

## Planejamento da Expansão de Sistemas Elétricos de Transmissão via Algoritmo Genético com Estratégias de Diversidade

Pedro G. Lopes\* Fernando A. Assis\* Marco Aurélio O. Schroeder\*  
Rodolfo A. R. Moura\* Antônio E. Assis\*\*

\* Departamento de Engenharia Elétrica, Universidade Federal de São  
João del-Rei, UFSJ, São João del-Rei, MG, Brasil (e-mails:  
gentilpedrol@gmail.com, fernandoassis@ufs.edu.br,  
schroeder@ufs.edu.br, moura@ufs.edu.br).

\*\* Companhia Energética de Minas Gerais, Cemig, Belo Horizonte,  
MG, Brasil (e-mails: aeassis84@gmail.com).

---

**Abstract:** Transmission expansion planning (TEP) is an important study among the various electrical power system activities. However, solving the optimization problem resulting from TEP studies for real large electrical systems is a complex task, which involves the analysis of a large space of solutions. In this sense, the present work proposes the investigation of diversity strategies combined with the meta-heuristic Genetic Algorithm (GA) to solve the TEP problem. The Deterministic Crowding and K-means techniques are used to create different versions of GA with population diversity. A real and present-day electrical system, which corresponds to the geoelectric region of southern Brazil, is used to carry out performance studies and analyze the use of different diversity strategies.

**Resumo:** O planejamento da expansão da transmissão (PET) configura um importante estudo dentre as diversas atividades realizadas em um sistema elétrico de potência. No entanto, solucionar o problema de otimização decorrente dos estudos PET para sistemas elétricos reais de grande porte é uma tarefa complexa, que envolve a análise de um grande espaço de soluções. Neste sentido, o presente trabalho propõe a investigação de estratégias de diversidade combinadas à metaheurística Algoritmo Genético (AG) para solução eficiente do problema PET. As técnicas *Deterministic Crowding* e *K-means* são utilizadas para criar diferentes versões do AG com diversidade populacional. Um sistema elétrico real e atual, que corresponde à região geoeletrica sul do Brasil, é utilizado para realizar os estudos de desempenho e analisar o emprego de diferentes estratégias de diversidade.

**Keywords:** Transmission expansion planning; Optimization; Genetic Algorithm; Diversity; Deterministic Crowding; K-means.

**Palavras-chaves:** Planejamento da Expansão da Transmissão; Otimização; Algoritmo Genético; Diversidade; *Deterministic Crowding*; *K-means*.

---

### 1. INTRODUÇÃO

Com o aumento da demanda por energia elétrica e mudanças no perfil dos consumidores, há uma necessidade constante de expandir e otimizar o uso de recursos nos sistemas elétricos de potência. Dentre esses recursos, destaque pode ser dado às redes de transmissão, que são responsáveis, basicamente, por interligar a geração às cargas, permitindo o aproveitamento otimizado de fontes energéticas do sistema e equalizando os custos e oportunidades para produtores e consumidores. Nesse contexto, o estudo do planejamento da expansão da transmissão (PET) baseia-se em determinar, ao menor custo possível, as modificações (ampliações e reforços) a serem realizadas na rede de transmissão a fim de que ela continue cumprindo seus objetivos frente

à demanda prevista para um horizonte futuro de estudo (Gomes e Saraiva, 2019).

O PET é classificado como um problema de otimização de natureza não linear com variáveis de decisão inteiristas. Solucionar esse problema não é uma tarefa simples, uma vez que, dadas as dimensões e características dos sistemas atuais, é necessário lidar com um grande número de possíveis soluções (alternativas de expansão) e elevados níveis de incertezas (p. ex., disponibilidade de fontes primárias de energia) (Gomes e Saraiva, 2019). Diversos trabalhos da literatura relacionada vêm propondo metodologias e estratégias para enfrentar esse problema. Dentre esses trabalhos, destaque pode ser dado ao emprego das metaheurísticas de otimização (Zhang et al., 2019; Assis et al., 2021), que apresentam uma boa relação de custo-benefício em relação ao esforço de implementação envolvido e à qualidade das soluções identificadas para o pro-

---

\* Este trabalho foi financiado pela Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

blema. Contudo, a depender das dimensões dos sistemas, nem mesmo as técnicas metaheurísticas garantem a identificação de boas soluções para o PET. Portanto, estratégias eficientes devem ser incorporadas a essas técnicas a fim de garantir a robustez da ferramenta e, conseqüentemente, a identificação de planos de expansão de boa qualidade.

