

Planejamento da Transmissão via Meta-Heurística Híbrida

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 a hybrid method based on the Gray Wolf Optimizer (GWO) and Whale Optimization Algorithm (WOA) metaheuristics where a discrete variable treatment is proposed to solve the transmission line expansion planning problem. Active transmission power losses and the deterministic N-1 reliability criterion are included in the problem. The Garver and Southern Brazilian equivalent systems are used to show the efficiency of the proposed methodology.

Resumo: Este trabalho apresenta um método híbrido baseado nas meta-heurísticas *Grey Wolf Optimizer* (GWO) e *Whale Optimization Algorithm* (WOA) onde um tratamento para variáveis discreta é proposto para resolver o problema de planejamento da expansão de linha de transmissão. As perdas de potência ativa e o critério de confiabilidade determinístico N-1 são incluídos no problema. Os sistemas Garver e equivalente Sul do Brasil são utilizados para mostrar a eficiência da metodologia proposta.

Keywords: Hybrid Meta-heuristic Approach, Whale Optimization Algorithm, Grey Wolf Optimizer, Transmission Line Expansion Planning, N-1 reliability criterion.

Palavras-chaves: Abordagem Meta-heurística Híbrida, Otimização via Algoritmo de Baleias, Otimizador Via Lobo Cinzento, Planejamento de Expansão de Linhas de Transmissão, Critério de Confiabilidade N-1.

1. INTRODUÇÃO

O Planejamento da Expansão da Transmissão (PET) consiste em determinar, entre um conjunto pré definido de linhas de transmissão candidatas à expansão, aquelas que devem ser construídas de forma a minimizar os custos de investimento no sistema elétrico, atendendo a demanda prevista para um horizonte de planejamento. O PET é um problema de programação não linear inteiro-misto, com espaço de busca não convexo e combinatoriamente explosivo. Assim, vários métodos apresentados na literatura têm sido investigados para resolver este problema (Mahdavi et al., 2018), destacando-se aí os métodos baseados em meta-heurísticas bio inspirada (Gideon Ude et al., 2019).

Em Gallego et al. (1998), duas melhorias foram introduzidas ao *Genetic Algorithm* para solucionar o PET. Essas melhorias consistem na população inicial obtida por métodos convencionais baseados em otimização e uma abordagem de mutação inspirada na técnica *Simulated Annealing*. Já em Rezende et al. (2009) os autores compararam desempenho das meta-heurísticas *Artificial Immune Systems* e *Differential Evolution* ao PET, onde o método AIS obteve melhor resultado nos casos estudados. Em Vilaça and Saraiva (2015), o método *Constructive Heuristic Algorithm* foi utilizado para reduzir o conjunto de

linhas de transmissão candidatas à expansão. Para obter a melhor solução do PET para o conjunto reduzido, fez-se uso da meta-heurística *Particle Swarm Optimization*. Em Oliveira et al. (2018a), multiplicadores de Lagrange e coeficientes de Benders foram utilizados para a redução do espaço de busca, para resolver o PET foi utilizado uma versão modificada da meta-heurística *Bat Algorithm*. 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, verificou-se, por meio de solução do fluxo de potência contínuo, qual linha possui a menor necessidade de construção, excluindo-a do planejamento. Na busca de resultados ótimos, uma versão binária do *Gray Wolf Optimizer* foi utilizada após a redução do espaço de busca.

Este trabalho realiza a comparação do desempenho entre as meta-heurísticas: *Whale Optimization Algorithm* (WOA) (Mirjalili and Lewis, 2016); *Grey Wolf Optimizer* (GWO) (Mirjalili et al., 2014); e *Hybrid Whale Optimization Algorithm and Grey Wolf Optimizer Algorithm* (HWGO) (Korashy et al., 2019). Sendo que HWGO consiste em um modelo híbrido que faz uso do mecanismo de hierarquia de liderança, oriundo do GWO, ao mecanismo de ataque com rede de bolhas do WOA. Além disso, é proposto neste artigo uma modificação no HWGO para que a mesma possa solucionar problemas com variáveis inteiras, como ocorre no planejamento da expansão de

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

linhas de transmissão onde as perdas ativas e o critério N-1 são considerados, sendo esta a maior contribuição do trabalho.

