



## Otimização de Redes de Distribuição de Energia Elétrica por BRKGA

**Ellen Marianne Bernal Cavalheiro**

Faculdade de Engenharia Elétrica e de Computação - UNICAMP  
Cidade Universitária Zeferino Vaz. Av. Albert Einstein, 400. CEP: 13083-852, Campinas - SP  
ellenmbc@gmail.com

**Christiano Lyra Filho**

Faculdade de Engenharia Elétrica e de Computação - UNICAMP  
Cidade Universitária Zeferino Vaz. Av. Albert Einstein, 400. CEP: 13083-852, Campinas - SP  
chrlyra@denisis.fee.unicamp.br

### RESUMO

Os sistemas de distribuição recebe energia dos sistemas de transmissão, ou subtransmissão, e entrega a energia aos consumidores através de linhas e equipamentos. Nessas linhas e equipamentos ocorrem dissipações de energia, devido às resistências elétricas, que causam perdas técnicas (por efeito joule). Existem várias alternativas para redução de perdas técnicas em redes de distribuição, como a procura das melhores configurações de redes, gestão dos fluxos de energia reativa, melhorias físicas por substituição de cabos e equipamentos, otimização do planejamento das redes e a adoção de fontes de gerações distribuídas, associadas ao conjunto de inovações caracterizadas pela expressão *Smart Grids*. Este trabalho estuda alternativas de encontrar as melhores configurações de redes através da heurística BRKGA com buscas locais. Os estudos de casos indicam que a inclusão de busca local no processo evolutivo do BRKGA pode trazer benefícios.

**PALAVRAS CHAVE.** Reconfigurações de redes de distribuição de energia elétrica. Algoritmos genéticos baseados em chaves aleatórias. Busca local.

**Tópicos:** EN - PO na Área de Energia, OC - Otimização Combinatória

### ABSTRACT

Distribution systems receive power from the transmission system, or sub-transmission, and delivers energy to the consumers through lines and equipment. In these lines and equipment energy dissipation occurs, due to the electrical resistance. There are several alternatives for reducing technical losses in distribution networks, such as the search for the best network configurations, reactive energy flows management, physical improvements with replacement of cables and equipment, optimization of network planning and the adoption of distributed generation, associated to the innovations of *Smart Grids*. This work studies alternatives to find optimal network configurations with the BRKGA heuristics enhanced with local searches. The case studies indicate that the inclusion of local search in the evolutionary process of BRKGA can bring benefits.

**KEYWORDS.** Reconfiguration of electric power distribution networks. Biased random-key genetic algorithm. Local search.

**Paper topics:** EN - OR in Energy, CO - Combinatorial Optimization



## Introdução

Este trabalho estuda o problema de encontrar configurações ótimas para redes radiais de distribuição de energia elétrica com geradores distribuídos, cenário para onde convergem as redes de distribuição com as inovações em gerações e controles associadas ao conceito de *Smart Grids*.

Encontrar configurações ótimas significa reconfigurar a rede de distribuição através da troca dos estados de chaves, normalmente aberta (NA) ou normalmente fechada (NF), procurando encontrar configurações radiais de mínimas perdas [Queiroz e Lyra, 2009]. Os engenheiros franceses Merlin e Back [1975] propuseram o problema de encontrar as configurações ótimas de redes de distribuição de energia elétrica e apresentaram duas alternativas para resolução do problema. A primeira alternativa é uma abordagem exata que utiliza o método “*branch-and-bound*”. A segunda alternativa é o procedimento heurístico de duas fases, que ficou conhecido como “abertura sequencial de chaves”. A primeira fase consiste no fechamento de todas as chaves para obtenção de uma solução com mínimas perdas em uma rede com ciclos; na segunda fase é aberta a chave pertencente ao ciclo que possui o menor fluxo de potência na solução de mínimas perdas com ciclos. As duas fases são repetidas até a obtenção de uma solução radial.

O trabalho de Merlin & Back impulsionou pesquisas e implementações na área. Na década de 80, Civanlar et al. apresentaram a heurística para reconfiguração de redes denominada “troca de ramos” (do inglês *branch-exchange*). Cada etapa da “troca de ramos” realiza uma permuta de estados entre pares de chaves em um ciclo, uma aberta e outra fechada, de forma a obter redução de perdas. Na década de 80, destacam-se os artigos de Baran e Wu [1989], Shirmohammadi e Hong [1989], Liu et al. [1989] e Lee e Brooks [1988].