Nesse contexto, de busca por ferramentas de otimização eficientes e capazes de solucionar o problema PET para sistemas elétricos de grandes dimensões, o presente trabalho se propõe à investigação de diferentes estratégias de diversidade incorporadas à metaheurística Algoritmo Genético (AG). Basicamente, utilizam-se duas estratégias baseadas em diferentes técnicas de diversidade: *Deterministic Crowding* (Mahfoud, 1995) e *K-means* (Jain, 2010). Essas estratégias são implementadas e empregadas separadamente e, também, em conjunto, formando diferentes versões da ferramenta AG. Para avaliar o desempenho das versões obtidas, o problema PET é solucionado para um sistema elétrico brasileiro atual e de grande porte, considerando o atendimento do critério determinístico de segurança “N-1” (Assis et al., 2021). Vale ressaltar que o atendimento deste critério aumenta consideravelmente a complexidade de solução do problema.

## 2. PLANEJAMENTO DA EXPANSÃO DA TRANSMISSÃO

Basicamente, solucionar um PET significa resolver um problema de otimização que busca minimizar uma função objetivo normalmente relacionada a custos (p. ex., investimento e operação). Restrições técnicas, ambientais, sociais, políticas e de mercado devem ser avaliadas na solução deste problema (Gomes e Saraiva, 2019).

### 2.1 Modelo do Problema PET

A definição das estratégias de abordagem do problema PET está intimamente relacionada ao horizonte de análise. Quanto mais distante o horizonte temporal, maior o nível de incertezas associado ao problema (p. ex., incertezas da carga e da geração) e, portanto, maior é o conjunto de opções de reforços a ser avaliado. À medida que o horizonte de planejamento diminui, com o decréscimo das incertezas e da quantidade de opções de reforços mais atrativos, modelos mais completos, que considerem, por exemplo, a representação dos suportes de reativos na rede, devem ser utilizados (Rider et al., 2007).

No presente trabalho, o problema PET é tratado no horizonte de longo prazo, com empregado do Modelo Linearizado (Assis et al., 2021):

$$\text{Min. } z = \sum_{ij \in \Omega_c} c_{ij}^{inv} n_{ij} + \sum_{k \in \Omega_g} c_k^g g_k + \sum_{m \in \Omega_l} c_m^r r_m \quad (1)$$

$$\text{s.a.: } g + B\theta + r = d \quad (2)$$

$$f_{ij} - B_{ij} (n_{ij}^0 + n_{ij}) \theta_{ij} = 0, \quad \forall (ij) \in \Omega_b \quad (3)$$

$$|f_{ij}| \leq (n_{ij}^0 + n_{ij}) f_{ij}^{\max}, \quad \forall (ij) \in \Omega_b \quad (4)$$

$$g^{\min} \leq g \leq g^{\max} \quad (5)$$

$$0 \leq n_{ij} \leq n_{ij}^{\max}, \quad \forall (ij) \in \Omega_c \quad (6)$$

$$0 \leq r \leq d \quad (7)$$

em que:  $z$  é a função objetivo que se busca minimizar;  $\Omega_c, \Omega_g, \Omega_l$  e  $\Omega_b$  correspondem, respectivamente, aos conjuntos de ramos candidatos ao reforço da rede, de barras de geração, de barras de carga e de ramos da rede;  $c_{ij}^{inv}$  é o custo de se construir um circuito no ramo  $i - j$ ;  $n_{ij}$  armazena o número de reforços no ramo  $i - j$  para uma determinada decisão de investimento  $n$ ;  $c_k^g$  é o custo de geração da barra  $k$ ;  $g_k$  é a geração na barra  $k$ ;  $c_m^r$  é o custo do corte de carga na barra de carga  $m$ ;  $r_m$  é o corte verificado na barra de carga  $m$ ;  $g$  é o vetor de gerações;  $B$  é a matriz de susceptâncias com componente  $B_{ij}$  correspondente ao ramo  $i - j$ ;  $\theta$  é o vetor de ângulos das tensões nodais;  $r$  é o vetor de gerações fictícias que representam os cortes de carga;  $d$  é o vetor de demanda;  $f_{ij}$  é o fluxo de potência ativa no ramo  $i - j$ ;  $n_{ij}^0$  é o número de circuitos existentes no ramo  $i - j$ ;  $\theta_{ij}$  é a abertura angular entre as tensões nodais das barras terminais  $i$  e  $j$ ;  $f_{ij}^{\max}$  é o fluxo máximo no ramo  $i - j$ ;  $g^{\min}$  e  $g^{\max}$  são, respectivamente, vetores com os limites mínimos e máximos de geração; e  $n_{ij}^{\max}$  é o número máximo de reforços para o ramo candidato  $i - j$ .

