

Comparação de desempenho de técnicas de rastreamento de máxima potência de módulos fotovoltaicos sob condições de sombreamento parcial

Fábio Inácio da Silva*, Caio Meira Amaral da Luz**, Enio Roberto Ribeiro**, Fernando Lessa Tofoli*

* *Universidade Federal de São João del-Rei*
Praça Frei Orlando, 170 - B. Centro 36307-352 São João del-Rei-MG, Brasil
(e-mail: fainsil@hotmail.com, fernandolessa@ufsj.edu.br)

** *Universidade Federal de Itajubá*,
Av. BPS, 1303 - B. Pinheirinho 37500-903 Itajubá-MG, Brasil
(e-mail: caiomeiramaral@hotmail.com, enio.k@unifei.edu.br)

Abstract: Partial shading conditions can significantly reduce the efficiency of a photovoltaic (PV) system. The literature has presented increasingly sophisticated techniques to deal with this problem, considering that conventional maximum power tracking (MPPT) approaches are inefficient in such a case. In this sense, this paper presents a comparison among four techniques for determining the maximum power point (MPP) when the irradiance levels incident on the PV modules are not uniform. Gray wolf optimization (GWO), differential evolution (DE), bat algorithm (BA), and golden section optimization (GSO) are chosen for this purpose. Simulation results on a total-cross-tied (TCT) PV string connected to a dc-dc single-ended primary inductance converter (SEPIC) are presented and discussed to compare the aforementioned approaches.

Resumo: Condições de sombreamento parcial podem reduzir significativamente a eficiência de um sistema fotovoltaico (*photovoltaic* – PV). A literatura tem apresentado técnicas cada vez mais sofisticadas para lidar com esse problema, considerando que os métodos convencionais de rastreamento de potência máxima (*maximum power point tracking* – MPPT) são ineficientes nesse caso. Nesse sentido, este trabalho apresenta uma comparação entre quatro técnicas para determinar o ponto de máxima potência quando os níveis de irradiância incidentes nos módulos PV não são uniformes. Otimização de lobo cinzento (*gray wolf optimization* – GWO), evolução diferencial (*differential evolution* – DE), algoritmo de morcego (*bat algorithm* – BA) e otimização de seção dourada (*golden section optimization* – GSO) são escolhidos para esse propósito. Resultados de simulação obtidos a partir de um arranjo TCT (*total-cross-tied*) conectado a um conversor CC-CC SEPIC (*single-ended primary inductance converter* – conversor com uma única indutância primária) são apresentados e discutidos para comparar as abordagens supracitadas.

Keywords: bat algorithm, golden section optimization, global maximum power point tracking, partial shading.

Palavras-chaves: algoritmo do morcego, otimização por seção áurea, rastreamento do ponto de máxima potência global, sombreamento parcial.

1. INTRODUÇÃO

A crescente demanda pela geração de energia elétrica de forma sustentável impulsionou pesquisas no campo de energias renováveis e não poluentes. Nesse contexto, a energia advinda de sistemas fotovoltaicos (*photovoltaic* – PV) ganhou grande destaque por ser uma fonte natural de grande abundância no planeta e livre de poluição (De Brito et al., 2010).

Uma importante questão associada a sistemas PV é o fato de que a máxima potência que pode ser extraída é estritamente dependente de condições atmosféricas em termos da temperatura de operação e níveis de irradiância incidentes nos módulos. Nesse contexto, diversas técnicas de rastreamento do ponto de máxima potência (*maximum power*

point tracking – MPPT) foram propostas na literatura (Tey et al., 2018a).

Um importante aspecto prático relacionado à operação de sistemas fotovoltaicos reside na condição de sombreamento parcial (*partial shading condition* - PSC) ocasionalmente provocada por nuvens, obstáculos, sedimentos depositados sobre a superfície dos módulos, entre outros fatores (Das et al., 2017). Esse inconveniente motivou o desenvolvimento de técnicas de rastreamento do ponto de máxima potência global (*global maximum power point tracking* – GMPPT) (da Luz et al., 2020).

Outro ponto que merece destaque reside no fato de que PSC pode causar a polarização reversa do módulo, isto é, quando uma célula começa a se comportar como uma carga e passa a consumir a energia produzida por outras células do sistema. Em situação mais extremas, PSC pode causar danos

permanentes aos módulos fotovoltaicos devido aos fenômenos de pontos quentes, situação essa, que pode ser tratada utilizando diodos de *Bypass* (Jha and Triar, 2019).

