

# Planejamento da Expansão do Sistema de Transmissão via *Coyote Optimization Algorithm*

Mariana C. S. Perpetuo \* Raphael P. B. Poubel \* Wesley Peres \*\*

\* Departamento de Engenharia Elétrica, Centro Federal de Educação Tecnológica, MG, (e-mail: marianasilva492@gmail.com, poubel@cefetmg.br).

\*\* Departamento de Engenharia Elétrica, Universidade Federal de São João del-Rei, MG, (e-mail: wesley.peres@ufsj.edu.br)

---

**Abstract:** This work deals with the static planning expansion of electric power transmission systems considering uncertainties associated with wind generation. The goal is to determine the required reinforcements that meet the power balance constraints and minimize the implementation costs. Three algorithms are employed to solve the problem: Differential Evolution, Particle Swarm Optimization, and Coyote Optimization. After that, the best algorithm is chosen to solve the Garver, IEEE-24 bus, and Equivalent Brazilian Southern test systems considering wind generation.

**Resumo:** Este trabalho trata do planejamento estático da expansão de sistemas de transmissão de energia elétrica considerando incertezas associadas à intermitência da geração eólica. Visa-se determinar os reforços que deverão ser implantados na rede de transmissão de forma a atender os requisitos energéticos do sistema e minimizar os custos de implantação. Três algoritmos são inicialmente empregados para a solução do problema: *Differential Evolution*, *Particle Swarm Optimization* e *Coyote Optimization*. A partir dos resultados, identifica-se o mais promissor para avaliação dos sistemas elétricos Garver, IEEE - 24 barras e o sistema Sul Equivalente do Brasil, na presença de aerogeradores.

**Keywords:** Transmission Planning; Wind Generation; Generation Uncertainties; Bioinspired Optimization; Demand Uncertainties.

**Palavras-chaves:** Planejamento da Transmissão; Geração Eólica; Incertezas na Geração; Otimização Bioinspirada; Incertezas na Demanda.

---

## 1. INTRODUÇÃO

Tem-se observado uma preocupação global para aliar o desenvolvimento econômico à políticas ambientais sustentáveis, especialmente no que diz respeito à redução das emissões de gases de efeito estufa. Esse movimento reflete diretamente no planejamento energético, com incentivo a pesquisas, desenvolvimento de novas tecnologias e mudança nos hábitos de consumo. Nessa perspectiva, a inclusão de fontes de energia alternativas e renováveis nas matrizes energéticas dos países se torna inevitável.

Apesar de não consumir combustíveis fósseis e não emitir gases poluentes durante sua operação, a geração eólica não é uma fonte de energia isenta de impactos ambientais. Os aerogeradores têm altas torres e grandes hélices que alteraram a paisagem local, podem interferir em rotas migratórias de pássaros e emitem ruídos capazes de incomodar a vizinhança. Outro problema é a intermitência do vento e suas variações de intensidade, que fazem os aerogeradores operarem fora do ponto de máxima potência. Ainda, os locais de maior potencial energético normalmente se encontram longes dos centros de consumo, exigindo grandes

investimentos nos sistemas de transmissão de energia (Valim et al., 2016).

A característica intermitente da geração eólica provoca variações significativas no carregamento das linhas de transmissão quando grandes blocos de energia são acrescentados ao sistema (Yu et al., 2009). Neste entremeio, um Planejamento da Expansão da Transmissão (PET) que não inclua as características estocásticas dessa fonte pode levar a planos com circuitos redundantes. A instalação de reforços capazes de atender a potência instalada nas usinas com aerogeradores pode representar elevados custos de investimento e equipamentos ociosos durante parte da operação do sistema. Em contrapartida, reforçar a rede de transmissão de forma a permitir uma capacidade próxima da média de geração dessas usinas pode proporcionar sobrecarga das linhas e até mesmo requerer cortes de geração. Por influenciar de forma operacional e financeira o sistema elétrico, as variações apresentadas por essa fonte devem ser consideradas na fase de planejamento da transmissão de forma a aproveitar melhor essa energia, permitir uma operação mais flexível e otimizar a destinação de investimentos (Burke and O'Malley, 2008).

O problema do planejamento abordado neste trabalho incorpora as incertezas associadas à geração eólica e tem como objetivo determinar quais e onde deverão ser construídos reforços no sistema de transmissão de energia, atendendo à previsão de demanda e com o menor custo de investimento possível. Esse se mostra como um problema de otimização complexo e de difícil solução. O grande número de elementos existentes e candidatos nos sistemas e a natureza combinatória do processo leva o problema à explosão combinatória, exigindo elevado esforço computacional. Trata-se também de uma questão de programação mista, englobando variáveis reais e inteiras, e de região de solução não convexa, na qual há várias soluções factíveis. Tal característica exige maior esforço por parte dos algoritmos.

Dentre as técnicas utilizadas na solução do PET as meta-heurísticas, e em especial aquelas bioinspiradas, ganham destaque (Gideon Ude et al., 2019). A vantagem principal dessas técnicas está na exploração eficiente do espaço de busca e maior probabilidade de encontro de solução ótima, além de possuírem fácil implementação, o que torna as ferramentas mais acessíveis. Nessa linha de pesquisa, esse trabalho apresenta uma adaptação da meta-heurística *Coyote Optimization Algorithm* (COA), para tratamento de variável binária e, consequentemente, aplicação no PET. As análises são realizadas nos sistemas elétricos Garver, IEEE 24 barramentos e Sul Equivalente do Brasil.

