

ESTRATÉGIAS EVOLUTIVAS PARA REDUÇÃO DE PERDAS EM SISTEMAS DE DISTRIBUIÇÃO DE GRANDE PORTE

JOSÉ PAULO R. FERNANDES, AUGUSTO C. DOS SANTOS, LEANDRO T. MARQUES, BRENO RUY, JOÃO BOSCO A. LONDON JÚNIOR

*LACO, Depart. de Engenharia Elétrica, Escola de Engenharia de São Carlos, Universidade de São Paulo
Av. Trabalhador São carlense nº 400, São Carlos-SP, Cep 13560-250, Fone: 55-16-33739321*

*E-mails: joseprf@usp.br, augusto@ifto.edu.br, leandrotolomeuj@gmail.com,
ruybr11@gmail.com, jbalj@sc.usp.br*

Abstract— This paper proposes evolutionary strategies to be applied in the active power loss reduction problem in distribution systems. Both strategies are based on a combination of multi-objective algorithms in tables with node-depth encoding, a combination that has been used in literature to deal with power restoration problems in large size networks (with thousands of buses and switches). Two algorithms using both techniques are implemented and applied to two different systems: a small one available in literature and a real large one. Results of various simulations are presented, analysed and compared. To validate the algorithms, results from literature are also considered.

Keywords— Network reconfiguration, loss reduction, evolutionary algorithm, distribution system, node-depth encoding.

Resumo— Este artigo propõe duas estratégias evolutivas para solução do problema de redução de perdas técnicas em Sistemas de Distribuição. As duas são baseadas na combinação de um Algoritmo Multiobjetivo em Tabelas com a Representação Nó-Profundidade, combinação que vem sendo utilizada na literatura para tratamento do problema de restabelecimento de energia em sistemas de grande porte (com milhares de barras e chaves). Dois algoritmos implementando as duas estratégias são então elaborados e aplicados em dois sistemas: um de pequeno porte disponível na literatura e outro real de grande porte. Os resultados de diversas simulações computacionais são então apresentados, analisados e comparados. Resultados apresentados na literatura são também considerados para balizar os resultados obtidos pelos algoritmos desenvolvidos.

Palavras-chave— Reconfiguração de redes, redução de perdas, algoritmo evolutivo, sistema de distribuição, representação nó-profundidade.

1 Introdução

As perdas em sistemas de distribuição representam um grande prejuízo ambiental e econômico para as concessionárias e consumidores, que acabam por pagar taxas mais altas a fim de compensar estes custos.

Conforme estabelece a Agência Nacional de Energia Elétrica (ANEEL), existem perdas técnicas, relacionadas ao processo de transformação e transporte de energia ao longo do sistema de distribuição (SD), e perdas não técnicas, que são aquelas decorrentes de ligações clandestinas e fraudes no sistema. Somadas, as perdas nos SDs representam um prejuízo 1,4 bilhão de reais e cerca de 1,7% da energia gerada entre setembro de 2016 e agosto de 2017 (ANEEL, 2017).

Intervenções de órgãos da justiça e segurança pública são necessárias para lidar com as perdas não técnicas. Por outro lado, as perdas técnicas podem ser reduzidas a partir de procedimentos de operação dos SDs. Uma técnica bastante prática, que aproveita a estrutura já existente nos SDs, é o processo de reconfiguração de redes.

Diversos trabalhos baseados na reconfiguração de redes, a partir de manobras em chaves normalmente abertas (NAs) e normalmente fechadas (NFs), mostram bons resultados para redução de perdas técnicas. Nesta linha trabalhos recentes baseados em meta-heurísticas, como visto em (Atteya et al., 2017) e (Raut, Mishra, 2017), obtiveram bons resultados em sistemas de distribuição do IEEE. Diferentes

abordagens também são apresentadas para tratar do problema. Em (Rao et al., 2012) é apresentada uma metodologia para minimização de perdas em redes com Geração Distribuída (GD), já em (Rugthaicharoencheep, Nedphograw, Wanaratwijit, 2011) a análise é feita considerando também bancos de capacitores, ambas utilizando meta-heurísticas. Por se tratar de um problema altamente combinatório, a utilização de meta-heurísticas é bastante comum, como pode ser visto ainda em (Patel, Patel, 2016), que utiliza um algoritmo genético (AG), e (Su, Chang, Chiou, 2005), onde um algoritmo de colônia de formigas é usado. Em (Romero et al., 2015) foi utilizada a programação matemática, onde o problema de programação não linear inteira mista é transformado em um problema de programação cônica de segunda ordem.

