

Planejamento do sistema de transmissão utilizando algoritmo genético e *Unit Commitment*

Karina Mosqueira Valente

Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro

Rio de Janeiro, Brasil

I. INTRODUÇÃO

O Sistema Interligado Nacional (SIN) é extremamente complexo. Além disso, a expectativa média de crescimento da carga no Brasil, segundo a Empresa de Pesquisa Energética (EPE), é de 3.6% ao ano no período de 2021-2025 [1]. Portanto, o planejamento do sistema elétrico é importante para se obter o atendimento integral à demanda e a menor custo.

Nesse sentido, as decisões tomadas com relação a expansão do sistema influenciam diretamente o consumidor. Dado que o sistema é complexo, existem inúmeras possibilidades para a expansão quando a mesma se faz necessária. Dessa forma, para reduzir o tempo de trabalho na busca de uma melhor solução, esse artigo propõe a utilização de computação evolucionária para solucionar o problema.

O algoritmo genético proposto busca encontrar as linhas de transmissão à serem expandidas minimizando o corte de carga e o custo de investimento. Para se encontrar o corte de carga, o algoritmo genético passa as linhas à serem expandidas para um otimizador que busca o corte de carga devido a essa rede. Dessa forma, para cada indivíduo do algoritmo genético roda-se um otimizador para se encontrar o corte de carga tanto na pré-contingência quanto na pós-contingência adotando-se o critério de confiabilidade N-1 e constrói-se a função de avaliação buscando minimizar o corte de carga dado pelo otimizador e os custos das linhas expandidas.

O otimizador é necessário para se encontrar o corte de carga e garantir-se que as leis físicas do sistema estão sendo respeitadas. Quando o otimizador não encontra uma solução viável, esse indivíduo é extremamente penalizado na função de avaliação do algoritmo genético.

Na seção II é apresentado o sistema, o otimizador utilizado para se encontrar o corte de carga, além de se respeitar as leis físicas do sistema, e o algoritmo genético construído para o problema. Na seção III é apresentado o passo a passo da solução. Na seção IV são apresentados os resultados encontrados na implementação do método. As conclusões são apresentadas na seção VI.

II. METODOLOGIA

Para resolver o problema do planejamento de linhas de transmissões o engenheiro responsável deve levar em consideração diversos parâmetros que são dependentes entre si o que acaba por dificultar a escolha de quais linhas deverão ser construídas a fim de reduzir o corte de carga mantendo o gasto o mais baixo possível. Além disso, o corte de carga é

previsto utilizando algoritmos de otimização que levam em consideração o custo de se cortar a carga de uma região tanto na pré-contingência quanto na pós-contingência, além das sobrecargas, se existir, nas barras do sistema. Assim, para cada sistema proposto é necessário verificar os cortes de carga, as sobrecargas e os custos de implementação, as variáveis que regem essas escolhas acabam alterando esses três parâmetros. Em um sistema real as possibilidades são tantas que não é possível encontrar uma solução ótima sem auxílio de algum algoritmo de otimização.

Dessa forma, é proposto nesse artigo a utilização de algoritmos de computação evolucionária, mais especificamente algoritmos genéticos, para tentar solucionar e mitigar esse problema descrito anteriormente. A Figura 1 mostra o diagrama de execução do algoritmo proposto.