Técnicas convencionais como perturba e observa (P&O) e condutância incremental (INC – *incremental conductance*) são ineficientes na busca pelo ponto de máxima potência global sob condições de PSC (Sousa et al., 2018). Nesse cenário, diferentes tipos de técnicas foram apresentadas na literatura com o objetivo de mitigar tal problema, incluindo algoritmos de computação inteligente envolvendo redes neurais artificiais (*artificial neural networks – ANNs*), lógica *fuzzy* e técnicas metaheurísticas, como algoritmo genético (*genetic algorithm – GA*), otimização do lobo cinzento (*grey wolf optimization – GWO*), otimização de colônia de formigas (*ant colony optimization – ACO*), dentre outras.

Nesse contexto, este trabalho apresenta uma comparação de desempenho de quatro técnicas GMPPT, a saber: método de otimização da seção áurea (*golden section optimization – GSO*) (Kheldoun et al., 2016), GWO (Mohanty et al., 2016), o algoritmo de evolução diferencial (*differential evolution – DE*) (Tajuddin et al., 2013) e o algoritmo do morcego (*bat algorithm – BA*) (Yang, 2010). A escolha se justifica por esses métodos não envolverem cálculos complexos e não envolverem elevado esforço computacional, podendo ser facilmente embarcadas em microcontroladores simples e de baixo custo como Arduino. Para a comparação das técnicas citadas, será observada a eficiência em alcançar o ponto de máxima potência e o tempo de convergência por meio de simulações computacionais, visando identificar as vantagens e as limitações de cada técnica.

2. TÉCNICAS DE RASTREAMENTO DE MÁXIMA POTÊNCIA

A literatura apresenta diversos estudos relacionados à proposição de técnicas de GMPPT visando extrair a máxima potência de sistemas PV submetidos a PSC. Nessa condição, a curva potência versus tensão ($P \times V$) do arranjo PV pode apresentar diversos picos locais e apenas um máximo local, o que pode levar técnicas convencionais como P&O e INC a não serem capazes de obter a máxima eficiência possível (Maharana et al., 2021). Assim, como foi anteriormente mencionado, a literatura apresenta uma diversidade de técnicas de GMPPT baseadas em diferentes princípios, como metaheurísticas, inteligência artificial, computação matemática, soluções híbridas, dentre outras. Esta seção apresenta uma breve descrição das quatro técnicas escolhidas neste trabalho.

2.1 GSO

O método GSO baseia-se no princípio de que um segmento de reta de comprimento L é dividido em dois subsegmentos L_1 e L_2 , de modo que a igualdade da equação (1) é válida (Kheldoun et al., 2016).

$$\frac{L}{L_1} = \frac{L_1}{L_2} \quad (1)$$

A equação (1) pode ser reescrita como (2).

$$\frac{L_1 + L_2}{L_1} = \frac{L_1}{L_2} = \Phi, \quad (2)$$

em que Φ é a razão áurea. Pela manipulação de (2), obtém-se (3).

$$\Phi^2 - \Phi - 1 = 0 \quad \Phi^2 - \Phi - 1 = 0. \quad (3)$$

A parte positiva da solução de (3) resulta em (4).

$$\Phi = \frac{1 + \sqrt{5}}{2} = 1,618. \quad (4)$$

Define-se então a seção áurea α_{GS} como sendo a razão entre L_2 e L_1 , por sua vez expressa por (5).

$$\alpha_{GS} = \frac{1}{\Phi} = \Phi - 1 = 0,618. \quad (5)$$

A partir da seção áurea α_{GS} , geram-se dois pontos no espaço de pesquisa, a saber, D_1 e D_2 , limitados no intervalo $[a, b]$. Na técnica GSO, esses pontos correspondem à razão cíclica imposta ao conversor CC-CC, ao passo que os pontos iniciais do intervalo são os limites $[0, 1]$ segundo (6).

$$\begin{cases} D_1 = a + 0,618(b - a) \\ D_2 = b - 0,618(b - a) \end{cases} \quad (6)$$

A função aptidão a ser maximizada para o sistema PV será a potência em cada ponto de operação $P(D)$. O processo de rastreamento é iterativo, de maneira que, após o início com o intervalo $[a, b] = [0, 1]$, tem-se:

- Se $P(D_1) < P(D_2)$, o ponto máximo não pode ser menor que D_1 . Então, o ponto máximo estará entre $[D_1, b]$, que será adotado como novo intervalo para a próxima iteração.
- Se $P(D_1) > P(D_2)$, o ponto máximo será menor que D_2 . Então, o ponto máximo estará entre $[a, D_2]$ e este será o novo intervalo para a próxima iteração.

