

Otimização via Hiena-Malhada aplicado ao Planejamento da Expansão da Transmissão Considerando Contingência e Geração de Energia Eólica^{*}

Lucas S. Nepomuceno^{*} Arthur N. de Paula^{*}
Edimar J. de Oliveira^{*}

^{*} Faculdade de Engenharia Elétrica, Universidade de Juiz de Fora, MG, (e-mail: lucas.nepomuceno@engenharia.ufjf.br; arthur.paula@engenharia.ufjf.br; edimar.joliveira@engenharia.ufjf.br)

Abstract:

This work presents an adaptation in the Spotted Hyena Optimize (SHO) metaheuristic to be applied to the transmission expansion planning of the electric energy (PET). The active transmission losses as well as the N-1 deterministic reliability criterion and the uncertainties of wind generation are taken into account in the modeling of the transmission system. The equivalent of Southern Brazil system is used to check the effectiveness of the proposed approach. The results show that the SHO is efficient to solve the PET problem.

Resumo: Este trabalho apresenta uma adaptação na meta-heurística *Spotted Hyena Optimizer* (SHO) para aplicação ao problema do planejamento da expansão da transmissão de energia elétrica (PET). As perdas de potência ativa na transmissão, o critério de segurança N-1 e as incertezas na geração de energia eólica são levados em consideração na modelagem do sistema de transmissão. O sistema equivalente a uma aproximação do sistema real encontrado no Sul do Brasil é usado no estudo. Os resultados apontam que o SHO é eficiente para solucionar o problema de PET.

Keywords: Spotted Hyena Optimizer, Transmission Line Expansion Planning, N-1 Reliability Criterion, Renewable Energy, Wind Power Uncertainty

Palavras-chaves: Otimização via Hiena-Malhada, Planejamento de Expansão de Linhas de Transmissão, Critério de Segurança N-1, Energia Renováveis, Incerteza da Energia Eólica

1. INTRODUÇÃO

O planejamento da expansão da transmissão de energia elétrica (PET) consiste em identificar os novos reforços a serem inseridos na rede de transmissão do sistema elétrico de potência para garantir uma adequada interligação entre a geração e demanda com o mínimo investimento considerando aspectos técnicos, ambientais e sociais. A diversificação da matriz energética com a redução do uso de combustíveis fósseis e a integração de fontes renováveis de energia representam novos desafios ao PET (Gomes and Saraiva, 2019), como por exemplo a necessidade de novos mecanismos para que possa ser tratado o comportamento intermitente das energias renováveis em tempos computacionais aceitáveis.

Matematicamente, o PET é um problema de programação não-linear inteiro-misto, com o espaço de busca não-convexo e com alto esforço computacional devido a natureza combinatória explosiva relacionada às alternativas de investimento (Mahdavi et al., 2018). A abordagem a ser

adotada para solucionar o PET depende diretamente da dimensão do sistema de potência e do horizonte de tempo considerado (curto, médio ou longo prazo). As ferramentas baseadas na modelagem de rede não-linear AC são capazes de associar o planejamento de reativos na rede, modelar de forma precisa as perdas e levar em consideração estudos de estabilidade de tensão. Entretanto com o aumento do número de incertezas no problema devido, principalmente, à inserção das fontes de energia renováveis, aumenta o esforço computacional necessário para solucionar o problema. Neste sentido, os modelos linearizados são amplamente aplicados ao problema PET (Mahdavi et al., 2018) e superam consideravelmente a eficiência computacional obtida pelo modelo não-linear, alcançando um bom grau de precisão.

A consideração da confiabilidade determinística N-1 tem como o objetivo garantir que ocorra o total atendimento da carga mesmo para o caso de qualquer contingência simples na rede de transmissão, sem que os demais equipamentos sejam demasiadamente sobrecarregados. Entretanto, quando considerada essa abordagem, o custo computacional cresce exponencialmente (Leite da Silva et al., 2010) com o aumento do número de equipamentos da rede.

^{*} Os autores gostariam de agradecer às agências brasileiras de pesquisa: CAPES, CNPq, FAPEMIG e INERGE por apoiarem esta pesquisa.

As técnicas de solução do problema PET são baseadas em métodos de otimização matemática, técnicas heurísticas e meta-heurísticas (Mahdavi et al., 2018). Destacando-se as meta-heurísticas, os métodos de otimização bio-inspirados mostraram grande potencial para encontrar soluções de alta qualidade com um custo computacional relativamente baixo nas últimas décadas, mesmo para sistemas de grande porte (Gideon Ude et al., 2019). A principal vantagem destas ferramentas consiste na exploração do espaço de busca de maneira eficiente, evitando a estagnação em ótimos locais. Além disso, os algoritmos de otimização bio-inspirados são geralmente simples e fáceis de implementar, sendo possível a modificação de suas estruturas e parâmetros para resolver uma ampla gama de problemas com características matemáticas distintas.

