

Alocação de Geração Distribuída Solar Fotovoltaica via NSGA-II e PSO Binário: Uma Formulação Multiobjetivo Considerando Fluxo de Potência Trifásico Desequilibrado e Sequencial no Tempo

João Paulo G. Andrade*. Francisco C. R. Coelho*. Wesley Peres*

*Departamento de Engenharia Elétrica, Universidade Federal de São João del-Rei
36307-352, Praça Frei Orlando, 170, São João del-Rei, MG, Brasil
(jpgomes17@hotmail.com. franciscocoelho@ufsj.edu.br. wesley.peres@ufsj.edu.br)

Abstract: Distributed Generation (DG) impacts the electric distribution system in several regards. Studies has been conducted aiming at potential operational benefits. This work presents a multiobjective formulation for the photovoltaic DG allocation problem, to be solved by two metaheuristic algorithms: The Non-Dominated Sorting Genetic Algorithm II (NSGA-II), and the binary version of Particle Swarm Optimization (PSO) combined with weighted sum. By means of these two methods, two Pareto fronts are built, taking into account the energy loss minimization along a week and minimizing the number of inserted photovoltaic systems. Among the considered constraints of the optimization problem, the voltages in all buses, all phases, during all the period of simulation, are restricted to the Brazilian regulatory agency pre-defined limits. The time series unbalanced power flow is performed by the OpenDSS software. The proposed methodology is applied to the IEEE 123 bus network, considering the allocation of three-phase DGs only. Through Pareto front and two performance metrics analysis, it can be seen that NSGA-II outperforms the binary PSO for the present problem formulation.

Resumo: A Geração Distribuída (GD) produz diversos impactos na rede de distribuição de energia elétrica. Muitos estudos vêm sendo realizados, com o intuito de se aproveitar seus potenciais benefícios operacionais. Este trabalho apresenta uma formulação multiobjetivo para o problema da alocação de GD solar fotovoltaica, a ser resolvido por dois algoritmos metaheurísticos de otimização: o *Non-Dominated Sorting Genetic Algorithm II* (NSGA-II) e o *Particle Swarm Optimization* (PSO) binário, associado à soma ponderada para escalarização do problema. Por meio dos dois algoritmos, duas fronteiras de Pareto são construídas, tendo como objetivos a minimização das perdas de energia ao longo de uma semana e a minimização do número de unidades de GD inseridas no sistema. Dentre as restrições consideradas, restringem-se as magnitudes de tensões em todas as fases, de todas as barras, em todo o período simulado, dentro dos limites pré-estabelecidos pela ANEEL. Para cálculo do fluxo de potência trifásico desequilibrado, sequencial no tempo, emprega-se o *software* OpenDSS. A validação da metodologia é realizada através de simulações com alocação de GDs trifásicas no sistema IEEE de 123 barras. Através da análise das fronteiras de Pareto e de duas métricas de performance, nota-se relativa superioridade do NSGA-II em relação ao PSO para o problema apresentado.

Keywords: Distributed Generation; Photovoltaic Energy; Time Series Power Flow; Pareto Front; Energy Losses; NSGA-II; PSO; OpenDSS.

Palavras-chaves: Geração Distribuída; Energia Solar Fotovoltaica; Fluxo de Potência Sequencial no Tempo; Fronteira de Pareto; Perdas de Energia; NSGA-II; PSO; OpenDSS.

1. INTRODUÇÃO

A definição de Geração Distribuída (GD) pode variar de acordo com o país e com a entidade definidora. No Brasil, de acordo com a ANEEL, a GD se divide em duas categorias, para efeitos práticos: a microgeração distribuída, que se caracteriza por uma potência instalada de 75 KW e que utilize cogeração qualificada ou fontes renováveis de energia; e a minigeração distribuída, com potência instalada superior a 75 KW e inferior a 3 MW para fontes hídricas e inferior ou igual a 5 MW para cogeração qualificada ou fontes renováveis de energia. Consideram-se ambas as categorias conectadas na rede de

distribuição por meio de instalações de unidades consumidoras (ANEEL, 2015).

Diversos países têm se mobilizado na direção de ceder incentivos para a aquisição de GD por parte dos consumidores (Ramírez *et al.*, 2017). Estes estímulos se justificam pelos potenciais benefícios que a GD pode proporcionar ao sistema elétrico e à sociedade como um todo. Dentre os benefícios almejados, constam o adiamento de investimentos em expansão dos sistemas de transmissão e distribuição, a redução de impactos ambientais, a redução no carregamento das redes, a diminuição das perdas de energia e a diversificação da matriz energética.

No entanto, devido ao aumento da complexidade da operação da rede de distribuição na presença de GD, necessita-se de um planejamento cuidadoso por parte das empresas distribuidoras de energia elétrica. Além dos potenciais benefícios previamente citados, a inserção de GD de forma não planejada pode acarretar em situações operativas indesejadas, como o aumento das perdas de energia e sobretensão (Viral and Khatod, 2012).

O problema da alocação de GD no sistema de distribuição pode ser formulado considerando diferentes objetivos, restrições e variáveis de decisão. Além do fato de que o problema pode ser abordado da perspectiva das distribuidoras, consumidores, entidades regulatórias, etc. Em meio aos objetivos comumente perseguidos, encontram-se a minimização das perdas de energia e dos custos de implantação das unidades geradoras.

Em geral, a formulação matemática do problema recai em um problema de otimização multimodal, não linear, inteiro misto (isto é, com variáveis inteiras e contínuas). Nestas condições, técnicas inteligentes como meta-heurísticas são comumente encontradas na literatura para a resolução dos problemas. A principal motivação para o emprego destas técnicas decorre da sua flexibilidade para tratar problemas multimodais (Coelho, 2018). Técnicas clássicas de otimização tendem a ficar estagnadas em ótimos locais e ter problemas com descontinuidades na função objetivo ou restrições (Takahashi, 2007).

