

## Planejamento da Transmissão com Critério de Segurança via Algoritmo Genético Aprimorado

Iamberg S. da Silva<sup>1</sup>, Fernando A. Assis<sup>2</sup>,  
Armando M. Leite da Silva<sup>1</sup>, Leonidas C. Resende<sup>2</sup>

<sup>1</sup>Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, PUC-Rio, Rio de Janeiro, RJ, Brasil (e-mails: iamberg.souza@gmail.com, am.leitedasilva@gmail.com).

<sup>2</sup>Departamento de Engenharia Elétrica, Universidade Federal de São João del-Rei, UFSJ, São João del-Rei, MG, Brasil (e-mails: fernandoassis@ufsj.edu.br, leonidas@ufsj.edu.br).

**Abstract:** This paper proposes the use of an enhanced genetic algorithm model, named AGA-PET, to solve the transmission expansion planning problem of electric power system networks. Heuristic information is integrated into the evolutionary process of metaheuristics to improve the expansion plans (solutions), which makes the optimization tool robust and ready to handle different types of systems. This heuristic information is translated in the form of sensitivity indices, based on the circuit loading/overloading and observed load shedding, considering both the intact network and the “N-1” contingency operating conditions (security criteria). The efficiency of the proposed AGA-PET tool is consistently evaluated through performance statistical indices. Results obtained with systems with different characteristics and dimensions are presented and widely discussed.

**Resumo:** Este artigo propõe o uso de um modelo de algoritmo genético aprimorado, denominado AGA-PET na solução do problema do planejamento da expansão da transmissão da rede de sistemas elétricos de potência. Informações heurísticas são integradas ao processo evolucionário da metaheurística de forma a aprimorar os planos de expansão (soluções), tornando a ferramenta robusta e preparada para lidar com diferentes tipos de sistema. Essa informação heurística é traduzida na forma de índices de sensibilidade, baseados na carga/sobrecarga de circuitos e no corte de carga, observados tanto em condições de rede intacta quanto condições de contingência (critério de segurança). A eficiência do AGA-PET proposto é avaliada de forma consistente através de índices estatísticos de desempenho. Os resultados obtidos com sistemas com diferentes características e dimensões são apresentados e amplamente discutidos.

**Keywords:** Genetic algorithm; Metaheuristic optimization; “N-1” criterion; Power system planning; Transmission expansion planning.

**Palavras-chaves:** Algoritmo genético; Critério “N-1”; Otimização metaheurística; Planejamento da expansão da transmissão; Planejamento de sistemas de potência.

### 1. INTRODUÇÃO

Na solução do problema de planejamento da expansão da transmissão (PET) de sistemas elétricos de potência novos reforços devem ser definidos para a rede, de forma a garantir a continuidade do fornecimento de energia aos consumidores frente ao crescimento da demanda e da geração. A decisão de investir em novos equipamentos de transmissão é essencial para assegurar níveis satisfatórios de confiabilidade na operação do sistema. De forma geral, boas alternativas de expansão devem garantir um bom compromisso entre os custos de investimento e de operação, mantendo, ao mesmo tempo, níveis adequados de qualidade no fornecimento da energia elétrica e a maximização do uso de recursos já disponíveis da rede. Ademais, investimentos adequados no sistema de transmissão possibilitam em um ambiente apropriado de interação entre consumidores, geradores e comercializadores de energia (Li, 2011; Hemmati, et al., 2013; Lumbreras & Ramos, 2016; Gomes & Saraiva, 2019).

De maneira geral, o PET é um problema de otimização de difícil solução, que pode ser classificado como um problema de programação não linear inteira mista com espaço de soluções não convexo (Haffner, et al., 2000; Zhang & Conejo, 2018). As atuais dimensões do sistema de potência, aliadas às incertezas relacionadas ao crescimento de carga e disponibilidade de fontes de energia e equipamentos, tornam a solução do PET uma tarefa complexa (Leite da Silva, et al., 2010). Com o objetivo de superar essas dificuldades, diversos trabalhos baseados em técnicas de otimização heurísticas e metaheurísticas vêm sendo propostos, indicando um crescimento na aplicação e aceitação de uso dessas ferramentas (Faria, et al., 2005; Silva, et al., 2005; Leite da Silva, et al., 2011; Sousa & Asada, 2015; Moradi, et al., 2016). Isso se deve principalmente à habilidade dessas técnicas em lidar com variáveis inteiras mistas e com a não linearidade do problema, além de requerer um menor nível de dificuldade em sua implementação e no tratamento de incertezas.

Para solucionar o problema PET de longo prazo, este trabalho propõe um novo algoritmo genético aprimorado, denominado AGA-PET. Na versão original do algoritmo genético aprimorado, EGA-OPF (Bakirtzis, et al., 2002), proposto para a solução do problema do fluxo de potência ótimo, após a aplicação de operadores genéticos básicos, operadores avançados e específicos do problema são utilizados para produzir novas gerações do processo evolutivo. De maneira similar, neste trabalho, mecanismos de busca local são empregados de forma a melhorar as soluções do problema PET, durante a evolução de soluções inerente à técnica algoritmo genético (AG) (Silva, et al., 2005). Para este fim, informações heurísticas baseadas nos resultados de avaliações do fluxo de potência da rede (carregamento de circuitos, sobrecarga de equipamentos e corte de carga do sistema) são atualizadas e utilizadas durante o processo de busca. O uso dessas informações acelera o processo de solução do problema PET e, ao mesmo tempo, garante bons níveis de qualidade das soluções obtidas. Essa estratégia, que caracteriza a contribuição mais relevante do presente trabalho, faz do AGA-PET uma ferramenta de otimização robusta e eficiente, preparada para lidar com o planejamento da transmissão de uma variedade de sistemas elétricos de potência. O atendimento ao critério determinístico de segurança “N-1” é considerado a fim de lidar com as eventuais falhas de equipamentos do sistema de transmissão (Leite da Silva, et al., 2010; Silva, et al., 2005).

