

Alocação Otimizada de Reatores Lineares por Meio de Algoritmo Genético

Luciano Jorge Menezes
Dept. Pós-Graduação em Engenharia
Elétrica
Universidade Federal de Uberlândia
Uberlândia-MG, Brasil
ljorgemenezes@gmail.com

Maria de Fátima Penha dos Santos
Dept. Graduação em Engenharia
Elétrica
Universidade Federal de Uberlândia
Uberlândia-MG, Brasil
maria.penha@ufu.br

Carlos Eduardo Tavares
Dept. Pós-Graduação em Engenharia
Elétrica
Universidade Federal de Uberlândia
Uberlândia-MG, Brasil
cetavares@ufu.br

Ivan Nunes Santos
Dept. Pós-Graduação em Engenharia
Elétrica
Universidade Federal de Uberlândia
Uberlândia-MG, Brasil
ivan.ufu@gmail.com

Paulo Henrique Oliveira Rezende
Dept. Pós-Graduação em Engenharia
Elétrica
Universidade Federal de Uberlândia
Uberlândia-MG, Brasil
paulohenrique.rezende@ufu.br

Gustavo Travassos Aguiar da Silva
Dept. Neoenergia/Coelba
Neoenergia/Coelba
Salvador-BA, Brasil
gtravassos@neoenergia.com

Abstract — O sistema elétrico de potência é complexo e dinâmico, e o seu correto funcionamento depende do adequado controle dos níveis de tensão em seus barramentos. Caso estes valores estejam fora dos limites aceitáveis pelas normativas vigentes, podem surgir problemas técnicos e financeiros. Sabe-se que a alocação de reatores lineares é uma das técnicas utilizadas para manter os níveis de tensão dentro de limites aceitáveis, pois eles reduzem os valores de tensão quando presentes em uma rede elétrica. Contudo, determinar o local de instalação e a potência desses reatores pode ser uma tarefa difícil. Neste sentido, este artigo apresenta a aplicação de um algoritmo genético para otimizar a alocação de reatores lineares em um sistema elétrico de potência com trinta barras. Esse algoritmo é implementado na linguagem de programação Python, com o auxílio do fluxo de potência de Newton-Raphson, cuja função é obter as tensões para cada um dos indivíduos gerados pelo algoritmo genético.

Keywords — Python, Algoritmo Genético, Alocação Otimizada de Reatores Lineares.

I. INTRODUÇÃO

Tendo em vista que este artigo está relacionado à qualidade de energia elétrica, é fundamental apresentar uma definição clara neste enfoque. De acordo com [1], a qualidade da energia elétrica se refere a qualquer variação na tensão, corrente ou frequência que possa levar a falhas ou mau funcionamento dos equipamentos elétricos do consumidor. Assim, esta área pode ser subdividida em qualidade do atendimento, qualidade do serviço e qualidade do produto.

A qualidade do atendimento concentra-se no relacionamento comercial entre a empresa e o cliente. Por sua vez, a qualidade do serviço está intimamente ligada à continuidade no fornecimento de energia elétrica, que de maneira resumida, pode ser exemplificada com possíveis interrupções no fornecimento de energia elétrica. Já a qualidade do produto é determinada pelas características da forma de onda da tensão fornecida ao cliente. Caso a tensão esteja fora dos padrões em termos de frequência, amplitude, ou apresentar componentes harmônicos distintos da frequência fundamental, é possível concluir que há um problema associado à qualidade do produto [2].

No que tange às normativas Brasileiras, têm-se como referência dois órgãos regulamentadores. O primeiro, trata-se dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico (PRODIST), e, complementarmente tem-se

os procedimentos de rede, estabelecido pelo Operador Nacional do Sistema Elétrico (ONS).

O PRODIST, em seu módulo oito, estabelece que o sistema elétrico deve atender aos níveis de tensão de energia elétrica em regime permanente preestabelecidos, os quais são fiscalizados e passíveis de aplicação de multas [3]. Sob esta perspectiva, as Tabelas I, II e III destacam, em conformidade com o PRODIST, os valores considerados adequados, precários e críticos para pontos de conexão com tensão nominal igual ou superior a 230 kV, tensão nominal igual ou superior a 69 kV e inferior a 230 kV e tensão nominal igual ou superior a 2,3 kV e inferior a 69 kV, respectivamente.

TABELA I. PONTOS DE CONEXÃO EM TENSÃO NOMINAL IGUAL OU SUPERIOR A 230 kV.

Tensão de atendimento	Faixa de variação da tensão de leitura (TL) em relação à tensão de referência (TR)
Adequada	$0,95TR \leq TL \leq 1,05TR$
Precária	$0,93TR \leq TL < 0,95TR$ ou $1,05TR < TL \leq 1,07TR$
Crítica	$TL < 0,93TR$ ou $TL > 1,07TR$

Fonte: [3].

TABELA II. PONTOS DE CONEXÃO EM TENSÃO NOMINAL IGUAL OU SUPERIOR A 69 kV E INFERIOR A 230 kV.

Tensão de atendimento	Faixa de variação da tensão de leitura (TL) em relação à tensão de referência (TR)
Adequada	$0,95TR \leq TL \leq 1,05TR$
Precária	$0,90TR \leq TL < 0,95TR$ ou $1,05TR < TL \leq 1,07TR$
Crítica	$TL < 0,90TR$ ou $TL > 1,07TR$

Fonte: [3].