O problema PET é solucionado neste trabalho a partir do desacoplamento do Modelo DC em dois subproblemas, de investimento e de operação, solucionados alternadamente a fim de contornar o problema da não linearidade presente na restrição (3) do modelo (Zhang et al., 2019; Assis et al., 2021). O subproblema de investimento apresenta como variáveis de decisão apenas os reforços  $n_{ij}$ . A avaliação de um plano  $n$  no subproblema de investimento é realizada com base no desempenho operativo do sistema, que é verificado a partir da solução do subproblema de operação. O subproblema de operação é caracterizado por um problema de otimização idêntico aquele apresentado em (1)-(7), onde cada variável  $n_{ij}$  apresenta um valor fixo definido no subproblema de investimento.

Com o intuito de melhor representar a operação do sistema, as perdas ôhmicas nas linhas são consideradas, assim como em Assis et al. (2021) e Silva et al. (2020). Além disso, o critério de segurança “N-1” é também considerado neste estudo. Para isso, após o processo de cálculo das perdas, o sistema é avaliado com a remoção de um circuito de cada um de seus ramos ativos. Para cada circuito removido, um fluxo de potência linear (fluxo DC) avalia a capacidade do sistema no atendimento da demanda considerando o mesmo despacho de geração obtido na condição de rede intacta (Silva et al., 2020; Assis et al., 2021).

### 2.2 Técnicas de Solução

De um modo geral, a técnica de otimização empregada para solução do problema PET possui relação direta com o modelo de abordagem do problema. Basicamente, as características relacionadas às equações (p. ex., lineares e não lineares) e às variáveis de decisão do problema (p. ex., reais, discretas e inteiras) definem a técnica de otimização a ser utilizada. Basicamente, as técnicas mais comuns aplicadas à solução do problema PET podem ser divididas em clássicas, heurísticas e metaheurísticas.

Na aplicação de técnicas clássicas de otimização, é possível obter a solução ótima global para o problema sob os aspectos considerados (Moreira et al., 2015). Porém, na maioria das vezes, o emprego de tais técnicas representa um maior nível de complexidade no processo de implementação, que

é intensificado na solução de problemas reais e de maior porte. Quando se trata do uso de técnicas heurísticas de otimização (Poubel et al., 2017), apesar da não garantia de identificação da solução ótima, a representação do problema se torna menos complexa. Nessas técnicas, informações específicas (heurísticas) relacionadas ao próprio problema são normalmente utilizadas.

Já as técnicas metaheurísticas são geralmente inspiradas em mecanismos gerais da natureza (Leite da Silva et al., 2011), e apresentam uma maior facilidade de implementação quando comparadas às técnicas clássicas. É possível, através das metaheurísticas, trabalhar com diferentes tipos de problema ajustando apenas alguns parâmetros. Além disso, do mesmo modo que as técnicas heurísticas, esse tipo de método não garante a identificação da solução ótima (i.e., soluções economicamente viáveis e tecnicamente aderentes à realidade operativa do sistema), entretanto consegue-se um conjunto de boas soluções, mesmo em casos mais complexos.

Entre as técnicas metaheurísticas mais empregadas para solução do problema PET, destaque pode ser dado ao AG. Esta técnica é baseada na seleção natural de espécies, em que indivíduos de uma população são recombinados entre si e sofrem a ação de mutações a cada geração para formar populações mais evoluídas (indivíduos com melhores aptidões) (Poubel et al., 2017; Silva et al., 2020).

Uma dificuldade recorrente relacionada ao emprego de técnicas metaheurísticas, como o AG, para solução de problemas de otimização está relacionada ao ajuste de seus parâmetros (p. ex., tamanho de população, formas de emprego dos operadores de recombinação/cruzamento e mutação, critérios de convergência etc.). A depender das características do problema, a identificação da solução ótima (ou ao menos de um conjunto de boas soluções) está fortemente relacionada ao ajuste desses parâmetros. Além disso, para problemas em que as soluções estão espalhadas em um grande espaço de busca, por exemplo, a falta de diversidade de soluções analisadas pode vir a causar a convergência prematura do processo evolutivo, com aprisionamento em regiões de ótimos locais. Sendo assim, populações diversificadas têm uma maior capacidade de identificar múltiplas e ótimas soluções para o problema. A ideia de diversidade populacional surge, então, a fim de tornar as ferramentas metaheurísticas de solução mais robustas.