Resultados obtidos com sistemas que apresentam diferentes características e dimensões são apresentados e extensivamente discutidos. A eficiência do AGA-PET proposto é avaliada através de índices estatísticos de desempenho. A partir de diversas execuções do algoritmo, utilizando diferentes sementes para a geração de números pseudo-aleatórios, é possível realizar uma análise quantitativa e consistente no que se refere ao desempenho da ferramenta estocástica de otimização. Além disso, os resultados obtidos com a ferramenta proposta são comparados aqueles obtidos utilizando uma versão clássica do AG, o qual, em seu processo evolutivo, não faz uso de informações heurísticas relacionadas ao problema.

## 2. FORMULAÇÃO DO PROBLEMA PET

Na formulação do problema PET estático com horizonte de longo prazo, modelos matemáticos simplificados são normalmente utilizados para a representação da rede do sistema. Entre eles, o modelo DC é o mais aceito (Li, 2011; Hemmati, et al., 2013; Lumbreras & Ramos, 2016; Gomes & Saraiva, 2019; Silva, et al., 2005; Sousa & Asada, 2015). A formulação do problema PET adotada neste trabalho é apresentada nesta seção, a qual, para avaliar as configurações da rede obtidas durante a solução do problema, utiliza um modelo DC com a inclusão de perdas ôhmicas (Faria, et al., 2005; Leite da Silva, et al., 2011) e do critério de segurança “N-1” (Leite da Silva, et al., 2010; Silva, et al., 2005).

### 2.1 Problema PET – Modelo DC

De forma geral, o modelo clássico de otimização para o problema PET, baseado nas equações linearizadas de fluxo de

potência (modelo DC), e ainda sem a consideração dos critérios de segurança, pode ser equacionado como:

$$\text{Min: } z = \sum_{ij \in \Omega_{cb}} c_{ij}^{inv} n_{ij} + \sum_{k \in \Omega_{gb}} c_k^g g_k + \sum_{m \in \Omega_{lb}} c_m^r r_m \quad (1)$$

$$\text{s.a. } g + B\theta + r = d \quad (1.2)$$

$$f_{ij} - B_{ij}(n_{ij}^0 + n_{ij})\theta_{ij} = 0 \quad \forall (ij) \in \Omega_b \quad (1.3)$$

$$|f_{ij}| \leq (n_{ij}^0 + n_{ij})f_{ij}^{\max} \quad \forall (ij) \in \Omega_b \quad (1.4)$$

$$g^{\min} \leq g \leq g^{\max} \quad (1.5)$$

$$0 \leq n_{ij} \leq n_{ij}^{\max} \quad \forall (ij) \in \Omega_{cb} \quad (1.6)$$

$$0 \leq r \leq d \quad (1.7)$$

em que:  $z$  é a função objetivo do problema que se busca minimizar;  $\Omega_{cb}$ ,  $\Omega_{gb}$ ,  $\Omega_{lb}$  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 do sistema;  $c_{ij}^{inv}$  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;  $n_{ij}^{\max}$  é o número máximo de reforços que podem ser adicionados ao ramo candidato  $i-j$ .

O problema PET, mesmo quando é adotado o modelo DC (1), consiste em um problema de programação não linear inteira mista (PNLIM), com explosão combinatória do número de alternativas de expansão do sistema. A não linearidade envolvendo o modelo DC pode ser observada na restrição (1.3), sendo caracterizada pelo produto entre variáveis de decisão do problema (decisão de investimento e ângulos das tensões nodais). Uma estratégia comum para contornar a dificuldade imposta pela não linearidade do modelo, que é adotada por muitos trabalhos da literatura relacionada (Li, 2011; Hemmati, et al., 2013; Lumbreras & Ramos, 2016; Gomes & Saraiva, 2019; Faria, et al., 2005; Silva, et al., 2005; Leite da Silva, et al., 2011), consiste em desacoplar o problema original em dois subproblemas: investimento e operação.

No problema desacoplado, o subproblema de investimento pode ser solucionado por técnicas heurísticas e metaheurísticas de otimização, por exemplo, tendo como objetivo identificar planos de expansão com custo de investimento reduzido e que sejam capazes de suprir a demanda futura. O subproblema de operação, por outro lado, consiste em um problema de otimização idêntico ao (1), porém, com valores fixados para as variáveis de decisão  $n_{ij}$  do plano  $n$ , identificado no subproblema de investimento. A solução do

subproblema de operação pode ser realizada por meio de uma técnica de programação linear. Neste trabalho, é empregado o método dual simplex de otimização linear.

## 2.2 Perdas Ôhmicas na Transmissão

A fim de se obter uma melhor representação do fluxo de potência ativa e, conseqüentemente, o futuro ponto de operação do sistema, perdas ôhmicas de transmissão devem ser levadas em conta na avaliação do subproblema de operação (Faria, et al., 2005; Leite da Silva, et al., 2011). Para calcular as perdas, um processo iterativo é realizado durante a avaliação de cada plano em condição de rede intacta. Basicamente, as perdas são calculadas conforme (2) para cada ramo do sistema com base na sua condutância equivalente (i.e.,  $g_{ij}$  do ramo  $i-j$ ) e no vetor  $\theta$ , obtido com a solução do subproblema de operação.

$$P_{ij}^{Losses} = g_{ij}\theta_{ij}^2 \quad (2)$$

Posteriormente, estas perdas são distribuídas como cargas fictícias entre as barras terminais. Ou seja, as barras  $i$  e  $j$  recebem metade das perdas estimadas para o ramo ativo  $i-j$  que as conecta. Uma barra é considerada ativa quando possui ao menos um circuito de interligação, seja ele pertencente à topologia base do sistema ou resultante de um reforço de expansão. Em seguida, o subproblema de operação é novamente solucionado com a inclusão das cargas fictícias, sendo encontrado um novo vetor  $\theta$ . O processo inteiro é repetido uma segunda vez, visando uma maior precisão dos valores calculados.

## 2.3 Critério de Segurança

Para consideração do critério de segurança “N-1” (Leite da Silva, et al., 2010; Silva, et al., 2005), um circuito é removido em cada ramo ativo do sistema pertencente à lista de contingências, a qual forma o conjunto  $\Omega_{ctg}$ . Para cada circuito removido, um fluxo de potência linearizado é solucionado para avaliar o desempenho da configuração obtida, assegurando o despacho de geração identificado para a rede intacta (descontado o eventual corte de carga observado). A análise de contingência objetiva avaliar a habilidade do sistema em garantir o atendimento à demanda sem redespacho da geração (com exceção da barra swing). Possíveis cortes de carga por ilhamento e sobrecargas de equipamentos verificados para cada contingência são observados neste processo. Deve-se notar que a inclusão de restrições de segurança aumenta consideravelmente a complexidade do problema e, portanto, a dificuldade de se encontrar a configuração ótima de expansão.

