

Análise Comparativa entre PSO e Gradiente Descendente para o Problema do Despacho de Geração Distribuída

Weberti Lucas da Silva, Francisco C. R. Coelho, Wesley Peres.

Departamento de Engenharia Elétrica, DEPEL, Universidade Federal de São João del-Rei – UFSJ
(e-mails: webertiufs@gmail.com, franciscocoelho@ufsj.edu.br, wesleyperes@ufsj.edu.br)

Abstract: The distributed generation (DG) optimal dispatch in electrical distribution systems consists in determining the injected power by the DGs in order to achieve operational benefits. Power loss reduction, enhancement of overall system voltage, and lower pollutants emission are some of the possible DG benefits. In this paper, a comparison between Particle Swarm Optimization (PSO), and Steepest Descent is carried out, aiming at sizing DGs. The main goal is to minimize the distribution system real power loss, while keeping voltages within regulatory limits. All simulations are done considering two DGs connected to the IEEE 13-bus. An unbalanced three-phase power flow is performed by the software OpenDSS (Open Distribution System Simulator). The results show that both optimization algorithms are effective in solving the proposed problem, with PSO finding lower losses and a faster performance of Steepest Descent.

Resumo: O despacho ótimo de Geração Distribuída (GD), em sistemas de distribuição de energia elétrica consiste em se determinar o montante de potência a ser injetada de forma a se obter benefícios operacionais. Redução das perdas ativas, aprimoramento do perfil de tensão e redução da emissão de poluentes são alguns destes potenciais benefícios. Neste trabalho, realiza-se uma comparação entre o *Particle Swarm Optimization* (PSO) e o método do gradiente descendente para a otimização do despacho de GD. O objetivo principal aqui considerado é a minimização das perdas ativas, mantando-se a tensão dentro de limites regulatórios. Todas as simulações são realizadas com duas GDs conectadas ao sistema IEEE 13 barras. O cálculo do fluxo de potência trifásico desequilibrado é feito pelo *software* OpenDSS, (*Open Distribution System Simulator*). Os resultados obtidos mostram que ambas as ferramentas são eficazes na resolução do problema proposto, com o PSO encontrando menores perdas e o gradiente convergindo mais rapidamente.

Keywords: Distributed Generation; Optimum Dispatch; PSO; Steepest Descent; OpenDSS.

Palavras-chaves: Geração Distribuída; Despacho Ótimo; PSO, Gradiente Descendente; OpenDSS.

1. INTRODUÇÃO

No Brasil, a ANEEL (Agência Nacional de Energia Elétrica) define distribuída (GD) como sendo a geração de energia elétrica, de qualquer potência, conectada diretamente no sistema de distribuição, ou através das instalações de consumidores, podendo operar em paralelo ou de forma isolada, despachada, ou não, pelo Operador Nacional do Sistema Elétrico (ONS) (ANEEL, 2018).

Dentre os principais benefícios proporcionados pela inserção de GD no sistema elétrico, podem-se destacar a redução das perdas de potência ativa, melhoria do perfil de tensão e ganhos ambientais, quando utilizando de fontes renováveis como por exemplo a energia solar fotovoltaica e eólica como fontes primárias, (Murty and Kumar, 2015).

Para usufruir destes potenciais benefícios, um dos passos principais é tratar o problema de dimensionamento das fontes distribuídas, que consiste na resolução de um problema de otimização cujas variáveis de decisão são as potências injetadas pelas GDs (Coelho, 2013).

Diante deste contexto, muitos trabalhos vêm sendo desenvolvidos na literatura, produzindo diferentes abordagens para os problemas de alocação e dimensionamento de GD. No trabalho desenvolvido em

(Moradi and Abedini, 2010), propõe-se a utilização do Algoritmo Genético (AG), para determinar a localização ideal e o montante de potência ótimo das GDs, sendo o principal objetivo a minimização das perdas ativas do sistema. Para a realização dos testes é utilizado o sistema de distribuição IEEE 33 barras. As simulações contemplam quatro tipos de tecnologias de geração distribuída: geração fotovoltaica, condensador síncrono, turbinas eólicas e também da hidrelétrica. Os resultados demonstram que o AG é mais eficiente, quando comparado com o PSO, PSO adaptativo (APSO), e *Reload-Flow*.

