



Alocação Ótima de REDs em Sistemas de Distribuição de Energia Elétrica via Inteligência Computacional

Adriana O. Mendonça, Alissa O. Reis, Helena B.S.P. Rezende, Mayra U. Barbosa, Vinícius A. Cabral
e Ivo C. Silva Junior

Universidade Federal de Juiz de Fora (UFJF)

Resumo—Ao longo dos últimos anos, vem sendo observado um aumento considerável da inserção de Recursos Energéticos Distribuídos (REDs) nos sistemas de distribuição de energia elétrica. Os REDs são dispositivos de geração ou armazenamento de energia elétrica, localizados em instalações residenciais ou no próprio sistema de distribuição, sendo capazes de atender totalmente ou parcialmente à demanda local. Dentro deste contexto, o presente artigo tem por objetivo avaliar e comparar o emprego de três técnicas relativamente recentes de inteligência artificial (*Bat Algorithm*, *Grey Wolf Optimizer* e *Sine Cosine Algorithm*) ao problema referente à alocação e ao dimensionamento ótimo de REDs em sistemas de distribuição visando à minimização das perdas técnicas e do desequilíbrio de tensão. As simulações foram realizadas usando o *software* OpenDSS® e aplicadas ao sistema de distribuição IEEE de 34 barras. Os resultados mostram que a inteligência computacional é uma ferramenta muito interessante, principalmente para sistemas de distribuição de grande porte, e que a inserção dos REDs pode contribuir de forma satisfatória para a redução das perdas técnicas nos sistemas de distribuição de energia, desde que bem alocados e com nível de penetração otimizado.

Palavras-Chave— Inteligência Computacional, Recursos Energéticos Distribuídos, Sistemas de Distribuição de Energia Elétrica

OPTIMUM ALLOCATION OF DERs IN POWER DISTRIBUTION
SYSTEMS USING COMPUTATIONAL INTELLIGENCE

Abstract— Over the past few years, there has been a considerable increase in the installation of Distributed Energy Resources (DERs) in power distribution systems. DERs are devices which generate or store electricity, located either in residential installations or in the distribution system itself, being able to supply all or part of the local demand. In this context, this paper aims to evaluate and compare the use of three relatively recent computational intelligence techniques (*Bat Algorithm*, *Gray Wolf Optimizer* and *Sine Cosine Algorithm*), to the problem concerning the allocation and optimal dimensioning of DERs in distribution systems, minimizing technical losses and voltage unbalances. The simulations

were performed using the OpenDSS® software and applied to the 34-bar IEEE distribution system. The results show that computational intelligence is a very interesting tool, especially for large distribution systems and that the insertion of DERs can contribute in a positive sense to the reduction of technical losses in energy distribution systems, as long as they are well allocated and have an optimized penetration level.

Key Words— Computational Intelligence, Distributed Energy Resources, Power Distribution Systems

I. INTRODUÇÃO

A integração dos Recursos Energéticos Distribuídos (REDs) no sistema de distribuição de energia elétrica tem aumentado de forma considerável nos últimos anos. De acordo com a Empresa de Pesquisa Energética (EPE), a matriz elétrica nacional tem mais de 80% de sua geração proveniente de fontes renováveis, sendo destes, 0,34% oriunda de fontes de geração distribuída. As previsões apontam para um percentual de participação destes REDs de 4% para 2029 e de 11% para 2050. Ou seja, os REDs irão ocasionar uma maior diversificação do sistema elétrico brasileiro em um futuro próximo [1].

Os REDs são dispositivos de geração ou armazenamento de energia elétrica localizado em instalações residenciais ou no próprio sistema de distribuição de energia, sendo capazes de atender integralmente ou parcialmente a demanda local e em determinadas situações, injetar potência no sistema de transmissão [2].

A Agência Nacional de Energia Elétrica (ANEEL), através de sua resolução 482 de 2012, proporcionou um aumento percentual significativo da geração distribuída com destaque para a energia solar [3]. Nesta resolução foi permitido, aos consumidores ativos cadastrados, conectar geradores de energia próprios, de fontes primárias renováveis, à rede da concessionária local de distribuição de energia elétrica. Outro ponto motivacional diz respeito a redução dos preços de energia provenientes de renováveis obtidos através de leilões [4].

Diante de uma maior contribuição/participação dos REDs nos sistemas de potência, os fluxos de energia passarão a ser multidirecionais e conseqüentemente, esta situação irá inserir maior complexidade na operação dos sistemas elétricos. Sendo assim, tecnologias mais robustas de monitoramento, controle, proteção e otimização serão necessárias para manter o sistema operando da forma satisfatória e com o grau de confiabilidade adequado [2].