Na década de 90, os trabalhos abordaram o problema de reconfiguração de redes explorando novas heurísticas e novas ideias que começavam a ser exploradas em problemas de otimização, como conceitos desenvolvidos na área de inteligência artificial e metaheurísticas para abordagem de problemas de otimização combinatória. Taylor e Lubkeman [1990] propuseram o uso de sistemas especialistas para otimizar as configurações de redes, procurando eliminar sobrecargas de transformadores e reduzir perdas. Nara et al. [1992] desenvolveram metodologia baseada em algoritmos genéticos para construir uma população de soluções com as melhores configurações de redes. Cavellucci e Lyra [1997] estenderam as ideias de Merlin e Back [1975] em um método de duas fases, baseado em gradiente reduzido para redes e buscas informadas, desenvolvidas com conceitos da área de inteligência artificial – a abertura de chaves é guiada pelas buscas informadas que utilizam informações de distribuições ótimas de fluxos obtidas pelo algoritmo gradiente reduzido para redes malhadas.

A literatura sobre reconfiguração otimizada de redes na primeira década dos anos 2000 explorou possibilidades de encontrar melhores soluções através de novas metaheurísticas, como, por exemplo, *otimização por colônia de formigas*, *GRASP* (acrônimo da expressão em inglês Greedy Randomized Adaptive Search Procedure) e *busca harmônica*. Além das metaheurísticas foram propostos modelos para abordar o problema de variações de demandas ao longo do período de estudo; foram também desenvolvidas metodologias que permitiram a solução do problema em redes de porte real. Vargas et al. [2004] exploraram o uso de sistemas classificadores para supervisionar redes em tempo real e realizar reconfigurações sempre que forem identificadas variações significativas de demandas. Bueno et al. [2004] propuseram uma nova formulação para o problema que considera explicitamente as variações de demandas, mas impede reconfigurações ao longo do período de estudo. Queiroz e Lyra [2009] desenvolveram um algoritmo genético híbrido adaptativo para resolver o problema proposto por Bueno et al. [2004] em redes de porte real.

A partir dos anos 2000 um conjunto de tecnologias permitiu implementações de gerações distribuídas nas redes de distribuição - essas novas tecnologias são caracterizadas coletivamente com a expressão *Smart Grid*. A evolução dos conceitos de *Smart Grid* até 2010 é historiada no artigo de Lightner e Widergren, publicado no primeiro número da revista *IEEE Transactions on Smart Grid* [Lightner e Widergren, 2010]. Trabalhos como Franco et al. [2013], Rao et al. [2013],



Esmaeilian e Fadaeinedjad [2015] e Jagtap e Khatod [2016] exploram o uso de geração distribuída determinística, considerando o conceito de *Smart Grids* para minimização de perdas através de reconfigurações de redes de distribuição de energia elétrica.

Franco et al. [2013] utilizam um modelo linear com variáveis inteiras aplicadas em redes com 66 e 417 nós. Rao et al. [2013] utilizaram um algoritmo de *busca harmônica* para redes com 33 e 69 nós, e compararam os resultados da busca harmônica com uma alternativa de solução por algoritmos genéticos [Nara et al., 1992; Zhu, 2002]. Esmaeilian e Fadaeinedjad [2015] utilizam algoritmo genético híbrido para encontrar soluções em redes de 33 e 83 nós. Jagtap e Khatod [2016] estudam cenários alternativos para o uso de geração distribuída controlável; as soluções foram obtidas por método heurístico em redes com 9 e 33 nós.

Os trabalhos acima mencionados indicam que o estudo do problema de encontrar configurações ótimas de redes radiais de distribuição com a presença de geração distribuída está ainda numa fase exploratória, restrita a cenários de gerações controláveis em redes pequenas – com exceção dos estudos realizados por Franco et al. [2013]. Por outro lado, os estudos consideram somente a existência de gerações distribuídas com valores de injeções controláveis. Em 2016 propomos um passo adicional na discussão sobre o problema de reconfiguração de redes radiais de distribuição, ao incluir a representação de aspectos aleatórios de gerações distribuídas [Cavalheiro et al., 2016]. As características do problema foram exploradas em uma rede maquete de pequeno porte, projetada para realçar as consequências da presença de gerações aleatórias nas redes. A solução do problema através dos algoritmos genéticos baseados em chaves aleatórias (BRKGA) foi explorada em Cavalheiro [2017]. Este trabalho estuda alternativas de aperfeiçoar a solução do problema através do algoritmo BRKGA com a inclusão de buscas locais. Nesses estudos adota-se uma representação determinística do problema, com objetivo de colocar o foco no algoritmo de solução.