TABELA III. PONTOS DE CONEXÃO EM TENSÃO NOMINAL IGUAL OU SUPERIOR A 2,3 kV E INFERIOR A 69 kV.

Tensão de atendimento	Faixa de variação da tensão de leitura (TL) em relação à tensão de referência (TR)
Adequada	$0,93TR \leq TL \leq 1,05TR$
Precária	$0,90TR \leq TL < 0,93TR$
Crítica	$TL < 0,90TR$ ou $TL > 1,05TR$

Fonte: [3].

Seguindo no âmbito de normativas brasileiras, para níveis de tensão em regime permanente, é importante ressaltar os procedimentos da rede básica, que é estabelecido pelo ONS.

No Submódulo 9.7, Indicadores de Qualidade de Energia elétrica da Rede Básica, é dada a classificação da tensão de atendimento em regime permanente, em função da tensão nominal para barramentos sob responsabilidade de concessionárias de transmissão, conforme Tabela IV [4].

TABELA IV. INDICADORES DE QUALIDADE DE ENERGIA ELÉTRICA DA REDE BÁSICA.

Tensão nominal do ponto de observação da tensão (kV)	Adequada	Precária	Crítica
$TN \geq 230$	$0,95TC \leq TL \leq 1,05TC$	$0,93TC \leq TL < 0,95TC$ ou $1,05TC \leq TL < 1,07TC$	$TL < 0,93TC$ ou $TL > 1,07TC$
$69 \leq TN \leq 230$	$0,95TC \leq TL \leq 1,05TC$	$0,90TC \leq TL < 0,95TC$ ou $1,05TC < TL \leq 1,07TC$	$TL < 0,90TC$ ou $TL > 1,07TC$
$1 < TN < 69$	$0,93TC \leq TL \leq 1,05TC$	$0,90TC \leq TL < 0,93TC$	$TL < 0,90TC$ ou $TL > 1,05TC$

Fonte: [4].

Diante do exposto até o momento, torna-se evidente a preocupação com os níveis de tensão nos barramentos do sistema elétrico de potência. Nesse contexto, a gestão de potência reativa tem adquirido uma importância crescente para as empresas fornecedoras de energia, cujo objetivo é manter a tensão em conformidade com as normativas nacionais e/ou internacionais [5].

Ao se tratar dos níveis de tensão em regime permanente duas situações podem ocorrer. A primeira diz respeito a barramentos com tensão inferior a tensão adequada preconizada (subtensão). A segunda diz respeito a barramentos com tensão superior a tensão adequada (sobretensão).

Na tentativa de resolver o problema de subtensão podem ser utilizados bancos de capacitores. Essa prática é comum em subestações de todo mundo, de modo a elevar a tensão de um ponto específico da rede elétrica [6]. Em outra vertente, pode ocorrer a sobretensão. Nessa situação podem ser empregados reatores lineares, que buscam diminuir a tensão na barra em que foi alocado e na sua vizinhança [7].

Contudo, além da escolha do dispositivo para manter a tensão dentro de níveis aceitáveis, deve-se dar o devido destaque aos possíveis pontos de instalação desses equipamentos, de maneira a minimizar os custos e manter a tensão dentro de limites aceitáveis por normas. Visto que o problema de alocação ótima representa um problema que possui espaço de busca combinatório, que dificilmente pode ser varrido por método exaustivo, os algoritmos genéticos (AGs) são largamente utilizados de maneira a encontrar possíveis soluções ótimas [8].

Neste contexto, este artigo tem como proposta, determinar, por meio da aplicação de algoritmos genéticos, as barras de alocação, a potência dos reatores, bem como a quantidade mínima suficiente com o intuito de manter as tensões nas barras tão próximas quanto possível de 1 P.U. A rede elétrica utilizada como teste foi o sistema IEEE 30 barras modificado.

O método de fluxo de potência de Newton-Raphson foi empregado como componente essencial do algoritmo

genético, revelando a tensão em cada barra após a seleção de um indivíduo (possível solução para o problema em pauta). Tanto o algoritmo genético quanto o método de Newton-Raphson foram implementados na linguagem Python, escolhida por sua sintaxe relativamente simples e pela ausência de custos associados.

II. ALGORITMOS GENÉTICOS

Conforme foi discutido na introdução, sabe-se que os algoritmos genéticos fazem parte da Computação Evolutiva, a qual baseia-se, sobretudo, em estratégias de adaptação, seleção e evolução observadas na natureza. Sob essa ótica, desenvolveram-se estratégias de resolução de problemas, dentre as quais se encontram os AGs, a partir da modelagem computacional dos sistemas a serem solucionados sob moldes que os aproximassem de processos evolutivos, assim como é demonstrado na Fig.1 [8] - [11].


Fig.1. Metáfora que relaciona processos evolutivos à resolução computacional de problemas.

Evolução	Resolução do problema
Ambiente	↔ Problema
Indivíduo	↔ Possível solução
Adaptabilidade	↔ Qualidade

Fonte: [11].

De natureza estocástica, ou seja, imbuído de certa aleatoriedade, o tipo de algoritmo em questão identifica-se, ainda, como uma técnica meta-heurística de otimização combinatória. Nessa conjuntura, os algoritmos genéticos também se destacam por basearem sua metodologia de funcionamento na teoria de evolução das espécies de Charles Darwin e em conceitos provenientes ou derivados da teoria genética do biólogo austríaco Gregor Mendell [11] - [17]. Assim, os AGs são elaborados a partir da combinação de conceitos e elementos como seleção natural cromossomos, seleção, recombinação, mutação, entre outros, os quais são aplicados de acordo com o fluxograma exibido na Fig. 2.

