

Algoritmo PSO com Voos de Lévy para Alocação e Dimensionamento de Geração Distribuída

Diego José da Silva * Gringo Barbosa * Edmarcio Antonio Belati *
Eduardo Werley S. Ângelos * Edimar Jose de Oliveira **

* *Universidade Federal do ABC, UFABC, Santo André/SP Brasil,
(e-mails: d.jose@ufabc.edu.br; gringo.galina@ufabc.edu.br;
edmarcio.belati@ufabc.edu.br; ew.angelos@ieee.org).*

** *Universidade Federal de Juiz de Fora, UFJF, Juiz de Fora/MG
Brasil, (e-mail: edimar.oliveira@ufjf.edu.br)*

Abstract: Distributed generation (DG) offers several benefits to the electrical system, such as the reduction of losses and improvement of the voltage profile. DG benefits can be maximized when allocation and sizing are optimal — a problem known as the Optimal Sizing and Placement of Distributed Generation (OSPDG). This paper presents a new meta-heuristic that associates PSO (Particle Swarm Optimization) with Lévy flights (LF) to solve the OSPDG, identified in this work as LFPSO. The tests carried out on the 69-bus distribution system indicate that the LFPSO is superior to the PSO in relation to the convergence process. The results obtained considering the allocation of up to three DG point to a reduction of 98.1 % in active power losses.

Resumo: A geração distribuída (GD) apresentam vários benefícios para o sistema elétrico, como a diminuição de perdas e a elevação do perfil de tensão. Os benefícios das GD podem ser maximizados quando a alocação e dimensionamento são ótimos. O problema é conhecido como Alocação e Dimensionamento Ótimo de Geração Distribuída (ADOGD). Neste artigo apresentamos uma nova meta-heurística que associa o PSO (em inglês, *Particle Swarm Optimization*) com os voos de Lévy (LF) (em inglês, *Lévy flights*) para resolver o problema de ADOGD, identificada neste trabalho como LFPSO. Testes realizados em um sistema de distribuição de 69 barras indicam que o LFPSO é superior ao PSO em relação ao processo de convergência. Os resultados obtidos, considerando a alocação de três GD, apontam para redução de 98,1 % das perdas de potência ativas.

Keywords: Distributed Generation; Power Losses, Voltage Profile, Particle Swarm Optimizer, Levy Flight.

Palavras-chaves: Geração Distribuída; Perdas Elétricas, Perfil de Tensão; Otimização por Enxame de Partículas; Voos de Lévy.

1. INTRODUÇÃO

A inserção de fontes alternativas em redes elétricas vem se intensificando nos últimos anos. A responsabilidade ambiental tornou-se uma das principais metas de indústrias, empresas e entidades governamentais. A Geração Distribuída (GD) pode contribuir para a redução dos gases de efeito estufa e ainda favorecer a redução de perdas técnicas e melhora de níveis de tensão (Abo El-Ela et al., 2021).

O problema de Alocação e Dimensionamento Ótimo de GD (ADOGD) envolve a determinação do melhor local e a capacidade ótima desses geradores com a finalidade usual de minimizar perdas ativas e melhorar o perfil de tensão. Na concepção matemática trata-se de um problema não-linear inteiro misto (PNLIM), ou seja, composto por funções não-lineares, variáveis inteiras e contínuas. Ade-

mais, algumas funções não são convexas (Coelho et al., 2018). Essas características dificultam a obtenção da solução ótima, independente da técnica utilizada. A alocação e/ou dimensionamento equivocados podem acarretar resultados subótimos, ou ainda ampliar as perdas do sistema (Mahmoud et al., 2016).

Diversas abordagens são propostas para resolver o problema de ADOGD (Bayat and Bagheri, 2018; Furlan et al., 2018; da Rosa et al., 2018), podendo ser classificadas em exatas e aproximadas. As primeiras apresentam elevado grau de precisão nos resultados, no entanto, exigem considerável esforço computacional, podendo inviabilizar sua aplicação em sistemas de médio e grande porte (Pesaran H.A et al., 2017). Já os métodos aproximados constituem técnicas heurísticas (Bayat and Bagheri, 2018; El-Khattam et al., 2004) e meta-heurísticas (Isac et al., 2020). Como características principais, geralmente não envolvem modelos matemáticos complexos, trabalham com variáveis discretas e contínuas e apresentam baixo esforço computacional. Contudo, devido à característica estocástica, não é pos-

* Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 - pelo suporte à execução deste trabalho.

sível garantir a convergência para o ótimo global nestes métodos. Desta forma, estratégias para melhorar o processo de otimização podem ser adotadas como hibridização (combinação entre duas técnicas) (Kansal et al., 2016; José da Silva et al., 2020) ou adaptações em algoritmos de otimização, como em Abdelsalam and El-Shorbagy (2018); Ullah et al. (2019); Sa'ad et al. (2021).