Embora os desafios de integração dos REDs sejam grandes e alguns paradigmas em relação à operação e ao planejamento tenham que ser revistos, os REDs podem trazer benefícios ao sistema elétrico. Nesta linha de raciocínio pode-se citar a oferta descentralizada de energia, a qual pode reduzir o carregamento/congestionamento da rede elétrica e desta forma, proporcionar uma redução de perdas técnicas. Outro ponto identificado é o aumento da confiabilidade do sistema elétrico, principalmente quando os REDs são operados de forma eficiente e otimizada.

Dentro deste contexto, o presente artigo tem por objetivo avaliar e comparar o emprego de três técnicas de inteligência computacional ao problema referente à alocação e ao dimensionamento ótimo de REDs em sistemas de distribuição visando a minimização das perdas técnicas. Os resultados mostram que a inserção dos REDs pode contribuir de forma satisfatória para a redução das perdas técnicas nos sistemas de distribuição de energia, desde que bem alocados e com nível de penetração otimizado.

Para tanto, esse artigo está organizado da seguinte forma. Na Seção II é apresentado as principais revisões bibliográficas que contribuíram para esse estudo. Na Seção III é apresentada a metodologia dos três algoritmos que são analisados, *Bat Algorithm*, *GreyWolf Optimizer* e *Sine Cosine Algorithm*. Na Seção IV é apresentada a formulação do problema e na Seção V é feito o estudo do caso proposto. A Seção VI conclui o trabalho e apresenta propostas de trabalhos futuros.

II. REVISÃO BIBLIOGRÁFICA

Diversas abordagens e perspectivas podem ser consideradas para avaliação dos impactos dos Recursos Energéticos Distribuídos (REDs) em sistemas de distribuição. Dentre os tipos de REDs, destaca-se a fotovoltaica como a fonte mais utilizada, sendo aplicada sozinha ou em conjunto com outras fontes. As técnicas de inteligência computacional são as mais utilizadas para a otimização de sistema elétricos de potência considerando a inserção de Geração Distribuída (GD). Os principais critérios analisados nesse processo de decisão são a alocação de GD e controle de geração, com a finalidade de atender critérios específicos como, redução das perdas técnicas, redução de sobrecarga nas linhas, redução do desequilíbrio entre as fases e a minimização dos custos de geração.

Kansal et al. [5] apresentam um método de otimização para determinar a alocação ótima de GDs e capacitores. Os locais e tamanhos tanto das GDs como dos capacitores foram determinados visando a minimização das perdas na distribuição de energia, considerando as restrições de fluxo de potência e perfil de tensão. Foram considerados, também, diversos fatores econômicos, como: os custos de investimento, os custos

operacionais e os de manutenção. O preço de mercado da energia elétrica foi considerado para recuperar o investimento inicial em um período específico. O problema foi otimizado considerando diferentes períodos de planejamento e a técnica de otimização utilizada foi a baseada em enxame de partículas (PSO).

Vadhra e Mahajn [6] colocam o problema como a definição da localização ideal da GD. Para tanto, foram utilizadas informações de fluxo de carga e o emprego de um algoritmo genético, o qual foi comparado com os métodos de enxame de partículas e algoritmo clonal. Com a integração da GD, houve uma redução significativa nas perdas de energia do sistema e o perfil de tensão foi melhorado de forma significativa.

Kumar e Ansari [7] fizeram uso do Algoritmo Genético (GA) para encontrar a melhor localização de um RED de 5MW, em uma rede de distribuição a fim de reduzir as perdas técnicas do sistema. Os resultados mostraram que o GA chega ao ponto ótimo de instalação sem precisar executar um fluxo de potência com o RED posicionado em cada barra do sistema e que sua instalação no ponto ótimo, de fato, reduz as perdas.

Sudabattula e Kowsalya [8] propuseram a utilização do *Cuckoo Search Algorithm* (CSA) na definição da alocação ótima de várias GDs eólicas no sistema IEEE 69 barras. A alocação teve por objetivo a redução das perdas de energia no sistema. Os resultados alcançados foram confrontados com os resultados obtidos via GA e o algoritmo PSO, sendo possível verificar a eficiência do CSA na resolução do problema.

Reddy et al. [9], com a finalidade de reduzir as perdas totais de energia, alocaram uma única GD através de uma metodologia baseada em Vetor de Índice (VI). Posteriormente, com a alocação definida pelo VI, a GD foi dimensionada pelo *Flower Pollination Algorithm* (FPA). Para cada sistema em análise foram feitos três testes: o primeiro com a GD tipo I, que injeta apenas potência ativa; o segundo com a GD tipo II, que injeta apenas potência reativa, e o terceiro com a GD tipo III, que injeta potência ativa e reativa. Os sistemas estudados foram o IEEE 15 barras, o IEEE 34 barras e o IEEE 69 barras. Os testes mostram que a utilização da GD tipo III, proporcionou, para os sistemas em estudo, os melhores resultados na redução de perdas e melhoria do perfil de tensão.