Uma vez definido o novo intervalo, o processo se repete refinando a função de aptidão até que uma tolerância tol seja alcançada segundo (7).

$$|D_2 - D_1| \leq tol. \quad (7)$$

Quando o módulo da diferença entre os pontos D_2 e D_1 satisfaz a equação (7), define-se a razão cíclica para o ponto de máxima potência como D_{MPPT} em (8).

$$D_{MPPT} = 0,5(D_1 + D_2). \quad (8)$$

2.2 GWO

GWO é uma técnica metaheurística que simula o comportamento de uma alcateia de lobos na busca por presas (Mohanty et al., 2016). Quatro tipos de lobos cinzentos são

empregados para simular a hierarquia do bando: alfa (α), beta (β), delta (δ) e ômega (ω), sendo que α indica a melhor solução; β e δ são a segunda e terceira melhores soluções, respectivamente; e o restante das soluções são consideradas ω , sendo essa uma condição na qual os lobos não realizam o processo de captura da presa.

Durante a caça, os lobos cercam a presa e o comportamento pode ser modelado pelas equações (9) e (10).

$$\bar{D} = |\bar{C} \cdot \bar{X}_p(t) - \bar{X}_p(t)|, \quad (9)$$

$$\bar{X}(t+1) = \bar{X}_p(t) - \bar{A} \cdot \bar{D}, \quad (10)$$

em que t denota a iteração atual; D , A e C representam vetores do coeficiente; X_p é o vetor posição da presa; e X indica o vetor posição do lobo cinzento. Os vetores A e C são calculados conforme (11) e (12).

$$\bar{A} = 2\bar{a} \cdot \bar{r}_1 - \bar{a}, \quad (11)$$

$$\bar{C} = 2 \cdot \bar{r}_2, \quad (12)$$

em que os componentes de a decaem linearmente de 2 até 0 durante o processo iterativo; r_1 e r_2 são vetores aleatórios dentro do intervalo $[0, 1]$. A caça é guiada pelo lobo α , seguido por β e δ . Portanto, a cada iteração, a melhor solução encontrada é considerada como sendo α e o objetivo da técnica é aproximar a grandeza X até X_p , justamente quando o valor de a tenderá a zero.

Para aplicar o método GWO em sistemas PV, a razão cíclica D é definida como a posição do lobo cinzento e, então, a equação (10) pode ser reescrita como (13).

$$\bar{D}(k+1) = \bar{D}_i(k) - \bar{A} \cdot \bar{D}. \quad (13)$$

Assim, a função objetivo do método será dada por (14).

$$P(k) > P(k-1), \quad (14)$$

em que $P(k)$ é a potência da iteração atual k e $P(k-1)$ é a potência obtida na iteração anterior. Assim, todas as iterações são comparadas e a melhor solução é definida como o ponto de máxima potência.

2.3 DE

O algoritmo DE foi proposto para a resolução de problemas de otimização global (Tajuddin et al., 2013). Nesse método, são criadas populações de indivíduos que são submetidas a operadores genéticos: seleção, mutação e recombinação. Esses operadores geram um novo indivíduo, com características do cruzamento genético anterior, que serão refinadas para caracterizar progressivamente uma melhor solução. Dessa maneira, o algoritmo é capaz de gerar novas populações por meio do método de evolução natural (da Costa, 2010).

A técnica DE utiliza vetores alvo como sendo a população e, para aplicar o algoritmo em sistemas PV, esses vetores são

criados com o valor da razão cíclica do conversor. A cada iteração do método, é testado o vetor para obter a potência P_{PV} referente a cada valor de D . O vetor alvo é dado por (15).

$$D_i = [0,2 \quad 0,4 \quad 0,6 \quad 0,8], \quad (15)$$

em que i refere-se à posição de cada elemento do vetor.

Para garantir que a população inicial cubra a maior parte da curva $P \times V$, os valores iniciais são dispostos conforme a equação (15). A cada iteração, o vetor D é testado e a potência de cada elemento gera um novo vetor potência P_i . A melhor solução encontrada é considerada P_{best} correspondendo à razão cíclica D_{best} .