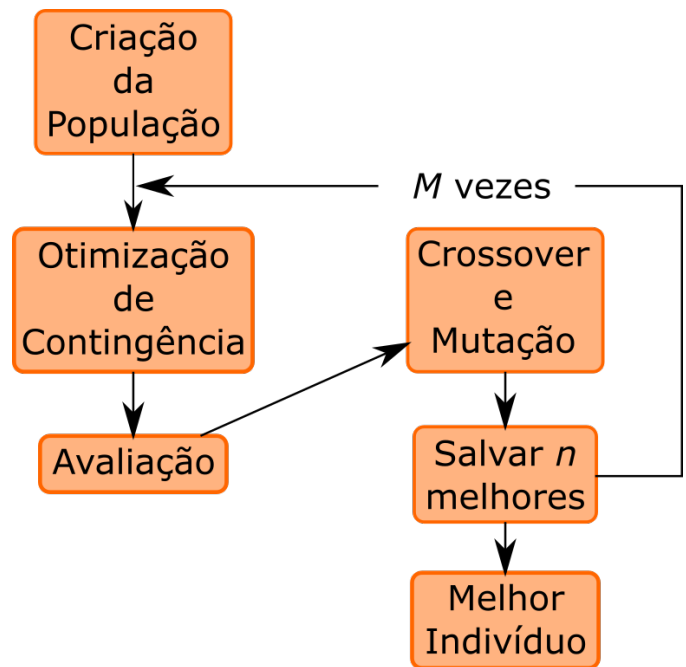


Fig. 1. Diagrama simplificado do algoritmo genético proposto.

Pode-se observar que para o funcionamento do algoritmo genético é necessário que a otimização de pré e pós contingência seja usada para estimar os possíveis cortes de cargas e as sobrecargas, e com esses resultados o algoritmo genético irá avaliar e ordenar os indivíduos mais aptos. Nas subseções

II-B e II-C faz-se o detalhamento dos parâmetros e variáveis utilizadas pelos dois algoritmos de otimização utilizados.

A. O sistema

Para esse problema foi utilizado sistema de 24 barras do IEEE para o teste de confiabilidade visto na Figura 2.

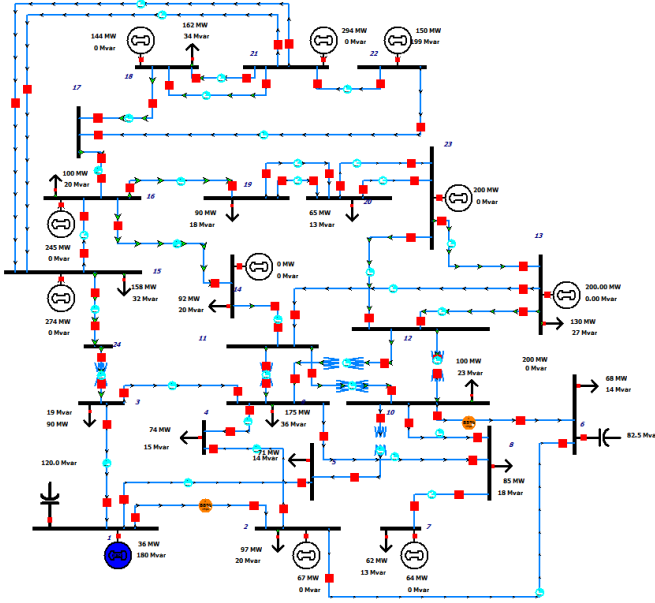


Fig. 2. Sistema de 24 barras do IEEE para teste de confiabilidade [2].

Para esse sistema foram propostas a possível construção de 12 novas linhas descritas na Tabela I. Essas linhas foram propostas sem nenhum objetivo específico, isso significa que qualquer outras linhas poderiam ter sido propostas.

TABELA I
PARÂMETROS DAS LINHAS PROPOSTAS.

ID	De	Para	$F_{C_{pu}}$	$xl_{C_{pu}}$	C_{lc}	Base
50	1	2	1.75	0.0139	7.03E+06	100
51	1	3	1.75	0.2112	1.07E+08	100
52	1	5	1.75	0.0845	4.27E+07	100
53	2	4	1.75	0.1267	6.41E+07	100
54	2	6	1.75	0.192	9.71E+07	100
55	3	9	1.75	0.119	6.02E+07	100
56	6	10	1.75	0.0605	3.06E+07	100
57	6	10	1.75	0.0605	3.06E+07	100
58	11	14	5	0.0418	2.11E+07	100
59	12	23	5	0.0966	4.89E+07	100
60	7	8	1.75	0.0614	3.11E+07	100
61	7	8	1.75	0.0614	3.11E+07	100