## 2. FORMULAÇÃO MATEMÁTICA DO PET

Nesta seção são apresentadas as modelagens utilizadas no que diz respeito a geração eólica, a formulação do PET considerando as incertezas da geração eólica e a ferramenta de otimização de solução do planejamento da expansão da transmissão.

### 2.1 Modelagem Matemática

O conjunto solução do problema de planejamento da expansão de sistemas de transmissão é composto por circuitos selecionados, dentre um grupo de candidatos, que minimizam os custos de investimento na malha de transmissão e atende às restrições de carregamento das LTs, aos limites de geração dos geradores convencionais e à demanda exigida pelas cargas. Foram inseridos geradores fictícios nas barras de carga do sistema elétrico para evitar possíveis problemas de inviabilidade. Assim, caso os reforços realizados não garantam o atendimento da demanda, esses geradores entram em operação garantindo suprimento de energia para as cargas. Todavia, esses geradores, também chamados de geradores de deficit, têm alto custo operacional, que é incorporado na função objetivo como uma espécie de penalidade, já que sua participação é inversamente proporcional à qualidade da solução avaliada.

A função objetivo do PET é descrita por (1).

$$\text{Min} \sum_{m=1}^{nr} c_m \cdot r_m + \sum_{k=1}^{nc} c_k \cdot PE_k \quad (1)$$

em que:  $nr$  representa o número de barras de carga do sistema,  $c_m$  custo de operação dos geradores fictícios,  $r_m$

potência gerada pelos geradores de deficit,  $nc$  número de circuitos candidatos,  $c_k$  custo de instalação do circuito candidato  $k$  e  $PE_k$  o parâmetro de expansão que dita se um determinado circuito deve ou não ser construído (assumindo valores 0 para a linha não construída ou 1 para a linha a ser construída).

Como é possível verificar em (2), em cada barra  $i$  do sistema elétrico, a soma da potência gerada pelos geradores convencionais  $g_i$ , da potência dos geradores de deficit  $r_i$  e do somatório dos fluxos de potência ativa  $f_{ij}$  entre a barra  $i$  e as barras conectadas  $j$ , deve ser igual à demanda  $d_i$  da barra, resultando em um balanço de potência do sistema.

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

em que  $\Omega_i$  representa o conjunto de barras diretamente conectadas à barra  $i$ .

Para os geradores, as injeções de potência  $g$  dos geradores convencionais devem respeitar os limites de geração da máquina  $g_{max}$ , Eq. (3), bem como as gerações  $r$  dos geradores de deficit e seus limites  $r_{max}$ , Eq. (4). Ainda, o fluxo de potência  $f_{ij}$  nas linhas entre as barras  $i$  e  $j$  não pode violar o limite de carregamento desses circuitos, tanto para o conjunto de circuitos existentes ( $E$ ) quanto para o conjunto de circuitos candidatos ( $C$ ), Eq. (5).

$$0 \leq g \leq g_{max} \quad (3)$$

$$0 \leq r \leq r_{max} \quad (4)$$

$$|f_{ij}| \leq f_{ijmax}, \forall (i, j) \in E, C \quad (5)$$

No planejamento do sistema de transmissão, são usadas estimativas do crescimento da demanda de energia elétrica e as previsões para a capacidade de geração que estará disponível no horizonte de planejamento considerado. A longo prazo, desvios consideráveis são cometidos nesta estimativa. Nessas condições, na fase inicial de planejamento, procura-se determinar a capacidade de transmissão que garanta o transporte de potência ativa com certo nível de flexibilidade e segurança. Por outro lado, a busca por uma solução que minimize os investimentos analisa um grande número de alternativas, exigindo o uso de um algoritmo de fluxo de potência que, mesmo quando repetido um elevado número de vezes, não torne proibitivo o tempo de computação. Usam-se, então, equações linearizadas para o fluxo de carga que, tendo em vista todas as estimativas envolvidas na concepção do sistema elétrico, não aumentam significativamente os erros cometidos no planejamento. Esse modelo baseia-se no acoplamento entre a potência ativa e a abertura angular entre as barras e não leva em consideração as magnitudes das tensões nodais - que são adotadas como 1 pu - as potências reativas e os taps dos transformadores, deixando os problemas de compensação de reativos e da regulação de tensão para fases posteriores do planejamento. Essas limitações impedem que esse modelo seja usado de forma generalizada em outros problemas corriqueiros de fluxo de carga, mas mostra-se muito útil em fases preliminares de estudos, em especial aqueles que envolvem análises de elevados números de casos (Mendonça et al., 2011).

