

Análise de Sensibilidade Associada com Enxame de Partículas para Alocação de Geração Distribuída**Sensitivity Analysis Associated with Particle Swarm Optimization for Distributed Generation Allocation**

DOI:10.34117/bjdv6n8-688

Recebimento dos originais:08/07/2020

Aceitação para publicação:31/08/2020

Lindenberg Isac

Doutorando em Energia pela Universidade Federal do ABC

Endereço:Avenida dos Estados, 5001 – CEP: 09210-580 – Santo André/SP – Brasil

E-mail:lindenberg.isac@ufabc.edu.br

Edmarcio Antonio Belati

Doutor em Engenharia Elétrica pela USP – São Carlos (2003)

Endereço:Avenida dos Estados, 5001 – CEP: 09210-580 – Santo André/SP – Brasil

E-mail:edmarcio.belati@ufabc.edu.br

Diego José da Silva

Mestrando em Engenharia Elétrica pela Universidade Federal do ABC

Endereço:Avenida dos Estados, 5001 – CEP: 09210-580 – Santo André/SP – Brasil

E-mail: d.jose@ufabc.edu.br

RESUMO

Este artigo apresenta uma metodologia para alocação de geração distribuída (GD) usando Otimização por Enxame de Partículas (PSO - *Particle Swarm Optimization*) e análise de sensibilidade (AS). O local para alocação das GD é determinado pelo PSO e a função é avaliada utilizando AS. A AS dispensa o uso do Fluxo de Carga (FC) para avaliar a rede, em cada proposta de alocação fornecida pelo PSO, tornando o algoritmo rápido. A AS empregada é de segunda ordem e apresenta ótima aproximação quando comparada com a solução do FC. Simulações computacionais foram realizadas em dois sistemas elétricos de distribuição com 34 e 70 barras, alocando dois geradores em cada sistema. Os resultados foram comparados com uma técnica de busca exaustiva (BE), atestando a exatidão das soluções, bem como a redução no tempo computacional. Foram obtidas reduções de até 83,0% nas perdas de potência ativa e consequente aumento no perfil de tensão do sistema elétrico, bem como diminuição de até 95,3% no tempo computacional, quando comparado com busca exaustiva.

Palavras-Chave: Geração distribuída, Sistema elétrico de distribuição, Otimização por enxame de partículas, Análise de sensibilidade.

ABSTRACT

This paper presents a new methodology for allocation of distribution generation (DG) using Particle Swarm Optimization (PSO) with Sensitivity Analysis (SA). The SA is used to evaluate the candidate

solutions directly instead of using an Optimal Power Flow (FPO), which is an iterative method. The proposed methodology was applied on two systems, containing 34 and 70 buses. For each system was allocated two DG's units. The algorithm presented was compared with an implemented exhaustive search technique and the gain in computational processing time was showed. As a main result, it was obtained the best locations for placement of DG's units considering the minimization of active power losses with a decrease up to 83.0% and consequently an improvement in the voltage profile of the system. It was noted a decrease in time spent on computer simulation of up to 95.3% when compared with exhaustive search.

Keywords: Distributed Generation, Electrical distribution system, Particle swarm optimization, Sensitivity Analysis.

1 INTRODUÇÃO

A demanda por energia elétrica vem crescendo rapidamente e as formas atuais de geração de eletricidade não serão capazes de suprir futuramente este consumo. A conversão, em energia elétrica, da energia proveniente de fontes alternativas é uma das possibilidades para se complementar a energia hidroelétrica no Brasil, que é predominante na matriz energética (EPE, 2019). Preocupações ambientais e econômicas têm limitado a construção de novas usinas elétricas. Nesse sentido, a Geração Distribuída (GD) é uma boa alternativa para atender novas demandas por energia elétrica, como também, atender a aspectos técnicos e econômicos (Furlan *et al.*, 2018).

Uma matriz energética fortemente dependente de recursos hídricos precisa ser planejada de forma a considerar uma eventual necessidade de fontes complementares. No caso do Brasil (Schultz *et al.*, 2005) mostra-se que o problema de escassez de chuvas pode ser reduzido com a implantação de parques eólicos, pois o ciclo de chuvas e períodos de altos ventos é complementar. Neste contexto a energia solar, embora intermitente, também pode contribuir para a complementação da matriz energética. Tanto a água das chuvas como o vento e a energia solar são recursos naturais que podem ser usados para a conversão de sua energia em eletricidade, de forma não poluente. Entretanto o fornecimento de tais recursos não é controlável pelo homem.

