

Meta-heurísticas Aplicadas ao Problema de Estimar os Parâmetros do Módulo Fotovoltaico

Thiago Favaro Duarte

Programa de Pós-Graduação em Energia
Universidade Federal do ABC
Santo André (SP), Brasil
thiago.duarte@ufabc.edu.br

Edmarcio Antonio Belati

Centro de Engenharia, Modelagem
e Ciências Sociais Aplicadas
Universidade Federal do ABC
Santo André (SP), Brasil
edmarcio.belati@ufabc.edu.br

Resumo—Este trabalho teve como objetivo aplicar e comparar seis meta-heurísticas no problema de estimação de parâmetros de modelos fotovoltaicos. As técnicas consideradas foram: Evolução Diferencial (DE), Polinização de Flores (FPA), Lobo Cinzento (GWO), Viúva-Negra com foco no canibalismo (cn-BWO), Viúva-Negra com foco no feromônio (pv-BWO) e Estratégia de Guerra (WSO). A estimação de parâmetros em modelos fotovoltaicos é um problema de otimização desafiador, devido à relação não linear entre corrente e tensão. Utilizando o modelo de diodo único, modelo de duplo diodo e modelo de triplo diodo, o desempenho das meta-heurísticas foi avaliado minimizando a raiz do erro quadrático médio para o painel Photowatt PWP201. Os resultados mostraram que a meta-heurística Estratégia de Guerra consistentemente obteve os menores valores em todas as modelagens, enquanto a Viúva-Negra com foco no canibalismo apresentou geralmente os piores valores e os maiores tempos de execução. A Viúva-Negra com foco no feromônio se destacou com grandes quantidades de agentes de busca, alcançando resultados próximos aos da Estratégia de Guerra. Em conclusão, as meta-heurísticas demonstraram ser eficazes para o problema analisado, destacando-se a Estratégia de Guerra como a mais promissora entre as testadas. Essa técnica alcançou os menores valores da raiz do erro quadrático médio: $2,423 \times 10^{-3}$ para os modelos de diodo único, duplo e triplo. Esses resultados se mostraram comparáveis ou superiores aos reportados em diversos estudos recentes da literatura para o mesmo painel e problema.

Index Terms—meta-heurística, Evolução Diferencial, Polinização de Flores, Lobo Cinzento, Viúva-Negra com foco no feromônio, Viúva-Negra com foco no canibalismo, Estratégia de Guerra, modelagem de painel fotovoltaico, estimativa de parâmetros

I. INTRODUÇÃO

A crescente relevância dos sistemas Fotovoltaico (FV) como uma alternativa crucial aos combustíveis fósseis tem impulsionado a necessidade de modelos precisos para descrever o comportamento dos módulos fotovoltaicos [3], [7]. A estimação precisa dos parâmetros desses modelos é fundamental para otimizar o design, prever o desempenho e aumentar a eficiência dos sistemas FV [1], [9], [14]. No entanto, a relação não linear corrente-tensão (I-V) dos módulos FV torna a tarefa de estimação de parâmetros um problema de otimização complexo [2], [8], [11].

A estimação de parâmetros em módulos FV busca identificar valores desconhecidos que melhor descrevam o comportamento elétrico do dispositivo sob diferentes condições ope-

rationais [8]. Historicamente, métodos analíticos e numéricos têm sido empregados com o objetivo de resolver esse tipo de problema. No entanto, essas abordagens frequentemente apresentam limitações significativas, como elevada carga computacional, sensibilidade a imprecisões nos dados de entrada e aumento da complexidade à medida que os modelos se tornam mais detalhados e com um maior número de parâmetros [2], [14].

Diante dessas dificuldades, as meta-heurísticas, algoritmos de otimização inspirados na natureza ou baseados em estocasticidade, têm se destacado como ferramentas poderosas e eficazes. Elas demonstram capacidade de explorar o espaço de busca de forma eficiente, evitando a convergência prematura para soluções subótimas [10], [14]. Com base nesta questão, este trabalho propõe a aplicação e análise comparativa de seis meta-heurísticas ao problema de estimação de parâmetros de módulos fotovoltaicos. As meta-heurísticas selecionadas, DE, FPA, GWO, cn-BWO, pv-BWO e WSO, foram escolhidas devido às suas características distintas de mecanismos e refinamento da exploração. O objetivo principal é avaliar o resultado de cada um desses algoritmos através da raiz do erro quadrático médio em relação aos dados do painel modelo Photowatt PWP201, visando uma melhor compreensão das potencialidades e limitações, contribuindo para a seleção de métodos mais eficazes e eficientes.

II. MODELAGEM DO PROBLEMA

Os modelos mais comuns e amplamente utilizados para este problema são: o modelo de diodo único (SDM), o modelo de duplo diodo (DDM) e, em alguns casos, o modelo de triplo diodo (TDM) [8]–[10]. Estes três modelos dependem de dados de entrada baseados na corrente e tensão experimentais medidas.

A. Modelos

a) *Único Diodo*: O modelo de diodo único é o mais popular devido à sua simplicidade e fácil implementação, oferecendo um bom equilíbrio entre complexidade e precisão [4], [12]. Na Fig. 1, ele é representado como um circuito elétrico equivalente de uma célula solar com uma fonte de corrente em paralelo com um diodo, uma resistência em série

que representa a resistividade do material e as perdas ôhmicas dos contatos, e uma resistência em paralelo que considera a corrente de fuga [3], [11], [16]. Estes elementos podem ser relacionados com (1), (2), (3) e (4).