Em (Gomes and Saraiva, 2015), o *Constructive Heuristic Algorithm* foi utilizado para reduzir o conjunto de linhas de transmissão candidatas à expansão, em sequência, a meta-heurística *Particle Swarm Optimization* foi aplicada para obter a solução do PET dado o conjunto reduzido. Similarmente em (Oliveira et al., 2018a), multiplicadores de Lagrange e coeficientes de Benders foram utilizados para a redução do espaço de busca e o PET foi solucionado por uma versão modificada da meta-heurística *Bat Algorithm*. Em (Kuntla, 2015), a meta-heurística *Cuckoo Search Algorithm* foi utilizada para solucionar o TEP com fluxo de potência AC. Em (Pengo et al., 2019), os autores propuseram um método para a obtenção de um espaço de busca reduzido que considera inicialmente todas as linhas candidatas para expansão como já construída, em seguida, verifica-se por meio de solução do fluxo de potência CC, qual corredor possui a menor necessidade de reforço, excluindo-o do planejamento. Após a redução do espaço de busca, uma versão binária modificada da *Gray Wolf Optimizer* foi utilizada na busca de resultados ótimos. Outras aplicações de meta-heurísticas para solucionar o PET são encontradas em (Gideon Ude et al., 2019).

Seguindo esta linha de pesquisa, este trabalho tem como contribuição a adaptação da meta-heurística *Spotted Hyena Optimizer* (SHO), introduzido em (Dhiman and Kumar, 2017), para tratamento de variável inteira. Desta forma, será possível avaliar a eficiência da SHO para solucionar o PET. As análises são realizadas no sistema elétrico equivalente do sul do Brasil, de 46 barras. As perdas de potência ativa, o critério de segurança N-1 e incertezas na geração de energia eólica serão levados em consideração. O desempenho do SHO será comparado com outras meta-heurísticas da literatura.

2. FORMULAÇÃO MATEMÁTICA DO PET

A função objetivo e as restrições do PET são apresentadas em (1) - (11):

$$\min \sum_{ikm \in C} ce_{ikm} EP_{ikm} + \sum_{k \in B} \sum_{w \in W} \sum_{s \in S} (rd_{kws} + rw_{kws}) \quad (1)$$

s.a.

$$p_{ikmws}^E = -b_{ikm}\theta_{kms} + \frac{1}{2}g_{ikm}\theta_{kms}^2, \quad (2)$$

$$\forall (k, m) \in B, s \in S, w \in W$$

$$p_{ikmws}^C = EP_{ikm}(-b_{ikm}\theta_{kms} + \frac{1}{2}g_{ikm}\theta_{kms}^2), \quad (3)$$

$$\forall (k, m) \in B, s \in S, w \in W$$

$$P_{kws} = \sum_{km \in \Omega_i^E} p_{ikmws}^E + \sum_{km \in \Omega_i^C} p_{ikmws}^C, \quad (4)$$

$$\forall (k, m) \in B, s \in S, w \in W$$

$$pg_{kws} - P_{kws} + rd_{kws} = d_k - pw_{kw}, \quad (5)$$

$$\forall k \in B, s \in S, w \in W$$

$$|p_{ikmws}^E| \leq \bar{p}_{ikm}^E, \quad \forall (k, m) \in E \quad (6)$$

$$|p_{ikmws}^C| \leq \bar{p}_{ikm}^C, \quad \forall (k, m) \in C \quad (7)$$

$$0 \leq pg_{kws} \leq \bar{pg}_k, \quad \forall k \in B, s \in S, w \in W \quad (8)$$

$$0 \leq rd_{kws} \leq d_k, \quad \forall k \in B, s \in S, w \in W \quad (9)$$

$$0 \leq rw_{kws} \leq pw_{kw}, \quad \forall k \in B, s \in S, w \in W \quad (10)$$

$$EP_{km} \in [0, 1], \quad \forall (k, m) \in B, s \in S, w \in W \quad (11)$$

onde: B , C , E , S e W representam respectivamente o conjunto de barras do sistema, os reforços candidatas a expansão, as linhas existentes, os estados operacionais e os cenários de geração eólica; Ω_k^C e Ω_k^E representam respectivamente o conjunto de linhas candidatas a expansão conectadas na barra k e o conjunto de linhas existentes conectadas na barra k ; a potência ativa gerada (MW) na barra k , cenário w e estado s é expressa por pg_{kws} ; rd_{kws} e rw_{kws} representam respectivamente os cortes de carga (MW) e de vento (MW) na barra k , cenário w e estado s , sendo que corte de vento se refere ao termo inglês *wind curtailment* que concerne à situação em que a produção das usinas eólicas é reduzida a um nível abaixo da sua capacidade corrente de geração, devido a alguma situação que impede a absorção dessa energia pelo sistema, seja esta uma baixa demanda ou uma falta na capacidade de transmissão (Park and Baldick, 2013), (Ugranli and Karatepe, 2015); a diferença angular (radianos) entre as barras k e m no cenário w e estado s é simbolizado por θ_{kms} , o fluxo de potência ativa (MW) na linha existente entre as barras k e m para o cenário w e estado s é expresso como p_{kms}^E , e o fluxo de potência ativa (MW) na linha candidata entre as barras k e m para o cenário w e estado s é representada como p_{kms}^C ; o fluxo de potência ativa saindo da barra k através das linhas conectadas a ela para o cenário w e estado s é expresso como P_{kws} ; \bar{p}_{km}^C e \bar{p}_{km}^E representam respectivamente o limite de potência ativa (MW) na linha candidata e existente entre as barras k e m ; o custo de investimento da linha candidata i entre as barras k e j (M\$) é simbolizado por ce_{ikm} ; \bar{pg}_k é o limite máximo de

