LI Simpósio Brasileiro de Pesquisa Operacional
Limeira–SP, 02 a 06 de setembro de 2019

ALGORITMO GENÉTICO DE CHAVES ALEATÓRIAS VICIADAS PARA O PROBLEMA DE ALOCAÇÃO DE BANCOS DE CAPACITORES EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Rafael Yamamoto
rafael.yuki@unesp.br

Leonardo H. Macedo
leohfmp@ieee.org

Rubén Romero
ruben.romero@unesp.br

Laboratório de Planejamento de Sistemas de Energia Elétrica – LaPSEE
Universidade Estadual Paulista – UNESP, Faculdade de Engenharia, Ilha Solteira
Avenida Brasil, 56, Centro, Ilha Solteira-SP, CEP 15385-000

RESUMO

Este artigo apresenta um algoritmo genético de chaves aleatórias viciadas aplicado ao problema de alocação ótima de bancos de capacitores em sistemas de distribuição de energia elétrica radiais. Pretende-se minimizar os custos de investimento e de operação do sistema de distribuição considerando vários níveis de demanda e um horizonte de operação anual. O algoritmo proposto deve então fornecer como solução o número de bancos de capacitores instalados em cada nó do sistema elétrico. Para a avaliação da qualidade de uma proposta de solução foi utilizado um algoritmo especializado de fluxo de carga para redes radiais, que fornece os custos de operação da rede, relacionados com as perdas elétricas durante o horizonte de tempo considerado, e também identifica se a proposta de solução é factível ou não, levando-se em conta os limites físicos e operacionais do sistema. Testes foram realizados utilizando-se os sistemas de 34 e 136 nós, conhecidos na literatura especializada. Os resultados mostram que a proposta é capaz de fornecer soluções de boa qualidade para o problema com um baixo esforço computacional.

PALAVRAS CHAVE. Algoritmos genéticos especializados. Alocação ótima de bancos de capacitores. Otimização de sistemas de distribuição.

EN&PG – PO na Área de Energia, Petróleo e Gás

ABSTRACT

This paper presents a biased random-key genetic algorithm applied to the problem of optimal allocation of capacitor banks in radial electric power distribution systems. It is intended to minimize the investment and operating costs of the distribution system considering several levels of demand and an annual operating horizon. The proposed algorithm must then provide as a solution the number of capacitor banks installed in each node of the electrical system. For the evaluation of the quality of a solution proposal, a specialized load flow algorithm for radial networks was used, which provides the network operating costs related to the electrical losses during the time horizon considered, and also identifies if the solution proposal is feasible or not, taking into account the physical and operational limits of the system. Tests were carried out using the 34- and 136-node systems, well-known in the specialized literature. The results show that the proposal is able to provide good-quality solutions to the problem with a low computational effort.

KEYWORDS. Specialized genetic algorithms. Allocation of capacitor banks. Optimization of distribution systems.

EN&PG – OR in Area of Energy, Oil, and Gas

https://proceedings.science/p/106668?lang=pt-br

1. Introdução

Nos sistemas de distribuição radiais devem ser instalados bancos de capacitores para compensar a potência reativa das cargas indutivas e, portanto, reduzir a potência reativa fornecida pelo sistema de energia elétrica, as perdas de energia elétrica devido às perdas ativas, melhorar o perfil de tensão e, em menor medida, aliviar o carregamento do sistema. Todos esses aspectos estão relacionados com a diminuição das perdas ativas do sistema. Nesse contexto, aparece o problema de alocação ótima de bancos de capacitores para reduzir os custos de operação de sistemas de energia elétrica diminuindo as perdas. Este problema, chamado de alocação ótima de bancos de capacitores em sistemas de distribuição radiais, deve determinar o local onde devem ser instalados os bancos, os tipos e tamanhos desses bancos e, também, o esquema de controle para esses bancos para o caso de operação em diferentes níveis de carga e quando se considera bancos de capacitores chaveados. A função objetivo minimiza os custos de operação para um horizonte de tempo especificado e as restrições estão representadas pelas equações de fluxo de carga e as restrições de operação, como os valores mínimo e máximo da magnitude de tensão nas barras do sistema elétrico e as capacidades de corrente nos ramos.

Este problema é relevante porque é de grande interesse na operação ótima dos sistemas de distribuição de energia elétrica e também porque o modelo matemático correspondente é um problema de programação não linear inteira mista (PNLIM) de elevada complexidade para sistemas de grande porte. Também, a demanda de cada barra varia de forma contínua e, portanto, elas devem ser discretizadas em um número de patamares adequado. Assim, a demanda é discretizada em um número determinado de níveis de demandas para que seja possível resolver o problema usando técnicas de otimização existentes. Portanto, para cada nível de demanda, deve-se determinar o esquema de chaveamento dos bancos de capacitores chaveados. Dessa forma a estratégia de chaveamento deve ser representada por meio de variáveis discretas. Por esse motivo, modelos matemáticos exatos se tornam ainda mais complexos, especialmente para resolver sistemas de grande porte. Assim, a alternativa de se usar meta-heurísticas para resolver esse problema é uma proposta válida e promissora. Na verdade, na literatura especializada aparecem muitas propostas de tipos de meta-heurísticas para resolver o problema de alocação de bancos de capacitores [Grainger e Lee, 1982; Baran e Wu, 1989; Chiang et al., 1990a; Chiang et al., 1990b; Sundhararajan e Pahwa, 1994; Huang et al., 1996; Gallego et al., 1998; Home-Ortiz et al., 2019].