Neste trabalho propomos uma metodologia para a solução do problema ADOGD baseada no algoritmo Enxame de Partículas, do inglês *Particle Swarm Optimization* (PSO), combinado com os voos de Lévy, do inglês *Lévy flight* (LF), identificada neste trabalho como LFPSO. Ao incorporar o LF ao PSO, promove-se uma melhor exploração do espaço de busca no processo de otimização, mantendo as características do PSO.

Na Seção 2, a formulação matemática do problema de ADOGD é apresentada. Na seção 3 é descrita a metodologia adotada. Na Seção 4 são então apresentados os resultados de testes computacionais. Por fim, na Seção 5 apresenta-se as conclusões do trabalho.

2. FORMULAÇÃO MATEMÁTICA

O problema de ADOGD é formulado neste trabalho visando minimizar perdas ativas sujeito às restrições operacionais como formulado pelas equações (1)-(8). A função objetivo é representada conforme apresentado em (El-Ela et al., 2018).

$$\min f(x) = \sum_{i=1}^{n_L} R_i I_i^2 \quad (1)$$

onde:

$f(x)$	perdas do sistema (W)
n_L	número de linhas do sistema
R_i	resistência no ramo i
I_i	corrente no ramo i .

A função objetivo (1) está sujeita às restrições de igualdade e desigualdade a seguir:

Restrições de fluxo de potência

$$0 = PG_k + PG_{G_k} - PC_k - V_k \sum_{m \in k} V_m (G_{km} \cos \theta_{km} + B_{km} \sin \theta_{km}) \quad (2)$$

$$0 = QG_k + QG_{G_k} - QC_k - V_k \sum_{m \in k} V_m (G_{km} \sin \theta_{km} - B_{km} \cos \theta_{km}) \quad (3)$$

em que:

PG_{G_k}, QG_{G_k}	potência ativa e reativa injetada pelo GD na barra k
PG_k, QG_k	potência ativa e reativa injetada na barra k pelos demais geradores
PC_k, QC_k	potência ativa e reativa das cargas na barra k
V_k, V_m	magnitudes de tensão nodal nas barras k e m , respectivamente
G_{km}, B_{km}	parte real e imaginária do elemento km da matriz admitância ($Y = G + jB$)
θ_{km}	diferença angular entre as barras k e m ;

Restrições de níveis de tensão

O perfil de tensão em cada barra V_k deve estar dentro dos níveis máximo e mínimo estabelecidos:

$$V_k^{min} \leq V_k \leq V_k^{max} \quad (4)$$

Restrições de capacidade dos GD

A injeção de potência dos GD deve estar atender os limites mínimos e máximos, tais como:

$$P_{Gk}^{min} \leq P_{Gk} \leq P_{Gk}^{max} \quad (5)$$

$$Q_{Gk}^{min} \leq Q_{Gk} \leq Q_{Gk}^{max} \quad (6)$$

Restrições do número de GD:

Esta restrição visa restringir a quantidade de GD alocada:

$$N_{GD} \leq N_{GD}^{max} \quad (7)$$

Quando os limites máximos e mínimos em (6) são nulos, o fator de potência (fp) da GD torna-se unitário. Caso contrário, o valor do fp em uma dada barra k , fp_{GD_k} , será definido conforme a Equação (8):

$$fp_{GD_k} = \cos \left(\text{atan} \left(\frac{Q_{GD_k}}{P_{GD_k}} \right) \right) \quad (8)$$

3. METODOLOGIA PROPOSTA

A metodologia de solução é baseada no PSO tradicional com a consideração de uma nova característica nos enxames, relacionada ao indivíduo que, por algum motivo, deixa de acompanhar o bando em algum momento. Essa nova meta-heurística, simulada por meio do LF, é identificada nesse trabalho como LFPSO. A seguir são apresentados a descrição e equacionamento do PSO tradicional, e na sequência introduzido o LF, para por fim compor a meta-heurística LFPSO proposta.

3.1 Algoritmo Enxame de Partículas

Originalmente proposto por Kennedy and Eberhart (1995), o PSO é uma meta-heurística bio-inspirada que busca reproduzir o comportamento dos pássaros, enxames de peixes ou outros fenômenos da natureza que se baseiam

em população de seres. No PSO, cada partícula $X_i = (X_{i1}, X_{i2}, \dots, X_{in})$ do enxame é uma candidata à solução do problema, conduzida pela sua respectiva velocidade $v_i = (v_{i1}, v_{i2}, \dots, v_{in})$. Durante o processo iterativo, a velocidade e a posição das partículas na iteração subsequente ($t+1$) são dadas pelas equações (9) e (10), respectivamente. A melhor posição encontrada pela partícula i é definida com P_i e a melhor posição do grupo por P_g .

$$v_i^{t+1} = wV_i^t + r_1C_1(P_i - X_i^t) + r_2C_2(P_g - X_i^t) \quad (9)$$

$$X_i^{t+1} = X_i^t + v_i^{t+1} \quad (10)$$

em que:

- r_1, r_2 são variáveis aleatórias entre $[0,1]$ representando a componente estocástica do algoritmo
- C_1, C_2 são os coeficientes de aceleração pessoal e global, respectivamente, que influenciam no tamanho máximo do passo que uma partícula pode dar em uma iteração
- ω é o peso de inércia (momento).