Na Tabela I a coluna *ID* representa a identificação da linha – como o sistema original de 24 barras possui 49 linhas – sendo os números de identificação das novas linhas sequenciais a partir da última linha do sistema original, as colunas *De* e *Para* representam de qual barra parte a linha e em qual barra a linha chega, $F_{C_{pu}}$ é a capacidade máxima da linha de transmissão

candidata em pu, $xl_{C_{pu}}$ é a reatância da linha de transmissão candidata em pu, C_{lc} é o custo de implementação de cada linha em reais, e Base é a base de potência em MW.

Os dados utilizados estão disponíveis em [3].

B. A otimização de pré-contingência e pós-contingência

A otimização de pré-contingência e pós-contingência retornará a soma de todos os cortes de carga do sistema. Essa soma será utilizada na função de avaliação do algoritmo genético.

Para se encontrar os cortes de carga do sistema, utilizou-se a função objetivo e as restrições de *Unit Commitment* para um único estágio. As equações seguem abaixo.

$$\min_{\theta} = \sum_{i \in U} c_i \cdot g_i + \sum_{b \in B} c_{def} \cdot def_b + \sum_{i \in U} \sum_{k \in K} c_i \cdot g_i^k + \sum_{b \in B} \sum_{k \in K} c_{def} \cdot def_b^k \quad (1)$$

sujeito à

$$\sum_{i \in U_b} g_i + \sum_{l \in L_B^+} f_l - \sum_{l \in L_B^-} f_l = d_b - def_b \quad \forall b \in B \quad (2)$$

$$0 \leq def_b \leq d_b \quad \forall b \in B \quad (3)$$

$$-F_l \leq f_l \leq F_l \quad \forall l \in L \quad (4)$$

$$f_l = \frac{1}{x_l} (\theta_{from(l)} - \theta_{to(l)}) \quad \forall l \in L \quad (5)$$

$$G_i^{min} \leq g_i \leq G_i^{max} \quad \forall i \in U \quad (6)$$

$$\sum_{i \in U_b} g_i^k + \sum_{l \in L_B^+} f_l^k - \sum_{l \in L_B^-} f_l^k = d_b - def_b^k \quad \forall b \in B \quad (7)$$

$$0 \leq def_b^k \leq d_b \quad \forall b \in B \quad (8)$$

$$-F_l \cdot a_l^{L,(k)} \leq f_l \leq F_l \cdot a_l^{L,(k)} \quad \forall l \in L \quad (9)$$

$$f_l = \frac{a_l^{L,(k)}}{x_l} (\theta_{from(l)}^{(k)} - \theta_{to(l)}^{(k)}) \quad \forall l \in L \quad (10)$$

$$G_i^{min} \cdot a_g^{G,(k)} \leq g_i \leq G_i^{max} \cdot a_g^{G,(k)} \quad \forall i \in U \quad (11)$$

onde as variáveis de decisão do conjunto θ são g_i , g_i^k , def_b , def_b^k , f_l , f_l^k , θ_b e θ_b^k .

Os dados de entrada dessa otimização são d_b que é a demanda de cada barra, G_i^{max} e G_i^{min} que são a geração máxima e mínima dos geradores do sistema, F_l que é a capacidade da linha de transmissão, x_l que é a reatância da linha de transmissão, c_i é o custo marginal dos geradores, e c_{def} é o custo do corte de carga.