Devido à existência de objetivos conflitantes, alguns trabalhos apresentam formulações multiobjetivo para o problema. Uma das estratégias, neste caso, é a obtenção da fronteira de Pareto através de algoritmos como o *Non-Dominated Sorting Genetic Algorithm II* (NSGA-II) usado em (Liu *et al.*, 2019) e o NSGA-III usado em (Ali, Mohamed and Hemeida, 2019), onde os objetivos considerados são a redução das perdas de energia e do desvio de tensão, e de um índice de estabilidade de tensão.

Outros objetivos também são estudados, como em (Prakash, Lokeshgupta and Sivasubramani, 2018), que utiliza o *Multi-Objective Bat Algorithm* (MOBA) para construir a fronteira de Pareto. Neste trabalho, considera-se a minimização dos seguintes objetivos conflitantes: custos da GD e as perdas de energia ativa. No trabalho de (Ben Hamida *et al.*, 2019) propõe-se um modelo cujos objetivos contemplam os custos de implantação e operação das GDs, as perdas de energia e a emissão de gases poluentes.

O objetivo deste trabalho é abordar o problema da alocação de GD solar fotovoltaica sob uma perspectiva multiobjetivo, considerando curvas de carga semanais no IEEE 123 barras, que é um sistema de distribuição trifásico desequilibrado. Para cálculo do fluxo de potência trifásico, sequencial no tempo, utiliza-se o *software* OpenDSS. Empregam-se os algoritmos de otimização NSGA-II e *Particle Swarm Optimization* (PSO), ambos implementados em ambiente MATLAB. Este último, adaptado para resolução de problemas multiobjetivo através da soma ponderada. Consideram-se dois objetivos conflitantes: (i) minimização das perdas de energia ao longo de uma semana; (ii) minimização do número de GDs (painéis fotovoltaicos) conectados. Apesar dos custos dos painéis não

serem considerados nos cálculos, supõe-se que estes sejam proporcionais ao número de unidades de GD inseridas na rede. Portanto, duas fronteiras de Pareto são construídas, uma para cada meta-heurística.

A fronteira de Pareto é composta pelas chamadas soluções eficientes (não dominadas), que representam um conjunto de soluções possíveis para escolha do tomador de decisões (normalmente, apenas uma solução pode ser implantada, na prática). Com o intuito de se comparar o desempenho do NSGA-II com o PSO adaptado, serão utilizadas duas métricas de performance: a Métrica 1 (M1), que determina o número de soluções não dominadas obtidas; e a Métrica 2 (M2), que denota a proximidade das soluções obtidas a um vetor ideal.

2. METODOLOGIA

2.1 Formulação Matemática do Problema

Na formulação aqui apresentada, considera-se a alocação de múltiplas unidades fotovoltaicas, cujo fator de potência é unitário. Como objetivo, deseja-se minimizar as perdas de energia ao longo do tempo (f_1) e o número de painéis solares inseridos na rede (f_2), mantendo as tensões nodais dentro dos limites pré-estabelecidos. Ressalta-se que f_1 é função de f_2 , ou seja, a depender da configuração de GDs na rede, as perdas se alteram. A seguir, a formulação matemática do problema de otimização é mostrada, sendo a Equação (1) a função objetivo (FOB).

$$\text{Minimizar } f_1 = \sum_{t=1}^T P_L^t, \quad f_2 = \sum_{j=1}^{nbus} GD_j \quad (1)$$

Sujeito a:

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

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

$$GD_j = \begin{cases} 0, & \text{sem GD} \\ 1, & \text{com GD} \end{cases} \quad (4)$$

$$V_j^{min} \leq V_j^{t,ph} \leq V_j^{max} \quad (5)$$

Sendo:

P_L^t Perdas de potência ativa do sistema, no cenário de operação t (kW).

GD_j Variável que indica o status de conexão de GD na barra j .

$nbus$ Número de barras do sistema.

$P_{GDj}^{t,ph}$ Potência ativa injetada pela GD na barra j , no cenário de operação t , na fase ph (kW).

$P_{Gj}^{t,ph}$ Potência ativa gerada na barra j , previamente a conexão de GD, no cenário de operação t , na fase ph (kW).

P_{Dj}^t	Potência ativa demandada na barra j , no cenário de operação t , na fase ph (kW).
$f_{Pjk}^{t,ph}$	Fluxo de potência ativa da barra k para a barra j , no cenário de operação t , na fase ph (kW).
$Q_{Gj}^{t,ph}$	Potência reativa gerada na barra j , previamente a conexão de GD, no cenário de operação t , na fase ph (kvar).
$Q_{Dj}^{t,ph}$	Potência reativa demandada na barra j , no cenário de operação t , na fase ph (kvar).
$f_{Qjk}^{t,ph}$	Fluxo de potência reativa da barra k para a barra j , no cenário de operação t , na fase ph (kvar).
$V_j^{t,ph}$	Magnitude de tensão na barra j , cenário de operação t , fase ph (kV).
V^{min}	Limite inferior da magnitude de tensão, por fase (kV).
V^{max}	Limite superior da magnitude de tensão, por fase (KV).

As equações (2) e (3) são referentes ao balanço de potência ativa e reativa nas barras do sistema, por fase, em cada cenário de operação, respectivamente. A equação (4) representa os dois estados de conexão das GDs, presentes, ou não, nos barramentos da rede. A Equação (5) restringe os níveis da magnitude de tensão aos limites pré-estabelecidos.