Com isso, o fluxo  $f_{ij}$  entre as barras  $i$  e  $j$  é tratado como o produto entre o inverso da reatância do circuito,  $\gamma_{ij}$ , e

a abertura angular  $\theta_{ij}$  das barras da extremidade, como mostrado na Eq. (6). Para os circuitos candidatos, a Eq. (7) descreve que a contribuição é contabilizada apenas se seu parâmetro de expansão  $PE$  for igual a 1, ou seja, se a linha for escolhida para construção.

$$f_{ij} = \gamma_{ij} \cdot \theta_{ij}, \forall (i, j) \in E \quad (6)$$

$$f_{ij} = PE_{ij} \cdot \gamma_{ij} \cdot \theta_{ij}, \forall (i, j) \in C \quad (7)$$

## 2.2 Geração Eólica

Para incorporar o caráter intermitente, os aerogeradores foram modelados tal como no trabalho (Moraes et al., 2020), como cenários de geração e suas respectivas probabilidades de ocorrência. Os autores utilizaram dados da região nordeste do Brasil, disponibilizados pelo Operador Nacional do Sistema (ONS), amostrados em intervalos de uma hora durante os meses de janeiro e dezembro de 2015. Para o agrupamento desses dados em cenários, foi utilizada a técnica de clusterização K-means. Esse método objetiva subdividir um conjunto de  $n$  elementos em  $k$  grupos, de forma que cada amostra do conjunto seja associada um grupo com elementos semelhantes. Para aplicação do método, é preciso definir, inicialmente, o número de agrupamentos desejados e escolher, aleatoriamente, um centroide para cada grupo. Em seguida, deve-se calcular para cada ponto do conjunto disponível o centroide de menor distância e associar o ponto analisado ao grupo relacionado ao centroide mais próximo. Após avaliar todos os elementos, reposicionam-se os centroides a partir da média da posição de todos os pontos do respectivo agrupamento e repete-se o processo até que seja obtida a posição ideal dos centroides (Morissette and Chartier, 2013). Após a realização do processo, os dados de geração eólica foram divididos em cinco cenários e são apresentados na Tabela 1.

Tabela 1. Cenários de geração e probabilidade de ocorrência (Moraes et al., 2020)

Geração Eólica (pu)	Probabilidade de Ocorrência
0.1807	14.59
0.3458	26.63
0.4779	28.02
0.6176	19.37
0.7788	11.39

A capacidade máxima de cada unidade geradora inserida na barra  $i$  foi modelada com um peso 10% da carga total ( $D$ ) instalada no sistema elétrico. Todavia, o valor total de inserção de eólica pelo aerogerador, dado pela Eq. 8, é inferior à capacidade máxima e é obtido por meio de uma média ponderada dos patamares de geração  $pw$  e suas probabilidades de ocorrência ( $\phi$ ) apresentados na Tabela 1.

$$z_i = \frac{10}{100} \cdot D \cdot \frac{\sum pw \cdot \phi}{\sum \phi} \quad (8)$$

## 2.3 Formulação do PET considerando a Geração Eólica

Como anteriormente mencionado, o conjunto solução do planejamento da expansão de sistemas de transmissão é composto por circuitos selecionados, dentre um grupo de

candidatos, que minimizam os custos de investimento na malha de transmissão e atende às restrições de carregamento das LTs, à demanda exigida pelas cargas e a limites de geração dos geradores convencionais.

Para cada cenário de geração eólica  $\omega \in W$ , a Eq. (9) mostra que, em cada barra, a soma da potência gerada pelos geradores convencionais  $g_{i,\omega}$ , da potência dos geradores de déficit  $r_{i,\omega}$  e do fluxo de potência ativa  $f_{ij,\omega}$  entre as barras  $i$  e  $j$ , deve ser igual à demanda  $d_{i,\omega}$  da barra subtraída da potência do aerogerador ali alocado  $z_i$ .

$$g_{i,\omega} + r_{i,\omega} + \sum_{j \in \Omega_i} f_{ij,\omega} = d_{i,\omega} - z_i, \forall \omega \in W \quad (9)$$

A representação dos cenários de geração eólica fornece uma solução mais realista do problema do PET, pois é capaz de retratar a característica intermitente da fonte de energia eólica.

## 2.4 Ferramenta de Solução do PET

Por ter um número elevado de variáveis e diversos mínimos locais, os métodos de otimização por população apresentam melhor desempenho quando comparados aos métodos de otimização numéricos clássicos no problema da expansão da transmissão. Para definição do método a ser utilizado, comparam-se os desempenhos dos algoritmos *Differential Evolution* (DE), *Particle Swarm Optimization* (PSO) e *Coyote Optimization Algorithm* (COA).

O DE (Price, 2013) é um algoritmo evolucionário que não é inspirado no comportamento animal. A ideia principal do algoritmo é gerar novos indivíduos, chamados vetores modificados, pela adição da diferença vetorial entre dois indivíduos aleatórios da população a um terceiro indivíduo, por um processo chamado mutação. As componentes deste novo indivíduo - chamado de doador - são misturadas com as componentes de um indivíduo escolhido aleatoriamente - chamado de vetor alvo. Esse processo de misturar componentes é chamado de cruzamento e resulta no denominado vetor experimental. Se o custo do vetor experimental for inferior ao custo do vetor alvo, então o vetor experimental será o vetor alvo da geração seguinte, operação essa chamada de seleção.