$$I_s = I_g - I_{d(1)} - I_p \quad (1)$$

$$I_{d(i)} = I_{sd(i)} \cdot \left[\exp \left(\frac{V_m + I_m \cdot R_s}{V_t} \right) - 1 \right] \quad (2)$$

$$V_t = \frac{n_{(i)} \cdot k_b \cdot T}{q} \quad (3)$$

$$I_p = \frac{V_m + I_m \cdot R_s}{R_p} \quad (4)$$

Sendo I_s a corrente de saída simulada (em Ampere), I_g a corrente fotogerada (em Ampere), $I_{d(i)}$ a corrente do diodo ideal dada pela equação de Shockley no diodo i (em Ampere), I_p a corrente no resistor paralelo (em Ampere), $I_{sd(i)}$ a corrente de saturação reversa referente ao diodo i (em Ampere), q a carga do elétron (aproximadamente $1,60217646 \times 10^{-19}$ Coulomb), V_m é a tensão experimental nos terminais (em Volts), I_m é a corrente experimental medida (em Ampere), R_s é a resistência em série (em Ohms), V_t é a tensão termodinâmica, $n_{(i)}$ é o fator de idealidade do diodo i (adimensional), k_b é a constante de Boltzmann (aproximadamente $1,38064852 \times 10^{-23}$ Joules por Kelvin), T a temperatura absoluta (em Kelvin) e R_p a resistência em paralelo (em Ohms). Onde i se refere à ordem do diodo.




Figura 1. Representação do modelo de diodo único.

Neste modelo há cinco parâmetros desconhecidos a serem estimados que formam o vetor $\theta = [I_g, I_{sd(1)}, R_s, n_{(1)}, R_p]$.

b) Duplo Diodo: O modelo de duplo diodo é proposto para melhorar a precisão do modelo de diodo único, especialmente em baixos níveis de irradiância, considerando o efeito da corrente resultante da recombinação na camada de depleção e as não idealidades [3], [10], [11]. O circuito equivalente inclui um diodo em paralelo a mais do que o SDM e calcula-se a corrente de saída com (5).

$$I_s = I_g - I_{d(1)} - I_{d(2)} - I_p \quad (5)$$

Já neste modelo, representado pela Fig. 2, há sete parâmetros desconhecidos a serem estimados que formam o vetor $\phi = [I_g, I_{sd(1)}, I_{sd(2)}, R_s, n_{(1)}, n_{(2)}, R_p]$.




Figura 2. Representação do modelo de duplo diodo.

c) Triplo Diodo: O modelo de triplo diodo é ainda mais preciso que o SDM e o DDM, pois considera a influência da recombinação nas regiões defeituosas e nos grãos, o que aumenta sua complexidade [9], [11], [16]. O circuito equivalente, representado pela Fig. 3, inclui um terceiro diodo em paralelo. A equação para a corrente de saída do TDM é descrita em (6).

$$I_s = I_g - I_{d(1)} - I_{d(2)} - I_{d(3)} - I_p \quad (6)$$

No TDM, o número de parâmetros desconhecidos sobe para nove conforme o vetor $\psi = [I_g, I_{sd(1)}, I_{sd(2)}, I_{sd(3)}, R_s, n_{(1)}, n_{(2)}, n_{(3)}, R_p]$.




Figura 3. Representação do modelo de três diodos.

d) Módulo Fotovoltaico: Para transformar o modelo da célula solar para um modelo de módulo fotovoltaico, basta relacionar os parâmetros dos modelos anteriores com a quantidade de células conectadas em série (N_s) e em paralelo (N_p) no módulo, assumindo que todas as células são idênticas e geram a mesma tensão [4], [6], [14]. As relações para um painel sem células em paralelo ($N_p = 1$) são descritas de forma sucinta em (7).

$$V_t = N_s \cdot V_t, \quad R_s = N_s \cdot R_s, \quad R_p = N_s \cdot R_p \quad (7)$$

B. Função Objetivo

A função objetivo, f_{obj} , no problema de estimação de parâmetros de módulos fotovoltaicos é geralmente definida para quantificar a diferença entre os dados medidos e os dados simulados pelo modelo [2]–[4], [6]. O objetivo principal é minimizar essa diferença, encontrando o conjunto de parâmetros que melhor represente o comportamento real da célula ou módulo solar. Uma função objetivo muito utilizada é a raiz do erro quadrático médio (RMSE) [2]–[4], [18]. Logo, as funções objetivo para o SDM, DDM e TDM são representadas por (8), (9) e (10), respectivamente.

$$Min.f_{obj}(\theta) = \sqrt{\frac{1}{M} \sum_{j=1}^M (I_{m(j)} - I_{s(\theta,j)})^2} \quad (8)$$

$$Min.f_{obj}(\phi) = \sqrt{\frac{1}{M} \sum_{j=1}^M (I_{m(j)} - I_{s(\phi,j)})^2} \quad (9)$$

$$Min.f_{obj}(\psi) = \sqrt{\frac{1}{M} \sum_{j=1}^M (I_{m(j)} - I_{s(\psi,j)})^2} \quad (10)$$

III. META-HEURÍSTICAS UTILIZADAS

Autores como [5], [13], [15] se referem ao teorema do 'Não existe almoço grátis' para demonstrar que nenhum algoritmo meta-heurístico é universalmente o melhor para todos os tipos de problemas de otimização, isto é, um algoritmo pode apresentar resultados excelentes em um conjunto de problemas, mas ter um desempenho inferior em outros. Por este motivo serão aplicados diferentes algoritmos neste trabalho, especificamente: Evolução Diferencial (DE), Polinização de Flores (FPA), Lobo Cinzento (GWO), duas versões da Viúva-Negra (BWO), uma com foco no canibalismo e outra com foco no feromônio e, por último, Estratégia de Guerra (WSO).

A. Evolução Diferencial

O algoritmo da Evolução Diferencial é um algoritmo meta-heurístico evolucionário inspirado nos princípios da seleção natural e foi proposto por [19] em 1997.

