

Reconfiguração de Redes de Distribuição com Nuvem de Partículas Baseada em Perdas Mínimas de Energia

Lorena T. S. Santos; Nivaldo R. Ferreira; Rai A. R. Pereira

Resumo - Neste trabalho a metaheurística PSO é utilizada para resolver o problema de reconfiguração de sistemas de distribuição de energia elétrica. O objetivo é minimizar as perdas de potência ativa do sistema sujeito a restrições físicas e operacionais do sistema de distribuição. As variáveis do problema representam a abertura e/ou fechamento de chaves de interconexão existentes nos ramos do sistema. Na metodologia utilizada todas as chaves de interconexão representam uma partícula, as partículas serão guiadas através de uma função objetivo, perdas mínimas. A cada iteração as partículas irão buscar uma configuração ótima de chaves, que respeitem a topologia radial do sistema e o critério de perdas mínimas, até encontrar uma solução desejada. São apresentados testes realizados em um sistema de 33 barras para avaliar a eficiência e robustez da metodologia proposta.

Palavras-chave — Configuração Ótima. Nuvem de Partículas. Perdas Mínimas. Reconfiguração. Sistemas de Distribuição. Topologia Radial.

I. NOMENCLATURA

NA – Normalmente Aberto
 NF – Normalmente Fechado
 PSO – Otimização por Nuvem de Partículas
 SDEE – Sistemas de Distribuição de Energia Elétrica

II. INTRODUÇÃO

O setor elétrico apresenta um mercado muito exigente, por isso as concessionárias de energia elétrica têm imprimido esforços para conceder um produto de qualidade, ou seja, o fornecimento de energia elétrica para os consumidores.

A maioria dos sistemas de distribuição tem por essência uma topologia radial, justamente para minimizar a corrente de falta, redução dos custos de equipamentos e uma maior simplicidade na coordenação de proteção. Atualmente encontramos cada vez mais sistemas de distribuição automatizados, isso permite alterar com maior facilidade a configuração da rede, através de manobras dos dispositivos de seccionamento. Essa reconfiguração tem por consequência tornar o sistema o mais radial possível, com objetivos de minimizar as perdas elétricas, melhorar os níveis de tensão e balancear as cargas entre os alimentadores.

Vale ressaltar que na reconfiguração de redes de distribuição, a abertura e fechamento das chaves não resultam em gastos adicionais para as empresas de distribuição.

Existem na literatura diversos métodos aplicáveis ao problema de reconfiguração de redes de distribuição, como AG – Algoritmo Genético [11] que utiliza os operadores genéticos de seleção, cruzamento e mutação, GRASP – *Greedy Randomized Adaptive Search Procedure* [8], que é uma metaheurística baseada em um algoritmo heurístico construtivo do tipo guloso, porém utiliza uma componente aleatória e adaptativa, utilizada para resolver problemas complexos e de grande porte. Há também métodos baseados na inteligência de enxames como ACO – *Ant Colony Optimization* [9] que se baseia no comportamento de uma colônia de formigas.

Neste projeto será utilizado Otimização por Nuvens de Partículas (PSO). Através dessa metodologia serão analisados os resultados encontrados, o tempo de convergência, o número de iterações e verificar se o método trabalhado, através de comparações com outras metodologias, atende as necessidades da reconfiguração, em que se procura o mínimo de perdas no sistema. Para isto foi estudado o caso de sistemas com 33 barras.

III. RECONFIGURAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO

No passado, a prática da reconfiguração no Sistemas de Distribuição de Energia Elétrica (SDEE) era realizada pela experiência prática dos próprios operadores, mas atualmente a operação de redes de distribuição se tornou um desafio da engenharia, porque recomenda-se que seja considerada a solução ótima e, devido à quantidade e complexidade destes problemas, o único caminho viável é a utilização de softwares especializados.