2. FORMULAÇÃO MATEMÁTICA DO PET

A função objetivo e as restrições do PET, são apresentadas em (1) - (8)

$$\text{Min} \sum_{m=1}^{nr} c_m \cdot r_m + \sum_{n=1}^{nc} c_n \cdot EP_n \quad (1)$$

sujeito a:

$$g_i + r_i + \sum_{j \in \Omega_i} f_{ij} = d_i, \forall (i) \in \Omega_B \quad (2)$$

$$|f_{ij}| \leq \bar{f}_{ij}, \forall (i, j) \in \Omega_E, \Omega_C \quad (3)$$

$$0 \leq g_i \leq \bar{g}_i, \forall (i) \in \Omega_B, \quad (4)$$

$$0 \leq r_i \leq \bar{r}_i, \forall (i) \in \Omega_B, \quad (5)$$

$$EP_n \in [0, 1], \forall n \in \Omega_C \quad (6)$$

$$f_{ij} = \gamma_{ij}\theta_{ij} + \frac{1}{2} \cdot g_{ij}\theta_{ij}^2, \forall (i, j) \in \Omega_E \quad (7)$$

$$f_{ij} = EP_n \cdot (\gamma_{ij}\theta_{ij} + \frac{1}{2} \cdot g_{ij}\theta_{ij}^2), \forall (i, j) \in \Omega_C \quad (8)$$

onde:

nr	Número de geradores fictícios;
c_m	Custo do déficit de energia US\$/MW;
r_m	Geração da unidade geradora fictícia MW;
nc	Número de linhas candidatas à expansão;
c_n	Custo de construção da linha candidata n US\$/MW;
EP_n	Parâmetro de expansão binária associado a linha candidata n ;
g_i	Geração da unidade geradora na barra i MW;
$\bar{g}_i$	Limite máximo de geração na barra i MW;
r_i	Geração da unidade geradora fictícia na barra i MW;
$\bar{r}_i$	Limite máximo da geração fictícia na barra i MW;
Ω_B	Conjunto de barras do sistema;
Ω_C	Conjunto de linhas candidatas à expansão;
Ω_E	Grupo de linhas existentes;
f_{ij}	Fluxo de potência ativa na a linha entre as barras i - j MW;
$\bar{f}_{ij}$	Limite de fluxo de potência ativada linha entre as barras i - j MW;
d_i	Demanda na barra i MW;
θ_{ij}	Diferença angular entre as barras i e j ;
γ_{ij}	Suceptância e Condutância da linha entre as barras i e j ;
g_{ij}	Condutância da linha entre as barras i e j .

A função objetivo (1), representa a minimização da soma dos investimentos referente a expansão e dos custos dos deficit de energia. Os geradores representativos do deficit são alocados em cada barra de carga do sistema com seus custos de geração elevados, esses geradores entram em operação somente quando o plano de expansão obtido não garantir o atendimento à demanda. A restrição de balanço de potência ativa é representada em (2). A equação (3) representa restrição de limite de fluxo de potência ativa nas linhas candidatas e existentes. As equações (4) e (5) são as restrições de limite de geração de potência ativa dos geradores existentes e de deficit (fictícios). A variável binária representada em (6) indica se a linha deve ser construída ou não. Se $EP_n = 1$ a linha é construída, caso contrário $EP_n = 0$. As equações (7) e (8) modelam a potência ativa considerando as perdas ativas de transmissão para as linhas existentes e candidatas, respectivamente.