Para realização do cálculo do fluxo de potência sequencial no tempo, utiliza-se aqui o *software* OpenDSS (Dugan and McDermott, 2011). Ressalta-se que a ANEEL, por meio de sua nota técnica nº 0104/2014-SRD, estabelece este *software* como a ferramenta recomendada para realização de estudos de fluxo de potência e de cálculo de perdas regulatórias por parte das distribuidoras de energia elétrica brasileiras (ANEEL, 2014).

Por meio da convergência de sua metodologia de cálculo de fluxo de potência trifásico, OpenDSS garante as restrições de igualdade presentes nas equações (2) e (3). A variável de decisão GD_j , presente na equação (4) é determinada pelo algoritmo de otimização. A forma de tratamento da restrição presente na Equação (5) será apresentada na subseção 2.4.

2.2 NSGA – II

Em se tratando de algoritmos de otimização multiobjetivo, o NSGA-II (Deb *et al*, 2002) é uma das técnicas mais usadas na literatura. Seu mecanismo de busca é semelhante ao do algoritmo genético tradicional (Holland, 1992) com diferença no cálculo de aptidão, que é realizado por ordem de dominância, sendo a população classificada em categorias com ordem de não dominados para dominados. Adicionalmente, nota-se uma importante diferença no que diz respeito às distâncias calculadas entre as soluções. Dado que soluções eficientes não são, por si só, umas melhores que as outras, aplica-se o critério de isolamento para classificá-las. Quanto mais esparsa a solução, melhor ela é considerada. Este mecanismo confere diversidade ao conjunto de soluções, ou população.

As etapas de processamento do NSGA-II são descritas no pseudocódigo da Figura 1. Cada solução proposta pelo algoritmo consiste em um vetor binário, cuja dimensão é dada pelo número de barras do sistema. Neste vetor/solução, consta “1” nas barras com GD e “0” nas barras sem GD.

```

1 Gere a População
2 Para 1 : número máximo de gerações faça
3   Selecione os Pais da População
4   Crie a População dos Filhos através dos Pais (cruzamento)
5   Aplique a mutação nos Filhos
6   Combine a População e População dos Filhos em População Atual
7   Para todos indivíduos em População Atual faça
8     Atribua rank baseado na não-dominância de Pareto
9   Fim para
10  Gere o conjunto das soluções não-dominadas de Pareto
11  Calcule a distância entre as soluções
12  Atualize a População inserindo as melhores soluções
13 Fim para
14 Retorne os resultados

```

Figura 1 - Pseudocódigo da meta-heurística NSGA-II (adaptado de Lacerda A.R.S. *et al*, 2016).

2.3 PSO

O PSO é um algoritmo de otimização que modela o comportamento social de enxames (Kennedy and Eberhart, 1995). O mesmo foi proposto originalmente como uma técnica de otimização para variáveis de decisão contínuas. Porém, existem problemas de otimização cujo modelo envolve variáveis discretas, a exemplo, o posicionamento de GD na rede de distribuição (ou se conecta GD em determinada barra, ou não). Desta forma, (Kennedy and Eberhart, 1997) adaptaram o algoritmo PSO para operar com variáveis binárias no domínio discreto. A estratégia do algoritmo fundamenta-se em procurar no espaço de busca da função objetivo, ajustando os movimentos das partículas em dois componentes principais: um componente aleatório e um componente determinístico. Essa estratégia é modelada pela equação (6).

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

De (Yang, 2014), os valores de ϵ_1 e ϵ_2 variam de forma aleatória entre 0 e 1. Os parâmetros α e β são parâmetros de aprendizagem global e local, respectivamente. A constante de inércia θ pode variar entre os valores 0 e 1, tipicamente é escolhido valores próximos a 1. A variável $gbest$ representa a melhor partícula global e a variável $xbest$ representa a melhor localização de uma determinada partícula dentro do seu histórico de posições ocupadas.

Nesta versão do PSO, cada dimensão da partícula/solução é forçada a assumir o valor 0 (zero) ou 1 (um), conforme mostrado nas equações (7) e (8). Desta forma cada partícula irá corresponder ao vetor de alocação mencionado anteriormente.

$$\text{sigmoide}(v_{ij}^{t+1}) = \frac{1}{1 + e^{-v_{ij}^{t+1}}} \quad (7)$$

$$x_{ij}^{t+1} = \begin{cases} 1, & \text{se } \text{rand} < \text{sigmoide}(v_{ij}^{t+1}) \\ 0, & \text{caso o contrário} \end{cases} \quad (8)$$

A Figura 2 descreve as etapas de processamento do chamado PSO binário.

- 1 Iniciar a posição de cada partícula x_{ij} e as velocidades v_{ij}
- 2 Encontrar g_{best} e x_{best}
- 3 **Para** $t = 1$: número máximo de interações **faça**
- 4 Gerar uma nova velocidade v_{ij}^{t+1} usando a Equação (6)
- 5 Atualizar a posição de cada partícula x_{ij}^{t+1} usando a Equação (8)
- 6 Avaliar a função objetivo
- 7 Atualizar x_{best}
- 8 Atualizar g_{best}
- 9 **Fim para**
- 10 Retorne os resultados

Figura 2 - Pseudocódigo da meta-heurística PSO binário (adaptado de Khanesar, Teshnehlab and Shoorehdeli, 2007).