O problema de reconfiguração de SDEE consiste na determinação de uma topologia radial e conexa da rede, através da definição dos estados (aberto ou fechado) das chaves de manobra acopladas aos circuitos de distribuição. Esta topologia otimiza um determinado índice de desempenho do sistema, como a redução das perdas técnicas, atendendo as restrições operacionais. Os dispositivos de chaveamento incluem as chaves de seccionamento ou normalmente fechadas (NF) e as chaves de interconexão ou normalmente abertas (NA).

O problema da reconfiguração de sistemas de distribuição pode ser formulado como uma otimização não linear com

Lorena Teixeira de Souza Santos, UFBA (lorena.txs@gmail.com)

Nivaldo Roberto Ferreira, UFBA (nivaldo@ufba.br)

Rai Aldebaran Ripardo Pereira, UFBA (raialdebaran@gmail.com)

variáveis inteiras e reais. A partir de todas as possíveis configurações, a solução encontrada é aquela que gera a menor perda de potência ativa e que satisfaça um conjunto definido de restrições. De forma geral o problema de reconfiguração de sistemas radiais pode ser formulado como:

$$\text{Minimizar} ==> F_k = \sum_{i=1}^{N_r} R_i \cdot I_i^2 \quad (1)$$

Sujeitos a:

- Restrições de fluxo de carga ($I_i \leq I_{max,i}$);
- Topologia radial;
- Níveis de tensão ($V_{min,j} \leq V_j \leq V_{max,j}$);
- Confiabilidade do sistema;
- Balanço de carga dos alimentadores.

Onde:

- F_k : Representa as perdas totais do sistema (Função objetivo) na configuração k;
- R_i : Resistência do i-ésimo ramo da configuração k;
- N_r : Número de ramos da configuração k;
- I_i : Valor da corrente do i-ésimo ramo na configuração k.

A natureza combinatória do problema de reconfiguração juntamente com as restrições, principalmente a radialidade, são fatores que dificultam sua resolução, pois é trabalhoso representar esta restrição através de relações algébricas e, portanto, se torna muito difícil usar algoritmos baseados em técnicas tradicionais de otimização para sua solução.

IV. OTIMIZAÇÃO POR NUENS DE PARTÍCULAS

As técnicas de computação evolucionária são motivadas pela evolução das espécies na natureza, existem nesse campo várias técnicas já desenvolvidas, como programação evolucionária (FOGEL, 1994), algoritmos genéticos (GOLDBERG, 1989), estratégias evolucionárias (KOZA, 1992) e programação genética (RE-CHEMBERG, 1994). Uma população de indivíduos, os quais representam as possíveis soluções para o problema, são manipulados, de acordo com as regras de sobrevivência, que melhor se adaptam aos operadores genéticos, tais como mutação, cruzamento e reprodução. A melhor solução evolui através das gerações. Essas técnicas têm sido aplicadas com sucesso em problemas de Otimização.

Com base nessas técnicas evolucionárias, James Kennedy e Russell Elberhart desenvolveram em 1995 um algoritmo diferente, denominado, em inglês, de *Particle Swarm Optimization* (PSO) e, em português, Otimização por Nuvem (ou Enxame) de Partículas, inspirado na simulação do comportamento de um bando de pássaros em revoada, com movimento local aleatório, mas socialmente determinado. As principais propriedades de um sistema de inteligência de enxame são (Millonas, 1994):

- a) Proximidade: necessita de espaço simples e pequeno tempo computacional.
- b) Qualidade: Respondendo a fatores de qualidade no

ambiente.

- c) Resposta diversa: Não entrando em um subconjunto restrito de soluções.
- d) Estabilidade: Podendo manter modos de comportamentos quando os ambientes mudam.
- e) Adaptabilidade: Podendo mudar modos de comportamentos quando a adaptação for necessária.

