

Performance Evaluation of Transfer Functions in Metaheuristics for AC Transmission Expansion Planning

1st Lucas Santiago Nepomuceno

Programa de Pós-Graduação em Engenharia Elétrica

Universidade Federal de Juiz de Fora

Juiz de Fora, Minas Gerais, Brasil

nepomuceno.lucas.santiago@gmail.com

2nd Edimar José de Oliveira

Programa de Pós-Graduação em Engenharia Elétrica

Universidade Federal de Juiz de Fora

Juiz de Fora, Minas Gerais, Brasil

edimar.joliveira@engenharia.ufjf.br

3rd Arthur Neves de Paula

Programa de Pós-Graduação em Engenharia Elétrica

Universidade Federal de Juiz de Fora

Juiz de Fora, Minas Gerais, Brasil

arthur.paula@engenharia.ufjf.br

4th Leonardo Willer de Oliveira

Programa de Pós-Graduação em Engenharia Elétrica

Universidade Federal de Juiz de Fora

Juiz de Fora, Minas Gerais, Brasil

leonardo.willer@engenharia.ufjf.br

Abstract—This study investigates the performance of different transfer functions applied to metaheuristics in solving the AC Transmission Network Expansion Planning (AC TNEP) problem. The metaheuristics Gray Wolf Optimizer (GWO), Whale Optimization Algorithm (WOA), and Sine Cosine Algorithm (SCA) are evaluated in combination with hyperbolic tangent, arctangent, and modified sigmoid transfer functions. The primary objective is to assess the effectiveness of these combinations in searching for optimal solutions to the AC TNEP problem. The validity of the proposed methodology is demonstrated through a case study using the IEEE RTS 24-bus test system.

Index Terms—AC Transmission Network Expansion Planning, Optimization, Metaheuristics, Gray Wolf Optimizer, Whale Optimization Algorithm, Sine Cosine Algorithm.

I. INTRODUÇÃO

O planejamento da expansão da transmissão de energia elétrica (PET) é um processo complexo que visa determinar onde, quantos e quando novos dispositivos devem ser incorporados à rede elétrica, de forma a garantir uma interligação eficiente entre a geração e o consumo de energia [1].

A abordagem utilizada para resolver o PET depende principalmente da dimensão do sistema elétrico, do horizonte de tempo considerado e do modelo de representação da rede [2]. Ferramentas que se baseiam na representação da rede no modelo CA são capazes de lidar com o planejamento de reativos na rede, modelar perdas de forma precisa e considerar estudos de estabilidade de tensão. Entretanto, o PET utilizando a representação da rede CA é um problema de otimização não-linear inteiro-misto, caracterizado por um espaço de busca não-convexo, de difícil solução [1, 2].

Os autores agradecem o apoio financeiro da CAPES - Agência Federal de Apoio e Avaliação da Pós-Graduação, CNPq - Conselho Nacional de Pesquisa, INERGE - Instituto Brasileiro de Ciência e Tecnologia e FAPEMIG - Fundação de Amparo à Pesquisa do Estado de Minas Gerais. Os autores também agradecem o apoio educacional da UFJF - Universidade Federal de Juiz de Fora.

Existem diversas técnicas para solucionar o problema PET, incluindo métodos de otimização clássica, técnicas heurísticas e meta-heurísticas. As meta-heurísticas se destacam devido à sua capacidade de encontrar soluções de alta qualidade com um custo computacional relativamente baixo, mesmo para sistemas complexos. Elas são eficientes na exploração do espaço de busca e são simples de implementar, permitindo modificações em suas estruturas e parâmetros para resolver uma ampla gama de problemas com características matemáticas diversas [1].

Em [3], foi utilizado o *genetic algorithm* (GA) para solucionar o problema de PET DC. Duas melhorias foram propostas pelos autores: a obtenção da população inicial por meio de um método convencional de otimização e uma abordagem de mutação inspirada na meta-heurística *simulated annealing* (SA).

Em [4], uma versão aprimorada do GA foi empregada para resolver o PET DC. Já em [5], o *Chu and Beasley genetic algorithm* (CBGA) foi adaptado para lidar com o PET DC, levando em consideração incertezas na carga do sistema. Duas formulações foram estudadas: uma que considera a incerteza na demanda total do sistema e outra que aborda as incertezas nas cargas individuais das barras.

Na referência [6], foi proposta uma metodologia heurística construtiva para reduzir o conjunto de linhas de transmissão candidatas à expansão, seguida pela aplicação da meta-heurística *particle swarm optimization* (PSO) para solucionar o PET DC. De forma semelhante, [7] aplicou multiplicadores de Lagrange e coeficientes de Benders para reduzir o conjunto de linhas candidatas à expansão e, em seguida, utilizou uma versão modificada da meta-heurística *bat algorithm* (BA) para resolver o PET DC, considerando o critério de segurança determinístico N-1.

Por sua vez, em [8], foi proposto um novo método para

redução do conjunto de linhas candidatas à expansão, no qual todas as linhas são inicialmente consideradas como já construídas. A partir da solução do fluxo de potência contínuo, o ramo com menor necessidade de reforço é identificado e excluído do planejamento. Após essa redução do espaço de busca, uma versão binária modificada do *gray wolf optimizer* (GWO) foi empregada para encontrar soluções ótimas para o PET DC.