Na próxima iteração, o processo de mutação é realizado a partir de três valores aleatórios (D_{r1} , D_{r2} e D_{r3}) selecionados a partir da iteração anterior, gerando um novo vetor doador D_{vi} . A mutação é realizada de maneira que as três partículas sejam comparadas e convirjam para a melhor solução na qual a partícula D_{r1} é comparada com D_{best} conforme (16).

$$D_{vi} = \begin{cases} D_{r1} - F | D_{r2} - D_{r3} |, & \text{se } D_{r1} \geq D_{best} \\ D_{r1} + F | D_{r2} - D_{r3} |, & \text{caso contrário} \end{cases}, \quad (16)$$

em que F é o fator de mutação, o qual é iniciado em 0,6 e reduzido linearmente até 0,3 à medida que o número de iterações aumenta para garantir uma convergência mais rápida.

Após a mutação, um novo vetor doador D_{vi} é gerado com quatro partículas. O próximo passo é o processo de cruzamento (*crossover*), no qual um novo vetor de testes D_{ui} é gerado. O cruzamento é realizado comparando um número aleatório *rand* com uma taxa de cruzamento *CR*. Se *rand* > *CR*, então a partícula do vetor doador D_{vi} é escolhida. Caso contrário, a partícula do vetor alvo D_i é escolhida. A taxa *CR* proposta tem valor de 0,67 (Tey et al., 2018b).

$$D_{ui} = \begin{cases} D_{vi}, & \text{se } rand \geq CR \\ D_i, & \text{caso contrário} \end{cases}. \quad (17)$$

De posse do vetor de teste D_{ui} , as razões cíclicas são aplicadas ao interruptor controlado do conversor, gerando o vetor de potência P_{ui} , que é então comparado com o vetor P_i conforme a equação (18). O vetor que possuir a melhor solução é adotado como vetor alvo para a próxima iteração.

$$D_{proxi} = \begin{cases} D_{ui}, & \text{se } P_{ui} \geq P \\ D_i, & \text{caso contrário} \end{cases}, \quad (18)$$

em que D_{proxi} é o vetor alvo da próxima iteração nas respectivas posições i .

O processo de parada é definido quando a diferença da potência das melhores soluções encontradas ΔP_i for menor que 5% e a diferença das razões cíclicas ΔD_i for menor que 0,05. Essa condição indica que as partículas estão consideravelmente próximas e, dessa maneira, a solução do algoritmo será a razão cíclica da melhor partícula (D_{best}).

2.4 BA

BA é uma técnica metaheurística de otimização, que se baseia no voo dos morcegos em busca da caça utilizando o sistema de ecolocalização, sendo que o morcego utiliza a emissão de pulsos com frequência f e escuta o eco (Yang, 2010). Duas variáveis são importantes nesse método: a taxa de emissão de pulsos r e a intensidade do pulso A . O método inicia a população com N morcegos com velocidades v_i e posições x_i em um espaço de busca D . Os morcegos realizam buscas aleatórias no espaço e, com base no melhor resultado, um novo vetor posição é gerado para fazer buscas locais nessa região. O processo então compara os resultados e cria uma melhor solução, que é base para reiniciar o processo de busca. A busca termina quando um critério de parada é atingido (Tey et al., 2018a).

Para a implementação da técnica em sistemas fotovoltaicos, a razão cíclica D do conversor é considerada como a posição dos morcegos e a solução do algoritmo é a potência de saída do arranjo fotovoltaico P_{PV} . Para iniciar a população visando cobrir todo o espaço, as razões cíclicas são definidas conforme (19).

$$D_i = [0,2 \quad 0,4 \quad 0,6 \quad 0,8] \quad (19)$$

As razões cíclicas são aplicadas ao conversor e as potências são comparadas entre si, sendo que P_{best} é a maior potência e a razão cíclica correspondente é dada por D_{best} . Em seguida, novos valores são gerados conforme as equações (20), (21) e (22).

$$f_i = f_{\min} + (f_{\max} - f_{\min})\beta, \quad (20)$$

$$v^{t+1} = v^t + (D^t - D_{best})f, \quad (21)$$

$$D^{t+1} = \begin{cases} D^t - |v^{t+1}|, & \text{se } D^t > D_{best} \\ D^t + |v^{t+1}|, & \text{caso contrário} \end{cases}, \quad (22)$$

em que f_i é a frequência da iteração atual e, pela definição do método, $f_{\min}=0,3$ e $f_{\max}=0,5$ são fixos (Tey et al., 2018a); β é um número no intervalo $[0, 1]$ escolhido aleatoriamente; v^{t+1} é a velocidade da próxima iteração; e v^t a velocidade atual, sendo iniciada com valor nulo. Por fim, a equação (22) define as razões cíclicas da próxima iteração que, de acordo com a velocidade, seguem em direção a D_{best} .