## 3. ALGORITMO GENÉTICO APRIMORADO PARA O PROBLEMA PET

O AGA-PET proposto neste trabalho, adaptado de (Bakirtzis, et al., 2002), corresponde a uma metaheurística evolucionária especializada, concebida para solução eficiente do problema PET. Informações heurísticas de desempenho da própria rede de transmissão são traduzidas por meio de índices de sensibilidade e utilizadas na solução do problema. A seguir são apresentados os detalhes relativos ao AGA-PET.

### 3.1 Representação das Soluções

Assim como normalmente utilizado por metaheurísticas evolucionárias, no AGA-PET a representação de soluções do PET é feita por meio de indivíduos (Silva, et al., 2005; Leite da Silva, et al., 2011; Sousa & Asada, 2015). Cada indivíduo é definido por um vetor composto por  $n_{cb}$  posições (genes), que correspondem aos  $n_{cb}$  ramos candidatos ao reforço, quer sejam ramos já ativos ou novos ramos. Dessa forma, cada posição do vetor (gene do indivíduo) corresponde a uma variável inteira e armazena o número de reforços (linhas de transmissão e transformadores) inseridos no respectivo ramo candidato de acordo com o plano. Durante o processo construtivo, cada indivíduo é avaliado utilizando a função objetivo do problema, a qual representa sua aptidão.

### 3.2 Função Objetivo

Na solução do problema PET, basicamente busca-se identificar soluções que minimizam o custo de investimento e que, ao mesmo tempo, permitam ao sistema operar sem cortes de carga e/ou sobrecargas de equipamentos. Neste sentido, a função objetivo  $f(n)$  utilizada pelo AGA-PET para avaliação dos indivíduos é definida em (3). Esta função, que se deseja minimizar, é constituída pela soma de duas parcelas principais: o custo total de investimento e um custo associado a eventuais cortes de carga e sobrecargas de equipamentos da rede de transmissão. Para um dado plano  $n$ , as informações que compõem a segunda parcela de  $f(n)$  são obtidas a partir da solução do subproblema de operação.

$$f(n) = \sum_{ij \in \Omega_{cb}} c_{ij}^{inv} n_{ij} + \alpha \left( ls(n) + \sum_{c=1}^{nc} [ils(n)_c + ovl(n)_c] \right) \quad (3)$$

Em (3),  $\alpha$  é a uma penalidade aplicada (para cada decisão  $n$ ) ao corte de carga de rede intacta ( $ls(n)$ ) e aos eventuais cortes de carga por ilhamento ( $ils(n)_c$ ) e sobrecargas ( $ovl(n)_c$ ) ocorridas na contingência  $c$ ;  $nc$  é o número de contingências observadas na aplicação do critério de segurança. Os cortes de carga e sobrecargas são expressos em MW. Portanto,  $\alpha$  é expressa em \$/MW. Durante o processo evolutivo do AGA-PET, uma solução (plano de expansão  $n$ ) é definida como viável para o problema quando é capaz de garantir o pleno atendimento à carga sem sobrecarregar qualquer equipamento da rede, mesmo no caso da ocorrência de contingências. Logo, com  $ls(n)$ ,  $ils(n)_c$ , e  $ovl(n)_c$  nulos, a aptidão do plano viável se resume ao custo total de investimento.

Por fim, no subproblema de investimento, cada solução definida deve respeitar os limites máximos e mínimos de reforços para cada ramo candidato  $i-j$ , assim como estabelecido em (1.6).

### 3.3 Índices de Sensibilidade

As informações atualizadas de fluxo de potência da própria rede de transmissão são utilizadas pelo AGA-PET para definir operadores genéticos avançados e específicos do problema, os quais são empregados durante o processo evolutivo do algoritmo. Para tanto, a partir dos resultados do subproblema de operação, são calculados três índices de sensibilidade (atratividade) normalizados para os ramos

candidatos ao reforço do sistema. Estes índices traduzem as necessidades da rede de transmissão, sendo eles os índices  $Ind_{hl-ij}$ ,  $Ind_{ovl-ij}^{self}$ , e  $Ind_{ovl-ij}^{others}$ .

O índice  $Ind_{hl-ij}$  é responsável por apontar necessidades da rede de transmissão em termos de rede intacta, sendo calculado como:

$$Ind_{hl-ij} = \frac{|\theta_{ij}|}{x_{ij} f_{ij}^{\max}} \quad (4)$$

em que:  $|\theta_{ij}|$ , em radianos, é a diferença angular absoluta entre as tensões das barras  $i$  e  $j$ ;  $x_{ij}$  e  $f_{ij}^{\max}$  são, respectivamente, a reatância e a capacidade máxima do circuito a ser adicionado ao ramo candidato  $i-j$ . Este índice é calculado para todos os ramos candidatos ao reforço do sistema (novo ou já ativo), e corresponde ao carregamento hipotético do ramo em condição de rede intacta, aquele que seria verificado sem considerar a consequente redução da diferença angular entre as barras terminais do ramo após a inserção do novo circuito. Em princípio, esses circuitos terão grande potencial para contribuir para uma melhor distribuição da potência ativa na rede, trazendo benefícios a alguns aspectos operacionais do sistema, como redução das perdas ôhmicas e do carregamento dos circuitos.

Os demais índices estão relacionados às carências da rede de transmissão para operação em caso de contingências de seus equipamentos. Portanto, são calculados apenas para o conjunto de ramos candidatos ativos  $\Omega_b^{active}$ , ou seja, ramos candidatos que já possuem pelo menos um circuito instalado na configuração resultante da rede.