Em [9], o algoritmo *harmony search* (HS) foi utilizado para solucionar o PET DC, enquanto [10] propôs uma melhoria ao HS para resolver o PET DC em um sistema elétrico de potência desregulado.

No estudo de [11], a meta-heurística PSO foi aplicado para resolver o PET com representação CA, integrando a alocação de fontes de potência reativa em um sistema elétrico de potência desregulado. O principal objetivo do problema de planejamento proposto era minimizar os custos de investimento e maximizar o benefício social (*social welfare*).

Em [12], foi proposta uma nova formulação para o PET CA, que permite a redução de carga (*load shedding*), tradicionalmente abordada no PET com modelo de rede DC, além da expansão de compensação shunt. Para resolver essa formulação, os autores apresentaram uma versão aprimorada da meta-heurística PSO. Em [13], a meta-heurística *cuckoo search* (CS) foi empregada para resolver o PET considerando o modelo de rede CA.

Por fim, a pesquisa de [14] apresentou uma nova formulação e um método de solução para o PET CA, considerando incertezas na demanda e na geração de fontes não despacháveis. Para abordar esse problema, os autores utilizaram uma técnica *simheuristic* que combina a Simulação de Monte Carlo com a Otimização por *ant colony optimization* (ACO).

Muitas meta-heurísticas foram originalmente projetadas para resolver problemas com variáveis contínuas, operando no espaço de soluções reais. Isso inclui técnicas como *particle swarm optimization* (PSO) [15], *harmony search* (HS) [16], *artificial bee colony* (ABC) [17], *bat algorithm* (BA) [18], *cuckoo search* [19] (CS), *gray wolf optimizer* (GWO) [20], *whale optimization algorithm* (WOA), *arithmetic optimization algorithm* (AOA) [21], entre outras. No entanto, quando aplicadas ao PET, essas meta-heurísticas precisam ser adaptadas para lidar com variáveis discretas ou inteiras, uma vez que as decisões de expansão envolvem escolhas binárias (construir ou não construir uma linha) ou inteiras (quantidade de infraestrutura a ser instalada).

Para adaptar essas meta-heurísticas ao tratamento de problemas discretos, como o PET, uma abordagem comum é a utilização de funções de transferência. Essas funções têm o papel crucial de mapear as soluções do espaço contínuo para um espaço binário, essencial para a binarização das meta-heurísticas [22]. A função de transferência normaliza os valores obtidos das variáveis contínuas, mapeando-os para um intervalo de [0, 1]. Em seguida, uma decisão é tomada com base na comparação desse valor com um número aleatório dentro do mesmo intervalo, determinando se a variável correspondente deve assumir o valor "0" ou "1".

A. Contribuições

Seguindo a linha de pesquisa apresentada anteriormente, este trabalho visa estudar o desempenho de funções de transferência aplicadas a diferentes meta-heurísticas na solução do problema de planejamento da expansão da transmissão com representação de rede CA (PET CA). As meta-heurísticas *gray wolf optimizer*, *whale optimization algorithm* e *sine cosine algorithm* serão investigadas em conjunto com as funções de transferência tangente hiperbólica, arco tangente e sigmoidal modificada, com o objetivo de avaliar a eficácia dessas combinações na obtenção de soluções ótimas para o PET CA.

II. FORMULAÇÃO DO PROBLEMA

Neste trabalho, o problema do planejamento da expansão da transmissão de energia elétrica considerando o modelo de rede CA (PET CA) é desacoplado em dois problemas: o problema de investimento e o problema de operação.

A. Problema de Investimento

A formulação matemática para o problema de investimento é representada pelas equações (1) e (22).

$$\text{minimizar} \quad C^{\text{inv}} = \sum_{(ij) \in \Omega} c_{ij} n_{ij} \quad (1)$$

sujeita a:

$$0 \leq n_{ij} \leq n_{ij}^{\max}; \quad n_{ij} \text{ inteiro} \quad (2)$$

onde C^{inv} é o custo total de investimento; c_{ij} é o custo da adição de um circuito entre as barras i e j ; n_{ij} é o número de circuitos adicionados entre as barras i e j ; n_{ij}^{\max} é o número máximo de circuitos permitidos entre as barras i e j ; Ω é o conjunto de todos os ramos onde é possível adicionar novas linhas de transmissão.

A função objetivo do problema de investimento (1) representa a minimização do custo com investimento. A restrição (2) limita a quantidade de circuitos que podem ser adicionados em cada um dos ramos candidatos à expansão.