### 3. METAHEURÍSTICAS COM DIVERSIDADE

A importância da diversificação populacional em técnicas de otimização evolutivas, como o AG, se dá pelo fato de evitar a concentração em indivíduos de uma mesma região do espaço de busca e, conseqüentemente, o aprisionamento do algoritmo em ótimos locais do problema. Estratégias dedicadas à garantia de diversidade populacional podem ser aplicadas em diferentes estágios do algoritmo. Nesta seção, são discutidas algumas delas.

Métodos gerais de clusterização (classificação) podem ser utilizados para a diversificação da população na técnica AG. Basicamente, o emprego desses métodos auxilia no processo de seleção de indivíduos diversificados a cada geração, para formação das novas populações. Como exem-

plo, podem ser citados o método *K-means* e métodos hierárquicos de clusterização. Sasirekha e Baby (2013) apresentam uma revisão geral do funcionamento dessa última estratégia de clusterização.

Mahfoud (1995) propõe uma metodologia para diminuir os erros de substituição dos indivíduos na população por meio do método chamado de *Deterministic Crowding* (DC), que é aplicado com o intuito de garantir a diversidade e evitar a perda de bons indivíduos. Em Souza e Camilo-Junior (2010), técnicas diversas são testadas para a geração da população inicial. Busca-se, basicamente, diversificar os indivíduos gerados para essa população e, conseqüentemente, garantir a diversidade nas populações nos processos evolutivos. São testadas neste trabalho técnicas como: Árvore Diversificadora Populacional, geração aleatória e geração complementar.

Por fim, podem-se citar os trabalhos de Tragante e Tinós (2009) e de Lopes (2012). Tragante e Tinós (2009) obtiveram bons resultados a partir da aplicação de técnicas de imigrantes aleatórios e hipermutação com o intuito de diversificar a população do AG quando aplicado à determinação de estruturas das proteínas. Já Lopes (2012) garantiu a diversidade do AG ao empregar a transformada de *Wavelet* associada à técnica *K-means* para diminuir o tamanho de uma população inicial de indivíduos sem, contudo, comprometer a sua diversidade.

### 4. SOLUÇÃO DO PROBLEMA PET VIA AG COM ESTRATÉGIAS DE DIVERSIDADE

Tendo em mente a complexidade de solução do problema PET para os sistemas elétricos de grandes dimensões, é proposta neste trabalho a aplicação da técnica metaheurística AG combinada a estratégias de diversidade populacional. A fim de tornar eficiente a solução do problema, são investigadas diferentes estratégias de diversidade associadas à técnica AG: *Deterministic Crowding* (DC) e clusterização não supervisionada via método *K-means* (CNS). No método de solução proposto, o subproblema de operação é solucionado por meio da técnica *Dual Simplex*. Ao longo desta seção, são apresentados o algoritmo geral do AG aplicado à solução do subproblema de investimento do problema PET e os detalhes relativos à consideração das estratégias de diversidade neste algoritmo.

#### 4.1 Algoritmo de Solução do Problema PET

Técnicas AGs tradicionais são caracterizadas, essencialmente, pela evolução de uma população de indivíduos (soluções do problema), os quais sofrem as ações de operadores genéticos de seleção, cruzamento e mutação a cada iteração do algoritmo (geração evolutiva). Os indivíduos são avaliados por meio de uma função aptidão, que, basicamente, serve de base para classificação e definição daqueles que seguem pelo processo evolutivo.

No presente trabalho, para solução do problema PET, cada indivíduo do AG é definido por um vetor com  $n_c$  elementos, que representam os  $n_c$  ramos candidatos ao reforço da rede de transmissão. Cada elemento do indivíduo pode receber um número inteiro  $n_{ij}$  que corresponde à quantidade de circuitos a serem construídos no respectivo ramo candidato

$i - j$ , respeitando o número máximo de reforços conforme restrição (6) do Modelo DC.