O algoritmo depende da criação de um vetor x com uma população aleatória de NP agentes de busca de dimensão D para a primeira geração e, através de um processo iterativo de mutação, cruzamento e seleção a cada nova geração, obtém-se o melhor agente.

a) Mutação: É a operação que, para cada vetor alvo x_i^G na geração G com i entre $[1, NP]$, um vetor mutante v_i^{G+1} é gerado através da diferença ponderada entre dois vetores de população somada a um terceiro vetor conforme (11).

$$v_i^{G+1} = x_{r_1}^G + F \cdot (x_{r_2}^G - x_{r_3}^G) \quad (11)$$

Onde: r_1, r_2 e r_3 são índices inteiros escolhidos aleatoriamente entre $[1, NP]$, que devem ser mutuamente diferentes e também diferentes do índice corrente i e F é um fator de escala real e constante pertencente ao intervalo $[0, 2]$, que controla a amplificação da diferença vetorial.

b) Cruzamento: Para aumentar a diversidade é realizado um cruzamento entre o vetor mutante v_i^{G+1} e o vetor alvo x_i^G , gerando um vetor de teste u_i^{G+1} . Para cada componente j no intervalo $[1, D]$, a regra descrita em (12) é aplicada ao cruzamento.

$$u_{ji}^{G+1} = \begin{cases} v_{ji}^{G+1} & \text{se } (r(j) \leq CR) \text{ ou } j = r_i, \\ x_{ji}^G & \text{se } (r(j) > CR) \text{ e } j \neq r_i \end{cases} \quad (12)$$

Sendo $r(j)$ o j -ésimo componente de um número aleatório uniformemente distribuído no intervalo $[0, 1]$, CR é a constante de cruzamento pertencente ao intervalo $[0, 1]$ que precisa ser definida manualmente e r_i é um índice escolhido aleatoriamente entre $[0, D]$ que garante que o vetor de teste receba pelo menos um parâmetro do vetor mutante.

c) Seleção: O processo de seleção avalia o novo vetor de teste (u_i^{G+1}) e o vetor atual (x_i^G) mantendo apenas o melhor para a próxima geração (x_i^{G+1}).

A resposta final da meta-heurística será o agente de busca com a melhor aptidão ao final do processo.

B. Polinização de Flores

O algoritmo que se baseia no processo de polinização das flores envolvendo a transferência de pólen por polinizadores e pelo vento com o objetivo de reprodução ótima das plantas e sobrevivência da mais apta, foi desenvolvido por [20] em 2012.

O FPA inicia-se com um grupo de agentes de busca de n flores que representam possíveis soluções aleatórias dentro do espaço de busca do problema, x , e a cada geração g , um valor aleatório de r entre 0 e 1 é gerado. Para a escolha da polinização compara-se o valor de r com um valor p a ser definido; caso $r < p$, ocorre a polinização global; já no caso contrário, $r \geq p$, ocorre a polinização local.

a) Polinização Global: A nova solução, x_i^{t+1} , é gerada por (13).

$$x_i^{t+1} = x_i^t + L(\lambda) \cdot (x_i^t - g_*) \quad (13)$$

Onde: x_i^t é a solução da flor i na iteração t , g_* é a melhor solução global encontrada até o momento e $L(\lambda)$ é o passo de voo de Lévy que corresponde à intensidade da polinização.

A distribuição de Lévy, usada para simular o comportamento de voo de longa distância dos polinizadores, é dada por (14).

$$L \sim \frac{\lambda \cdot \Gamma(\lambda) \cdot \sin(\pi \cdot \lambda/2)}{\pi} \cdot \frac{1}{s^{1+\lambda}}, \quad (s \gg s_0 > 0) \quad (14)$$

Sendo válida para a função gama padrão $\Gamma(\lambda)$ e passos grandes $s > 0$.

b) Polinização Local: Duas flores diferentes, j e k , são selecionadas aleatoriamente da população. A nova solução, x_i^{t+1} , é gerada usando (15).

$$x_i^{t+1} = x_i^t + \epsilon \cdot (x_j^t - x_k^t) \quad (15)$$

Sendo ϵ um fator aleatório gerado por uma distribuição uniforme entre $[0, 1]$ que ajusta dinamicamente a magnitude da variação, promovendo uma exploração a curta distância.

A resposta final da meta-heurística será a flor com a melhor aptidão.

C. Lobo Cinzento

O algoritmo do Lobo Cinzento, criado por [15] em 2014, é um algoritmo meta-heurístico inspirado no comportamento de caça e na hierarquia social dos lobos *Canis lupus*.

O processo de otimização no GWO é baseado nas três principais etapas da caça dos lobos:

a) *Rastreamento e Cerco da Presa*: O algoritmo começa com uma quantidade definida de agentes de busca (população de lobos). O cerco da presa (a solução ótima) é matematicamente modelado pela distância entre o lobo e a presa e pela atualização da posição dos demais lobos, (16) e (17), respectivamente.

$$D = |C \cdot X_p^t - X^t| \quad (16)$$

$$X^{t+1} = X_p^t - A \cdot D \quad (17)$$

Onde: D é a distância entre o lobo e a presa, A e C são vetores de coeficiente, X_p é o vetor de posição da presa, X indica o vetor de posição de um lobo e t é a iteração corrente. Para o cálculo dos vetores A e C tem-se (18).

$$A = 2 \cdot a \cdot r_1 - a, \quad C = 2 \cdot r_2 \quad (18)$$

Sendo a um parâmetro que diminui linearmente de dois para zero ao longo das iterações e r_1 e r_2 são valores aleatórios no intervalo de $[0, 1]$.

b) *Caça*: Em um espaço de busca desconhecido, não se tem a localização do ótimo (presa). A fim de simular matematicamente o comportamento de caça, supõe-se que os lobos α , β e δ têm melhor conhecimento sobre a localização potencial da presa. Portanto, são salvas as três melhores soluções obtidas até o momento e, obrigatoriamente, os demais lobos ω atualizam suas posições de acordo com a média dos melhores agentes através de (19) e (20), resultando em sua posição final (21).

$$D_\alpha = |C_1 \cdot X_\alpha^t - X^t|, \quad \dots, \quad D_\delta = |C_3 \cdot X_\delta^t - X^t| \quad (19)$$

$$X_1 = X_\alpha - A_1 \cdot D_\alpha, \quad \dots, \quad X_3 = X_\delta - A_3 \cdot D_\delta \quad (20)$$

$$X_\omega^{t+1} = \frac{X_1 + X_2 + X_3}{3} \quad (21)$$

c) *Ataque à Presa*: A exploração é controlada pelo parâmetro a e pelos vetores A e C . O parâmetro a diminui ao longo das iterações, o que influencia o vetor A . Quando $|A| > 1$, os lobos tendem a se dispersar para procurar a presa; quando $|A| < 1$, os lobos tendem a convergir em direção à presa. O vetor C fornece pesos aleatórios para a presa, ajudando a evitar ótimos locais.