B. Problema de Operação

A formulação matemática para o problema de operação corresponde à formulação do problema de fluxo de potência ótimo CA [12, 23]. É representada pelas equações (3) a (12).

$$\text{minimizar} \quad C^{\text{op}} = \sum_{k \in \Phi} \alpha_1 p_k + \alpha_2 |q_k| \quad (3)$$

sujeita a:

$$\mathbf{P}(\mathbf{V}, \theta, \mathbf{n}) - \mathbf{P}_g - \mathbf{p} + \mathbf{P}_d = 0 \quad (4)$$

$$\mathbf{Q}(\mathbf{V}, \theta, \mathbf{n}) - \mathbf{Q}_g - \mathbf{q} + \mathbf{Q}_d = 0 \quad (5)$$

$$\mathbf{P}_g^{\min} \leq \mathbf{P}_g \leq \mathbf{P}_g^{\max} \quad (6)$$

$$Q_g^{\min} \leq Q_g \leq Q_g^{\max} \quad (7)$$

$$p_k^{\min} \leq p_k \leq p_k^{\max} \quad (8)$$

$$q_k^{\min} \leq q_k \leq q_k^{\max} \quad (9)$$

$$\mathbf{V}^{min} \leq \mathbf{V} \leq \mathbf{V}^{max} \quad (10)$$

$$\mathbf{S}^{from} \leq \mathbf{S}^{max} \quad (11)$$

$$\mathbf{S}^{to} \leq \mathbf{S}^{max} \quad (12)$$

onde p_k é a redução de carga ativa (*active load shedding*) na barra de carga k ; α_1 é o custo associado à redução de carga ativa; q_k é a redução de carga reativa; α_2 é o custo associado à redução de carga reativa; p_k^{\max} e q_k^{\max} são os vetores de limites máximos de redução de carga ativa e reativa, respectivamente; p_k^{\min} e q_k^{\min} são os vetores de limites mínimos de redução de carga ativa e reativa na barra de carga k , respectivamente; θ é o vetor de ângulos de tensão nodais; \mathbf{P}_g e \mathbf{Q}_g são os vetores de geração de potência ativa e reativa, respectivamente; \mathbf{P}_d e \mathbf{Q}_d são os vetores de demanda de potência ativa e reativa, respectivamente; \mathbf{P}_g^{\max} e \mathbf{Q}_g^{\max} são os vetores de limites máximos de geração de potência ativa e reativa, respectivamente; \mathbf{P}_g^{\min} e \mathbf{Q}_g^{\min} são os vetores de limites mínimos de geração de potência ativa e reativa, respectivamente; \mathbf{V}^{max} e \mathbf{V}^{min} são os vetores de limites máximos e mínimos de magnitudes de tensão, respectivamente, adotados neste subproblema como 105% e 95% do valor nominal; \mathbf{S}^{from} e \mathbf{S}^{to} são os vetores de fluxo de potência aparente (MVA) nos ramos em ambos os terminais; \mathbf{S}^{max} é o vetor de limites máximos de fluxo de potência aparente; Φ é o conjunto que inclui todas as barras de carga (PQ) do sistema.

A função objetivo (3) representa o custo total da operação do sistema após sua expansão. Esse custo de operação engloba os gastos associados à redução de carga ativa e redução de carga reativa. A redução é representada por geradores fictícios alocados em todas as barras de carga (PQ) do sistema. Os custos associados à redução de carga ativa e reativa possuem valores substancialmente elevados, ao passo que os custos de geração dos geradores existentes no sistema não são considerados nesse contexto. A formulação adota o valor absoluto da redução de carga reativa, desta forma, a geração fictícia de potência reativa capacitiva e indutiva são igualmente consideradas.

As equações (6) e (7) estabelecem os limites para a geração de potência ativa e reativa dos geradores existentes, respectivamente. Os limites para a geração de potência ativa e reativa dos geradores fictícios são representados por (8) e (9). A equação (10) determina as restrições sobre os limites de magnitudes de tensão em cada barra do sistema. Os limites de fluxo de potência ativa e reativa nas linhas de transmissão são expressos nas equações (11) e (12).

As equações (4) e (5) representam as equações de injetões de potência ativa e de potência reativa na barra i . Os elementos dos vetores $\mathbf{P}(\mathbf{V}, \theta, \mathbf{n})$ e $\mathbf{Q}(\mathbf{V}, \theta, \mathbf{n})$ são calculados por (13) e (14), respectivamente.

$$P_i(\mathbf{V}, \theta, \mathbf{n}) = V_i \sum_{j=1}^{\Phi} V_j [G_{ij}(n) \cos \theta_{ij} + B_{ij}(n) \sin \theta_{ij}] \quad (13)$$

$$Q_i(\mathbf{V}, \theta, \mathbf{n}) = V_i \sum_{j=1}^{\Phi} V_j [G_{ij}(n) \sin \theta_{ij} - B_{ij}(n) \cos \theta_{ij}] \quad (14)$$

onde $i, j \in \Phi$ representam barras e Φ é o conjunto de todas as barras; ij representa o circuito entre as barras i e j ; θ_{ij} representa a diferença no ângulo de fase entre as barras i e j . Os elementos da matriz de admitância (\mathbf{G} e \mathbf{B}) são obtidos conforme (15) e (16), respectivamente.