Na sequência, a busca local é implementada de acordo com (23).

$$D^{t+1} = D^t + \varepsilon A^t, \text{ se } rand(0,1) > r^t, \quad (23)$$

em que $\varepsilon \in [-1, 1]$ é um valor escolhido aleatoriamente; A^t é a intensidade, definida como 0,5; $rand(0,1)$ é um número aleatório entre o intervalo $[0, 1]$; e r^t é a taxa de pulso, sendo a taxa de pulso inicial r^0 , definida como 0,67. Observa-se que a equação (23) modifica a razão cíclica da iteração posterior a partir de uma condição aleatória.

De posse dos novos valores, as potências são comparadas com o ciclo anterior e as melhores soluções são selecionadas conforme (24).

$$\left. \begin{aligned} D^{t+1} &= D^t \\ P^{t+1} &= P^t \end{aligned} \right\} \text{ se } P(D^{t+1}) < P(D^t). \quad (24)$$

A partir de (24), as melhores soluções são selecionadas para a próxima iteração. A taxa de pulsos e a intensidade também são atualizadas a partir de (25) e (26), respectivamente.

$$A^{t+1} = 0,5A^t, \quad (25)$$

$$r^{t+1} = r^0 (1 - e^{-0,5t}). \quad (26)$$

Então, o processo de busca reinicia e terminará quando a diferença na potência das melhores partículas ΔP_{best} for um valor inferior a 5%. Assim, o ponto de máxima potência é definido como D_{best} .

3. RESULTADOS DE SIMULAÇÕES

Para a comparação das técnicas apresentadas, considera-se um arranjo PV com nove módulos de 5 W em condições de teste padrão (*standard test condition* – STC), modelo KM(P)5 fabricado por Komaes Solar®, por sua vez arranjados na configuração TCT segundo a Figura 1.

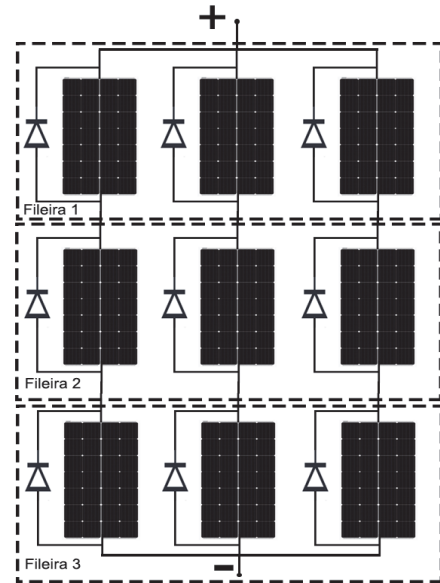


Figura 1 – Representação dos módulos fotovoltaicos dispostos na configuração TCT.

O arranjo PV é conectado a um conversor SEPIC, sendo que a escolha desse tipo de conexão se deve ao fato de apresentar melhor desempenho em PSC segundo (Das et al., 2017). Na Figura 1, cada fileira receberá diferentes valores de irradiância e temperatura para a emulação de PSC. O conversor SEPIC foi adotado por ser amplamente empregado em sistemas PV, em virtude de possuir corrente de entrada com ondulação reduzida quando operando em modo de condução contínua (MCC), bem como da capacidade de

e elevar e reduzir a tensão de entrada, percorrendo assim toda a curva $P \times V$ (Duran et al., 2011).

Para analisar a influência do sombreamento parcial, o circuito foi simulado no *software* PSIM. As condições de temperatura e irradiância foram alteradas seguindo a Tabela 1, criando-se assim dois padrões distintos de sombreamento. Observa-se na Figura 2 e na Figura 3 os múltiplos picos na curva $P \times V$.

Tabela 1 - Padrões climáticos de teste para simulação do sombreamento parcial.

Linha	Padrão de Teste 1			Padrão de Teste 2		
	W/m ²	°C	Máxima Potência Teórica (W)	W/m ²	°C	Máxima Potência Teórica (W)
#1	190	40	14,0785	190	45	21,9588
#2	330	60		800	55	
#3	1130	65		1130	65	




Figura 2 - Curva $P \times V$ para o padrão de irradiância 1, com potência máxima de 14,0785 W.

