

ALOCÇÃO ÓTIMA DE PARQUES EÓLICOS EM REDES DE DISTRIBUIÇÃO UTILIZANDO UM ALGORITMO MICROGENÉTICO MULTI-OBJETIVO.

HELTON N. ALVES, CAMILA C. ARAUJO

*Departamento de Eletroeletrônica, Instituto Federal de Educação, Ciência e Tecnologia do Maranhão-IFMA
Av. Getúlio Vargas, 4, São Luís - MA, 65036-490
E-mails: helton@ifma.edu.br, araujo.camila10@gmail.com*

Abstract— This paper presents a multi-objective algorithm based on weighted sum method for the optimal allocation of wind turbines and other types of dispersed generation in power distribution networks. A microgenetic algorithm is used. The objective function considers the power and energy losses and voltage regulation. A compensation power flow method is used to consider the presence of dispersed generation. For the losses evaluation, the load duration curve segmented in three levels is adopted. The proposed method is tested on a 104-bus feeder and compared with a method based on a genetic algorithm. The results demonstrate the efficacy of the proposed method.

Keywords— Microgenetic algorithm, weighted sum method, wind turbine, power distribution system.

Resumo— Este trabalho apresenta um algoritmo multi-objetivo baseado na soma ponderada para a alocação ótima de aerogeradores e de outros tipos de geração distribuída em redes de distribuição de energia elétrica. Um algoritmo microgenético é utilizado. A função objetivo adotada representa as perdas de potência e de energia durante todo o horizonte de planejamento, bem como a regulação da tensão no último ano de planejamento. Para a avaliação das perdas, o algoritmo proposto faz uso de uma ferramenta de cálculo de fluxo de potência baseada na técnica da compensação iterativa, adaptada para a presença dos geradores distribuídos na rede. O cálculo das perdas de energia utiliza também a curva de duração de carga segmentada em três níveis. São realizados testes em um alimentador de 104 barras encontrado na literatura e seu desempenho computacional é comparado com um algoritmo genético. Os resultados obtidos evidenciam sua eficácia.

Palavras-chave— Algoritmo microgenético, soma ponderada, aero gerador, redes de distribuição.

1 Introdução

O sistema elétrico tem buscado se ajustar a uma demanda crescente de potência, garantindo a segurança na oferta e níveis satisfatórios de confiabilidade. Com o intuito de dar suporte ao sistema elétrico convencional e aumentar a sua confiabilidade, atualmente tem se utilizado a Geração Distribuída (GD). Entre as vantagens (Andrade, 2007) da alocação de GD está o aumento da oferta de energia, diminuição da sobrecarga, adequação dos níveis de tensão, redução de perdas e do número de interrupções quando a GD opera de forma ilhada. No entanto, a instalação de GD pode ter impactos negativos na rede elétrica relacionados principalmente a regulação de tensão e aos níveis de curto-circuito (Brown et al., 2001). A análise do sistema com a alocação de GDs, principalmente com fontes renováveis, tem sido estudado ao longo dos últimos anos. Vários tipos de GDs (pequenas centrais hidrelétricas, microgeradores térmicos e geradores movido a gás ou diesel) garantem em condições normais uma potência ativa constante durante o seu funcionamento. Diferentes destes, os aerogeradores fornecem uma potência ativa intermitente, sendo completamente estocástica devido à natureza intermitente da velocidade do vento.

A análise de confiabilidade na presença de GDs com potência constante e com potência intermitente tem sido estudada na literatura por vários autores. Em (Nara et al., 2001) é proposto um algoritmo baseado em Busca Tabu para alocação ótima de GDs com a finalidade de reduzir as perdas de potência da rede. Em (Huang et al., 2006) é feito um estudo de custo da confiabilidade com geradores eólicos mode-

lados com três estados de operação. Em (Grandromkar et al., 2005) é apresentado uma metodologia baseada em um método híbrido baseado em um algoritmo genético e busca tabu aplicada a alocação ótima de GDs em redes de distribuição.

Este trabalho propõe uma metodologia baseada em um algoritmo microgenético multi-objetivo adaptado para o problema de alocação ótima de GDs, considerando as particularidades de geração de energia dos parques eólicos. Os objetivos do algoritmo são de minimizar os custos das perdas de potência e de energia e regular a tensão da rede.