Por fim, a resposta final da meta-heurística será o lobo α .

D. Viúva-Negra com foco no canibalismo

A meta-heurística da viúva-negra apresenta duas variações em sua criação. A primeira, publicada em 2020 por [13], inspira-se na aranha *Latrodectus hasselti*, com foco no canibalismo sexual e materno cn-BWO. Já a segunda, publicada no fim do mesmo ano por [17], inspira-se na aranha *Latrodectus hesperus*, com foco no feromônio produzido pelas fêmeas pv-BWO e na movimentação típica da aranha pela teia.

Em ambas as versões, inicia-se com os agentes de busca tratados como aranhas proporcionais ao tamanho da dimensão N_{var} do problema. A partir deste ponto, as duas se divergem, com as etapas do cn-BWO sendo:

a) *Procriação e Canibalismo*: Pares de pais são selecionados aleatoriamente para se reproduzirem e gerarem uma nova geração de indivíduos que participam da procriação com base na porcentagem PP definida. Nesta etapa cria-se um vetor α com valores aleatórios entre $[0, 1]$ e os descendentes são então produzidos utilizando (22).

$$\begin{cases} y_1 = \alpha \cdot x_1 + (1 - \alpha) \cdot x_2 \\ y_2 = \alpha \cdot x_2 + (1 - \alpha) \cdot x_1 \end{cases} \quad (22)$$

Onde: x_1 e x_2 são os pais selecionados e y_1 e y_2 são os filhotes.

Este processo é repetido para $N_{var}/2$ vezes e os pais selecionados não devem ser repetidos. Posteriormente, considera-se que o genitor com maior valor de aptidão seja a fêmea que canibaliza o macho durante ou após o acasalamento e, portanto, apenas os filhotes e a mãe são adicionados a um novo vetor de população e classificados por seu valor de aptidão. Agora, de acordo com a taxa de canibalismo (CN) a ser determinada entre 0 e 1, somente os melhores indivíduos sobrevivem.

b) *Mutação*: Definido pela taxa de mutação PM definida, uma porcentagem dos indivíduos da população passa por um processo de mutação em que alguns de seus valores são permutados aleatoriamente entre si.

Ao final, a resposta final da meta-heurística será a aranha com a melhor aptidão.

E. Viúva-Negra com foco no feromônio

As etapas do algoritmo pv-BWO são:

a) *Movimentação na teia*: As aranhas se movem no espaço de busca da mesma forma que se movimentam em sua teia, seja de forma linear ou espiral. Esta movimentação é modelada por (23).

$$x_i^{t+1} = \begin{cases} x_*^t - m \cdot x_{r1}^t & \text{se } rm \leq 0,3 \\ x_*^t - \cos(2 \cdot \pi \cdot \beta) \cdot x_i^t & \text{se } rm > 0,3 \end{cases} \quad (23)$$

Sendo x_i^{t+1} a nova posição, x_*^t a melhor aranha da iteração anterior, m um número de ponto flutuante entre $[0,4, 0,9]$, $r1$ um número inteiro aleatório no intervalo $[1, N^\circ \text{ de agentes de busca}]$, rm um número aleatório no intervalo $[0, 1]$, x_{r1}^t o agente na posição $r1$ com $i \neq r1$, β um valor de ponto flutuante entre $[-1, 1]$ e x_i^t o agente de busca atual.

b) *Feromônios*: Aranhas fêmeas com baixas taxas de feromônio possuem maior suscetibilidade ao canibalismo e, por isso, são evitadas pelos machos na busca de parceiras para o acasalamento. Sendo a taxa de feromônio expressa por (24):

$$Ph_i = \frac{Fit_{max} - Fit_i}{Fit_{max} - Fit_{min}} \quad (24)$$

Onde: Ph_i é o valor do feromônio que representa a aptidão normalizada no intervalo de $[0, 1]$ e Fit_{min} e Fit_{max} são o

pior e o melhor valor de aptidão na geração atual, respectivamente; enquanto Fit_i é o valor de aptidão atual do agente de busca na posição i .

Para baixos valores de feromônio, a aranha fêmea não será escolhida e deverá ser substituída conforme (25).

$$x_i^t = \begin{cases} x_*^t + 0,5 \cdot [x_{r1}^t - (-1)^\sigma \cdot x_{r2}^t] & \text{se } Ph_i \leq 0,3 \\ x_i^t & \text{se } Ph_i > 0,3 \end{cases} \quad (25)$$

Sendo x_i^t a aranha avaliada, $r1$ e $r2$ são números inteiros aleatórios no intervalo $[1, N^\circ \text{ de agentes de busca}]$ com $r1 \neq r2$, x_{r1}^t a aranha na posição $r1$, x_{r2}^t a aranha na posição $r2$, x_*^t a melhor aranha da iteração anterior e σ é um número binário aleatoriamente gerado em uma taxa de 0,5.

Da mesma forma que sua variação anterior, a resposta final da meta-heurística será a aranha com a melhor aptidão.

F. Estratégia de Guerra

O algoritmo da Estratégia de Guerra é uma meta-heurística proposta por [5] em 2022. A inspiração para o WSO provém das estratégias de guerra de exércitos antigos que modelam o movimento das tropas durante um conflito.