Como a formulação aqui apresentada é multiobjetivo, também chamada de otimização vetorial, emprega-se o método da soma ponderada para escalarização do problema multiobjetivo original, transformando-o em um problema mono-objetivo ponderado (Aliano Filho, 2016). Desta forma, é possível resolver o problema através do PSO, que por natureza otimiza um único objetivo por vez. Assumindo as funções normalizadas, as equações (9) e (10) mostram como é formulado o problema, neste caso.

$$\text{Minimize } z = \sum_{k=1}^r w_k * f_k(x) \quad (9)$$

$$\sum_{k=1}^r w_k = 1, \text{ onde } w_k \in [0,1] \quad (10)$$

Sendo x a variável de decisão, r o número de funções objetivo e w_k o peso para cada um dos objetivos. Pela variação dos pesos associados a cada função, permite-se a obtenção de diferentes soluções eficientes para a composição da fronteira de Pareto.

2.4 OpenDSS: Modelo do Sistema Fotovoltaico e Cooperação com o MATLAB

A Figura 3 mostra o modelo esquemático do sistema fotovoltaico implementado no OpenDSS. Este modelo apresenta uma potência ativa injetada no ponto de interconexão que é em função da irradiação, temperatura, eficiência do conversor, tensão da rede e potência nominal no ponto de máxima potência (P_{mp}) (Freitas, 2015).

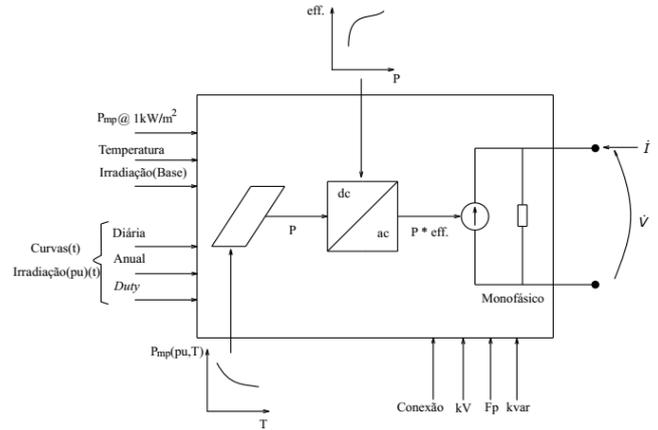


Figura 3 - Diagrama esquemático do painel fotovoltaico no OpenDSS (Freitas, 2015).

As Figuras 4 e 5 apresentam respectivamente as curvas diárias de irradiação e de temperatura inseridas no modelo de painel fotovoltaico do OpenDSS, para fins de cálculo da potência injetada na rede.

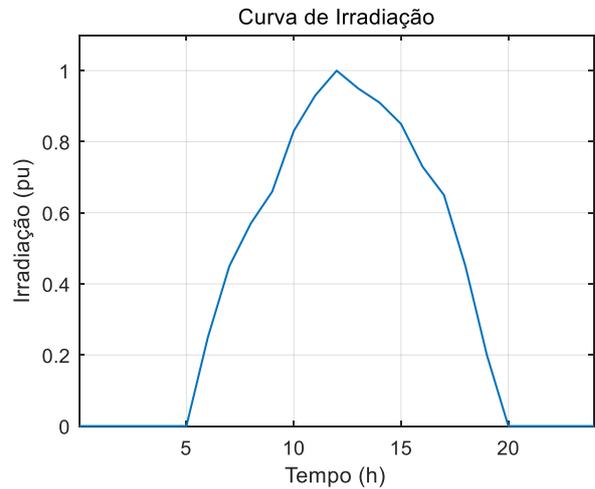


Figura 4 - Curva de irradiação diária.

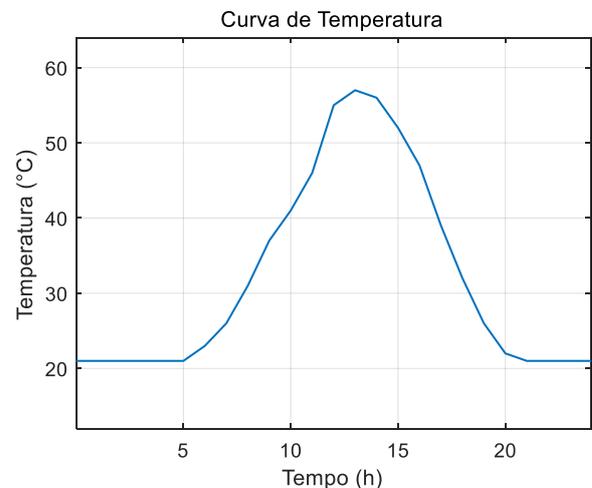


Figura 5 - Curva de temperatura diária.

A cooperação entre o OpenDSS e o MATLAB pode ser dividida em duas etapas, como se observa na Figura 6. Na primeira etapa, são propostas configurações de alocação de GD através do NSGA-II ou do PSO + Soma ponderada, a depender de qual algoritmo está sendo executado. Na sequência, estas informações são repassadas para o OpenDSS, que calcula o fluxo de potência trifásico desequilibrado sequencial no tempo, considerando a proposta de conexão de GDs vinda do algoritmo de otimização. Para avaliação das soluções propostas, as meta-heurísticas necessitam de informações para realização do cálculo da FOB. Estas informações correspondem às perdas de energia resultantes daquela conexão de GDs e das magnitudes das tensões nodais para penalização da FOB, como será mostrado a seguir.