2 Formulação do Problema

2.1 Velocidades dos Ventos

A velocidade dos ventos possui um comportamento aleatório e muda frequentemente de valor. Conhecer a forma como essa velocidade se comporta é fundamental para alocação de usinas eólicas. As variações do vento podem ser definidas como variações diárias, sazonais, anuais e de curta duração. Para analisar o seu comportamento em um determinado espaço é necessário conhecer um grande número de variáveis que são obtidas através de um registro das velocidades dos ventos realizado por um longo tempo. No entanto, o que geralmente é feito é uso de modelos probabilísticos para reproduzir o comportamento dos ventos. A definição de probabilidade que melhor define o comportamento da velocidade dos ventos é a função de distribuição Weibull (Leite, 2005),

$$prob(v) = \frac{k}{c} \left(\frac{v}{c} \right)^{k-1} e^{-\left(\frac{v}{c} \right)^k} \quad (1)$$

Onde v é a velocidade para qual será calculada a probabilidade $prob$; c é o parâmetro de escala e k é o parâmetro de forma. O valor de k é inversamente proporcional à variação do vento, ou seja, quanto maior for k menor será a variação da velocidade do vento como pode ser observado na Fig.1. O parâmetro c diz respeito ao valor médio da velocidade e quanto maior for este valor maior será a velocidade média dos ventos. Os parâmetros c e k são calculados por :

$$k = \left(\frac{\sigma}{\bar{v}} \right)^{-1,086} \quad (2)$$

$$c = \frac{\bar{v}}{G \left(1 + \left(\frac{1}{k} \right) \right)} \quad (3)$$

Onde σ é o desvio padrão e $\bar{v}$ é a velocidade média. A função $G(y)$ é definida por:

$$G(y) = \int_0^{\infty} e^{-x} x^{y-1} dx \quad (4)$$




Figura 1. Influência de k na distribuição de Weibull

Para se calcular a estimativa da energia gerada de forma mais precisa leva-se em consideração o histograma de velocidade dos ventos ou a curva de distribuição de Weibull e a curva de potência da turbina eólica. O cálculo é realizado através do produto da quantidade de horas na qual o vento permanece em uma determinada velocidade pela potência gerada pela turbina, que pode ser retirada por meio da curva de potência. A curva de potência é obtida através dos parâmetros associados ao aerogerador que são: velocidade mínima (v_m), velocidade nominal (v_n) e velocidade de corte (v_c). A turbina produz potência entre os valores de v_m e v_c e fora desse intervalo a potência é nula. Para valores entre v_m e v_n a potência gerada é influenciada diretamente pelas velocidades dos ventos. Entre v_n e v_c a potência de saída será igual à potência nominal. Neste trabalho foi utilizada a curva de potência mostrada na Fig. 2 definida com base em dados contidos na Tabela 1.

Um aerogerador pode ser modelado a p estados operativos e isso é determinado de acordo com as velocidades do vento que tem maior probabilidade de ocorrer no local em que o aerogerador está instalado.




Figura 2. Curva de potência da turbina

Tabela 1. Velocidade do vento e potência do gerador eólico.

v (m/s)	P (kW)	v (m/s)	P (kW)	v (m/s)	P (kW)
1	0	11	1658	21	2500
2	0	12	1984	22	2500
3	0	13	2264	23	2500
4	15	14	2454	24	2500
5	120	15	2500	25	2500
6	248	16	2500	26	0
7	429	17	2500	27	0
8	662	18	2500	28	0
9	964	19	2500	29	0
10	1306	20	2500	30	0

2.2 Características da Carga

Em estudos que envolvem a representação da carga elétrica geralmente utiliza-se a curva de carga aproximada por uma função-escada de dois degraus correspondentes aos horários de pico e fora de pico. Melhor aproximação se consegue tomando-se mais degraus, embora isso implique maior esforço. Neste trabalho foram empregadas funções de três degraus. Assim, o cálculo dos custos das perdas de potência e de energia elétrica em um alimentador pode ser expresso do seguinte modo, considerando a curva de duração de carga segmentada em 3 níveis:

$$C(s) = \sum_{h=1}^a \sum_{j=1}^3 k_p \left(\sum_{i=1}^p P a_j prob(p) \right) (1+i_c)^{h-1} + \sum_{h=1}^a \sum_{j=1}^3 k_e \Delta t_j \left(\sum_{i=1}^p P a_j prob(p) \right) (1+i_c)^{h-1} \quad (5)$$