As velocidades das partículas são mantidas dentro de um intervalo pré-estabelecido (11):

$$v_i^{min} \leq v_i \leq v_i^{max} \quad (11)$$

Existem diferentes maneiras de inicializar ou modificar o peso de inércia do algoritmo, que pode ser um parâmetro constante ou variável Bansal et al. (2011). Neste trabalho o peso de inércia é calculado usando a equação (12). Essa estratégia ajuda a intensificar a busca próximo à posição da partícula, ao final do processo iterativo.

$$\omega = \omega_{max} - \frac{\omega_{max} - \omega_{min}}{iter_{max}} \cdot t \quad (12)$$

em que:

- ω_{max} é o valor máximo do peso de inércia
- ω_{min} é valor mínimo do peso de inércia
- $iter_{max}$ é número máximo de iterações.

3.2 Voos de Lévy

Ao investigar as características das meta-heurísticas, percebe-se que a aleatoriedade desempenha um papel crucial tanto na exploração do espaço de busca como no refinamento das soluções. Comumente, a randomização é obtida por métodos aleatórios simples que consideram distribuições uniformes ou gaussianas. Em outros casos, técnicas de randomização mais sofisticadas utilizando os chamados *Voos de Lévy* (LF) ou cadeias de Markov são usadas (Yang, 2014).

Em algumas circunstâncias, alguns indivíduos do enxame podem se desprender e voar longas distâncias, influenciados por fenômenos como, por exemplo, na ocorrência de tempestades. Tal comportamento pode ser modelado pelos LF — categoria de caminhada aleatória cujo tamanho do passo é definido a partir da distribuição de Lévy, expressa em termos de uma lei de potência, como descrito por Yang (2014):

$$L(S) \sim |S|^{-1-\beta} \quad (13)$$

onde:

- S é uma variável que descreve o tamanho do passo
- β é um índice no intervalo $[0, 2]$.

A distribuição de Lévy também pode ser expressa em termos da transformada de Fourier (Yang, 2014).

Na literatura é possível encontrar vários trabalhos que utilizam os LF. Neste trabalho foi considerado um processo de passeio aleatório com probabilidade de passo de comprimento (L) conforme a equação 14:

$$L = \frac{\sigma \left\{ \frac{r(1+\beta) \sin \frac{\pi\beta}{2}}{\tau \left[\frac{1+\beta}{2} \right] \beta 2^{\frac{\beta-1}{2}}} \right\}^{\frac{1}{\beta}}}{abs(\sigma)^{\frac{1}{\beta}}} \quad (14)$$

onde:

- τ é uma função gama padrão
- σ fornece valores pseudoaleatórios de uma distribuição normal padrão.

3.3 LFPSO – Algoritmo proposto

A fundamentação do algoritmo LFPSO proposto é que, a partir de uma determinada posição, uma partícula X_i pode “voar” para uma nova posição distante do grupo, sendo aleatoriamente definida a partir da distribuição de voos de Lévy (13). Muitas observações revelaram que, frequentemente, ótimos de alta qualidade são localizados “centralmente” entre ótimos locais (Tran et al., 2014). Se esta conclusão for válida na otimização de problemas do mundo real, o processo de voos de Lévy aliado a outros mecanismos de busca, no caso o PSO, deve ajudar a encontrar um número de ótimos locais e em seguida a região promissora ao ótimo global.

A proposta que envolve o LFPSO é incluir ao processo de busca uma equação adicional, dada por:

$$v_i^{(t+1)} = \omega v_i^t + L_i^{t+1}(P_g - X_i^t) \quad (15)$$

A escolha entre as formas de atualização (9) ou (15) será determinada por um parâmetro de controle de busca, ou “seletor”, φ , modelado com uma variável randômica com intervalo $[0, 1]$.

É importante observar que em (15) também é usado o peso de inércia, ω , para controlar a velocidade, fazendo que o processo de busca diminua a região explorada nas últimas iterações. Assim, de forma resumida, a proposta é adicionar um mecanismo para escapar de ótimos locais, buscando o ótimo global por meio do LF. É esperado que o LFPSO tenha um melhor desempenho em relação ao PSO, principalmente em problemas com grande complexidade, como exemplo o ADOGD.

3.4 Implementação computacional do LFPSO aplicado ao problema de ADOGD

No PSO convencional, as partículas são atualizadas considerando uma única estratégia. No presente trabalho, devido às grandezas que envolvem o problema de ADOGD serem de naturezas distintas (alocação e dimensionamento), o algoritmo original foi adaptado para que a atualização das partículas ocorra separadamente, buscando tornar o algoritmo mais eficiente. A estratégia proposta está relacionada com a posição das partículas, onde os elementos $X_{B_kGD_i}^t$ representa a i -ésima GD alocada na barra k , $X_{P_kGD_i}^t$ representa o valor da potência ativa da i -ésima GD alocada na barra k e $X_{Q_kGD_i}^t$ representa o valor da potência reativa da i -ésima GD alocada na barra k . A Figura (1) ilustra os elementos de uma partícula X_i .