Fig.2. Fluxograma de um algoritmo genético.



Fonte: [18].

III. ELEMENTOS DOS ALGORITMOS GENÉTICOS

Nesta seção são apresentados os operadores genéticos que fazem parte do algoritmo implementado neste artigo, objetivando a alocação ótima de reatores lineares de forma a corrigir desvios de tensão superiores aos valores máximos estabelecidos pelas normativas brasileiras.

A. População

Cada população corresponde a um conjunto de indivíduos, que representam possíveis soluções, cuja qualidade deve ser verificada mediante aplicação no sistema estudado. No caso da população inicial, a escolha dos componentes pode ocorrer de diversas maneiras, sendo que uma estratégia interessante e comumente utilizada consiste na escolha aleatória destes indivíduos.

O valor desta técnica de inicialização deriva do fato de que a formulação randômica favorece uma maior variedade de soluções e, conseqüentemente, propicia maior diversidade dos caminhos de busca da solução ótima, o que favorece que o algoritmo desenvolva uma busca mais completa. No entanto, também é possível determinar a população inicial a partir de estimativas ou resultados prévios, bem como de diferentes técnicas de definição. Já no que se refere às demais populações, a formação é feita por meio da aplicação de operadores genéticos, como cruzamento, mutação e elitismo [18] - [20].

B. Função fitness

A função fitness consiste no parâmetro de avaliação da qualidade de cada indivíduo, ou seja, do quão adequada é de fato a possível solução em análise. Desse modo, ela é utilizada para determinar a aptidão de cada indivíduo e, por conseguinte, suas chances de sobrevivência e de seleção para o processo de recombinação. A determinação desta função, por sua vez, é bastante importante, pois descreve quais fatores serão considerados na determinação da qualidade de uma solução candidata e, portanto, na escolha da melhor solução encontrada.

Nesse sentido, a função fitness é comumente igualada à função objetivo, a qual é formulada a partir dos elementos a serem minimizados ou maximizados no sistema estudado. Todavia, também é possível incluir outros fatores, como penalidades, a depender das necessidades do cenário de aplicação do algoritmo [18], [19], [21].

C. Seleção

A seleção corresponde ao processo de escolha dos indivíduos a serem utilizados na recombinação, bem como no elitismo. Para isso, é aplicado um mecanismo probabilístico que favorece os candidatos cujo nível de qualidade foi considerado maior durante a avaliação da função fitness. Desse modo, os indivíduos que foram considerados mais aptos e, que representariam, portanto, melhores soluções ao problema analisado, possuem maior probabilidade de serem escolhidos [8], [21].

Entretanto, aqueles que possuem menor adaptabilidade, também podem ser selecionados, embora possuam menor chance, visto que não são aplicadas técnicas determinísticas nesta etapa do algoritmo. Ademais, considera-se que pode haver características úteis a serem transmitidas à nova geração quando analisadas separadamente mesmo que a combinação não tenha apresentado um resultado favorável. À luz disso, podem ser aplicados diversos métodos estocásticos


de seleção dentre os quais se destacam o Método da Roleta e o Método do Torneio [8].

D. Cruzamento

Também chamado de crossover ou recombinação, o cruzamento é o operador genético que promove a formação inicial dos novos filhos por meio da aplicação de estratégias de combinação das informações dos pais selecionados.

Sob esse viés, destaca-se que é possível escolher entre diversas estratégias de implementação do operador em questão, de maneira que se pode citar como exemplos os crossovers simples, multiponto, uniforme e aritmético. Representada nos passos (b) e (c) da Fig.3, a recombinação simples ocorre por meio da escolha, geralmente randômica, de um ponto que separa o trecho que o filho receberá do pai 1 e o que ele receberá do pai 2.

Fig.3. Exemplo da operação de crossover de um ponto e mutação.



Fonte: [8].

O crossover uniforme, por sua vez, é aplicado a partir da geração estocástica de uma máscara uniforme, a qual é utilizada para determinar gene a gene, isto é, informação a informação, quais dados serão selecionados de cada pai. Esta estratégia mostra-se interessante por promover uma maior diversidade na formação dos novos indivíduos.

Por fim, na recombinação aritmética, a mistura de informações dos pais selecionados se dá, como o nome sugere, por meio da média aritmética dos dados associados a cada um deles. É possível, ainda, implementar também uma estratégia de recombinação baseada em uma média ponderada, na qual define-se um coeficiente que atribui certo peso a cada gene de cada um dos pais [19], [17], [18], [20], [21].

E. Mutação

Também considerada como um operador genético, a mutação consiste na utilização de estratégias para modificar um dos genes do cromossomo selecionado para ser submetido a ela, bem como é ilustrado nas etapas (c) e (d) da Fig.3. Tal operador é aplicado em um indivíduo por vez e deve ocorrer a uma taxa pequena, visto que, ao promover a troca do gene escolhido, ocasiona a perda de determinada informação da população.

Contudo, vale ressaltar a importância desta técnica, uma vez que ela incentiva a ampliação do espaço de busca ao inserir informações que não seriam incluídas na população na ausência de mutação e, assim, evita a estagnação do algoritmo.