Assim como em outras abordagens de inteligência coletiva, PSO é baseada em uma população de indivíduos capazes de interagir entre si e com o meio ambiente. Com base nas propriedades de auto avaliação, comparação e imitação, os indivíduos são capazes de lidar com um número de possíveis situações que o ambiente lhes apresenta. Os comportamentos globais serão, portanto, resultados emergentes dessas interações.

O método PSO possui vantagens como sua implementação simples, boa velocidade pois não requer cálculo de derivadas, poucos parâmetros para serem definidos pelos usuários e alta precisão.

V. O ALGORITMO PSO

Na versão original do PSO, o sistema é inicializado com uma população de soluções randômicas, que é muito similar a algumas técnicas da computação evolucionária, como os algoritmos genéticos (AG), entretanto, ele difere dessas outras técnicas populacionais, pois, para obter uma nova geração de indivíduos, não é utilizado nenhum operador inspirado nos procedimentos de DNA. Em vez disso, são utilizadas partículas em movimento em um espaço de busca D-dimensional, sendo cada uma delas uma solução potencial para o problema. Cada partícula possui uma velocidade que é ajustada dinamicamente de acordo com sua própria experiência e das partículas vizinhas, para que possa percorrer o espaço de busca do problema.

O PSO original emprega dois princípios sócio-métricos, que representam dois tipos de informação importante no processo de decisão. O primeiro princípio, melhor posição global (gbest), conecta conceitualmente todos os membros de uma população entre si. Como consequência, o comportamento de cada partícula é influenciado pelo comportamento de todas as outras partículas. A segunda métrica, melhor posição da partícula (pbest), cria uma vizinhança para cada indivíduo composta por ele próprio e seus vizinhos mais próximos. Ambas as métricas são medidas por uma função de avaliação ($f(p)$), também chamada função objetivo ou de aptidão (fitness), que corresponde à optimalidade da solução do problema.

Cada partícula i pode ser representada como um objeto com várias características. A posição atual da partícula é representada por $X_i = (X_i(1), X_i(2), \dots, X_i(t))$. A melhor posição prévia, ou seja, a posição que dá o melhor valor de aptidão da i -ésima partícula, é registrada e representada por $pB_i = (pB_i(1), pB_i(2), \dots, pB_i(t))$. O índice da melhor partícula entre todas as partículas na população, é representado pelo símbolo gB. A taxa da mudança de posição, que é chamada de velocidade, é representada por

$$V_i = (V_i(1), V_i(2), \dots, V_i(t)).$$

A movimentação de cada partícula é baseada nos três parâmetros já observados: fator de sociabilidade; fator de individualidade; e velocidade máxima, que delimita o movimento, uma vez que esse é direcional e determinado. As partículas são então manipuladas de acordo com as seguintes equações:

$$V_i(t+1) = W \cdot V_i(t) + c1 \cdot r1 \cdot (pB_i(t) - X_i(t)) + c2 \cdot r2 \cdot (gB(t) - X_i(t)) \quad (2)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (3)$$

Onde:

- **c1 e c2:** são duas constantes positivas que correspondem às componentes cognitivas e sociais.
- **r1 e r2:** são duas funções aleatórias no intervalo [0,1].
- **W:** é o fator de inércia que determina a diversificação ou intensificação das partículas.

A primeira equação é usada para calcular a nova velocidade da partícula, de acordo com sua velocidade anterior e as distâncias entre sua posição atual, sua melhor posição, e a melhor posição do grupo. A partir daí a partícula “voa” para uma nova posição de acordo com a segunda equação. O desempenho de cada partícula é medido de acordo com uma função de aptidão pré-definida que é relacionada ao problema a ser resolvido. Os parâmetros ω , $c1$, $c2$ são os coeficientes fornecidos pelo usuário. Cada um dos três termos da equação de atualização de velocidade tem diferentes papéis no algoritmo PSO.