Khoa et al. [10] utilizaram uma variação do *Cuckoo Search Algorithm*, sendo proposto o método ORCSA (*One Rank Cuckoo Search Algorithm*) para encontrar a localização e os tamanhos ideais de unidades de geração distribuída em redes de distribuição. O problema de otimização da alocação das GDs foi formulado com múltiplos objetivos: perda mínima de energia, o desvio mínimo e a melhoria da estabilidade de tensão. O método proposto foi testado no sistema IEEE 69 barras e os resultados obtidos foram comparados com outros métodos de inteligência computacional. A comparação dos resultados indicou que as soluções obtidas pelo ORCSA são competitivas.

Ali et al. [11] tiveram uma abordagem na obtenção da localização e do dimensionamento ótimo da GD em sistemas de distribuição, visando minimizar as perdas de energia elétrica e otimizar o perfil de tensão. Para tanto, quatro algoritmos foram comparados: recozimento simulado (SA), algoritmo genético (GA), algoritmo genético híbrido (HGA) de GA combinado

com um método de busca local (VSED) e pesquisa de vizinhança variável. Todas as metodologias encontraram ótimos resultados, mas verificou-se que o algoritmo HGA proporcionou a obtenção da melhor solução, porém com um esforço computacional maior.

Tolba et al. [12] consideraram múltiplos objetivos para alocação ótima e o dimensionamento adequado de GD na rede de distribuição. Um algoritmo híbrido denominado de *Hybrid Particle Swarm* (HPSO) foi proposto e em conjunto com o algoritmo Quasi-Newton (QN) foram utilizados para resolver o problema de dimensionamento da GD. O algoritmo proposto foi testado nos sistemas IEEE33 e IEEE69 barras. Os resultados comprovaram a capacidade e o bom desempenho do método na obtenção da alocação e o dimensionamento ótimos das GDs.

Shi e Baran [13] propuseram uma metodologia de otimização Volt/Var (VVO) descentralizada para sistemas de distribuição com alta penetração de recursos energéticos distribuídos. O esquema VVO apresentado divide o sistema em subáreas com base na sensibilidade Volt/Var, que se encaixa em uma arquitetura de comunicação mestre-escravo. Ao determinar o suporte de reativo ideal (Var) dos inversores inteligentes, o processo mantém a tensão do sistema em um nível aceitável, ao mesmo tempo em que fornece uma correção efetiva do fator de potência para manter as perdas elétricas em patamares reduzidos. Tal esquema é computacionalmente eficiente e adequado para implementação em tempo real. Os resultados da simulação com alta penetração de PV, com discretização temporal horária em um período de 24 horas, mostraram a eficácia da metodologia VVO proposta.

Selim et al. [14] aplicaram o método de otimização *Sine-Cosine Algorithm* e a teoria do mapa do caos a fim de fazer a alocação ótima de módulos PV e de banco de baterias nos sistemas IEEE 33 e 69 nós. Esse estudo teve por objetivo reduzir as perdas do sistema, o desvio de tensão e garantir a estabilidade do sistema. O trabalho considera, além de curvas de geração e de carga, as incertezas associadas à irradiação solar. O resultado prova que o CSCA proposto é mais eficiente para resolver a alocação ótima de múltiplas gerações distribuídas com mínima perda de potência e alta taxa de convergência.

Shaheen et al. [15] utilizam um algoritmo de otimização de equilíbrio aprimorado (IEOA) combinado com uma estratégia de reciclagem para configurar redes de distribuição de energia considerando a alocação ótima de múltiplos geradores distribuídos. A eficácia do algoritmo proposto foi verificada, a priori, em vinte e três funções de benchmark padrão. A verificação da adequação técnica proposta, ao problema, foi feita através de um sistema de distribuição composto por 137 barras. As simulações realizadas levaram a um melhor desempenho, qualidade e confiabilidade do sistema de distribuição. Diante das simulações, pode-se verificar que os resultados obtidos apontaram para a eficácia e robustez da técnica proposta.

Batista et Al. [16] apresentam uma abordagem para alocação ótima de geradores distribuídos (GD) em sistemas de distribuição de energia para a redução total de perdas utilizando a técnica de algoritmos genéticos. No processo de otimização, as incertezas da demanda das cargas e os cenários de carregamento ao longo do dia foram considerados, visando uma representação

adequada da operação real dos sistemas de distribuição, o que permite uma avaliação mais criteriosa da barra ideal para alocação de GD.

Diante da revisão bibliográfica apresentada, pode-se verificar que os algoritmos baseados em inteligência computacional têm sido amplamente utilizados na otimização de sistemas de distribuição de energia elétrica. E sendo assim, o presente trabalho tem por objetivo avaliar e comparar o emprego de três técnicas de inteligência computacional ao problema referente à alocação e ao dimensionamento ótimos de REDs em sistemas de distribuição visando a minimização das perdas técnicas.