A escolha do gene mutado comumente se dá de maneira randômica e, assim como a recombinação, a estratégia de modificação pode ser implementada de diversas formas, a depender da necessidade e do modelo de representação adotado no código. Em algoritmos que utilizam a representação binária, a mutação comumente ocorre por meio do método bit-flip, ou método de inversão de bit, o qual implica que, caso o gene mutado contenha o dado '1', este será trocado por '0' e o oposto ocorre caso contrário. Em outra perspectiva, quando se faz necessária a representação decimal, o novo gene pode ser escolhido, por exemplo, de forma randômica [17], [18].

F. Elitismo


O elitismo é um mecanismo cujo objetivo é garantir a permanência dos melhores indivíduos na população. Para isso, é implementado, no algoritmo, um processo que faz com que as n soluções candidatas que apresentaram a maior adequação a função fitness, ou seja, as de melhor qualidade sejam transferidas de uma geração à outra sem modificações.

Desse modo, essa técnica evita que os cromossomos mais favoráveis ao alcance do objetivo final sejam perdidos ao longo das iterações e, consequentemente, aumenta a velocidade de convergência do algoritmo [17], [18], [21].

IV. CONSIDERAÇÕES SOBRE A REDE ELÉTRICA SIMULADA

O sistema elétrico sob investigação, o IEEE 30 barras, desempenha um papel central neste estudo de alocação ótima de reatores lineares por meio de algoritmos genéticos. Visando atender aos propósitos específicos da pesquisa, foram realizadas modificações no sistema, introduzindo ajustes nos níveis de tensão em diversos barramentos. Essa adaptação foi crucial para identificar barras com tensão crítica, constituindo a base para a alocação estratégica dos reatores lineares. A Fig.4 ilustra a topologia do sistema estudado, apresentando as informações das barras e dos ramos de ligação entre elas. A representação gráfica oferece uma visão abrangente da estrutura do sistema, evidenciando a complexidade das interconexões.

Fig.4. Topologia do sistema IEEE 30 Barras.



Fonte: [22].

A Tabela V apresenta os resultados das tensões nos barramentos do sistema IEEE 30 barras modificado, destacando as cargas geradas e consumidas em cada barra. Vale salientar que os barramentos que não são de referência possuem geração reativa nula e, por esse motivo, não são

inclusos na tabela. Nota-se que várias tensões excederam os níveis recomendados, conforme discutido na seção introdutória deste trabalho.


TABELA V. DADOS DO SISTEMA IEEE 30 BARRAS MODIFICADO.

Nome	Tipo	Tensão [pu]	Geração Ativa [pu]	Carga ativa [pu]	Carga reativa [pu]	B Shunt
Barra 1	SLACK	1,0200	--	0,000	0,000	0,000
Barra 2	PV	1,0200	0,400	0,217	0,127	0,200
Barra 3	PQ	1,0403	--	0,024	0,012	0,200
Barra 4	PQ	1,0380	--	0,076	0,016	0,200
Barra 5	PV	1,0200	--	0,942	0,190	0,150
Barra 6	PQ	1,0414	--	0,000	0,000	0,200
Barra 7	PQ	1,0351	--	0,228	0,109	0,200
Barra 8	PV	1,0200	--	0,300	0,300	0,150
Barra 9	PQ	1,0962	--	0,000	0,000	0,150
Barra 10	PQ	1,1491	--	0,058	0,020	0,200
Barra 11	PV	1,0200	--	0,000	0,000	0,200
Barra 12	PQ	1,0326	--	0,112	0,075	0,150
Barra 13	PV	1,0200	--	0,000	0,000	0,150
Barra 14	PQ	1,0803	--	0,062	0,016	0,200
Barra 15	PQ	1,0952	--	0,082	0,025	0,150
Barra 16	PQ	1,0881	--	0,035	0,018	0,100
Barra 17	PQ	1,1389	--	0,090	0,058	0,200
Barra 18	PQ	1,1616	--	0,032	0,009	0,200
Barra 19	PQ	1,1739	--	0,095	0,034	0,150
Barra 20	PQ	1,1731	--	0,022	0,007	0,100
Barra 21	PQ	1,1628	--	0,175	0,112	0,200
Barra 22	PQ	1,1656	--	0,000	0,000	0,150
Barra 23	PQ	1,1455	--	0,032	0,016	0,150
Barra 24	PQ	1,1741	--	0,087	0,067	0,100
Barra 25	PQ	1,2213	--	0,000	0,000	0,100
Barra 26	PQ	1,2301	--	0,035	0,023	0,050
Barra 27	PQ	1,2197	--	0,000	0,000	0,100
Barra 28	PQ	1,0621	--	0,000	0,000	0,200
Barra 29	PQ	1,2622	--	0,024	0,009	0,100
Barra 30	PQ	1,2603	--	0,106	0,019	0,100

Fonte: Autores.

A Fig.5 fornece uma representação gráfica abrangente das tensões que se afastam dos níveis aceitáveis, conforme estabelecido pelas normativas brasileiras. O gráfico em barras destaca claramente as condições de operação fora dos limites permitidos, identificando as tensões em vermelho como aquelas que excedem as faixas permissíveis de variação. Em contraste, as barras em verde indicam os pontos em que as tensões se mantêm dentro dos parâmetros adequados. Essa análise visual é de suma importância para identificar locais específicos que demandam atenção imediata e possíveis intervenções, visando otimizar o desempenho e a confiabilidade do sistema elétrico.