A quantidade definida de agentes de busca, soldados, é distribuída aleatoriamente e a força de ataque de cada soldado é calculada através do valor da função objetivo ou aptidão, junto com seu ranque e peso; estes dois últimos possuem valores iniciais iguais a 0 e 2, respectivamente, para todos os soldados e serão recalculados com base no sucesso da estratégia de ataque. Posteriormente, os soldados são reclassificados e quem possuir a melhor força de ataque (aptidão) é designado como o Rei, seguido do segundo melhor, que será designado como Comandante.

A estratégia é decidida por um valor aleatório ρ entre 0 e 1, que, se for maior que um parâmetro definido (ρ_r), a estratégia de defesa é usada e, caso contrário, a estratégia de ataque é aplicada. Por fim, o soldado mais fraco é substituído e começa a próxima batalha.

a) *Estratégia de Ataque*: Cada soldado move-se influenciado pelas posições do Rei e do Comandante. A fórmula para atualizar a posição usando esta estratégia é apresentada em (26).

$$X_i^{t+1} = X_i^t + 2 \cdot \rho \cdot (C - K) + r \cdot (W_i \cdot K - X_i^t) \quad (26)$$

Onde: X_i^{t+1} é a nova posição do soldado i , X_i^t é a posição do soldado i na iteração t , K é a posição do Rei, C é a posição do Comandante, r é um número aleatório entre $[0, 1]$ e W_i é o peso do soldado i .

b) *Atualização dos Soldados*: A atualização de cada soldado, após a estratégia de ataque, depende da força de ataque na nova posição, F_n , e da posição anterior, F_p , conforme (27), (28) e (29) para problemas de minimização.

$$X_i^{t+1} = \begin{cases} X_i^{t+1} & \text{se } F_n \leq F_p \\ X_i^t & \text{se } F_n > F_p \end{cases} \quad (27)$$

$$R_i = \begin{cases} R_i + 1 & \text{se } F_n \leq F_p \\ R_i & \text{se } F_n > F_p \end{cases} \quad (28)$$

$$W_i = \begin{cases} W_i \cdot [1 - (R_i / \text{Maxiter})]^\tau & \text{se } F_n \leq F_p \\ W_i & \text{se } F_n > F_p \end{cases} \quad (29)$$

Onde: X_i é a posição, R_i é o ranque, W_i é o peso, Maxiter é o número máximo de iterações e τ é um parâmetro ajustável.

c) *Estratégia de Defesa*: A posição de cada soldado é atualizada com base nas posições do Rei, do Comandante e de um soldado aleatório na forma apresentada em (30), enquanto o ranque e o peso permanecem os mesmos.

$$X_i^{t+1} = X_i^t + 2 \cdot \rho \cdot (K - X_{ri}^t) + r \cdot W_i \cdot (C - X_i^t) \quad (30)$$

Sendo X_{ri}^t a posição de um soldado aleatório na iteração t , e os outros parâmetros são os mesmos da estratégia de ataque.

d) *Realocação dos Soldados*: Soldados com a pior força de ataque, X_w , podem ser substituídos por novos soldados (novo agente de busca) ou, conforme demonstrado por (31), realocados para mais perto da mediana do exército para melhorar a convergência do algoritmo. Esta realocação possui uma influência dependente de um valor aleatório r entre $[0,1]$.

$$X_w^{t+1} = -(1 - r) \cdot (X_w^t - \text{mediana}(X)) + K \quad (31)$$

Após terminar a guerra, a resposta final da meta-heurística será o Rei.

IV. CONSIDERAÇÕES

- De forma a minimizar as influências exercidas pelo grupo de agentes de busca na comparação das meta-heurísticas escolhidas, optou-se por criar um grupo de agentes de busca inicial único e utilizá-lo em todos os testes, para que o ponto de partida seja o mesmo.
- Optou-se por testar grupos de agentes com tamanhos de 10, 25, 50 e 100 indivíduos em cada meta-heurística com 1.000 iterações e 20 repetições por teste.
- A contagem do tempo contemplará a execução completa da função principal da meta-heurística, descartando os tempos de preparo inicial e consolidação dos resultados.
- Deve-se destacar que os valores adotados para os limites da modelagem (θ , ϕ e ψ) são apresentados na Tabela I; os valores de entrada dos parâmetros ajustáveis das meta-heurísticas na Tabela II. Estes valores foram definidos com base em estudos similares de outros autores [4], [6]–[8], [17].
- A escolha do módulo fotovoltaico considerou como referência as mesmas medições amplamente utilizadas na literatura para avaliar vários métodos de otimização do problema proposto [16]. Estas 25 medições foram obtidas por [12] a partir do painel solar policristalino com 36 células em série, modelo Photowatt PWP201.
- A programação utilizada neste trabalho foi realizada no software MATLAB, versão R2021a, em um computador

Tabela I
LIMITES DOS MODELOS

Parâmetros	Limite Inferior	Limite Superior
I_g (A)	0,01	2
$I_{sd1}, I_{sd2}, I_{sd3}$ (μ A)	0,01	50
n_1, n_2, n_3	1	2
R_s (Ω)	0,01	2
R_p (Ω)	0,01	2000

Tabela II
VALORES DE ENTRADA AJUSTÁVEIS

Meta-heurística	Valores de Entrada	
cn-BWO	$PP = 0,8$	$CN = 0,5$
	$PM = 0,4$	
DE	$F = 0,4$	$CR = 0,4$
FPA	$P = 0,8$	$\lambda = 1,5$
GWO	Sem Ajustes	
pv-BWO	Sem Ajustes	
WSO	$\rho_r = 0,5$	$\tau = 2$
	Soldado fraco irá para próximo da mediana	

tipo desktop com as seguintes configurações: processador AMD RyzenTM 5 PRO 4650GE com RadeonTM Graphics 3,3 GHz, memória RAM de 16GB e sistema operacional de 64 bits com Windows 11 Pro.