III. INTELIGÊNCIA COMPUTACIONAL

O processo de otimização pode ser definido como um conjunto de procedimentos por meio dos quais se busca minimizar ou maximizar uma determinada função, denominada função objetivo, sujeita ou não a uma série de restrições, obtendo assim um melhor aproveitamento dos recursos disponíveis [17]. Para resolver problemas de otimização, podem ser utilizados dois grupos de algoritmos: os determinísticos e os probabilísticos, sendo a inteligência computacional inserida neste último grupo.

Diferente dos métodos determinísticos, os métodos probabilísticos não necessitam de informações de derivadas do problema e também são independentes da solução inicial considerada. Entretanto, a desvantagem em relação aos métodos determinísticos está no grande esforço computacional requerido e no fato de que muitas vezes elas não garantem resultado ótimo ou a repetibilidade dos experimentos. Ou seja, são métodos que possuem sua maior aplicabilidade em problemas multimodais.

Existe uma classe dentro dos métodos probabilísticos que são os algoritmos evolutivos. Estes são inspirados nos mecanismos evolutivos observados na natureza ou no comportamento humano. Os algoritmos evolutivos fazem uso de uma população de indivíduos que interagem e competem entre si pela evolução da população. Essa classe de algoritmos emprega regras de transição probabilística e para as restrições são utilizados, como por exemplo, penalidades para os indivíduos que violarem alguma das restrições do problema.

Alguns exemplos de métodos de otimização baseados na natureza são: Algoritmos Genéticos (GA) [18], Colônia de Formigas (ACO) [19], Enxame de Partículas (PSO) [20], Algoritmo do Morcego (BA) [21] e Alcateia de Lobos Cinzentos (GWO) [22].

No presente trabalho, devido a característica multimodal do problema em estudo, optou-se por investigar três diferentes técnicas baseadas em populações, sendo duas bio-inspiradas (BA e GWO) e uma inspirada em funções matemáticas, o algoritmo Seno e Cosseno (SCA) [23]. O objetivo de se utilizar os três métodos para a solução do problema é aferir a técnica que apresenta o melhor desempenho na determinação ótima da alocação e do dimensionamento dos recursos energéticos distribuídos em sistemas de distribuição de energia elétrica.

A escolha pelos algoritmos mencionados acima se dá pelo fato de serem técnicas relativamente recentes e que apresentam boa eficiência na resolução de diversos outros problemas de otimização existentes na literatura [24,25]. A seguir serão abordados brevemente os conceitos, equacionamentos e

comportamentos de busca local e global dos métodos de otimização aqui investigados.

A. BAT ALGORITHM

O *Bat Algorithm* (BA) é um algoritmo metaheurístico para otimização global, desenvolvido por Xin-She Yang em 2010 [21]. O BA é inspirado na capacidade biológica utilizada pelos morcegos para determinar fatores como posição e distância de obstáculos ou presas em um ambiente por meio da emissão de ondas ultrassônicas (ecolocalização). Essa capacidade biológica garante que esses animais consigam montar um mapa de localização sem utilizar a visão.

Inicialmente três parâmetros são definidos no BA: o número de morcegos (η), as taxas de decréscimo da amplitude do pulso (α) e de aumento da emissão de pulso da onda sonora (γ). Com a definição dos parâmetros iniciais são inicializadas de forma aleatória, as seguintes informações: posições dos morcegos (X_i), velocidade (V_i), frequência ($f r_i$), taxa de emissão de pulso (r_i) e amplitude do pulso (A_i). Quando o morcego identifica uma possível presa, a taxa de emissão de pulso é acelerada e a amplitude é diminuída para que a presa não seja perdida. Após as definições dos parâmetros é feita a avaliação da população dos morcegos. Essa avaliação refere-se ao valor numérico da função objetivo do problema para cada um dos morcegos da população, sendo assim possível determinar a posição onde se encontra o melhor morcego, denominada X_* .

Na sequência se inicia o processo de busca bio-inspirado até atingir um critério de parada, que pode ser o número máximo de iterações ou a estagnação da melhor solução. Para cada iteração t são atualizadas as novas frequências ($f r_i$) e esta é utilizada para definir a nova velocidade (V_i^{t+1}) e a nova posição (X_i^{t+1}) temporária do morcego i , sendo esta posição uma função da melhor posição encontrada até o instante t . Esse processo iterativo utiliza (1), na qual a frequência do morcego i está em torno do valor mínimo ($f r_{min}$) e máximo ($f r_{max}$) atribuídos e sendo β é um número aleatório entre $[0,1]$, (2) e (3) exibidas a seguir.

$$f r_i = f r_{min} + (f r_{max} - f r_{min}) \cdot \beta \quad (1)$$

$$V_i^{t+1} = V_i^t + (X_i^t - X_*^t) \cdot f r_i \quad (2)$$

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (3)$$

Após esse processo de atualização das posições dos morcegos é iniciada a etapa de busca local, onde a taxa de emissão de pulso (r_i) é comparada com um valor aleatório entre $[0,1]$. Se essa condição for satisfeita ($\text{rand} > r_i$) é aplicada (4), que gera uma nova localização para o morcego (X_i^{t+1}) em relação ao melhor morcego (X_*) da população, utilizando da média da amplitude do pulso (A^t) e de um vetor aleatório ϵ entre $[-1,1]$ de dimensão equivalente ao morcego. A posição do morcego (X_i^{t+1}) é verificada com base nos limites definidos para se avaliar a viabilidade da solução.