Fig.5. Demonstração gráfica das tensões nos barramentos do sistema IEEE 30 barras modificado.



Fonte: Autores.

No que diz respeito às informações relativas aos ramos do sistema IEEE 30 barras modificado, as resistências, reatâncias e susceptâncias entre as barras consideradas na simulação são detalhadamente apresentadas na Tabela VI.

TABELA VI. DADOS DOS RAMOS DO SISTEMA IEEE 30 BARRAS MODIFICADO.

De	Para	R [pu]	X _L [pu]	B [pu]
0	1	0,0192	0,0575	0,0528
0	2	0,0452	0,1652	0,0408
1	3	0,0570	0,1737	0,0368
2	3	0,0132	0,0379	0,0084
1	4	0,0472	0,1983	0,0418
1	5	0,0581	0,1763	0,0374
3	5	0,0119	0,0414	0,0090
4	6	0,0460	0,1160	0,0204
5	6	0,0267	0,0820	0,0170
5	7	0,0120	0,0420	0,0090
5	8	0,0000	0,2080	0,0000
5	9	0,0000	0,5560	0,0000
8	10	0,0000	0,2080	0,0000
8	9	0,0000	0,1100	0,0000
3	11	0,0000	0,2560	0,0000
12	11	0,0000	0,1400	0,0000
12	13	0,1231	0,2559	0,0000
12	14	0,0662	0,1304	0,0000
12	15	0,0945	0,1987	0,0000
13	14	0,2210	0,1997	0,0000
15	16	0,0524	0,1923	0,0000
14	17	0,1073	0,2185	0,0000
17	18	0,0639	0,1292	0,0000
18	19	0,0340	0,0680	0,0000
9	19	0,0936	0,2090	0,0000
9	16	0,0324	0,0845	0,0000
9	20	0,0348	0,0749	0,0000
9	21	0,0727	0,1499	0,0000
20	21	0,0116	0,0236	0,0000
14	22	0,1000	0,2020	0,0000
21	23	0,1150	0,1790	0,0000
22	23	0,1320	0,2700	0,0000
23	24	0,1885	0,3292	0,0000
24	25	0,2544	0,3800	0,0000
24	26	0,1093	0,2087	0,0000
27	26	0,0000	0,3960	0,0000
26	28	0,2198	0,4153	0,0000
26	29	0,3202	0,6027	0,0000
28	29	0,2399	0,4533	0,0000
7	27	0,0636	0,2000	0,0428
5	27	0,0169	0,0599	0,0130


Fonte: Autores.

V. CONSIDERAÇÕES SOBRE O ALGORITMO GENÉTICO IMPLEMENTADO EM PYTHON

Visto que os algoritmos genéticos podem ser implementados de diversas maneiras, este item do artigo tem como meta pontuar as escolhas adotadas do algoritmo genético implementado em Python.

Dito isto, a primeira etapa do algoritmo genético consiste na inicialização da população, que na maioria dos casos é feita na forma mais simples possível, fazendo-se de forma aleatória [8]. Como consequência, este trabalho seguiu essa estratégia. Para exemplificar, na Fig.6 é mostrado um indivíduo, que representa uma possível resposta para o problema de alocação ótima de reatores lineares.

Fig.6. Representação de um indivíduo da população inicial escolhida de forma aleatória.



Fonte: Autores.

Para a Fig.6, de forma aleatória, foram escolhidas as barras representadas pelos números 18, 19, 26 e 24. As susceptâncias shunt, são representadas (em pu) pelos números 0,22, 0,29, 0,3 e 0,29 respectivamente. Para todas as simulações realizadas foram adotados 50 indivíduos para a população inicial.

Outra informação importante sobre o algoritmo implementado refere-se à quantidade de genes de cada indivíduo. Para o exemplo mostrado na Fig.6, os vetores barras e susceptâncias shunt possuem 4 genes. Isto significa que a quantidade de barras candidatas para alocação dos reatores é igual a 4. Neste contexto, para o presente artigo foram simuladas diversas situações, que foram: para 2, 3, 4, 5, 6 e 7 barras candidatas. Para 7 barras ocorreu o resultado em que todas as 30 barras do sistema elétrico ficaram com valores de tensão em módulo entre 0,93 e 1,05 pu.

Outro importante parâmetro do algoritmo genético é a função de avaliação implementada (função objetivo). Para o presente artigo a função objetivo é descrita em (1).

$$f_{objetivo} = \sum_{i=1}^n |V_i - 1| \quad (1)$$

Em que:

i – Barra do sistema elétrico analisado;

n – Número total de barras do sistema;

V_i – Módulo da tensão da barra i em pu.

A partir da função objetivo estabelecida em (1), é feita a seleção dos indivíduos que possuem maior aptidão, e, assim, quais deles têm maior probabilidade de contribuir com material genético para as futuras gerações. Os melhores indivíduos são aqueles que possuem os menores resultados como resposta da função objetivo, ou seja, aqueles cujas barras possuem valores de tensão mais próximos a 1 pu.


Ainda sobre a função objetivo é importante destacar que para cada indivíduo da população foi criada uma matriz de admitância, e, para cada uma dessas matrizes foi utilizado o fluxo de potência pelo método de Newton Raphson. Como resultado, foram obtidos os módulos das tensões em cada uma das barras. Em seguida esses valores foram aplicados na função objetivo descrita em (1).