V. RESULTADOS E DISCUSSÃO

Nesta seção concentra-se a apresentação dos resultados obtidos pelas seis meta-heurísticas aplicadas, seguida de uma breve discussão sobre eles, a indicação do melhor valor encontrado para as variáveis θ , ϕ e ψ e uma comparação entre o melhor resultado de cada meta-heurística e alguns dos algoritmos existentes na literatura.

Por se tratar de um trabalho envolvendo módulo FV e meta-heurísticas, é possível visualizar a curva característica de corrente e tensão (Curva I-V), Fig. 4, e a curva de convergência, Fig. 5. Porém, devido ao volume de dados, os resultados das meta-heurísticas foram separados em tabelas conforme a modelagem, sendo que na Tabela III observam-se os valores do RMSE considerando o modelo SDM, na Tabela IV o modelo DDM e na Tabela V o modelo TDM.

Tabela III
RMSE PARA O MODELO SDM

Meta-heurística	Agentes de Busca			
	10	25	50	100
cn-BWO	3,984 E-03	6,095 E-03	7,164 E-03	5,609 E-03
DE	2,734 E-03	3,522 E-03	3,526 E-03	3,122 E-03
FPA	3,089 E-03	3,326 E-03	3,420 E-03	3,622 E-03
GWO	3,518 E-03	2,999 E-03	3,021 E-03	3,143 E-03
pv-BWO	7,030 E-02	3,243 E-03	2,749 E-03	2,423 E-03
WSO	2,986 E-03	2,423 E-03	2,423 E-03	2,423 E-03

Os resultados do RMSE demonstram que a meta-heurística WSO consegue obter valores mais próximos do ótimo e a meta-heurística cn-BWO obteve os piores resultados. É possível inferir que o número de agentes de busca não possui grande influência nas quantidades escolhidas, uma vez que




Figura 4. Curva I-V para três diodos e 50 agentes de busca.




Figura 5. Curva de convergência para três diodos e 50 agentes de busca

Tabela IV
RMSE PARA O MODELO DDM

Meta-heurística	Agentes de Busca			
	10	25	50	100
cn-BWO	3,422 E-01	3,443 E-01	3,440 E-01	1,489 E-01
DE	2,984 E-03	5,344 E-03	3,630 E-03	3,590 E-03
FPA	4,702 E-03	5,331 E-03	4,993 E-03	4,009 E-03
GWO	3,156 E-03	3,479 E-03	3,074 E-03	3,954 E-03
pv-BWO	3,345 E-02	5,676 E-03	2,966 E-03	2,427 E-03
WSO	2,977 E-03	2,423 E-03	2,423 E-03	2,423 E-03

Tabela V
RMSE PARA O MODELO TDM

Meta-heurística	Agentes de Busca			
	10	25	50	100
cn-BWO	1,007 E-02	2,766 E-02	9,517 E-03	8,024 E-03
DE	3,777 E-03	5,755 E-03	5,373 E-03	5,459 E-03
FPA	6,402 E-03	5,943 E-03	6,311 E-03	3,819 E-03
GWO	4,386 E-03	3,205 E-03	3,483 E-03	3,553 E-03
pv-BWO	1,815 E-02	3,235 E-03	2,925 E-03	2,453 E-03
WSO	2,948 E-03	2,423 E-03	2,423 E-03	2,423 E-03

os melhores resultados de cada meta-heurística encontram-se distribuídos, com exceção da BWO, em que se observa em ambas as versões uma grande dependência da quantidade de agentes para gerar melhores resultados. Esta influência é tamanha que a meta-heurística pv-BWO chegou muito perto de superar os melhores valores da WSO com 100 agentes de busca. Também se destaca que o algoritmo da DE respondeu melhor a números baixos de agentes de busca e os resultados da WSO apresentaram desempenho consistente nas três modelagens.

Já as Tabelas VI, VII e VIII, expõem os tempos de execução de cada teste. Os valores estão em segundos e correspondem ao valor médio por iteração.

Tabela VI
TEMPO MÉDIO POR ITERAÇÃO (EM SEGUNDOS) - SDM

Meta-heurística	Agentes de Busca			
	10	25	50	100
cn-BWO	0,531	1,276	2,526	5,000
DE	0,215	0,496	0,963	1,936
FPA	0,232	0,548	1,082	2,151
GWO	0,214	0,484	0,955	1,901
pv-BWO	0,243	0,684	1,684	4,136
WSO	0,220	0,495	0,977	1,908

Tabela VII
TEMPO MÉDIO POR ITERAÇÃO (EM SEGUNDOS) - DDM

Meta-heurística	Agentes de Busca			
	10	25	50	100
cn-BWO	0,717	1,749	3,476	7,095
DE	0,228	0,538	1,055	2,125
FPA	0,247	0,594	1,172	2,402
GWO	0,224	0,533	1,051	2,126
pv-BWO	0,263	0,738	1,706	5,319
WSO	0,234	0,540	1,060	2,238

Tabela VIII
TEMPO MÉDIO POR ITERAÇÃO (EM SEGUNDOS) - TDM

Meta-heurística	Agentes de Busca			
	10	25	50	100
cn-BWO	0,979	2,368	4,729	9,409
DE	0,257	0,591	1,172	2,353
FPA	0,281	0,665	1,316	2,630
GWO	0,254	0,596	1,185	2,341
pv-BWO	0,296	0,826	1,894	4,670
WSO	0,259	0,625	1,174	2,336

Os tempos de execução mantiveram a lógica de quanto mais agentes de busca, mais demorado será o processamento; e esta relação seguiu de forma aproximada na mesma proporção da variação dos agentes de busca, com exceção da meta-heurística pv-BWO que cresceu em uma proporção maior que as demais. Diferente dos resultados pelo RMSE, não é possível definir a meta-heurística mais rápida, mas com certeza a meta-heurística mais lenta é a cn-BWO, seguida da meta-heurística pv-BWO.

Antes de finalizar, na Tabela IX, encontram-se os valores de θ , ϕ e ψ considerando apenas o melhor resultado RMSE

obtido. Observa-se que os valores para a modelagem SDM e DDM estão muito próximos.