$$X_i^{t+1} = X_*^t + \epsilon \cdot \text{média}(A^t) \quad (4)$$

Em seguida, os morcegos são avaliados e inicia-se o processo iterativo para a busca da solução global. Esse processo possui duas condições: se o valor randômico é menor que a amplitude do pulso ($\text{rand} < A_i^t$) e, em problemas de minimização, se o valor numérico da função objetivo atual é menor que na iteração anterior ($f(X_i^{t+1}) < f(X_i^t)$). Se essas duas condições forem satisfeitas, a taxa de emissão de pulso e de amplitude do morcego são atualizadas, de acordo com (5) e (6).

$$r_i^{t+1} = r_i^0 \cdot [1 - e^{-\gamma \cdot t}] \quad (5)$$

$$A_i^{t+1} = \alpha \cdot A_i^t \quad (6)$$

Durante o processo de busca iterativo, a amplitude de pulso (A_i) diminui e a taxa de emissão de pulso (r_i) cresce. Assim, o mecanismo de busca global ocorre diversas vezes no início do processo, mas como a média da amplitude vai tendendo a zero, no término a condição é dificilmente satisfeita devido a queda da amplitude do pulso e a busca local sendo mais minuciosa.

Assim como outras técnicas de busca evolucionária, o BA pode ser utilizado na resolução de problemas de programação inteira ou binária e com região de solução não convexa (regiões multimodais) [26]. O pseudocódigo do algoritmo, conforme a metodologia descrita anteriormente, é apresentado no Algoritmo I.

Algoritmo I Bat algorithm

- 1: **Inicializar** Parâmetros η, α, γ
 - 2: **Inicializar** Morcegos: (X_i , com $i = 1, 2, \dots, N_{\text{morcegos}}$)
 - 3: **Avaliar** Morcegos: $\text{FOB}(X_i)$
 - 4: **Atualizar** Melhor morcego: (X_*^t)
 - 5: **Enquanto** critério de parada não atendido, **faça**:
 - 6: **Loop** 1: η
 - 7: $f r_i = f r_{min} + (f r_{max} - f r_{min})\beta$, $\beta \in [0,1]$
 - 8: $V_i^{t+1} = V_i^t + (X_i^t - X_*^t)f r_i$
 - 9: $X_i^{t+1} = V_i^{t+1} + X_i^t$
 - 10: **Se** $\text{rand} > r_i$, $\text{rand} \in [0,1]$, **faça**:
 - 11: $X_i^{t+1} = X_*^t + \epsilon \text{média}(A_i^t)$, $\epsilon \in [-1,1]$
 - 12: **Fim Se**
 - 13: **Verificar** violações e **Avaliar** morcego: $\text{FOB}(X_i^{t+1})$
 - 14: **Se** $\text{rand} < A_i^t$ e $\text{FOB}(X_i^{t+1}) \leq \text{FOB}(X_i^t)$, **faça**:
 - 15: $r_i^{t+1} = r_i^0(1 - e^{-\gamma t})$
 - 16: $A_i^{t+1} = \alpha A_i^t$
 - 17: **Fim Se**
 - 18: **Fim Loop**
 - 19: **fim Enquanto**
 - 20: **Retornar** X_*^t
-

B. GREY WOLF OPTIMIZER

O *Grey Wolf Optimizer* (GWO) é um método de otimização bioinspirado que foi apresentado em 2014 por Mirjalili e Lewis [22]. Este método modela matematicamente as técnicas de caça e a hierarquia social dos lobos cinzentos. Os lobos cinzentos geralmente vivem em alcateia e a hierarquia dos lobos é dividida em classes: lobos alfa (α), beta (β), delta (δ) e ômega (ω), em ordem decrescente de dominância, respectivamente.

Os lobos alfa, lobos dominantes, são responsáveis por tomar decisões importantes para o grupo e suas ordens devem ser seguidas, como por exemplo a caça, o local de dormir e o horário de acordar. Os lobos beta são os futuros sucessores do posto dos lobos alfas. Os betas auxiliam e dão suporte no controle dos lobos inferiores. Em terceiro lugar na hierarquia estão os lobos delta que são representados pelas sentinelas, anciãos, escoteiros, caçadores e cuidadores. Em seguida, estão os lobos ômega, ocupando o nível mais baixo da hierarquia da alcateia e executando o papel de bode expiatório. Estes são submissos a todos os outros lobos e possuem fundamental importância na manutenção da ordem e da paz entre os lobos ao manter bem definida a estrutura de dominância.