Já o PSO (Kennedy and Eberhart, 1995) é motivado pelo comportamento de bandos de pássaros e cardumes. Os indivíduos dessa população são designados partículas e se movimentam dentro de um espaço de busca. Cada partícula possui associada uma posição e uma velocidade, que serão atualizadas com o tempo de acordo com suas próprias experiências e com as experiências do restante do bando. A melhor posição já alcançada por qualquer partícula, chamada de melhor pessoal, é guardada e também é comunicada ao restante da população inteira. Isso influencia o movimento do bando em direção à melhor região detectada até o momento, denominada melhor global. O processo também é encerrado por meio de algum critério de parada.

O COA (Pierezan and Coelho, 2018) também é classificado como algoritmo bioinspirado e é motivado pelo comportamento social de coiotes. Cada coiote tem uma condição social associada, que é utilizada para avaliar sua aptidão em

relação à função objetivo, e uma idade. Os indivíduos são organizados em matilhas e o coioite mais bem adaptado de cada bando é denominado de alpha. Além disso, é definida a tendência cultural da matilha, dada pela mediana das condições sociais dos coioites que constituem esse grupo. A cada geração nascem novos coioites, cuja sobrevivência será ditada se o desempenho desse novo indivíduo for melhor que o de algum coioite já existente na matilha. Em caso positivo, o coioite mais velho dentre os menos adaptados é substituído pelo novo coioite. É possível, ainda, a migração de indivíduos entre as matilhas, resultando em um intercâmbio cultural da população global.

A população de coioites é dividida em  $N_m$  matilhas de  $N_p$  coioites, sendo o tamanho da população dado por  $N_m \times N_p$ . A condição social de um coioite  $c$  da matilha  $m$  representa uma possível solução para o problema de otimização no instante  $t$ , dada pela Eq. 10.

$$soc_c^m(t) = (s_1, s_2, s_3, \dots, s_N) \quad (10)$$

em que  $N$  representa a dimensão do problema, nesse caso dado pela quantidade de linhas candidatas.

A condição social da primeira geração da população é inicializada aleatoriamente com valores binários e é avaliada pelo custo da função objetivo. Os coioites são distribuídos de forma estocástica entre as matilhas mas podem, por vezes, migrar para outra matilha ou se tornar um indivíduo solitário. A evasão de um coioite ocorre com probabilidade  $P_e$  dada pela Eq. 11.

$$P_e = 0.005N_c^2 \quad (11)$$

A migração entre matilhas auxilia na diversificação da população e promove um intercâmbio cultural entre os elementos. Cada matilha é liderada por um coioite *alpha*, que representa a melhor solução encontrada pelo grupo naquele momento. Ainda, o COA assume que os coioites são organizados a ponto de compartilhar as condições sociais entre si e contribuir para a sobrevivência da matilha. Dessa forma, é definida a tendência social da matilha, calculada pela mediana das condições sociais dos coioites das matilhas no tempo  $t$ .

Os dois eventos principais da vida de um coioite são o nascimento e morte e, para isso, o COA leva em consideração a idade dos coioites. O nascimento de um novo coioite é descrito pela combinação das condições sociais dos pais  $p_1$  e  $p_2$  escolhidos de forma aleatória dentro da matilha. O elemento  $s_j$  da condição social do filhote pode ser descrita pela Eq. 12.

$$s_j^{filho} = \begin{cases} s_j^{p_1}, & \text{se } rand < P_s \\ s_j^{p_2}, & \text{se } rand \geq P_s + P_a \\ R, & \text{caso contrário.} \end{cases} \quad (12)$$

em que  $P_s$  é a probabilidade de dispersão,  $P_a$  a probabilidade de associação,  $R$  um valor binário escolhido aleatoriamente e  $rand$  um número real entre 0 e 1 gerado de forma aleatória.

As probabilidades de dispersão e associação são definidas pelas Eq. 13 e Eq. 14.

$$P_s = \frac{1}{N} \quad (13)$$

$$P_a = \frac{1 - P_s}{2} \quad (14)$$

Para manter o tamanho das matilhas, o nascimento e morte dos coioites é sincronizado. Após avaliar o desempenho do filhote, selecionam-se os coioites da matilha menos adaptados que o filhote e o mais velho desse conjunto é substituído pelo coioite recém gerado.

O COA considera a influência do coioite alpha e da tendência cultural da matilha sobre os coioites. Define-se a melhor condição social do coioite alpha como  $soc^{alpha}$  e a tendência da matilha como  $soc^{tend}$ . O valor  $\zeta_1$  corresponde à diferença entre o coioite alpha e um coioite ( $cr_1$ ), enquanto o valor  $\zeta_2$  corresponde à diferença entre a tendência cultural da matilha e um coioite ( $cr_2$ ). Os coioites  $cr_1$  e  $cr_2$  são escolhidos dentro da matilha de forma aleatória e os valores  $\zeta_1$  e  $\zeta_2$  são definidos pelas Eq. 15 e Eq. 16.

$$\zeta_1 = soc^{alpha}(t) - soc^{cr_1}(t) \quad (15)$$

$$\zeta_2 = soc^{tend}(t) - soc^{cr_2}(t) \quad (16)$$

A condição social do coioite, que representa nesse problema o parâmetro de expansão das linhas, é então atualizada em função das influências do coioite alpha e da matilha, como mostrado na Eq.17.

$$soc_{new}(t) = soc_c^m(t) + r_1 \cdot \zeta_1 + r_2 \cdot \zeta_2 \quad (17)$$

em que  $r_1$  e  $r_2$  são dois pesos gerados de forma aleatória com distribuição uniforme dentro do intervalo  $[0,1]$ . O valor obtido é transformado para a forma binário a partir das Eq. 18 e Eq. 19 e, então, avalia-se a nova condição social, aplicando-a na função objetivo. Caso essa apresente um desempenho melhor que o atual estado do coioite, a condição social do coioite é substituída pelo resultado encontrado na Eq. 17.