A solução do PET é realizada através da divisão em dois sub-problemas: 1- Sub-problema de investimento para definir quais linhas devem ser construídas. Este passo é definido pela metodologia hibrida proposta neste artigo; 2- Sub-problema de operação para verificar se os investimentos realizados foram suficientes para operação sem corte de carga, sem e com contingência N-1. A soma das funções objetivos dos problemas 1 e 2 é utilizada como *fitness* para a meta-heurística proposta. Esta divisão em dois sub-problemas é amplamente utilizada para solução do PET (Oliveira et al., 2018b).

3. META-HEURÍSTICA HÍBRIDA - HWGO

O algoritmo *Whale Optimization Algorithm* inspira-se no comportamento especial de caça das baleias jubartes, simulando matematicamente o seu movimento na busca por uma fonte de alimento. Quando a presa é localizada, as baleias jubartes iniciam uma peculiar estratégia de caça. No início, as baleias mergulham a uma profundidade maior que a do alvo e, em seguida, iniciam um movimento de aproximação em forma de espiral ao mesmo tempo em que liberam bolhas de ar, esse movimento especial é intitulado como ataque com rede de bolhas.

O algoritmo *Grey Wolf Optimizer* é uma meta-heurística populacional inspirada no processo de caça e hierarquia de liderança dos lobos cinzentos, onde os lobos são divididos em quatro categorias: os alfa α , casal líder da alcateia, são responsáveis pelas tomadas de decisões. Os betas β , prováveis candidatos a sucessão dos α . No terceiro grau de hierarquia encontram-se os delta δ , subordinados aos α e β , mas dominam os ômegas ω , que se encontram na base da pirâmide hierarquia da alcateia.

Uma das diferenças entre as meta-heurísticas WOA e GWO é que o WOA toma como referência, para a atualização da posição do agente de busca, a posição da melhor solução encontrada até então ou um agente de busca aleatório pertencente a população atual, enquanto no GWO a posição é atualizada em função das três melhores soluções. Além disso, o WOA possui um mecanismo de movimento em espiral para simular o ataque de redes de bolhas.

O modelo híbrido, *Hybrid Whale Optimization Algorithm and Grey Wolf Optimizer Algorithm*, combina os mecanismos bioinspirados dos algoritmos em WOA e GWO com

o intuito de melhorar o processo evolutivo. A referencia Korashy et al. (2019) utilizou o mecanismo de hierarquia de liderança, oriundo da meta-heurística GWO, associado ao mecanismo de ataque com rede de bolhas, pertencente ao WOA, para solucionar o problema de coordenação de relés de sobrecorrente direcionais, onde se obteve melhores resultados quando comparado com o WOA, GWO e outras técnicas de otimização bioinspiradas.

A cada iteração, os agentes de busca atualizam suas posições de duas maneiras de acordo com o valor absoluto do parâmetro $\vec{A}$

$$\vec{A} = 2\vec{a} \cdot \vec{k}_1 - \vec{a} \quad (9)$$

onde $\vec{k}_1$ representa um número aleatório no intervalo [0, 1]. O parâmetro $\vec{a}$ decresce linearmente de dois a zero ao longo do processo evolutivo, logo $\vec{A}$ representa um vetor com elementos randômico no intervalo de $[-a, a]$.

- se $|\vec{A}| < 1$ os agentes de busca atualizam sua posição de acordo com as posições dos três melhores resultados (α , β e δ);
- se $|\vec{A}| > 1$ os agentes de busca atualizam sua posição em relação a um agente de busca aleatório;

A atualização da posição do agente de busca de acordo com a posição de outro escolhida aleatoriamente é modelada em (10) e (11).

$$\vec{D} = |\vec{C} \cdot \vec{X}_{rand} - \vec{X}| \quad (10)$$

$$\vec{X}(t+1) = \vec{X}_{rand} - \vec{A} \cdot \vec{D} \quad (11)$$

Onde $\vec{X}_{rand}$ é a posição de um indivíduo aleatório e $\vec{C}$ é um vetor aleatório no intervalo [0, 2].