A estratégia de caça dos lobos cinzentos é dividida em três etapas: (i) rastreamento, perseguição e aproximação à presa; (ii) cerca a presa até parar o seu movimento; (iii) ataque à presa. No algoritmo de otimização, essa estratégia é modelada computacionalmente como sendo o processo de busca ao longo da região de solução.

Considerando o contexto de otimização, as melhores soluções obtidas são referentes às posições dos lobos alfa, beta e delta. As posições desses lobos são utilizadas durante a execução do algoritmo na atualização das posições dos lobos ômega durante o processo iterativo. As Equações (7) a (10) modelam o comportamento dos lobos cinzentos no algoritmo.

$$\vec{X}^{t+1} = \vec{X}_p^t - \vec{A} \cdot \vec{D} \tag{7}$$

Onde t representa a iteração corrente e \vec{X}_p representa o posicionamento de um dos lobos dominantes (α , β , e δ). Os coeficientes \vec{A} e \vec{D} permitem a busca local ou global durante o processo de atualização das soluções no espaço de busca, e são obtidos através de (8) e (9).

$$\vec{D} = |\vec{C} \cdot \vec{X}_p^t - \vec{X}^t| \tag{8}$$

$$\vec{A} = 2\vec{a}_t \cdot \vec{r}_1 - \vec{a}_t \tag{9}$$

$$\vec{C} = 2 \cdot \vec{r}_2 \tag{10}$$

O coeficiente \vec{a}_t é o coeficiente de exploração e tem um comportamento de decrescer linearmente com o passar das iterações entre o intervalo [0,1]. O coeficiente \vec{C} que é definido em (10), tem a função de aumentar (com $\vec{C} > 1$) ou atenuar (com $\vec{C} < 1$) a magnitude das melhores soluções durante o procedimento de busca. Os vetores \vec{r}_1 e \vec{r}_2 são valores aleatórios uniformemente

distribuídos no intervalo [0,1], sorteados a cada iteração, e auxiliam o algoritmo a evitar estagnações em ótimos locais [27].

Com $|\vec{A}| < 1$, os lobos são forçados a atacar a presa, fazendo com que o algoritmo realize uma busca local e no caso em que $|\vec{A}| > 1$, os lobos vão buscar uma melhor presa dentro de seu espaço de busca, fazendo uma busca global [22].

Na natureza o processo de caça é usualmente guiado pelos lobos alfa, entretanto no contexto de otimização a localização da solução ótima (presa) pode ser difícil de ser encontrada. Logo, seguindo esta linha de raciocínio, o algoritmo GWO utiliza os dados das três melhores soluções encontradas durante o processo de otimização (X_α , X_β e X_δ , respectivamente), para direcionar a busca. Dessa forma, todos os outros lobos da alcateia atualizam sua posição no espaço de busca considerando a posição dos três lobos dominantes, conforme (11).

$$\vec{X}^{t+1} = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \tag{11}$$

Em que os valores de \vec{X}_1 , \vec{X}_2 e \vec{X}_3 estão definidos em (12), (13) e (14) exibidas a seguir.

$$\vec{X}_1 = |\vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha| \tag{12}$$

$$\vec{X}_2 = |\vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta| \tag{13}$$

$$\vec{X}_3 = |\vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta| \tag{14}$$

O posicionamento das três melhores soluções na iteração t é representado por X_α , X_β e X_δ . Já em relação aos coeficientes \vec{A}_1 , \vec{A}_2 e \vec{A}_3 , estes são obtidos em (9) e os coeficientes \vec{D}_α , \vec{D}_β e \vec{D}_δ são obtidos através de (15) a (17):

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \tag{15}$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \tag{16}$$

$$\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \tag{17}$$

Após a atualização é verificado se houve alguma violação do espaço de busca e o valor numérico da FOB diante das novas localizações. Se a solução encontrada for melhor que a posição dos lobos alfa, beta e delta, a melhor solução irá substituir a posição corrente de liderança e, assim, toda a hierarquia é também atualizada.

Em resumo, uma população aleatória de lobos composta de N indivíduos é criada e avaliada através da função objetivo do problema em análise. Definida a hierarquia, inicia-se o processo iterativo utilizando as equações (7) a (17) até que um critério de parada seja satisfeito. Ao final do processo iterativo, a melhor solução, aquela referente à posição do lobo alfa, é retornada. O pseudocódigo do GWO é apresentado no Algoritmo II.