Por fim, a condição social do coioite melhor adaptado é selecionado como solução global do sistema. O pseudocódigo do COA é descrito no Algoritmo 1.

---

#### Algorithm 1 Pseudocódigo do COA

---

- 1: Inicialização das  $N_c$  coioites e  $N_m$  matilhas
  - 2: Avaliação da condição social dos coioites
  - 3: **while** critério de parada não for atendido **do**
  - 4:     **for** cada matilha  $m$  **do**
  - 5:         Selecione o *alpha* da matilha
  - 6:         Calcule a tendência social da matilha
  - 7:         **for** cada coioite  $c$  da matilha  $m$  **do**
  - 8:             Atualize a condição social
  - 9:             Avalie a nova condição social
  - 10:             Avalie a adaptação da nova solução
  - 11:         **end for**
  - 12:         Avaliação do nascimento e morte dos coioites
  - 13:     **end for**
  - 14:     Transição entre matilhas
  - 15:     Atualiza a idade dos coioites
  - 16: **end while**
  - 17: Seleção do coioite mais adaptado
-

Como sistema teste para comparação do desempenho dos algoritmos foi utilizado o sistema IEEE- 24 barras e foram realizadas 35 simulações, com populações de 80 indivíduos e critério de parada de 100 iterações. Ainda, como o parâmetro de expansão tem natureza binária, esses métodos, originalmente desenvolvidos para a solução de problemas contínuos, devem ser adaptados para o tratamento de variáveis inteiras. Esse tratamento foi realizado por meio de uma função sigmoide (Nepomuceno et al., 2020), já que este método é de simples implementação e apresenta um resultado melhor que o arredondamento direto. Para um vetor solução  $\vec{X}(t)$ , o elemento contínuo  $x_i$  é discretizado por meio das Eq. (18) e Eq. (19).

$$sig(x_i) = \frac{1}{1 + e^{-10(x_i - 0.5)}} \quad (18)$$

$$x_i = \begin{cases} 1, & \text{se } sig(x_i) > \text{que rand} \\ 0, & \text{caso contrário.} \end{cases} \quad (19)$$

em que *rand* é um número gerado aleatoriamente com distribuição uniforme amostrado no intervalo [0, 1]. A Fig. 1 mostra o comportamento da Eq. 18.

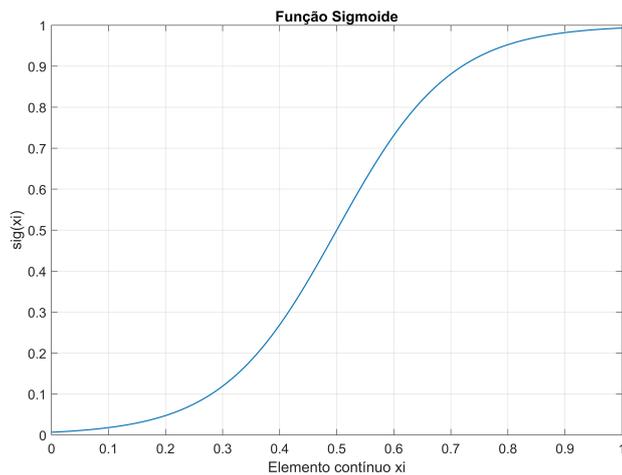


Figura 1. Função sigmoide no intervalo [0, 1].

Após as simulações propostas foi possível elaborar o diagrama de dispersão apresentado na Fig. 2. Verifica-se que o COA apresentou melhor desempenho dentre os métodos comparados, já que foi capaz de alcançar o mínimo global conhecido na literatura e ainda apresenta a menor dispersão entre os métodos com um custo computacional ligeiramente menor (DE: 1,5708 min, PSO: 1,6833 min, COA: 1,4791 min), justificando a escolha por esse algoritmo.

### 3. RESULTADOS

Nesta seção a modelagem apresentada na seção 2 será resolvida com o auxílio do algoritmo COA. Os parâmetros adotados no planejamento clássico, bem como no planejamento considerando incertezas, foram os mesmos utilizados na seção 2.4 para a comparação entre os algoritmos, a saber: 35 simulações por sistema elétrico, com 80 indivíduos e 100 iterações.