Tabela IX
VALORES DE θ , ϕ E ψ

Parâmetros	θ	ϕ	ψ
I_g	1,030 E+00	1,030 E+00	1,030 E+00
$I_{sd(1)}$	3,528 E+00	3,246 E+00	4,443 E+00
$n_{(1)}$	1,353 E+00	1,353 E+00	1,396 E+00
$I_{sd(2)}$	-	2,859 E-01	1,340 E-02
$n_{(2)}$	-	1,352 E+00	1,099 E+00
$I_{sd(3)}$	-	-	1,827 E-02
$n_{(3)}$	-	-	1,110 E+00
R_s	3,334 E-02	3,334 E-02	3,362 E-02
R_p	2,791 E+01	2,791 E+01	3,144 E+01

Por fim, na Tabela X, os melhores resultados de cada meta-heurística são comparados com outros estudos recentes que, para este mesmo problema, utilizaram algoritmos inspirados em: Variação do algoritmo de predadores marinhos (IMPA) [1]; Algoritmo generalizado de baleias marinhas com um operador de exploração adicional (MWGG) [2]; Dinâmica de voo do beija-flor (AHO), incluindo as variações por Newton-Raphson (NR) e Lambert W (LW) [4]; e Modificação da estratégia de caça do gavião-asa-de-telha, ou Harris hawks (WHHO) [16].

Tabela X
COMPARAÇÃO DO RMSE COM A LITERATURA RECENTE

Meta-heurística	SDM	DDM	TDM
AHO [4]	2,425 E-03	-	-
AHO + LW [4]	2,295 E-03	-	-
AHO + NR [4]	2,295 E-03	-	-
cn-BWO [8]	5,900 E-03	5,100 E-03	-
cn-BWO [*]	3,984 E-03	1,489 E-01	8,024 E-03
DE [*]	2,734 E-03	2,984 E-03	3,777 E-03
FPA [*]	3,089 E-03	4,009 E-03	3,819 E-03
GWO [*]	2,999 E-03	3,074 E-03	3,205 E-03
IMPA [1]	2,425 E-03	-	-
MWGG [2]	2,040 E-03	2,040 E-03	-
pv-BWO [8]	3,500 E-03	5,000 E-03	-
pv-BWO [14]	2,425 E-03	2,426 E-03	-
pv-BWO [*]	2,423 E-03	2,427 E-03	2,453 E-03
WHHO [16]	2,425 E-03	2,047 E-03	2,017 E-03
WSO [6]	2,425 E-03	-	-
WSO + NR [6]	2,049 E-03	-	-
WSO [*]	2,423 E-03	2,423 E-03	2,423 E-03

* Este trabalho.

Nesta comparação, para a modelagem SDM, os resultados das meta-heurísticas WSO e pv-BWO deste trabalho se destacam por estarem entre os melhores, além de superarem os valores encontrados nos outros estudos que utilizaram o mesmo algoritmo sem modificação. Esta superação também foi observada na meta-heurística cn-BWO. Quanto à modelagem DDM, apenas a meta-heurística WSO manteve o mesmo destaque, apesar disso, a meta-heurística pv-BWO obteve resultado muito próximo ao melhor valor dos estudos para o mesmo algoritmo. Deve-se observar que o algoritmo cn-BWO deste trabalho obteve a pior resposta para esta modelagem. Sobre a

modelagem TDM, não há muito o que se comparar, além da constatação de que não houve superação ao valor do algoritmo WHHO.

As demais meta-heurísticas, DE, FPA e GWO, não apresentaram valores superiores aos outros estudos nem se destacaram pelos seus resultados em qualquer das modelagens.

VI. CONCLUSÃO

Este trabalho propôs a aplicação e análise comparativa de seis meta-heurísticas distintas, Evolução Diferencial (DE), Polinização de Flores (FPA), Lobo Cinzento (GWO), Viúva-Negra com foco no canibalismo (cn-BWO), Viúva-Negra com foco no feromônio (pv-BWO) e Estratégia de Guerra (WSO), para resolver o problema complexo de estimação de parâmetros de modelos de módulos fotovoltaicos.

A análise consistiu na avaliação do desempenho dessas meta-heurísticas utilizando o modelo de diodo único (SDM), o modelo de duplo diodo (DDM) e o modelo de triplo diodo (TDM) e o valor mínimo da raiz do erro quadrático médio (RMSE) entre os dados medidos e os dados simulados para o painel Photowatt PWP201. Foram realizados testes com diferentes quantidades de agentes de busca, separados em 10, 25, 50 e 100 agentes, ao longo de 1.000 iterações com 20 repetições por teste.

Os resultados de RMSE demonstraram que a meta-heurística WSO se destacou por obter consistentemente os valores mais baixos e mais próximos dos melhores da literatura, nas três modelagens. Mas há indícios de que, para quantidades maiores de agentes, a meta-heurística pv-BWO possa superar os resultados da WSO, mesmo que seja mais lenta para isso. Por outro lado, a meta-heurística cn-BWO apresentou, em geral, os piores resultados de RMSE e tempo de execução, sugerindo menor eficiência e eficácia para este problema.

A comparação dos melhores resultados de RMSE deste trabalho com estudos recentes da literatura para o mesmo problema e painel, demonstrou que as meta-heurísticas aplicadas, em especial a WSO e a pv-BWO, alcançaram desempenhos semelhantes ou superiores, mesmo em relação a estudos que utilizaram os mesmos algoritmos.