Na sequência do algoritmo genético, deve ser implementado o método de seleção dos pais. É importante salientar que este processo deve simular o mecanismo de seleção natural que atua sobre espécies biológicas, em que os pais mais capazes geram mais filhos [8].

Segundo [21], as duas principais metodologias para seleção dos pais são o Método da Roleta e o Método do Torneio. No algoritmo genético implementado foi escolhido o Método da Roleta. Basicamente, este método consiste na criação de uma roleta virtual, na qual cada indivíduo recebe

um pedaço proporcional à sua avaliação, conforme exemplificado na Fig.7. Após isso a roleta é rodada e o selecionado será o indivíduo sobre o qual ela parar [8].

Fig.7. Exemplo de percentuais gerados em roleta virtual para aplicação em algoritmos genéticos.



Fonte: Autores.

Ainda sobre o método da roleta é importante definir a probabilidade de seleção (p_i), que é determinada em (2).

$$p_i = \frac{f_i}{\sum_{i=1}^N f_i} \quad (2)$$

Na equação 2, a variável f_i representa a aptidão de determinado indivíduo.

Ainda sobre o método da roleta, para exemplificar, suponha a Tabela VII, que foi utilizada para elaborar o gráfico da roleta mostrado na Fig.7. Nela, são descritos os indivíduos, a aptidão determinada pela função objetivo e a aptidão acumulada.

TABELA VII. EXEMPLO DE PERCENTUAIS GERADOS EM ROLETA VIRTUAL PARA APLICAÇÃO EM ALGORITMOS GENÉTICOS.

Indivíduos	Aptidão (f_i)	Aptidão acumulada
1	2,0	2,0
2	1,6	3,6
3	1,4	5,0
4	0,7	5,7
5	0,3	6,0

Fonte: [23].

Para os dados mostrados, de maneira aleatória será escolhido um número entre 0 e 6. Por exemplo, se este número for 4 o indivíduo escolhido como pai será o número 3.

Selecionados os pais, deve ser aplicada a técnica de cruzamento ou crossover, obtendo os filhos da próxima geração a ser testada. Semelhante à seleção dos pais, para o cruzamento existem várias técnicas, conforme está descrito em [8] e [21]. Dentre essas metodologias foi escolhida a técnica de crossover uniforme. Neste método, é sorteado de maneira aleatória um conjunto de bits (0 ou 1). Caso o bit seja igual a 0 é escolhido o gene do primeiro pai, caso o bit seja igual a 1 é escolhido o gene do segundo pai, de acordo com a Fig.8.

Fig.8. Exemplo de *crossover* aplicando a técnica de máscara uniforme.

PAI 1	[10, 15, 21, 28]	[0,2, 0,1, 0,15, 0,06]
PAI 2	[3, 4, 6, 25]	[0,12, 0,11, 0,23, 0,08]
MÁSCARA UNIFORME	[0, 1, 1, 0]	[1, 1, 0, 0]
FILHO	[10, 4, 6, 28]	[0,12, 0,11, 0,15, 0,06]

Fonte: Autores.

Após a obtenção dos filhos é aplicado o operador genético de mutação. O valor adotado foi de 0,5%, conforme recomendado pela referência [8]. Em seguida é sorteado um número entre 0 e 1. Caso o número sorteado seja inferior ao percentual atribuído altera-se o gene aleatoriamente dentro das possibilidades do problema proposto. Por fim, para garantir a validade das soluções, após a mutação é verificado se o indivíduo contém barras repetidas. Em caso afirmativo, um novo gene é sorteado de forma aleatória até que a repetição seja eliminada.

Além dos operadores genéticos aplicados, o elitismo foi implementado para garantir que os melhores indivíduos sejam preservados em cada geração. Para isso, os 2 melhores indivíduos avaliados foram selecionados para a próxima geração.

VI. RESULTADOS OBTIDOS

Os resultados obtidos nas simulações revelaram-se satisfatórios. Na abordagem metodológica adotada, os reatores lineares foram incrementalmente inseridos, iniciando com 2 reatores distribuídos em barras distintas na primeira simulação. Na segunda simulação, consideraram-se 3 reatores, e assim sucessivamente, até que todas as barras atingissem níveis adequados de tensão. É relevante destacar que, para o sistema em análise, todos os barramentos alcançaram níveis de tensão apropriados quando a simulação contemplou a alocação de 7 reatores.

Na configuração envolvendo 7 reatores shunt, o algoritmo genético destacou as barras 8, 9, 18, 19, 23, 24 e 28 como as mais apropriadas para a alocação dos reatores. Os valores correspondentes das susceptâncias shunt na última geração foram definidos em 0,26 pu, 0,30 pu, 0,26 pu, 0,26 pu, 0,27 pu, 0,21 pu e 0,21 pu, conforme detalhado na Tabela VIII. Esta tabela apresenta de forma consolidada as barras selecionadas e os respectivos valores de susceptância shunt na última geração.

TABELA VIII. BARRAS E SUSCEPTÂNCIAS DA ÚLTIMA GERAÇÃO PARA O SISTEMA COM SETE REATORES.


Barra da última geração	B shunt [pu] da última geração
08	0,26
09	0,30
18	0,26
19	0,26
23	0,27
24	0,21
28	0,21

Fonte: Autores.