No cálculo do primeiro termo, $W \times V_i(t)$, a velocidade anterior está sendo multiplicada pelo momento de inércia, que é um parâmetro que avalia a velocidade, sendo responsável por manter a partícula se movendo na mesma direção em que estava originalmente. Um fator de inércia maior facilita exploração global, ou seja, a procura por novas áreas dentro do espaço, enquanto um fator de inércia menor tende a facilitar exploração local para refinar a área de procura atual. A seleção satisfatória do fator de inércia W pode prover um equilíbrio entre habilidades de exploração global e local, podendo dessa forma requerer menos repetições, em média, para encontrar o valor ótimo.

O segundo termo é composto pela componente de cognição $c1$, multiplicado por um número randômico no intervalo [0,1], que por sua vez multiplica a diferença existente entre a posição atual da partícula e a melhor posição encontrada pela partícula ($pbest$), ou seja, essa diferença, $(pB_i(t) - X_i(t))$, age como a memória da partícula, fazendo com que ela tenda a voltar para as regiões do espaço de busca em que experimentou alta aptidão individual.

O terceiro termo da equação é composto pela componente social $c2$, também multiplicado por um número randômico no intervalo [0,1], que por sua vez multiplica a diferença existente entre a posição atual da partícula e a melhor solução encontrada por uma população até o momento ($gbest$), ou seja, essa diferença, $(gB(t) - X_i(t))$, representa a experiência da nuvem de onde

a solução está.

O algoritmo PSO é repetido até que um critério de terminação seja atingido ou as mudanças nas velocidades das partículas estejam perto de zero.

VI. VERSÃO BINÁRIA DO PSO

Uma versão binária do PSO foi introduzida pelo Kennedy e Eberhart (1997). Esta versão, também chamada de BPSO, é útil para representar problemas que são por natureza binários. Esta versão restringe os valores de componente de X_i e pB_i para serem elementos do intervalo [0,1]. Porém, não há nenhuma restrição no valor da velocidade, V_i , de uma partícula. Entretanto, quando a velocidade é usada para atualizar as posições, ela deve ser colocada dentro do intervalo de [0,0-1,0] e tratada como probabilidade. Isto pode ser obtido utilizando a função sigmoide, definida por:

$$S(V_i(t)) = \frac{1}{1 + e^{-V_i(t)}} \quad (4)$$




Figura 1. Função Sigmoide

A atualização da equação do BPSO pode ser definida em dois importantes passos. Primeiramente na equação que define a velocidade é usada para atualizar a velocidade, em seguida essa velocidade será usada na função sigmoide para limitá-la no intervalo [0, 1]. O segundo passo consiste na nova posição da partícula e ela será concebida da seguinte maneira:

$$X_i(t) = \begin{cases} 1, & \text{se } rand < S(V_i(t)) \\ 0 & \text{caso contrário} \end{cases} \quad (5)$$

Onde $rand$ é um número aleatório uniformemente distribuído no intervalo de [0, 1].

VII. RECONFIGURAÇÃO ATRAVÉS DO PSO BINÁRIO MODIFICADO

Este artigo irá utilizar como base o método Binário modificado, metodologia proposta por Khalil et al. (2012). Será traduzida a sequência de passos da metodologia a fim de torná-los aplicáveis ao problema da reconfiguração de sistemas de distribuição.

Em 2012, Khalil e Gorpínich propuseram uma modificação simples no PSO binário para busca em um espaço selecionado. No SPSO (*Selective Particle Swarm Optimization*), um espaço de busca em cada dimensão é um conjunto de n posições, onde n é a quantidade de posições selecionadas. O espaço de busca é representado por $S_d = (S_{d,1}, S_{d,2}, \dots, S_{d,n})$.