Além de reduzir as perdas, as configurações de operação fornecidas por esses algoritmos precisam respeitar todas as restrições operacionais estabelecidas pelas agências regulamentadoras e também as restrições físicas, ligadas à infraestrutura de rede disponível. Normalmente, os limites de tensão e carregamento da rede e das subestações são os principais pontos a serem observados, mas a manutenção da radialidade da rede, para facilitar a coordenação de dispositivos de proteção, também é bastante usada como uma das restrições operacionais.

Neste artigo propõe-se a solução do problema de redução de perdas, com base no processo de reconfiguração de redes, combinando um Algoritmo Evolutivo Multiobjetivo em Tabelas (AEMT) com a representação nó-profundidade (RNP) (Delbem et al.,

2004). Importa destacar que essa combinação foi desenvolvida e utilizada em (Marques et al., 2017) para tratamento do problema de restabelecimento de energia após a ocorrência de faltas permanentes. A utilização de um algoritmo multiobjetivo em um problema mono-objetivo, como a redução de perdas, permite a realização de uma melhor varredura do espaço de busca com tratamento simultâneo do objetivo e das restrições. Seguindo este modelo, duas estratégias para solução do problema são propostas neste trabalho: uma baseada na minimização das perdas, conforme os modelos tradicionais de tratamento do problema de perdas, e outra baseada na maximização da redução das perdas em relação à configuração inicial da rede, sendo esta ainda não explorada na literatura. Dessa forma, são elaborados dois algoritmos, cada um implementando uma das estratégias propostas. O espaço de busca explorado é o mesmo para ambas as estratégias, porém como são representadas por funções matemáticas distintas (funções objetivo), os espaços de objetivos percorridos por cada AEMO são também distintos.

Resultados de simulações computacionais de ambos os algoritmos, considerando um sistema teste de pequeno porte e um SD real de grande porte, serão ilustrados, analisados e comparados. Resultados apresentados na literatura são também considerados para balizar os resultados obtidos pelos algoritmos propostos.

2 Representação de SDs através de grafos

Para tratar computacionalmente problemas envolvendo o processo de reconfiguração de redes em SDs, o primeiro passo é modelar matematicamente a topologia elétrica desses sistemas, para simulá-lo através de programas computacionais. Para isso utilizam-se, normalmente, grafos, conforme ilustrado na Figura 1. Nessa figura um SD com 3 alimentadores está sendo representado a partir de grafos, da seguinte forma: cada barra (ou nó) do grafo representa um setor (blocos de cargas ou subestações separados por chaves seccionadoras) e as arestas do grafo, interligando as barras, representam chaves seccionadoras. As arestas em linhas cheias representam as chaves NFs e as em linhas tracejadas representam as chaves NAs. As barras 1, 2 e 3 se encontram em subestações (SEs). Face ao exposto, cada alimentador é representado por uma árvore de grafos, sendo o SD representado por uma floresta de grafo.

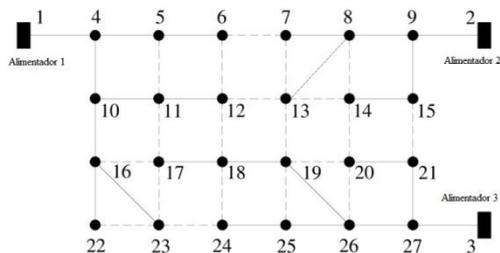


Figura 1. Floresta de grafo representando um SD com três alimentadores

Tendo em vista a representação do SD através de grafos, a eficiência de técnicas computacionais para solução de problemas envolvendo o processo de reconfiguração de redes em SDs depende da eficiência da estrutura de dados utilizada para armazenamento e tratamento da floresta de grafos. Dentre essas estruturas destaca-se, a nosso ver, a RNP (Delbem et al., 2004).

A RNP baseia-se nos conceitos de caminhos e de profundidade do nó em um grafo (árvore) e consiste, basicamente, de uma lista contendo os nós da árvore e suas respectivas profundidades, formando pares do tipo (n_i, p_i) , onde n_i é o nó da árvore e p_i a profundidade do nó. A fim de gerar novas florestas, a partir de uma floresta inicial representada computacionalmente através de RNPs, em (Delbem et al., 2004) foram propostos dois operadores com características de operação distintas, porém produzindo resultados similares. Estes operadores garantem a produção de novas árvores T' quando aplicados em outras árvores T de uma mesma floresta. Maiores informações sobre a utilização da RNP e de seus operadores, para tratamento de problemas envolvendo reconfiguração de redes, podem ser obtidas, por exemplo, em (Santos et al., 2010).