### Caracterização e Formulação do Problema

Uma rede de distribuição de energia elétrica pode ser representada por grafos [Ahuja et al., 1993]. A rede de distribuição apresentada na Figura 1 ilustra os principais componentes para abordagens do problema de redução de perdas técnicas por reconfigurações: chaves (arcos), blocos de cargas (nós), linhas elétricas (arcos) e subestação (nós). Como as redes de distribuição operam com configurações radiais, o problema de encontrar a configuração ótima para uma rede ao longo de determinado período corresponde a encontrar a árvore geradora da rede que permita atender às demandas ao longo do período em estudo com as menores perdas possíveis. As variáveis de decisão que definem as árvores geradoras são os estados das chaves existentes na rede (abertas ou fechadas), como ilustra a Figura 1.

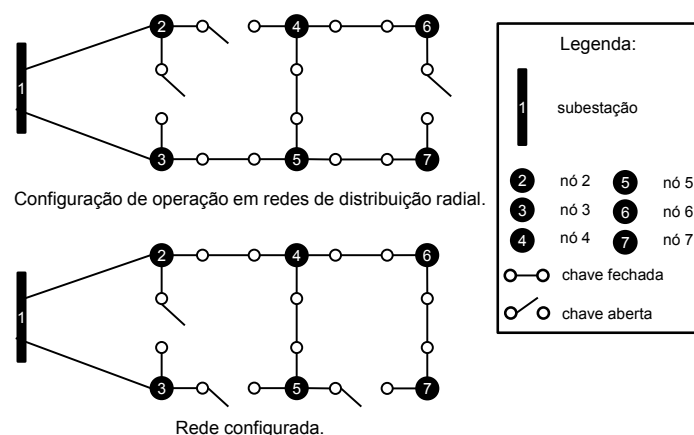


Figura 1: Exemplo de configuração de operação e de reconfiguração por chaveamentos em uma rede de distribuição.



Como já mencionado, este trabalho propõe a exploração de alternativas de buscas locais associadas ao algoritmo BRKGA, para resolver o problema de reconfigurações ótimas em redes com gerações distribuídas de valores determinísticos. O problema pode ser representado pelas Equações 1-5, a seguir.

$$\text{Min}_{s_k \in \mathcal{S}} \left[ l \sum_{k \in N} r_k \frac{(P_k)^2 + (Q_k)^2}{(v_k)^2} \right] \quad (1)$$

sujeito a

$$\mathcal{S} = \{0, 1\} \quad (2)$$

$$\begin{cases} P_k = \sum_{j \in A_k} P_{k,j} + P_{L_k} - P \cdot z_k \\ Q_k = \sum_{j \in A_k} Q_{k,j} + Q_{L_k} - Q \cdot z_k \end{cases} \quad (3)$$

$$\begin{cases} (v_{k+1,j})^2 = (v_k)^2 - \\ -2(r_{k+1,j}P_{k+1,j} + x_{k+1,j}Q_{k+1,j}) \\ \underline{v}_k \leq v_k \leq \overline{v}_k \end{cases} \quad (4)$$

$$G' = (N, A') \text{ é uma árvore} \quad (5)$$

onde:

- $s_k$  representa o estado de uma chave associado ao arco  $k$  (fechado se  $s_k = 1$  e aberto se  $s_k = 0$ );
- $r_k$  é a resistência da linha  $k$ ,  $P_k$ ,  $Q_k$ , e  $v_k$  são, respectivamente, a potência ativa e a potência reativa que flui no arco  $k$ , e o valor da tensão no nó  $k$ , quando a potência ativa  $P$  e a potência reativa  $Q$  são injetados pela fonte de geração;
- $A_k$  é o conjunto de arcos com origem no nó  $k$  (emandado do nó  $k$ );  $P_{k,j}$  e  $Q_{k,j}$  são, respectivamente, a potência ativa e reativa que flui nos arcos " $k, j$ ", *sucessores* do nó  $k$  na *árvore* que representa o alimentador;
- $P_{L_k}$  e  $Q_{L_k}$  são, respectivamente, cargas de potência ativa e reativa no nó  $k$ ;  $z_k = 1$  se a fonte de geração estiver conectada ao nó  $k$ , e  $z_k = 0$  caso contrário (observa-se que a formulação supõe a existência de apenas uma fonte de geração distribuída, com injeção significativa em relação ao total de cargas da rede);
- $\underline{v}_k$  e  $\overline{v}_k$  são, respectivamente, os limitantes inferiores e superiores para os valores de tensão  $v_k$ ;
- $G'$  é um subgrafo que inclui todos os nós na rede e  $A'$  é o subconjunto do conjunto de arcos  $A$  que inclui todos os arcos com fluxos não-zero;
- As Equações (3-5) são generalizações das equações simplificadas de DistFlow, estudadas em Baran e Wu [1989].

A próxima seção apresenta uma abordagem de otimização para resolver o problema 1-5 baseada no *algoritmo genético baseado em chaves aleatórias* (BRKGA) com a adição de uma heurística de busca local.



### Algoritmos Genéticos Baseados em Chaves Aleatórias – BRKGA

Uma alternativa para resolver este problema difícil de otimização combinatória é o algoritmo genético baseado em chaves aleatórias viciadas, denominado BRKGA (*Biased Random-Key Genetic Algorithm*), proposto por Gonçalves e Resende [2011a]. Este algoritmo tem sido aplicado em problemas difíceis de otimização combinatória, como problema de roteamento [Buriol et al., 2005], empacotamento [Gonçalves e Resende, 2011b] e *scheduling* [Mendes et al., 2009].

O BRKGA é baseado no algoritmo genético de chaves aleatórias (do inglês, *Random-Key Genetic Algorithm* - RKGA) de Bean [1994]. O RKGA e o BRKGA representam uma solução do problema com um vetor de  $n$  chaves, onde cada chave é um número real gerado aleatoriamente, no intervalo contínuo  $[0, 1]$ . O algoritmo geralmente começa com uma população inicial de  $p$  vetores com  $n$  chaves geradas aleatoriamente.

Para calcular o custo da solução (*fitness*), o BRKGA utiliza um decodificador que encontra através do algoritmo de árvore de peso mínimo a solução associada a cada vetor de chaves. A cada iteração a população é dividida em duas subpopulações. A primeira subpopulação corresponde ao pequeno conjunto de  $|p_e|$  elementos que possuem os melhores valores de *fitness*, denominado *conjunto elite*; o restante da população compõem o *conjunto não-elite*. O conjunto elite é automaticamente copiado para a geração seguinte, juntamente com novos vetores de chaves aleatórias, chamados de mutantes  $p_m$ . O restante da população é completada com  $|p - p_e - p_m|$  vetores gerados via *crossover*. Segundo Gonçalves e Resende [2011a], os mutantes têm o mesmo papel dos operadores de mutação nos algoritmos genéticos clássicos; sendo assim, procuram evitar convergência para um ótimo local.

O que difere o BRKGA do RKGA é a seleção dos progenitores na realização do processo evolutivo *crossover*. No RKGA, os dois progenitores são escolhidos entre os indivíduos da população. No BRKGA, um progenitor é proveniente do conjunto elite e outro progenitor do conjunto não-elite. A Figura 2, baseada em Gonçalves e Resende [2011a], ilustra a transição da geração  $k$  para a geração  $k + 1$  no processo evolutivo do BRKGA.