Onde $C(s)$ é a função custo; s é um conjunto de parâmetros que definem os pontos de instalação dos GDs; k_p é o custo da perda de potência em cada nível [\$/kW]; j é o nível de carga da mais leve até o pico; k_e é o custo da perda de energia em cada nível [\$/kWh]; a é o horizonte de planejamento [anos]; h é um ano qualquer dentro do horizonte de planejamento [$h=1...a$]; $P_j(s)$ são as perdas de potência na rede em cada nível j do primeiro ano [kW]; p é o número de estados operativos do aerogerador; $prob(p)$ é a probabilidade de ocorrência do estado operativo p ;

Δt_j é a duração anual de cada nível de carga [$j=1...3$], em horas.

2.3 Regulações de Tensão

O conceito de Qualidade da Energia Elétrica (QEE) vem sofrendo alterações em consequência do constate avanço tecnológico. Há alguns anos, a principal preocupação com a QEE concentrava-se na qualidade de serviço, ou seja, na duração e no número de interrupções da tensão. Atualmente, parâmetros como a amplitude e frequência da tensão, desequilíbrio de tensão e distorção harmônica, assumem elevada importância no contexto da QEE (Allen et al., 2005). Os fenômenos elétricos que afetam a QEE são subdivididos em transitórios, variações de tensão de curta duração, variações de tensão de longa duração, desequilíbrio de tensão, distorções na forma de onda, flutuação de tensão e variações da frequência do sistema. Em especial, nas variações de tensão de longa duração se tem o afundamento de tensão que é caracterizado por um decréscimo no valor eficaz da tensão a valores menores que 0,9 pu, considerando-se a frequência do sistema, e com período de duração maior que 1 minuto (Dugan, 1996). Os afundamentos de tensão são decorrentes principalmente do carregamento excessivo dos circuitos alimentadores, ou do excesso de reativo transportado pelos circuitos de distribuição.

O objetivo do algoritmo proposto é melhorar o perfil de tensão ao longo de todo o alimentador respeitando os limites de tensão que são definidos em PRODIST (Procedimentos de distribuição de energia elétrica no sistema elétrico nacional) módulo 8 (Agência Nacional de Energia Elétrica, 2016) e mostrados em

$$0.93|V_n| \leq |V_b| \leq 1.05|V_n| \quad (6)$$

Onde V_n é a tensão nominal e V_b é a tensão da barra.

Neste trabalho a função que trata sobre o perfil de tensão no alimentador é expressa da seguinte forma,

$$Perfil(s) = num_barras_viola(s) \quad (7)$$

Onde num_barras_viola é o número de barras do alimentador com os GDs alocados de acordo com s que violam os limites estabelecidos em (6).

2.4 Algoritmos Multi-objetivo

Formulações multi-objetivos são modelos mais realistas para muitos problemas complexos de otimização encontrados na engenharia. Em muitos problemas da vida real, existem normalmente vários objetivos conflitantes que precisam ser avaliados na tomada de decisões. Otimizar uma solução particular no que diz respeito a um único objetivo pode incorrer em resultados inaceitáveis em relação aos outros objetivos. Uma solução razoável para um problema multi-objetivo seria investigar um conjunto de soluções, cada uma das quais satisfazendo os objetivos a um nível aceitável, sem serem dominados por qualquer outra solução. Normalmente, não existe uma única solução ótima para este tipo de problema e é

necessário utilizar as preferências do gestor para diferenciar entre as soluções. Existem várias abordagens para a otimização de funções multi-objetivo (Deb, 2001). Neste trabalho é utilizado o método da soma ponderada, devido à sua simplicidade e sua característica de ser uma abordagem onde o gestor pode interferir, quando escolhe os pesos (fatores de ponderação). Atribuir pesos para cada critério utilizado irá refletir sua importância relativa para a decisão. O método da soma ponderada combina os pesos e pontuações para cada critério para derivar um valor global.