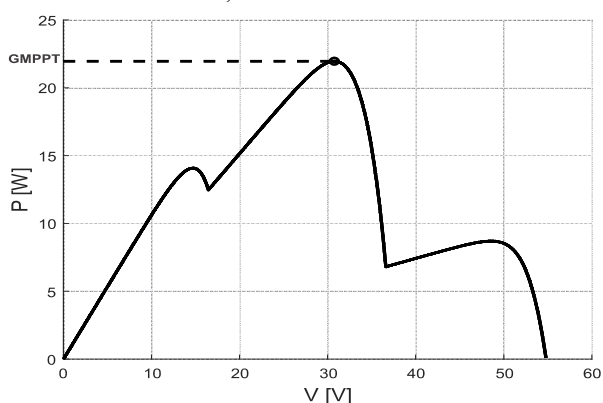


Figura 3 - Curva $P \times V$ para o padrão de irradiância 2, com potência máxima de 21,9588 W.

3.1 GSO

A potência extraída do arranjo PV empregando a técnica GSO é mostrada na Figura 4 e na Figura 5 para os dois padrões simulados. Observa-se que o método refina

progressivamente os valores da razão cíclica, determinando o ponto de máxima potência global em menos de 0,3 s.

GSO destaca-se por sua precisão e sua capacidade de encontrar o GMPPT rapidamente, pois apenas duas condições são testadas a cada iteração do método, diferentemente dos métodos metaheurísticos apresentados nesse trabalho, que requerem no mínimo quatro condições para esta finalidade.

Outro parâmetro de relevância fundamental é a tolerância do método, definida na equação (8) e estabelecida como 0,1 W nas simulações. A tolerância é o parâmetro que definirá o critério de parada do algoritmo e, quanto menor o seu valor, mais testes serão analisados na curva de potência, refinando cada vez mais a busca pelo máximo global, porém com dispêndio maior de tempo. Portanto, a escolha correta desse parâmetro é essencial para o sucesso do método.




Figura 4 - Potência extraída do sistema PV empregando o método GSO para o padrão de teste #1.




Figura 5 - Potência extraída do sistema PV empregando o método GSO para o padrão de teste #2.

3.2 GWO

A Figura 6 e a Figura 7 mostram a potência extraída empregando o algoritmo GWO. Em ambos os testes, o tempo para determinação do GMPPT foi ligeiramente superior a 0,3 s.

A técnica dos lobos cinzentos possui boa eficiência na determinação do ponto de máxima potência. Observa-se nas simulações que durante o início da busca, os lobos, representados pelas razões cíclicas, estão mais dispersos um dos outros. O início é de extrema importância pois, nesse período, são realizadas buscas espaçadas cobrindo boa parte da curva $P \times V$, evitando que todos os lobos estejam posicionados próximos de um máximo local. Nas iterações seguintes, os lobos se aproximam da melhor solução (α), até que estejam próximos o suficiente, justamente quando o método se encerra.

Em ambos os casos, também é possível observar pontos de potência consideravelmente distantes da melhor solução, representando os lobos ω . Esses pontos trazem alterações bruscas na razão cíclica do conversor e, como consequência, dificuldades na estabilização do valor da potência. Em alguns casos, estes pontos apresentam potências reduzidas próximos de zero, pois representam os lobos que não participam do processo de caça junto ao bando, correspondendo a valores de razão cíclica distante dos demais.

Porém, os lobos ω possuem fundamental importância no método. Caso os demais lobos estejam deslocando erroneamente a um máximo local e o lobo ω encontre um ponto com potência superior, este se torna um lobo α , passando a guiar a caça a partir desse momento para o ponto correto.

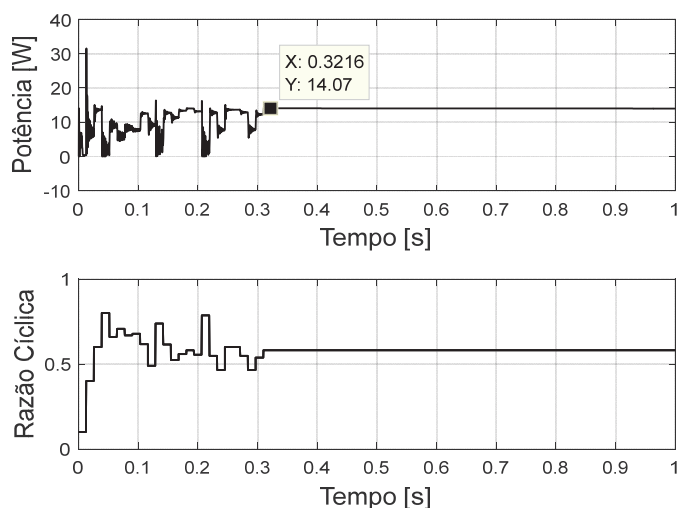


Figura 6 - Potência extraída do sistema PV empregando o método GWO para o padrão de teste #1.