Em (Liu et al., 2018), é proposto um algoritmo de aprendizado de reforço cooperativo para a resolução do despacho econômico, com o objetivo de minimizar os custos de operação de micro-redes. O modelo da micro-rede é constituído por unidades de geração distribuída e também por dispositivos de armazenamento de energia. Para a análise e validação do algoritmo proposto os autores fazem simulações baseadas em dados de carga reais e comparações com o *fuzzy-Q learning* e com o *Scenario-based algorithm*, mostrando que sua metodologia é eficaz na minimização dos custos do despacho de GD em micro-redes. Como limitação, o autor não leva em considerações as perdas ativas e reativas do sistema tanto em sua função objetivo (FOB) quanto na restrição de balanço de potência.

Já em (Hadidian-Moghaddam et al., 2018), para solução do problema de alocação e de dimensionamento de GDs emprega-se o algoritmo bioinspirado *Ant Lion Optimization*. Os autores levam em consideração um índice de confiabilidade que representa o custo de energia não suprida (CENS), sendo assim, um dos objetivos do problema de otimização é a melhoria da confiabilidade da rede. Os testes foram realizados nos sistemas de distribuição IEEE 33 barras e IEEE 69 barras, ambos equivalentes monofásicos. Pela análise dos resultados, pôde-se concluir que a metaheurística *Ant Lion Optimization*, supera as performances das metaheurísticas PSO e AG.

Com o objetivo de minimizar as perdas de potência ativa, em (Sabarinath and Manohar, 2018), propõe-se o *power loss index* (PLI), para a alocação das unidades de GD juntamente com a metaheurística *flower pollination algorithm* (FPA). Para validação da metodologia, são testados diferentes tipos de tecnologias de GDs nos sistemas IEEE 33 e 69 barras.

Em (Jobanputra and Kotwal, 2018), o trabalho tem como objetivo a minimização dos custos de geração através do despacho ótimo de 10 unidades de GD, tendo como restrição o limite de fluxo nas linhas de transmissão. Para a resolução do problema é utilizado o algoritmo PSO. Os testes são realizados no sistema de distribuição IEEE 39 barras.

Neste trabalho, a metaheurística PSO e o método do gradiente descendente são implementados para a resolução do problema de dimensionamento de GDs. Os testes são realizados em uma rede trifásica desequilibrada, fazendo com que os resultados sejam mais realistas. Por meio da busca exaustiva, foi possível a obtenção do gráfico das perdas em função da potência injetada do problema com a presença de duas unidades de GD na rede, facilitando assim a avaliação dos algoritmos em comparação. Realizaram-se simulações repetitivas visando a obtenção de dados estatísticos sobre a performance destes algoritmos.

2. METODOLOGIA

A metodologia de otimização aqui apresentada tem por objetivo a minimização as perdas de potência ativa da rede, com o aprimoramento do perfil de tensão geral do sistema.

2.1 Formulação Matemática do Problema

A FOB para a minimização das perdas ativas na rede é representada a seguir (Coelho, 2013):

$$\text{Minimizar } P_L \quad (1)$$

Sujeito a:

- (i) Balanço de Potência Ativa e Reativa

$$P_{GDj} + P_{Gj} - P_{Dj} + \sum_{k=1}^{nbus} f_{Pjk} = 0 \quad (2)$$

$$Q_{Gj} - Q_{Dj} + \sum_{k=1}^{nbus} f_{Qjk} = 0 \quad (3)$$

- (ii) Restrições de Tensão e potência despachada

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

$$0 \leq P_{GDj} \leq P_{GD}^{max} \quad (5)$$

P_L	Perdas de potência ativa da rede (kW)
P_{GDj}	Potência ativa injetada pela GD na barra j (kW);
P_{Gj}	Potência ativa gerada na barra j , previamente à conexão de GD (kW);
P_{Dj}	Potência ativa demandada na barra j (kW);
$nbus$	Número de barras do sistema;
f_{Pjk}	Fluxo de potência ativa da barra k para barra j (kW);
Q_{Gj}	Potência reativa gerada na barra j , previamente a conexão de GD (kvar);
Q_{Dj}	Potência reativa demandada na barra j (kvar);
f_{Qjk}	Fluxo de potência reativa da barra k para j (kvar);
V^{min}	Limite inferior de tensão nas barras (kV);
V_j	Tensão na barra j (kV);
V^{max}	Limite superior de tensão nas barras (kV);
P_{GD}^{max}	limite de potência despachável pela GD (kW)