Neste trabalho, o método de solução adotado irá encontrar uma estratégia eficiente para alocação de um conjunto de GDs em uma rede de distribuição baseado em dois critérios: custos das perdas e perfil de tensão.

O algoritmo proposto utiliza como função multi-objetivo no qual cada objetivo é normalizado pelo seu valor máximo para uma determinada população:

$$FO(s) = w_1 \frac{Perfil(s)}{N_B} + w_2 \frac{C(s)}{C_{ORIG}} \quad (8)$$

Onde $C(s)$ é o custo das perdas de potência e energia com GDs instalados de acordo com s ; C_{ORIG} é o custo das perdas de potência e energia sem GDs instalados; $Perfil(s)$ é o número de barras do alimentador com os GDs alocados de acordo com s que violam (6); Este processo é feito a cada nova geração. N_B é o número de barras do alimentador; w_1 é o peso para o perfil de tensão e w_2 é o peso para custos. Os pesos são definidos por:

$$w_1 + w_2 = 1 \quad (9)$$

3 Algoritmo Proposto

3.1 Algoritmos Microgenéticos

Os algoritmos microgenéticos são originados dos algoritmos genéticos e muitas de suas características são semelhantes. A seguir são mostrados os principais conceitos desses algoritmos e suas diferenças.

Os algoritmos genéticos propostos por Holland em (Holland, 1976) e os algoritmos microgenéticos (AMGs) propostos por Krishakumar (Krishakumar, 1989), são inspirados na evolução das espécies, segundo a teoria de Darwin. Com base nos postulados dessa teoria, Holland desenvolveu algoritmos que tem como base a codificação genética e que busca simular o processo de evolução. O objetivo final do algoritmo é encontrar o indivíduo mais forte e mais adaptado ao ambiente em que se encontra através de cruzamentos e mutações em uma determinada população.

A desvantagem dos algoritmos genéticos é o elevado tempo de processamento (Delfanti et al, 2000). Isso se deve à sua concepção evolutiva, que é um processo aleatório e normalmente demorado.

Entretanto, meios de atenuar esse problema já foram propostos, tais como uma escolha mais apropriada de como codificar as soluções e a redução do espaço de busca por meio do conhecimento especialista. Outra forma utilizada é o algoritmo microgenético, cujo tempo de processamento é consideravelmente menor.

Um algoritmo genético ou microgenético básico compreende a criação aleatória da população inicial e um ciclo de três estágios :

- Avaliação de cada cromossomo;
- Seleção dos cromossomos para reprodução;
- Manipulação genética para criar a nova população.

Cada vez que esse ciclo se completa é dito que ocorreu uma geração. A seleção dos cromossomos para reprodução é efetuada por mecanismos aleatórios. Além disso, o critério de sobrevivência é baseado em uma função objetivo que avalia a adaptação de cada cromossomo da população as condições ambientais.

Nos algoritmos genéticos e microgenéticos inicialmente, um grupo de soluções possíveis é codificado aleatoriamente para formar a população inicial. Geralmente o tamanho da população não varia no decorrer das gerações. A cada geração são criados novos cromossomos a partir da população já existente e os componentes desta população podem ser substituídos pelos novos de acordo com a sua função aptidão e com a técnica de elitismo empregada. O tamanho da população e o número de vezes que ela é criada são os principais fatores que diferenciam os algoritmos genéticos e microgenéticos (Davis, 1991).

A maioria dos algoritmos genéticos produz resultados ruins quando as populações são pequenas, pois são processadas informações insuficientes sobre o problema e em decorrência a convergências prematuras para ótimos locais. Geralmente o tamanho da população varia de 30 a 300 indivíduos. Em contraste, os algoritmos microgenéticos exploram justamente a possibilidade de se trabalhar com pequenas populações (de 5 a 50 indivíduos normalmente) para reduzir o tempo de processamento. Do ponto de vista genético, sabe-se que reproduções frequentes dentro de uma pequena população podem favorecer a disseminação de doenças hereditárias raramente encontradas em grandes populações. Por outro lado, pequenas populações podem atuar como laboratórios naturais onde características genéticas desejáveis podem rapidamente emergir.