3 O problema de Redução de Perdas

O problema de redução de perdas, em SDs, consiste na determinação de uma configuração radial para operação da rede com mínimas perdas ativas, que respeite as restrições operacionais (limites de tensão e carregamento da rede e das subestações). Dessa forma, esse problema é usualmente formulado como um problema mono-objetivo, com diversas restrições (Marques et al., 2017), da seguinte forma:

$$\begin{aligned}
 & \text{Minimizar } \gamma(G) \\
 & \text{sujeito a:} \\
 & A(G)x(G) = c(G) \\
 & A(G)Y_x(G)A(G)^t v(G) = c(G) \\
 & X(G) \leq 1 \\
 & B(G) \leq 1 \\
 & V(G) \leq 1 \\
 & G \text{ ser uma floresta,}
 \end{aligned} \tag{1}$$

onde G representa uma configuração radial do SD, $\gamma(G)$ é o total de perdas ativas em G ; $A(G)$ é a matriz incidência arestas-nós de G ; $x(G)$ é o vetor com os fluxos de correntes complexas nas linhas em G ; $c(G)$ é o vetor contendo as correntes complexas nas barras de carga ($bi < 0$), de passagem ($bi = 0$) e da subestações ($bi > 0$); $Y_x(G)$ é a matriz admitância diagonal da rede, em G ; $v(G)$ é o vetor de tensões complexas nodais em G ; $X(G)$ é o máximo carregamento da rede em G , dado por $X(G) = \text{MAX}(x_j / \bar{x}_j)$, sendo \bar{x}_j um limitante superior de corrente para cada magnitude de corrente x_j em uma linha j ; $B(G)$ é o máximo carregamento de subestação em G , dado por $B(G) = \text{MAX}(bs / \bar{b}_s)$, sendo \bar{b}_s um limitante superior para

cada magnitude de injeção de corrente b_s , provida por uma subestação s ; $V(G)$ é a máxima queda de tensão em G , dada por $V(G) = \text{MAX} (|v_s - v_k|/\delta)$, sendo v_s a magnitude de tensão na barra de uma subestação s , v_k é a magnitude de tensão em uma barra k da rede e δ é a máxima queda de tensão admissível (neste trabalho 10%, isto é, $\delta = 0,1$).

As duas primeiras restrições representam as leis de Kirchhoff; a terceira, quarta e quinta correspondem às restrições operacionais e representam, respectivamente, os limites para carregamento da rede, subestação e queda de tensão; a última restrição representa a necessidade de se manter a radialidade da rede.

4 Algoritmos propostos

Algoritmos Evolutivos Multiobjetivos (AEMOs) são algoritmos de busca estocástica que utilizam princípios da teoria da evolução e estratégias para otimização multiobjetivo (Deb, 2001). Da mesma forma que os algoritmos evolutivos tradicionais, os AEMOs buscam soluções ótimas para um determinado problema através da manipulação de um conjunto de soluções candidatas (indivíduos), chamado de população. A população inicial é gerada aleatoriamente e deve representar adequadamente o espaço de busca das soluções do problema. A primeira população é avaliada de acordo com a função objetivo desejada e um subconjunto da população é selecionado. Nesse subconjunto são aplicados operadores para modificar os indivíduos produzindo uma nova população. O processo de produção de uma população, a partir de uma anterior, é chamado de geração.

4.1 Algoritmo Evolutivo Multiobjetivo em Tabelas

O AEMT apresentado em (Marques et al., 2017) trabalha em paralelo com várias subpopulações armazenadas em tabelas, onde as melhores soluções (ou configurações do SD no contexto deste trabalho), para cada característica do problema (objetivos e restrições), são armazenadas em suas respectivas tabelas. Consequentemente, possibilita a busca por soluções ótimas extremas, mínimas ou máximas. Porém, estratégias para selecionar subconjuntos de soluções ranqueadas por mais de um objetivo podem ser incorporadas ao AEMT, dando origem a novas tabelas. Dessa forma, tabelas considerando o ranking de dominância, utilizado pelo AEMO *Non Dominated Sorting Genetic Algorithm II* (NSGA-II) (Deb et al., 2002), são facilmente incorporadas ao AEMT, conforme apresentado em (Marques et al., 2017). Isto possibilita o estabelecimento de compromissos entre os extremos mínimos e/ou máximos de diferentes critérios de otimização para obtenção de um conjunto de soluções não dominadas.