O problema da alocação ótima de bancos de capacitores é um problema que é analisado desde a década de 1960 usando modelos matemáticos relaxados e técnicas de otimização exata, assim como usando heurísticas e meta-heurísticas especializadas [Huang et al., 1996; Gallego et al., 1998]. Assim foram propostas técnicas de solução usando a otimização clássica como a decomposição de Benders, relaxando a modelagem matemática.

Nos últimos anos foram propostos algoritmos especializados usados para resolver problema combinatórios e complexos, tais como simulated annealing, algoritmos genéticos [Goldberg, 1989; Michalewicz, 1996; Buriol et al., 2005] e tabu search [Reeves, 1993; Glover e Kochenberger, 2003]. Neste trabalho, apresenta-se um algoritmo genético especializado, chamado de algoritmo genético de chaves aleatórias viciadas, para resolver o problema de alocação ótima de bancos de capacitores em sistemas de distribuição radiais e o desempenho do algoritmo proposto é comparado com o de outras propostas apresentadas na literatura.

2. Formulação do Problema de Alocação de Bancos de Capacitores

O problema da alocação ótima de bancos de capacitores em sistemas de distribuição radiais tem como objetivo minimizar os custos relacionados com as perdas de energia e o investimento relacionado à instalação dos bancos de capacitores para um horizonte de operação e mantendo adequadas condições de operação do sistema. Assim, as restrições do problema estão representadas pela necessidade de se cumprir as duas leis de Kirchhoff e cumprir com as restrições de limites de operação dos módulos de tensão das barras dentro de limites especificados e os módulos de corrente também em limites especificados. A modelagem matemática do problema de alocação de bancos de capacitores é de programação não linear inteira mista de elevada complexidade. Neste trabalho o modelo matemático completo não é mostrado porque o problema é resolvido usando

uma meta-heurística que dispensa do uso do modelo completo. Dessa forma a função objetivo, que consiste na minimização de custos, com valores expressos em dólares, é representada por (1):

$$\text{minimize } v = k_e \sum_{i=1}^{3} T_i P_i + k_c n_{bc} + k_f n_{bf} + k_a n_a \tag{1}$$

onde k_e é o custo da energia dado em US$/kWh, T_i é o tempo de operação do sistema em horas no horizonte de operação anual, P_i representa as perdas ativas do sistema operando no nível de demanda i, k_c é o custo do equipamento de chaveamento, em US$, n_{bc} é o número barras com bancos de capacitores chaveados alocados no sistema elétrico, k_f é o custo de um banco de capacitores, n_{bf} é o número de bancos de capacitores alocados no sistema, k_a é custo de instalação de bancos em uma barra do sistema elétrico e n_a é o número de barras em que foram instalados bancos de capacitores. No problema a curva de demanda é discretizada em três níveis (pesado, médio e leve). Nos testes foram usados bancos de 300 kVAr com custos $k_c = 300$ US$ para o equipamento de chaveamento e $k_f = 900$ US$ para cada banco de capacitor. O horizonte de operação é de um ano distribuídos em demanda elevada com $T_1 = 1000$ horas, demanda normal $T_2 = 6760$ horas, e demanda leve $T_3 = 1000$ horas. Adicionalmente foi escolhido $k_e = 0{,}06$ US$/kWh.

Neste trabalho o problema de alocação de bancos de capacitores foi resolvido usando um algoritmo genético de chaves aleatórias viciadas que é um algoritmo genético especializado. Assim, apresenta-se a forma genérica de funcionamento do algoritmo genético especializado e a forma em que foi adaptado para resolver o problema de alocação de bancos de capacitores. Finalmente, são mostrados os testes e resultados.

3. Características Fundamentais do Algoritmo Genético Especializado

O algoritmo genético de chaves aleatórias viciadas, chamado de algoritmo BRKGA, do inglês *Biased Random-Key Genetic Algorithm*, é uma modificação do chamado algoritmo RKGA, do inglês *Random-Key Genetic Algorithm*, inicialmente proposto por Bean em [Bean, 1994], onde a proposta original foi apresentada para resolver problemas de sequenciamento de tarefas. A diferença fundamental entre a meta-heurística RKGA de outras meta-heurísticas se encontra na forma de representar uma proposta de solução.

No algoritmo original RKGA, uma proposta de solução é representada de forma codificada por meio de um vetor com n elementos, e os elementos de esse vetor assumem valores no intervalo $[0{,}1]$. Portanto, essa proposta de solução apresentada de forma codificada deve ser decodificada usando um decodificador. Esse decodificador é um algoritmo determinístico que, a partir de uma proposta de solução apresentada de forma codificada, encontra uma proposta de solução do problema original. A proposta de solução decodificada permite a avaliação da qualidade (avaliação da função objetivo ou equivalente) e verificar se a proposta de solução é factível ou infactível. A forma e estrutura do decodificador depende do tipo de problema que se pretende resolver.

O nome de algoritmo de chaves aleatórias, do inglês *random key*, é pela forma em que é gerada uma proposta de solução e pelo valor que assume cada componente de uma proposta de solução (valores no intervalo $[0{,}1]$). A palavra viciada, do inglês *biased*, no algoritmo BRKGA, incorporada pelos autores de [Gonçalves e Resende, 2011], é para mostrar que a recombinação não é puramente aleatória, isto é, uma das soluções geradoras deve ser necessariamente de elite (viciada) em contraposição com a proposta original em que as duas soluções geradoras podem ser do conjunto da população.