$$\mathbf{G} = \begin{cases} G_{ij}(n) = -(n_{ij}g_{ij} + n_{ij}^0g_{ij}^0) \\ G_{ii}(n) = \sum_{j \in \Phi_i} (n_{ij}g_{ij} + n_{ij}^0g_{ij}^0) \end{cases} \quad (15)$$

$$\mathbf{B} = \begin{cases} B_{ij}(n) = -(n_{ij}b_{ij} + n_{ij}^0b_{ij}^0) \\ B_{ii}(n) = b_i^{sh} + \sum_{j \in \Phi_i} [n_{ij} (b_{ij} + b_{ij}^{sh}) + n_{ij}^0 (b_{ij}^0 + (b_{ij}^{sh})^0)] \end{cases} \quad (16)$$

onde Φ_i representa o conjunto de todas as barras diretamente conectadas à barra i ; g_{ij} , b_{ij} e b_{ij}^{sh} são a condutância série, susceptância série e susceptância shunt da linha de transmissão ou transformador ij (se ij for um transformador, $b_{ij}^{sh} = 0$), respectivamente; b_i^{sh} é a susceptância shunt da barra i . Note que, em (15) e (16), considera-se a possibilidade de uma nova linha de transmissão ou transformador ser adicionado em paralelo a um equipamento existente n_{ij}^0 (no caso base) entre as barras i e j , mesmo que os parâmetros do circuito equivalente possam diferir. Deve ser observado que os taps fora do nominal dos transformadores não são considerados e, nesse caso, tanto as linhas de transmissão quanto os transformadores têm circuitos equivalentes semelhantes.

O fluxo de potência aparente (MVA) passante nos circuitos do sistema após a expansão é calculado conforme (17) - (22).

$$S_{ij}^{from} = \sqrt{(P_{ij}^{from})^2 + (Q_{ij}^{from})^2} \quad (17)$$

$$P_{ij}^{from} = V_i^2 g_{ij} - V_i V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (18)$$

$$Q_{ij}^{from} = -V_i^2 (b_{ij} + b_{ij}^{sh}) - V_i V_j (b_{ij} \sin \theta_{ij} - g_{ij} \cos \theta_{ij}) \quad (19)$$

$$S_{ij}^{to} = \sqrt{(P_{ij}^{to})^2 + (Q_{ij}^{to})^2} \quad (20)$$

$$P_{ij}^{to} = V_j^2 g_{ij} - V_i V_j (g_{ij} \cos \theta_{ij} - b_{ij} \sin \theta_{ij}) \quad (21)$$

$$Q_{ij}^{to} = -V_j^2 (b_{ij} + b_{ij}^{sh}) + V_i V_j (b_{ij} \sin \theta_{ij} + g_{ij} \cos \theta_{ij}) \quad (22)$$

onde S_{ij}^{from} e S_{ij}^{to} representam, respectivamente, o fluxo de potência (MVA) que flui no sentido da barra i para a barra j e o fluxo de potência (MVA) no sentido da barra j para a barra i . De maneira semelhante, P_{ij}^{from} e Q_{ij}^{from} são, respectivamente, o fluxo de potência ativa (MW) e o fluxo de potência reativa (MVAr) que fluem no sentido da barra i para a barra j , enquanto P_{ij}^{to} e Q_{ij}^{to} são, respectivamente, o fluxo de potência ativa e o fluxo de potência reativa que fluem no sentido da barra j para a barra i .

III. MÉTODO DE SOLUÇÃO

O método utilizado para solucionar o PET CA combina técnicas meta-heurísticas com o método de pontos interiores. As meta-heurísticas são aplicadas ao problema de investimento, onde cada indivíduo da população é representado por um vetor binário (0 ou 1). O valor 1 indica que a linha candidata à expansão será construída, enquanto 0 indica que não será. Para avaliar a função aptidão de cada indivíduo, resolva-se o problema de fluxo ótimo de potência CA considerando a expansão indicada.

Três meta-heurísticas são utilizadas nesse trabalho

- *gray wolf optimizer* (GWO), meta-heurística inspirado na hierarquia social e na caça dos lobos cinzentos [20].
- *whale optimization algorithm* (WOA), meta-heurística baseada no comportamento de caça das baleias jubarte [24].
- *sine cosine algorithm* (SCA), meta-heurística que faz uso das funções trigonométricas para orientar a busca por soluções ótimas [25].

Essas meta-heurísticas foram escolhidas por serem simples, de alta flexibilidade para modificações e eficiência na exploração do espaço de busca, conforme apontando nas referências [26], [27] e [28] respectivamente. Além disso, ambas foram originalmente propostas para solução de problemas com variáveis continuais.

Para adaptá-las às variáveis de investimento este trabalho utiliza da estratégia de Função de Transferência e Binarização. A primeira etapa dessa estratégia consiste em aplicar uma função de transferência em cada valor contínuo do indivíduo. A função de transferência é um operador simples, usado para mapear valores contínuos para o intervalo [0, 1]. A Binarização, segunda etapa desse processo, transforma o valor obtido com a aplicação da função de transferência em um valor discreto 0 ou 1 através da aplicação de uma regra [22].