O problema de encontrar a melhor localização e potência das unidades geradoras é referido como problema de alocação de GD. O local para instalação da GD depende dos objetivos, podendo ser um aprimoramento da parte técnica, econômica ou ambiental (Kumar *et al.*, 2014). A alocação de GD tem como uma das finalidades a redução das perdas técnicas decorrentes do efeito joule no sistema elétrico de distribuição. A GD é alocada com uma quantidade fixa de potência ativa ou com degraus de potência ativa para encontrar o melhor ponto de conexão.

Khoa (2004) apresentou uma técnica baseada em método de pontos interiores que determina quais são os geradores distribuídos que devem ser despachados, visando a reduzir as perdas ôhmicas.

Gandomkar (2005) apresentou uma solução exata, por meio de busca exaustiva, variando a potência dos geradores. O local e potência ótimos da GD foram encontrados, contudo o tempo computacional para solucionar este problema mostrou-se elevado.

Acharya (2006) utilizou Fluxo de Potência Ótimo (FPO) para encontrar o local ótimo de instalação da GD e minimizar as perdas dos sistemas elétricos de distribuição. Outro trabalho (Kazemi, 2009) de alocação de GD foi apresentado com a finalidade de aprimorar os níveis de tensão do sistema IEEE de 34 barras. Foi apresentada em 2010 a alocação de GD (El-Ela, 2010) para solucionar o problema de minimização das perdas por meio de Algoritmo Genético (AG) e Programação Linear (PL). Utilizando AG e PL conseguiu-se, além de encontrar o local, também determinar a potência da GD, otimizando assim o sistema elétrico empregado nas simulações.

Outra metodologia (Prado, 2013) foi apresentada para encontrar o melhor ponto de conexão da GD onde as perdas ôhmicas seriam minimizadas. A metodologia proposta consistiu na utilização de AG combinado com a técnica de fluxo de carga (FC) específico para sistemas de distribuição (*Backward-Forward-Sweep*). Esta metodologia foi testada em sistemas de 10, 34 e 70 barras.

Bouktir (2015) apresentou uma técnica de alocação de GD por meio de Otimização por Enxame de Partículas (*Particle Swarm Optimization – PSO*) em um sistema de 33 barras, que conseguiu reduzir a perda ôhmica em 69,5% no pior caso e 85,8% no melhor caso, porém sem mencionar o tempo computacional gasto.

O trabalho feito por Rosa et al. (2016) apresentou uma metodologia para alocar GD e reduzir as perdas. Nesta metodologia, inicialmente as barras são classificadas utilizando ITL (*Incremental Transmission Losses*), que ordena as barras candidatas à alocação. Em seguida, a técnica de Análise de Sensibilidade (AS) é utilizada para verificar o comportamento do sistema quando a potência inserida sofre variações.

Sahib et al. (2017) usaram a técnica PSO para alocar GD no sistema de 37 barras IEEE, resultando em alocação de 16 geradores no 1º cenário de testes e 9 geradores no 2º e no 3º caso. Isto reduziu, respectivamente, a perda ôhmica em 49,3%, 47,9% e 21,1%, mas sem considerar o tempo computacional gasto na otimização e a viabilidade econômica na alocação de 9 ou 16 geradores.

Ali et al. (2017) propuseram uma nova meta-heurística ALO (*Ant Lion Optimizer*) bio-inspirada em população de *ant lions* para alocação e dimensionamento ótimo de GD. Os testes foram realizados em sistemas de 33 e 69 barras. Inicialmente foi feita uma análise de sensibilidade de perdas para detectar as barras candidatas à alocação. Logo após, o ALO foi utilizado para encontrar o local e o tamanho dos GD apresentando excelentes reduções de perdas ativas da ordem de 60% e melhorias significativas no perfil de tensão.

Coelho et al., (2018) desenvolveram uma metodologia de otimização baseada na mobilização militar WO (*War Optimization*), que foi aplicada em um sistema de 69 barras e em um sistema real brasileiro de 476 barras. A função objetivo foi modelada para minimizar as perdas ativas obedecendo às restrições operacionais da rede. Como resultado, as soluções quando comparadas a trabalhos similares apresentaram menor dispersão de dados, mesmo se tratando de um método probabilístico aproximado.

Recentemente alguns estudos têm considerado a combinação de diferentes técnicas aplicadas ao problema de alocação de GD para melhorar a performance dos algoritmos, tanto em precisão quanto em tempo computacional gasto. Como exemplo, em Farh et al. (2020), os autores apresentaram o método CSA-PSO, junção do algoritmo do corvo (CSA – *Crow Search Algorithm*) com PSO modificado, objetivando encontrar o local, o dimensionamento e a quantidade de GD necessárias em um sistema de 30 barras. A função objetivo foi modelada para minimizar o custo total e perdas nas linhas.