No cálculo do índice  $Ind_{ovl-ij}^{self}$ , dado por (5), toda sobrecarga observada no ramo ativo e candidato  $i-j$  ( $ovl(n)_{c-ij}$ ) é acumulada na aplicação ao plano de expansão  $n$  de cada contingência do conjunto  $\Omega_{ctg}$ .

$$Ind_{ovl-ij}^{self} = \sum_{c \in \Omega_{ctg}} ovl(n)_{c-ij} \quad (5)$$

Já para o índice  $Ind_{ovl-ij}^{others}$ , são acumuladas as sobrecargas observadas em qualquer ramo ativo  $r-s$  do sistema ( $ovl(n)_{c-rs}$ ) decorrentes da contingência  $c$  no ramo candidato  $i-j$ . Caso a contingência  $c$  resulte em corte de carga por ilhamento ( $ils(n)_c$ ), o mesmo também deverá ser considerado. Esse índice é calculado como:

$$Ind_{ovl-ij}^{others} = \sum_{(r,s) \in \Omega_b^{active}} ovl(n)_{c-rs} + ils(n)_c \quad (6)$$

Pelas características inerentes aos dois últimos índices apresentados ( $Ind_{ovl-ij}^{self}$ , e  $Ind_{ovl-ij}^{others}$ ), espera-se que, durante o processo de solução do AGA-PET, reforços por eles indicados possam contribuir de forma significativa no total atendimento ao critério de segurança “N-1”.

### 3.4 Algoritmo AGA-PET

De forma geral, o AGA-PET evolui uma população de indivíduos (planos de expansão) aplicando operadores genéti-

cos básicos, avançados e específicos do problema, além de uma estratégia de refinamento de soluções. O fluxograma básico que descreve sua dinâmica de funcionamento pode ser visto na Fig. 1. No processo evolutivo, o AGA-PET faz uso de três conjuntos básicos de soluções, os quais devem ser criados inicialmente vazios:

- $\Omega_{FI}$ : conjunto onde são armazenadas os  $N_{FI}$  melhores indivíduos viáveis já gerados no processo;
- $\Omega_{POP}$ : população que contém os  $N_{POP}$  indivíduos que participam do processo evolutivo do AGA-PET;
- $\Omega_{NEW}$ : conjunto que armazena, a cada geração do AGA-PET, os novos indivíduos criados por meio dos operadores genéticos.

Os parâmetros  $N_{FI}$  e  $N_{POP}$  devem ser previamente definidos pelo planejador, assim como os critérios de convergência do algoritmo e as taxas de probabilidade que definem o emprego ou não dos operadores genéticos de cruzamento ( $\alpha_{CR}$ ) e de mutação ( $\alpha_{MT}$ ). Para convergência é considerada a execução de um número máximo de gerações ( $N_{MAX-GER}$ ) da porção iterativa do AGA-PET ou de um número pré-definido de gerações ( $N_{STG}$ ) com estagnação do melhor indivíduo viável já identificado, o que ocorrer primeiro.

#### 1) População Inicial

Para geração dos  $N_{POP}$  indivíduos da população inicial, cada gene do indivíduo (posição do vetor plano de expansão) recebe reforços a partir do sorteio de um número pseudoaleatório. Com 5% de probabilidade, o gene recebe o valor 2 (2 reforços), com 10% de probabilidade, o gene recebe o valor 1 (1 reforço) e, com 85% de probabilidade, o gene recebe valor 0 (nenhum reforço). As probabilidades para adição dos valores 0, 1 ou 2 foram ajustadas a fim de controlar/limitar o número total de reforços apresentados pelos indivíduos resultantes, a fim de que não apresentem um número excessivo de reforços (solução de elevado custo de investimento) e, ao mesmo tempo, não apresentem uma quantidade insuficiente de reforços (solução inviável para operação). Adotando esta estratégia, o número médio de reforços adicionados por gene é igual a 0,2. Como exemplo, para um problema PET cujo sistema apresente 40 ramos candidatos ao reforço (i.e., indivíduo com 40 genes), espera-se que os indivíduos da população inicial apresentem, em média, 8 reforços. De forma geral, estes 8 reforços não garantem a otimalidade e nem a viabilidade/factibilidade dos indivíduos da população inicial, porém, fornecem soluções aleatórias mais adequadas para o início do processo evolutivo de busca. Ao fim do processo de geração, os  $N_{POP}$  indivíduos são avaliados de acordo com (3) e armazenados em  $\Omega_{POP}$ .

#### 2) Processo Evolutivo

No processo evolutivo do AGA-PET, até que algum dos critérios de convergência seja atingido, são empregados operadores genéticos aos indivíduos de  $\Omega_{POP}$ . Vale lembrar que este conjunto é atualizado a cada geração do algoritmo evolucionário, conforme definido na Fig. 1. Os  $N_{FI}$  melhores indivíduos viáveis identificados durante todo o processo de solução são armazenados em  $\Omega_{FI}$  e correspondem às soluções finais do AGA-PET. A seguir, são apresentados os primei-

nores de cada operador genético empregado e, também, a forma como são empregados pela ferramenta de otimização.

a) *Operador Básico de Cruzamento*: Com auxílio de uma máscara aleatória de bits, o operador básico de cruzamento uniforme, comumente empregado por ferramentas de otimização evolucionária, é utilizado pelo AGA-PET para recombinar genes de indivíduos progenitores sob certa taxa de cruzamento ( $\alpha_{CR}$ ). A seleção de indivíduos progenitores a partir de  $\Omega_{POP}$  é realizada por meio de uma roleta, que é definida no início de cada geração do algoritmo com base nas aptidões dos indivíduos deste conjunto. Nesta roleta, indivíduos com melhores valores de aptidão têm maiores chances de procriação. Na ocorrência de não aplicação do operador de cruzamento, os indivíduos filhos seguem iguais aos progenitores para emprego dos operadores de mutação.

b) *Operadores de Mutação Específicos*: No AGA-PET, são empregados dois diferentes tipos de operadores de mutação, ambos concebidos com base nas informações heurísticas relacionadas ao problema PET e traduzidas pelos índices de sensibilidade definidos na Subseção 3.3: operadores de mutação por permuta (*PerMut*) e especialista (*EspMut*). De forma geral, estes operadores específicos do problema são aplicados, sob certa taxa de mutação  $\alpha_{MT}$ , a cada indivíduo filho resultante do emprego do operador de cruzamento.