As funções de transferências utilizadas neste trabalho são tangente hiperbólica, arco tangente e sigmoide modificada, conforme as equações (23), (24) e 25, respectivamente.

$$T(\bar{X}(i+1)) = \tanh(\bar{X}(i+1)) \quad (23)$$

$$T(\bar{X}(i+1)) = \arctan(\bar{X}(i+1)) \quad (24)$$

$$T(\bar{X}(i+1)) = \frac{1}{1 + e^{-10[\bar{X}(i+1)-0.5]}} \quad (25)$$

onde \bar{X} é um indivíduo com valores contínuos na iteração $i+1$.

A regra para binarização adotada é apresentada em (26). Essa regra é aplicada em cada variável j do indivíduo (vetor solução).

$$\overline{X^{bin}}(i+1) = \begin{cases} 1 & \text{se } rand \leq T(\bar{X}(i+1)), \\ 0 & \text{caso contrário.} \end{cases} \quad (26)$$

onde $\overline{X^{bin}}$ representa o indivíduo com valores discretos na iteração $i+1$, e $rand$ corresponde a um valor aleatório uniformemente distribuído no intervalo [0, 1].

IV. ESTUDOS DE CASOS

A metodologia proposta foi aplicada ao sistema IEEE de 24 barras, conforme descrito em [29]. Este sistema inclui 24 barras e 41 ramos candidatos à expansão, sendo que 34 ramos já existem na topologia original e 7 são novos. Considerase que todas as linhas em um mesmo ramo candidato são idênticas, com um limite máximo de três linhas por ramo. As linhas de 230 kV têm um custo de investimento de 120.000,00 \$/km, enquanto as de 132 kV têm um custo de 70.000,00 \$/km.

Três meta-heurísticas foram utilizadas neste trabalho: *gray wolf optimizer* (GWO), *whale optimization algorithm* (WOA) e *sine cosine algorithm* (SCA).

As meta-heurísticas GWO, WOA e SCA foram avaliadas utilizando as funções de transferência tangente hiperbólica, arco tangente e sigmoide modificada. Foram feitas 20 simulações para cada combinação de meta-heurística e função de transferência. O número de iterações e tamanho da população adotados para todas as meta-heurísticas foi de 100 e 50, respectivamente. O critério de parada máximo adotado é o número máximo de iterações. Foi adotado a mesma população inicial para todas as simulações. Esse população inicial foi obtida de maneira aleatória.

Todas as simulações foram executadas em um processador Core i7 de 3.4 GHz, utilizando o software MATLAB®. O problema de fluxo de potência ótimo em CA foi resolvido com a ferramenta de código aberto MATPOWER [30], amplamente reconhecida para análise de sistemas de potência. O solucionador adotado foi o Matpower Interior Point Solver (MIPS) [31].

A Tabela I apresenta os melhores planos de expansão obtidos por cada meta-heurística em combinação com as diferentes funções de transferência adotadas. Para a meta-heurística GWO, o melhor plano de expansão foi alcançado com um custo de investimento de 341 milhões de dólares,

utilizando as funções de transferência tangente hiperbólica e sigmoide modificada. Este plano sugere a construção de uma linha de transmissão entre as barras 2-4, 4-24, 9-11, 11-13, e duas linhas de transmissão entre as barras 1-3 e 7-8.

No caso da meta-heurística WOA, o plano de expansão mais eficaz foi obtido com a função de transferência sigmoide modificada, resultando em um custo de 584 milhões de dólares. Este plano de expansão recomenda a construção de uma linha entre as barras 1-2, 2-4, 2-8, 3-24, 7-8, 9-11, 10-12, 11-13, 13-14, 14-16, 15-16, 17-22, 21-22, e duas linhas entre as barras 1-3.

Por fim, a meta-heurística SCA também apresentou um custo de investimento de 341 milhões de dólares como melhor solução, obtido com a função de transferência sigmoide modificada. Este plano de expansão é idêntico ao encontrado pela GWO com as funções de transferência sigmoide modificada e tangente hiperbólica.

Todos os melhores planos de expansão presentes na tabela I permitem uma operação do sistema sem a necessidade de redução da demanda de potência ativa e da demanda de potência reativa.

A partir desses resultados, observa-se que a função de transferência sigmoide modificada demonstrou-se eficaz na obtenção dos melhores planos de expansão para todas as meta-heurísticas testadas, destacando-se como uma ferramenta competitiva no processo de binarização de meta-heurísticas originalmente desenvolvidas para variáveis contínuas.

A tabela II apresentada análise estatística os resultados obtidos para diferentes combinações de meta-heurísticas (GWO, WOA, SCA) e funções de transferência (tangente hiperbólica, arco tangente, sigmoide modificada) aplicadas ao problema de planejamento da expansão da transmissão com representação de rede CA. Os indicadores analisados incluem o melhor e o pior valor de fitness encontrado ao longo de 20 simulações, a média, a mediana, o desvio padrão e a variância, todos expressos em milhões de dólares (M\$).

A meta-heurística GWO apresentou os melhores resultados de *fitness* com a função de transferência sigmoide modificada, atingindo um valor mínimo de 341,00 M\$. Esta combinação também proporcionou a menor variância (92,68 M\$²) e desvio padrão (9,63 M\$), indicando uma alta consistência nos resultados. No entanto, a média de 351,30 M\$ e a mediana de 348,00 M\$ sugerem que, embora a solução seja estável, o desempenho geral está ligeiramente abaixo das outras combinações da GWO. Por outro lado, a função de transferência arco tangente obteve a maior variância (4.572,09 M\$²) e desvio padrão (67,62 M\$), sugerindo uma maior dispersão nos resultados. Isso reflete um comportamento menos previsível da meta-heurística quando combinada com essa função de transferência.