O algoritmo RKGA trabalha de forma geracional como um algoritmo genético tradicional, mas apresenta particularidades muito específicas. A primeira grande diferença é que o algoritmo RKGA codifica uma proposta de solução em um vetor de tamanho n e onde cada elemento desse vetor é um número no intervalo $[0{,}1]$ como já foi mencionado anteriormente. A população inicial de tamanho n^{pop} é montada de forma aleatória, isto é, para cada proposta de solução,

escolhe-se seus n elementos gerando números aleatórios entre 0,0 e 1,0. O processo é repetido até completar os elementos da população.

Após montar a população inicial de forma aleatória, deve-se calcular a função objetivo de cada proposta de solução. Essa tarefa é realizada pelo decodificador. Após calcular a função objetivo de todos os elementos da população, deve-se separar os elementos da população em dois grupos. Um grupo menor formado pelas n^e soluções de elite, isto é, formado por aqueles que têm valores de função objetivo de melhor qualidade e outro grupo formado pelas $n^{pop} - n^e$ soluções restantes.

Para gerar a nova população, o algoritmo BRKGA usa elitismo. Assim, todas as n^e soluções de elite da geração k passam diretamente a formar parte das soluções da geração $k + 1$. Como toda estratégia elitista a ideia fundamental é preservar as melhores soluções e manter uma incumbente monotonamente decrescente. As outras propostas de solução que devem formar parte da geração $k + 1$ são encontradas usando duas estratégias, isto é, introduzindo mutantes na população corrente e implementando o operador de recombinação. O algoritmo BRKGA não realiza a mutação como os algoritmos genéticos tradicionais. A estratégia de mutação no algoritmo BRKGA consiste em gerar um conjunto reduzido de n^m propostas de solução usando a mesma estratégia usada para gerar as propostas de solução da população inicial. Assim, para incorporar n^m propostas de solução na iteração $k + 1$ são geradas n^m propostas de solução usando a mesma estratégia usada para montar a população inicial. Essas propostas de solução são chamadas de mutantes e substituem a estratégia de mutação usada no algoritmo genético tradicional.

As outras propostas de solução para completar a nova população de n^{pop} elementos, na iteração $k + 1$, são geradas usando o operador de recombinação. Assim, deve-se gerar $n^{pop} - n^e - n^m$ propostas de solução usando o operador de recombinação. No algoritmo genético tradicional, o operador de seleção escolhe duas propostas de solução da população k e essas soluções são recombinadas para gerar duas novas propostas de solução que devem ser incorporadas na nova população na iteração $k + 1$ (geralmente após implementar a mutação nesses dois novos descendentes). No algoritmo RKGA não existe o operador de seleção convencional, existe apenas o operador de elitismo que já foi usado para incorporar as n^e soluções de elite na população da iteração $k + 1$. Assim, para implementar a recombinação, escolhe-se aleatoriamente dois elementos (propostas de solução) da iteração k e esses elementos são submetidos a recombinação para gerar apenas um descendente que é incorporada na população da iteração $k + 1$.

Essa estratégia permite que soluções de qualidade diversificada sejam escolhidas aleatoriamente já que não é usado o valor da função objetivo para escolher as soluções geradoras de novas soluções. Nesta estratégia aparece uma nova proposta que é chamada de algoritmo BRKGA apresentada em [Gonçalves e Resende, 2011]. Duas estratégias novas podem ser montadas para escolher as duas propostas de solução que devem ser submetidas a recombinação: (i) escolher uma proposta de solução geradora das n^e soluções de elite e a outra proposta de solução geradora dentre as outras $n^{pop} - n^e$ que não são soluções de elite, ou (ii) escolher uma proposta de solução geradora das n^e soluções de elite e a outra proposta de solução geradora dentre todas as propostas de solução da população corrente.

Deve-se observar que nessas novas propostas se encontra de forma implícita o operador de seleção. A primeira proposta sempre escolhe uma solução de elite e na segunda proposta sempre participa uma solução de elite e a outra proposta de solução pode ser de elite ou pode não ser de elite. Como as soluções de elite representam um número reduzido de elementos, então a participação das soluções de elite deve ser muito intensa na geração de novas soluções no algoritmo BRKGA quando comparado com o algoritmo RKGA. Obviamente, cada elemento da população pode ser chamado mais de uma vez para participar da recombinação. A Figura 1 mostra como se monta a nova população na iteração $k + 1$ a partir da população na iteração k. O outro aspecto fundamental é a forma em que se implementa a recombinação.

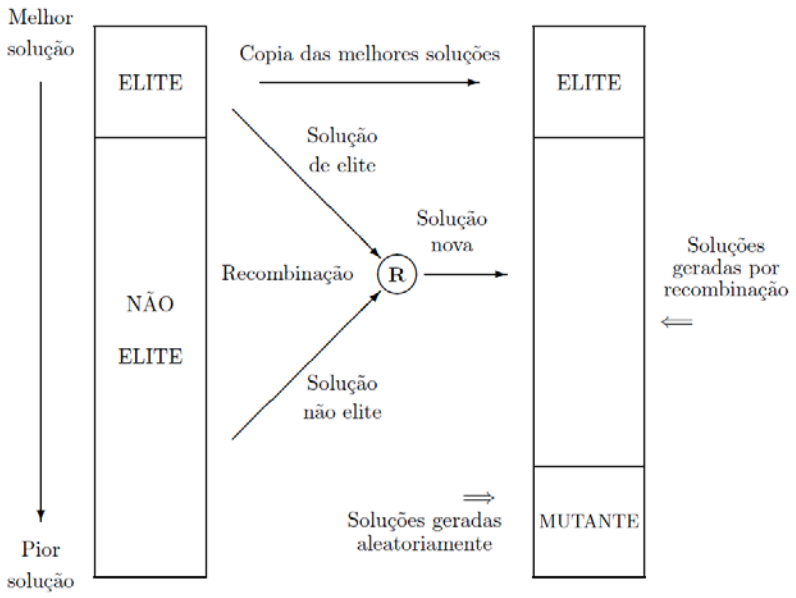


Figura 1: Montagem da população na iteração $k+1$ [Gonçalves e Resende, 2011].