A atualização da posição dos agente de busca em função das três melhores soluções encontradas será chamada de Mecanismo de Ataque com Rede de Bolhas com Hierarquia de Liderança e consiste em duas partes que serão intituladas como Mecanismo de Encolhimento com Hierarquia de Liderança e Mecanismo de Atualização da Posição em Espiral com Hierarquia de Liderança.

Adota-se uma probabilidade de 50% para se escolher qual mecanismo será utilizado na atualização da posição do agente de busca durante o processo de otimização. Sendo p é um número aleatório dentro de [0, 1],

- se $p < 0,5$ os agentes de busca atualizam sua posição utilizando o Mecanismo de Encolhimento em Hierarquia de Liderança;
- se $p \geq 0,5$ os agentes de busca atualizam sua posição utilizando o Mecanismo de Atualização da Posição em Espiral;

Mecanismo de Encolhimento com Hierarquia de Liderança

As distâncias entre a posição do indivíduo atual e a dos indivíduos alfa, beta e delta são calculados em (12) - (14).

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \quad (12)$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \quad (13)$$

$$\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (14)$$

Onde, t representa a iteração atual, $\vec{X}$ é o vetor posição de cada agente, $\vec{X}_\alpha$, $\vec{X}_\beta$ e $\vec{X}_\delta$ são o vetor posição do alfa, beta e delta, respectivamente. Os vetores $\vec{C}_1$, $\vec{C}_2$ e $\vec{C}_3$ são vetores gerados aleatoriamente no intervalo [0, 2].

A atualização da posição do agente de busca nesse mecanismo é apresentada em (15) - (18).

$$\vec{X}_1 = |\vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha| \quad (15)$$

$$\vec{X}_2 = |\vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta| \quad (16)$$

$$\vec{X}_3 = |\vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta| \quad (17)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (18)$$

Os vetores $\vec{A}_1$, $\vec{A}_2$ e $\vec{A}_3$ são vetores gerados aleatoriamente da mesma forma que em (9).

Mecanismo de Atualização da Posição em Espiral com Hierarquia de Liderança

A atualização da posição dos agente de busca ao longo de um caminho em forma de espiral é formulada em (19) - (25).

$$\vec{D}'_\alpha = |\vec{X}_\alpha(t) - \vec{X}(t)| \quad (19)$$

$$\vec{D}'_\beta = |\vec{X}_\beta(t) - \vec{X}(t)| \quad (20)$$

$$\vec{D}'_\delta = |\vec{X}_\delta(t) - \vec{X}(t)| \quad (21)$$

$$\vec{X}_1 = \vec{D}'_\alpha \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}_\alpha(t) \quad (22)$$

$$\vec{X}_2 = \vec{D}'_\beta \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}_\beta(t) \quad (23)$$

$$\vec{X}_3 = \vec{D}'_\delta \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}_\delta(t) \quad (24)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (25)$$

onde b é uma constante que define a forma da espiral logarítmica, l é um numero aleatório pertencente ao intervalo [-1, 1].

O pseudocódigo da meta-heurística HWGO é apresentado no Algoritmo 1.

Algoritmo 1 Pseudocódigo do Algoritmo HWGO

```

1:  $t_{max}$  = número máximo de iterações
2:  $N$  = número total de agentes de busca
3: Inicializar a população aleatoriamente
4: Calcular a fitness de cada agente de busca
5:  $X_\alpha$  = o melhor agente de busca
6:  $X_\beta$  = o segundo melhor agente de busca
7:  $X_\delta$  = o terceiro melhor agente de busca
8: while  $t < t_{max}$  do
9:   for  $i = 1$  até  $N$  do
10:    Atualizar os parâmetros  $a$ ,  $A$ ,  $C$ ,  $l$  e  $p$ 
11:    if  $p < 0,5$  then
12:      if  $|A| \geq 1$  then
13:        Atualizar a posição do agente de busca
        atual usando (11)
14:      else if  $|A| \leq 1$  then
15:        Selecionar um agente aleatório  $X_{rand}$ 
16:        Atualizar a posição do agente de busca
        atual usando (18)
17:      end if
18:      else if  $p \leq 0,5$  then
19:        Atualizar a posição do agente de busca atual
        usando (25)
20:      end if
21:    end for
22:    Calcular fitness de cada agente de busca
23:    Atualizar  $X_\alpha$ ,  $X_\beta$  e  $X_\delta$ 
24:     $t = t + 1$ 
25: end while
26: Retornar  $X_\alpha$ 