2.2 Fluxo de Potência Trifásico Desequilibrado

O fluxo de potência trifásico desequilibrado é calculado por meio do *software* OpenDSS (*Open Distribution System Simulator*), que faz uso da iteração de ponto fixo. Através de um cálculo direto do circuito, considerando apenas as injeções de corrente das fontes presentes no sistema, as tensões em todas as barras são obtidas. Trata-se de um valor inicial para as grandezas elétricas. Na sequência, atualizam-se as correntes de compensação com base no quão distantes estas estão dos valores necessários para se atingir a carga especificada, que pode ser de potência ou corrente constantes, dentre outros modelos. Seguindo, as tensões são atualizadas. O processo iterativo se repete até que a maior variação de tensão seja menor do que certa tolerância. Sendo este o caso, o algoritmo converge. Mais informações podem ser encontradas em (Dugan and McDermott, 2011).

2.3 Técnicas da Otimização

A. Particle Swarm Optimization (PSO)

O algoritmo PSO, desenvolvido por Kennedy e Eberhart em 1995, baseado no comportamento de enxames na natureza, faz a varredura do espaço de busca de uma função objetivo ajustando as trajetórias de agentes individuais, chamadas partículas, com os caminhos formados por partes determinísticas e estocásticas (Yang, 2014).

Gerar população inicial de n partículas x_i

Enquanto ($t < \text{Max iterações}$)

Avaliação função objetivo para cada partícula

Salvar melhor posição de cada partícula

Salvar melhor partícula

Atualizar a velocidade e posição de cada partícula

Fim enquanto

Pós-processamento e visualização de resultados

Figura 1 - Algoritmo PSO [adaptado de (Yang, 2014)].

(i) Inicialização das partículas

Cada partícula recebe um valor aleatório de potência ativa para cada dimensão, que é definida pelo número de GDs alocadas no sistema de distribuição. Esses valores são gerados através de uma distribuição normal de probabilidade, limitados pela restrição de máxima potência, conforme a Equação (5).

(ii) Avaliação função objetivo

Nesta etapa, através do OpenDSS, é feito o cálculo das perdas ativas no sistema em função da potencia injetada por cada partícula. Com esses valores, as partículas são dispostas em uma lista crescente em relação aos valores de perdas, sendo a configuração que gerou menores perdas a primeira da lista.

(iii) Critério de parada

O critério de parada adotado neste trabalho é o número máximo de iterações.

(iv) Atualização da velocidade da partícula

Cada partícula possui sua velocidade atualizada pela Equação (6):

$$v_i^{(t+1)} = v_i^{(t)} + \alpha \epsilon_1 [g^* - x_i^{(t)}] + \beta \epsilon_2 [x_i^* - x_i^{(t)}] \quad (6)$$

Sendo:

- $v_i^{(t+1)}$ Velocidade da partícula i , na iteração $t + 1$;
- $v_i^{(t)}$ Velocidade da partícula i , na iteração t ;
- α e β Fatores social e cognitivo, respectivamente;
- ϵ_1 e ϵ_2 Vetores aleatórios $\in [0, 1]$
- g^* Posição da melhor partícula da população na iteração t ;
- x_i^* Melhor posição já ocupada pela partícula i ;
- $x_i^{(t)}$ Posição da partícula i , na iteração t .