O *PerMut* é um operador que se baseia na troca de material genético entre dois diferentes genes de um indivíduo, ou seja, na permuta de reforços entre ramos candidatos do plano de expansão, sendo que um reforço é retirado de um ramo e transferido para o outro. A seleção dos pares de genes para troca de material genético é realizada com auxílio dos índices de sensibilidade ( $Ind_{hl-ij}$ ,  $Ind_{ovl-ij}^{self}$ , e  $Ind_{ovl-ij}^{others}$ ). Basicamente, o gene que perde um reforço é aquele que corresponde ao ramo com o menor valor para o índice observado. Já o ramo que apresenta o maior valor do índice, define o gene que recebe o reforço. Portanto, após emprego do cruzamento, é realizado para cada indivíduo resultante um primeiro sorteio que define, de acordo com a taxa de mutação  $\alpha_{MT}$ , se o indivíduo sofrerá ou não a perturbação gerada pela mutação. Caso a decisão seja positiva, são então selecionados três pares de genes do indivíduo, um par a partir de cada índice de sensibilidade. A realização da perturbação, ou seja, troca de material genético dentro de cada par de genes, gera três novos indivíduos, que seguem para emprego do operador de mutação especialista. Destaca-se que, caso a decisão, de acordo com  $\alpha_{MT}$ , seja de não aplicação do operador por permuta (*PerMut*), o indivíduo proveniente do cruzamento segue sem modificações para a mutação especialista.

No *EspMut*, é verificado, por meio de sorteio simples e de acordo com a taxa de mutação  $\alpha_{MT}$ , se cada gene do indivíduo sob ação do operador sofrerá ou não uma perturbação. Em caso afirmativo, é realizado um segundo sorteio que define a decisão de se realizar o incremento ou, caso contrário, a subtração de um reforço no gene. Para este segundo sorteio, a decisão de incremento ou de subtração de um reforço é realizada com base na média aritmética dos valores apresentados pelos três índices de sensibilidade calculados para os ramos candidatos relacionados ao gene. Neste caso, a proba-

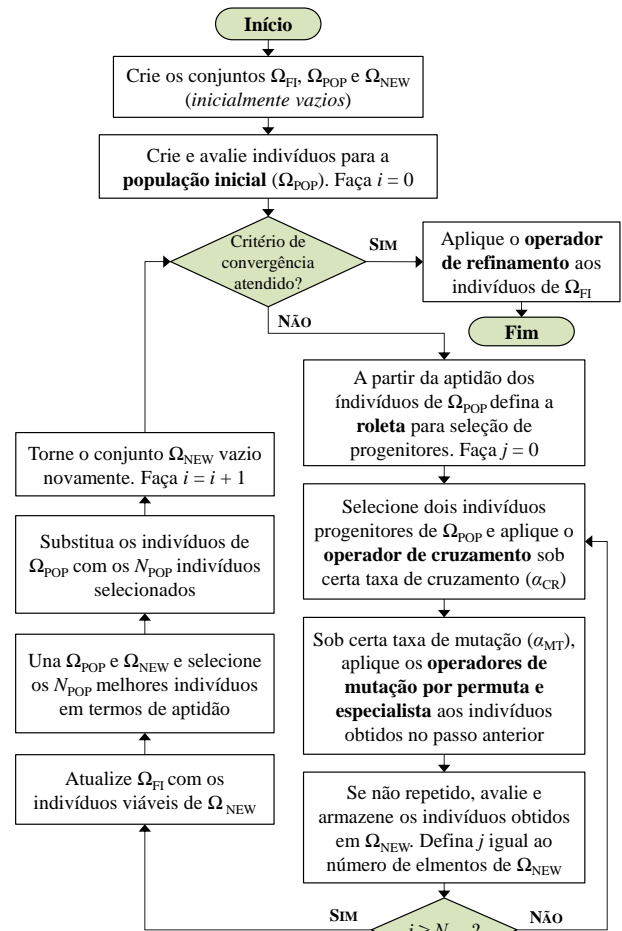


Fig. 1 Fluxograma simplificado da ferramenta AGA-PET.

bilidade de incrementar o gene (adicionar um reforço) corresponde ao valor da média obtido. Se de acordo com o sorteio a decisão é a de não incremento, um reforço é então subtraído do gene (caso possua algum). Portanto, os genes relacionados aos ramos com maiores valores de carregamento na operação com rede intacta e/ou de sobrecarga em caso de contingências apresentam maiores probabilidades de receber um reforço. Por outro lado, aos genes que correspondem a ramos candidatos com menores níveis de carregamento e de sobrecarga (e, portanto, menores valores para os índices de sensibilidade) estão atreladas maiores probabilidades de subtração de reforços. Vale lembrar que os índices de sensibilidade são normalizados, o que viabiliza o emprego do operador de mutação especialista.

Dada a ação do operador por permuta (*PerMut*), cada indivíduo proveniente do cruzamento pode gerar até três novos indivíduos no processo de mutação, que sofrem ação do operador especialista (*EspMut*) e, em seguida, são avaliados conforme função objetivo (3). No caso da geração de três indivíduos neste processo, é selecionado para seguir pelo processo evolutivo do AGA-PET apenas aquele que possui a melhor aptidão. Uma situação hipotética deste processo de mutação, em que cada indivíduo gerado no cruzamento sofre as perturbações causadas tanto pelo operador por permuta (*PerMut*) quanto pelo operador especialista (*EspMut*), é ilustrada na Fig. 2.

c) *Operador de Refinamento*: O refinamento é um operador avançado empregado ao final do processo evolutivo do AGA-PET a cada indivíduo viável do conjunto  $\Omega_{FI}$  final. Ao final do processo iterativo, esses indivíduos podem apresentar reforços desnecessários, que podem ser removidos sem tornar o plano inviável. Portanto, quando aplicado a um indivíduo, o refinamento realiza a remoção de seus reforços um a um, avaliando a viabilidade de cada um dos indivíduos resultantes. As soluções geradas após o emprego deste operador equivalem às soluções finais do AGA-PET.

#### 4. TESTES E RESULTADOS

A análise de desempenho da ferramenta AGA-PET proposta é baseada em testes realizados com dois diferentes sistemas de potência: o sistema IEEE-RTS (IEEE APM, 1979) e uma configuração do Sistema Sul Brasileiro (SSB) (Haffner, et al., 2000). Estes sistemas apresentam dimensões e características distintas entre si e são amplamente empregados para realização de estudos do planejamento da transmissão.