Como no PSO clássico, uma função de aptidão deve ser definida. Neste caso, mapeia-se a cada dimensão (d) de (n) posições do espaço selecionado (S_d), em que a posição de cada partícula foi alterada de um ponto no espaço real para um ponto no espaço selecionado. Por conseguinte, a transformação sigmoide foi alterada para (6), e a posição de cada partícula na dimensão d passa a ser um valor seletivo, que é atualizado pela equação (7).

$$\text{Sig}(V_{i,d+1}) = n \times \frac{1}{1 + e^{-V_{i,d+1}}} \quad (6)$$

$$X_{i,d+1} = \begin{cases} S_{d,1}, \text{ se } \text{Sig}(V_{i,d+1}) < 1 \\ S_{d,2}, \text{ se } \text{Sig}(V_{i,d+1}) < 2 \\ \vdots \\ S_{d,n}, \text{ se } \text{Sig}(V_{i,d+1}) < n \end{cases} \quad (7)$$

Onde $S_{d,1}, S_{d,2}, \dots, S_{d,n}$ são os valores selecionados na dimensão d . Os valores de velocidade são restritos a valores mínimos e máximos utilizando a seguinte fórmula:

$$V_{i,d+1} = \begin{cases} V_{max}, \text{ se } V_{i,d+1} > V_{max} \\ V_{i,d+1}, \text{ se } V_{min} < V_{i,d+1} < V_{max} \\ V_{min}, \text{ se } V_{i,d+1} < V_{min} \end{cases} \quad (8)$$

Para evitar a invariabilidade do valor da velocidade das partículas no máximo ou no mínimo e forçar cada partícula a atravessar o espaço de busca utiliza-se a seguinte fórmula:

$$V_{i,d+1} = \begin{cases} \text{rand} \times V_{i,d+1}, \text{ se } |V_{i,d+1}| = |V_{i,d}| \\ V_{i,d+1}, \text{ caso contrário} \end{cases} \quad (9)$$

A resolução de problema de Reconfiguração de Sistemas de Distribuição por SPSO pode ser dividido em três etapas:

1. Especificar o número de dimensões;
2. Encontrar o espaço de busca para cada dimensão;
3. Usar SPSO para achar a provável solução a partir dos espaços de busca.

A. Especificação da dimensão do Sistema

Pode-se definir o sistema de distribuição como circuitos divididos em malhas, mas pelo fato do sistema de distribuição ter que manter uma topologia radial ou em árvores, essas malhas são abertas através de chaves. Para que seja definida a dimensão do sistema deve ser feito o seguinte procedimento: todas as chaves devem ser fechadas, isso irá fornecer ao usuário o número de loops ou circuitos fechados do sistema. O número de loops é igual ao número da dimensão do sistema.

B. Espaço de Busca

O espaço de busca para cada dimensão serão os ramos (trechos) contidos em cada laço. Os ramos que não pertencem a qualquer laço não representam os espaços de pesquisa, e, portanto, ele será descartado do algoritmo para otimização do sistema.

C. Solução

Após a especificação da dimensão e também seleção do

espaço de busca, a metodologia pode ser empregada para se obter uma solução com perda mínima de energia.

D. Criação da População Inicial

A população inicial foi gerada de forma randômica, de modo a dotar o algoritmo de diversidade dentro do espaço de busca. Como definido nas seções anteriores, foi obtida a dimensão do sistema. Será escolhida uma chave de cada laço e cada chave terá sua coordenada correspondente. A escolha dessas disposições permitirá que o sistema opere de forma radial, já que um trecho escolhido não está contido em mais de um laço. Os parâmetros $c1=c2$ tiveram seus valores iguais a 2. O momento de inércia ficou com os valores $W_{max} = 0,9$ e $W_{min} = 0,4$, sendo fixado o número máximo de iterações em 300 para o sistema de 33 barras.

E. Determinação das Perdas das Partículas

Após selecionadas as chaves a serem abertas, em que cada chave representa uma partícula, é necessário encontrar uma função que conduza a população ao encontro das melhores posições, que será definida como função objetivo do problema. No caso do sistema de distribuição de energia, nosso interesse é minimizar as perdas do sistema.