(v) Atualização da posição da partícula i

$$x_i^{(t+1)} = x_i^{(t)} + v_i^{(t+1)} \quad (7)$$

(vi) Penalização

Com o objetivo de manter as tensões nodais dentro dos limites pré-estabelecidos, aplica-se uma penalização na FOB. Ou seja, se em função da injeção de potência das fontes distribuídas, existir extrapolação dos limites de tensão em qualquer fase de qualquer barra da rede, esta partícula recebe um acréscimo numérico no seu valor de perdas na ordem de 10^7 . Trata-se de uma forma de garantir que as soluções (em termos de despacho de GD) que prejudicam a tensão do sistema sejam consideradas de baixa qualidade pelo PSO.

(vii) Limites de velocidade e do espaço de busca

Nesta etapa do algoritmo, tem-se o tratamento de extrapolação de limites de velocidade e de posição. Aqui, o limite de geração das GDs restringe o espaço de busca (0 a 3 MW, por GD). Já o limite de velocidade é ajustado em um valor máximo, com o objetivo de que a busca não seja realizada em deslocamentos excessivamente grandes na região de busca. Caso algum destes limites seja extrapolado, estas variáveis são trazidas de volta para o valor limite.

(viii) Elitismo

Como é importante manter a melhor solução adquirida em cada etapa da tarefa de otimização, a melhor partícula da população, alcançada até a iteração corrente é salva, garantindo assim que a melhor partícula esteja presente na iteração seguinte. Ressalta-se que o chamado "elitismo" não faz parte do algoritmo PSO original. Porém, devido aos resultados de qualidade obtidos, incluiu-se este mecanismo no PSO implementado neste trabalho.

B. Gradiente Descendente

O algoritmo do Gradiente Descendente pertence à família de métodos de direção de busca. Sua diretriz é baseada nas derivadas parciais da função objetivo. Em se tratando de minimização, seu propósito é encontrar a direção contrária à direção do gradiente, que é a direção onde a função decresce mais rapidamente (Takahashi, 2007).

Inicialização da solução inicial no espaço de busca

Enquanto ($t < \text{Max iterações}$)

Calcular numericamente gradiente na posição

Otimizar Parâmetro Alpha (tamanho do passo)

Atualizar solução

Fim enquanto

Pós-processamento e visualização de resultados

Figura 2 - Algoritmo Gradiente Descendente [adaptado de (Takahashi, 2007)].

(i) Inicialização da solução

Por meio de uma distribuição normal de probabilidade é atribuído uma posição aleatória para a solução inicial no espaço de busca. Os valores da solução correspondem às potências injetadas pelas GDs. A dimensão do vetor solução é determinada pelo número de GDs conectadas.

(ii) Cálculo numérico do gradiente

Após a entrada no processo iterativo, o gradiente da função objetivo é estimado numericamente segundo a Equação (8), que precisa ser calculada para cada dimensão.

$$g_i \leftarrow \frac{f(x + \delta e_i) - f(x)}{\delta} \quad (8)$$

Sendo:

- g_i Derivada parcial da dimensão i ;
- x Vetor solução;
- δ Pequena perturbação para aproximação do cálculo das derivadas parciais ($\delta \approx 0$).
- e_i Vetor binário associado à dimensão i ($e_1 = 1 \mid e_i = 0 \forall i \neq 1$);

(iii) Cálculo do tamanho do passo na direção de busca

Realizado o cálculo do gradiente, a próxima etapa consiste em se obter o passo a ser dado naquela direção, α_g . Para a realização deste cálculo, a estratégia utilizada neste trabalho é o passo decrescente, no qual o mesmo é dividido por um fator fixo até que a FOB (perdas) diminua, ou então, até que este passo atinja um valor mínimo pré-definido.

(iv) Atualização da solução

De posse do passo ótimo, a solução é atualizada pelas equações (9) e (10).

$$d_t = -g_t \quad (9)$$

$$x^{(t+1)} = x^{(t)} + \alpha_g d_t \quad (10)$$

(v) Critério de Parada

O critério de parada adotado para o gradiente finalizar seu processo de otimização é o número máximo de iterações.

2.4 Parâmetros Utilizados nas Simulações

Tabela 1 - Parâmetros utilizados nas Simulações.