A fim de se verificar os reais benefícios inerentes ao emprego do AGA-PET, seu desempenho é comparado àquele apresentado por uma versão clássica do algoritmo genético, aqui denominada (AGC). Basicamente, a ferramenta AGC foi implementada seguindo as mesmas premissas consideradas para o AGA-PET em relação à sua estrutura, conforme fluxograma da Fig. 1. As diferenças básicas entre o AGC implementado em relação ao AGA-PET residem na não utilização dos operadores de mutação específicos e do operador avançado de refinamento. Sendo assim, após emprego do cruzamento, no AGC uma estratégia básica de mutação é utilizada. Para cada gene do indivíduo submetido à mutação, é realizado um primeiro sorteio que define, de acordo com a taxa de mutação  $\alpha_{MT}$ , se este elemento sofrerá ou não uma perturbação. Em caso afirmativo, um segundo sorteio define, com igual probabilidade, se o elemento será incrementado ou decrementado, respeitando-se os limites superior e inferior para o elemento, i.e., a restrição (1.6).

Com o objetivo de verificar a robustez dos algoritmos em relação aos seus parâmetros, os mesmos ajustes são utilizados tanto no AGA-PET quanto no AGC, bem como para os dois sistemas em estudo. De forma geral, são efetuados testes com dois diferentes tamanhos de população:  $N_{POP} = 600$  e  $N_{POP} = 700$ . Os demais parâmetros são definidos, em todos os testes, como: tamanho de  $\Omega_{FI}$  limitado em 50 indivíduos (i.e.,  $N_{FI} = 50$ ); taxas de cruzamento ( $\alpha_{CR}$ ) e de mutação ( $\alpha_{MT}$ ) iguais a, respectivamente, 65% e 8%;  $N_{MAX-GER} = 200$  e  $N_{STG} = 15$ , ou seja, o processo evolutivo é interrompido quando atinge um número máximo de gerações igual a 200 ou com a estagnação do melhor indivíduo viável conhecido por 15 gerações consecutivas, o que acontecer primeiro.

Uma vez que o AGA-PET proposto configura uma ferramenta de otimização estocástica, propõe-se, ainda, a avaliação de sua eficiência em cada teste por meio de quatro índices estatísticos de desempenho, calculados a partir de 50 execuções do algoritmo, em que diferentes sementes para o gerador de números pseudoaleatórios são utilizadas em cada uma delas. Os índices de desempenho são definidos como:

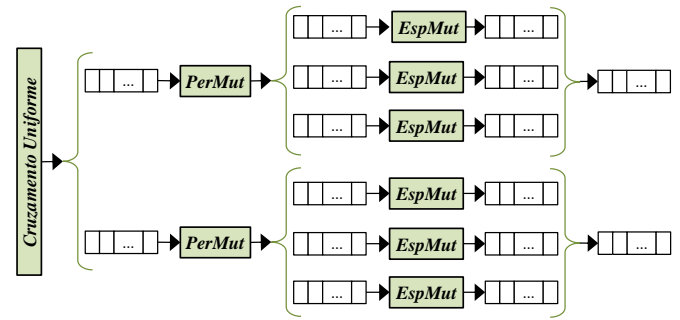


Fig. 2 Processo de mutação.

- *Taxa de Sucesso* –  $T_S$  (em %): razão percentual entre o número de execuções de sucesso e o total de execuções realizadas. Uma execução é considerada de sucesso quando encontra pelo menos uma das 10 melhores soluções conhecidas para o problema;
- *Tempo Médio de Execução* –  $T_M$  (em minutos): corresponde ao tempo médio por execução;
- $D_{Best}$  (em %): desvio percentual médio entre a aptidão da melhor solução encontrada em cada execução e o investimento da melhor solução conhecida;
- $D_{10Best}$  (em %): desvio percentual verificado entre a média das aptidões das 10 melhores soluções encontradas em cada execução e o investimento da melhor solução conhecida.

Por fim, cabe informar que as rotinas do AGA-PET e do AGC foram desenvolvidas em linguagem C#.NET, com exceção da biblioteca GLPK utilizada para solução dos problemas de otimização linear, implementada em C++, e da biblioteca para solução do fluxo de potência DC a cada contingência analisada, implementada em FORTRAN. Todos os testes foram realizados utilizando um computador pessoal (PC) com processador Intel Xeon 3.5 GHz.

##### 4.1 Sistema IEEE-RTS

O sistema IEEE-RTS (IEEE APM, 1979) apresenta em sua topologia base 24 barras, 34 ramos com 38 circuitos já existentes. Sua capacidade total de geração instalada é de 3405 MW e o pico de carga verificado é de 2850 MW. Para o IEEE-RTS, no estudo PET são considerados 41 ramos candidatos que podem receber até 3 reforços cada, o que resulta em soluções representadas por indivíduos compostos por 41 genes, que podem apresentar os valores 0, 1, 2 ou 3.

Os índices estatísticos de desempenho apresentados pelos algoritmos AGA-PET e AGC para o IEEE-RTS podem ser vistos na Tabela 1. Conforme definição, estes índices foram calculados com base no conjunto das 10 melhores soluções encontradas em todas as execuções com o sistema IEEE-RTS. Para este sistema, o menor investimento obtido em todos os testes foi de \$681 milhões, sendo que todas as 10 melhores soluções identificadas são compostas de 17 reforços e apresentam este mesmo investimento. Neste caso, cada solução apresenta um conjunto próprio de reforços, com subconjuntos comuns.