A contribuição deste método CSA-PSO consistiu em dividir o problema entre as duas técnicas, onde o CSA é utilizado para dimensionar os GD e o PSO modificado para indicar o local e calcular o fluxo de potência ótimo. Os resultados foram comparados com PSO e PSO-GSA (*Gravitational Search Algorithm*), apresentando resultados competitivos com reduções de custos de energia e perdas ativas.

Suresh e Edward (2020) associaram o algoritmo do gafanhoto (GOA - *Grasshopper Optimization Algorithm*) com o algoritmo do cuco (CS – *Cuckoo Search*) para minimização das perdas ativas. A combinação das duas técnicas melhorou a convergência do algoritmo. Foram realizadas simulações nos sistemas de 33 e 69 barras e resultados comparados com GA, PSO e GA-PSO, e os resultados foram melhores em redução das perdas técnicas e tempo computacional.

Seguindo esta linha em José et al. (2020), os autores apresentaram o método híbrido FPA-BE a combinação do algoritmo de Polinização de Flores (FPA) com algoritmo de busca exaustiva (BE) para alocação e dimensionamento de banco de capacitores. Os resultados, apontaram redução de perdas ativas e melhoria nos níveis de tensão na rede de 85 barras quando comparados a trabalhos correlatos.

Em muitos trabalhos versando sobre alocação de GD não se realizam estudos econômicos quanto à viabilidade da instalação de geradores, desconsiderando o gasto com o próprio equipamento. O custo de manutenção também é desprezado em muitos casos. Nesse sentido, propõe-se no presente trabalho alocar somente duas GD para manter a viabilidade econômica na aplicação prática da técnica de alocação. Adicionalmente, com dois geradores e utilizando a

combinação das técnicas de PSO e AS de segunda ordem, consegue-se reduzir o tempo computacional gasto em relação às técnicas anteriormente apresentadas nesta seção, de modo a apresentar uma proposta robusta e rápida para alocação e dimensionamento da GD. Foi desenvolvido um algoritmo de Busca Exaustiva (BE) usando a AS apenas com a finalidade de comparar o custo computacional, podendo assim validar a técnica proposta.

A contribuição do trabalho está na utilização de PSO com AS de segunda ordem para encontrar o melhor ponto para conexão de GD, visando à redução das perdas de potência ativa e melhoria no perfil de tensão da rede, de forma ágil e econômica. O diferencial em utilizar AS é que a solução é obtida de forma direta, ao contrário do FC que é um método iterativo, proporcionando ganho de tempo em processamento.

O trabalho está dividido da seguinte forma: na seção Introdução, a técnica de geração distribuída é apresentada, bem como uma revisão sucinta em trabalhos correlatos, mostrando a fronteira do conhecimento no tema em estudo. Na seção de Metodologia são apresentados o PSO utilizado, bem como a técnica AS. Na seção de Resultados são expostos os valores obtidos nas simulações computacionais e, por fim, a seção de Conclusão decorrente do presente trabalho.

2 METODOLOGIA

2.1 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

PSO é uma técnica meta-heurística utilizada para otimização baseada no comportamento do cardume de peixes e bando de pássaros (Kennedy, 1995). O PSO resolve o problema inicialmente criando uma população de soluções candidatas onde se deve otimizar uma função objetivo. Essa população inicial é formada por partículas que se movem em torno do espaço de pesquisa. A velocidade de uma partícula i , na iteração t , é dada pelas equações (1) e (2):

$$F_i^{t+1} = \omega F_i^t + c_1 r_1 \cdot (p_i - X_i^t) + c_2 r_2 \cdot (p_g - X_i^t) \quad (1)$$

$$X_i^{t+1} = X_i^t + F_i^{t+1} \quad (2)$$

Onde:

ω – coeficiente de inércia;

F_i^t – velocidade da partícula i na iteração t ;

r_1, r_2 – vetores aleatórios;

c_1, c_2 – constantes de aceleração referentes ao melhor individual e global, respectivamente;

p_i – melhor posição conhecida pela partícula (experiência individual);

p_g – melhor posição conhecida pelo enxame (experiência coletiva);

X_i^t – corresponde ao vetor da posição da partícula i da iteração t .

A equação (1) possui todos os termos que são utilizados para retratar o comportamento do enxame de partículas. O algoritmo de PSO é utilizado em várias áreas da ciência em sua maioria para solucionar problemas de otimização (Yang, 2010). Neste trabalho, o PSO será utilizado junto com a técnica de AS a fim de tornar o algoritmo mais rápido, sendo identificado doravante como PSO-AS.