Os elementos $X_{B_kGD_i}^t$ são valores inteiros, escolhidos dentre o conjunto de barras candidatas. Se todas as barras do sistema forem candidatas, o espaço de busca é o conjunto de barras do sistema. Os elementos $X_{P_kGD_i}^t$ são valores contínuos no intervalo definido, que vai de zero até a capacidade máxima permitida de potência ativa para GD. A mesma consideração é aplicada aos elementos $X_{Q_kGD_i}^t$, mas relacionada com a potência reativa da GD. Após a atualização das variáveis, as partículas são avaliadas buscando o valor da “fitness”. Na aplicação proposta foi utilizado o Fluxo de Carga Newton-Raphson para obter as perdas ativas da rede.

O fluxograma do LFPSO aplicado ao problema de ADOGD é apresentado na Figura 2. Como descrito no fluxograma, se alguma variável ultrapassar o limite, é imposto que na interação corrente ela assuma o valor mais próximo do limite (superior ou inferior). Note que o “seletor” φ é aplicado para cada elemento da partícula, conforme destacado no retângulo em vermelho.

4. TESTES E RESULTADOS

Nesta seção são apresentados os resultados obtidos usando o LFPSO para o problema de ADOGD. Os resultados foram comparados com o PSO, usando $\varphi=1$, com objetivo de avaliar o desempenho do LFPSO frente ao PSO. Os resultados também foram comparados com outras metodologias disponíveis na literatura. Nas análises foi considerado um sistema radial de distribuição de 69 barras.

A função utilizada para os cálculos dos passos do LF, implementada no MATLAB, está ilustrada na Figura 3. A função retorna os valores dos passos, conforme a dimensão d . Note que foi utilizado $\beta = \frac{3}{2}$, como sugerido em Yang (2014).

O algoritmo foi testado para alocação de uma, duas e três GDs, considerando fp unitário e fp livre, ou seja, com geração de potência ativa e reativa pelas GDs. Em todos os testes os algoritmos LFPSO e PSO foram executados 10 vezes cada, sendo as melhores soluções apresentadas nas tabelas comparativas. Os parâmetros utilizados nas simulações, obtidos empiricamente, estão na Tabela 1. O número máximo de iterações e o número de partículas foi escolhido visando minimizar o custo computacional.

Tabela 1. Parâmetros utilizados nas simulações para o LFPSO

Parâmetro	Valor
It_{max}	100
N_p	70
C_1	1,2
C_2	0,8
ω_{max}	0,9
ω_{min}	0,4
vB_{max}	5
vB_{min}	-5
vP_{max}	0,5
vP_{min}	-0,5
vQ_{max}	0,5
vQ_{min}	-0,5
φ	0,7

Nos testes realizados todas as barras do sistema foram candidatas à alocação de GD. Como os valores dos elementos $X_{B_kGD_i}^t$ devem ser inteiros, foi utilizada a função “ceil” do MATLAB, que arredonda para o inteiro mais próximo. As capacidades das GDs, de potência ativa e reativa, foram limitadas em 4 MW e 4 MVar, respectivamente. O fator de potência dos GDs, em todos os casos, foi adiantado.

As simulações foram realizadas em um computador com processador Intel®Core™ i5 210M CPU @ 2,50 GHz com 8 GB de RAM, usando o Matlab®.

4.1 Sistema de 69 barras

O sistema de 69 barras utilizado é baseado em Das (2008), que apresenta nível de tensão de 12,66 kV. As cargas ativas e reativas somam respectivamente 3.802,1 kW e 2.694,7 kVar. O sistema apresenta perdas de 225,00 kW sem a presença das GDs, sendo este designado o caso base. A Figura 4 mostra o diagrama unifilar do sistema.

4.2 Sistema de 69 barras com fator de potência unitário

A Tabela 2 apresenta uma análise comparativa considerando a alocação de GDs com fp unitário, ou seja, fornecendo somente potência ativa. As comparações foram realizadas com os seguintes algoritmos: *Improved Analytical* (IA) (Hung and Mithulananthan, 2013), *Mixed Integer Non-Linear Programming* (MINLP) (Kaur et al., 2014), *Modified Teaching-Learning Optimization Algorithm* (MTLBO) (Martín García and Gil Mena, 2013) e *Hybrid Grey Wolf Optimizer* (HGWO) (Sanjay et al., 2017). Nota-se que tanto o PSO quanto o LFPSO encontraram a melhor solução quanto às perdas, com base nos trabalhos analisados, mas verificou-se que o LFPSO não apresentou *outliers*.