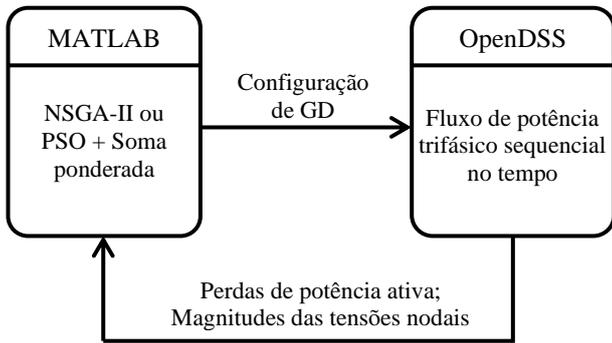


Figura 6 - Diagrama da cooperação entre MATLAB e OpenDSS (adaptado de (Coelho, 2018)).

Os limites da magnitude de tensão, presentes na Equação (5), são incorporados ao NSGA-II e PSO através da penalização da FOB. Se a magnitude de tensão de determinada fase ultrapassar V_{max} ou V_{min} , será somada à função objetivo uma penalização, descrita matematicamente na Equação (11), em que T corresponde ao total de pontos simulados no tempo. Ressalta-se que este cálculo só é ativado no caso da existência de extrapolações das magnitudes de tensões para determinada configuração de GDs. No Brasil, de acordo com a ANEEL, a magnitude de tensão mínima permitida é de 0,93 pu e a magnitude de tensão máxima permitida é de 1,05 pu (ANEEL, 2018).

$$pen = \exp\left(\sum_{t=1}^T \sum_{j=1}^{nbus} \sum_{ph=1}^3 \left|V_j^{t,ph} - \frac{V_{max} + V_{min}}{2}\right|\right) \quad (11)$$

A proposta deste método é penalizar de maneira proporcional as configurações de GD que ultrapassem os limites da magnitude de tensão. Ou seja, quanto maior o número de barras que ultrapassam os limites, e com maior intensidade, maior será o valor adicionado à função objetivo, que se deseja minimizar, evitando assim soluções cujos bons valores de perdas, por exemplo, acarretem em tensões inadequadas. A penalização exponencial, assim como o desvio da média, foram determinados de forma empírica, através de simulações e análises de resultados durante o desenvolvimento do trabalho.

2.5 Métricas de Performance para Avaliação das Meta-heurísticas

Para problemas de otimização multiobjetivo, a avaliação da qualidade das soluções é mais complexa em relação a problemas de otimização mono-objetivo. Diferentes métricas de performance avaliam diferentes características do conjunto de soluções eficientes apresentado. Assim, a interpretação adequada dos resultados de determinada métrica depende da compreensão de seus mecanismos de cálculo. Tendo em vista que as métricas são diferentes, recomenda-se a aplicação de mais de uma para que os resultados sejam avaliados com consistência. Neste trabalho, empregam-se duas métricas.

A Métrica 1 (M1) determina o número de soluções presentes na fronteira de Pareto obtida pelo algoritmo de otimização. Quanto maior o número de soluções eficientes, melhor é a avaliação do método. A Métrica 2 (M2) denota uma distância inversa acumulada específica das soluções não dominadas e normalizadas com relação à origem (Aliano Filho *et al.*, 2019). Seu cálculo é mostrado na Equação (12).

$$M2 = \sum_{j=1}^n \frac{1}{\|\bar{z}^j\|} \quad (12)$$

Sendo $\|\cdot\|$ é a distância euclidiana entre a solução e a origem. O parâmetro n é o número de soluções no conjunto não dominado e \bar{z}^j são as soluções normalizadas, calculadas através da Equação (13).

$$\bar{z}_i^j = \frac{z_i^j}{\max\{z_i^j\} - \min\{z_i^j\}}, i = 1, 2. \quad (13)$$

Onde z_i^j é a imagem das soluções do conjunto não dominado, com i representando o índice dos objetivos (Neste problema, f_1 e f_2). A proposta dessa métrica é quantificar a distância da fronteira de Pareto a um determinado ponto ideal, que nesse caso é a origem. Como M2 utiliza a distância inversa, isto significa que quanto maior o seu valor, mais próxima à fronteira de Pareto está em relação ao ponto ideal.

3. RESULTADOS E DISCUSSÕES

O objetivo dessa seção é apresentar os resultados decorrentes da implementação da metodologia proposta para resolver o problema de alocação de GD. O estudo consiste na inserção de painéis fotovoltaicos, com fator de potência unitário e com potência nominal no ponto de máxima potência de 1 MW, nas barras trifásicas do sistema IEEE de 123 barras. Tendo em vista o período de uma semana de simulação, discretizado em intervalos de uma hora, deseja-se minimizar as perdas de energia da rede empregando o menor número possível de painéis fotovoltaicos.

O sistema IEEE de 123 barras possui demanda de 3,49 MW e 1,92 Mvar (IEEE, 2014). No caso base, isto é, sem a presença de GD, a rede apresenta perdas de 16,25 MWh ao longo da semana simulada. A topologia do sistema é apresentada na Figura 7.

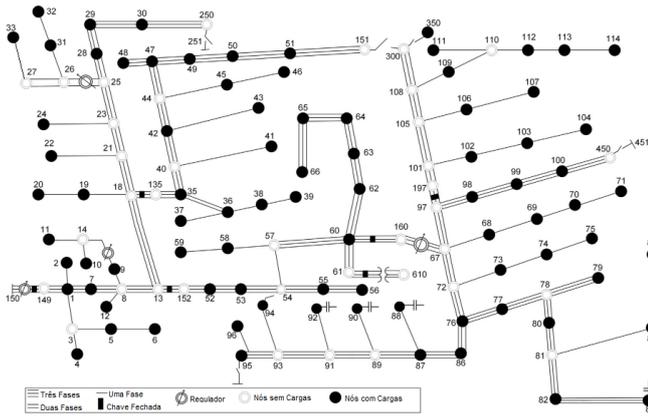


Figura 7 – Topologia do sistema trifásico IEEE de 123 barras. Fonte: (Dahal and Salehfar, 2016).