2.2 ANÁLISE DE SENSIBILIDADE

A AS empregada neste trabalho é de segunda ordem, e é baseada na modelagem de um FPO.

O FPO é uma técnica de otimização de complexidade elevada, cujo intuito é melhorar as condições de operação do sistema elétrico. Para diminuir tal complexidade, as variáveis do sistema são consideradas estáticas, isto é, seus valores não se alteram em função do tempo. Ainda assim, dependendo das dimensões do sistema, a sua otimização continua sendo difícil, demandando o emprego de heurísticas que conduzam à localização de melhores soluções.

Tipicamente, o FPO é composto por três partes: função objetivo, variáveis e restrições. Como é uma técnica de otimização, sua função objetivo pode ser do tipo para maximizar ou minimizar variáveis de um problema. As variáveis representam as decisões que podem afetar o valor da função objetivo e as restrições representam os conjuntos das equações e inequações, as quais as variáveis devem satisfazer. A equação (3) representa a modelagem matemática correspondente ao problema de FPO utilizado neste trabalho.

$$\begin{aligned} \min f(x) \\ \text{s. a. } g_i(x) = 0 \end{aligned} \quad (3)$$

Onde:

$f(x)$: função objetivo que representa o desempenho do sistema;

$g_i(x) \in \mathcal{R}^n$: vetor das equações do fluxo de potência;

$x(\theta, V) \in \mathcal{R}^n$: vetor das variáveis de estado.

A função objetivo representa as perdas do sistema, as variáveis de estado representam o ângulo de defasagem (θ) e a tensão (V) nas barras do sistema. As restrições referentes à igualdade $g(x) = 0$ representam as equações de balanço de potência nas barras da rede.

A técnica AS utilizada neste trabalho foi apresentada pela primeira vez por Fiacco (1976) e é usada para estimar rapidamente soluções de forma simples, quando outras técnicas não obtêm resposta para o problema. A AS é de grande importância nos estudos de planejamento da operação dos sistemas de potência, pois ela ajuda no entendimento da relação causa-efeito entre os parâmetros do sistema. Na área de programação matemática, a AS é utilizada para obter condições ótimas, convergência de algoritmos, estimar soluções onde os parâmetros de entrada são alterados, dentre outras aplicações.

A técnica AS desenvolvida no presente trabalho é apresentada nesta seção, considerando-se perturbações nas restrições de igualdade que acontecem quando há uma alteração nestas restrições, no caso uma injeção de potência ativa provocada pela GD. A modelagem matemática da técnica é apresentada a seguir.

Na equação (3) são introduzidas perturbações ε_i , que correspondem à adição das potências ativas relacionadas as GD nas restrições de igualdade, conforme a equação (4):

$$\begin{aligned} \min f(x) \\ \text{s. a. } g_i(x) + \varepsilon_i = 0, \quad i = 1, \dots, m \end{aligned} \quad (4)$$

Ao problema apresentado pela equação (4), associa-se a seguinte função Lagrangiana, obtendo a equação (5):

$$L(x, \lambda, \varepsilon) = f(x) + \sum_{i=1}^m \lambda_i [g_i(x) + \varepsilon_i] \quad (5)$$

Para aplicar a técnica de AS, é preciso ter uma solução inicial (*) do sistema sem perturbação (x^*, λ^*) , ou seja, a solução para o problema (5) com $\varepsilon = 0$ (caso sem adição das GD), em que podemos associar os multiplicadores de Lagrange das igualdades, representados por λ , como mostrado na equação (5). Na técnica de AS consideram-se o gradiente da função Lagrangiana, as condições de folgas complementares e as restrições de igualdade perturbadas, em que λ é irrestrito.

$$\begin{cases} \nabla_x L(x, \lambda, \varepsilon) = 0 \\ g_i(x) = 0 \end{cases} \quad (6)$$

As raízes do sistema não linear da equação (6) são determinadas linearizando-se o sistema no ponto (x^*, λ^*) , em que $\varepsilon_i = 0$, o que resulta no seguinte sistema linear:

$$\begin{cases} \nabla_{xx}^2 L(x^*, \lambda^*) \Delta x + \nabla_x g_i(x^*) \Delta \lambda = 0 \\ \nabla_x g_i(x^*) \Delta x = -\varepsilon_i \end{cases} \quad (7)$$

Na forma matricial, o sistema de equações (7) é dado por:

$$\begin{bmatrix} \nabla^2 L^* & G^* \\ (G^*)^T & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ \Delta \lambda \end{bmatrix} = - \begin{bmatrix} 0 \\ E \end{bmatrix} \quad (8)$$