Na avaliação da qualidade da função objetivo de cada configuração, utiliza-se um programa para o cálculo do fluxo de potência para uma rede radial (BRANDINI, 2000). No programa utilizado, foi disposto em uma tabela os valores das potências em cada trecho, assim como reatâncias e resistências.

Segundo Brandini (2000) o cálculo das perdas deve ser realizado da seguinte maneira: Inicialmente, é escolhido um valor para os módulos de tensão em cada barra. Normalmente é utilizado como base a tensão da subestação, assim para cada barra k , assume-se que $V_k = V_{ref} + j0$, em que V_{ref} é o módulo de tensão da subestação. Com as tensões nas barras definidas, é obtido o conhecimento da corrente de carga que transita em todas as barras e as correntes em todos os ramos do sistema radial. Este processo inicia-se das barras extremas e percorrendo as barras em direção à subestação (*backward*). Calculadas as correntes nos ramos se pode calcular as perdas ativas (e reativas) do sistema. Desta maneira pôde ser calculado o valor das perdas do sistema.

Calculadas as correntes nos ramos do sistema, através do processo (*backward*), é obtido o conhecimento da corrente que está transitando no mesmo, além das informações com as correntes que estão saindo da subestação. Com base nestes últimos valores é iniciado o processo a partir da subestação em sentido (*forward*) das barras finais, de modo a calcular os novos valores das tensões de todas as barras do sistema. Com base nos novos valores de tensão das barras, é obtido o conhecimento do novo trânsito de correntes de carga nas barras e as correntes em todos os ramos do sistema. Esses novos valores de correntes encontrados permitem a geração de novos valores de perdas ativas (e reativas) do sistema. Este processo iterativo termina com a convergência dos valores de tensão entre duas iterações sucessivas, permitindo encontrar as perdas nos sistemas de distribuição.

F. Determinação das Melhores Posições

Após iniciado o algoritmo, a sua premissa é buscar o melhor resultado ou configuração ideal de chaves, em que o nível de perdas seja mínimo.

Após o procedimento de busca, cada chave terá calculada as perdas no seu laço de referência ou espaço de busca. Esses valores serão armazenados em uma matriz, que irá receber os valores de menor perda de energia ativa de cada partícula em conjunto com a configuração das chaves ou coordenadas das partículas.

A cada ciclo da metodologia, esses resultados armazenados na matriz serão comparados com os resultados das partículas atuais. Caso essa partícula obtenha um melhor resultado do que a partícula anterior, ela irá sobrepor aquela já armazenada. Assim será obtido no final do programa o melhor resultado para o sistema.




Figura 2. Fluxograma do método proposto

G. Cálculo da Velocidade e Posição

Para o cálculo da velocidade das partículas, deve-se utilizar a equação de atualização da velocidade a seguir:

$$V_{i,d+1} = W \cdot V_{i,d} + c1 \cdot r1 \cdot (pB_{i,d} - X_{i,d}) + c2 \cdot r2 \cdot (gB_d - X_{i,d}) \quad (10)$$

Como foi mencionado, por se tratar de um problema discreto, as diferenças $(pB_{i,d} - X_{i,d})$ e $(gB_d - X_{i,d})$ devem ser valores inteiros. Após iniciado o algoritmo com os valores de partículas, parâmetros e melhores posições locais e globais, a velocidade encontrada na equação anterior deve ser averiguada para certificar que está dentro dos valores máximos e mínimos pré-determinados no início do procedimento. Esses valores de V_{max} e V_{min} servem para limitar as velocidades das partículas. Após ser averiguada, verifica se

a velocidade da partícula foi mantida, então ela será multiplicada pelos números randômicos e caso ela tenha sido alterada irá ficar com esse último valor calculado.

Após calculada a velocidade, a nova função sigmoide deve ser utilizada. O resultado obtido será comparado para obtermos a nova posição da partícula. Assim $X_{i,d+1}$ sempre será um número inteiro, pois os valores de $X_{i,d+1}$ serão as coordenadas das chaves.