geração de potência ativa (MW) na barra k ; a geração de potência ativa amostrada do parque eólico $n_{ce_{ikm}}$ a barra k e cenário w (MW) é expresso como pw_{kw} ; a demanda de potência ativa na barra k (MW) é simbolizado por d_k ; o custo de investimento da linha candidata i entre as barras k e m (M\$) é representado por ce_{ikm} ; b_{ikm} e g_{ikm} são respectivamente a susceptância e a condutância na linha i entre as barras k e m ; a variável de expansão binária associado a linha candidata i entre as barras k e m é simbolizada por EP_{ikm} .

A função objetivo (1) busca minimizar os custos de investimento e cortes de carga e vento. Os fluxos de potência ativa das linhas existentes e candidatas são avaliados por (2) e (3), respectivamente. O fluxo de potência ativa que flui em direção à barra i , pelas linhas de transmissão que a conectam, é representado em (4). O balanço de potência ativa relacionado à Primeira Lei de Kirchhoff é apresentada em (5). As equações (6) e (7) representam os limites de fluxo de potência ativa nas linhas candidatas e existentes, respectivamente. As restrições de limite de geração de potência ativa dos geradores existentes, corte de carga e eólicos são modelados respectivamente por (8), (9) e (10). A restrição em (11) torna a variável relacionada ao investimento nas linhas de transmissão uma variável binária, assim, se $EP_{ikm} = 1$ há investimento na linha, caso contrário, $EP_{ikm} = 0$.

A estratégia adotada para tratar as variáveis inteiras consiste no desacoplamento do problema original em dois subproblemas: (i) *investimento*, onde se define quais linhas devem ser construídas, neste caso, será usado a meta-heurística da hiena-malhada; e (ii) *operação*, onde é verificado se os investimentos são adequados para que a rede opere sob os cenários considerados. Neste caso, a função objetivo (1) é utilizada como “*fitness function*” para o problema de investimento. É importante destacar que no problema de operação não existe variáveis inteiras já que elas foram decididas pela meta-heurística, ou seja, a restrição (11) é retirada do problema.

3. SPOTTED HYENA OPTIMIZATION (SHO)

O *Spotted Hyena Optimization* (SHO) é uma técnica de otimização bioinspirada baseada em enxame, proposta por (Dhiman and Kumar, 2017), tendo como inspiração o comportamento colaborativo das hienas-malhadas no processo de caça. O SHO se destaca devido a sua estrutura simples, de fácil implementação e de menor número de parâmetros. Em (Dhiman and Kumar, 2017) foi comparado o desempenho do algoritmo recém-desenvolvido com outras meta-heurísticas para resolver problemas restritos e irrestritos de projetos de engenharia, além de funções *benchmark*. Em relação ao processo de intensificação, o SHO obteve o melhor desempenho em 6 das 7 funções unimodais testadas, o que significa que o SHO pode obter uma melhor intensificação que as demais meta-heurísticas comparadas. Para avaliar o potencial de exploração foram utilizadas 16 funções *benchmark* multimodais, onde o SHO se mostrou mais eficiente em 7 dessas funções e ainda obteve bons resultados nas demais funções de teste, demonstrando assim que o SHO possui uma boa capacidade de exploração. No geral, os resultados apresentados demonstram que o SHO é uma meta-heurística extremamente

competitivos em comparação com outras as outras técnicas de otimização bio-inspiradas testadas, sendo elas: *Grey Wolf Algorithm* (GWO), *Particle Swarm Optimization* (PSO), *Moth Flame Optimization Flame* (MFO), *Multi-Verse Optimizer* (MVO), *Sine Cosine Algorithm* (SCA), *Gravitational Search Algorithm* (GSA), *Genetic Algorithm* (GA) e *Harmony Search* (HS).

Em (Dhiman and Kumar, 2018), os autores propuseram a versão multiobjetivo do SHO denominada como *Multi-objective Spotted Hyena Optimizer* (MOSHO). A eficácia do algoritmo desenvolvido é testada com a ajuda de vinte funções de *benchmark*, e o mesmo algoritmo é comparado com as seis outras meta-heurísticas citadas no paragrafo anterior e novamente os resultados revelaram que o desempenho do MOSHO é superior aos demais métodos de otimização bio-inspirados utilizados.