A meta-heurística WOA, ao ser combinada com a função de transferência tangente hiperbólica, apresentou o pior valor de *fitness* de 1.481,00 M\$ e a maior média de 1.141,80 M\$, indicando uma tendência para soluções menos eficazes. A elevada variância (31.280,15 M\$²) e o desvio padrão (176,86 M\$) reforçam a inconsistência dessa combinação. Por outro

lado, a função de transferência sigmoide modificada trouxe uma melhora significativa, com uma média de 1.093,30 M\$ e uma mediana de 1.151,00 M\$, mas ainda com um desvio padrão elevado (200,70 M\$) e variância de 40.282,03 MM\$². Este comportamento sugere que, embora a sigmoide modificada possa potencialmente levar a boas soluções, a dispersão dos resultados é ampla, o que pode afetar a confiabilidade da WOA.

A meta-heurística SCA, quando associada à função de transferência sigmoide modificada, atingiu o melhor valor de *fitness* (341,00 M\$), além de apresentar a menor média (382,00 M\$), mediana (372,50 M\$), desvio padrão (32,8 M\$) e variância (1.079,3 MM\$²). Pode-se dizer que a função de transferência sigmoide modificada é mais competitiva que as demais funções de transferências testadas quando aplicada ao SCA na solução do PET AC.

A figura 1 apresenta as curvas de convergência da melhor solução encontrada para cada meta-heurística em relação às funções de transferência analisadas. Observa-se que a meta-heurística WOA demonstrou uma estagnação prematura em todas as funções de transferência. Isso sugere que a estratégia de função de transferência e binarização pode não ser trivial para o WOA. Em contraste, para o GWO e o SCA, é possível notar uma estagnação mais prolongada.

V. CONCLUSÕES

Este estudo avaliou o desempenho de diferentes funções de transferência aplicadas às meta-heurísticas *gray wolf optimizer* (GWO), *whale optimization algorithm* (WOA) e *sine cosine algorithm* (SCA) para solucionar problema de planejamento da expansão da transmissão de energia elétrica com representação de rede CA (PET CA). A função de transferência sigmoide modificada demonstrou ser a mais eficaz, resultando em planos de expansão com menor custo de investimento e maior consistência, tanto para a meta-heurística GWO quanto para a SCA. Em particular, a meta-heurística GWO e a SCA alcançaram o custo mais baixo de 341 milhões de dólares ao usar a função de transferência sigmoide modificada. Por outro lado, a meta-heurística WOA, apesar de também ter apresentado bons resultados com a função sigmoide modificada, mostrou uma maior variabilidade nos resultados e um custo mais elevado em comparação com GWO e SCA. A análise estatística corroborou que a função sigmoide modificada é uma ferramenta competitiva para a binarização de meta-heurísticas, evidenciando sua eficácia na obtenção de soluções ótimas para o PET CA.

AGRADECIMENTOS

Os autores agradecem às agências brasileiras de pesquisa: CAPES, CNPq, FAPEMIG e INERGE por apoiarem esta pesquisa.

REFERENCES

- [1] Nnachi Gideon Ude, Yskandar Hamam, and Coneth Richards. A comprehensive state-of-the-art survey on the

TABLE I
 MELHOR PLANO DE EXPANSÃO ENCONTRADO POR CADA META-HEURÍSTICA

Meta-heurística	Função de transferência	Melhor plano de expansão	Custo com investimento (M\$)
GWO	tangente hiperbólica	1-3 (2), 2-4, 3-24, 7-8 (2), 9-11, 11-13	341,00
GWO	arco tangente	1-3, 2-4, 3-24, 7-8 (2), 9-11, 11-13, 15-24	358,00
GWO	sigmoide modificada	1-3 (2), 2-4, 4-24, 7-8 (2), 9-11, 11-13	341,00
WOA	tangente hiperbólica	1-3, 2-4, 2-8, 3-9, 3-24, 6-10, 7-8, 9-12, 11-13, 12-13, 12-23, 15-21, 17-17, 19-23, 21-22	904,00
WOA	arco tangente	1-3 (2), 2-4, 2-8, 3-24, 5-10, 6-7, 7-8, 9-11, 10-12, 11-13, 13-14, 14-16, 15-16, 17-22, 21-22	904,00
WOA	sigmoide modificada	1-2, 1-3 (2), 2-4, 2-8, 3-24, 7-8, 10-11, 11-14 (2), 15-24	584,00
SCA	tangente hiperbólica	1-3, 2-4, 3-24, 6-10, 7-8, 9-12, 11-13, 12-13, 15-24, 16-17	460,00
SCA	arco tangente	1-3, 1-8, 2-4, 3-24, 7-8 (2), 9-11, 11-13, 15-24	393,00
SCA	sigmoide modificada	1-3 (2), 2-4, 4-24, 7-8 (2), 9-11, 11-13	341,00