Uma vez escolhidas as duas propostas de solução que devem participar da recombinação, então a recombinação proposta no algoritmo BRKGA é a chamada recombinação PUC, do inglês *Parametrized Uniform Crossover*. A recombinação PUC é simplesmente a recombinação uniforme para gerar apenas um descendente.

Para apresentar a recombinação PUC, supor que foram selecionadas a solução de elite A e a solução B para participar da recombinação. Adicionalmente, escolhe-se o parâmetro ρ^e que indica a probabilidade de que um elemento (alelo) da solução de elite A seja escolhido para ser incorporado no descendente que está sendo construído. Assim, para gerar os n elementos do descendente C, deve-se decidir se se copia o valor armazenado em A ou em B. Assim, em um processo que é repetido n vezes, gera-se um número aleatório $\rho \in [0,1]$ e o compara com ρ^e. Se $\rho \leq \rho^e$ então copia-se o valor armazenado na solução A e, em caso contrário, copia-se o valor armazenado em B. O valor usado para ρ^e é elevado e tipicamente é escolhido $\rho^e = 0{,}7$. Assim, em cada caso, existe uma probabilidade de 0,7 para que o valor armazenado em A seja copiado no descendente C que está sendo gerado. Obviamente essa estratégia permite que a maioria dos elementos copiados em C sejam elementos armazenados na solução de elite. Essa estratégia explica também os motivos pelos quais é gerado apenas um descendente ao contrário do que é feito no algoritmo genético tradicional.

Após montar a nova população da iteração $k+1$, deve-se calcular o valor da função objetivo das novas propostas de solução usando o decodificador e verificar o critério de parada. Assume-se que qualquer nova solução gerada representa uma proposta de solução no espaço de busca original do problema de otimização usando o decodificador.

A meta-heurística BRKGA na verdade apresenta uma estrutura geral para resolver problemas muito variados. Essa estrutura apresenta duas parcelas claramente diferenciadas como se mostra na Figura 2. Existe uma parcela que é independente do problema e, portanto, não precisa conhecer o problema que está sendo resolvido. Assim, a única conexão com o problema que está sendo resolvido é através do decodificador que recebe uma proposta de solução codificada na forma de chaves aleatórias e, a partir dessa solução, encontra a solução no espaço de busca original, assim como o valor da função objetivo. Portanto, para definir as características específicas de um algoritmo BRKGA é necessário apenas definir a forma de codificação no formato de chaves aleatórias e o decodificador.

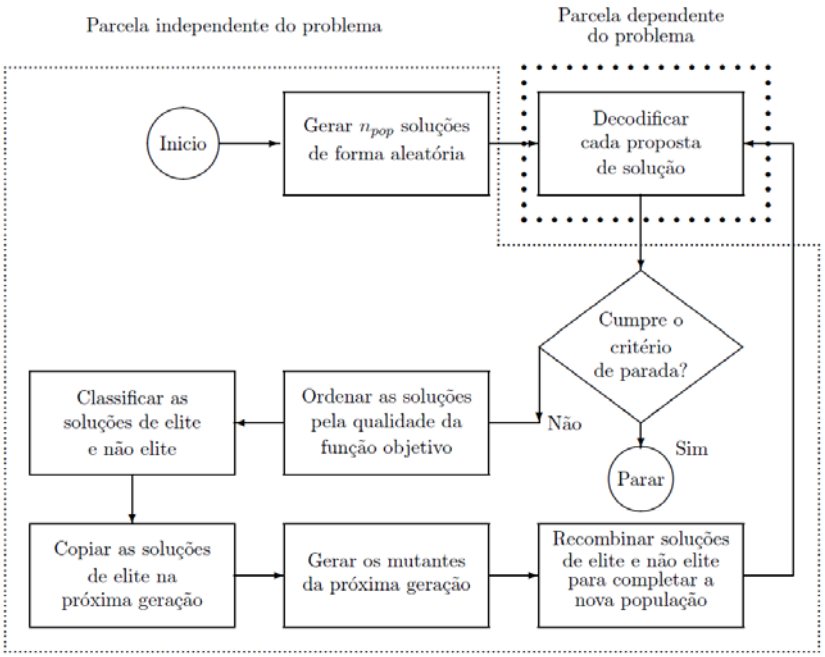


Figura 2: Fluxograma do algoritmo BRKGA [Gonçalves e Resende, 2011].

4. Algoritmo BRKGA Adaptado ao Problema de Alocação de Bancos de Capacitores

Apresenta-se aqui o método especializado proposto, baseada na meta-heurística BRKGA para resolver o problema de alocação ótima de bancos de capacitores em sistemas de distribuição radial.

4.1. Codificação e decodificação de uma proposta de solução

O tamanho do vetor de codificação de uma proposta de solução será igual ao número de níveis de demanda considerados multiplicado pelo número de barras do sistema, sendo que cada posição do vetor indicará (de forma codificada, e com números reais no intervalo $[0,1]$) o número de bancos de capacitores na barra e no nível de demanda correspondentes. A Figura 3 ilustra uma proposta de solução codificada.