Em (Panda, 2018), o SHO foi utilizado para o treinamento de redes neurais e obteve desempenho superior a meta-heurísticas populares como AG, PSO e GWO.

No presente trabalho, é proposto uma adequação ao SHO para permitir seu uso em problemas com variáveis inteiras, em particular para solução do PET. A seguir são detalhados a técnica para tratar variável inteira e os quatro operadores principais do algoritmo SHO: cercar, caçar, atacar e buscar a presa.

3.1 Cercar a presa

É sabido que as hienas-malhadas podem estar familiarizadas com a localização das presas e cercá-las. Este comportamento é representado na SHO, onde a melhor solução da iteração corrente é considerada ser a presa (ótimo global) já que o espaço de busca não é conhecido *a priori*. Nesta etapa, os agentes de busca atualizam suas posições em relação à posição da presa. O modelo matemático é apresentado em (12) - (16):

$$\vec{D}_h = |\vec{B} \cdot \vec{P}_p(t) - \vec{P}(t)| \quad (12)$$

$$\vec{P}(t+1) = \vec{P}_p(t) - \vec{E} \cdot \vec{D}_h \quad (13)$$

$$\vec{B} = 2 \cdot \vec{r}_1 \quad (14)$$

$$\vec{E} = 2 \vec{h} \cdot \vec{r}_2 - \vec{h} \quad (15)$$

sendo que \vec{P}_p representa o vetor posição da presa, melhor posição encontrada até então; \vec{P} representa o vetor posição do agente de busca; \vec{D}_h é o vetor distância entre a presa e a hiena-malhada; \vec{B} e \vec{E} são vetores coeficientes calculados em (14) e (15); \vec{r}_1 e \vec{r}_2 são vetores aleatórios no intervalo $[0, 1]$.

O vetor \vec{h} sofre um decréscimo linear de 5 até 0 ao longo das iterações, permitindo assim o equilíbrio entre a exploração e intensificação, onde t representa a iteração corrente e t_{max} a iteração máxima.

$$\vec{h} = 5 - \left(t + \frac{5}{t_{max}}\right) \quad (16)$$

3.2 Caçar a presa

Hienas-malhadas geralmente vivem e caçam em grupos. Nesse operador, supõe-se que o melhor agente de busca tenha conhecimento sobre a localização da presa e que os demais agentes de busca formam um grupo no entorno do melhor agente. Matematicamente utilizam das melhores soluções para atualizar suas novas posições. Esse mecanismo é apresentado em (17) - (20):

$$\vec{D}_h = |\vec{B} \cdot \vec{P}_h - \vec{P}_k| \quad (17)$$

$$\vec{P}_k = \vec{P}_h - \vec{E} \cdot \vec{D}_h \quad (18)$$

$$\vec{C}_h = \vec{P}_k - \vec{P}_{k+1} + \dots + \vec{P}_{k+N} \quad (19)$$

$$N = \text{contagem}_{ns}(\vec{P}_h, \vec{P}_{h+1}, \vec{P}_{h+2}, \dots, (\vec{P}_h + \vec{M})) \quad (20)$$

onde: \vec{P}_h é a posição do melhor agente de busca; \vec{P}_k representa as posições dos outros agentes; o número de hienas-malhadas pertencente ao grupo de melhores soluções é representado por N ; \vec{M} é um vetor no intervalo $[0,5, 1]$; ns é número de agentes de busca; \vec{C}_h é o grupo formado pelos N melhores agentes de busca. É importante ressaltar que a estrutura da equação (20) é representada em (Dhiman and Kumar, 2017).

3.3 Atacar a presa

Esse operador é responsável pelo processo de intensificação: com o decréscimo linear do vetor \vec{h} , ocorre a diminuição no valor de \vec{E} ; quando $|\vec{E}| < 1$, o grupo de hienas-malhadas é forçado a mover em direção à presa. O modelo matemático desse mecanismo é apresentado em (21):

$$\vec{P}_{t+1} = \frac{\vec{C}_h}{N} \quad (21)$$

onde: \vec{P}_{t+1} contém a melhor solução e é utilizado para atualizar as posições dos agentes de busca.

3.4 Procurar a presa

O processo de exploração ocorre quando $|\vec{E}| > 1$, permitindo que o SHO realize uma busca global. Além disso, a aleatoriedade de \vec{B} é útil para evitar problemas relacionados à estagnação em ótimos locais.