A Fig.9 ilustra a evolução da média de aptidão para o caso de 7 reatores. Observa-se, na Fig.9, que a média fitness da primeira geração se estabeleceu em 2, indicando que as tensões nos barramentos estão consideravelmente afastadas de 1 pu. À medida que as gerações avançam, nota-se uma

tendência de melhoria, chegando a aproximadamente 0,6. Esse valor mais baixo sugere que as tensões nos barramentos estão mais próximas do ideal de 1 pu. Essa análise visual oferece informações preciosas sobre o progresso alcançado durante as iterações do algoritmo genético em direção à otimização. O comportamento observado na Fig.9 evidencia que a função objetivo está desempenhando eficazmente seu papel, guiando o sistema em direção ao objetivo de aproximar as tensões nos barramentos ao valor ideal de 1 pu.

Fig.9. Comportamento da média de aptidão para o sistema com sete reatores alocados.



Fonte: Autores.

Os resultados das tensões para a configuração com 7 reatores são apresentados na Tabela IX. Destaca-se que, nesta situação, todas as barras alcançaram patamares apropriados de tensão, indicando uma melhoria significativa em relação às condições iniciais mencionadas na Tabela VI.


TABELA IX. NÍVEIS DE TENSÃO POR BARRAMENTO APÓS A ALOCAÇÃO DE SETE REATORES LINEARES POR MEIO DO AG.

Nome barra	Tensão [pu]	Nome barra	Tensão [pu]
Barra 1	1,0200	Barra 16	1,0328
Barra 2	1,0200	Barra 17	1,0319
Barra 3	1,0310	Barra 18	1,0230
Barra 4	1,0264	Barra 19	0,9942
Barra 5	1,0200	Barra 20	0,9921
Barra 6	1,0243	Barra 21	1,0229
Barra 7	1,0248	Barra 22	1,0230
Barra 8	1,0200	Barra 23	1,0309
Barra 9	1,0152	Barra 24	0,9956
Barra 10	1,0217	Barra 25	0,9986
Barra 11	1,0200	Barra 26	0,9998
Barra 12	1,0277	Barra 27	1,0216
Barra 13	1,0200	Barra 28	1,0301
Barra 14	1,0464	Barra 29	0,9862
Barra 15	1,0324	Barra 30	1,0074

Fonte: Autores.

A eficácia do algoritmo genético em otimização é evidenciada na Fig.10, que apresenta os níveis de tensão em cada barramento por meio de gráficos de barras. O algoritmo garantiu que todas as tensões atingissem os patamares adequados durante o processo de otimização.

Fig.10. Níveis das tensões em cada barramento dispostos em gráfico de barras para o sistema com sete reatores alocados.



Fonte: Autores.

A análise dos resultados para diferentes configurações de reatores shunt revelou uma tendência consistente de melhoria na qualidade das tensões do sistema à medida que o número de reatores aumenta. Esses avanços foram evidenciados pelo progresso na convergência da média de aptidão para valores mais próximos do ideal, assim como pela diminuição no número de barras que não atingiram os níveis desejados. A alocação otimizada de reatores shunt, conduzida pelo algoritmo genético, demonstrou eficácia em aproximar as tensões nos barramentos ao valor ideal de 1 pu. Esses resultados fornecem *insights* valiosos para o aprimoramento das condições de operação da rede elétrica, indicando a viabilidade e eficácia do método proposto.

VII. CONCLUSÃO

Diante dos resultados obtidos nas simulações é possível concluir que a aplicação do algoritmo genético, no contexto da alocação de reatores shunt, apresentou resultados promissores para a melhoria da qualidade de energia elétrica em sistemas de potência. A abordagem adotada, utilizando o algoritmo genético em conjunto com o método de fluxo de potência de Newton-Raphson, demonstrou eficácia na busca por soluções ótimas para a alocação de reatores, visando manter as tensões próximas a 1 pu.

Os resultados específicos das simulações indicaram que, à medida que mais reatores são alocados, há uma progressiva melhoria nas condições de tensão em cada barramento do sistema IEEE 30 barras modificado. A análise das médias de aptidão ao longo das gerações evidenciou a capacidade do algoritmo genético em guiar o sistema em direção ao objetivo de aproximar as tensões dos barramentos ao valor ideal de 1 pu. Assim, a comparação dos diferentes cenários, considerando a alocação de 2 a 7 reatores shunt, revelou que o perfil das tensões do sistema se aprimora significativamente com o aumento do número de reatores. Essa tendência positiva sugere que a aplicação de mais recursos na forma de reatores shunt pode resultar em melhorias substanciais na conformidade com os padrões de qualidade de energia elétrica.

Além disso, a metodologia proposta não apenas busca melhorar o nível das tensões, mas também considera a eficiência econômica ao otimizar a alocação dos reatores. Logo, a minimização do número de reatores necessários para

atingir os objetivos de tensão desejados pode representar uma economia significativa para as empresas do setor elétrico.

Diante do exposto, fica evidente que a abordagem baseada em algoritmos genéticos pode ser uma ferramenta valiosa para a tomada de decisões na gestão de potência reativa, contribuindo para a otimização dos sistemas elétricos de potência. Dessa forma, o presente estudo oferece *insights* valiosos para profissionais e pesquisadores do setor elétrico interessados em estratégias eficientes para a melhoria da qualidade de energia elétrica.