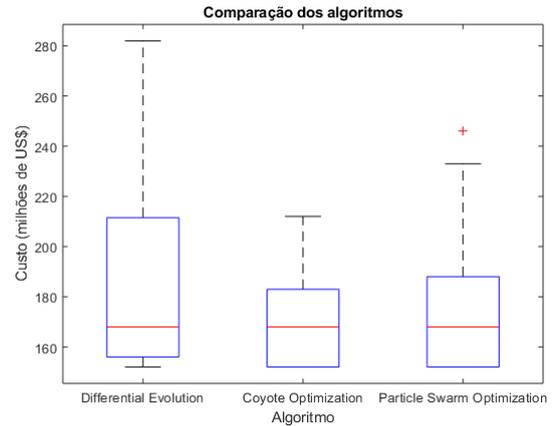


Figura 2. Comparação entre os métodos de otimização.

#### 3.1 Planejamento Clássico

Para gerar os casos de referência, avaliaram-se os planos de expansão sem inclusão dos aerogeradores para os sistemas elétricos Garver 6 barras, Sistema IEEE-24 barras e Sistema Sul Equivalente do Brasil 46 barras. Todos os sistemas estudados consideram redespacho dos geradores convencionais e trabalham com conjuntos reduzidos de circuitos candidatos, já que utilizar os conjuntos disponíveis na íntegra podem levar tanto a problemas de explosão combinatória quanto estagnação do algoritmo em torno de mínimos locais. Como não é foco desse trabalho desenvolver uma metodologia de redução de circuitos candidatos, utilizou-se de conjuntos reduzidos disponíveis para os sistemas estudados, retirados de (Moraes, 2020) e (de Mendonça et al., 2016), em que é permitido para cada rota candidata construir até 3 circuitos. Foram avaliados também os impactos de patamares de carga nos planos de expansão (Zhuo et al., 2019; Borges and Martins, 2012).

- Carga leve: Demanda = 60% da carga projetada
- Carga média: Demanda = 80% da carga projetada
- Carga pesada: Demanda = 100% da carga projetada

O sistema Garver (Garver, 1970) é composto por 6 barras, 6 linhas de transmissão existentes e 3 geradores. A carga instalada no sistema é de 760 MW. A Tabela 2 apresenta as rotas candidatas à expansão, podendo ser construídos até 3 circuitos por rota. A notação 1 (2-3) significa que foi construída uma linha do ramo (2-3), enquanto que 3 (4-6) significa na construção das três linhas possíveis no ramo (4-6). Já a Tabela 3 apresenta os planos de expansão por patamar de carga para esse sistema.

Tabela 2. Rotas candidatas - Sistema Garver

Conjunto de linhas candidatas - Sistema Garver
2 - 3; 2 - 6; 3 - 5; 4 - 6

Tabela 3. Resultados para o Sistema Garver

Patamar de carga	Rotas escolhidas	Custo (US\$ x 10 <sup>6</sup> )
Carga leve	1 (2 - 3)	20,00
Carga média	1 (3 - 5), 1 (2 - 3)	70,00
Carga pesada	3 (4 - 6), 1 (3 - 5)	110,00

O sistema IEEE 24-Barras (Moraes, 2020) tem 38 linhas de transmissão e 10 geradores. A carga total instalada é de 8550 MW. A Tabela 4 apresenta as rotas candidatas a

expansão, a Tabela 5 apresenta os planos de expansão por patamar de carga para esse sistema.

Tabela 4. Rotas candidatas - Sistema IEEE - 24 barras

Conjunto de linhas candidatas - Sistema IEEE - 24 barras
1 - 5; 3 - 24; 4 - 9; 6 - 10; 7 - 8; 11 - 13; 10 - 12; 12 - 13; 14 - 16; 15 - 24; 16 - 17

Tabela 5. Resultados para o Sistema IEEE - 24 barras

Patamar de carga	Rotas escolhidas	Custo (US\$ x 10 <sup>6</sup> )
Carga leve	1 (7-8)	16,00
Carga média	1 (1-5)	22,00
Carga pesada	1 (6-10); 2 (7-8) 1 (10-12); 1 (14-16)	152,00

A configuração básica do sistema Sul Equivalente do Brasil (Romero et al., 2002) tem 46 barras, 66 linhas de transmissão, 12 geradores e carga instalada de 6880 MW. A Tabela 6 apresenta as rotas candidatas à expansão, podendo ser construídas até 3 reforços por rota. Foi acrescentada ao conjunto de candidatos a rota 13 - 20, que não constava inicialmente no proposto em (de Mendonça et al., 2016). A inclusão desse circuito possibilita que o algoritmo encontre a combinação referente ao plano de expansão ótimo conhecido na literatura (Moraes, 2020). Já a Tabela 7 apresenta os planos de expansão por patamar de carga para esse sistema.