```

3.1 HWGO para Variáveis Inteiras

O HWGO é proposto para resolver problemas de otimização com variáveis contínuas. Portanto, é necessário uma adaptação do método para solucionar o PET, formulado como um problema de programação inteira-mista com solução restrita aos valores binários zero e um. Este trabalho propõe a aplicação semelhante ao modelo proposto em Panwar et al. (2017), onde os autores utilizaram a função sigmoide para forçar a posição contínua dos agentes de busca a ser um valor binário.

No modelo binário, a função sigmoide será aplicada ao Mecanismo de Ataque com Rede de Bolha com Hierarquia de Liderança após a utilização de (18) e (25) bem como ao processo de exploração, após utilização da equação (11), como segue:

$$sigmoid(x) = \frac{1}{1 + e^{-10(\vec{X}^{(t+1)} - 0.5)}} \quad (26)$$

$$\vec{X}_{BIN}^{(t+1)} = \begin{cases} 1, & \text{se } sigmoid(\vec{X}^{(t+1)}) \geq rand \\ 0, & \text{caso contrário} \end{cases} \quad (27)$$

onde $rand$ é um número aleatório no intervalo $[0,1]$.

4. RESULTADOS

A metodologia apresentada é aplicada ao sistema Garver (Garver, 1970) e ao sistema equivalente sul-brasileiro (Monticelli et al., 1982). Deve-se destacar que a técnica utilizada para tornar o HWOA capaz de solucionar problemas

com variáveis inteiras é também aplicada nas metodologias WOA e GWO afim de comparar o desempenho das três meta-heurísticas.

As simulações foram conduzidas com todas as linhas candidatas a expansão, ou seja, sem redução do espaço de busca. Os seguintes casos foram simulados:

- Caso A: sem considerar contingências.
- Caso B: considerando contingência N-1 nas linhas existente do sistema.

Todas as simulações foram conduzidas usando um PC core *i7* com 3.4 GHz e todos os algoritmos foram implementados com o *software* MATLAB®. Para ambos sistemas foram realizadas 100 simulações considerando a população com 200 indivíduos e o número máximo de iteração de 100 (número de gerações). O número máximo de iterações é levado em consideração como critério de parada. Para o sistema Garver, todas as contingências individuais das linhas existentes são consideradas e, para o sistema Sul, o critério de segurança N-1 considera um conjunto de linhas. Sob cada contingência, a flexibilidade é considerada para a operação do sistema através de sobrecarga admissível de até 10% em cada linha.

4.1 Sistema Garver

O sistema Garver é composto por seis barras e seis linhas existentes na topologia base, além de três geradores e uma carga esperada de 760 MW. Existem quinze linhas de transmissão candidatas à expansão e até 3 linhas podem ser construídas em cada ramo.

A Tabela 1 apresenta o melhor resultado obtido por cada método para Caso A além do tempo computacional médio de execução para solucionar o PET. Todas as três meta-heurística obtiveram a solução ótima que consiste no custo de investimento de 130 M\$ (Oliveira et al., 2018b). A Tabela 2 mostra a frequência dos resultados obtidos pelas meta-heurísticas no Caso A, onde o algoritmo HWOA obteve um desempenho superior, alcançando a solução ótima do sistema 93 vezes, embora o tempo computacional tenha sido ligeiramente superior.

Tabela 1. Melhor solução obtida no Caso A para o Sistema Garver.