Como consumidores diferentes apresentam característica de consumo diferentes, discriminaram-se duas classes de consumo para realização das simulações: Consumidor residencial e consumidor industrial. Com exceção das cargas das barras 47 e 48, consideradas industriais, todas as outras foram consideradas residenciais. Além desta divisão, cada tipo de consumidor se comporta de forma diferente a depender do dia da semana. Por este motivo, as curvas de carga são divididas em três conjuntos: (i) Dias comuns (ou “de feira”); (ii) Sábados; e (iii) Domingos e feriados. As curvas de carga utilizadas são mostradas nas figuras 8 a 10.

Toda a implementação computacional foi realizada nos softwares MATLAB 2010a e OpenDSS, em um processador Intel® Core™ i3, 1.70 GHz e 4 GB de memória RAM. Em cada algoritmo de otimização, foram utilizados 80 indivíduos para realizar a busca ao longo de 60 interações. No algoritmo PSO binário, o peso 1 (p_1) da função perdas de energia elétrica e o peso 2 (p_2) da função quantidade de GD alocadas no sistema foram se modificando ao longo da simulação, sendo $p_1 = 0,2$ e $p_2 = 0,8$; $p_1 = 0,3$ e $p_2 = 0,7$; $p_1 = 0,4$ e $p_2 = 0,6$; $p_1 = 0,5$ e $p_2 = 0,5$; $p_1 = 0,6$ e $p_2 = 0,4$; $p_1 = 0,7$ e $p_2 = 0,3$ e $p_1 = 0,8$ e $p_2 = 0,2$, totalizando sete conjuntos de pesos. Após essa etapa os dados foram analisados usando relação de dominância para a construção da fronteira de Pareto.

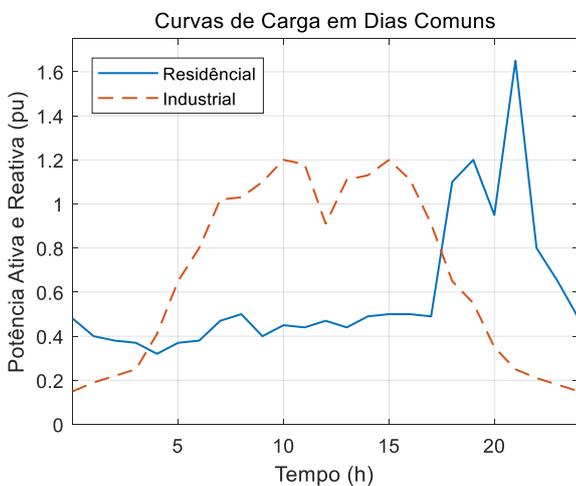


Figura 8 - Curvas de carga em dias comuns.

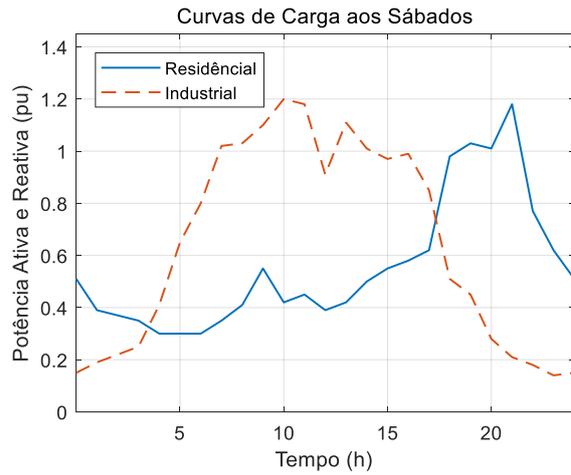


Figura 9 - Curvas de carga aos sábados.

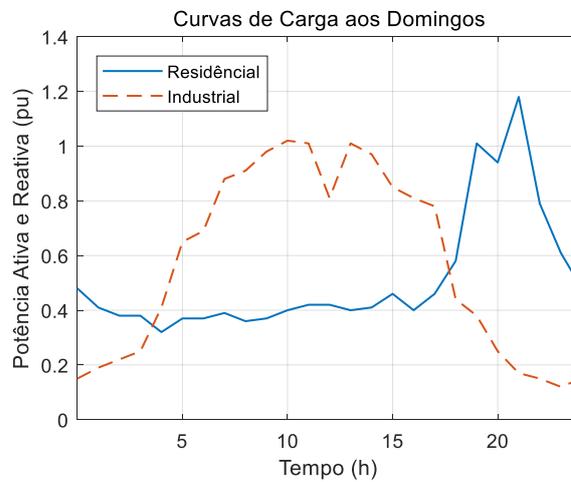


Figura 10 - Curvas de carga aos domingos e feriados.

A Tabela 1 mostra os valores utilizados para os parâmetros dos algoritmos NSGA-II e PSO, que foram escolhidos com base nos trabalhos de (Prakash and Sujatha, 2017) e (Sheng *et al*, 2015) respectivamente.

Tabela 1 - Parâmetros dos Algoritmos

Algoritmo	Parâmetro	Valor	Descrição
PSO	α	2,3	Aprendizagem global
	β	2,5	Aprendizagem local
	θ	0,9	Fator de inércia
NSGA-II	fm	0,25	Fator de mutação
	fc	0,9	Fator de cruzamento

As Figuras 11 e 12 exibem as fronteiras de Pareto obtidas com as simulações do PSO e NSGA-II, respectivamente. Conforme evidenciado nos gráficos, a métrica M1 para o PSO é igual a 4 e para o NSGA-II é igual a 6, dando ao algoritmo NSGA-II uma pequena vantagem no quesito número de soluções eficientes.