Nos algoritmos genéticos somente a população inicial é criada e as operações genéticas sobre ela é que vão garantir o surgimento de novos indivíduos. Logo, a diversidade genética está fortemente ligada à população inicial. Nos algoritmos microgenéticos cada vez que a população de tamanho n se torna homogênea, ou seja, quando a diferença entre os índices de aptidão de cada indivíduo da população for menor que uma tolerância pré-definida, o indivíduo mais bem adaptado migra para uma nova população, também criada aleatoriamente, de tamanho n .

1. Este mecanismo é utilizado para compensar a pequena diversidade genética devido ao tamanho da população, buscando evitar que o algoritmo convirja para um valor ótimo local. Dessa forma a diversidade genética é mantida e o algoritmo microgenético sempre terá a chance de encontrar o melhor indivíduo. Por outro lado, é necessária a adoção de uma estratégia de prevenção contra a perda de diversidade da população. Isso é feito utilizando o método do torneio sem reposição como forma de seleção para o cruzamento. Ele garante que todos os cromossomos poderão ser escolhidos para o torneio independente da sua aptidão, a qual só é levada em conta depois de sorteadas aleatoriamente duplas da população atual. Essa característica é muito importante nos algoritmos microgenéticos visto que quando ocorre a migração do melhor indivíduo de uma população para outra, a tendência é que esse indivíduo, já evoluído, tenha um grau de aptidão bem superior aos outros cromossomos criados aleatoriamente. O método do torneio garante que mesmo assim, todos os cromossomos tenham chances de participar da reprodução.

3.2 Solução

O algoritmo baseado em AMGs desenvolvido neste trabalho compreende os seguintes passos:

1. Adotar (8) como função de aptidão (fitness);
2. Gerar aleatoriamente uma população inicial com n indivíduos e ir para o passo 4;
3. Gerar aleatoriamente uma população de tamanho $n-1$ e acrescentar a ela o cromossomo de maior fitness da geração anterior;
4. Determinar o índice de aptidão de cada indivíduo;
5. Escolher m cromossomos da população atual através do método do torneio. Com esse subgrupo é realizado o cruzamento de pares de cromossomos;
6. Determinar índice de aptidão dos novos cromossomos;
7. Escolher uma nova população de tamanho n entre a população atual e os novos cromossomos considerando os cromossomos mais adaptados.
8. Repetir os passos 5 a 7 por g gerações.
9. Manter o melhor cromossomo e descartar os outros;
10. Repetir os passos de 3 a 9 até que o mesmo indivíduo seja o melhor por h migrações consecutivas.

Os números m , g e h são pré-estabelecidos. O método do torneio adotado funciona da seguinte forma: um subgrupo da população é gerado de forma aleatória e o cromossomo com maior grau de aptidão é escolhido para o cruzamento. Neste trabalho o conjunto de barras G_s do alimentador que pode ser usado para alocação é definido pelo gestor. A estrutura cromossômica utilizada é baseada em três informações: N_{GD} que define o número de GDs que será alocado, T_{GD} que define qual tipo de GD é alocado e N_{BUS} que define a barra onde o GD está alo-

cado. A codificação apresenta um vetor composto por N_{GD} posições de números inteiros. O tipo de GD, as barras que compõem o conjunto Gs são representadas no cromossomo por sua posição dentro do conjunto. Essa estrutura está ilustrada na parte de cima da Fig. 3, que mostra como exemplo um alimentador de 50 barras, onde 15 barras foram escolhidas para participarem da solução e 3 GDs foram alocadas. A posição do vetor indica o tipo do GD. Dessa forma, cada uma das 3 posições do cromossomo irá assumir um valor inteiro entre 1 e 15 sem que ocorra repetições. Como pode ser observado no exemplo mostrado na Fig. 3, Pai1 determina a alocação de GDs tipo 1 na barra 22, tipo 2 na barra 12 e tipo 3 na barra 39 do conjunto Gs. Pai2 determina a alocação de GDs tipo 1 na barra 45, tipo 2 na barra 39 e tipo 3 na barra 18 do conjunto Gs.