Conforme demonstrado em diversos trabalhos empregando a combinação do AEMT com RNP, para problemas de reconfiguração de redes, o tratamento

de objetivos e restrições do problema como tabelas de subpopulações possibilita um melhor mapeamento do espaço de busca garantindo a obtenção de soluções de qualidade (Santos et al., 2010), (Marques et al., 2017) e (Marques, Delbem, London, 2017). Isso motivou a proposição da aplicação do AEMT (uma abordagem multiobjetivo) para solução do problema mono-objetivo de redução de perdas. Porém, nesse contexto, não serão consideradas tabelas com estratégias para selecionar subconjuntos de soluções ranqueados por mais de um objetivo. O interesse é a obtenção de soluções ótimas extremas.

Para tratamento da função objetivo apresentada em (1) vislumbraram-se duas estratégias. Uma direta, considerando o objetivo de minimizar as perdas ativas. Outra indireta, maximizando o percentual de redução de perdas em relação à configuração inicial da rede. Dessa forma, para contemplar essas duas estratégias, dois AEMOs são elaborados, ambos baseados na combinação do AEMT com a RNP, mas com tratamento diferente do objetivo do problema.

Os dois AEMOs possuem tabelas de subpopulação associadas às restrições operacionais do sistema. Ou seja, tabelas que ao longo do processo evolutivo armazenarão as configurações radiais obtidas (soluções candidatas) com o mínimo de: **Tabela P₁** - Carregamento da Rede ($X(G)$); **Tabela P₂** - Carregamento de subestação ($B(G)$); **Tabela P₃** - Queda de tensão ($V(G)$); e **Tabela P₄** - Menores valores da função agregação normalizada definida como:

$$f_a(G) = \frac{\gamma(G)}{\gamma(G^i)} + k_x \frac{X(G)}{X(G^i)} + k_B \frac{B(G)}{B(G^i)} + k_V \frac{V(G)}{V(G^i)} \quad (2)$$

onde G^i é a configuração inicial do sistema, k_x , k_B e k_V são as constantes de ponderação para carregamento de rede, subestação e queda de tensão, respectivamente. Neste trabalho, k_x , k_B e k_V assumem o valor 100 se violar a restrição ou 0, caso contrário.

Tendo em vista a utilização da RNP e de seus operadores, respectivamente para armazenar e manipular o grafo representando a topologia elétrica do SD, a restrição de radialidade é atendida para qualquer configuração gerada no processo evolutivo dos AEMOs propostos (são geradas a partir dos operadores da RNP). Para garantir o atendimento das restrições associadas às Leis de Kirchhoff, basta aplicar o fluxo de potência por varredura direta-inversa com base na RNP proposto em (Santos et al., 2008). Mais informações sobre a utilização da RNP e de seus operadores para atendimento desse conjunto de restrições operacionais podem ser obtidas em (Santos et al., 2010), (Marques et al., 2017) e (Marques, Delbem, London, 2017).

Conforme previamente mencionado, a diferença entre os dois AEMOs propostos refere-se ao tratamento da função objetivo apresentada em (1). O primeiro algoritmo proposto, que será chamado de AEMO 1, trata de forma direta. Assim, além das tabelas já destacadas, ele possui outras duas tabelas de subpopulação que ao longo do processo evolutivo armazenam: **Tabela P₅** – configurações radiais com

menores valores de perdas ativas; e **Tabela P₆** – configurações radiais com menores valores de perdas ativas atendendo a todas as restrições operacionais do problema (melhores soluções factíveis encontradas).

O segundo algoritmo proposto, denominado AEMO 2, trata a função objetivo de forma indireta e, por consequência, além das quatro tabelas supracitadas relacionada às restrições do problema, ele possui outras duas tabelas de subpopulação que ao longo do processo evolutivo armazenam: **Tabela P₅** – configurações radiais com os maiores valores de redução percentual de perdas; e **Tabela P₆** – configurações radiais com os maiores valores de redução percentual de perdas atendendo a todas as restrições operacionais do problema (melhores soluções factíveis encontradas).

Observe que nas **Tabelas P₅** dos dois AEMOs propostos podem ser armazenadas soluções não factíveis. Já as **Tabelas P₆**, desses AEMOs, armazenam apenas soluções factíveis.

4.2 Funcionamento dos AEMOs propostos

A partir da configuração inicial (indivíduo I_0), que deverá ser conexa e acíclica (representada por uma floresta de grafo armazenada em RNPs), gerar-se-ão novos indivíduos a fim de preencher todas as tabelas de subpopulação, dando origem à primeira população. Para isso, os operadores da RNP são aplicados aleatoriamente na configuração inicial, ou em uma das configurações já geradas a partir dela, até que todas as tabelas estejam completas. Observe que neste estágio dos AEMOs propostos, todos os indivíduos gerados são armazenados em todas as tabelas, independente das correspondentes características elétricas. Vale destacar que todas as tabelas possuem uma quantidade fixa, pré-determinada, de indivíduos que ela pode armazenar (cinco neste trabalho).