A função objetivo do subproblema de investimento, que se deseja minimizar, caracteriza a aptidão do plano de expansão  $n$  (indivíduo) na solução do problema PET:

$$f(n) = \sum_{ij \in \Omega_c} c_{ij}^{inv} n_{ij} + \alpha \left( R + \sum_{k=1}^K (sc_k + ci_k) \right) \quad (8)$$

em que a primeira parcela corresponde ao valor total de investimento e a segunda parcela representa uma penalização, com fator  $\alpha$ , para o montante de corte de carga  $R$  observado na condição de rede intacta e para os montantes de sobrecarga  $sc_k$  nos circuitos e cortes de carga por ilhamento  $ci_k$ , observados para cada contingência  $k$  do conjunto de  $K$  contingências avaliadas no critério de segurança "N-1". De forma geral, no emprego do AG busca-se identificar planos de expansão que permitam o total atendimento da carga do sistema, mesmo em condição de contingência simples da rede, ou seja, cuja segunda parcela da função  $f(n)$  seja nula. Neste trabalho, esses planos são chamados de soluções viáveis para o problema PET.

Para dar início ao processo evolutivo do AG, gera-se uma população inicial de  $N_{POP}$  indivíduos. No presente trabalho, a população inicial é gerada de forma aleatória, utilizando a mesma estratégia de Silva et al. (2020). Em seguida, inicia-se o processo iterativo de aplicação dos operadores genéticos. Basicamente, até formar uma nova população, pais (indivíduos progenitores) são selecionados da população atual para formar, sob certa taxa  $\alpha_{cru}$ , indivíduos filhos por meio do cruzamento. O operador de cruzamento uniforme é utilizado. No AG referência (AG-REF) considerado nesse estudo, a seleção dos progenitores é realizada a partir de mecanismo de escalonamento de roleta, onde indivíduos com melhores aptidões têm maiores chances de serem selecionados para reprodução.

Os filhos gerados pelo operador de cruzamento são submetidos à mutação, que é responsável por inserir perturbações aleatórias em suas estruturas. Nesse operador, é realizado um sorteio para cada gene do indivíduo, a fim de definir, sob certa taxa  $\alpha_{mut}$ , se o gene sofrerá ou não uma perturbação. Em caso positivo, um segundo sorteio define, sob determinados valores de probabilidade, se o gene recebe ou perde um reforço.

Além do emprego dos operadores genéticos tradicionais, são também consideradas como parte do AG-REF, neste trabalho, duas estratégias importantes, responsáveis por aprimorar a ferramenta para solução do problema PET em sistemas de grande porte: mecanismos de i) refinamento (MR) e ii) depuração (MD) (Assis et al., 2021). O MR é aplicado a cada solução viável identificada durante o processo evolutivo e é utilizado para evitar que esses indivíduos possuam reforços desnecessários em sua estrutura. Já o MD é uma estratégia que consiste na formação de um novo indivíduo a partir de cada indivíduo da nova população gerada a cada iteração do AG. Nesse caso, de cada indivíduo é retirado um de seus reforços, aquele que pertence ao ramo com menor carregamento na avaliação de rede intacta. Feito isso, os novos planos formados são também avaliados e adicionados à população gerada.

No emprego do AG referência nesse trabalho, ao final de cada geração, dentre os indivíduos da população de progenitores e da nova população gerada por meio dos operadores genéticos e mecanismos MR e MD, os  $N_{POP}$  indivíduos que apresentam as melhores aptidões são então selecionados para seguir pelo processo evolutivo de solução. A convergência do processo de solução é definida quando há a estagnação da melhor solução identificada, ou seja, quando não há a identificação de uma nova melhor solução por  $n_{estag}$  gerações consecutivas.

Verifica-se, portanto, que o AG-REF definido nesta subseção não apresenta qualquer estratégia de diversidade em sua estrutura. A seguir, são apresentadas estratégias de diversidade gerais que compõem outras versões do AG investigadas no trabalho, cujos desempenhos são comparados ao desempenho do AG-REF.

#### 4.2 Deterministic Crowding

Um dos métodos de diversidade investigados é o *Deterministic Crowding* (DC). Proposto por Mahfoud (1995), basicamente, o método consiste em comparar, após emprego dos operadores de cruzamento e de mutação, os indivíduos filhos com seus progenitores. Neste caso, são comparados os filhos e pais mais similares entre si, sendo que o mais apto dentro de cada comparação é selecionado para seguir no processo. Verifica-se, portanto, que indivíduos pais podem substituir os filhos na evolução, além de que indivíduos menos similares (i.e., mais diversificados) são resultado do processo realizado pelo DC. A versão do AG que faz uso do DC investigada é denominada AG-DC.