Algoritmo	Parâmetro	Valor	Descrição
PSO	n	10	Nº de partículas
	ite	25	Nº de iterações
	α	0,1	Fator social
	β	0,1	Fator cognitivo
	v_{lim}	± 1000	Limite de velocidade
Gradiente	ite	25	Número de iterações
	$\alpha_{g\,inic}$	40000	Passo inicial
	$\alpha_{g\,min}$	10e-6	Passo mínimo
	δ	10e-4	Perturbação

A Tabela 1, mostra os valores de parâmetros utilizados em todas as simulações. Efetuaram-se as escolhas dos parâmetros com base em testes de sensibilidade dentro da faixa de valores recomendados na literatura.

2.5 Sistema IEEE 13 barras

O sistema de distribuição escolhido para avaliação dos algoritmos é o sistema IEEE 13 barras, mostrado na Figura 3 (Kersting, 2001). Este alimentador apresenta uma demanda total de 3,4 MW e 2,1 kVAr, em 4,16 kV. As perdas no caso base, isto é, sem a presença de GD, são de 111,06 kW.

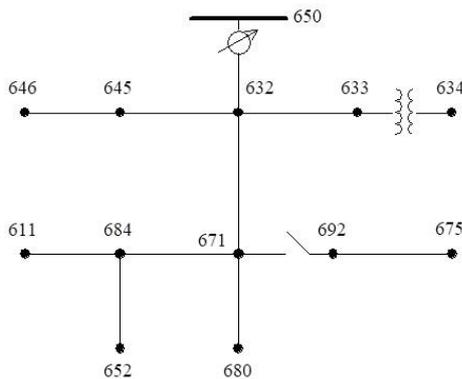


Fig. 3: Sistema IEEE 13 barras (Kersting, 2001).

3. RESULTADOS E DISCUSSÕES

Os resultados presentes nesta seção advêm da inserção de duas unidades de GD no alimentador IEEE 13 barras. O problema da alocação não é abordado neste trabalho. Portanto, buscou-se na literatura por trabalhos que se propõem a estudar o problema de escolha das barras candidatas à conexão de GD neste rede.

Como pode ser visto em (Anwar and Pota, 2011), a metodologia de busca exaustiva mostra que a barra 675 é um local ótimo de alocação. Já em (Anwar and Pota, 2012), os autores utilizam o critério de alocar as fontes distribuídas nos barramentos mais carregadas do sistema. Portanto, as barras escolhidas para as simulações são as barras 675 e 671.

O limite de geração considerado para cada GD é de 3 MW, enquanto as tensões em todas as barras devem permanecer entre 0,93 e 1,05 conforme consta no Módulo 8 do PRODIST (ANEEL, 2017).

Toda a implementação computacional foi realizada nos ambientes dos *softwares* MATLAB 2010a e OpenDSS versão 8.3.5.1. As simulações foram executadas por meio do processador Intel® Core™ i5 1,60 GHz com 6 GB de memória RAM.

3.1 Análise de Perdas

Nesta seção, as perdas encontradas pelos algoritmos são apresentadas e analisadas. Cada algoritmo foi executado 100 vezes. Para o mapeamento das perdas por busca exaustiva, adotou-se a discretização da potência injetada pelas GDs em 80 kW. A Tabela 2 mostra a configuração de potência injetada, perdas e tempo de simulação para as metodologias em seu melhor resultado encontrado (dentre 100 repetições para PSO e Gradiente).

Tabela 2 – Melhor solução encontrada.

Algoritmo	Potência 671 (MW)	Potência 675 (MW)	Perdas (kW)	Tempo (s)
PSO	2,12	0,91	34,84	10
Gradiente	2,12	0,91	34,84	4
Busca Exaustiva	2,16	0,88	34,85	32,1

Em relação aos resultados presentes na Tabela 2, ressalta-se que, em se tratando do PSO, em cada uma das execuções o algoritmo contou com uma população inicial aleatória diferente. No caso do gradiente, o ponto de partida também é aleatório e distinto em cada uma das 100 simulações.