Onde $E = [\varepsilon_1, \dots, \varepsilon_m]^T$ é o vetor perturbação. O sistema de equações (8) pode ser organizado como:

$$\begin{bmatrix} \Delta x \\ \Delta \lambda \end{bmatrix} = - \begin{bmatrix} \nabla^2 L^* & G^* \\ (G^*)^T & 0 \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ E \end{bmatrix} \quad (9)$$

Após realizada uma perturbação, o novo estado do sistema pode ser obtido mediante a equação (10). Por meio da equação (11) pode ser atualizado o valor dos multiplicadores de Lagrange λ .

$$x(\varepsilon) = \Delta x + x^* \quad (10)$$

$$\lambda(\varepsilon) = \Delta \lambda + \lambda^* \quad (11)$$

A matriz contida no sistema (8) é usada para obter as relações de sensibilidade das restrições de igualdade com respeito à função objetivo (perdas de potência ativa). Com o sistema (9) de matrizes, uma resposta pode ser obtida com pouco esforço computacional, após mudanças no vetor perturbação E .

3 RESULTADOS

As simulações computacionais foram realizadas com software MATLAB® e utilizando um computador Inspiron DELL 5000, processador Intel® Core™ i7-2410M CPU @ 2.40 GHz, 8 GB de memória RAM, sistema operacional Windows 10 Home - 64 bits. A metodologia proposta PSO-AS foi aplicada em dois sistemas de distribuição, de 34 e 70 barras, sendo ambos comparados com a técnica BE empregando AS para solução. Os dois sistemas de distribuição podem ser encontrados, respectivamente, nas referências Chis (1997) e Prado (2013).

3.1 ALOCAÇÃO DE GERAÇÃO DISTRIBUÍDA - REDUÇÃO DE PERDAS

Para a locação da GD foi utilizado o método BE, no qual foram alocadas duas fontes de geração fixa de 1 MW, cada uma, a fim de determinar o melhor ponto de alocação que reduz as perdas dos sistemas testados. Essa simulação foi realizada para os sistemas de 34 e 70 barras. A tabela 1 apresenta os resultados referentes às perdas ativas dos sistemas testados e os melhores locais para realizar a alocação da GD.


Tabela I- Comparação das perdas ativas empregando modelos PSO-AS E BE

Sistema	Perdas (MW)		Perdas (MW)	Barras
	PSO-AS	BE	Sem Alocar	
34 Barras	0,0568	0,0570	0,2223	10 e 25
70 Barras	0,0383	0,0385	0,2250	63 e 64

Fonte: os autores.

Ao alocar a GD de 1MW nas barras 10 e 25 houve uma otimização, causando uma redução de aproximadamente 74,4% das perdas ativas do sistema de 34 barras, o que implicou na melhoria dos níveis de tensão nas barras. Tanto na técnica BE como utilizando PSO-AS, os melhores pontos de alocação foram os mesmos. O diagrama unifilar do sistema e o local encontrado para a alocação da GD são apresentados na figura 1.

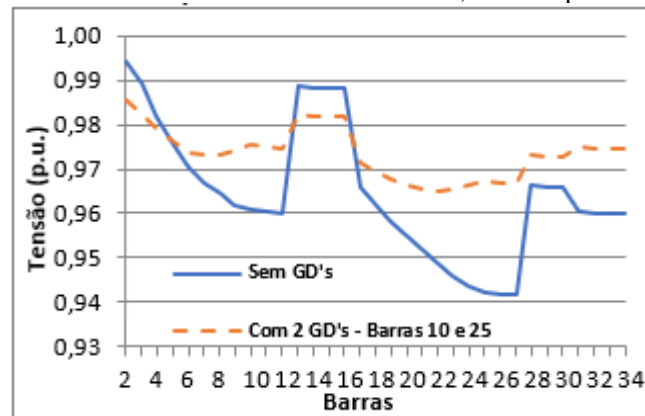
Figura 1 - Sistema de 34 Barras com Alocação nas Barras 10 e 25.



Fonte: os autores.

A figura 2 apresenta o resultado dos níveis de tensão ao alocar a GD nas barras 10 e 25, comparando com os níveis de tensão sem alocar a GD, ou seja, anteriores à otimização. Com a inserção da GD houve uma redução das perdas ativas e ainda uma melhoria nos níveis de tensão, com tensão mínima de 0,965 (p.u.).