TABELA 1. RESULTADOS PARA SISTEMA IEEE-RTS

Teste	Ferramenta	$N_{POP}$	$T_S$ (%)	$T_M$ (min.)	$D_{Best}$ (%)	$D_{10Best}$ (%)
A.1	AGA-PET	600	94	2,33	0,23	1,49
A.2	AGA-PET	700	96	2,70	0,12	1,51
A.3	AGC	600	38	1,34	3,91	7,05
A.4	AGC	700	44	1,30	2,93	5,97

Para os resultados do AGA-PET, destaque pode ser dado às elevadas taxas de sucesso ( $T_S$ ) atingidas. No Teste A.1, por exemplo, verifica-se que em 47 das 50 execuções ( $T_S = 94\%$ ) o AGA-PET foi capaz de identificar pelo menos uma das 10 melhores soluções conhecidas. Ainda assim, mesmo que nem todas as execuções tenham sido capazes de identificar uma dessas 10 soluções, a melhor solução de cada execução apresenta, em média, um investimento apenas 0,23% ( $D_{Best}$ ) maior que o melhor conhecido (\$ 681 milhões). Além disso, a média de investimento das 10 melhores soluções de cada execução é apenas 1,49% maior que este investimento ( $D_{10Best}$ ). Já no Teste A.2, em 48 das 50 execuções do AGA-PET, pelo menos uma das 10 melhores soluções conhecidas foi identificada ( $T_S = 96\%$ ), acarretando em  $D_{Best} = 0,12\%$  e  $D_{10Best} = 1,51\%$ . Esta leve melhora em relação ao Teste A.1 é consequência da utilização de uma maior população.

No que se refere ao tempo médio por execução ( $T_M$ ), é possível verificar uma redução média de 47,17% nos testes com o AGC (Testes A.3 e A.4) em relação àqueles realizados com o AGA-PET (A.1 e A.2). Tal constatação pode ser explicada pelo fato de que o emprego dos operadores específicos e avançados de mutação no AGA-PET resulta na geração e avaliação de um maior número de indivíduos a cada geração do processo evolutivo, acarretando, assim, em um maior esforço computacional exigido. Contudo, os resultados do AGA-PET se mostram consideravelmente superiores aos do AGC em todos os demais índices de desempenho. As taxas de sucesso ( $T_S$ ) obtidas pelos Testes A.3 e A.4, por exemplo, foram, em média, 56,87% menores que àquelas obtidas em A.1 e A.2. Já os índices  $D_{Best}$  e  $D_{10Best}$  apresentaram, em média, valores 20,71 e 4,34 vezes maiores.

#### 4.2 Sistema SSB

O Sistema Sul Brasileiro (SSB) (Haffner, et al., 2000) é composto de 46 barras e 47 ramos, com 62 circuitos. Destaca-se que, das 46 barras do sistema SSB, 11 são inicialmente isoladas da rede, sendo 2 delas barras de geração. Para o estudo PET, são considerados 79 ramos candidatos que podem receber até 3 reforços cada um.

Os índices estatísticos de desempenho apresentados pelas ferramentas AGA-PET e AGC para o sistema SSB podem ser vistos na Tabela 2. Ressalta-se, que os mesmos conjuntos de parâmetros utilizados para o IEEE-RTS foram também utilizados para o sistema SSB. Para este sistema, o menor investimento obtido foi apresentado por um só plano de expansão, com 22 reforços, e corresponde ao montante de \$ 239,02 milhões. O investimento médio verificado para as 10 melhores soluções identificadas em todos os testes é de \$ 243,13 milhões, e o número médio de reforços é de 22,6.

TABELA 2. RESULTADOS PARA SISTEMA SSB

Teste	Ferramenta	$N_{POP}$	$T_S$ (%)	$T_M$ (min.)	$D_{Best}$ (%)	$D_{10Best}$ (%)
B.1	AGA-PET	600	68	5,92	2,24	5,91
B.2	AGA-PET	700	72	7,13	1,81	5,35
B.3	AGC	600	6	4,84	17,24	21,17
B.4	AGC	700	12	5,43	15,76	19,90

Apesar do sistema SSB possuir maior dimensão que o IEEE-RTS, é possível constatar um bom desempenho do AGA-PET quando comparado com o AGC. Como exemplo, citam-se as elevadas taxas de sucesso verificadas para os Testes B.1 e B.2 em relação a B.3 e B.4 (em média, 87,25% maiores). Além disso, valores reduzidos de  $D_{Best}$  e de  $D_{10Best}$  podem ser verificados para o AGA-PET, o que indica a boa qualidade tanto da melhor quanto das 10 melhores soluções obtidas em cada execução da ferramenta. Para o AGC, os índices  $D_{Best}$  e  $D_{10Best}$  apresentam, em média, valores 8,20 e 3,65 vezes maiores em relação àqueles apresentados pelo AGA-PET.

#### 4.3 Análise dos Resultados

De forma geral, o desempenho do AGA-PET pode ser ainda refinado a partir de um aprimoramento no ajuste de seus parâmetros. Contudo, mediante os resultados apresentados e analisados, é possível verificar uma grande robustez apresentada pela ferramenta proposta em relação a este ajuste. Mesmo frente às diferentes dimensões dos problemas estudados, um só conjunto de parâmetros foi capaz de garantir a identificação de boas soluções (planos de expansão) para os dois sistemas utilizados. O mesmo não pôde ser verificado a partir dos resultados apresentados pelo AGC. Com esta última ferramenta, quando são utilizados os mesmos ajustes de parâmetros para todos os testes, foi observada uma queda considerável de qualidade dos resultados para o sistema SSB (de maior porte) em comparação com o sistema IEEE-RTS. Assim sendo, infere-se que a robustez em relação ao ajuste de parâmetros é um aspecto altamente positivo e relevante do AGA-PET.

Além disso, em termos de qualidade do conjunto final de soluções, o AGA-PET apresenta uma maior recorrência de planos de expansão com melhores investimentos se comparado ao AGC. Na Fig. 3, gráficos *Boxplot*, gerados a partir das 10 melhores soluções identificadas em todas as 50 execuções dos Testes A.2, A.4, B.2 e B.4 (com  $N_{POP} = 700$ ), corroboram esta afirmação. Nesses gráficos, são exibidos os desvios percentuais dados por cada uma dessas soluções (500 soluções de cada teste) em relação ao melhor investimento conhecido para o respectivo sistema. De forma geral, além de desvios máximos consideravelmente menores, para o AGA-PET verifica-se também uma maior concentração de soluções mais próximas aos mínimos (0%) em cada gráfico. Para o IEEE-RTS (Fig. 3.a), por exemplo, pelo menos 75% das soluções analisadas do AGA-PET apresentam desvios menores ou iguais a 2,35% (quartil superior), enquanto que para o AGC este limite é 3,44 vezes maior (8,08%). Comportamento análogo é verificado para o SSB (Fig. 3.b), em que pelo menos 75% das soluções identificadas pelo AGA-PET apresentam desvios menores ou iguais ao quartil