Leve					Médio					Pesado				
1	2	3	...	nb	1	2	3	...	nb	1	2	3	...	nb
0,28	0,87	0,15	...	0,93	0,28	0,92	0,46	...	0,93	0,36	0,92	0,68	...	0,97

Figura 3: Codificação de uma proposta de solução [Elaboração dos autores].

Obviamente, uma proposta de solução como a da Figura 3 não faz nenhum sentido no contexto do problema se não for apresentada a forma de decodificá-la. Nesse caso, a proposta de decodificador é considerar intervalos correspondentes para cada número inteiro de bancos conectados em cada barra. Considera-se, por exemplo, o intervalo $[0;0{,}75)$ correspondendo a nenhum banco conectado, $[0{,}75;0{,}80)$ correspondendo a um banco, $[0{,}80;0{,}85)$ correspondendo a dois bancos, $[0{,}85;0{,}90)$ correspondendo a três bancos, $[0{,}90;0{,}95)$ correspondendo a quatro bancos, e $[0{,}95;1{,}00]$ correspondendo a cinco bancos. Esses intervalos, entretanto, devem ser ajustados para cada instância do problema que se deseja resolver. Dessa forma, na proposta codificada na Figura 3, no nível de demanda leve, as barras 1 e 3 não têm bancos conectados, a barra 2 tem três bancos fixos e um chaveado e a barra nb tem quatro bancos fixos e um chaveado.

O processo de geração dos números aleatórios deve ter uma etapa de correção, de forma a garantir que na mesma barra, o número aleatório gerado para o nível de demanda leve seja menor ou igual que o número aleatório gerado para o nível de demanda médio que, por sua vez, deve ser menor ou igual que o número aleatório gerado para o nível de demanda pesado.

4.2. Geração da população inicial

A população inicial do algoritmo BRKGA é montada, inicialmente, escolhendo-se as melhores barras e atribuindo-se maior probabilidade de ser alocado um banco de capacitor naquela barra. Inicialmente testa-se todas as barras instalando-se apenas um banco em cada uma e verifica-se a função objetivo do problema, as melhores são selecionadas e possuem maior probabilidade de serem escolhidas na criação da população.

Além desse fato, é utilizado um limitante no número de barras que podem ter capacitores instalados, já que se sabe que a solução ótima deste tipo de problema terá apenas alguns bancos de capacitores instalados no sistema [Grainger e Lee, 1982; Baran e Wu, 1989; Chiang et al., 1990a; Chiang et al., 1990b; Sundhararajan e Pahwa, 1994; Huang et al., 1996; Gallego et al., 1998].

4.3. Conjunto de solução de elite

O tamanho do conjunto de solução de elite será, neste trabalho, igual a 5% do tamanho da população, sempre arredondado para cima, obtendo-se assim uma parcela de tamanho relativamente razoável mesmo em populações grandes. A população de elite será sempre o conjunto de soluções que possuir os melhores valores de função objetivo dentre toda a população.

4.4. Melhoramento das soluções

Para obter-se resultados de melhor qualidade e tornar o algoritmo mais eficiente, foram utilizadas algumas técnicas para agilizar o processo de otimização por meio do melhoramento das soluções de elite. As etapas de melhoramento são descritas a seguir.

4.4.1. Correção dos dados

Espera-se que em um nível de demanda com carga maior, exista, no mínimo, o mesmo número de bancos de capacitores conectados em cada barra do sistema que no nível de demanda com carga imediatamente inferior. Para garantir que isso ocorra, na geração das populações, realiza-se a geração controlada de uma proposta de solução como foi explicado anteriormente, de forma que em cada barra do sistema em um nível de demanda menor, não pode operar com um número maior de bancos.

4.4.2. Mover bancos para as barras vizinhas

A primeira vizinhança utilizada no algoritmo foi a de translação dos bancos de capacitores para as barras vizinhas. Para isso, os bancos de capacitores de uma certa barra são transferidos para as barras vizinhas, uma a uma. A melhor troca encontrada torna-se parte da população se levar a uma melhoria na qualidade da solução, enquanto as outras soluções assim obtidas são descartadas.

4.4.3. Retirar um banco de capacitor de cada barra com banco instalado

Tenta-se remover um banco de capacitores de cada barra que tem bancos instalados em todos níveis de demanda. A solução corrente em que essa busca local é aplicada é substituída caso ocorra uma melhoria no valor da função de avaliação do problema.

4.4.4. Adicionar um banco de capacitor por barra com banco instalado

Semelhante ao caso anterior, caso haja bancos em déficit, esta vizinhança tenta resolver alocando mais um banco em barras que já possuem bancos, em caso de melhoria na função de avaliação, o banco instalado é mantido, caso contrário é removido.

4.4.5. Retirada do dispositivo de chaveamento

Seguindo, nesta vizinhança remove-se todos os dispositivos de chaveamento, um por vez, na tentativa de melhorar a função objetivo, levando em conta que os dispositivos de chaveamento representam um valor extra na instalação. Caso a função objetivo melhore, os dispositivos permanecem removidos, caso contrário são reinstalados.

4.5. Recombinação e parcela mutante da população

Em cada geração do algoritmo BRKGA, uma parte da população corrente é mantida (parcela de elite) enquanto a outra parcela é alterada. No algoritmo proposto, 40% dos indivíduos de uma população será formado por soluções mutantes, enquanto os outros 55% irão ser recombinados.

O processo de criação das soluções mutantes é idêntico ao processo da criação da população inicial, mas limitado à sua parcela da população que é 40%. Já a recombinação utilizada é a chamada recombinação PUC, discutida anteriormente, sendo que se considera o coeficiente de recombinação igual à 0,7, que indica que 70% das vezes, o alelo herdado virá da solução de elite, mantendo prioritariamente nos descendentes as características das melhores soluções obtidas no processo.