4.3 Sistema de 69 barras com fator de potência livre

Na Tabela 3 apresenta-se uma análise comparativa dos algoritmos PSO e LFPSO e outros relevantes considerando a alocação de GDs com fp livre, ou seja, podendo fornecer potência ativa e reativa. A relação entre as potências leva a um fator de potência otimizado, apresentado na Tabela. Devido à característica indutiva da rede, os fp encontrados




Figura 1. Elementos do vetor X

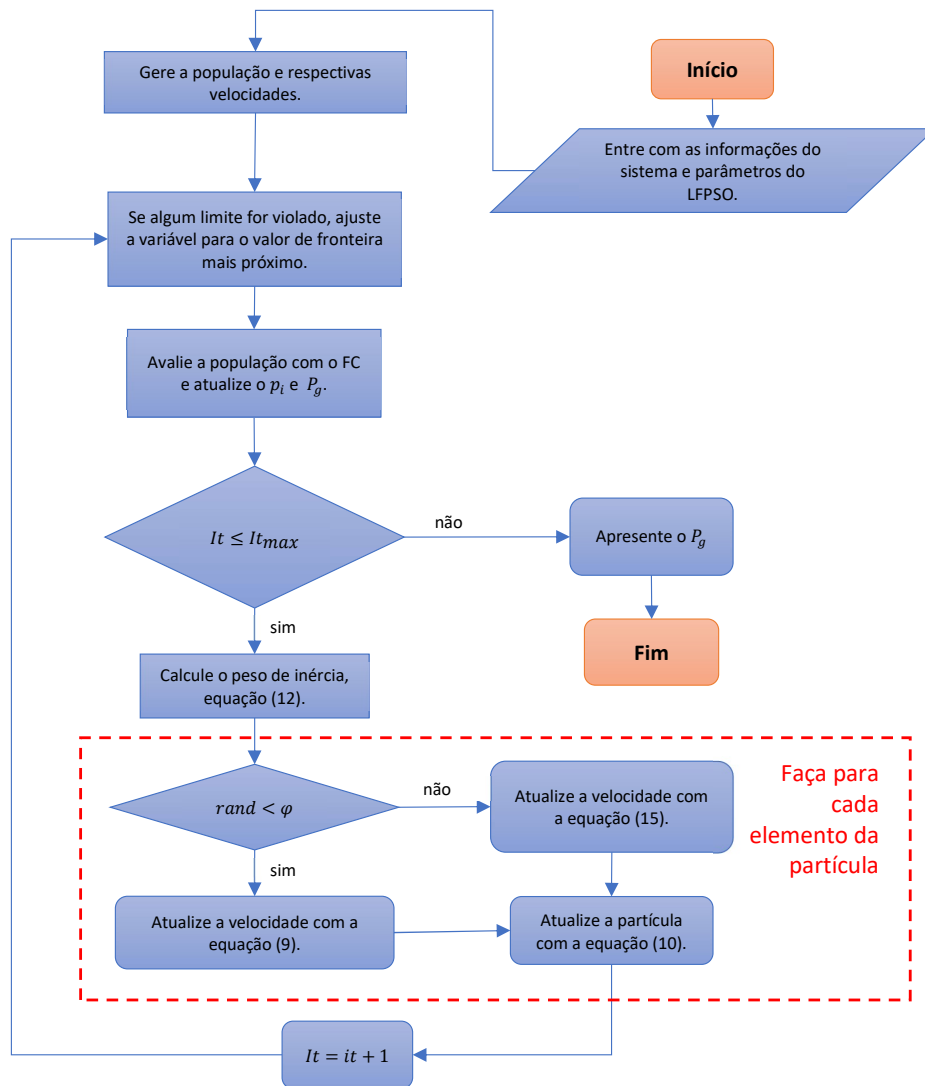


Figura 2. Fluxograma do LFPSO aplicado ao problema de ADOGD

```
function [L] = Levy( d )
beta=3/2;
sigma=(gamma(1+beta)*sin(pi*beta/2)/(gamma((1+beta)/2)*beta*2^((beta-1)/2)))^(1/beta);
u=randn(1,d)*sigma;
v=randn(1,d);
step=u./abs(v).^(1/beta);
L=step;
end
```

Figura 3. Função Voos de Lévy (linguagem MATLAB)