Os genes dos pais herdados pelos filhos são selecionados de forma aleatória conforme esquematizado na Fig. 4. Os pais representam um conjunto de GDs que ao serem escolhidos para o cruzamento darão origem a um novo conjunto onde se escolhe de forma aleatória N_{GD} barras para gerar o filho. Dessa forma, as barras escolhidas para o filho serão todas diferentes. Essa forma de codificação e cruzamento adotada garante que a solução encontrada pelo AMG possua o número de GDs que devem ser instaladas.

$G_s = \{ 7 \ 12 \ 18 \ 22 \ 25 \ 29 \ 30 \ 33 \ 35 \ 39 \ 40 \ 42 \ 45 \ 47 \ 50 \}$




Figura 3. Estrutura cromossômica proposta.




Figura 4. Mecanismo de reprodução adotados

4 Resultados

O algoritmo proposto é aplicado a um alimentador primário de 104 barras e tensão de 12,66 kV cujos dados de linha são encontrados em (Alves et al., 2005). Foi considerado um horizonte de planejamento de 5 anos, com um taxa anual de crescimento de 3%. Foi adotado um fator de potência único de 0,90.

No algoritmo proposto foi adotada uma taxa de cruzamento de 100% com uma população de 12 cromossomos que realizam 30 gerações antes de cada

migração. O número de migrações que o mesmo indivíduo pode realizar são 10 migrações. No AG foi adotada uma taxa de cruzamento de 60%, uma taxa de mutação de 1% com uma população de 70 cromossomos que realizam 100 gerações. Todas as barras foram consideradas possíveis candidatas de alocação do GD ($G_s=103$).

Tabela 2. Níveis da carga, operação, custo de perda de potência e energia aplicadas no alimentador de 104 barras.

	Leve	Interm.	Pico
Nível da carga	0.2	0.4	0.6
Operação (h)	2190	5475	1095
Custo perda de potência (\$/kW)	8	8	25
Custo perda de energia (\$/kWh)	0.1	0.1	0.3

Neste trabalho foram definidas duas configurações de alocação de GDs: na configuração 1 foram utilizados dois GDPCs e na configuração 2 foi utilizado um GD de potência ativa constante (GDPC) e um aerogerador. Os dados dos GDs são mostrados na Tabela 3. GDPC 1 tem controle PV com a tensão de 0,98 pu especificada na barra de alocação, GDPC 2 tem controle PQ (mesma potência ativa do aerogerador) e o aerogerador tem fator de potência unitário. O aerogerador utilizado tem os dados mostrados na Tabela 4 com $v_m=3$, $v_n=15$, $v_c=25$, $\bar{v}=6,07$ e $\sigma=1.89$. Neste trabalho são utilizados 13 estados de velocidade dos ventos.

Tabela 3. Dados dos GDs a serem alocados.

GD	PG (kW)	PG_{max}	PG_{min}	V_{ref}
GDPC 1	500	310	-310	0,98
GDPC2	600	200	200	
Aerogerador	600			

Tabela 4. Dados do aerogerador.

Estado	v (m/s)	P (kW)	Prob (%)
1	0-3	0	12,4
2	4	15	10,8
3	5	120	12,4
4	6	248	12,7
5	7	429	12
6	8	662	10,5
7	9	964	8,6
8	10	1306	6,7
9	11	1658	4,9
10	12	1984	3,4
11	13	2264	2,2
12	14	2454	1,5
13	15-25	2500	1,9


Os resultados obtidos com o algoritmo proposto e com o algoritmo genético foram os mesmos (tabela 5), a diferença entre eles foi o tempo de processamento. O algoritmo microgenético se mostrou mais eficiente no item tempo de processamento,

obtendo os mesmos resultados em comparação com o AG, mas com um tempo de processamento menor. Na Fig. 5 é mostrado o perfil de tensão do alimentador sem GDs e com GDs alocados de acordo com as configurações 1 e 2, no nível de carga de pico no último ano do planejamento. A configuração 2 mostra uma perda bem maior que a configuração 1 devido a intermitência de geração do aerogerador.