Tabela 6. Rotas candidatas - Sistema Sul Equivalente do Brasil

Conjunto de linhas candidatas - Sistema Sul Equivalente do Brasil
5-6; 9-14; 13-18; 13-20; 19-25; 26-29; 14-15; 27-29; 20-21; 20-23; 24-25; 28-31; 28-30; 29-30; 31-32; 32-43; 40-45; 42-43; 46-6

Tabela 7. Resultados para o sistema Sul Equivalente

Patamar de carga	Rotas escolhidas	Custo (US\$ x 10 <sup>6</sup> )
Carga leve	1 (20-21)	8,178
Carga média	1 (20-21); 1 (42-43); 1 (46-6); 1 (5-6)	40,539
Carga pesada	1 (20-23); 1 (13-20); 2 (20-21); 1 (42-43) 1 (46-6); 2 (5-6)	70,289

Observa-se que, em todos os casos, quanto maior a demanda, maiores são os investimentos necessários para atingir o equilíbrio energético do sistema elétrico. Apesar da relação linear adotada para formação dos patamares de carga, isso é, as demandas definidas como uma porcentagem da carga projetada, os planos de expansão e os custos de investimento para implantação dos reforços não seguem a mesma lei de formação, evidenciando a natureza não linear do problema. Além disso, para as condições de carga pesada, equivalentes à demanda igual à carga instalada, os resultados encontrados para os sistemas Garver, IEEE - 24 barras e Sul equivalente do Brasil estão em conformidade com os planejamentos ótimos conhecidos na literatura correspondente (Moraes, 2020), (Mendonça et al., 2011). Ressalta-se, ainda, a eficiência do algoritmo utilizado, capaz de convergir para as soluções ótimas rapidamente sem demandar um número tão elevado de indivíduos e

iterações, a saber: Sistema Garver: 0,2261 min, Sistema IEEE - 24 barras: 1,3209 min e Sistema Sul equivalente: 4,3456 min.

### 3.2 Planejamento com Incertezas

As incertezas da geração eólica foram modeladas segundo a Tabela 1 e Eq. 8 e os aerogeradores foram inseridos em barras de cargas. Para o Sistema IEEE-24 barras, os geradores foram alocados nos mesmos locais que o trabalho (Moraes et al., 2020), enquanto que nos Sistemas Garver e Sul Equivalente do Brasil os aerogerados foram alocados nas barras mais carregadas do sistema. São compiladas na Tabela 8 as informações referentes aos barramentos selecionados para instalação dos aerogeradores e a potência modelada de cada gerador eólico. Os sistemas avaliados levam em consideração uma demanda igual à carga projetada e os resultados encontrados serão comparados aos resultados de carga pesada do planejamento clássico.

Tabela 8. Geradores eólicos inseridos

Sistema elétrico	Barras escolhidas	Capacidade (MW)
Garver	2 e 5	35,01
IEEE - 24 barras	3 e 20	394,35
Sul Equivalente	20 e 42	316,96

Nas Tabelas 9 e 10 são comparados os planos de expansão encontrados e seus respectivos custos de implantação para os cenários sem e com aerogeradores. Cabe enfatizar que os valores consideram apenas os reforços no sistema de transmissão e que os custos de implantação e operação dos aerogeradores não foram contabilizados. Os tempos médios para conclusão das simulações foram: Sistema Garver: 0,1957 min, Sistema IEEE - 24 barras: 1,1678 min e Sistema Sul Equivalente: 3,9065 min.

Observa-se que, para todos os sistemas simulados, os planos de expansão considerando a inclusão de aerogeradores apresentaram reforços menos onerosos para o sistema de transmissão. Ao incluir a geração eólica nas barras de cargas reduz-se o fluxo circulante nas linhas do sistema elétrico, sendo necessário, conseqüentemente, menos reforços nos sistemas de transmissão. No sistema Garver, os reforços escolhidos para o cenário com incertezas apresentam apenas um circuito similar ao cenário sem os aerogeradores, (3-5), e o sistema Sul Equivalente apresenta dois circuitos, (20-23) e (5-6). Isso torna evidente a natureza não linear do problema, já que foi possível encontrar uma nova combinação que atendesse às restrições do problema e resultasse em custo de implantação reduzido. Já no sistema IEEE - 24 barras, um dos circuitos entre as barras 7 e 8, apresentados no primeiro plano de expansão, torna-se obsoleto na presença da geração eólica.

Tabela 9. Comparação entre os planos de expansão

Sistema	Sem aerogerados	Com aerogeradores
Garver	3 (4 - 6); 1 (3 - 5)	2 (2 - 6); 1 (3 - 5); 1 (2 - 3)
24 barras	1 (6 - 10); 2 (7 - 8) 1 (10 - 12); 1 (14 - 16)	1 (6 - 10); 1 (7 - 8) 1 (10 - 12); 1 (14 - 16)
Sul	1 (20 - 23); 1 (13 - 20); 2 (20 - 21); 1 (27 - 29) 1 (46 - 6); 2 (5 - 6)	1 (9 - 14); 2 (14 - 15) 1 (20 - 23); 1 (31 - 32) 1 (5 - 6)

Tabela 10. Comparação dos custos de implantação de reforços

Sistema elétrico	Sem aerogerados (US\$ x 10 <sup>6</sup> )	Com aerogeradores (US\$ x 10 <sup>6</sup> )
Garver	110,00	100,00
IEEE - 24 barras	152,00	136,00
Sul Equivalente	70,289	53,393

#### 4. CONCLUSÃO

Neste trabalho foi utilizado *Coyote Optimization Algorithm* para a solução do problema de planejamento da expansão de sistemas de transmissão de energia elétrica considerando incertezas relacionadas à intermitência da geração eólica. Essa característica foi tratada a partir da técnica de clusterização K-means, associando a cada cenário de geração uma probabilidade de ocorrência.