A função objetivo (1) busca minimizar o custo da geração dado os custos dos geradores e o custo de corte de carga. As restrições de pré-contingência vão até a equação (6), após essa equação são as restrições de pós-contingência. A equação (2) é a primeira lei de Kirchhoff, a equação (3) mostra o domínio do corte de carga de cada barra, a equação (4) limita o fluxo de potência nas linhas de transmissão para

não extrapolar as capacidades, a equação (5) é a segunda lei de *Kirchhoff*, e, por fim, a equação (6) limita a geração dos geradores para não extrapolar as capacidades. As outras equações são iguais as citadas acima, mas para cada cenário de contingência, em que $a_l^{L,(k)}$ e $a_g^{G,(k)}$ são matrizes de dimensão número de linhas de transmissão versus número de cenários de contingência e número de geradores versus número de cenários de contingência, respectivamente. Essas matrizes possuem o número 1 nos elementos ativos e 0 nos elementos que falharam. Utilizando o critério N-1, em cada cenário ou um gerador ou uma linha de transmissão estará em falta.

C. O algoritmo genético proposto

O algoritmo genético proposto tem por objetivo apresentar e definir quais linhas devem ser construídas tendo como objetivo a minimização do custo financeiro e o menor corte de carga possível. Para descrever o algoritmo genético criado, pode-se iniciar pela descrição do cromossomo.

Dada a Tabela I, os cromossomos criados representam a criação ou não de uma determinada linha e dessa forma uma representação possível é um vetor com valores binários. A equação (12) representa um típico cromossomo do GA proposto.

$$[x_1 \ x_2 \ x_3 \ \cdots \ x_9 \ x_{10} \ x_{11} \ x_{12}] \quad (12)$$

onde $x_{n_1 \dots n_2}$ representa cada linha entre as linhas candidatas e seu valor $\{x_{n_1 \dots n_2} \in \mathcal{N} | x_{n_1 \dots n_2} \in [0, 1]\}$ – representa a construção da linha (se for 1) ou a não construção (se for 0). Assim, se o cromossomo assumir o valor da equação (13) as linhas 50, 51, 55, 59, 60 e 61 devem ser construídas.

$$[1 \ 1 \ 0 \ 0 \ 0 \ 1 \ 0 \ 0 \ 0 \ 1 \ 1 \ 1] \quad (13)$$

A função objetivo do algoritmo é dada pela equação

$$\sum_{(i,j) \in \Omega} c_{ij} \cdot n_{ij} + \alpha \sum_{i \in \Gamma} \sum_{k \in K} r_i^k \quad (14)$$

onde Ω é o conjunto das linhas candidatas, Γ é o conjunto dos cortes de carga para cada barra, K é o conjunto de todos os cenários de contingência, c_{ij} é o custo da criação da linha que vai de i até j , n_{ij} – onde $\{n_{ij} \in \mathcal{N} | 0 \geq n_{ij} \leq 4\}$ – é a variável binária que indica se a linha ij será construída ou não, r_i é o corte de carga para a barra i e α é o coeficiente de déficit de carga.

O resumo dos parâmetros usados no algoritmo genético está disponível na Tabela II

TABELA II
PARÂMETROS DA CONFIGURAÇÃO DO GA.

Função Objetivo	$\sum_{(i,j) \in \Omega} c_{ij} \cdot n_{ij} + \alpha \sum_{i \in \Gamma} \sum_{k \in K} r_i^k$
Objetivo	Minimizar a função de avaliação
Padrão de <i>crossover</i>	Binário e corte em 2 pontos
Critério de parada antecipada:	Diferença entre os melhores de 50 gerações seguidas menor que 10^{-6}
Espaço de busca	$\{x_{n_1 \dots n_2} \in \mathcal{N} x_{n_1 \dots n_2} \in [0, 1]\}$
Tamanho da população	20 indivíduos
Número de gerações:	1200 épocas
Taxa de <i>crossover</i>	80%
Taxa de mutação	0.8%
Taxa de elitismo	10%
Seed	Cromossomo com nenhuma das linhas construídas

III. IMPLEMENTAÇÃO

A implementação da solução proposta por este artigo foi feita em dois *softwares* diferentes. O programa principal é executado no MATLAB® e a otimização para se encontrar o corte de carga de um dado sistema é feito em Julia. Um diagrama que mostra como foi implementado o programa completo pode ser visto na Figura 3.