4. ADAPTAÇÃO DO SHO PARA O PET

Este trabalho propõe a adaptação do SHO para ser capaz de solucionar problemas de otimização com variáveis inteiras. Para isto, será utilizada a função sigmoide para transformar a posição dos agentes de busca em valores binários. O processo proposto neste trabalho é similar ao realizado em (Panwar et al., 2017), onde foi apresentada uma versão binária para meta-heurística “lobo cinzento”

(GWO). A função sigmoide é aplicada ao operador “atacar a presa”, conforme apresentado em (22) e (23):

$$\text{sigmoide}(\vec{X}^{(t+1)}) = \frac{1}{1 + e^{-10(\vec{X}^{(t+1)} - 0.5)}} \quad (22)$$

$$\vec{X}_{BIN}^{(t+1)} = \begin{cases} 1, & \text{se } \text{sigmoide}(\vec{X}^{(t+1)}) \geq \text{rand} \\ 0, & \text{caso contrário} \end{cases} \quad (23)$$

onde rand é um número aleatório com distribuição uniforme amostrado no intervalo $[0, 1]$.

Além disso, este artigo propõe uma modificação na equação (20), referente ao número N de hienas-malhadas pertencentes ao grupo de melhores soluções C_h devido ao fato do valor da função *fitness* ser relacionado ao custo monetário. Os agentes de busca participantes do grupo de melhores soluções serão aqueles que tiverem o valor da função *fitness* de acordo a um percentual definido aleatoriamente entre 100% e 150% do valor da melhor solução encontrada até então. A cada iteração será sorteado um valor aleatório no intervalo de $[1; 1,5]$ que representa o percentual do valor da melhor solução corrente. O valor da variável N será a quantidade de agentes de busca que possuírem a “*fitness*” menor ou igual ao valor equivalente a porcentagem da melhor solução encontrada até então.

O pseudocódigo do SHO adaptado pelas duas alterações previamente descritas é apresentado no Algoritmo 1, sendo n o número máximo de agentes de busca.

Algoritmo 1 Pseudocódigo da meta-heurística hienamalhada adaptada para variável discreta

- 1: **Entrada:** população das hienas-malhadas P_i ($i = 1, 2, \dots, n$)
 - 2: **Saída:** melhor agente de busca
 - 3: Iniciar h, E, B e N
 - 4: Calcular a *fitness* de cada agente de busca
 - 5: $P_h =$ o melhor agente de busca
 - 6: $C_h =$ o grupo com N melhores soluções
 - 7: $t_{max} =$ número máximo de iterações
 - 8: **while** $t < t_{max}$ **do**
 - 9: **for** cada agente de busca **do**
 - 10: Atualizar a posição do agente corrente (21)
 - 11: Converter a posição do agente corrente para binário (22) - (23)
 - 12: **end for**
 - 13: Atualizar h, E, B e N
 - 14: Calcular a *fitness* de cada agente de busca
 - 15: Atualizar P_h se houver uma solução melhor do que solução ótima anterior
 - 16: Atualizar o grupo C_h de acordo com P_h
 - 17: $t = t + 1$
 - 18: **end while**
 - 19: Retorna P_h
-

5. RESULTADOS

A metodologia apresentada é aplicada ao sistema equivalente a uma aproximação do sistema real instalado no sul brasileiro (Monticelli et al., 1982). Comparações são realizadas através das meta-heurísticas do Lobo Cinzento (GWO) e da Baleia (WOA). Em todas as funções sigmoide

foi usada para mitigar o problema de variáveis discreta. Os seguintes casos são avaliados:

- Caso A: sem considerar contingências e cenários de geração eólica.
- Caso B: considerando contingência N-1 sem considerar cenários de geração eólica.
- Caso C: considerando cenários de geração eólica sem considerar contingências.
- Caso D: considerando contingência N-1 e cenários de geração eólica.

Todas as simulações foram conduzidas usando um processador Core *i7* com 2.7 GHz. Os códigos foram implementados com o *software* MATLAB®. Para todos os casos foram considerados 50 agentes de busca, sendo que o número máximo de iterações para o caso A e B foi de 100 e para os casos C e D foi de 50. O número máximo de iterações é levado em consideração como critério de parada. Foram realizadas 50 simulações para os casos A, B e C, já para o Caso D foram realizadas apenas 20 simulações devido ao elevado tempo computacional exigido para avaliar os cenários de geração eólica e contingência.

As simulações foram conduzidas com todas as linhas candidatas a expansão, ou seja, sem redução do espaço de busca para os casos onde não é considerado o critério de segurança N-1, sendo eles os casos A e C. Para os casos B e D é aplicada a redução de linhas candidatas a expansão proposto em (Oliveira et al., 2018b).

5.1 Sistema Sul-Brasileiro

O sistema equivalente uma aproximação do sistema instalado no sul do Brasil é composto por 46 barras e 66 linhas na topologia base, tendo 79 linhas de transmissão candidatas à expansão e até três linhas podendo ser construídas em cada ramo. O sistema é composto por 12 unidades geradoras, totalizando 10.545 MW de capacidade de geração para atender uma carga total de 6880 MW. Embora este sistema contenha um número reduzido de barras, ele representa bem o problema de planejamento de linha de transmissão tendo em vista apresentar 11 barras isoladas introduzindo maior dificuldade de encontrar a solução ótima.