Algoritmo II *Grey Wolf Optimizer*

- 1: **Inicializar** População de Lobos: (X_i , com $i = 1, 2, \dots, N_{lobos}$)
- 2: **Avaliar** Alcateia: $FOB(X_i)$
- 3: **Definir** Hierarquia: ($X_\alpha, X_\beta, X_\delta$)

```

4: Enquanto critério de parada não atendido, faça:
5:   Atualizar coeficiente de exploração  $\vec{a}_t$ 
6:   Para cada lobo  $\in (i = 1, 2, \dots, N_{lobos})$ , faça:
7:      $\vec{A} = 2\vec{a}_t \cdot \vec{r}_1 - \vec{a}_t$ ,  $\vec{r}_1 \in [0,1]$ 
8:      $\vec{C} = 2 \cdot \vec{r}_2$ ,  $\vec{r}_2 \in [0,1]$ 
9:      $\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha^t - \vec{X}_i^t|$ ,  $\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta^t - \vec{X}_i^t|$ ,  $\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta^t - \vec{X}_i^t|$ 
10:     $\vec{X}_1 = |\vec{X}_\alpha^t - \vec{A}_1 \cdot \vec{D}_\alpha|$ ,  $\vec{X}_2 = |\vec{X}_\beta^t - \vec{A}_2 \cdot \vec{D}_\beta|$ ,  $\vec{X}_3 = |\vec{X}_\delta^t - \vec{A}_3 \cdot \vec{D}_\delta|$ 
11:     $\vec{X}_i^{t+1} = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3}$ 
12:    Avaliar Alcateia e Atualizar Hierarquia ( $X_\alpha, X_\beta, X_\delta$ )
13:  fim Para Cada
14: fim Enquanto
15: Retornar  $X_\alpha$ 

```

C. SINE COSINE ALGORITHM

O *Sine Cosine Algorithm* (SCA) é uma técnica de otimização desenvolvida por Mirjalili em 2016 [23]. Nessa técnica é realizado o processo de busca local e global a partir de uma população inicial, na qual a atualização da população é feita através das funções trigonométricas seno e cosseno.

No SCA é estabelecido o número de soluções candidatas, definidos por n , e as soluções, chamadas de X_i , são inicializadas aleatoriamente na região de solução e avaliadas pela função objetivo. Assim, é definida a melhor solução, indicada como P^* , deste conjunto.

Dá-se início ao processo iterativo e a exploração pela solução ótima é realizada através da aproximação ou distanciamento entre a posição da solução atual (X_i^t) com a posição da melhor solução (P^*). Baseando-se nessa premissa é definido a posição atualizada (X_i^{t+1}), como se pode observar através de (18), onde o valor aleatório entre [0,1] do parâmetro r_4 define a escolha pelo componente seno ou cosseno.

De acordo com Mirjalili, através do parâmetro r_1^t , o algoritmo tem a capacidade de busca global nas primeiras iterações e buscas locais mais ao final do processo iterativo, pois conforme t se aproxima de $T_{máx}$ temos que o diminuindo se aproxima do subtraendo de (19) e o resultado de r_1^t se aproxima de zero. O coeficiente r_1^t é, também, denominado de coeficiente de exploração e é definido em função do número máximo de iterações ($T_{máx}$), da iteração atual (t) e de uma constante (a_s) atribuída. Este parâmetro influencia a busca pela solução na região, ou seja, quando ($r_1 < 1$) é esperado que a posição atualizada (prevista) possa estar na região entre a solução atual (X_i^t) e a melhor (P^*) ou fora desse espaço para ($r_1 > 1$).

$$X_i^{t+1} = \begin{cases} X_i^t + r_1^t \cdot \cos(r_2) \cdot |r_3 P_i^t - X_i^t|, r_4 < 0,5 \\ X_i^t + r_1^t \cdot \sin(r_2) \cdot |r_3 P_i^t - X_i^t|, r_4 \geq 0,5 \end{cases} \quad (18)$$

Onde:

$$r_1^t = a_s - t \cdot \frac{a_s}{T_{máx}} \quad (19)$$

Visto que este termo decresce com o decorrer do processo iterativo, a busca global é realizada com maior frequência no início e a busca local no término. O parâmetro r_2 tem relação com a direção de busca direta ou oposta a melhor solução (P^*). Já o parâmetro r_3 influencia no peso associado à avaliação da melhor solução. Dessa forma, ($r_3 < 1$) atenua e ($r_3 > 1$) aumenta a magnitude da melhor solução, ambas obtidos aleatoriamente entre $[0, 2\pi]$ e $[0, 2]$, respectivamente. Posteriormente, são verificados os limites e a solução (X_i^{t+1}) é avaliada. Por fim, é atualizada a posição da melhor solução (P_i^t).

O SCA possui simples implementação e poucos parâmetros de ajuste, o que torna ainda mais interessante sua aplicação em problemas de otimização multimodais. É apresentado no Algoritmo III, o pseudocódigo do algoritmo SCA de acordo com a metodologia aqui descrita.