Método	Ramos	Custo(M\$)	Tempo(min)
WOA	3 (4-6), 1 (2-3), 1 (3-5)	130	6,34
GWO	3 (4-6), 1 (2-3), 1 (3-5)	130	7,13
HWOA	3 (4-6), 1 (2-3), 1 (3-5)	130	7,57

Tabela 2. Frequência dos resultados obtidos no Caso A para o Sistema Garver.

Custo M\$	Método		
	WOA	GWO	HWOA
130,00	22	86	93
140,00	69	10	4
162,71	9	4	3

O melhor resultado obtido por cada meta-heurística para o sistema Garver no Caso B é apresentado na Tabela 3.

A Tabela 4 apresenta a frequência dos resultados entre os algoritmos no caso B, onde a solução ótima foi obtida 97 vezes pelo HWGO, 89 e 52 vezes pelo GWO e WOA, respectivamente. O melhor resultado encontrado pelas três meta-heurísticas no custo de investimento de 160 M\$ (Neves de Paula et al., 2020). Como já mencionado, todas as contingências individuais das linhas foram consideradas para esse sistema.

Tabela 3. Melhor solução obtida no Caso B para o Sistema Garver.

Método	Ramos	Custo(M\$)	Tempo(min)
WOA	2 (4-6), 2 (2-3), 2 (3-5)	160	51,75
GWO	2 (4-6), 2 (2-3), 2 (3-5)	160	52,22
HWOA	2 (4-6), 2 (2-3), 2 (3-5)	160	52,64

Tabela 4. Frequência dos resultados obtidos no Caso B para o Sistema Garver.

Custo M\$	Método		
	WOA	GWO	HWGO
160,00	52	89	97
170,00	36	11	3
177,78	12	0	0

4.2 Sistema Sul-Brasileiro

O equivalente ao sistema sul-brasileiro 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. Existem 12 unidades geradoras e uma carga de 6880 MW.

A Tabela 5 apresenta o melhor resultado obtido no Caso A por cada meta-heurística para o sistema Sul. Em 100 simulações, a meta-heurística HWGO obteve o resultado ótimo 45 vezes, o GWO e WOA obtiveram o resultado ótimo 37 e 35 vezes, respectivamente. Este resultado consiste no custo de investimento da solução ótima é de 75,98 M\$ conforme encontrado na referencia (Neves de Paula et al., 2020).

Tabela 5. Melhor solução obtida no Caso A para o Sistema Sul.

Método	Ramos	Custo(M\$)	Tempo(min)
WOA	2 (5-6), 1 (18-20), 2(20-21), 1 (20-23), 1 (42-43), 1(46-6)	75,89	16,19
GWO	2 (5-6), 1 (18-20), 2(20-21), 1 (20-23), 1 (42-43), 1(46-6)	75,89	16,54
HWOA	2 (5-6), 1 (18-20), 2(20-21), 1 (20-23), 1 (42-43), 1(46-6)	75,89	17,58

Para o Sistema Sul, considerando o Caso B, o conjunto de linhas adotado para contingência N-1 é apresentado na Tabela 6.

Tabela 6. Contingências adotadas para o sistema Sul.

Linhas
(2-5), (19-21), (20-23), (32-43), (42-44), (19-32), (42-43)




Figura 1. Comparação dos resultados obtidos no sistema Sul para o Caso B.

Para estas condições, a Tabela 7 apresenta o melhor resultado obtido por cada meta-heurística para o sistema Sul no Caso B. O melhor resultado obtido pelo HWGO possui o custo de investimento de 163,76 M\$. As meta-heurísticas GWO e WOA tiveram como melhor resultado o custo de investimento de 169,50 M\$. Este resultado mostra que o modelo híbrido foi eficiente para aproveitar o melhor de cada método.

Tabela 7. Melhor solução obtida no Caso B para o Sistema Sul.