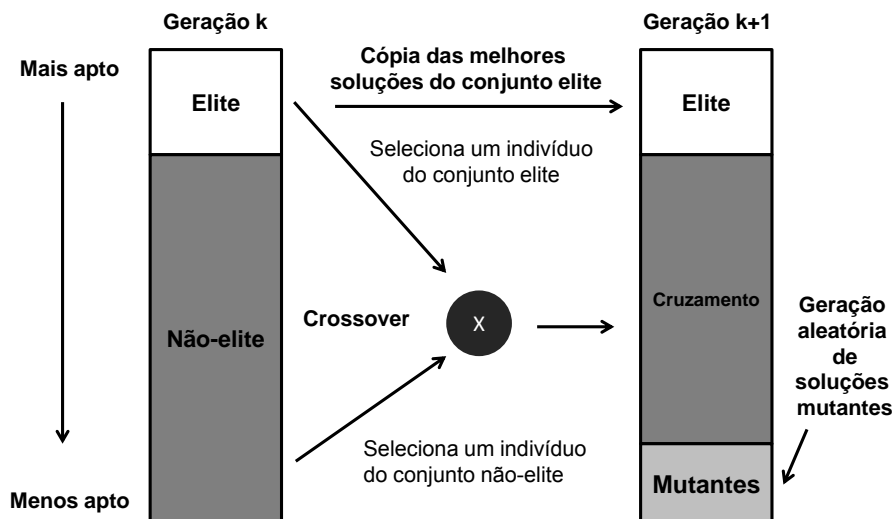


Figura 2: Transição da geração  $k$  para a geração  $k + 1$  no BRKGA.



## Solução do Problema por BRKGA

O algoritmo gera uma população inicial de  $p$  indivíduos representados por  $n$  vetores de chaves aleatórias, com valores distribuídos uniformemente no intervalo  $[0, 1]$ . Em seguida, a informação cromossômica codificada nos valores de chaves do BRKGA dos  $p$  indivíduos da população são decodificados em fenótipo (através do algoritmo de árvore de peso mínimo), permitindo a avaliação do *fitness*. A população inicial é avaliada e separada em subpopulações elite e não-elite, que guiará os processos evolutivos do BRKGA: seleção, *crossover*, mutação e novas avaliações. O processo continua até que não sejam obtidas reduções de perdas nas melhores soluções, desencadeando um reinício do algoritmo BRKGA ou fornecendo a melhor solução encontrada até o momento, se o número máximo de iterações for atingido.

A representação do cromossomo é baseada em dois níveis de representação *network random keys* (NRK) [Rothlauf et al., 2002] originalmente usada para o problema de reconfiguração de redes em da Costa [1999], depois adotada por Vargas *et al.* [Vargas et al., 2004] e Queiroz e Lyra [2009]. É uma representação baseada em arco onde o número de chaves de um cromossomo ( $n$ ) é igual ao número de arcos. Aqui todas as chaves estão no intervalo contínuo  $[0, 1]$  para melhor corresponder a filosofia do BRKGA – isto é análogo, mas ligeiramente diferente da codificação adotada anteriormente para o problema de reconfiguração de redes, onde as chaves são números inteiros.

O algoritmo Kruskal (*minimum spanning tree algorithm*) [Ahuja et al., 1993] é aplicado em cada indivíduo da população para a obtenção da árvore associada ao cromossomo, (isto é, o fenótipo). Como o algoritmo Kruskal sempre mapeia um vetor de  $n$  chaves sobre uma árvore, a representação do problema de reconfiguração de redes de dois níveis garante que uma configuração de rede radial está associada a cada indivíduo da população.

A função de avaliação calcula o *fitness* de cada indivíduo, obtida a partir do valor da função objetivo dada pela Equação 1.

O *parametrized uniform crossover* [Spears e DeJong, 1991] é adotado no processo de reprodução (*crossover*) no BRKGA. Dois cromossomos são selecionados aleatoriamente, um do *conjunto elite* e outro do *conjunto não-elite*. Outro vetor de chaves aleatórias do mesmo tamanho dos cromossomos é gerado e utilizado como uma máscara na operação *crossover*. Se o valor da máscara for menor que  $\rho_a$ , a chave descendente correspondente herda o valor do pai do *conjunto elite*; caso contrário, o valor do pai do *conjunto não-elite*.

A população de *mutantes* é gerada por procedimento *scramble mutation* [Bäck et al., 2000]. Um subconjunto do cromossomo é selecionado aleatoriamente e alguns dos seus valores chaves são modificados aleatoriamente.