4.6. Avaliação da factibilidade de uma proposta de solução

Como a alocação de bancos de capacitores trata-se de um problema real, existem restrições que devem ser respeitadas, que no caso abordado serão os limites do módulo da tensão mínima e máxima nas barras do sistema. Essa verificação é realizada através da solução de um problema de fluxo de carga para redes radiais para cada proposta de solução. O método para a solução do problema de fluxo de carga em sistemas radiais utilizado neste trabalho foi desenvolvido por [Shirmohammadi et al., 1988] e adaptado de [Possagnolo, 2015], e é conhecido como método de varredura.

Em todos os sistemas que serão testados, as magnitudes de tensão mínima e máxima serão 0,93 p.u. e 1,05 p.u., respectivamente.

Portanto, para respeitar estes limites, sempre que ocorre uma violação dos limites de tensão em uma barra do sistema em uma proposta de solução, um valor elevado, proporcional à violação, é somado na função de avaliação, o que torna as soluções com mais violações as piores soluções da população, sendo então, descartadas no processo de otimização.

5. Resultados

Neste trabalho foram realizados testes em dois sistemas distintos, que possuem 34 e 136 barras, respectivamente [LaPSEE, 2019]. Os testes foram realizados considerando o tamanho da população igual ao dobro do número de barras do sistema. Os dados dos testes para cada sistema são apresentados nas Tabelas 1 e 2.

Tabela 1: Dados de fatores de carga para os sistemas

Sistema	Fator de demanda			Tempo anual por nível de demanda (horas)		
	Leve	Média	Pesada	Leve	Média	Pesada
34 barras	0,6	0,8	1,1	1000	6760	1000
136 barras	0,6	1,0	1,5	1000	6760	1000

Tabela 2: Dados dos bancos de capacitores

Sistema	Custo dos capacitores			Custos operacionais
	Chaveado (US$)	Fixo (US$)	Manutenção (US$)	Custo das perdas (US$/kWh)
34 barras	300	900	1000	0,06
136 barras	300	900	1000	0,06

O método proposto foi implementado em Matlab e testado em um computador com processador Intel® Core™ i3-7100 e 4 GB de RAM.

5.1. Sistema de 34 barras

O sistema em seu estado inicial era factível, com tensão máxima de 1,00 p.u. e tensão mínima de 0,9355 p.u. no nível pesado, com perdas de 77,0112 kW no nível baixo, 139,5120 kW no nível médio e 271,6757 kW no nível alto, com custo anual de perdas igual a US$ 77.510,21. Para este sistema a solução ótima é obtida quando são instalados 2 bancos de capacitores fixos na barra 10 e 3 bancos de capacitores fixos na barra 23, com custo de perdas igual a US$ 58.077,49 e custo de instalação de US$ 6.500,00, totalizando US$ 64.577,49.

Para este sistema, foi utilizado um limite de barras que poderiam possuir bancos e um limite de bancos por barra, iguais a 5 e 3, respectivamente.

Após aplicar a meta-heurística ao problema, encontrou-se a solução ótima para o sistema em 41,14 segundos, onde foram resolvidos 14.402 fluxos de carga para redes, obtendo-se um custo de perdas de US$ 58.077,49 e custo de investimento de US$ 6.500,00, totalizando US$ 64.577,49. Analisando-se os valores das tensões, verifica-se a factibilidade da solução, possuindo a menor tensão igual a 0,9413 p.u. e a maior igual a 1,00 p.u. Para melhor análise, a Figura 4 mostra a comparação dos perfis de tensão no sistema antes e após a instalação dos bancos de capacitores. Nessa figura é possível verificar uma melhoria no perfil de tensão do sistema após a alocação de bancos de capacitores—as magnitudes das tensões em todas as barras e em todos os níveis de demanda estão mais próximas da tensão nominal do sistema (1 pu).