Após o preenchimento das tabelas com os indivíduos da primeira população, inicia-se o processo evolutivo, que ocorre da seguinte forma:

- Sorteia-se uma tabela;
- Sorteia-se um indivíduo dessa tabela (uma configuração do SD em análise). Esse indivíduo foi selecionado para reproduzir e gerar uma nova configuração;
- Aplica-se um dos dois operadores da RNP no indivíduo escolhido, gerando um novo indivíduo (nova configuração). A escolha do operador da RNP a ser aplicado é aleatória, mas com uma probabilidade que se ajusta dinamicamente, conforme proposto em (Santos et al., 2010);
- Aplica-se, então, ao novo indivíduo (a configuração gerada), o fluxo de potência de varredura direta-inversa com base da RNP para determinar as suas características elétricas (tensões nodais, carregamento da rede e das subestações e as perdas ativas). Para isso utiliza-se o modelo de corrente constante com a tensão, com uma tolerância para convergência de 10^{-3} ;

- Determinadas as características elétricas do novo indivíduo (I_{novo}), este é comparado com o pior indivíduo presente, em cada uma das tabelas de subpopulação, e será incluído em uma tabela P_n , qualquer, se for melhor que a pior solução presente em P_n . Assim, dependendo da adequação de I_{novo} às características do problema (objetivo e restrições), este poderá ser armazenado em uma ou mais tabelas ou ainda descartado. Tendo em vista que o tamanho das tabelas é fixo, se I_{novo} entrar em uma tabela P_n , o pior indivíduo em P_n deverá ser descartado. Para exemplificar esse processo, consideremos que I_{P1}^{Pior} seja o pior indivíduo armazenado na Tabela P_1 . Tendo em vista que essa tabela visa a minimização do carregamento de rede, I_{P1}^{Pior} é o indivíduo com maior carregamento armazenado na Tabela P_1 até a geração de I_{novo} . Dessa forma, se I_{novo} apresentar um carregamento menor que I_{P1}^{Pior} , I_{novo} será armazenado nessa tabela e I_{P1}^{Pior} será descartado;
- O processo de gerar novos indivíduos e alterar a composição das tabelas existentes continua até que uma quantidade máxima de geração de indivíduos (G_{max}), pré-determinada, seja atingida. Ao final do processo, cada tabela terá armazenado os melhores indivíduos em relação a uma característica específica do problema;
- A solução final corresponderá ao melhor indivíduo armazenado na **Tabela P₆**.

5 Testes, Resultados e Discussões

Com a finalidade de avaliar os AEMOs propostos e comparar o desempenho dos mesmos, foram realizados testes em dois SDs. Um de pequeno porte utilizado na literatura e outro real, de grande porte, que consiste no SD da COPEL em operação na cidade de Londrina-Paraná no ano de 2014.

Foi utilizado um computador pessoal com processador Intel Core i7-3770 de 3,40GHz, 32 GB de memória RAM e sistema operacional Ubuntu 16.04 LTS 64 bits. O programa foi codificado em linguagem C.

Na Tabela 1 os tempos de processamento (em segundos) para cada SD e algoritmo proposto são apresentados.

Tabela 1. Tempo de processamento (s).

	SD Kagan		SD Londrina	
	AEMO 1	AEMO 2	AEMO 1	AEMO 2
Mínimo	4,87	5,45	139,05	139,66
Média	6,06	6,83	163,67	162,18
Máximo	8,09	8,31	190,85	186,41
Desvio Padrão	0,84	0,61	15,41	14,93

5.1 Simulações com o SD de pequeno porte

O SD de pequeno porte foi utilizado em outros trabalhos (Kagan, 1999), (Delbem, 2002) e possui 3

subestações, 25 setores, 93 barras e 31 chaves, sendo 17 chaves NFs e 14 chaves NAs. A Tabela 2 apresenta as características elétricas da configuração base desse sistema, que será considerada como a configuração inicial para aplicação dos AEMOs propostos. Destaca-se que os dados da Tabela 2 não são os mesmos apresentados em (Kagan, 1999), em função de no estudo aqui relatado ter sido considerado fator de potência igual a 0,92 para todas as cargas, ao contrário do fator de potência unitário utilizado em (Kagan, 1999). Isto foi realizado para verificar o comportamento dos AEMOs propostos na presença de fluxo de potência reativa.

Tabela 2. Características da configuração original do SD de pequeno porte.