Para explorar outras possibilidades de implementação do BRKGA foi incorporada uma busca local baseada na heurística troca de ramos [Civanlar et al., 1988] - esse tipo de busca apresentou bons resultados no algoritmo genético híbrido para reconfiguração de redes radiais proposto por Queiroz e Lyra [2009]. A heurística realiza uma busca na vizinhança de uma solução, procurando por outra configuração que proporcione redução de perdas. Cada etapa da troca de ramos realiza troca entre um arco aberto e outro que esteja fechado em um mesmo ciclo. Civanlar et al. [1988] observaram que maiores reduções de perdas ocorrem quando se realiza operações de troca de ramos com arcos que estejam do lado de menor tensão, entre as tensões nos nós terminais de uma chave aberta. A implementação da busca local segue a estratégia de Baran e Wu [1989], que aperfeiçoaram o método de troca de ramos proposto por Civanlar et al., introduzindo uma estimativa para redução de perdas entre o arco  $x$  (NA) e o arco  $y$  (NF).

Para registrar nos genótipos a operação de troca de arcos, altera-se os genes dos arcos, atribuindo-se valores altos para os arcos que devem ser abertos e valores baixos para os arcos que devem ser fechados [Queiroz e Lyra, 2009]. A Figura 3 apresenta o fluxograma da heurística troca de ramos, baseada em Queiroz e Lyra [2009].

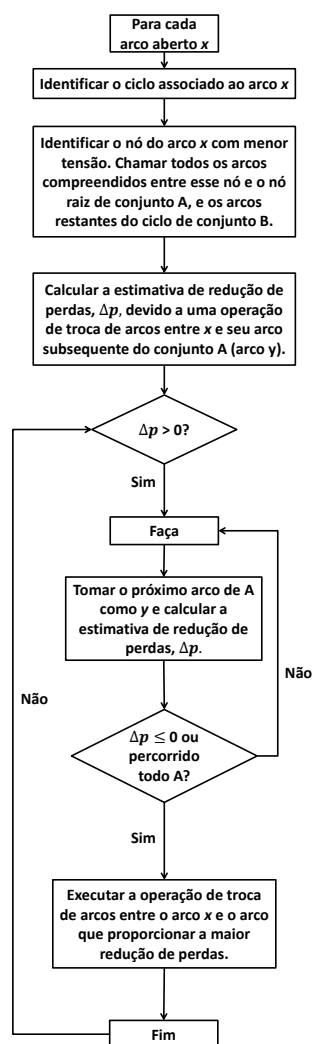


Figura 3: Método de troca de ramos.

## Estudos de Casos

A metodologia foi avaliada em três redes radiais propostas na literatura. A Tabela 1 resume os principais dados para essas redes<sup>1</sup>. Os dados na Tabela 1 também incluem um nó raiz adicional, conectado às subestações pelos arcos do nó adicional.

Rede	Nós	Arcos	Alimentadores	Chaves abertas	Chaves fechadas	Potência total	
						P (kW)	Q (kVAr)
rede 1	144	164	8	21	143	18312	7930
rede 2	205	219	3	15	204	27571	17084
rede 3	881	907	7	27	880	124871	74362

Tabela 1: Dados das redes.

Todos os algoritmos são codificados em MATLAB e as simulações foram realizadas em um PC com Intel Core i7-4790 CPU executando em 3.60GHz, 16Gb RAM e sistema operacional Windows 64 bits. A Tabela 2 resume os parâmetros do BRKGA, baseados nos valores recomendados por Gonçalves e Resende [2011a].

<sup>1</sup>dados estão disponíveis em <http://www.dejazzer.com/reds.html>



Parâmetros	Descrição	Valor
$p$	tamanho da população	100
$p_e$	tamanho da população elite	20
$p_m$	tamanho da população mutante	10
$\rho_a$	probabilidade de herança de alelos da elite	0.7

Tabela 2: Parâmetros adotados no BRKGA.

O algoritmo é reiniciado se a melhor solução do elite não melhora em 50 (iterações) gerações. Caso contrário, o processo de otimização finaliza após 1000 gerações. A busca local é realizada na primeira geração do algoritmo; após a primeira execução, é realizada a cada 25 iterações, sempre no melhor indivíduo da população.

Foram implementadas quatro alternativas para o problema de reconfiguração de redes: *Alternativa 1* com reinicialização e sem busca local; *Alternativa 2* com reinicialização e com busca local; *Alternativa 3* sem reinicialização e com busca local; *Alternativa 4* sem reinicialização e sem busca local. Uma única fonte de energia com valor determinístico foi considerada em todos os estudos de caso. A Tabela 3 fornece o nó que está inserida a geração distribuída, o valor da geração distribuída em  $kW$ , o valor das perdas em  $kW$  e os tempos de processamento em *segundos* para todas as alternativas.