As linhas nos ramos “2-5”, “19-21”, “20-23”, “32-43”, “42-44”, “19-32” e “42-43” compõem a lista de contingência no critério de segurança N-1. A lista foi obtida a partir de um estudo que definiu o conjunto de linhas que causam maior impacto na rede quando retiradas de operação. Sob contingência, é considerada uma flexibilidade de até 10% de sobrecarga em cada linha do sistema.

Para o estudo com cenários de geração eólica são acrescentados três parques eólicos de 700 MW contendo 250 turbinas nas barras 1, 21 e 43. Os cenários de geração eólica apresentados na Tabela 1 foram obtidos com a utilização do algoritmo *k-means*, seguindo a metodologia apresentada em (Assis et al., 2018), fazendo uso das séries históricas de despacho eólico apresentada em (Leite da Silva et al., 2012). O *k-means* agrupa cenários de despacho eólicos similares em grupos, reduzindo drasticamente o número de avaliações da operação da rede necessárias para considerar as incertezas de curto-prazo inerentes ao comportamento dos ventos. Neste caso, cada cenário contribui

com a respectiva probabilidade para formação do custo do investimento. Por exemplo, o cenário 10 terá menos influência no custo de investimento que o cenário 2.

Tabela 1. Cenários de vento utilizados.

Cenário	Capacidade eólica (%)			Probabilidade (%)
	Barra 1	Barra 2	Barra 3	
1	5,80	8,82	7,66	28,44
2	13,84	28,51	12,65	15,08
3	27,60	48,70	17,18	9,20
4	22,59	40,38	40,71	9,02
5	9,87	16,94	31,31	8,42
6	44,26	67,50	31,43	7,86
7	36,18	60,06	59,41	6,91
8	56,63	82,04	70,14	6,51
9	83,77	97,03	87,38	5,13
10	71,66	88,35	41,01	3,43

Após esta considerações, as simulações são realizadas. A Tabela 2 apresenta o melhor resultado obtido e o tempo médio de execução gasto por cada meta-heurística nos casos A e B.

- Para o Caso A, em 50 simulações, a meta-heurística SHO obteve o resultado ótimo 22 vezes enquanto o WOA obteve resultado ótimo 8 vezes e o GWO obteve 10 vezes. Este resultado consiste no custo de investimento de 75,985 M\$, obtido em (de Paula et al., 2020). A Figura 1 apresenta o *boxplot* para o Caso A, onde pode ser observado que o SHO apresenta a mediana dos resultados mais próxima da solução ótima.
- Para o Caso B, o melhor resultado obtido pelas três meta-heurísticas foi a solução com o custo de investimento de 163,853 M\$ tendo a ocorrência de uma única vez no WOA, duas vezes para o GWO e três vezes no SHO. A Figura 2 mostra o *boxplot* para o caso B, onde a mediana mais próxima do melhor resultado foi obtida pelo GWO. Além disso, nota-se que o limite superior dos resultados obtidos pelo SHO é menor do que os limites do GWO e WOA.

Tabela 2. Melhor Solução - Casos A e B.

Caso	Método	Linhas Construídas	Invest. (M\$)	Tempo (médio)
A	WOA	2 (5-6), 1 (18-20), 2 (20-21), 1 (20-23), 1 (42-43), 1 (46-6)	75,895	4,60
A	GWO	2 (5-6), 1 (18-20), 2 (20-21), 1 (20-23), 1 (42-43), 1 (46-6)	75,895	4,72
A	SHO	2 (5-6), 1 (18-20), 2 (20-21), 1 (20-23), 1 (42-43), 1 (46-6)	75,895	4,05
B	WOA	1 (2-5), 2 (20-23), 1 (19-21), 2 (20-21), 1 (32-43), 1 (42-44), 2 (42-43), 1 (46-6), 1 (31-32), 2 (5-6)	163,853	22,23
B	GWO	1 (2-5), 2 (20-23), 1 (19-21), 2 (20-21), 1 (32-43), 1 (42-44), 2 (42-43), 1 (46-6), 1 (31-32), 2 (5-6)	163,853	23,58
B	SHO	1 (2-5), 2 (20-23), 1 (19-21), 2 (20-21), 1 (32-43), 1 (42-44), 2 (42-43), 1 (46-6), 1 (31-32), 2 (5-6)	163,853	17,56

A Tabela 3 apresenta o melhor resultado obtido por cada meta-heurística nos casos C e D além do tempo médio de execução.