Essa nova coordenada encontrada servirá para o cálculo da nova velocidade, através das diferenças $(pB_{i,d} - X_{i,d})$ e $(gB_d - X_{i,d})$. A essa nova posição também será calculado a perda de potência pelo fluxo de carga. Caso essa posição seja melhor que a anterior, ela será armazenada como a melhor configuração, até a próxima geração.

H. Considerações

Após aplicado a metodologia, a cada ciclo será reconhecido uma configuração ótima, até que a melhor configuração de todas as gerações seja encontrada. Esses resultados serão melhores e melhorados, quando se adotar um número considerável de iterações e conjunto de partículas.

VIII. RESULTADOS

A seguir serão apresentados os resultados obtidos através das simulações realizadas utilizando a metodologia proposta, que foi escrita na linguagem de programação Matlab 8.0.3 (R2014a), baseado em Nguyen (2014), e todas as simulações foram feitas utilizando um processador Intel® Core i7 de 2,40 GHz e 8 GB de memória.

Os testes computacionais foram realizados utilizando-se um sistema de distribuição de 33 barras disponível na literatura. Esse sistema foi apresentado em GRASP (OLIVEIRA, 2011), colônia de formigas (PEREIRA, 2010) e algoritmo genético refinado (ZHU, 2002). Os dados do sistema de distribuição testado podem ser encontrados em Baran e Wu (1989), a potência base utilizada foi de 100 MVA, com tensão base de 12,66 kV.

O sistema de 33 barras é um sistema teste que possui 32 barras de carga e uma subestação com 37 ramos. As condições de carga total são iguais a 3.715 KW e 2.315 KVAR. Este sistema possui cinco ramos de interligação e inicialmente as chaves abertas são 33, 34, 35, 36 e 37 que estão representadas por linhas tracejadas na Figura 3, que por sua vez representa o sistema de 33 barras.




Figura 3. Sistema 33 barras (Fonte: Pereira, 2010)

Podem ser vistos na tabela abaixo, os resultados obtidos com a metodologia proposta (SPSO) para o sistema de 33

barras. Sendo os parâmetros $c1=c2=2$ e $n=20$ (partículas) com número de 300 iterações.

TABELA I – Resultados obtidos para sistema de 33 barras

Método	Configuração Inicial	Perda Inicial (kW)	Configuração Final	Perda Final (kW)	Redução (%)
SPSO	33 34 35 36 37	202,7	7 9 14 32 37	139,54	31,1
ACO	33 34 35 36 37	202,7	7 9 14 28 32	139,97	31,1
AG	33 34 35 36 37	202,7	7 9 14 32 33	139,54	31,1
GRASP	33 34 35 36 37	202,7	7 9 14 32 37	139,54	31,1

As chaves de interconexão abertas na configuração final e as perdas ativas desta configuração são compatíveis com as encontradas na literatura para o sistema de 33 barras, (OLIVEIRA, 2011), (PEREIRA, 2010) e (ZHU, 2002). O tempo computacional médio gasto pelo método proposto para este sistema foi de 87,33 segundos. A configuração dotada por Zhu (2002) apresenta uma disposição diferente, devido a uma mudança de referência na enumeração das chaves. No trabalho apresentado por Zhu (2002), o mesmo faz comparações com Shimohammadi et al. (1989), e o AG apresenta perda de 139,5 kW, enquanto que a metodologia de Shimohammadi et al. (1989) apresenta perda de 141,5 kW.

O método proposto convergiu para 139,54 kW de perda nas iterações 27, 32 e 34 nas três simulações realizadas como pode ser visto no gráfico abaixo.




Figura 4. Gráfico de Convergência

Na Figura abaixo são apresentadas as tensões da configuração inicial e final do sistema de 33 barras.