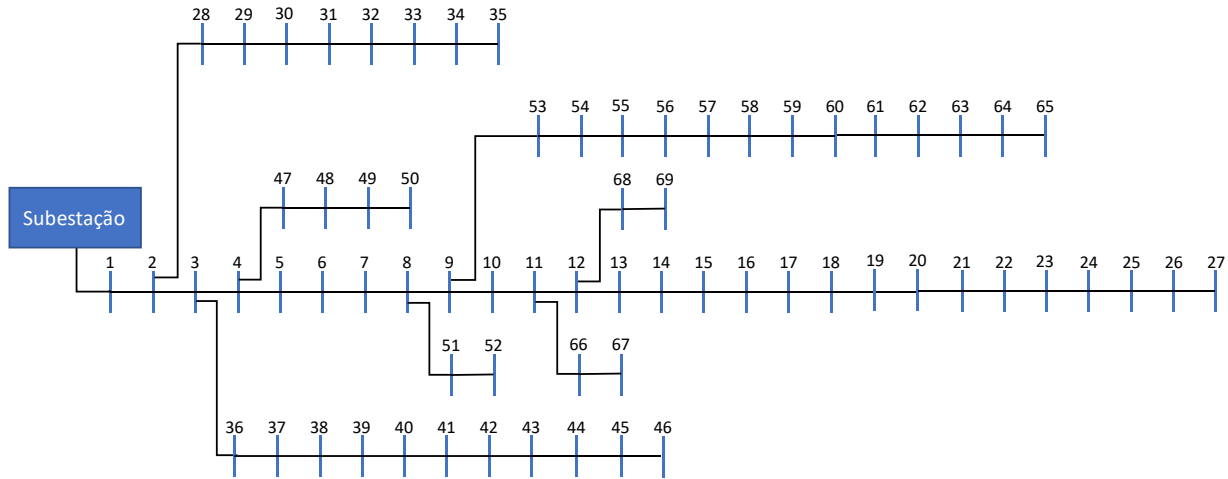


Figura 4. Diagrama unifilar do sistema de distribuição de 69 barras

Tabela 2. Resultados para o sistema de 69 barras com alocação de GD com fp unitário

Método	fp unitário - 1 GD		fp unitário - 2 GD		fp unitário - 3 GD	
	kW (barra)	perdas (kW)	kW (barra)	perdas (kW)	kW (barra)	perdas (kW)
caso base	—	225	—	225	—	225
IA	1900 (61)	83,55	510 (17); 1700 (61)	71,92	510 (11); 340 (17); 1700 (61)	70,23
MINLP	1870 (61)	83,48	530 (17); 1780 (61)	71,92	530 (11); 380 (17); 1720 (61)	69,67
MTLBO	1819 (61)	83,32	519 (17); 1732 (61)	71,77	493 (11); 378 (18); 1672 (61)	69,53
HGWO	1872 (61)	83,2	531 (17); 1781 (61)	71,67	527 (11); 380 (17); 1718 (61)	69,42
PSO	1872,69 (61)	83,22	531,5 (17); 1781,5 (61)	71,67	562,9 (11); 380,6 (17); 1718,9 (61)	69,42
LFPSO	1872,69 (61)	83,22	531,5 (17); 1781,5 (61)	71,67	526,9 (11); 380,6 (17); 1718,9 (61)	69,42

em todos os casos são capacitivos. Considerando 10 execuções, observa-se que ambos os algoritmos encontraram boas soluções. Os resultados foram comparados aos métodos *Artificial Bee Colony* (ABC) (Abu-Mouti and El-Hawary, 2011), *Mixed Integer Non-Linear Programming* MINLP (Kaur et al., 2014) e *Improved Analytical* (IA) (Hung and Mithulananthan, 2013). Para o caso com três GDs, o LFPSO foi superior tanto ao PSO quanto aos demais métodos, obtendo perdas de 4,27 kW para 3 GDs alocados, uma redução de 1,9% das perdas do caso base. É importante notar que as barras encontradas pelos algoritmos diferem, porém, os valores encontrados para as perdas foram próximos.

O processo de convergência dos dois algoritmos foi analisado considerando 10 execuções. A Figura 5 mostra que o PSO e LFPSO obtiveram o melhor resultado em todas as execuções para a alocação de uma GD. Para duas GDs, o LFPSO teve desempenho superior, conforme mostra a Figura 6. Em todas as execuções, o LFPSO chegou praticamente à melhor solução. Para o caso mais difícil, a alocação de três GDs, o LFPSO, além de concentrar as soluções mais próximas da melhor solução, também obteve um resultado superior, conforme mostra a Figura 7. Analisando os gráficos apresentados é possível afirmar que o PSO apresenta um bom desempenho, porém, em problemas mais complexos, pode convergir para mínimos locais. O LFPSO, mesmo para problemas mais complexos, consegue escapar dos mínimos locais, indicando superioridade na convergência em relação ao PSO.

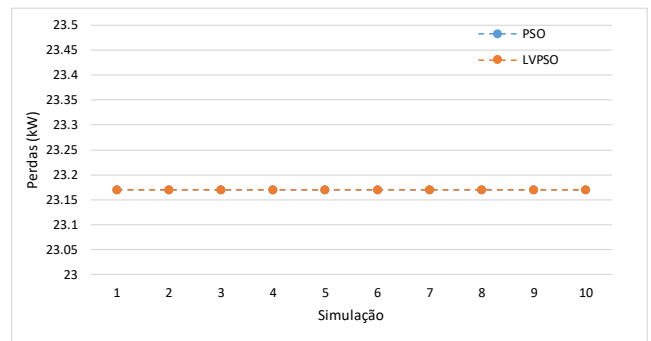


Figura 5. LFPSO e PSO para uma GD (10 execuções)

O perfil de tensão do sistema de 69 barras melhorou com a alocação das GD, como era esperado. Nota-se na Figura 8 que a distribuição de GDs no sistema faz com que o perfil de tensão fique mais próximo de 1 p.u, sem grandes variações ao longo do sistema.

Como observado, o LFPSO pode ser usado para indicar as melhores barras para alocação de GDs em uma rede de distribuição. Cabe ao responsável pela rede propor incentivos aos responsáveis pelas GDs, visando a escolha das melhores localizações e da capacidade dos geradores.