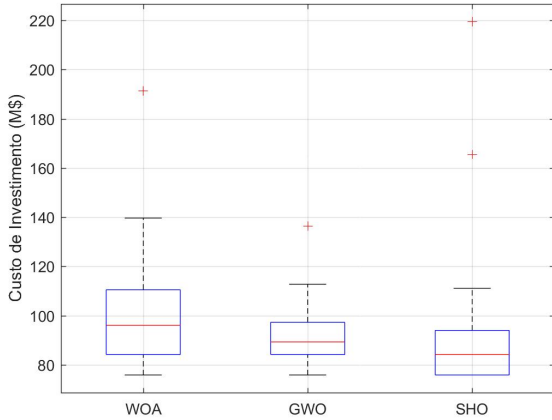


Figura 1. Custos de investimento obtidos para o Caso A.




Figura 3. Custos de investimento obtidos para o Caso C.




Figura 2. Custos de investimento obtidos para o Caso B.




Figura 4. Custos de investimento obtidos para o Caso D.

- Para o Caso C em 50 simulações a melhor solução encontrada pelas três meta-heurísticas possui o custo de investimento de 75,895 M\$. O SHO obteve esse resultado três vezes enquanto o WOA obteve duas vezes e GWO obteve esse resultado 9 vezes. A Figura 3 apresenta o *boxplot* para o Caso C. Mesmo com a utilização de 50 iterações, a inserção de cenários de geração eólica proporcionou uma dispersão menor dos resultados e mais próxima da melhor solução encontrada do que o caso A. Além disso, nota-se que tanto no caso C quanto nos anteriores a meta-heurística SHO obteve resultados *outliers* que indicam estagnações prematuras em ótimos locais.
- Para o Caso D, em vinte simulações para cada meta-heurística, o melhor resultado encontrado possui o custo de investimento de 163,853 M\$ e foi obtido duas vezes pelo WOA. O melhor resultado obtido pelo GWO possui o custo de 180,618 M\$ e ocorreu seis vezes. O melhor resultado obtido pelo SHO foi a solução com custo de 169,588 M\$ e ocorreu duas vezes. A Figura 4 apresenta o *boxplot* para o caso D, onde nota-se que apesar da discrepância nas dispersões dos resultados obtidos por cada meta-heurística, as medianas são consideravelmente próximas uma das outras.

6. CONCLUSÃO

Este trabalho propôs uma adaptação da meta-heurística *Spotted Hyena Optimizer* (SHO) para que essa possa ser utilizada no problema do planejamento da transmissão

Tabela 3. Melhor Solução - Casos C e D.

Caso	Método	Linhas Construídas	Invest. (M\$)	Tempo (min)
C	WOA	2 (5-6), 1 (18-20), 2 (20-21), 1 (20-23), 1 (42-43), 1(46-6)	75,895	19,98
C	GWO	2 (5-6), 1 (18-20), 2 (20-21), 1 (20-23), 1 (42-43), 1(46-6)	75,895	21,64
C	SHO	2 (5-6), 1 (18-20), 2 (20-21), 1 (20-23), 1 (42-43), 1(46-6)	75,895	18,65
D	WOA	1 (2-5), 2 (20-23), 1 (19-21), 2 (20-21), 1 (32-43), 1 (42-44), 2 (42-43), 1 (46-6), 1 (31-32), 2 (5-6)	163,853	186,84
D	GWO	1 (2-5), 1 (19-21), 1 (20-21), 1 (32-43), 1 (42-44), 2 (42-43), 1 (46-6), 1 (21-25), 1 (31-32), 2 (24-25), 2 (5-6)	180,618	194,37
D	SHO	1 (19-21), 2 (20-23), 1 (32-43), 1 (42-44), 2 (20-21), 2 (42-43), 1 (46-3), 1 (31-32), 2 (2-3)	169,588	171,03

de energia elétrica, adequando-a para o tratamento de variáveis discretas e ajustando o mecanismo de seleção do grupo de melhores agente de busca.

Para avaliar o desempenho da meta-heurística adaptada, foi utilizado o sistema de 46 barras, equivalente a uma simplificação do sistema real encontrado no Sul do Brasil, considerando as perdas de potência ativa, o critério de segurança N-1 e as incertezas de curto-prazo na geração de energia eólica.

Para o Caso A, onde não é levado em consideração os cenários de geração eólica e contingência determinística N-1, o SHO foi mais eficaz na obtenção da solução ótima.

Para o Caso B, no qual é considerado contingência determinística N-1 mas sem cenário de geração eólica, e para Caso C, onde é considerado cenário de geração eólica e sem contingência, a meta-heurística GWO obteve o melhor conjunto de resultados seguido do SHO.

Para o caso D, onde é levado em consideração contingência e cenário de geração eólica, o algoritmo WOA obteve a melhor solução.

A partir dos resultados obtidos pode-se afirmar que a adaptação proposta obteve êxito na solução do PET, mostrando-se uma ferramenta competitiva para a solução do problema. No entanto, o desempenho da SHO depende de ajustes nos parâmetros assim como ocorre em outras meta-heurísticas.