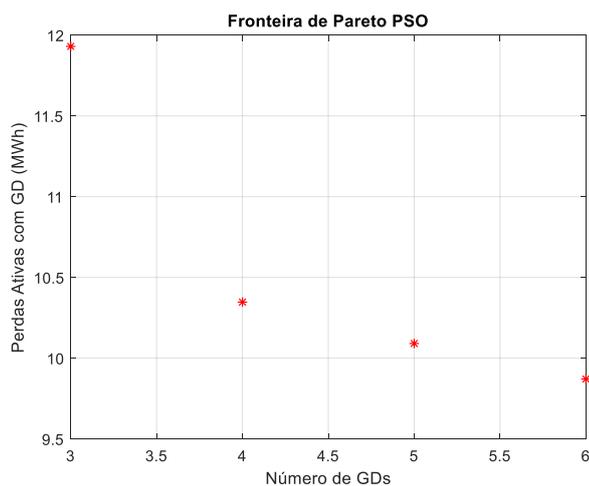


Figura 11 - Fronteira de Pareto – PSO.

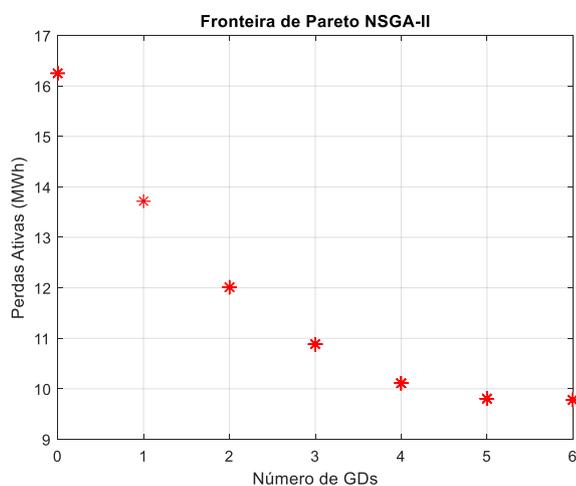


Figura 12 - Fronteira de Pareto - NSGA-II.

Em relação a métrica M2, que mensura a distância inversa acumulada das soluções eficientes a origem, o PSO obteve um valor de 0,7482 enquanto o NSGA-II obteve um valor de 3,6875, caracterizando o algoritmo NSGA-II como sendo mais eficiente para a resolução do problema aqui formulado.

Os resultados das métricas corroboram as informações que constam nos gráficos de fronteira, principalmente para o caso em que se inseriu 3 GDs na rede de distribuição através dos dois algoritmos. Neste caso, há uma diferença de redução de 1,04 MWh de perdas de energia, de forma favorável ao NSGA-II. Nota-se também que este, ao alocar 5 unidades de GD, obteve 9,80 MWh de perdas, enquanto o PSO obteve 9,87 MWh com 6 unidades, ou seja, com um custo mais alto. Outra questão que fica clara ao se analisar os gráficos é que os dois objetivos são, de fato, conflitantes: Ao baixar o número de GDs conectadas há uma tendência de crescimento no valor das perdas de energia.

A Tabela 2 mostra as barras escolhidas onde as GDs serão alocadas e as reduções das perdas ativas de energia para cada solução da fronteira e para ambos os métodos utilizados.

Tabela 2 - Barras Escolhidas e Reduções de Perdas

PSO		NSGA-II	
Barras escolhidas	Reduções de perdas (%)	Barras escolhidas	Reduções de perdas (%)
—	—	76	15,59
—	—	67, 76	26,08
18, 28, 160	26,58	44, 67, 76	33,02
50, 57, 64, 93	36,32	44, 63, 67, 76	37,77
40, 50, 54, 91, 79	37,90	25, 44, 63, 67, 76	39,65
29, 49, 53, 60, 67, 86	39,25	1, 25, 44, 63, 67, 76	39,81

4. CONCLUSÃO

Neste trabalho, propõe-se a utilização das meta-heurísticas NSGA-II e PSO binário para resolver um problema multiobjetivo de alocação de GD (em forma de painéis fotovoltaicos), em um sistema de distribuição de energia elétrica trifásico desequilibrado. Utilizando-se o *software* OpenDSS, as simulações contemplam curvas de carga industriais e residenciais ao longo de uma semana no IEEE 123 barras.

No estudo de caso apresentado, o NSGA-II foi mais eficiente em relação ao PSO considerando as duas métricas utilizadas. Isto é, a fronteira de Pareto obtida pelo NSGA se aproxima mais da origem, e existem mais soluções eficientes, ou não dominadas, disponíveis para o tomador de decisão, dado que em problemas de planejamento como o tratado aqui, apenas uma solução é adotada na prática.

A metodologia aplicada neste trabalho pode ser utilizada em trabalhos futuros considerando mais características reais deste tipo de problema. Como exemplo, seria possível a aplicação de incertezas nas cargas e na produção de energia solar, a inclusão de custos de investimento e operação dos painéis fotovoltaicos e a simulação do fluxo de potência ao longo de períodos mais longos. Desta forma, torna-se possível a produção de trabalhos de planejamento robustos e eficientes do ponto de vista econômico, energético e ambiental.

AGRADECIMENTOS

Os autores deste trabalho agradecem à Universidade Federal de São João del-Rei, à Pró-Reitoria de Pesquisa e Pós-Graduação da UFSJ e ao Programa Institucional de Desenvolvimento Acadêmico nas Ações Afirmativa da UFSJ.