Tabela 3. Resultados comparativos para o sistema de 69 barras com alocação de GD com fp otimizado

Método	fp otimizado. - 1 GD			fp otimizado. - 2 GD			fp otimizado. - 3 GD		
	kW (barra)	fp	perdas (kW)	kW (barra)	fp	perdas (kW)	kW (barra)	fp	perdas (kW)
caso base	—	—	225	—	—	225	—	—	225
ABC	1870 (61)	0,85	23,92	—	—	—	—	—	—
2IA	1839 (61)	0,82	23,24	510 (17)	0,85	7,99	—	—	—
				1785 (61)	0,85	—	—	—	—
3MINLP	1828 (61)	0,81	23,31	540 (17)	0,82	7,45	630 (17)	0,82	5,09
				1799 (61)	0,82	—	900 (50)	0,82	—
							900 (61)	0,82	—
3PSO	1828,5 (61)	0,81	23,17	522,3 (17)	0,83	7,20	552,1 (17)	0,81	4,93
				1734,7 (61)	0,81	—	792,1 (49);	0,83	—
							1734,3 (61)	0,81	—
3LFPSO	1828,5 (61)	0,81	23,17	522,3 (17)	0,83	7,20	496,2 (11)	0,81	4,27
				1734,8 (61)	0,81	—	378,3 (18);	0,83	—
							1673,9 (61)	0,81	—

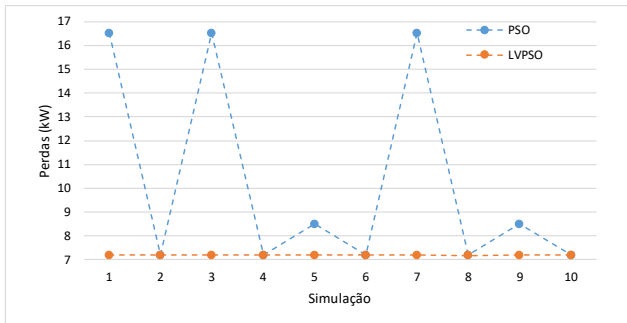


Figura 6. LFPSO e PSO para duas GDs (10 execuções)

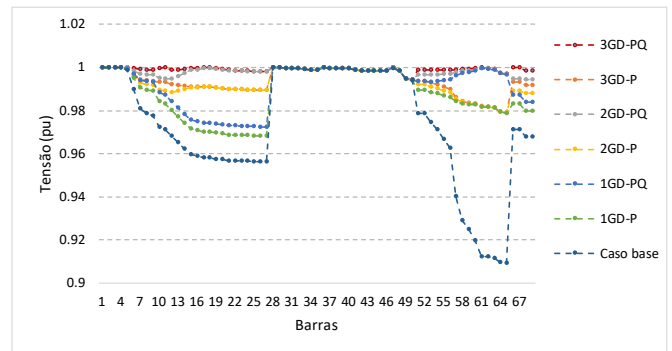


Figura 8. Perfil de tensão para os casos analisados no sistema de 69 barras




Figura 7. LFPSO e PSO para três GD — 10 execuções e fp ótimo

5. CONCLUSÃO

Neste artigo, o problema de alocação e dimensionamento ótimo de geração distribuída foi resolvido com o algoritmo PSO modificado. A proposta é fundamentada no algoritmo PSO combinado com voos de Lévy, originando o LFPSO para redução das perdas ativas e elevação do perfil de tensão. O LFPSO foi implementado e simulado em uma rede de distribuição radial de 69 barras e comparado com o PSO regular e as técnicas ABC, IA, MINLP, MTLBO e

HGWO, apresentando vantagens significativas. Em algoritmos de otimização, busca-se eficiência e qualidade nos resultados, o que pode ser verificado no LFPSO, em termos de convergência, quando comparado com o já consagrado PSO. Além do mais, o algoritmo proposto apresentou bom desempenho quando a dificuldade do problema foi elevada (três GDs, com fp livre) evidenciando que pode ser aplicado em sistemas maiores e com elevados números de GDs. A técnica proposta pode ser aplicada considerando intermitência de GDs (fontes eólicas e solares) e variação de carga ao longo do dia, em situações mais próximas às reais.

REFERÊNCIAS

- Abdelsalam, A.M. and El-Shorbagy, M. (2018). Optimization of wind turbines siting in a wind farm using genetic algorithm based local search. *Renewable Energy*, 123, 748–755.
- Abo El-Ela, A.A., Allam, S.M., Shaheen, A.M., and Nagem, N.A. (2021). Optimal allocation of biomass distributed generation in distribution systems using equilibrium algorithm. *International Transactions on Electrical Energy Systems*, 31(2), e12727. doi:https://doi.org/10.1002/2050-7038.12727.