REFERÊNCIAS

- Assis, F.A., Manso, L.A.F., da Silva, A.M.L., and Leon, J.E.A. (2018). Transmission expansion planning with wind sources based on constructive metaheuristics. In *2018 Simposio Brasileiro de Sistemas Eletricos (SBSE)*, 1–6.
- de Paula, A., Oliveira, E., Oliveira, L., and Honorio, L. (2020). Robust static transmission expansion planning considering contingency and wind power generation. *Journal of Control, Automation and Electrical Systems*. doi:10.1007/s40313-019-00556-w.
- Dhiman, G. and Kumar, V. (2017). Spotted hyena optimizer: A novel bio-inspired based metaheuristic technique for engineering applications. *Advances in Engineering Software*, 114, 48 – 70. doi: <https://doi.org/10.1016/j.advengsoft.2017.05.014>. URL <http://www.sciencedirect.com/science/article/pii/S0965997816305567>.
- Dhiman, G. and Kumar, V. (2018). Multi-objective spotted hyena optimizer: A multi-objective optimization algorithm for engineering problems. *Knowledge-Based Systems*, 150, 175 – 197. doi: <https://doi.org/10.1016/j.knosys.2018.03.011>. URL <http://www.sciencedirect.com/science/article/pii/S0950705118301357>.
- Gideon Ude, N., Yskandar, H., and Coneth Graham, R. (2019). A comprehensive state-of-the-art survey on the transmission network expansion planning optimization algorithms. *IEEE Access*, 7, 123158–123181.
- Gomes, P.V. and Saraiva, J.T. (2015). Static transmission expansion planning using heuristic and metaheuristic techniques. In *2015 IEEE Eindhoven PowerTech*, 1–6. doi:10.1109/PTC.2015.7232377.
- Gomes, P.V. and Saraiva, J.T. (2019). State-of-the-art of transmission expansion planning: A survey from restructuring to renewable and distributed electricity markets. *International Journal of Electrical Power & Energy Systems*, 111, 411 – 424. doi:<https://doi.org/10.1016/j.ijepes.2019.04.035>.
- Kuntla, V. (2015). Cuckoo search algorithm for optimal transmission expansion planning with generator/load models and frequency controls.
- Leite da Silva, A.M., d. F. Manso, L.A., d. S. Sales, W., Flavio, S.A., Anders, G.J., and de Resende, L.C. (2012). Chronological power flow for planning transmission systems considering intermittent sources. *IEEE Transactions on Power Systems*, 27(4), 2314–2322.
- Leite da Silva, A., Rezende, L., Manso, L., and Anders, G. (2010). Transmission expansion planning: A discussion on reliability and “n-1” security criteria. *2010 IEEE 11th International Conference on Probabilistic Methods Applied to Power Systems, PMAPS 2010*, 244 – 251. doi:10.1109/PMAPS.2010.5528652.
- Mahdavi, M., Sabillon, C., Ajalli, M., and Romero, R. (2018). Transmission expansion planning: Literature review and classification. *IEEE Systems Journal*, PP, 1–12. doi:10.1109/JSYST.2018.2871793.
- Monticelli, A., Santos, A., F. Pereira, M.V., Cunha, S.H., Parker, B.J., and G. Praca, J.C. (1982). Interactive transmission network planning using a least-effort criterion. *IEEE Transactions on Power Apparatus and Systems*, PAS-101(10), 3919–3925. doi:10.1109/TPAS.1982.317043.
- Oliveira, E., Moraes, C., Oliveira, L., Honorio, L., and Poubel, R. (2018a). Efficient hybrid algorithm for transmission expansion planning. *Electrical Engineering*, 100. doi:10.1007/s00202-018-0744-2.
- Oliveira, E., Moraes, C., Oliveira, L., Honorio, L., and Poubel, R. (2018b). Efficient hybrid algorithm for transmission expansion planning. *Electrical Engineering*, 100. doi:10.1007/s00202-018-0744-2.
- Panda, N. (2018). How effective is spotted hyena optimizer for training multilayer perceptrons. *International Journal of Recent Technology and Engineering*, 8. doi: 10.35940/ijrte.B3736.078219.
- Panwar, L., Reddy, S., Verma, A., Panigrahi, B., and Kumar, R. (2017). Binary grey wolf optimizer for large scale unit commitment problem. *Swarm and Evolutionary Computation*, 38. doi:10.1016/j.swevo.2017.08.002.
- Park, H. and Baldick, R. (2013). Transmission planning under uncertainties of wind and load: Sequential approximation approach. *IEEE Transactions on Power Systems*, 28(3), 2395–2402.
- Pengo, P., Rebello, G., Oliveira, E., and Junior, I. (2019). Transmission line exclusion algorithm to solve the expansion planning problem. 1–6. doi:10.1109/PTC.2019.8811003.
- Ugranli, F. and Karatepe, E. (2015). Multi-objective transmission expansion planning considering minimization of curtailed wind energy. *International Journal of Electrical Power Energy Systems*, 65.