REFERÊNCIAS

- Ali, S. M., Mohamed, A. A. A. and Hemeida, A. M. (2019) 'A Pareto Strategy based on Multi-Objective for Optimal Placement of Distributed Generation Considering Voltage Stability', *Proceedings of 2019 International Conference on Innovative Trends in Computer Engineering, ITCE 2019*. IEEE, (February), pp. 498–504. doi: 10.1109/ITCE.2019.8646383.
- Aliano Filho, A. et al. (2019) 'An exact scalarization method with multiple reference points for bi-objective integer linear optimization problems', *Annals of Operations Research*. Springer US. doi: 10.1007/s10479-019-03317-9.
- ANEEL (2015) 'Resolução Normativa no 687 de 2015 da ANEEL', p. 24.
- ANEEL (2018) 'Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional, Módulo 8: Qualidade de Energia', 8, p. 88. Available at: http://www.aneel.gov.br/documents/656827/14866914/Módulo_8-Revisão_10/2f7cb862-e9d7-3295-729a-b619ac6baab9.
- ANEEL - Agência Nacional de Energia Elétrica (2014) 'Nota Técnica no 0104/2014-SDR', Aneel.
- Ben Hamida, I. et al. (2019) 'A New Short-Term Planning Strategy for Multi-Objective Distribution Network Reconfiguration and Optimal DG Insertion', *Arabian Journal for Science and Engineering*. Springer Berlin Heidelberg, 44(8), pp. 6813–6826. doi: 10.1007/s13369-018-3645-9.
- Coelho, F. C. R. (2018) *Alocação de Geração Distribuída em Sistemas de Distribuição de Energia Elétrica Via Meta-heurística Empírica Discreta*. Universidade Federal de Juiz de Fora.
- Dahal, S. and Salehfar, H. (2016) 'Impact of distributed generators in the power loss and voltage profile of three phase unbalanced distribution network', *International Journal of Electrical Power and Energy Systems*. Elsevier Ltd, 77, pp. 256–262. doi: 10.1016/j.ijepes.2015.11.038.
- Deb, k. . P. A. . A. S. . M. T. (2002) 'A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II', *IEEE Transactions on Evolutionary Computation*, 6(2), pp. 182–197. doi: 10.1109/4235.996017.
- Dugan, R. C. and McDermott, T. E. (2011) 'An open source platform for collaborating on smart grid research', *IEEE Power and Energy Society General Meeting, (Ivvc)*, pp. 1–7. doi: 10.1109/PES.2011.6039829.
- Filho, A. A. (2016) 'Novas Extensões de Técnicas de Escalarizações no Problema de Corte Unidimensional Inteiro Multiobjetivo', p. 204, Tese de Doutorado.
- Freitas, P. R. R. de (2015) 'Modelos avançados de análise de redes elétricas inteligentes utilizando o software OpenDSS', pp. 1–189.
- Holland, J. H. (1992) *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. MIT Press.
- IEEE (2014) IEEE 123 Node Test Feeder Letterhead, Power System Analysis, *Computing and Economics Committee*.
- Kennedy, J. E. R. (1995) 'Particle Swarm Optimization', *Proceedings of ICNN'95 - International Conference on Neural Networks*, 4, pp. 1942–1948. doi: 10.1109/ICNN.1995.488968.
- Kennedy, J. and Eberhart, R. C. (1997) 'Discrete binary version of the particle swarm algorithm', *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics*, 5, pp. 4104–4108. doi: 10.1109/icsmc.1997.637339.
- Khanesar, M. A., Teshnehlab, M. and Shoorehdeli, M. A. (2007) 'A novel binary particle swarm optimization', *2007 Mediterranean Conference on Control and Automation, MED*, 1(1). doi: 10.1109/MED.2007.4433821.
- Lacerda A.R.S. ; Silva Filho, A. G. ; Santos, W.P. ; Cordeiro, Filipe Rolim, H. F. ; F. (2016) 'Redução de Energia em Casas Inteligentes utilizando uma Abordagem Multiobjetivo baseada nos Perfis de Uso de Equipamentos', (July 2018).
- Liu, W. et al. (2019) 'Optimal siting and sizing of distributed generation based on improved nondominated sorting genetic algorithm II', *Processes*, 7(12), pp. 1–10. doi: 10.3390/PR7120955.
- Prakash, R., Lokeshgupta, B. and Sivasubramani, S. (2018) 'Multi-Objective Bat Algorithm for Optimal Placement and Sizing of DG', *2018 20th National Power Systems Conference, NPSC 2018*. IEEE, pp. 1–6. doi: 10.1109/NPSC.2018.8771440.
- Prakash, R. and Sujatha, B. C. (2017) 'Optimal placement and sizing of DG for power loss minimization and VSI improvement using bat algorithm', *2016 National Power Systems Conference, NPSC 2016*. doi: 10.1109/NPSC.2016.7858964.
- Ramírez, F. J. et al. (2017) 'Combining feed-in tariffs and net-metering schemes to balance development in adoption of photovoltaic energy: Comparative economic assessment and policy implications for European countries', *Energy Policy*. Elsevier, 102(January), pp. 440–452. doi: 10.1016/j.enpol.2016.12.040.
- Takahashi, R. H. C. (2007) *Otimização Escalar e Vetorial*. Universidade Federal de Minas Gerais.
- Viral, R. and Khatod, D. K. (2012) 'Optimal planning of distributed generation systems in distribution system: A review', *Renewable and Sustainable Energy Reviews*. Elsevier, 16(7), pp. 5146–5165. doi: 10.1016/j.rser.2012.05.020.
- Yang, X.-S. (2014) *Introduction to Algorithms, Nature-Inspired Optimization Algorithms*. doi: 10.1016/B978-0-12-416743-8.00001-4.