Tabela 5 - Alocação Ótima para o alimentador de 104 barras

Alg.	Conf.	Execução (min)	Barra com GD	Tipo de GD	Custo (10 ³ \$)
AMG	1	2,55	2989 807	GDPC1 GDPC2	530,3
AG	1	6,15	2989 807	GDPC1 GDPC2	530,3
AMG	2	18,94	807 813	GDPC1 AERO	926,9
AG	2	33,15	807 813	GDPC1 AERO	926,9

Figura 5. Perfil de tensão no último ano de planejamento.



5 Conclusões

Neste trabalho foi apresentada uma metodologia multi-objetivo baseada em um algoritmo microgenético para a alocação ótima de unidades de geração distribuída em redes de distribuição considerando aerogeradores. As funções objetivo utilizadas são as perdas de potência e de energia e o perfil de tensão do alimentador. O método considerou a natureza intermitente de geração dos aerogeradores no processo de cálculo das perdas e do perfil de tensão. O método também considerou na formulação do problema dois parâmetros essenciais para a análise das redes, são eles: a característica da demanda da rede, representada pela curva de duração de carga; e o efeito do crescimento da carga durante um horizonte de planejamento. O algoritmo proposto apresentou excelentes resultados além de demonstrar uma boa eficiência computacional quando comparado a um AG.

Agradecimentos

Os autores agradecem ao IFMA, FAPEMA e ao CNPq pelo apoio ao desenvolvimento deste projeto.

Referências Bibliográficas

- Allen, D. E., Apostoly, A. and Kreiss, D (2005). Automated analysis of power system events, *IEEE Power & Energy magazine*, New York, v.3, n.5, pp. 48-55.
- Alves, H. N., Souza, B. A. e Ferreira, H. A (2005). Banks of Automatic Capacitors in Electrical Distribution Systems: a Hybrid Algorithm of Control. *Revista Controle & Automação*, Vol. 16 No. 1, p. 93-99.
- Andrade, W (2007). Avaliação da confiabilidade de sistemas de distribuição e sub-transmissão considerando geração distribuída, Tese de doutorado, Dept. Eng. Elétrica., UFRJ.
- ANEEL (2016). Procedimentos de distribuição de energia elétrica no sistema elétrico nacional módulo 8, de 01 de janeiro de 2016. Disponível em: < <http://www.aneel.gov.br>>. Acesso em: 25/01/2016.
- Brown, R. E and Freeman, L. A (2001). Analyzing the reliability impact of distributed generation, *Proceedings of the IEEE Summer Meeting*, pp. 1013-1018.
- Davis, L. D. Handbook of genetic algorithms. [S.l.]: Van Nostrand Reinhold, 1991.
- Deb, K (2001). Multi-objective optimization using evolutionary algorithms. Chichester, UK: John Wiley & Sons.
- Delfanti, M., Granelli, P. G., Marannino, P., Montagna, M. (2000). Optimal Capacitor Placement Using Deterministic and Genetic Algorithms. *IEEE Transactions on Power Systems*, EUA, 15(3):1041-1046.
- Dugan, R. C., Mc Granaghan, M. F. and Beaty, H. W (1996). *Electrical power systems quality*, New York: McGraw-Hill.
- Gandomkar, M., Vakilian, M. and Ehsan, M (2005). A genetic-based tabu search algorithm for optimal DG allocation in distribution networks, *Electric Power Components and Systems*, Vol. 33, Iss. 12.
- Holland, J. H (1976). *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor.
- Huang, H. S. and CHIANG, C. T (2006). Reliability worth assessment of distribution system with large wind farm considering wake effect, *Power India Conference- IEEE*.l
- Krishakumar, K (1989). Micro-Genetic Algorithms for Stationary and non Stationary Function Optimization, *SPIE Intelligent Control And Adaptive System*, 1196, Philadelphia, pp. 289-296.
- Leite, A (2005). Modelagem de fazendas eólicas pra estudo de confiabilidade, Tese de doutorado, Dept. Eng. Elétrica., UFRJ.
- Nara, K., Hayashi, Y.; Ikeda, K. and Ashizawa, T (2001). Application of tabu search to optimal placement of distributed generators, in *Proc. 2001 IEEE Power Engineering Society Winter Meeting*, vol. 2 pp. 918-923.