [20].



Şekil 3. a) Akrebin farklı avlanma vücut kısımlarının çizimi, iğne, pençe ve bacak dahil (Polis, 1990'dan değiştirilmiştir), (b) Akrebin avlanma stratejisinin ardışık betimlemesi (Adım 1: vücut yönelimi, Adım 2: pençenin avı yakalamak için ileriye doğru hareket ettirilmesi, Adım 3: avın yakalanması, Adım 4: iğne hareketi, Adım 5: avın ısırılması, Adım 6: istenilen yere taşınması ve Adım 7: sindirim süreci) [18].

A. Algoritmanın Matematik Modeli

Herhangi bir popülasyon tabanlı meta-sezgisel algoritma gibi, AAS algoritması da popülasyonun başlatılmasıyla başlar. Popülasyon, i'nin 1'den n'ye kadar değiştiği, n'nin toplam popülasyonu, yani akreler ve diğer hayvanlar (av veya avcı) kombinasyonunu temsil ettiği şekilde başlatılır. Popülasyondaki her birey, konum matrisiyle tanımlanan bir arama ajanı (veya aday çözüm) olarak kabul edilir.

$$\mathbf{x}_i = \begin{bmatrix} x_i(1,1) & x_i(1,2) & \cdots & x_i(1,\text{dim}) \\ x_i(2,1) & x_i(2,2) & \cdots & x_i(2,\text{dim}) \\ \vdots & \vdots & \ddots & \vdots \\ x_i(n,1) & x_i(n,2) & \cdots & x_i(n,\text{dim}) \end{bmatrix} \quad (9)$$

Burada, x_i değişkeninin boyutu dim olarak belirtilmiştir. Başlangıçta, her aday çözümün konumu, sırasıyla LB ve UB olarak belirtilen alt ve üst uçlara sahip sürekli rastgele bir uniform (unifrnd) dağılım kullanılarak rastgele üretilir.

$$x_i^j = \text{unifrnd} \times (UB^j - LB^j) + LB^j \quad (10)$$


Burada x_i^j , i -inci adayın j -inci boyuttaki konumunu temsil eder, j değeri 1'den dim değerine kadar değişir. LB^j ve UB^j , optimize edilen problemin j -inci adayının alt ve üst sınırlarını temsil eder. Aday çözümünün karşılık gelen maliyet (veya uygunluk) değeri şu şekilde verilir:

$$F_x = \begin{bmatrix} f(x_{1,1}, x_{1,2}, \dots, x_{1,dim}) \\ f(x_{2,1}, x_{2,2}, \dots, x_{2,dim}) \\ \vdots \\ f(x_{n,1}, x_{n,2}, \dots, x_{n,dim}) \end{bmatrix} \quad (11)$$

Burada $f(\cdot)$, optimizasyon probleminin maliyet fonksiyonudur. Minimizasyon optimizasyon görevi göz önüne alındığında, minimum değere sahip aday en iyi çözüm olarak kabul edilir ve X_{best} ile gösterilir. X_{best} değeri şu şekilde hesaplanır:

$$x_{best} = \arg \min(F_x) \quad (12)$$

Bir titreşim sinyali, iki popülasyon üyesi arasındaki etkileşimi tanımlar: Eğer bir akrep, bir av üyesine yönelirse, buna "titreşim" denir; bir akrep, bir avcı üyesine yönelirse, buna ise " β titreşimi" denir. Eğer bir akrep, başka bir akrebe doğru hareket ederse, bu durum, $\alpha\beta$ titreşiminin mutasyonu olarak kabul edilir (Şekil 4). Maliyet fonksiyonu, akrebin av veya avcı ile karşılaşma olasılıklarını belirler. Bununla birlikte, bir akrebin başka bir akreple karşılaşma olasılığı (yani $\alpha\beta$ mutasyonu sırasında) %20'dir ($\mu = \alpha\beta = 0.2$). Bu gibi durumlarda, yüksek pençe (ω) ve iğne (Ψ) gücüne sahip akrep, diğerlerine göre üstün olacaktır. Akrepler arasındaki herhangi bir etkileşim sonrası, titreşim sinyali, bir zayıflama oranı olan $\mu_{damp} = 0.98$ ile güncellenir. Popülasyon üyeleri, titreşimleri algıladıklarında birbirlerine doğru hareket etmeye devam ederler. Algoritma, sonlandırma koşuluna (yani maksimum iterasyon sayısına) ulaşana kadar çalışmaya devam eder. Her iterasyondan sonra, α ve β birer birim artırılır (Algoritma 1).