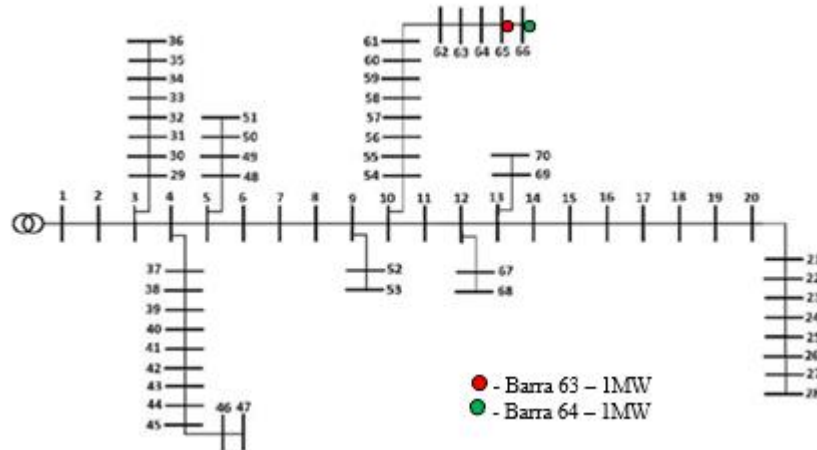
Figura 2 - comparação dos níveis de tensão no sistema de 34 barras, antes e após a otimização por meio de GD.



Fonte: os autores.

Ao realizarmos a mesma alocação para o sistema de 70 barras, ocorreu uma redução de aproximadamente 83,0% nas perdas ativas. O melhor ponto de conexão para a redução das perdas ativas, tanto usando a técnica de PSO-AS como BE, foram as barras 63 e 64. O diagrama unifilar do sistema de distribuição de 70 barras é apresentado na figura 3.

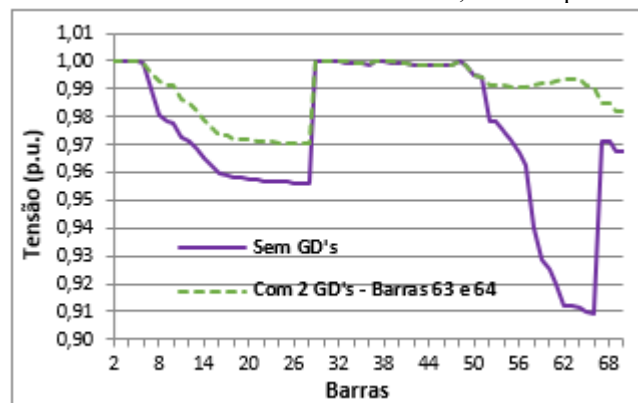
Figura 3 - Sistema de 70 Barras com alocação nas Barras 63 e 64.



Fonte: os autores.

Na figura 4 tem-se uma comparação dos níveis de tensão com a alocação de dois geradores de 1 MW cada e sem esta alocação. Nota-se que a tensão mínima é de 0,97 (p.u.).

Figura 4 - Comparação dos níveis de tensão no sistema de 70 Barras, antes e após a otimização por meio de GD.



Fonte: os autores.

Ao alocar nas barras 63 e 64 houve uma redução de aproximadamente 91,3% das perdas ativas do sistema de 70 barras, com uma melhoria nos perfis de tensão de todas as barras deste sistema.

3.2 ALOCAÇÃO DE GERAÇÃO DISTRIBUÍDA - NÍVEIS DE TENSÃO

As alocações da GD nos sistemas de 34 barras e 70 barras visaram uma melhora dos níveis de tensão nas barras, ou seja, minimizar o desvio de tensão em torno de 1 p.u. Novamente, o algoritmo proposto PSO-AS foi comparado com BE e os resultados dos níveis de tensão e as perdas ativas podem ser verificados a seguir. A tabela 2 apresenta a comparação das perdas ativas dos sistemas testados quando o objetivo é melhoria nos perfis de tensão.


Tabela II-Comparação das perdas ativas empregando modelos PSO-AS E BE para melhoria no perfil de tensão

Sistema	Perdas (MW) PSO-AS	Perdas (MW) BE	Perdas (MW) Sem Alocar	Barras
34 Barras	0,0608	0,0611	0,2223	22 e 24
70 Barras	0,0805	0,0806	0,2250	28 e 67

Fonte: os autores.

Na figura 5 tem-se o diagrama unifilar do sistema de distribuição de 34 barras com alocação de GD nas barras 22 e 24, sendo um gerador de 1 MW em cada barra.