TABLE II
 ANÁLISE ESTATÍSTICA

Meta-heurística	Função de transferência	Melhor valor fitness (M\$)	Pior valor fitness (M\$)	Média	Mediana	Desvio padrão	Variância
GWO	tangente hiperbólica	341,00	478,00	419,50	427,50	42,49	1.805,62
GWO	arco tangente	358,00	594,00	431,10	433,50	67,62	4.572,09
GWO	sigmoide modificada	341,00	368,00	351,30	348,00	9,63	92,68
WOA	tangente hiperbólica	904,00	1.481,00	1.141,80	1.118,00	176,86	31.280,15
WOA	arco tangente	904,00	1.338,00	1.072,40	1.056,50	143,61	20.622,51
WOA	sigmoide modificada	584,00	1.300,00	1.093,30	1.151,00	200,70	40.282,03
SCA	tangente hiperbólica	460,00	856,00	635,30	598,00	159,41	25.412,66
SCA	arco tangente	393,00	1.016,00	597,40	599,00	181,86	33.071,58
SCA	sigmoide modificada	341,00	438,00	382,00	372,50	32,85	1.079,33

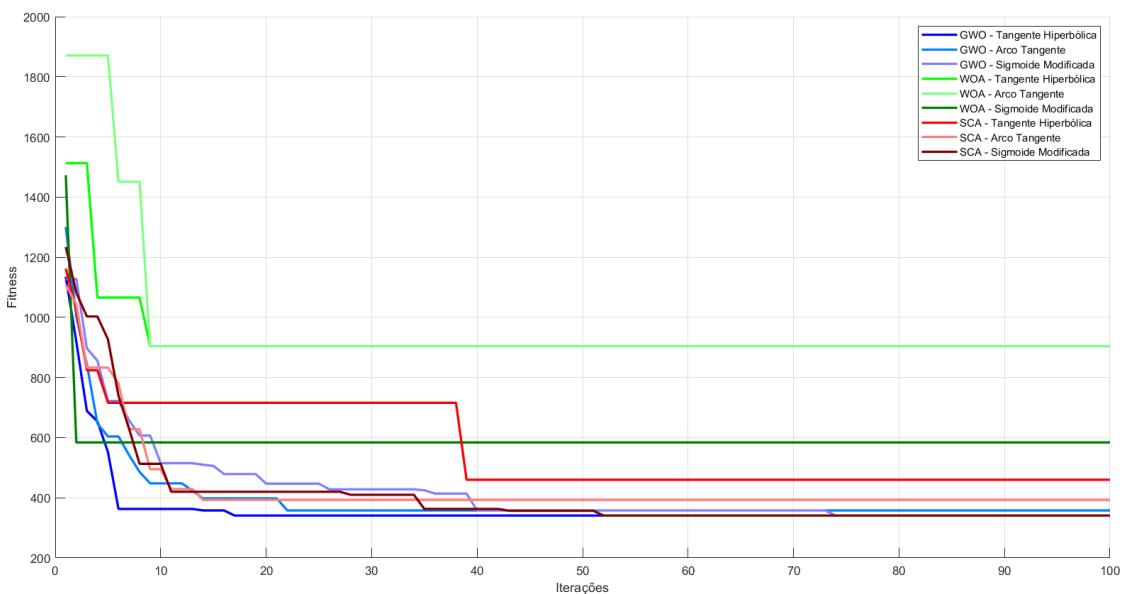


Fig. 1. Curvas de convergência.