A medida de similaridade utilizada para definir qual pai compete com qual filho é a Distância Euclidiana dada por:

$$D_{km} = \sqrt{\sum_{u=1}^{n_e} (n_{ij}^{u-k} - n_{ij}^{u-m})^2} \quad (9)$$

em que o filho  $k$  e o pai  $m$  possuem, respectivamente, os componentes  $n_{ij}^{u-k}$  e  $n_{ij}^{u-m}$  na  $u$ -ésima posição.

Com a utilização da estratégia DC, dois indivíduos "parecidos" (ou similares) são submetidos a uma competição, sendo que o mais apto permanece no processo. Além da simplicidade da aplicação, tal método evita a perda de indivíduos potencialmente bons, pois não leva em conta somente suas aptidões com relação aos outros indivíduos da população, mas sim sua aptidão com relação a indivíduos similares, garantindo a diversidade populacional e evitando o aprisionamento do algoritmo em ótimos locais. No emprego do DC, basicamente calcula-se a distância de cada filho para cada pai, formando os pares para comparação. A formação dos pares para competição de acordo com o DC é realizada como apresentado na Figura 1.

#### 4.3 K-means

A clusterização é, basicamente, um método de aprendizagem não supervisionada que consiste em separar elementos de um conjunto em grupos (*clusters* ou *classes*) de acordo com uma medida de similaridade utilizada (p. ex., (10)). Dentre as técnicas de clusterização existentes, o algoritmo




Figura 1. Estratégia de formação de indivíduos - DC.

não supervisionado *K-means* (Jain, 2010) foi selecionado para investigação no presente trabalho. Portanto, uma versão do AG, denominada AG-KM, que emprega o *K-means* para seleção de indivíduos a cada geração, é avaliada.

No algoritmo AG, a aplicação da técnica *K-means* se dá na seleção dos indivíduos que seguem pelo processo evolutivo ao final de cada geração. Basicamente, todos os indivíduos obtidos na geração corrente, mais os indivíduos da população progenitora, são distribuídos em  $N_{pop}$  classes pelo *K-means*. Posteriormente, são selecionados para a próxima geração os melhores indivíduos em termos de aptidão dentro de cada classe obtida. A diversidade populacional é garantida com essa estratégia, além da manutenção de soluções de boa qualidade no processo evolutivo.

## 5. RESULTADOS

### 5.1 Caracterização do Problema

A aplicação da metodologia proposta se dá pelo emprego de quatro versões distintas da ferramenta de otimização: AG-REF; AG-DC; AG-KM e AG-DC-KM, sendo que este último corresponde ao algoritmo AG com combinação simultânea das técnicas DC e *K-means*. A fim de comparar o desempenho destas diferentes versões, é realizada a solução do problema PET para um mesmo sistema de transmissão, com um mesmo ajuste de parâmetros:  $N_{POP} = 500$  indivíduos;  $\alpha_{cru} = 65\%$ ;  $\alpha_{mut} = 8\%$  (na mutação a chance de um ramo receber um reforço é de 30% e a chance de retirada de um reforço é de 70%); e  $n_{estag} = 60$ .

A rede de transmissão utilizada no estudo corresponde à região geoeletrica sul do Brasil, um subsistema do Sistema Interligado Nacional (SIN) brasileiro. Este sistema foi proposto por Assis et al. (2021), cujos dados estão disponíveis em Test system data (2021). Abrangendo os estados do Rio Grande do Sul, Santa Catarina, Paraná e Mato Grosso do Sul, esse é um sistema de grande porte que possui um total de 242 barras, ligadas entre si por uma rede de 345 ramos, onde estão instalados 467 circuitos. A lista de candidatos ao reforço é formada por 108 ramos ( $n_c = 108$ ), sendo que 83 ramos já possuem circuitos na configuração base da rede. Cada ramo pode receber até 3 reforços (i.e.,  $n_{ij}^{max} = 3$ ). A topologia base do sistema equivale à rede do ano de 2017 e o ano de 2025 é considerado como o último ano do horizonte de planejamento. Além disso, é relevante citar que é considerado um cenário crítico de geração e carga para o sistema, em que a região norte do país apresenta um menor nível de chuvas (i.e., cenário Norte Seco).