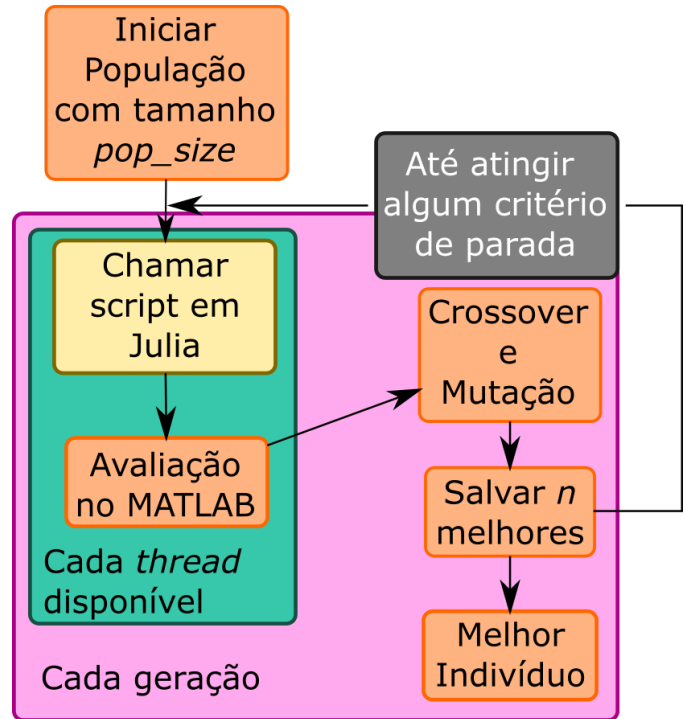


Fig. 3. Diagrama do programa implementado.

Nota-se que para realizar a avaliação de um indivíduo é necessário executar, primeiramente, a otimização que encontra o corte de carga de um dado sistema, e com o resultado obtido, avaliar e ordenar os indivíduos. Esse processo segue até atingir

algum dos critérios de paradas (parada antecipada ou número máximo de gerações).

Ademais, para aumentar a eficiência do programa foram utilizadas técnicas de computação paralela, nativas do Julia e através da *Parallel Computing toolbox* do MATLAB®.

IV. RESULTADOS

Para comparar os resultados e verificar se o GA conseguiu obter um resultado satisfatório, utiliza-se como base o caso original. Nessa situação, tem-se o custo de implementação de R\$ 0,00 e o déficit de carga de 32587,32 MW. A ideia é reduzir ao máximo o déficit sem ter um custo muito alto de implementação. Rodando o GA pode-se obter os resultados apresentados nas Figuras 4 a 8.

Vale salientar que os indivíduos com as menores avaliações são os mais aptos. Isso, tendo em vista a função de avaliação apresentada na equação (14), mostra que o indivíduos com avaliação maior significa mais gasto ou investimento, que é exatamente o oposto do objetivo desejado.

Além disso, para verificar se o resultado obtido não foi encontrado por acaso, o algoritmo foi rodado 10 vezes para cada configuração. Os resultados apresentados aqui são apenas um dos resultados obtidos e que representam o comportamento geral de todas os resultados obtidos para cada configuração.




Fig. 4. Média de avaliações por geração dos indivíduos.

Na Figura 4, pode-se observar que no início a média das avaliações é alta. Esse comportamento era esperado tendo em vista que é possível que o GA gere indivíduos que não sejam soluções viáveis para a otimização que busca o corte de carga de cada barra tanto na pré-contingência quanto na pós-contingência, e, nesse caso, há uma penalização grande para esses indivíduos. Nota-se, no entanto, que a média decresce com o tempo, mostrando que os indivíduos inviáveis tendem a desaparecer com o tempo, permanecendo, em sua maioria, as soluções viáveis para a otimização realizada em Julia.

É importante salientar que os valores das médias mínimas atingidos pelo GA não são 0 como aparenta ser na Figura 4.