Figura 5. Perfil de Tensão para 33 barras

IX. CONCLUSÃO

Neste trabalho o problema de reconfiguração de sistemas

de distribuição de energia elétrica foi analisado utilizando a metaheurística de Otimização por Nuvem de Partículas, tendo como objetivo a diminuição das perdas ativas do sistema de distribuição. Uma das grandes vantagens de se utilizar o método Seletivo do PSO é sua forma simples e adequada de resolver o problema de Reconfiguração com uma pequena modificação do método PSO binário.

Essa metodologia foi testada no sistema de 33 barras encontrado na literatura especializada e através da análise comparativa realizada, pôde-se concluir alguns aspectos: o resultado encontrado pela SPSO foi o mesmo encontrado pelo AG e GRASP. Em comparação com o método colônia de formigas, SPSO encontrou uma configuração um pouco superior, com uma diferença de perdas em torno de 0,2%. O perfil de tensão apresentou uma melhora substancial, pois antes da reconfiguração o mesmo estava fora das especificações da ANEEL (2014) e após a reconfiguração o perfil encontrava-se dentro do desejado. Assim pode-se afirmar que a metodologia utilizada obteve bons resultados com eficiência e robustez para resolver o problema de reconfiguração de sistemas de distribuição de energia elétrica, para sistemas de pequeno porte.

X. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL. “Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST”. Brasília, revisado em 15 de Abril de 2015.
- [2] BARAN, M. E.; WU, F. F. “Network reconfiguration in distribution systems for loss reduction and load balancing.” IEEE Trans. Power Del., vol. 4, no. 2, pp. 1401–1407, April 1989.
- [3] BRANDINI, A. C. “Análise crítica de algoritmos de fluxo de carga usados em sistemas de distribuição radial”. 2000. 71 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia de Ilha Soteira, Universidade Estadual Paulista, 2000.
- [4] KHALIL T. M. AND GORPINICH A. V., “Selective Particle Swarm Optimization” International Journal of Multidisciplinary Sciences and Engineering (IJMSE), vol. 3, issue 4, pp. 1-4, April 2012.
- [5] KENNEDY, J.; EBERHART, R. C., “Particle Swarm Optimization”. Proceedings of IEEE International Conference on Neural Networks, Perth, Australia, 1995, pp. 1942-1948.
- [6] KENNEDY, J.; EBERHART, R. C., “A Discrete Binary Version of Particle Swarm Algorithm”. IEEE International Conference on Systems, Man and Cybernetics, IEEE Press, New York, 1997, pp. 4101-4108.
- [7] NGUYEN, P. D, S. (2014). “Network Reconfiguration by BPSO method”. Disponível em: <<http://www.mathworks.com/matlabcentral/fileexchange/45946-network-reconfiguration-by-bpso-method>>. Acesso em: 01 jun. 2014.
- [8] OLIVEIRA, M. B. C. “Reconfiguração de Alimentadores em Sistemas de Distribuição Usando a Metaheurística Grasp”. 2011. 86 f. Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica, Universidade Estadual Paulista “Julio De Mesquita Filho”, Ilha Solteira, 2011.
- [9] PEREIRA, F. S. “Reconfiguração ótima de sistemas de distribuição de energia elétrica baseado no comportamento de colônias de formigas”. 2010. 104 f. Dissertação (Doutorado em Engenharia Elétrica) - Escola de Engenharia de São Paulo, Universidade de São Paulo, São Carlos, 2010.
- [10] SHIMOHAMMADI, D.; HONG, H. W. “Reconfiguration of electric distribution for resistive line loss reduction”. IEEE Transactions on Power Delivery, New York, v. 4, n. 2, p. 1492-1498, 1989.
- [11] ZHU, J. Z. “Optimal reconfiguration of electrical distribution network using the refined genetic algorithm”. Electric Power Systems Research, Lausanne, v. 62, n. 1, p. 37- 42, 2002.