Por se tratar de uma ferramenta estocástica de otimização, 10 execuções com diferentes sementes para geração dos

Tabela 1. 10 melhores soluções encontradas em todos os testes

Plano	Versão que encontrou	Investimento (Milhões de R\$)	Nº de reforços
1	AG-DC	828,006	22
2	AG-DC	837,534	22
3	AG-DC	847,559	22
4	AG-DC	851,985	22
5	AG-DC-KM	866,245	22
6	AG-DC-KM	875,830	23
7	AG-DC-KM	876,762	22
8	AG-DC-KM	881,707	22
9	AG-DC-KM	885,799	22
10	AG-DC-KM	896,315	22

números pseudoaleatórios são realizadas com cada versão do AG (o mesmo conjunto de sementes é utilizado para cada versão). A partir dessas execuções, índices estatísticos são calculados e utilizados para avaliação de desempenho da ferramenta. Esses índices são calculados com base nas 10 melhores soluções encontradas em todos os testes:

- *Taxa de sucesso* -  $T_s$  (em %): Razão percentual entre o número de execuções de sucesso e o número total de execuções realizadas. Uma execução é considerada de sucesso quando encontra pelo menos uma solução das 10 melhores conhecidas para o problema;
- *Tempo médio* -  $T_M$  (em horas): É a média de tempo por execução;
- *Desvio melhor plano* -  $D_{BEST}$  (em %): Desvio percentual médio entre o investimento do melhor plano encontrado em cada execução e o investimento do melhor plano conhecido;
- *Desvio 10 melhores planos* -  $D_{10BEST}$  (em %): Desvio percentual médio entre os 10 melhores investimentos encontrados em cada execução e o investimento do melhor plano conhecido.

### 5.2 Análise dos Resultados

As 10 melhores soluções encontradas para o problema PET proposto na Subseção 5.1, a partir dos testes realizados com as quatro versões propostas do AG, são apresentadas na Tabela 1. É possível verificar que as soluções que compõem o conjunto das 10 melhores identificadas foram encontradas exclusivamente por apenas duas das quatro versões do AG consideradas: AG-DC e AG-DC-KM. Portanto, constata-se que, em termos de identificação de melhores soluções, essas duas versões foram superiores nos estudos realizados. Vale destacar que, em relação aos resultados identificados por Assis et al. (2021), uma melhor solução em termos de montante total de investimento foi identificada (Plano 1).

Na Tabela 2, são apresentados os índices estatísticos de desempenho obtidos com base nos resultados da Tabela 1. Verifica-se que as versões AG-DC e AG-DC-KM identificaram soluções da Tabela 1 em apenas 1 de suas 10 execuções (i.e.,  $T_s = 10\%$  para os dois casos). Esse resultado aponta a complexidade de solução do problema PET sob análise nesse trabalho. É possível ainda verificar, a partir desses resultados, que o desempenho da estratégia DC foi superior ao da estratégia *K-means* quando empregadas para garantia de diversidade na solução do problema PET proposto,

Tabela 2. Desempenho Estatístico dos testes

Teste	Versão do AG	$T_s$ (%)	$T_M$ (h)	$D_{BEST}$ (%)	$D_{10BEST}$ (%)
1	AG-REF	0	19,34	13,41	16,16
2	AG-DC	10	14,86	19,63	24,49
3	AG-KM	0	11,61	54,47	56,23
4	AG-DC-KM	10	16,18	22,41	25,04

uma vez que está presente nas duas versões com melhores valores para o índice  $T_s$ .

Em relação aos tempos médios por execução ( $T_M$ ), a versão AG-KM foi aquela que apresentou melhor desempenho. Já a versão de referência (AG-REF), apresentou o pior desempenho em relação a este índice. Verifica-se, portanto, que o emprego de estratégias de diversidade, da forma como é proposto nesse trabalho, permite acelerar o processo de solução.

Em termos de qualidade das melhores soluções identificadas, desempenho superior é verificado para a versão AG-REF, que apresentou os menores valores para os índices  $D_{BEST}$  e  $D_{10BEST}$ . Constata-se, dessa forma, que a inserção de estratégias de diversidade no processo evolutivo do AG garante, de fato, a exploração de diferentes regiões do espaço de soluções, resultando, inclusive, em soluções finais distintas em termos de qualidade. Nesse ponto, é importante verificar que aprimoramentos devem ainda ser realizados no emprego das estratégias de diversidade consideradas a fim de melhorar a qualidade do conjunto final de soluções. Por fim, ainda em relação à qualidade das melhores soluções identificadas, verifica-se que o emprego da estratégia de diversidade baseada na técnica DC foi o mais eficiente entre as estratégias investigadas.