Removendo os *outliers* e focando o gráfico na região a partir da geração 10, nota-se o gráfico apresentado na Figura 5.




Fig. 5. Média de avaliações por geração dos indivíduos, a partir da 10ª.

O limites das avaliações médias estão mais claros e são definidos entre $1,0589 \times 10^{12}$ e $1,4 \times 10^{23}$. Observa-se também que os valores da média, com o passar das gerações, fica oscilando em torno de $3,5 \times 10^{22}$.

Observando, agora, apenas o melhor indivíduo de cada geração destaca-se a Figura 6




Fig. 6. Melhor avaliação por geração.

Nota-se que a avaliação foi reduzindo com o tempo, mostrando que o GA conseguiu encontrar indivíduos viáveis que solucionam o problema de planejamento da expansão. O melhor indivíduo foi encontrado na geração 10.

O cromossomo encontrado, infelizmente, não possui déficit de corte de carga nulo, mas consegue reduzir pela metade o déficit. O valor encontrado para tal é de 15085,2801 MW.

Um teste interessante de se realizar é alterar o tamanho da população para ver o comportamento. Para isso, altera-se o

tamanho da população para 8. Os resultados obtidos podem ser vistos nas Figuras 7 e 8




Fig. 7. Média de avaliações por geração dos indivíduos.




Fig. 8. Melhor avaliação por geração.

Nota-se que o resultado obtido na configuração original também foi encontrado com a população menor. A grande diferença foi o número de gerações necessários para encontrar o melhor indivíduo. Mas no geral o comportamento foi o mesmo. Em ambos os casos o melhor indivíduo encontrado é apresentado na equação (15)

$$[0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 1 \ 1] \quad (15)$$

V. CONCLUSÃO

A seção IV apresenta os resultados encontrados para o programa desenvolvido neste artigo. Notou-se a capacidade de solucionar problemas mais complexos, onde a escolha manual é muito custosa, do GA. Mesmo não conseguindo encontrar uma solução com corte carga nulo, o resultado encontrado pelo algoritmo genético obteve uma redução de 53.7% na soma

dos cortes de carga do sistema saindo de 32587.32 MW para 15085.2801 MW.

Ademais, com os resultados obtidos nesse trabalho pode-se afirmar que o GA é uma ferramenta útil para os engenheiros que fazem o planejamento de expansão de um sistema de transmissão, reduzindo o tempo necessário para saber se a configuração é viável ou não para se construir.

Como comentado na seção II, as linhas candidatas propostas podem não ter sido suficientes para que o déficit de carga fosse nulo. Assim, uma melhoria para esse trabalho está em fazer um estudo acrescentando mais linhas candidatas para esse sistema, possibilitando um déficit de carga nulo em todos os cenários.

VI. CONCLUSÃO

Este trabalho não poderia ter sido realizado sem a inspiração dada pelo Fernando A. de Assis do Departamento de Engenharia Elétrica (DEPEL) da Universidade Federal de São João del-Rei(UFSJ). Além das ideias colaborativas de Henrique Pinheiro Saraiva, Doutorando em Engenharia Elétrica da Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio).

REFERÊNCIAS

- [1] Epe, ons e ccee divulgam previsão de carga para o planejamento anual da operação energética - ciclo 2021-2025. [Online]. Available: <https://www.epe.gov.br/pt/imprensa/noticias/epe-ons-e-ccee-divulgam-previsao-de-carga-para-o-planejamento-anual-da-operacao-energetica-ciclo-2021-2025->
- [2] IEEE 24-Bus System. [Online]. Available: <https://icseg.iti.illinois.edu/ieee-24-bus-system/>
- [3] Github dos dados utilizados no artigo. [Online]. Available: <https://github.com/karinaMV21/PlanejamentoTransmissaoGA/>
- [4] M. F. Anjos and A. J. Conejo, *Unit Commitment in Electric Energy Systems*.