Em um primeiro momento foi tratado o planejamento sem incertezas e da consideração de três possíveis patamares de carga, avaliando a metodologia para os sistemas Garver, IEEE - 24 barras e o sistema Sul Equivalente do Brasil. Os resultados encontrados são coerentes e estão de acordo com os resultados disponíveis na literatura, mostrando que o algoritmo utilizado é eficaz.

Em um segundo momento, considerou-se a adição de dois parques eólicos a cada um dos sistemas elétricos estudados. Em todos os casos, há redução dos custos de implantação de reforços nos sistemas de transmissão. Nos sistemas Garver e Sul Equivalente do Brasil são encontradas novas combinações de linhas e no sistema IEEE - 24 barras há a evidência de circuito que se torna redundante após a inclusão dos aerogeradores.

Com isso, mostra-se pertinente considerar fontes intermitentes de energia no planejamento da transmissão, pois essa condição pode resultar em planos de implantação de reforços menos onerosos e contribuir para um sistema elétrico que opere de forma mais confiável e flexível.

Como propostas de continuação, pode-se levar em consideração cenários de contingência e critérios de confiabilidade, avaliação de outras modelagens para os aerogeradores e alocação de unidades de geração distribuída e o planejamento dinâmico do sistema de transmissão.

#### AGRADECIMENTOS

Os autores agradecem ao PPGEL/CEFET-MG pelo auxílio financeiro.

#### REFERÊNCIAS

Borges, C.L.T. and Martins, V.F. (2012). Multistage expansion planning for active distribution networks under demand and distributed generation uncertainties. *International Journal of Electrical Power & Energy Systems*, 36(1), 107–116.

Burke, D.J. and O'Malley, M. (2008). Optimal wind power location on transmission systems—a probabilistic load flow approach. In *Proceedings of the 10th International Conference on Probabilistic Methods Applied to Power Systems*, 1–8. IEEE.

de Mendonça, I.M., Junior, I.C.S., Dias, B.H., and Marcato, A.L. (2016). Identification of relevant routes for

static expansion planning of electric power transmission systems. *Electric Power Systems Research*, 140, 769–775.

Garver, L.L. (1970). Transmission network estimation using linear programming. *IEEE Transactions on Power Apparatus and Systems*, (7), 1688–1697.

Gideon Ude, N., Yskandar, H., and Graham, R. (2019). A comprehensive state-of-the-art survey on the transmission network expansion planning optimization algorithms. *IEEE Access*, 7(1), 123158–123181.

Kennedy, J. and Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95-international conference on neural networks*, volume 4, 1942–1948. IEEE.

Mendonça, I., Junior, I.S., Moreira, T., Marcato, A.L., Dias, B.H., and Oliveira, E. (2011). Planejamento estático da expansão de sistemas de transmissão de energia elétrica via otimização por enxame de partículas. *XLIII Simpósio Brasileiro de Pesquisa Operacional, XLIII SBPO, Ubatuba, SP*.

Moraes, C.A. (2020). *Planejamento de sistemas de transmissão considerando restrições de segurança, potência reativa e incertezas sobre carga e geração eólica*. Ph.D. thesis, Universidade Federal do Juiz de Fora.

Moraes, C.A., de Oliveira, E.J., Botelho, D.F., de Oliveira, L.W., and Pinto, M.F. (2020). Wind generation impact in transmission expansion planning. *Journal of Control, Automation and Electrical Systems*, 31(1), 247–256.

Morissette, L. and Chartier, S. (2013). The k-means clustering technique: General considerations and implementation in mathematica. *Tutorials in Quantitative Methods for Psychology*, 9(1), 15–24.

Nepomuceno, L.S., de Paula, A.N., and de Oliveira, E.J. (2020). Otimização via hiena-malhada aplicado ao planejamento da expansão da transmissão considerando contingência e geração de energia eólica. *Anais da Sociedade Brasileira de Automática*, 2(1).

Pierezan, J. and Coelho, L.D.S. (2018). Coyote optimization algorithm: a new metaheuristic for global optimization problems. In *2018 IEEE congress on evolutionary computation (CEC)*, 1–8. IEEE.

Price, K.V. (2013). Differential evolution. In *Handbook of optimization*, 187–214. Springer.

Romero, R., Monticelli, A., Garcia, A., and Haffner, S. (2002). Test systems and mathematical models for transmission network expansion planning. *IEEE Proceedings-Generation, Transmission and Distribution*, 149(1), 27–36.

Vallim, A.N., Dutra, R., and Júnior, A. (2016). *Perpectivas da Geração eólica no Brasil: A questão da transmissão com enfoque nas instalações compartilhadas de geração*. Ph.D. thesis, Universidade Federal do Rio de Janeiro.

Yu, H., Chung, C., Wong, K., and Zhang, J. (2009). A chance constrained transmission network expansion planning method with consideration of load and wind farm uncertainties. *IEEE Transactions on Power Systems*, 24(3), 1568–1576.

Zhuo, Z., Du, E., Zhang, N., Kang, C., Xia, Q., and Wang, Z. (2019). Incorporating massive scenarios in transmission expansion planning with high renewable energy penetration. *IEEE Transactions on Power Systems*, 35(2), 1061–1074.