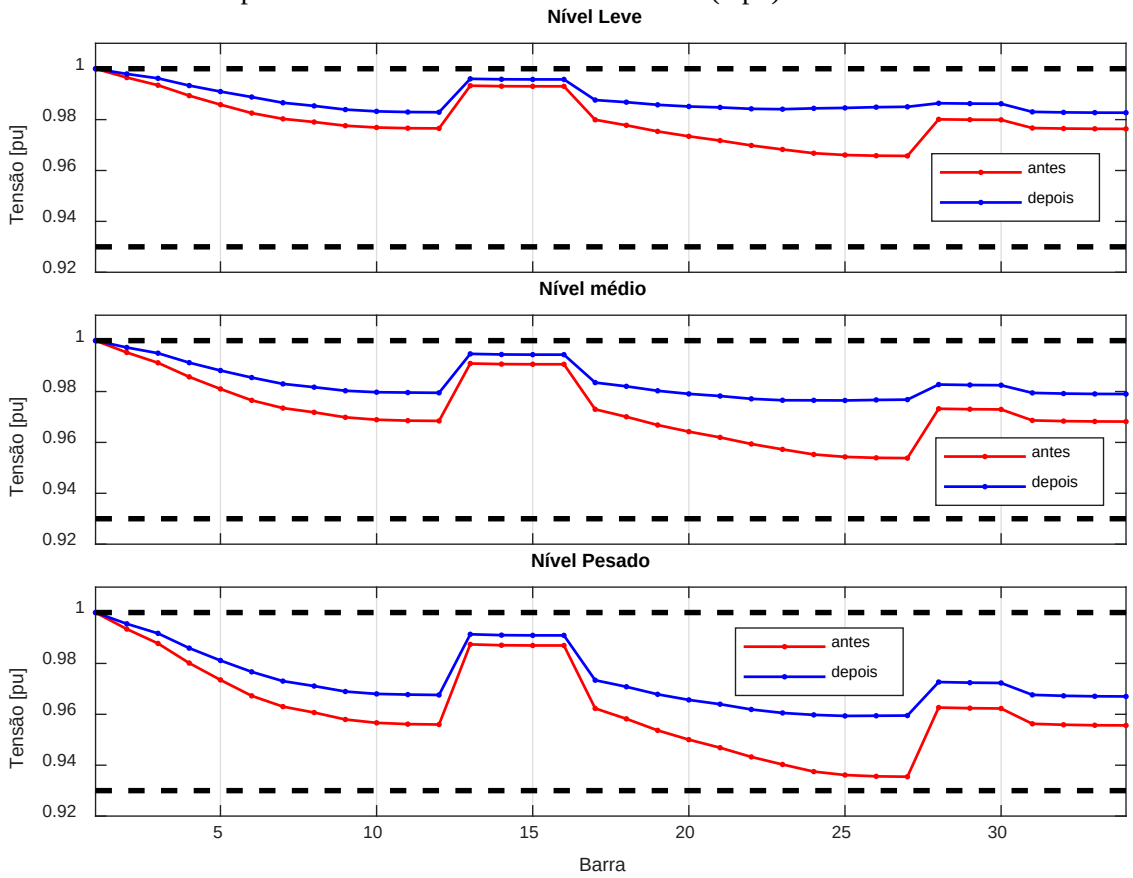


Figura 4: Comparação dos perfis das tensões no sistema de 34 barras.

5.2. Sistema de 136 barras

Nesse caso, o sistema é inicialmente infactível, possuindo uma tensão máxima de 1,00 p.u., mas com tensão mínima de 0,8904 p.u. no nível pesado, inferior à tensão limite de 0.93 p.u. Inicialmente o sistema possuía perdas em demanda leve de 111,6922 kW, em demanda média de

320,2664 kW e em demanda pesada de 753,2673 kW. No total, o custo das perdas anuais deste sistema era inicialmente de US$ 181.797,64.

Utilizando-se o limite de barras com bancos de capacitores igual a 5 e o limite de bancos por barra igual a 5, a meta-heurística proposta foi utilizada para resolver o problema.

A melhor solução encontrada tem um custo anual de perdas igual à US$ 169.235,47 e custo de investimento de US$ 5.500,00, totalizando US$ 174.735,47. Esta solução foi obtida ao se instalar 5 bancos de capacitores fixos na barra 106 do sistema. Neste processo foram resolvidos realizados 35.288 fluxos de carga, levando 56,79 segundos para realizar a operação. O resultado encontrado foi capaz de diminuir o custo das perdas em US$ 12.562,17.

A solução ótima para este sistema tem custo total de US$ 174.562,56, diferindo em apenas 0,1% do valor da solução obtida pelo algoritmo proposto, o que indica um resultado satisfatório.

Considerando os perfis de tensões mostrados na Figura 5, nota-se uma grande diferença após a instalação dos bancos, sendo que no nível de demanda pesado a operação do sistema passa a ser factível—as magnitudes das tensões em alguns nós do sistema que estavam abaixo de 0,93 pu no nível de demanda pesado passam para valores acima do limite mínimo estabelecido.