Şekil 4. Av veya avcıya tepki olarak α ve β operatörlerinin çalışma prensibinin görselleştirilmesi [18].

Algoritma 1: AAS algoritması sözde-kodu.

Başlatma: Akreplerin ve avların popülasyonunu oluşturma ($x_i = 1, 2, \dots, n$)

Tanımla: x_i 'deki α

Tanımla: x_i 'deki β titreşimi

Tanımla: x_i 'deki pence gücü katsayısı ω /* [0.1 ile 0.3] arası rastgele değer */

Tanımla: Sting Power coefficient of ψ in x_i /* [0.1 ile 0.3] arası rastgele değer */

Tanımla: $\alpha\beta$ Mutasyon Oranı $\mu = 0.2$

```

1  while iterasyon  $\leq$  iterasyonmax do
2      for i = 1 to n do
3          for j = 1 to n do
4              while  $\alpha > 0$  or  $\beta > 0$  do
5                  Akrep i, av j'ye doğru hareket eder.
6                   $\alpha = \alpha + 1$ 
7                   $\beta = \beta + 1$ 
8              end
9               $\alpha\beta$  mutasyonunu  $\mu$  ile uygula.
10             Yeni çözümleri maliyet fonksiyonu ile değerlendir ve titreşimi güncelle.
11         end
12     end
13     Popülasyonu sırala ve sıralama yap, ardından mevcut küresel en iyi çözümü bul.
14     Yeni nesil oluşturma.
15 end
    
```

Şekil 5. AAS algoritmasının sözde-kodu

Popülasyonun birbirine doğru hareketi, Sinyal veya titreşim emilim katsayısına göre, Denklem 13 ile hesaplanır:

$$M = \psi \times e^{-\omega \times r_{ij}}, \quad (13)$$

r_{ij} iki üye arasındaki mesafeyi temsil eder. M , bir noktadan diğerine (yani, akrebin konumundan avın konumuna) titreşim emilim katsayısını temsil eder. M değerinin düşük olması, iki üye arasındaki mesafenin daha büyük olduğunu gösterir, çünkü titreşim sinyali daha zayıftır. M değeri, iki üye birbirine yaklaştıkça titreşim sinyali arttığı için yükselecektir. Akrebin güncellenmiş pozisyonu $x_{i,new}$, Denklem 14' ile hesaplanır.

$$x_{i,new} = x_i + M(x_j - x_i) + \mu \times e_{div}, \quad (14)$$

Burada, x_i önceki konumu, μ değeri $\alpha\beta$ mutasyonunu ve e_{div} hareket yolu boyunca çeşitliliği dahil etmek için kullanılan çeşitlilik faktörüdür. Bu özellik, algoritmayı daha dinamik ve daha az doğrusal hale getirir. Denklem 18 ile verilen bir uniform rastgele vektördür:

$$e_{div} = \delta \times \text{unifrnd} \times (-1, +1), \quad (15)$$

Burada δ uniform mutasyon aralığını temsil eder ve $0.05 \times (UB-LB)$ olarak hesaplanır. Son olarak, $\alpha\beta$ mutasyonu, Denklem 16'ye göre güncellenir:

$$\mu = \mu \times \mu_{damp}. \quad (16)$$

En iyi çözüm, yeni konuma karşılık gelen maliyet fonksiyonunu sıralayarak ve derecelendirerek elde edilir, Denklem 17'ye göre:

$$x_{best} = \text{armin}(f(x_{i,new})). \quad (17)$$

AAS algoritmasının sözde kodu (pseudo-code), Şekil 5'de gösterilmiştir.

B. Algoritmanın PV Modül Tahmine Uygulanması


DDM senaryosu, aşağıdaki yedi parametrenin tahmin edilmesini gerektirir: I_{ph} , I_{sd1} , I_{sd2} , R_{sh} , R_s , n_1 , n_2 ve bu parametrelerin alt ve üst sınırları, Tablo 1'te gösterilmiştir. Şekil 6a, AAS algoritması için yakınsama eğrisini göstermektedir. Deneysel ve tahmin edilen değerler arasındaki mutlak akım ve güç hataları, Lambert W fonksiyonu kullanarak yapılan parametre tahmini, Tablo 2'de yer almaktadır.