Figura 7 - Potência extraída do sistema PV empregando o método GWO para o padrão de teste #2.

3.3 DE

Os resultados para o algoritmo DE são mostrados na Figura 8 e Figura 9. O método inicia realizando testes espaçados de maneira uniforme na curva $P \times V$ e, na sequência, o processo de mutação aproxima algumas soluções, escolhidas aleatoriamente da melhor solução. Posteriormente, o processo de cruzamento seleciona, de maneira randômica, as candidatas que serão comparadas para a próxima iteração criando o novo vetor alvo. Destaca-se a elevada rapidez em que o método encontra o máximo global, pois o cruzamento dos vetores sempre ocorre com a melhor solução e traz celeridade ao método. Deve-se ressaltar a utilização de um quesito aleatório para a escolha das soluções que serão selecionadas e cruzadas. Desta maneira, esse processo pode trazer distintas soluções para cada simulação, mesmo com os mesmos padrões de irradiância e temperatura.




Figura 8 - Potência extraída do sistema PV empregando o algoritmo DE para o padrão de teste #1.




Figura 9 - Potência extraída do sistema PV empregando o algoritmo DE para o padrão de teste #2.

3.4 BA

Os resultados das simulações utilizando o algoritmo BA podem ser observados nas Figura 10 e na Figura 11. Destaca-se a grande variação de potência definida pelos voos aleatórios dos morcegos no início do método. Posteriormente, os morcegos são escolhidos de forma randômica para se aproximarem da melhor solução, o que define as buscas locais. A maneira aleatória que o algoritmo define os morcegos que seguirão na direção da melhor solução garante que nem sempre todos os morcegos voarão na mesma direção, o que ajuda o método a não se prender em pontos de máxima potência locais. Nesse método, os valores da velocidade e da intensidade, definidos pelas equações (21) e (25), respectivamente, possuem grande influência no sucesso do método, pois esses parâmetros podem guiar os morcegos de maneira equivocada ao assumirem valores elevados.




Figura 10 - Potência extraída do sistema PV empregando o algoritmo BA para o padrão de teste #1.




Figura 11 - Potência extraída do sistema PV empregando o algoritmo BA para o padrão de teste #2.

3.5 Comparação entre Os Resultados Obtidos

Todos os métodos simulados apresentaram condições satisfatórias na busca do ponto de máxima potência global, não se prendendo a máximos locais. Assim, a Tabela 2 apresenta os resultados encontrados para cada técnica de MPPT. Observa-se que, em ambos os testes realizados, o método GSO obteve a melhor eficiência em regime permanente em relação aos demais algoritmos. Tal método possui ótimo desempenho em virtude das expressões matemáticas que definem a razão cíclica do conversor CC-CC a partir da seção áurea, de maneira a refinar cada vez mais a busca na direção do máximo global. Outro fato de destaque do algoritmo GSO é a não utilização de componentes aleatórias, o que leva os pontos calculados sempre na mesma direção.

Tabela 2 – Comparação entre os resultados encontrados pelos algoritmos de GMPPT analisados.

Algoritmo	Padrão de Teste	Potência Extraída (W)	Tempo de Convergência (s)	Eficiência
GSO	#1	14,0706	0,2715	99,94%
	#2	21,8720	0,2706	99,60%
GWO	#1	14,0706	0,3216	99,94%
	#2	21,6000	0,3122	98,37%
DE	#1	13,8904	0,1744	98,66%
	#2	21,7936	0,2510	99,25%
BA	#1	14,0400	0,7362	99,73%
	#2	21,5167	0,7362	97,99%

4. CONCLUSÃO

Este trabalho apresentou a análise de quatro algoritmos de GMPPT visando solucionar o problema de PSC em sistemas fotovoltaicos. As estratégias escolhidas foram implementadas e avaliadas computacionalmente para dois padrões de sombreamento distintos, que resultaram em três picos na curva $P \times V$ do arranjo, correspondendo a dois máximos locais e um máximo global.