Rede	Nó geração	Geração (kW)	Perdas (kW)				Tempo computacional (segundos)			
			Alter. 1	Alter. 2	Alter. 3	Alter. 4	Alter. 1	Alter. 2	Alter. 3	Alter. 4
rede 1	63	-5680	217,2009	210,8622	216,6457	229,0116	461,7031	529,6563	612,2969	438,3594
rede 2	63	-5680	444,1335	444,0227	514,9483	459,9654	550,875	600,2969	703,0938	541,2813
rede 3	16	-5068	455,0285	451,0998	452,0367	448,8670	1952,9219	2169,0313	9019,4531	1917,0781

Tabela 3: Nó geração, valor da geração, perdas e tempo de processamento.

Os resultados apresentados na Tabela 3 permitem as seguintes observações:

- A **Alternativa 2** obteve perdas menores, mostrando que a inserção da busca local resultou numa melhor exploração do espaço de soluções do problema;
- Comparando os resultados de redução de perdas da **Alternativa 2** e **Alternativa 3**, percebe-se que a adição de busca local com reinicialização levou a melhores resultados.
- Os tempos computacionais da **Alternativa 4** foram menores devido ao algoritmo não precisar passar pelo processo de reinicialização e de buscas locais. No entanto, as perdas são maiores do que com as obtidas com as outras alternativas.

## Discussões Finais

O trabalho apresenta um estudo da evolução do problema de reconfiguração de redes em sistemas de distribuição de energia elétrica, incluindo os trabalhos mais recentes que consideram geração distribuída. Em seguida, apresenta uma formulação matemática para o problema em redes com geração distribuída e desenvolve uma metodologia de solução baseada no algoritmo BRKGA. A metodologia de solução explora também a inclusão de busca local para reforçar o aspecto elitista do algoritmo. O algoritmo BRKGA é capaz de resolver o problema de reconfiguração para redes grandes com baixos tempos computacionais. Os estudos de casos mostraram também que a inclusão de busca local por troca de ramos traz melhorias para a estratégia de solução por BRKGA.

## Agradecimentos

Os autores agradecem o apoio financeiro do CNPq e CAPES.





## Referências

- Ahuja, R., Magnanti, T., e Orlin, J. (1993). *Network Flows: Theory, Algorithms and Application*. Prentice Hall, Englewood Cliffs.
- Bäck, T., Fogel, D., e Michalewicz, Z., editors (2000). *Evolutionary Computation 1: Basic Algorithms and Operators*. Institute of Physics Publishing, Bristol.
- Baran, M. E. e Wu, F. F. (1989). Network reconfiguration in distribution systems for loss reduction and load balancing. *IEEE Transactions on Power Delivery*, 4(2):1401–1407.
- Bean, J. C. (1994). Genetic algorithms and random keys for sequencing and combinatorial and optimization. *Journal on Computing*, 6(2):154–180.
- Bueno, E. A., Lyra, C., e Cavellucci, C. (2004). Distribution network reconfiguration for loss reduction with variable demands. *Transmission and Distribution Conference and Exposition: Latin America, 2004 IEEE/PES*, p. 384–389.
- 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.
- Cavalheiro, E. M. B. (2017). Otimização das configurações de redes de distribuição de energia elétrica com fontes distribuídas. Dissertação de mestrado a ser apresentado a faculdade de engenharia elétrica e de computação da unicamp, 1º semestre de 2017, FEEC - Universidade Estadual de Campinas, Campinas - SP - Brasil.
- Cavalheiro, E. M. B., Vergílio, A. H. B., e Lyra, C. (2016). Configurações Ótimas de redes de distribuição de energia elétrica com gerações distribuídas de valores aleatórios. In *Anais do XLVIII SBPO*, p. 1–9, Vitória, ES. 2016 XLVIII Simpósio Brasileiro de Pesquisa Operacional - SBPO.
- Cavellucci, C. e Lyra, C. (1997). Minimization of energy losses in electric power distribution systems by intelligent search strategies. *International Transactions in Operational Research*, 4(1):23–33.
- Civanlar, S., Grainger, J. J., Yin, H., e Lee, S. S. H. (1988). Distribution feeder for loss reduction. *IEEE Transactions on Power Delivery*, 3(3):1217–1223.
- da Costa, M. F. N. (1999). Evolutionary computation for resistive loss minimization on electric power distribution systems (in portuguese). Master, School of Electrical and Computer Engineering, University of Campinas - UNICAMP, Campinas - SP, Brazil.
- Esmailian, H. R. e Fadaeinedjad, R. (2015). Energy loss minimization in distribution systems utilizing an enhanced reconfiguration method integrating distributed generation. *IEEE Systems Journal*, 9(4):1430–1439.
- Franco, J. F., Rider, M. J., Lavorato, M., e Romero, R. (2013). A mixed-integer lp model for the reconfiguration of radial electric distribution systems considering distributed generation. *Electric Power Systems Research*, 97:51–60.
- Gonçalves, J. F. e Resende, M. G. C. (2011a). Biased random-key genetic algorithms for combinatorial optimization. *Journal of Heuristics*, 17(5):487–525.
- Gonçalves, J. F. e Resende, M. G. C. (2011b). A parallel multi-population genetic algorithm for a constrained two-dimensional orthogonal packing problem. *Journal of Combinatorial Optimization*, 22(2):180–201.