- Abu-Mouti, F.S. and El-Hawary, M.E. (2011). Optimal distributed generation allocation and sizing in distribution systems via artificial bee colony algorithm. *IEEE Transactions on Power Delivery*, 26(4), 2090–2101. doi:10.1109/TPWRD.2011.2158246.
- Bansal, J.C., Singh, P.K., Saraswat, M., Verma, A., Jadon, S.S., and Abraham, A. (2011). Inertia weight strategies in particle swarm optimization. In *2011 Third World Congress on Nature and Biologically Inspired Computing*, 633–640. doi:10.1109/NaBIC.2011.6089659.
- Bayat, A. and Bagheri, A. (2018). Optimal distributed generation allocation using a new metaheuristic. *Applied Energy*, 29(1), 91–98.
- Coelho, F.C., da Silva Junior, I.C., Dias, B.H., and Peres, W.B. (2018). Optimal distributed generation allocation using a new metaheuristic. *J Control Autom Electr Syst*, 29(1), 91–98.
- da Rosa, W.M., Teixeira, J.C., and Belati, E.A. (2018). New method for optimal allocation of distribution generation aimed at active losses reduction. *Renewable Energy*, 123, 334 – 341.
- Das, D. (2008). Optimal placement of capacitors in radial distribution system using a fuzzy-ga method. *International Journal of Electrical Power & Energy Systems*, 30(6), 361–367.
- El-Ela, A., El-Sehiemy, R., and Abbas, A. (2018). Optimal placement and sizing of distributed generation and capacitor banks in distribution systems using water cycle algorithm. *IEEE Systems Journal*, 12, 3629.
- El-Khattam, W., Bhattacharya, K., Hegazy, Y., and Salama, M.M.A. (2004). Optimal investment planning for distributed generation in a competitive electricity market. *IEEE Transactions on Power Systems*, 19(3), 1674–1684.
- Furlan, R.H., Bataglioli, R.P., Carvalho, W.C., and e. M. Oleskovicz (2018). Optimal allocation of distributed generation in a radial distribution network for losses reduction and voltage profile improvement. In *2018 Simposio Brasileiro de Sistemas Eletricos (SBSE)*, 1–6.
- Hung, D.Q. and Mithulananthan, N. (2013). Multiple distributed generator placement in primary distribution networks for loss reduction. *IEEE Transactions on Industrial Electronics*, 60(4), 1700–1708. doi:10.1109/TIE.2011.2112316.
- Isac, L., Belati, E.A., and Silva, D.J. (2020). Sensitivity analysis associated with particle swarm optimization for distributed generation allocation. *Brazilian Journal of Development*, 6, 63479–63494.
- José da Silva, D., Antonio Belati, E., and Werley Silva dos Angelos, E. (2020). Fpaes: A hybrid approach for the optimal placement and sizing of reactive compensation in distribution grids. *Energies*, 13(23).
- Kansal, S., Kumar, V., and Tyagi, B. (2016). Hybrid approach for optimal placement of multiple dgs of multiple types in distribution networks. *International Journal of Electrical Power & Energy Systems*, 75, 226–235.
- Kaur, S., Kumbhar, G., and Sharma, J. (2014). A minlp technique for optimal placement of multiple dg units in distribution systems. *International Journal of Electrical Power & Energy Systems*, 63, 609–617.
- Kennedy, J. and Eberhart, R. (1995). Proceedings of icnn'95 - international conference on neural networks. In *Optimization of the occlusion strategy in visual tracking, 1942–1948*. Washington DC, USA.
- Mahmoud, K., Yorino, N., and Ahmed, A. (2016). Optimal distributed generation allocation in distribution systems for loss minimization. *IEEE Transactions on Power Systems*, 31(2), 960–969.
- Martín García, J.A. and Gil Mena, A.J. (2013). Optimal distributed generation location and size using a modified teaching–learning based optimization algorithm. *International Journal of Electrical Power & Energy Systems*, 50, 65–75.
- Pesaran H.A, M., Huy, P.D., and Ramachandaramurthy, V.K. (2017). A review of the optimal allocation of distributed generation: Objectives, constraints, methods, and algorithms. *Renewable and Sustainable Energy Reviews*, 75, 293–312. doi:https://doi.org/10.1016/j.rser.2016.10.071.
- Sanjay, R., Jayabarathi, T., Raghunathan, T., Ramesh, V., and Mithulananthan, N. (2017). Optimal allocation of distributed generation using hybrid grey wolf optimizer. *IEEE Access*, 5, 14807–14818. doi:10.1109/ACCESS.2017.2726586.
- Sa'ad, S., Muhammed, A., Abdullahi, M., Abdullah, A., and Hakim Ayob, F. (2021). An enhanced discrete symbiotic organism search algorithm for optimal task scheduling in the cloud. *Algorithms*, 14(7).
- Tran, T., Nguyen, T.T., and Nguyen, H.L. (2014). Global optimization using lévy flights. *CoRR*, abs/1407.5739.
- Ullah, Z., Wang, S., and Radosavljević, J. (2019). A novel method based on pppo for optimal placement and sizing of distributed generation. *IEEE Transactions on Electrical and Electronic Engineering*, 14(12), 1754–1763.
- Yang, X.S. (2014). *Nature-Inspired Optimization Algorithms*. Elsevier, London.