Tendo em vista as perdas do caso base (sem GD: 111 kW), nota-se uma redução significativa no valor das perdas ativas através das três ferramentas em comparação. Nota-se também que a melhor solução do PSO e gradiente são idênticas, sendo o mesmo valor de despacho para as barras e o mesmo valor de perdas encontrado. Porém, o PSO leva mais tempo por simulação em relação ao gradiente. Destaca-se também a dificuldade encontrada pela busca exaustiva analisando o tempo de simulação requerido, que é muito superior às demais ferramentas de otimização implementadas, mesmo com uma discretização de 80 kW. No caso de uma discretização menor, o que deixaria a metodologia mais precisa, o tempo de simulação passaria a ser proibitivo.

A Figura 4, apresenta de forma gráfica o comportamento das perdas de potência ativa em função da injeção de potência proveniente das GDs. Nota-se que tanto para valores próximos a zero quanto para valores próximos ao máximo

permitido (3 MW), as soluções tendem a perder qualidade, pois as perdas se elevam.

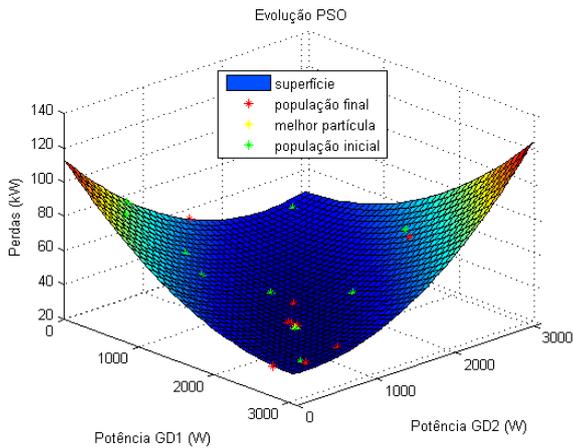


Fig. 4: Evolução do algoritmo PSO.

Na Figura 5, observa-se em cor rosa a solução inicial e em cor vermelha a solução final no espaço de busca. Nota-se a evolução da posição para a região mais escura do gráfico, região cujos valores de perdas são mais baixos.

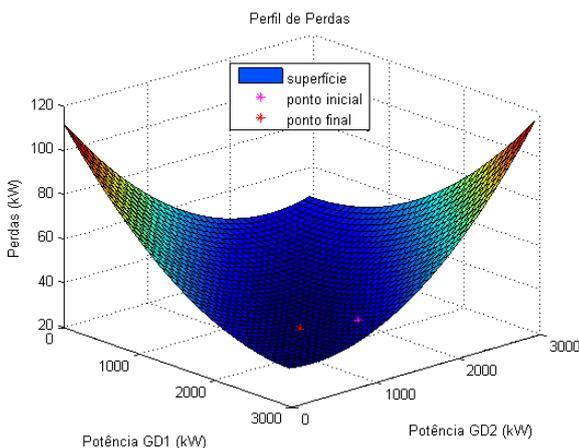


Fig. 5: Evolução Gradiente Descendente.

A Figura 6 apresenta a *box plot* com a dispersão dos dados de perdas provenientes das 100 simulações realizadas, tanto para o PSO quanto para o gradiente descendente.

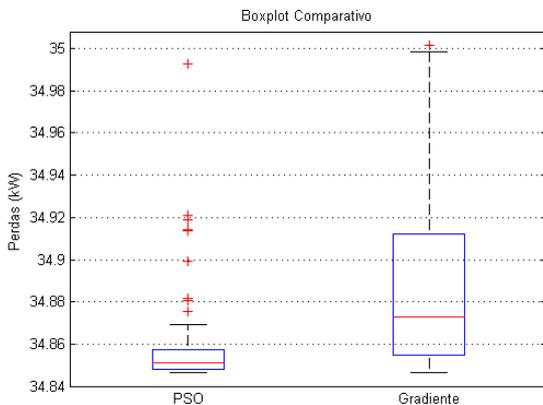


Fig. 6 *Box Plot*: dados de perdas encontrados pelo PSO e Gradiente nas 100 simulações.

Nota-se que o PSO apresenta-se como uma ferramenta mais confiável, pois, apesar de mais lento, as chances de se obter uma solução com perdas mais baixas é maior ao se executar apenas uma vez. Tal característica pode ser aferida dos gráficos pela menor dispersão total apresentada pelo PSO. A linha vermelha no interior dos diagramas representa a mediana do conjunto de 100 soluções finais obtidas pelos algoritmos.