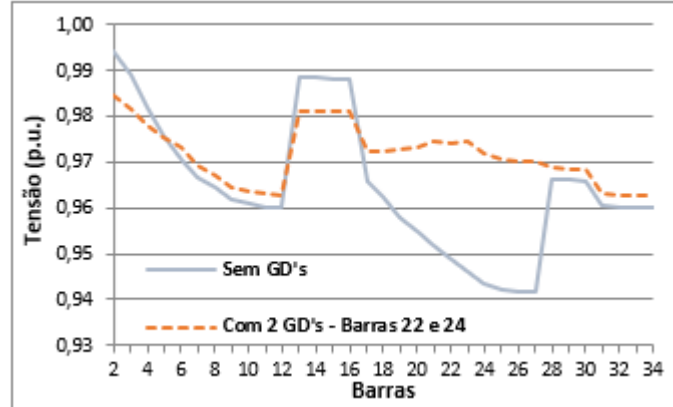
Figura 5 - Sistema de 34 Barras com Alocação nas Barras 22 e 24.



Fonte: os autores.

A figura 6 apresenta o resultado referente aos níveis de tensão para o sistema de 34 barras, quando foram alocados dois geradores de 1 MW cada.

Figura 6 - comparação dos níveis de tensão no sistema de 34 barras, antes e após a otimização por meio de GD.




Fonte: os autores.

No sistema de 34 barras, os melhores pontos de conexão visando à melhoria dos níveis de tensão são as barras 22 e 24, resultando em tensão mínima de 0,963 p.u. Ao realizar essa alocação, as perdas ativas do sistema sofrem uma redução de aproximadamente 72,7%.

Ao realizar-se a mesma alocação para o sistema de 70 barras, houve uma redução em torno de 64,2% das perdas ativas do sistema. Para obter o melhor perfil de tensão, a GD deveria ser conectada nas barras 28 e 67, como se pode verificar na figura 7.


Figura 7 - sistema de 70 barras com alocação nas barras 28 e 67.



Fonte: os autores.

Ao alocar nesses pontos, todas as barras do sistema apresentam tensão acima de 0,96 p.u., conforme figura 8, satisfazendo critérios típicos de qualidade da energia.

Figura 8 - comparação dos níveis de tensão no sistema de 70 barras, antes e após a otimização por meio de GD.



Fonte: os autores.

A tabela 3 apresenta os resultados de tempo de simulação computacional, na qual houve uma diminuição de aproximadamente 91% no tempo gasto para o sistema de 70 barras e cerca de 95% no sistema de 34 barras, quando utilizada a metodologia PSO-BE em relação ao emprego de BE para os mesmos sistemas. Como a BE do presente trabalho também utiliza AS, o seu tempo computacional não é tão alto quanto de uma busca exaustiva clássica, na qual o FC seria calculado para todos os possíveis estados de alocação.

Tabela III-Comparação do tempo computacional médio entre técnicas PSO-AS E BE

Sistema	Tempo (s) BE	Tempo (s) PSO-AS	Redução (%)
34 Barras	73,92	3,47	- 95,30
70 Barras	328,44	28,76	- 91,24

Fonte: os autores.

4 CONCLUSÃO

Este artigo apresentou uma proposta para alocação otimizada de GD baseada no algoritmo PSO-AS. O PSO é dotado de heurística que direciona a busca para alocação e o uso de AS permite calcular, de forma direta, as perdas ôhmicas e demais variáveis do estado da rede. Em comparação a outros métodos baseados em FC, o PSO-AS promove redução significativa de tempo no processo computacional de otimização.

A metodologia PSO-AS foi verificada mediante comparação com os resultados de busca exaustiva. A solução obtida com o uso de PSO-AS, na média, consumiu um tempo de processamento computacional 93,3% menor em relação à busca exaustiva.

Foi demonstrado que a alocação de GD proporcionou uma diminuição nas perdas ôhmicas dos sistemas testados, alcançando até 74,4% no sistema de 34 barras e até 83,0% no sistema de 70

barras. Ainda se observou uma elevação sistêmica no perfil de tensão, o que é benéfico para a operação de sistemas elétricos de distribuição, imputando maior qualidade no fornecimento.

Os resultados obtidos mostraram-se eficazes para um melhor aproveitamento da energia elétrica nos sistemas testados, além de contribuírem substancialmente para a compreensão e disseminação da aplicação da técnica PSO-AS apresentada neste trabalho. Além disso, neste trabalho computou-se o tempo gasto no processo de otimização, demonstrando a viabilidade de aplicação da metodologia para solução de problemas que necessitam de uma otimização *on-line*.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro e à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pela concessão 2018/03051-2.