Características Elétricas	Valores
$\gamma(G)$ soma das perdas resistivas em kW	421,74
$V(G)$ máxima queda de tensão em %	2,79
$X(G)$ máximo carregamento da rede em %	75,17
$B(G)$ máximo carregamento da SE em %	66,99

Para fazer uma análise estatística, os dois AEMOs foram executados 50 vezes, com diferentes sementes para o gerador de números aleatórios, onde em cada execução a função objetivo é avaliada 30 mil vezes, além dos 5 indivíduos gerados para compor a configuração inicial. Em seguida, armazenam-se as 50 soluções finais obtidas pelos algoritmos (melhores indivíduos armazenados na Tabela P₆ dos dois AEMOs após as suas execuções). Com base nessas soluções, na Tabela 3 são apresentados os valores mínimos, máximos, médios e desvio padrão para $\gamma(G)$ e $\Delta\gamma(G, G^0)$, onde $\Delta\gamma(G, G^0)$ é a máxima redução de perdas da solução final obtida pelos AEMOs em relação às perdas da configuração original.

Tabela 3. Desempenho dos AEMOs no SD de pequeno porte.

		AEMO 1	AEMO 2
$\gamma(G)$ (kW)	Média	372,82	374,84
	Pior Indivíduo	372,82	378,67
	Melhor Indivíduo	372,82	372,82
	Desvio Padrão	0,00	0,85
$\Delta\gamma(G, G^0)$ (%)	Média	11,60	11,12
	Pior Indivíduo	11,60	10,21
	Melhor Indivíduo	11,60	11,60
	Desvio Padrão	0,00	0,20

O número máximo de gerações utilizado para o sistema de pequeno porte foi de $G_{max} = 30.000$ para os dois AEMOs. Porém, a configuração apresentada como resposta, geralmente é encontrada com menos de 1.000 gerações. Verificar a geração em que uma boa configuração é encontrada não é o objetivo principal desse trabalho, mas podemos comparar a convergência dos AEMOs 1 e 2 para o SD de pequeno porte e de grande porte e tirar várias conclusões. Nesse sentido, a Figura 2 ilustra o diagrama de caixas que representa a geração em que o melhor indi-

víduo da Tabela P₆ é encontrado após 50 execuções do AEMO 1 e do AEMO2, para o SD de pequeno porte.

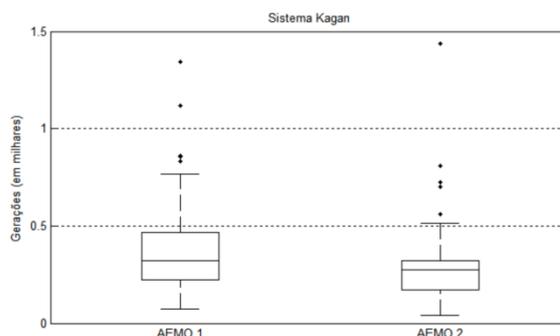


Figura 2. Diagrama de caixas indicando a geração em que o melhor indivíduo da Tabela P₆ foi encontrado pelos AEMO1 e AEMO 2 para o SD de pequeno porte.

5.2 Simulações com o SD da cidade de Londrina

O SD da Cidade de Londrina/Paraná testado, em operação no ano de 2014, possui 21.642 barras, 151 chaves automáticas, 3.429 chaves manuais, 7 subestações, 68 alimentadores e mais de 231 mil consumidores.

A Tabela 4 apresenta as características elétricas da configuração base do sistema, que será considerada como a configuração inicial de referência para aplicação dos AEMOs propostos.

Tabela 4. Características da configuração original do SD da cidade de Londrina.

Parâmetros	Valores
$\gamma(G)$ soma das perdas resistivas em kW	3252,89
$V(G)$ máxima queda de tensão em %	6,42
$X(G)$ máximo carregamento da rede em %	81,95
$B(G)$ máximo carregamento da SE em %	90,11

A Tabela 5 foi elaborada da mesma forma que a Tabela 3, porém considerando 50 execuções, cada uma com 75.000 gerações dos AEMOs para o sistema de Londrina, ou seja, a função objetivo é avaliada 75 mil vezes, além dos 5 indivíduos gerados para compor a configuração inicial.

Tabela 5. Desempenho dos AEMOs no SD da cidade de Londrina.

		AEMO 1	AEMO 2
$\gamma(G)$ (kW)	Média	2913,91	3210,21
	Pior Indivíduo	2958,98	3218,79
	Melhor Indivíduo	2885,99	3185,47
	Desvio Padrão	19,96	10,06
$\Delta\gamma(G, G^0)$ (%)	Média	10,42	1,31
	Pior Indivíduo	9,03	1,05
	Melhor Indivíduo	11,28	2,07
	Desvio Padrão	0,61	0,31

A Figura 3 demonstra, através de diagrama de caixas, em quais gerações os melhores indivíduos foram encontrados após 50 execuções dos AEMOs em simulações com o SD da cidade de Londrina.