- Jagtap, K. M. e Khatod, D. K. (2016). Loss allocation in radial distribution networks with various distributed generation and load models. *Electrical Power and Energy Systems*, 75:173–186.
- Lee, R. E. e Brooks, L. C. (1988). A method and its application to evaluate automated distribution control. *IEEE Transactions on Power Delivery*, 3(3):1232–1240.
- Lightner, E. M. e Widergren, S. E. (2010). An orderly transition to a transformed electricity system. *IEEE Transactions on Smart Grid*, 1(1):3–10. ISSN 1949-3053.
- Liu, C. C., Lee, S. J., e Vu, K. (1989). Loss minimization of distribution feeders: Optimality and algorithms. *IEEE Transactions on Power Delivery*, 4(2):1281–1289.
- Mendes, J. J. M., Gonçalves, J. F., e Resende, M. G. C. (2009). A random key based genetic algorithm for the resource constrained project scheduling problem. *Computers & Operations Research*, 36(1):92–109.
- Merlin, A. e Back, H. (1975). Search for a minimal-loss operating spanning tree configuration in an urban power distribution system. *Proc. 5th Power System Computation Conference*, p. 1–18.
- Nara, K., Shiose, A., Kitagawa, M., e Ishihara, T. (1992). Implementation of genetic algorithm for distribution systems loss minimum re-configuration. *IEEE Transactions on Power Systems*, 7(3): 1044–1051.
- Queiroz, L. M. O. e Lyra, C. (2009). Adaptive hybrid genetic algorithm for technical loss reduction in distribution networks under variable demands. *IEEE Transactions on Power Systems*, 24(1): 445–453.
- Rao, R. S., Ravindra, K., Satish, K., e Narasimham, S. V. L. (2013). Power loss minimization in distribution system using network reconfiguration in the presence of distributed generation. *IEEE Transactions on Power Systems*, 28(1):317–325.
- Rothlauf, F., Goldberg, D., e Heinzl, A. (2002). Network random keys: a tree representation scheme for genetic and evolutionary algorithms. *Evolutionary Computation*, 10(1):75–97. doi: 10.1162/106365602317301781.
- Shirmohammadi, D. e Hong, H. W. (1989). Reconfiguration of electric distribution networks for resistive line losses reduction. *IEEE Transactions on Power Delivery*, 4(2):1492–1498.
- Spears, W. M. e DeJong, K. A. (1991). On the virtues of parameterized uniform crossover. p. 230–236. In *Proceedings of the Fourth International Conference on Genetic Algorithms*.
- Taylor, T. e Lubkeman, D. (1990). Implementation of heuristic search strategies for distribution feeder reconfiguration. *IEEE Transactions on Power Delivery*, 5(1):239–246.
- Vargas, P. A., Lyra, C., e Von Zuben, F. J. (2004). Application of learning classifier systems to the on-line reconfiguration of electric power distribution networks. *Studies in Fuzziness and Soft Computing*, 150:260–275.
- Zhu, J. Z. (2002). Optimal reconfiguration of electrical distribution network using the refined genetic algorithm. *Electric Power Systems Research*, 62(1):37–42.