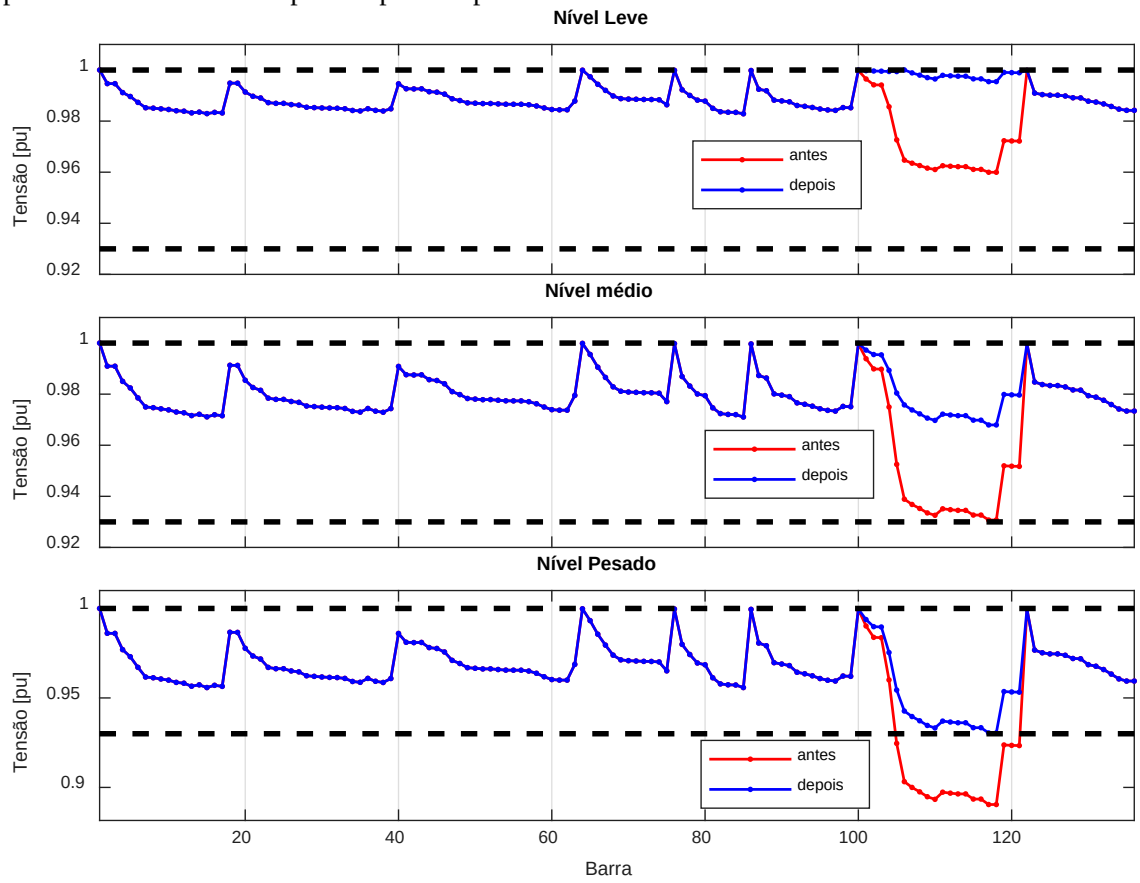


Figura 5: Comparação dos perfis de tensões do sistema de 136 barras.

6. Conclusão

Este artigo apresentou a aplicação de um algoritmo genético de chaves aleatórias viciadas para resolver o problema de alocação de bancos de capacitores em sistemas de distribuição de energia elétrica radiais.

A técnica proposta utiliza um algoritmo eficiente de fluxo de carga para redes radiais para a avaliação da qualidade e factibilidade de uma proposta de solução. O objetivo do problema é minimizar os custos de investimento e de operação do sistema para um horizonte de operação.

O algoritmo desenvolvido mostrou-se eficiente na resolução do problema quando aplicado aos sistemas de 34 e 136 nós, apresentando resultados de boa qualidade em um tempo relativamente curto para uma meta-heurística.

7. Agradecimentos

Este trabalho recebeu apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), processo 305852/2017-5, e da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processos 2018/21721-1, 2015/21972-6 e 2018/20355-1.

Referências

Baran, M. E. e Wu, F. F. (1989). Optimal sizing of capacitors placed on a radial distribution system, *IEEE Transactions on Power Delivery*, 4(1):735–743.

Bean, J. C. (1994). Genetic algorithms and random keys for sequencing and optimization, *ORSA Journal on Computing*, 6(2):154–160.

Buriol, L. S., Resende, M. G. C., Ribeiro, C. C. e Thorup, M. (2005). A hybrid genetic algorithm for the weight setting problem in OSPF/IS-IS routing, *NETWORKS*, 46(1):36–56.

Chiang, H. D., Wang, J. C., Cockings, O. e Shin, H. D. (1990a). Optimal capacitor placement in distribution systems part I: a new formulation and the overall problem, *IEEE Transactions on Power Delivery*, 5(2):634–642.

Chiang, H. D., Wang, J. C., Cockings, O. e Shin, H. D. (1990b). Optimal capacitor placement in distribution systems part II: solution algorithms and numerical results, *IEEE Transactions on Power Delivery*, 5(2):643–649.

Gallego, R. A., Monticelli, A. e Romero R. (1998). Comparative studies of nonconvex optimization methods for transmission network expansion planning, *IEEE Transactions on Power Systems*, 13(3):822–828.

Glover, F. W. e Kochenberger, G. A. (2003). Handbook of metaheuristics, *Kluwer Academic Publishers*.

Goldberg, D. E. (1989). Genetic algorithms in search, optimization and machine learning, *Addison-Wesley*.

Gonçalves, J. F. e Resende, M. G. C. (2011). Biased random-key genetic algorithms for combinatorial optimization, *Journal of Heuristics*, 17(5):487–525.

Grainger, J. J. e Lee, S. H. (1982). Capacity release by shunt capacitor placement on distribution feeders: a new voltage-dependent model, *IEEE Transactions on Power Apparatus and Systems*, PAS-101(5):1236–1244.

Home-Ortiz, J.M., Vargas, R., Macedo, L. H., e Romero, R. (2019). Joint reconfiguration of feeders and allocation of capacitor banks in radial distribution systems considering voltage-dependent models. *International Journal of Electrical Power & Energy Systems*, 107:298–310.

Huang, Y. C., Yang, H. T. e Huang, C. L. (1996). Solving the capacitor placement problem in a radial distribution system using tabu search approach, *IEEE Transactions on Power Systems*, 11(4):1868–1873.

LaPSEE Power System Test Cases Repository (2019). http://www.feis.unesp.br/#!/lapsee (acesso em 10/04/2019).

Michalewicz, Z. (1996). Genetic algorithms + data structure = evolution programs, *Springer-Verlag*.

Possagnolo, L. H. F. M. (2015). Reconfiguração de sistemas de distribuição operando em vários níveis de demanda através de uma meta-heurística de busca em vizinhança variável. Dissertação de mestrado, Universidade Estadual Paulista Júlio de Mesquita Filho, Faculdade de Engenharia, Ilha Solteira.

Reeves, C. R. (1993). Modern heuristic techniques for combinatorial problems, *McGraw-Hill*.

Shirmohammadi, D., Hong, H. W., Semlyen, A., e Luo, G. (1988). A compensation-based power flow method for weakly meshed distribution and transmission networks. *IEEE Transactions on Power Systems*, 3(2):753–762.

Sundhararajan, S. e Pahwa, A. (1994). Optimal selection of capacitors for radial distribution systems using a genetic algorithm, *IEEE Transactions on Power Systems*, 9(3):1499–1507.