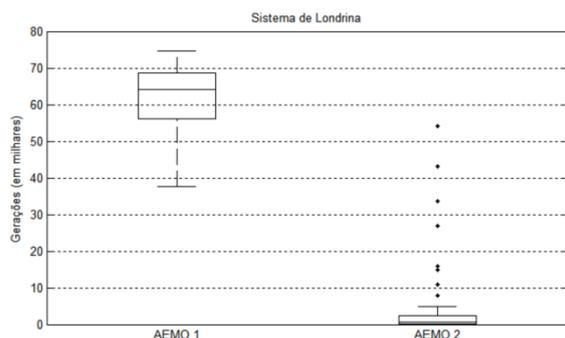


Figura 3. Diagrama de caixas indicando a geração em que o melhor indivíduo da Tabela P₆ foi encontrado pelos AEMO1 e AEMO 2 para o SD da cidade de Londrina

5.3 Discussões dos Resultados

Os AEMOs foram desenvolvidos para encontrar a solução factível com menores perdas resistivas. Nesse sentido, para o SD de pequeno porte, o AEMO 1 encontrou, em todas as execuções, a mesma solução, reduzindo as perdas em 11,60% em relação à configuração original, enquanto no AEMO 2 a redução média foi de 11,12%. Em (Kagan, 1999), a redução percentual encontrada para perdas foi de 13,83%, utilizando somente cargas resistivas.

Ao analisar o diagrama de caixas apresentado na Figura 2 para o SD de pequeno porte, observa-se que o desempenho de ambos AEMOs, em relação ao número de geração em que a melhor solução foi encontrada, é semelhante. O AEMO 2 converge com um número de gerações menor. Porém, em algumas execuções, ficou preso em “ótimos locais”, entregando, como resposta, uma configuração com mais perdas que a encontrada pelo AEMO 1.

Para o SD de grande porte, observa-se que o desempenho do AEMO 1 foi bem melhor que o desempenho do AEMO 2. Em média, a redução das perdas em relação à configuração original, para o AEMO 1, foi de 10,42%, enquanto para o AEMO 2 foi de 1,31%. Pelo diagrama de caixas apresentado na Figura 3, nota-se que para 75 mil gerações do AE, a mediana do número de gerações em que o AEMO 1 encontra a solução ótima é próxima a 65 mil, enquanto a mediana do AEMO 2 está em 653 gerações. Isso demonstra que o AEMO 2 se prende em “ótimos locais” gerados bem próximos ao início do processo.

6 Conclusões

Com base na combinação de um AEMT com a RNP, duas estratégias evolutivas para solução do problema de redução de perdas técnicas em SDs foram propostas neste trabalho. Dois algoritmos, implementando essas estratégias, foram então desenvolvidos e submetidos a diversas simulações computacionais. Para isso foram utilizados dois sistemas,

um de pequeno porte, utilizado na literatura, e outro real, de grande porte, que consiste no SD da COPEL em operação na cidade de Londrina no ano de 2014.

Os resultados obtidos pelos dois algoritmos, para o sistema teste de pequeno porte, mostraram-se adequados quando comparados com os resultados encontrados em (Kagan, 1999). Vale lembrar, entanto, que no estudo aqui apresentado foi considerado fator de potência igual a 0,92 para todas as cargas, ao contrário do fator de potência unitário utilizado em (Kagan, 1999).

Os resultados obtidos mostraram que o AEMO 1, baseado na estratégia de minimização da função objetivo apresentada em (1) de forma direta (ou seja, minimização das perdas), teve desempenho superior ao AEMO 2, que busca maximizar a redução de perdas. O AEMO 1 mostrou maior consistência em número de gerações necessárias, e encontrou resultados melhores para os dois sistemas testados, em especial para o SD real de grande porte. Dessa forma pode-se concluir, com base nos resultados obtidos, que assumir a maximização da redução de perdas, como objetivo principal do problema, não é uma estratégia eficiente no modelo de algoritmo proposto.

Em um trabalho futuro pretende-se explorar o AEMO 1 para solução do problema de minimização de perdas, em SDs, considerando vários níveis de demanda.

Agradecimentos

Os autores agradecem à Universidade de São Paulo (USP) e ao Instituto Federal de Educação, Ciência e Tecnologia do Tocantins (IFTO) pelo apoio. Também agradecem às agências de fomento CAPES e CNPq (processo nº 309087/2015-5) e à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) (processo 2017/23728-0) pelo apoio financeiro.