Tablo 1. DDM için bilinmeyen parametrelerin üst ve alt sınırları

Parametre	Üst Sınır	Alt Sınır
$I_{ph}(A)$	1	0
$I_{sd1}(\mu A)$	1	0
$I_{sd2}(\mu A)$	1	0
$R_{sh}(\Omega)$	100	0
$R_s(\Omega)$	0.5	0
n_1	2	1
n_2	2	1

Tablo 2. AAS algoritması kullanarak DDM için farklı yaklaşımlarla tahmin edilen parametreler

Parametre	Tahmin Edilen
$I_{ph}(A)$	0.760825469
$I_{sd1}(\mu A)$	0.279997519
$I_{sd2}(\mu A)$	0.276788151
$R_{sh}(\Omega)$	54.29056421
$R_s(\Omega)$	0.036499966
n_1	1.949332575
n_2	1.470009271



Şekil 5. Optimizasyon sonuçları (a) yakınsama eğrisi (b) V-I grafiği (c) V-P grafiği

Şekil 5(b), V-I eğrisine ait ölçülen ve tahmin edilen değerlerin grafiğini gösterirken, Şekil 5(c) ise V-P eğrisine ait ölçülen ve tahmin edilen değerlerin grafiğini sunmaktadır. İstatiksel analiz sonuçları Tablo 3’de verilmiştir.

Tablo 3. İstatiksel analiz

Parametre	Değer
En iyi uygunluk değeri	7.93E-04
Ortalama	2.51E-04
Standart Sapma	7.92516129907915e -05

Tablo 4. İm (ölçülen) ve İe (tahmin edilen)

Sıra	Ölçülen	Tahmin	Hata (%)	Sıra	Ölçülen	Hata (%)	Hata
1	0.764	0.764667	0.0873	14	0.728	0.727409	0.0812
2	0.762	0.763122	0.1473	15	0.7065	0.707078	0.0818
3	0.7605	0.761704	0.1583	16	0.6755	0.675516	0.0024
4	0.7605	0.760402	0.0129	17	0.632	0.63115	0.1345
5	0.76	0.759212	0.1037	18	0.573	0.572322	0.1183
6	0.759	0.758115	0.1166	19	0.499	0.499644	0.1290
7	0.757	0.757088	0.0116	20	0.413	0.413523	0.1267
8	0.757	0.756072	0.1226	21	0.3165	0.317132	0.1998
9	0.7555	0.754963	0.0710	22	0.212	0.211939	0.0290
10	0.754	0.753504	0.0657	23	0.1035	0.102542	0.9251
11	0.7505	0.751217	0.0955	24	-0.01	-0.00937	6.3016
12	0.7465	0.7472	0.0938	25	-0.123	-0.12437	1.1129
13	0.7385	0.740011	0.2046	26	-0.21	-0.20904	0.4586

V. SONUÇLAR

Bu çalışmada, güneş fotovoltaik (PV) model parametrelerinin tahmin edilmesinde Akrep Avlanma Stratejisi (AAS) algoritmasının etkinliği araştırılmıştır. AAS algoritması, meta-sezgisel optimizasyon tekniklerinden biri olarak, doğrusal olmayan ve karmaşık parametre tahmini problemlerinde başarılı sonuçlar elde edilmesini sağlamıştır. Deneysel verilerle yapılan karşılaştırmalarda, AAS algoritması kullanılarak elde edilen parametre tahminlerinin, ölçülen verilerle uyumlu olduğu ve düşük hata oranlarıyla başarılı sonuçlar sağladığı gözlemlenmiştir.

Deneysel verilerden yapılan tahminlerde, RMSE değerlerinin minimize edilmesi hedeflenmiş ve algoritmanın performansı, ölçülen ve tahmin edilen değerler arasındaki farkların istatistiksel olarak anlamlı bir şekilde azaldığı gösterilmiştir. AAS algoritması, parametre tahmini konusunda mevcut diğer meta-sezgisel algoritmalara göre daha yüksek doğruluk oranları ve daha düşük hesaplama maliyetleri sunarak önemli bir avantaj sağlamaktadır.

İstatistiksel analiz sonuçları, AAS algoritmasının parametre tahminlerinde yüksek doğruluk ve güvenilirlik sağladığını, sistemin optimize edilmesine katkı sunduğunu ve genel anlamda PV sistemlerinin performans analizine dair önemli bulgular sunduğunu ortaya koymuştur. Bu bulgular, AAS algoritmasının, güneş PV sistemlerinin model parametrelerini tahmin etmek için etkili ve güvenilir bir yöntem olduğunu desteklemektedir.