AGRADECIMENTOS

Os autores agradecem à FAPEMIG e à CAPES pelo financiamento deste projeto.

REFERÊNCIAS

- [1] R. C. Dugan, M. F. McGranaghan, S. Santoso, and H. W. Beaty, *Electrical Power Systems Quality*, Second Edition. New York: Mc. Graw-Hill, 2003.
- [2] N. Kagan, E. J. Robba, and H. P. Schmidt, *Estimação de indicadores de qualidade da energia elétrica*, 1a edição. Blucher, 2009.
- [3] Agência Nacional de Energia Elétrica (ANEEL), “Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico nacional (PRODIST): Módulo 8 - Qualidade da energia elétrica. Brasil.” 2021. [Online]. Available: https://www2.aneel.gov.br/cedoc/aren2021956_2_7.pdf
- [4] Operador Nacional do Sistema Elétrico (ONS), “Procedimentos de Rede do Operador Nacional do Sistema Elétrico: Submódulo 9.7 - Indicadores de qualidade de energia elétrica da Rede Básica. Brasil.” 2020. [Online]. Available: https://apps08.ons.org.br/ONS.Sintegre.Proxy/ecmprsite/ecmfragment sdocuments/Submódulo 9.7-IN_2020.12.pdf
- [5] T. Sousa, “Estudo de planejamento de reativos em sistemas elétricos de potência,” Dissertação, Universidade Federal de São Carlos, 2003.
- [6] L. W. de Oliveira, “Reconfiguração e alocação ótima de capacitores em sistemas de distribuição,” Tese, Universidade Federal do Rio de Janeiro, 2009.
- [7] C. de S. Chaves, “Projeto, modelagem e avaliação da eficácia dos reatores a núcleo saturado ao processo da regulação de tensão,” Tese, Universidade Federal de Uberlândia, 2016.
- [8] R. Linden, *Algoritmos genéticos*, 3a Edição. Rio de Janeiro: Ciência Moderna, 2012.
- [9] L. de Castro and F. J. Von Zuben, *Introdução à computação evolutiva*. Campinas: Faculdade de Engenharia Elétrica e de Computação, 2002.
- [10] J. O. Rezende, “Otimização de Potência Reativa em Sistemas Elétricos com Energia Solar Fotovoltaica Utilizando Algoritmo Genético,” Tese, Universidade Federal de Uberlândia, 2021.
- [11] A. E. Eiben and J. E. Smith, *Introduction to Evolutionary Computing*. 2015. [Online]. Available: www.springer.com/series/
- [12] L. (George M. U. Sean, *Essentials of Metaheuristics: A Set of Undergraduate Lecture Notes*, Second. Lulu, 2010.
- [13] B. V. de A. Correia, “Heurísticas e meta-heurística para eficiente alocação e uso de unidades de desfragmentação espectral em redes ópticas elásticas,” Dissertação, Universidade Federal de Pernambuco, 2018.
- [14] X.-S. S. Yang and M. Karamanoglu, *Nature-Inspired Metaheuristic Algorithms Second Edition*, Second., vol. 4, no. C. United Kingdom: Luniver Press, 2013. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/B978012405163800016%0Ahttp://linkinghub.elsevier.com/retrieve/pii/B978012405163800020X>
- [15] M. H. K. Roni, M. S. Rana, H. R. Pota, M. M. Hasan, and M. S. Hussain, “Recent trends in bio-inspired meta-heuristic optimization techniques in control applications for electrical systems: a review,” *Int. J. Dyn. Control*, vol. 10, no. 3, pp. 999–1011, 2022, doi: 10.1007/s40435-021-00892-3.
- [16] C. Darwin, *A origem das espécies*, vol. 1, no. 5. Porto: Planeta Vivo, 2009.
- [17] G. de P. Prado, “Algoritmo genético de codificação real aplicado à otimização termoeconômica,” Universidade Tecnológica Federal do Paraná, 2021.
- [18] G. R. Rocha; and M. A. Z. M. e Silva;, “Software de roteirização e carregamento de veículo utilizando algoritmos genéticos . Resultados e Discussão Material e Métodos,” 2021.
- [19] E. L. Siqueira, “Uso de Algoritmo genético no ajuste linear através de dados experimentais,” Dissertação, Universidade Federal da Paraíba, 2015.
- [20] É. D. O. C. Zini, “Algoritmo Genético Especializado na Resolução de Problemas com Variáveis Contínuas e Altamente Restritos,” Dissertação, Universidade Estadual Paulista Julio de Mesquita Filho, 2009. [Online]. Available: http://www.dee.feis.unesp.br/pos/teses/arquivos/234-dissertacao_erico.pdf
- [21] D. E. Goldberg, *Genetic algorithms in search, optimization, and machine learning*. California: Addison-Wesley, 1989.
- [22] “Sistema IEEE: 30 barras-Modelagem da Rede Elétrica.” https://www.researchgate.net/figure/Figura-2-Sistema-IEEE-30-barras-Modelagem-da-Rede-Eletrica-no-Nivel-Barra-Ramo_fig2_262745037 (accessed Nov. 12, 2023).
- [23] Alexandre Gonçalves Silva, “Algoritmos genéticos.” <https://www.inf.ufsc.br/~alexandre.goncalves.silva/courses/14s2/ine5633/slides/aulaAG.pdf> (accessed Dec. 09, 2023).