## 6. CONCLUSÕES

No presente trabalho é proposta a aplicação da metaheurística Algoritmo Genético (AG) combinada com diferentes estratégias de diversidade populacional para solução do problema de planejamento da expansão da transmissão (PET) de sistemas elétricos. As técnicas *Deterministic Crowding* (DC) e *K-means* definem diferentes versões do AG, cujos desempenhos são analisados na solução do problema PET para a rede elétrica da região geoeletrica do sul do Brasil.

Em linhas gerais, a partir dos estudos realizados, é possível verificar que o emprego de estratégias de diversidade durante o processo evolutivo do AG permite uma maior exploração do espaço de busca do problema, o que permite identificar soluções economicamente viáveis e tecnicamente aderentes à realidade operativa do sistema. Destaque pode ser dado às versões do AG que envolvem a utilização da técnica DC, as quais apresentaram bons desempenhos em uma avaliação estatística de solução do problema.

Vale destacar que os resultados aqui apresentados e analisados correspondem a investigações preliminares sobre a utilização de estratégias de diversidade combinadas a técnicas metaheurísticas de otimização para solução do problema PET. Aprimoramentos dessas estratégias, bem como novas técnicas, estão atualmente sendo estudadas.

## AGRADECIMENTOS

Os autores gostariam de agradecer à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e à Pró-Reitoria de Pesquisa e Pós-Graduação (PROPE) da Universidade Federal de São João del-rei (UFSJ).

## REFERÊNCIAS

- Assis, F.A., Leite da Silva, A.M., Manso, L.A.F., e Castro, J.F.C. (2021). Transmission expansion planning of large power networks via constructive metaheuristics with security constraints and load uncertainty analysis. *Int. T. Electr. Energy*, 31(1), e12595.
- Gomes, P.V. e Saraiva, J.T. (2019). State-of-the-art of transmission expansion planning: A survey from restructuring to renewable and distributed electricity markets. *Int. J. Elec. Power*, 111, 411–424.
- Jain, A.K. (2010). Data clustering: 50 years beyond k-means. *Pattern Recogn Lett.*, 31(8), 651–666.
- Leite da Silva, A.M., Rezende, L.S., Honório, L.M., e Manso, L.A.F. (2011). Performance comparison of metaheuristics to solve the multi-stage transmission expansion planning problem. *IET-GTD*, 5(3), 360–367.
- Lopes, E.C.C. (2012). *Aplicação da transformada discreta de Wavelet no controle da diversidade populacional nos algoritmos genéticos em problemas de otimização*. Master's thesis, UNINOVE, São Paulo.
- Mahfoud, S.W. (1995). *Niching Methods for Genetic Algorithms*. Ph.D. thesis, University of Illinois.
- Moreira, A., Street, A., e Arroyo, J.M. (2015). An adjustable robust optimization approach for contingency-constrained transmission expansion planning. *IEEE Trans Power Syst*, 30, 2013–2022.
- Poubel, R.P.B., Oliveira, E., Manso, L.A.F., Honorio, L.M., e Oliveira, L. (2017). Tree searching heuristic algorithm for multi-stage transmission planning considering security constraints via genetic algorithm. *Electr. Pow. Syst. Res.*, 142, 290–297.
- Rider, M.J., Garcia, A.V., e Romero, R. (2007). Power system transmission network expansion planning using ac model. *IET-GTD*, 1, 731–742.
- Sasirekha, K. e Baby, P. (2013). Agglomerative hierarchical clustering algorithm - a review. *Int. J. Sci. Res.*, 3, 1–3.
- Silva, I., Assis, F.A., Leite da Silva, A.M., e Resende, L.S. (2020). Planejamento da transmissão com critério de segurança via algoritmo genético aprimorado. In *XXIII Congresso Brasileiro de Automática*, volume 2.
- Souza, T.H. e Camilo-Junior, C.G. (2010). Uma nova abordagem para aumentar a diversidade genética da população inicial em algoritmos genéticos. In *XLII Simpósio Brasileiro de Pesquisa Operacional*, 1469–1479.
- Test system data (2021). Southern brazilian TEP problem. URL <https://sites.google.com/view/southernbrazilian/data>.
- Tragante, V. e Tinós, R. (2009). Controle da diversidade da população em algoritmos genéticos aplicados na predição de estruturas de proteínas. *Scientia*, 20, 83–93.
- Zhang, L., Zhou, Q., Gao, Q., Cheng, H., e Zhang, S. (2019). Multistage fuzzy-robust transmission network expansion planning under uncertainties. *Int Trans Elect Energy Syst.*, 29(7), e12054.