KAYNAKLAR

- [1] Singh, S. (2021). Energy crisis and climate change: Global concerns and their solutions. *Energy: crises, challenges and solutions*, 1-17.
- [2] Alshahrani, A., Omer, S., Su, Y., Mohamed, E., & Alotaibi, S. (2019). The technical challenges facing the integration of small-scale and large-scale PV systems into the grid: A critical review. *Electronics*, 8(12), 1443.
- [3] Bošnjaković, M., Stojkov, M., Katinić, M., & Lacković, I. (2023). Effects of extreme weather conditions on pv systems. *Sustainability*, 15(22), 16044.
- [4] Islam, H., Mekhilef, S., Shah, N. B. M., Soon, T. K., Seyedmahmoudian, M., Horan, B., & Stojcevski, A. (2018). Performance evaluation of maximum power point tracking approaches and photovoltaic systems. *Energies*, 11(2), 365.
- [5] Cárdenas-Bravo, C., Dutykh, D., & Lepsinats, S. (2024). On the parameters domain of the single-diode model. *Solar Energy*, 277, 112718.
- [6] Çelik, E., Karayel, M., Maden, D., Abdel-Salam, M., Öztürk, N., Kaplan, O., ... & Baljon, M. (2025). Reconfigured single-and double-diode models for improved modelling of solar cells/modules. *Scientific reports*, 15(1), 2101.
- [7] Ayyarao, T. S., & Kumar, P. P. (2022). Parameter estimation of solar PV models with a new proposed war strategy optimization algorithm. *International Journal of Energy Research*, 46(6), 7215-7238.
- [8] Ibrahim, H., & Anani, N. (2017). Evaluation of analytical methods for parameter extraction of PV modules. *Energy procedia*, 134, 69-78.
- [9] Ingenhoven, P., Belluardo, G., & Moser, D. (2017). Comparison of statistical and deterministic smoothing methods to reduce the uncertainty of performance loss rate estimates. *IEEE Journal of Photovoltaics*, 8(1), 224-232.
- [10] Rawat, N., & Thakur, P. (2022). Comparative analysis of hybrid and metaheuristic parameter estimation methods of solar PV. *Materials Today: Proceedings*, 65, 3748-3756.
- [11] Nguyen, T. T., Nguyen, T. T., & Tran, T. N. (2022). Parameter estimation of photovoltaic cell and module models relied on metaheuristic algorithms including artificial ecosystem optimization. *Neural Computing and Applications*, 34(15), 12819-12844.
- [12] Jearsiripongkul, T., Prempraneerach, P., Eslami, M., & Moarrefi, M. A. (2023). A novel hybrid metaheuristic approach to parameter estimation of photovoltaic solar cells and modules. *Engineered Science*, 27, 979.
- [13] Sharma, A., Sharma, A., Averbukh, M., Jatelly, V., Rajput, S., Azzopardi, B., & Lim, W. H. (2023). Performance investigation of state-of-the-art metaheuristic techniques for parameter extraction of solar cells/module. *Scientific reports*, 13(1), 11134.
- [14] Arandhakar, S., Chaudhary, N., Depuru, S. R., Dubey, R. K., & Bhukya, M. N. (2021). Analysis and implementation of robust metaheuristic algorithm to extract essential parameters of solar cell. *IEEE Access*, 10, 40079-40092.
- [15] Meidani, K., Hemmasian, A., Mirjalili, S., & Barati Farimani, A. (2022). Adaptive grey wolf optimizer. *Neural Computing and Applications*, 34(10), 7711-7731.
- [16] Parsopoulos, K. E., & Vrahatis, M. N. (2002). Recent approaches to global optimization problems through particle swarm optimization. *Natural computing*, 1(2), 235-306.

- [17] Nassef, A. M., Abdelkareem, M. A., Maghrabie, H. M., & Baroutaji, A. (2023). Review of metaheuristic optimization algorithms for power systems problems. *Sustainability*, 15(12), 9434.
- [18] Singh, A., Mousavi, S. M. H., & Gaurav, K. (2024). SHS: Scorpion Hunting Strategy Swarm Algorithm. *arXiv preprint arXiv:2407.14202*.
- [19] Brownell, P., & Farley, R. D. (1979). Prey-localizing behaviour of the nocturnal desert scorpion, *Paruroctonus mesaensis*: orientation to substrate vibrations. *Animal Behaviour*, 27, 185-193.
- [20] Graham, M. R. (2011). Scorpions of the World. *The Journal of Arachnology*, 39(1), 166-167.