3.2 Análise do Perfil de Tensão

Além da redução nas perdas de potência ativa, a melhoria no perfil de tensão também é um dos potenciais benefícios proporcionados pela inserção de GD nos sistemas de distribuição de energia elétrica.

A Figura 7 apresenta os níveis de tensão nas barras, por fase, em relação à distância da subestação. Nota-se que para o caso base, ou seja, o sistema trifásico desequilibrado sem alocação de GD, algumas tensões de algumas fases violam o limite inferior recomendado pela ANEEL neste nível de tensão, que é de 0,93 pu.

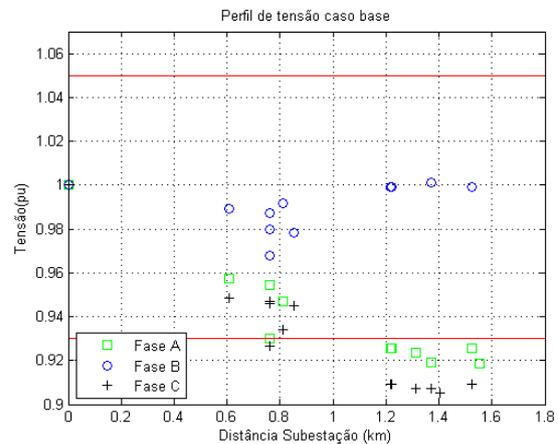


Fig. 7: Perfil de tensão sistema simples IEEE 13 barras.

Pela análise das figuras 8 e 9, constata-se que com a otimização dos montantes de potência despachados pelas GDs, as tensões em todas as fases, de todas as barras, estão dentro dos limites recomendados.

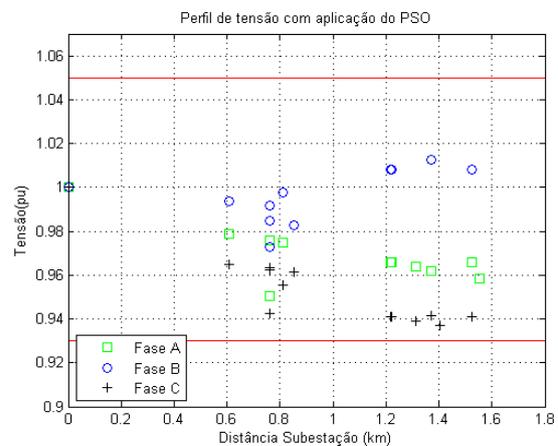


Fig. 8: Perfil de tensão para a melhor solução PSO.

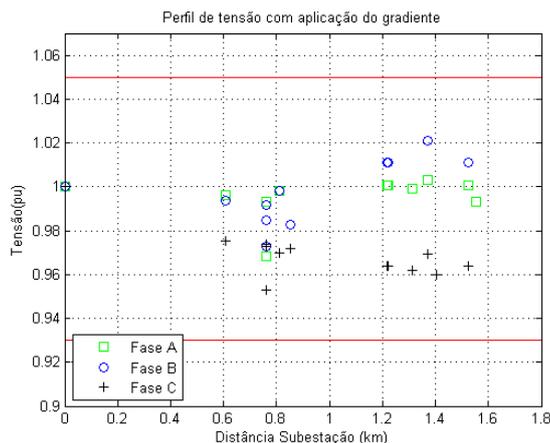


Fig. 9: Perfil de tensão para a melhor solução Gradiente.

Observa-se também que, assim como no caso base, a fase C é a que apresenta os menores níveis de tensão, indicando que se trata da fase com o maior carregamento neste sistema. A fase B, por conseguinte, tem menos clientes conforme a distância da subestação aumenta.

4. CONCLUSÕES

Conforme apresentado na introdução, o problema do despacho ótimo de Geração Distribuída se coloca como atual e de grande relevância no que se refere à operação eficiente das redes de distribuição de energia elétrica.