REFERÊNCIAS

- Acharya, N.; Mahat, P.; Mithulananthan, N. An analytical approach for dg allocation in primary distribution network. *Electric Power e Energy Systems*, n. 28, p. 669–678, 2006.
- Ali, E.S.; Abd Elazim, S.M.; Abedalaziz, A.Y. Antlion optimization for optimal location and sizing of renewable distributed generations. *Renewable Energy*, n. 101, p. 1311-1324, 2017.
- Bouktir, Tarek; Guerriche, K. Ras. Optimal allocation and sizing of distributed generation with particle swarm optimization algorithm for loss reduction. *Revue des Sciences et de la Technologie - RST*, v. 6, n. 1, 2015.
- Coelho, F. C. R. et al. Optimal distributed generation allocation using a new metaheuristic. *Journal of Control, Automation and Electrical Systems*, v. 29, n. 1, p. 91-98, 2018.
- Chis, M.; Salama, M. M. A.; Jayaram, S. Capacitor placement in distribution systems using heuristic search strategies. *Generation, Transmission and Distribution - IEEE Proceedings*, v. 144, p. 225-230, 1997.
- El-Ela, A. A. A.; Allama, S. M.; Shatlab, M. M. Maximal optimal benefits of distributed generation using genetic algorithms. *Electric Power Systems Research*, n. 80, 2010.
- Empresa de Pesquisa Energética – EPE. Plano decenal de expansão de energia 2019. Disponível em: <http://www.mme.gov.br/documents/10584/1256592/PDE2019_03Maio2010.pdf/d6bf6183-c8ff-440d-a8e2-2b50ae6c5d15> Acesso em: fev. 2019.
- Farh, H. M. H. et al. A novel crow search algorithm auto-drive pso for optimal allocation and sizing of renewable distributed generation. *IEEE Access*, v. 8, p. 27807–27820, 2020.
- Fiacco, A., Sensitivity analysis for nonlinear programming using penalty methods. *Mathematical Programming*, v. 10, p. 287-311, 1976.
- Furlan, R.H.; Bataglioli, Carvalho. W. C.; Oleskovicz, M. Optimal allocation of distributed generation in a radial distribution network for losses reduction and voltage profile improvement. *7th Brazilian Electrical Systems Symposium – SBSE 2018*, p. 1-6, 2018.
- Gandomkar, M.; Vakilian, M.; Ehsan, M. Optimal distributed generation allocation in distribution network using hereford ranch algorithm. *IEEE Electrical Machines and Systems*, 2005.
- José, D.; Belati, E.; Angelos, E. A new hybrid methodology to resolve the problem of optimal allocation of capacitor banks. *Brazilian Journal of Development*, 2020.
- Kazemi, A.; Sadeghi, M. Distributed generation allocation for loss reduction and voltage improvement. *Power and Energy Engineering Conference*, 2009.
- Kennedy, J.; Eberhart, R. Particle swarm optimization. *Proceedings of IEEE International Conference on Neural Networks*. p. 1942–1948, 1995.
- Khoa, T. Q. D.; Binh, P. T. T.; Tran, H. B. Optimizing location and sizing of distributed generation in distribution systems. *IEEE - Transactions on Power Systems*, 2004.

Kumar, D. et al. Reliability-constrained based optimal placement and sizing of multiple distributed generators in power distribution network using cat swarm optimization. *Electric Power Component*, v. 42, p. 149–64, 2014.

Prado, I. F. Alocação de geração distribuída utilizando o algoritmo genético de Chu-Beasley e índices de sensibilidade. Universidade Federal do ABC (Dissertação de mestrado), 2013.

Prado, I. F.; Garces, L. P. Chu-Beasley genetic algorithm applied to the allocation of distributed generation. *IEEE PES Conference on Innovative Smart Grid Technologies*, 2013.

Rosa, W. M. et al. Insertion of wind generators in electrical power systems aimed at active losses reduction using sensitivity analysis. *International Journal of Electrical Power and Energy Systems*, v. 80, p. 306–311, 2016.

Sahib, T. J. et al. Optimum allocation of distributed generation using PSO: IEEE test case studies evaluation. *International Journal of Applied Engineering Research*, v. 12, n. 11, 2017.

Schultz, D. J. et al. Sistemas complementares de energia eólica e hidráulica no Brasil. In: *Espaço Energia*. 3. ed., 2005.

Suresh, H. M. C. V.; Edward, J. B. A hybrid algorithm based optimal placement of DG units for loss reduction in the distribution system. *Applied Soft Computing Journal*, v. 91, p. 106-191, 2020.

Yang, X.-S. *Nature-inspired metaheuristic algorithms*. 2. ed. United Kingdom: Luniver Press, 2010.