Os resultados mostram que todas as técnicas foram capazes de determinar a máxima potência global. Ressalta-se que a aleatoriedade de alguns parâmetros dos algoritmos metaheurísticos pode afetar o resultado das comparações. Dessa maneira, para análises mais profundas, tornam-se necessárias maiores quantidades de simulações.

Destaca-se neste trabalho o desempenho do algoritmo GSO, por possuir a maior precisão em ambos os testes realizados, apesar de apresentar um tempo de rastreamento ligeiramente maior quando comparado ao método DE. Outro aspecto relevante da técnica GSO é o esforço computacional, pois a técnica possui cálculos extremamente simples, utilizando somente adições, subtrações e multiplicações, comparando a cada iteração apenas dois pontos para obter os resultados.

AGRADECIMENTOS

Os autores agradecem o apoio das seguintes instituições: UFSJ, UNIFEI, FAPEMIG, CAPES, CNPq e INERGE.

REFERÊNCIAS

- da Costa WT (2010) Modelagem, Estimação de Parâmetros e Método MPPT para Módulos Fotovoltaicos. Universidade Federal do Espírito Santo, Brazil.
- da Luz CMA, Vicente EM and Tofoli FL. (2020) Experimental Evaluation of Global Maximum Power Point Techniques Under Partial Shading Conditions. *Solar Energy* 196: 49-73.
- Das P, Mohapatra A and Nayak B (2017) Modeling and Characteristic Study of Solar Photovoltaic System Under Partial Shading Condition. *Materials Today: Proceedings* 4: 12586-12591.
- De Brito MA, Luigi G, Sampaio LP, et al. (2010) Avaliação das Principais Técnicas Para Obtenção de MPPT de Painéis Fotovoltaicos. *2010 9th IEEE/IAS International Conference on Industry Applications - INDUSCON 2010*. IEEE, 1-6.
- Duran E, Andujar J, Segura F, et al. (2011) A High-Flexibility Dc Load for Fuel Cell and Solar Arrays Power Sources Based on Dc-Dc Converters. *Applied energy* 88: 1690-1702.
- Jha V and Triar US (2019) A Detailed Comparative Analysis of Different Photovoltaic Array Configurations Under Partial Shading Conditions. *International Transactions on Electrical Energy Systems* 29: e12020.
- Kheldoun A, Bradai R, Boukenoui R, et al. (2016) A New Golden Section Method-Based Maximum Power Point Tracking Algorithm for Photovoltaic systems. *Energy Conversion and Management* 111: 125-136.
- Maharana SM, Mohapatra A, Saiprakash C, et al. (2021) Comparative Analysis of Different Pv Array Configurations Under Partial Shading Conditions. *2020 3rd International Conference on Energy, Power and Environment: Towards Clean Energy Technologies*. IEEE, 1-5.
- Mohanty S, Subudhi B and Ray PK (2016) A New MPPT Design Using Grey Wolf Optimization Technique for Photovoltaic System Under Partial Shading Conditions. *IEEE Transactions on Sustainable Energy* 7: 181-188.
- Sousa SM, Rodrigues GG, da Luz CMA, et al. (2018) Estudo Comparativo de Técnicas de MPPT Baseadas em Controlador Fuzzy e o Algoritmo Beta para Sistemas Fotovoltaicos Utilizando Conversor CC-CC SEPIC. *Congresso Brasileiro de Automática - CBA 2018*, pp.1-8.
- Tajuddin MFN, Ayob SM, Salam Z, et al. (2013) Evolutionary Based Maximum Power Point Tracking Technique Using Differential Evolution Algorithm. *Energy and Buildings* 67: 245-252.
- Tey KS, Mekhilef S and Seyedmahmoudian M. (2018a) Implementation of BAT Algorithm as Maximum Power Point Tracking Technique for Photovoltaic System Under Partial Shading Conditions. *2018 IEEE Energy Conversion Congress and Exposition (ECCE)*. 2531-2535.
- Tey KS, Mekhilef S, Seyedmahmoudian M, et al. (2018b) Improved Differential Evolution-Based MPPT Algorithm Using SEPIC for PV Systems Under Partial Shading Conditions and Load Variation. *IEEE Transactions on Industrial Informatics* 14: 4322-4333.
- Yang X-S. (2010) A New Metaheuristic Bat-Inspired Algorithm. *Nature inspired cooperative strategies for optimization (NICSO 2010)*. Springer, 65-74.