Dada a formulação do problema, as duas técnicas de otimização implementadas se mostraram eficazes, produzindo resultados de qualidade, isto é, baixos valores de perdas e tensões adequadas. Apesar de ambas eficazes, o PSO chegou a valores melhores para as perdas nas simulações repetitivas. No entanto, o algoritmo do gradiente descendente se mostrou capaz de realizar a busca em menor tempo computacional.

Como trabalhos futuros, a exploração de outras técnicas de otimização, assim como o despacho de múltiplas unidades de GD são possíveis alternativas. Adicionalmente, a obtenção de dados do sistema de distribuição junto à concessionárias de energia também se mostra como uma grande possibilidade para o desenvolvimento de uma pesquisa aplicada.

REFERÊNCIAS

ANEEL. (2017), “Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST Módulo 8 – Qualidade de Energia Elétrica - Revisão 10”, *Procedimentos de Distribuição de Energia Elétrica No Sistema Elétrico Nacional – PRODIST*.

ANEEL. (2018), “Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST Módulo 1 – Introdução - Revisão 10”.

Anwar, A. and Pota, H.R. (2011), “Loss reduction of power distribution network using optimum size and location of distributed generation”, *Universities Power Engineering Conference (AUPEC), 2011 21st Australasian*, IEEE, Brisbane, QLD, Australia, pp. 1–6.

Anwar, A. and Pota, H.R. (2012), “Optimum capacity allocation of DG units based on unbalanced three-phase optimal power flow”, *2012 IEEE Power and Energy Society General Meeting*, IEEE, pp. 1–8.

Coelho, F.C.R. (2013), “Alocação de Geração Distribuída em Sistemas de Distribuição de Energia Elétrica via Otimização Bioinspirada na Ecolocalização de Morcegos”, Universidade Federal de Juiz de Fora, Juiz de Fora.

Dugan, R.C. and McDermott, T.E. (2011), “An open source platform for collaborating on smart grid research”, *2011 IEEE Power and Energy Society General Meeting*, IEEE, pp. 1–7.

Hadidian-Moghaddam, M.J., Arabi-Nowdeh, S., Bigdeli, M. and Azizian, D. (2018), “A multi-objective optimal sizing and siting of distributed generation using ant lion optimization technique”, *Ain Shams Engineering Journal*, Ain Shams University, Vol. 9 No. 4, pp. 2101–2109.

Jobanputra, J. and Kotwal, C. (2018), “Optimal Power Dispatch using Particle Swarm Optimization”, *Proceedings - 2018 International Conference on Smart Electric Drives and Power System, ICSEDPS 2018*, IEEE, pp. 157–161.

Kersting, W.H. (2001), “Radial distribution test feeders”, *Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference*, Vol. 2 No. WINTER MEETING, pp. 908–912.

Liu, W., Zhuang, P., Liang, H., Peng, J. and Huang, Z. (2018), “Distributed Economic Dispatch in Microgrids Based on Cooperative Reinforcement Learning”, *IEEE Transactions on Neural Networks and Learning Systems*, IEEE, Vol. 29 No. 6, pp. 2192–2203.

Moradi, M.H. and Abedini, M. (2010), “Optimal multi-distributed generation location and capacity by genetic algorithms”, *PEOCO 2010 - 4th International Power Engineering and Optimization Conference, Program and Abstracts*, IEEE, No. June, pp. 440–444.

Murty, V.V.S.N. and Kumar, A. (2015), “Optimal placement of DG in radial distribution systems based on new voltage stability index under load growth”, *International Journal of Electrical Power & Energy Systems*, Elsevier Ltd, Vol. 69, pp. 246–256.

Sabarinath, G. and Manohar, T.G. (2018), “Optimal placement and sizing of distributed generation using flower pollination algorithm for power loss reduction maximization in distribution networks”, *2018 2nd IEEE International Conference on Power Electronics, Intelligent Control and Energy Systems, ICPEICES 2018*, IEEE, Vol. 3, pp. 253–256.

Takahashi, R.H.C. (2007), “Notas de Aula: Otimização Escalar e Vetorial”, Universidade Federal de Minas Gerais, Belo Horizonte.

Yang, X.-S. (2014), “Introduction to Algorithms”, *Nature-Inspired Optimization Algorithms*, Elsevier, pp. 1–21.