Referências Bibliográficas

- Agência Nacional de Energia Elétrica – ANEEL (2017). Perdas de energia. Disponível em: http://www.aneel.gov.br/metodologia-distribuiacao/-/asset_publisher/e2INtBH4EC4e/content/perdas/654800?inheritRedirect=false. Acesso em 04 de Março de 2018.
- ATTEYA, I. I., ASHOUR, H., FAHMI, N., STRICKLAND, D. (2017). Radial distribution network reconfiguration for power losses reduction using a modified particle swarm optimisation. 24th International Conference & Exhibition on Electricity Distribution (CIRED), no. 1, pp. 2505-2508.
- DEB, K. (2001). Multi-Objective Optimization Using Evolutionary Algorithms. Chichester, Wiley, UK.
- DEB, K., PATRAP, A., AGARWAL, S., MEYARIVAN, T. (2002). A fast and elitist

- multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182–197.
- DELBEM, A.C.B. (2002). Restabelecimento de Energia em Sistemas de Distribuição por Algoritmo Evolucionário Associado a Cadeias de Grafos, Escola de Engenharia de São Carlos, Universidade de São Paulo, Tese de Doutorado.
- DELBEM, A. C. B.; de CARVALHO, A. C. P. L. F.; POLICASTRO, C. A.; PINTO, A. K.; HONDA, K.; GARCIA, A. C. (2004). Node-depth encoding for evolutionary algorithm applied to network design. *Genetic and Evolutionary Computation Conference*, pp. 678-687.
- KAGAN, N. (1999). Configuração de Redes de Distribuição através de Algoritmos Genéticos e Tomada de Decisão Fuzzy, Tese de livre docência/EP-USP, São Paulo.
- MARQUES, L. T., LONDON JR., J. B. A., CAMILLO, M. H. M., LIMA, T. W. (2017). A new multi-objective evolutionary algorithm for service restoration: Non-dominated Sorting Genetic Algorithm-II Subpopulation Tables. *Power Tech, IEEE Manchester*.
- MARQUES, L. T., DELBEM, A. C. B., LONDON JR, J. B. A. (2017). Service Restoration with Prioritization of Customers and Switches and Determination of Switching Sequence. *IEEE Transactions on Smart Grid* (DOI 10.1109/TSG.2017.2675344).
- PATEL, A. G.; PATEL, C. (2016). Distribution reconfiguration for loss reduction, *International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*, Chennai – Índia.
- RAO, R. S.; RAVINDRA, K.; SATISH, K.; NARASIMHAM, S. V. L. (2012). Power Loss Minimization in Distribution System Using Network Reconfiguration in the Presence of Distributed Generation. *IEEE Transactions on Power Systems*, vol. 28, no. 1, pp. 317-325.
- RAUT, U.; MISHRA, S. (2017). Power Distribution Network Reconfiguration for Loss Minimization using a New Graph Theory Based Genetic Algorithm. *IEEE Calcutta Conference (CALCON)*, Calcutta – India.
- ROMERO, R., FRANCO, J. F., LEÃO, F. B., RIDER, M. J., de SOUZA, E. S. (2015). A New Mathematical Model for the Restoration Problem in Balanced Radial Distribution Systems. *IEEE Transactions on Power Systems*, v. 31, pp. 1-10.
- RUGTHAICHAROENCHEEP, N.; NEDPHOGRAW, S.; WANARATWIJIT, W. (2011). Distribution system operation for power loss minimization and improved voltage profile with distributed generation and capacitor placements. *4th International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT)*, Shandong – China.
- SANTOS, A. C., DELBEM, A. C. B., LONDON JR., J. B. A., BRETAS, N. G. (2010). Node-Depth Encoding and Multiobjective Evolutionary Algorithm Applied to Large-Scale Distribution System Reconfiguration. *IEEE Transactions on Power Systems*, v.25, n.3, p.1254 –1265.
- SANTOS, A. C., NANNI, M., MANSOUR, M. R., DELBEM, A. C. B., LONDON JR., J. B. A., BRETAS, N. G. (2008). A Power Flow Method Computationally Efficient for Large-Scale Distribution Systems. *IEEE Transmission and Distribution Conference and Exposition: Latin America*. Bogotá, Colômbia.
- SU, C.-T.; CHANG, C.-F.; CHIOU, J.-P. (2005). Distribution network reconfiguration for loss reduction by ant colony search algorithm. *Electric Power Systems Research*, vol. 75, no. 2 e 3, pp. 190-199.