- transmission network expansion planning optimization algorithms. *IEEE Access*, PP:1–1, 08 2019.
- [2] Meisam Mahdavi, Carlos Sabilon, Majid Ajalli, and Rubén Romero. Transmission expansion planning: Literature review and classification. *IEEE Systems Journal*, PP:1–12, 10 2018.
- [3] RA Gallego, A Monticelli, and R Romero. Transmision system expansion planning by an extended genetic algorithm. *IEE Proceedings-Generation, Transmission and Distribution*, 145(3):329–335, 1998.
- [4] Edson Luiz Da Silva, Hugo Alejandro Gil, and Jorge Mauricio Areiza. Transmission network expansion planning under an improved genetic algorithm. *IEEE Transactions on Power Systems*, 15(3):1168–1174, 2000.
- [5] I de J Silva, Marcos J Rider, Rubén Romero, and Carlos AF Murari. Transmission network expansion planning considering uncertainty in demand. *IEEE transactions on Power Systems*, 21(4):1565–1573, 2006.
- [6] Phillippe Vilaça Gomes and João Tomé Saraiva. Static transmission expansion planning using heuristic and metaheuristic techniques. In *2015 IEEE Eindhoven PowerTech*, pages 1–6. IEEE, 2015.
- [7] EJ De Oliveira, CA Moraes, LW Oliveira, LM Honório, and RPB Poubel. Efficient hybrid algorithm for transmission expansion planning. *Electrical Engineering*, 100:2765–2777, 2018.
- [8] Paula Vasconcelos Pengo, Gustavo Rebello, Edimar Jose de Oliveira, and Ivo Chaves da Silva Junior. Transmission line exclusion algorithm to solve the expansion planning problem. In *2019 IEEE Milan PowerTech*, pages 1–6. IEEE, 2019.
- [9] A Verma, BK Panigrahi, and PR Bijwe. Harmony search algorithm for transmission network expansion planning. *IET generation, transmission & distribution*, 4(6):663–673, 2010.
- [10] Abdollah Rastgou and Jamal Moshtagh. Improved harmony search algorithm for transmission expansion planning with adequacy-security considerations in the deregulated power system. *International Journal of Electrical Power & Energy Systems*, 60:153–164, 2014.
- [11] Rahmat-Allah Hooshmand, Reza Hemmati, and Moein Parastegari. Combination of ac transmission expansion planning and reactive power planning in the restructured power system. *Energy Conversion and Management*, 55:26–35, 2012.
- [12] Santiago P Torres and Carlos A Castro. Expansion planning for smart transmission grids using ac model and shunt compensation. *IET Generation, Transmission & Distribution*, 8(5):966–975, 2014.
- [13] K Veeresham, K Vaisakh, and M Veerakumari. Cuckoo search algorithm for optimal transmission expansion planning with various load models and ffc. *Energy Procedia*, 117:826–834, 2017.
- [14] Richard M Sanchez, Luis R Villacres, Santiago P Torres, and Carlos A Castro. Ac transmission expansion planning considering uncertainty. In *2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)*, pages 1–5. IEEE, 2019.
- [15] James Kennedy and Russell Eberhart. Particle swarm optimization. In *Proceedings of ICNN'95-international conference on neural networks*, volume 4, pages 1942–1948. ieee, 1995.
- [16] Zong Woo Geem, Joong Hoon Kim, and Gobichettipalayam Vasudevan Loganathan. A new heuristic optimization algorithm: harmony search. *simulation*, 76(2):60–68, 2001.
- [17] Dervis Karaboga and Bahriye Basturk. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (abc) algorithm. *Journal of global optimization*, 39:459–471, 2007.
- [18] X Yang. S.: A new metaheuristic bat-insspired algorithm. nature inspired cooperative strategies for optimization. *Studies in Computational Intelligence (Springer)*. pp:65–74, 2010.
- [19] Xin-She Yang and Suash Deb. Cuckoo search via lévy flights. In *2009 World congress on nature & biologically inspired computing (NaBIC)*, pages 210–214. Ieee, 2009.
- [20] SMSM Mirjalili, Seyed Mohammad Mirjalili, and Andrew Lewis. Grey wolf optimizer adv eng softw 69: 46–61. ed, 2014.
- [21] Laith Abualigah, Ali Diabat, Seyedali Mirjalili, Mohamed Abd Elaziz, and Amir H Gandomi. The arithmetic optimization algorithm. *Computer methods in applied mechanics and engineering*, 376:113609, 2021.
- [22] Jeng-Shyang Pan, Pei Hu, Václav Snášel, and Shu-Chuan Chu. A survey on binary metaheuristic algorithms and their engineering applications. *Artificial Intelligence Review*, 56(7):6101–6167, 2023.
- [23] Zongjie Wang, Abdollah Younesi, M Vivienne Liu, Ge Claire Guo, and C Lindsay Anderson. Ac optimal power flow in power systems with renewable energy integration: A review of formulations and case studies. *IEEE Access*, 2023.
- [24] Seyedali Mirjalili and Andrew Lewis. The whale optimization algorithm. *Advances in engineering software*, 95:51–67, 2016.
- [25] Seyedali Mirjalili. Sca: a sine cosine algorithm for solving optimization problems. *Knowledge-based systems*, 96:120–133, 2016.
- [26] Hossam Faris, Ibrahim Aljarah, Mohammed Azmi Al-Betar, and Seyedali Mirjalili. Grey wolf optimizer: a review of recent variants and applications. *Neural computing and applications*, 30:413–435, 2018.
- [27] Nadim Rana, Muhammad Shafie Abd Latiff, Shafi'i Muhammad Abdulhamid, and Haruna Chiroma. Whale optimization algorithm: a systematic review of contemporary applications, modifications and developments. *Neural Computing and Applications*, 32:16245–16277, 2020.
- [28] Asma Benmessaoud Gabis, Yassine Meraïhi, Seyedali Mirjalili, and Amar Ramdane-Cherif. A comprehensive survey of sine cosine algorithm: variants and applica-

- tions. *Artificial Intelligence Review*, 54(7):5469–5540, 2021.
- [29] MJ Rider, AV Garcia, and R Romero. Power system transmission network expansion planning using ac model. *IET Generation, Transmission & Distribution*, 1(5):731–742, 2007.
- [30] Ray Daniel Zimmerman, Carlos Edmundo Murillo-Sánchez, and Robert John Thomas. Matpower: Steady-state operations, planning, and analysis tools for power systems research and education. *IEEE Transactions on power systems*, 26(1):12–19, 2010.
- [31] Hongye Wang, Carlos E Murillo-Sánchez, Ray D Zimmerman, and Robert J Thomas. On computational issues of market-based optimal power flow. *IEEE Transactions on power Systems*, 22(3):1185–1193, 2007.