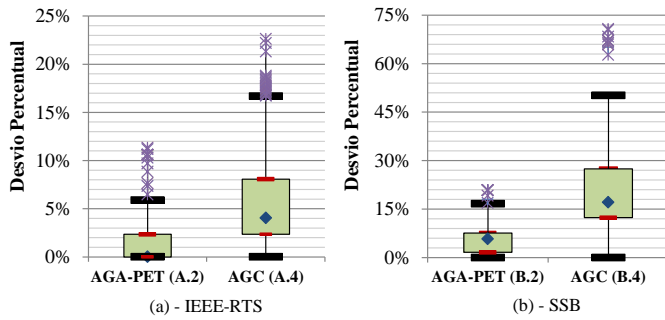


Fig. 3 Desvios percentuais: Testes (a) A.2 e A.4; (b) B.2 e B.4.

superior de 7,63%. Para o AGC, este mesmo limite é 3,60 vezes maior (27,48%). Na Fig. 3.b), para o SSB, deve-se notar, ainda, o grande número e a distância de valores acima do máximo quartil nas soluções geradas pelo AGC em comparação às soluções analisadas do AGA-PET.

## 5. CONCLUSÕES

É proposto neste artigo, para solução eficiente do problema de planejamento da transmissão, um novo algoritmo genético aprimorado, denominado AGA-PET. Informações heurísticas relacionadas ao fluxo de potência da rede de transmissão, traduzidas por meio de índices de sensibilidade, são incorporadas ao processo evolutivo da técnica algoritmo genético, resultando em uma ferramenta preparada para lidar com expansão de sistemas elétricos que apresentam diferentes características, tanto de dimensões quanto topológicas. De forma geral, o emprego dos índices de sensibilidade conduz o processo evolutivo do AGA-PET com observância das necessidades operativas específicas da rede de transmissão. O critério de segurança “N-1” é incorporado ao processo de otimização e um modelo DC com perdas é implementado para análise das configurações obtidas.

Índices estatísticos de desempenho, calculados a partir de várias execuções do algoritmo, com diferentes sementes para geração dos números pseudoaleatórios, permitiram constatar a eficiência do AGA-PET. Mediante análise dos resultados obtidos para dois sistemas testes utilizados, que apresentam diferentes dimensões e características, foi possível, ainda, verificar um bom nível de robustez em relação ao ajuste de parâmetros. Além disso, os resultados obtidos pelo AGA-PET se mostraram consideravelmente superiores àqueles apresentados por uma versão clássica do algoritmo genético.

É importante ressaltar, que o AGA-PET proposto neste trabalho, com base no problema estático e de longo prazo para o planejamento da transmissão, é uma ferramenta de otimização flexível. Esta ferramenta pode ser adaptada e empregada em conjunto com outros modelos de formulação do PET, considerando diferentes fases de estudo do problema. Para o horizonte de curto prazo, por exemplo, quando a utilização do modelo AC é amplamente difundida, informações heurísticas relacionadas aos níveis de tensão das barras e aos fluxos de potência reativa da rede podem ser manipuladas e transformadas em índices de sensibilidade, os quais passam a ser também utilizados durante o processo evolutivo de solução do AGA-PET.

- Bakirtzis, A.G., Biskas, P.N., Zoumas, C.E. and Petridis, V. (2002). Optimal power flow by enhanced genetic algorithm. *IEEE Trans. Power Syst.*, 17(2), pp. 229-236.
- Faria, H., Binato, S., Resende, M.G.C., and Falcão, D.M. (2005). Power transmission network design by greedy randomized adaptive path relinking. *IEEE Trans. Power Syst.*, 20(1), pp. 43-49.
- Gomes, P.V. and Saraiva, J.T. (2019). State-of-the-art of transmission expansion planning: a survey from restructuring to renewable and distributed electricity markets. *Electr. Power and Energy Syst.*, 111, pp. 411-424.
- Haffner, S., Monticelli, A., Garcia, A., Mantovani, J., and Romero, R. (2000). Branch and bound algorithm for transmission system expansion planning using a transportation model. *IEE Proc. Gen. Trans. Distrib.*, 147(3), pp. 149-156.
- Hemmati, R., Hooshmand, R.A., and Khodabakhshian, A. (2013). State-of-the-art of transmission expansion planning: comprehensive review. *Renew. Sust. Energ. Rev.*, 23, pp. 312-319.
- IEEE APM (1979). IEEE reliability test system. *IEEE Trans. Power App. and Syst.*, 98(6), pp. 2047-2054.
- Leite da Silva, A.M., Rezende, L.S., Manso, L.A.F., and Anders, G.J. (2010). Transmission expansion planning: a discussion on reliability and N-1 security criteria. *Proceedings of the 11th International Conference on Probabilistic Methods Applied to Power Systems*. IEEE, Singapore.
- Leite da Silva, A.M., Rezende, L.S., Honório, L.M., and Manso, L.A.F. (2011). Performance comparison of meta-heuristics to solve the multistage transmission expansion planning problem. *IET-GTD*, 5(3), pp. 360-367.
- Li, W. (2011). *Probabilistic transmission system planning*. Wiley-IEEE Press, New Jersey.
- Lumbreras, S. and Ramos, A. (2016). Challenges to transmission expansion planning. Survey of recent practice and literature review. *Electr. Power Syst. Res.*, 134, pp. 19-29.
- Moradi, M., Abdi, H., Lumbreras, S., Ramos, A., and Karimi, S. (2016). Transmission expansion planning in the presence of wind farms with a mixed AC and DC power flow model using an imperialist competitive algorithm. *Electr. Power Syst. Res.*, 140, pp. 493-506.
- Silva, I.J., Rider, M.J., Romero, R., Garcia, A.V., and Murari, C.A. (2005). Transmission network expansion planning with security constraints. *IEE Gen., Transm., Distrib.*, 152(6), pp. 828-836.
- Sousa, A.S. and Asada, E.N. (2015). Long-term transmission system expansion planning with multi-objective evolutionary algorithm. *Electr. Power Syst. Res.*, 119, pp. 149-156.
- Zhang X. and Conejo, A. J. (2018). Candidate line selection for transmission expansion planning considering long- and short-term uncertainty. *Electr. Power and Energy Syst.*, 100, pp. 320-330.