Método	Ramos	Custo(M\$)	Tempo(min)
WOA	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), 1 (21-25), 1 (28-43), 1 (46-11), 1 (24-25), 1 (9-10)	169,5	146,24
GWO	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), 1 (21-25), 1 (28-43), 1 (46-11), 1 (24-25), 1 (9-10)	169,5	150,26
HWOA	1 (2-5), 1 (19-21), 2 (20-23), 1 (32-43), 1 (42-44), 2 (20-21), 2 (42-43), 1 (46-6), 1 (28-43), 1 (31-32), 3 (5-6)	163,76	155,84

As Figuras 1 e 2 apresentam boxplots para os resultados obtidos pelas meta-heurísticas no sistema Sul para os casos A e B respectivamente. Destaca-se que o modelo híbrido HWGO obteve o melhor desempenho em ambos os casos, sendo portanto, promissor para aplicação em sistemas de grande porte.

4.3 Conclusão

Este trabalho apresentou uma meta-heurística híbrida (HGWO) baseada na técnica bioinspirada *Grey Wolf Op-*




Figura 2. Comparação dos resultados obtidos no sistema Sul para o Caso B.

timizer (GWO) e Whale Optimization Algorithm (WOA). Uma modificação foi acrescentada para tornar o método HGWO adequado para tratamento de variável discreta para acomodar o problema de planejamento de sistema de transmissão. A partir dos resultados obtidos com o sistema Garver e equivalente Sul Brasileiro, alguns pontos podem ser destacados:

- A meta-heurística híbrida obteve o melhor conjunto de resultados em todos os casos testados;
- O número de vezes que a metodologia HGWO encontrou o resultado ótimo foi superior aos métodos originais GWO e WOA;
- O método HGWO apresentou bom desempenho não havendo necessidade de redução de espaço de busca;

Tendo em vista a melhoria encontrada no método híbrido, a metodologia proposta é promissora para aplicação em sistemas reais com inserção de energia renováveis que requer um número elevado de simulações para representar a incertezas destas fontes de energia.

REFERÊNCIAS

- Gallego, R.A., Monticelli, A., and Romero, R. (1998). Transmission system expansion planning by an extended genetic algorithm. *IEE Proceedings - Generation, Transmission and Distribution*, 145(3), 329–335. doi:10.1049/ip-gtd:19981895.
- Garver, L. (1970). Transmission network estimation using linear programming. *Power Apparatus and Systems, IEEE Transactions on*, PAS-89, 1688 – 1697. doi:10.1109/TPAS.1970.292825.
- Gideon Ude, N., Hamam, Y., and Graham, R. (2019). A comprehensive state-of-the-art survey on the transmission network expansion planning optimization algorithms. *IEEE Access*, PP, 1–1. doi:10.1109/ACCESS.2019.2936682.
- Korashy, A., Kamel, S., Jurado, F., and Youssef, A.R. (2019). Hybrid whale optimization algorithm and grey wolf optimizer algorithm for optimal coordination of direction overcurrent relays. *Electric Power Components and Systems*, 47, 644–658. doi:10.1080/15325008.2019.1602687.
- 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.
- Mirjalili, S. and Lewis, A. (2016). The whale optimization algorithm. *Advances in Engineering Software*, 95, 51–67. doi:10.1016/j.advengsoft.2016.01.008.
- Mirjalili, S., Mirjalili, S., and Lewis, A. (2014). Grey wolf optimizer. *Advances in Engineering Software*, 69, 46–61. doi:10.1016/j.advengsoft.2013.12.007.
- 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.
- Neves 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.
- 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.
- 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.
- 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.
- Rezende, L., Leite da Silva, A., and Honorio, L. (2009). Artificial immune systems and differential evolution based approaches applied to multi-stage transmission expansion planning. 1 – 6. doi:10.1109/ISAP.2009.5352957.
- Vilaça, P. and Saraiva, J. (2015). Static transmission expansion planning using heuristic and metaheuristic techniques. doi:10.1109/PTC.2015.7232377.