REFERÊNCIAS

- [1] M. Abdel-Basset, D. El-Shahat, R. K. Chakraborty e M. Ryan, "Parameter estimation of photovoltaic models using an improved marine predators algorithm", *Energy Conversion and Management*, vol. 227, p. 113491, jan. 2021, doi: 10.1016/j.enconman.2020.113491.
- [2] M. Abdel-Basset, R. Mohamed, M. Sharawi, L. Abdel-Fatah, M. Abouhawwash e K. Sallam, "A comparative study of optimization algorithms for parameter estimation of PV solar cells and modules: Analysis and case studies", *Energy Reports*, vol. 8, p. 13047–13065, nov. 2022, doi: 10.1016/j.egyr.2022.09.193.
- [3] D. F. Alam, D. A. Yousri e M. B. Eteiba, "Flower Pollination Algorithm based solar PV parameter estimation", *Energy Conversion and Management*, vol. 101, p. 410–422, set. 2015, doi: 10.1016/j.enconman.2015.05.074.
- [4] T. S. L. V. Ayyarao e G. I. Kishore, "Parameter estimation of solar PV models with artificial humming bird optimization algorithm using various objective functions", *Soft Comput*, vol. 28, no 4, p. 3371–3392, fev. 2024, doi: 10.1007/s00500-023-08630-x.
- [5] T. S. L. V. Ayyarao, N. S. S. Ramakrishna, R. M. Elavarasan, N. Polumahanthi, M. Rambabu, G. Saini, B. Khan e B. Alatas, "War Strategy Optimization Algorithm: A New Effective Metaheuristic Algorithm for Global Optimization", *IEEE Access*, vol. 10, p. 25073–25105, 2022, doi: 10.1109/ACCESS.2022.3153493.
- [6] T. S. L. V. Ayyarao e P. P. Kumar, "Parameter estimation of solar PV models with a new proposed war strategy optimization algorithm", *Intl J of Energy Research*, vol. 46, no 6, p. 7215–7238, maio 2022, doi: 10.1002/er.7629.
- [7] S. T. Thanikanti, P. R. J. Kumar, N. Kumari e R. Natarajan, "Solar PV parameter extraction using FPA", em 2016 IEEE 6th International Conference on Power Systems (ICPS), New Delhi, India: IEEE, p. 1–6, mar. 2016, doi: 10.1109/ICPES.2016.7584047.
- [8] A. Chauhan e S. Prakash, "Comparison and performance analysis of pheromone value and cannibalism based black widow optimisation approaches for modelling and parameter estimation of solar photovoltaic mathematical models", *Optik*, vol. 259, p. 168943, jun. 2022, doi: 10.1016/j.ijleo.2022.168943.
- [9] A. Chauhan e S. Prakash, "A novel black widow optimization approach to improve the precision in parameter estimation problem of solar photovoltaic electrical model", *Env Prog and Sustain Energy*, vol. 41, no 5, p. e13846, set. 2022, doi: 10.1002/ep.13846.
- [10] D. T. Cofas, M. Madhilarasan e P. A. Cofas, "Extraction of the Multijunction Solar Cell Parameters Using Two Metaheuristic Algorithms", *IEEE Access*, vol. 12, p. 109634–109656, 2024, doi: 10.1109/ACCESS.2024.3439344.
- [11] E. Cuevas, O. Avalos e J. Gálvez, "Comparison of Optimization Techniques for Solar Cells Parameter Identification", *Analysis and Comparison of Metaheuristics*, vol. 1063, em *Studies in Computational Intelligence*, vol. 1063, Cham: Springer International Publishing, 2023, p. 121–167, doi: 10.1007/978-3-031-20105-9_7.
- [12] T. Easwarakhanthan, J. Bottin, I. Bouhouch e C. Boutrit, "Nonlinear Minimization Algorithm for Determining the Solar Cell Parameters with Microcomputers", *International Journal of Solar Energy*, vol. 4, no 1, p. 1–12, jan. 1986, doi: 10.1080/01425918608909835.
- [13] V. Hayyolalam e A. A. P. Kazem, "Black Widow Optimization Algorithm: A novel meta-heuristic approach for solving engineering optimization problems", *Engineering Applications of Artificial Intelligence*, vol. 87, p. 103249, jan. 2020, doi: 10.1016/j.engappai.2019.103249.
- [14] M. Madhilarasan, D. T. Cofas e P. A. Cofas, "Black Widow Optimization Algorithm Used to Extract the Parameters of Photovoltaic Cells and Panels", *Mathematics*, vol. 11, no 4, p. 967, fev. 2023, doi: 10.3390/math11040967.
- [15] S. Mirjalili, S. M. Mirjalili e A. Lewis, "Grey Wolf Optimizer", *Advances in Engineering Software*, vol. 69, p. 46–61, mar. 2014, doi: 10.1016/j.advengsoft.2013.12.007.
- [16] M. Naeijian, A. Rahimnejad, S. M. Ebrahimi, N. Pourmousa, e S. A. Gadsden, "Parameter estimation of PV solar cells and modules using Whippy Harris Hawks Optimization Algorithm", *Energy Reports*, vol. 7, p. 4047–4063, nov. 2021, doi: 10.1016/j.egyr.2021.06.085.
- [17] A. F. Peña-Delgado, H. Peraza-Vázquez, J. H. Almazán-Covarrubias, N. T. Cruz, P. M. García-Vite, A. B. Morales-Cepeda e J. M. Ramirez-Arredondo, "A Novel Bio-Inspired Algorithm Applied to Selective Harmonic Elimination in a Three-Phase Eleven-Level Inverter", *Mathematical Problems in Engineering*, vol. 2020, p. 1–10, dez. 2020, doi: 10.1155/2020/8856040.
- [18] Y. B. Said, Z. Sakhi e M. Bennai, "An approach for improving parameter extraction in PV solar cell models using metaheuristic algorithms", *Energy Syst*, nov. 2024, doi: 10.1007/s12667-024-00709-0.
- [19] R. Storn e K. Price, "Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces", *J Glob Optim*, p. 341–359, 1997, doi: 10.1023/A:100 8202821328.
- [20] X.-S. Yang, "Flower Pollination Algorithm for Global Optimization", *Unconventional Computation and Natural Computation 2012, Lecture Notes in Computer Science*, vol. 7445, p. 240–249, 2012, doi: 10.1007/978-3-642-32894-7_27.