Algoritmo III Sine Cossine Algorithm

```

1: Inicializar Soluções Candidatas: ( $X_i$ , com  $i = 1, 2, \dots, N_{sol}$ )
2: Avaliar Soluções: FOB( $X_i$ )
3: Definir Melhor Solução:  $P^*$ 
4: Enquanto critério de parada não atendido, faça:
5:   Atualizar coeficiente de exploração  $r_1^t$ 
6:   Para cada solução  $\in (i = 1, 2, \dots, N_{sol})$  faça:
7:      $X_i^{t+1} = \begin{cases} X_i^t + r_1^t \cdot \sin(r_2) \cdot |r_3 P_i^t - X_i^t|, r_4 < 0,5 \\ X_i^t + r_1^t \cdot \cos(r_2) \cdot |r_3 P_i^t - X_i^t|, r_4 \geq 0,5 \end{cases}$ 
8:      $r_2 \in [0, 2\pi], r_3 \in [0, 2]$  e  $r_4 \in [0, 1]$ 
9:   Avaliar Solução e Atualizar Melhor Solução:  $P^*$ 
10:  fim Para cada
11: fim Enquanto
12: Retornar  $P^*$ 

```

IV. FORMULAÇÃO DO PROBLEMA

Os estudos e simulações no sistema de distribuição foram desenvolvidos através do software OpenDSS[®], desenvolvido pelo EPRI (*Electric Power Research Institute*), que permite a modelagem de sistemas de distribuição trifásicos desbalanceados. O sistema em estudo é o IEEE-34 barras, que é composto por 32 barras de 24,9 kV e duas barras de 4,16 kV. A configuração dessas barras é mostrada na Fig. 1.




Fig. 1. Sistema de distribuição 34 barras [24].

A barra mais distante desse sistema está a 59 km de distância da subestação. A maior parte das cargas do sistema possuem demandas variando de 1 a 67,5 kW, com exceção daquelas localizadas na barra 844 (405 kW) e na barra 890 (450 kW).

Para a simulação do sistema com a aplicação dos REDs, foi aplicada uma curva de carga horária ao longo de um período de 24 horas às cargas do sistema, apresentada na Fig. 2. Esta curva foi definida de forma arbitrária, com um comportamento semelhante ao encontrado na prática em sistemas elétricos reais.




Fig. 2. Curvas de demanda diária do alimentador.

No presente estudo, a fonte fotovoltaica será o RED considerado para o processo de otimização da alocação e dimensionamento. No OpenDSS®, a simulação dessa fonte necessita das características do painel instalado, do conversor DC/AC e dos dados referentes à conexão à rede, além das curvas de irradiância e de temperatura do local. O modelo esquemático desse elemento no OpenDSS é mostrado na Fig. 3.

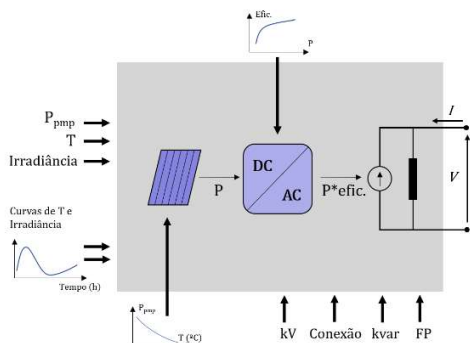


Fig. 3. Modelo do Sistema Fotovoltaico no OpenDSS.

Um dos parâmetros importantes do painel PV é a potência injetada quando operado no ponto de máxima potência P_{pmp} , para uma Temperatura (T) fixa e a Irradiância Nominal. Essa informação é fornecida ao software através de uma curva característica da P_{pmp} pela temperatura, como mostra a Fig. 4.




Fig. 4. Curva de $P_{pmp} \times T$.

Em relação ao conversor DC/AC, a eficiência do processo de conversão deve ser fornecida através da curva de Eficiência pela Potência ($Eff \times P$), como mostrado na Fig. 5.




Fig. 5. Curva de $Eff \times P$.

Os dados de temperatura e irradiância devem ser fornecidos através de curvas cuja granularidade está diretamente relacionada ao tipo de simulação em estudo. Neste estudo, como a simulação é horária e para um período de 24 horas, devem ser definidas as respectivas curvas para cada usina instalada, considerando, assim, a variação dessas informações devido às diferentes localizações em que podem ser inseridas as usinas.

A curva de temperatura deve ser disponibilizada com os valores em grau Celsius ($^{\circ}C$) e a curva de irradiância deve ser fornecida de forma normalizada (valores compreendidos no intervalo entre zero e um), pois tais valores serão multiplicados pelo valor base de irradiância. A Fig. 6 apresenta as curvas de temperaturas e irradiâncias consideradas ao longo do período de 24 horas. Essas curvas foram definidas de forma arbitrária e foram mantidas fixas para todas as usinas alocadas. É importante destacar que, na prática, as curvas de irradiância e temperatura são dependentes da localização da usina. No entanto, essas curvas normalmente possuem um comportamento semelhante, principalmente em localizações próximas, como é o caso do sistema em estudo. Assim, a aplicação de curvas fixas para as usinas implica em uma simplificação do estudo, mas que não acarreta em consideráveis impactos com relação à definição do local de instalação das unidades de geração.




Fig. 6. Curva de temperatura e irradiância em 24 horas.

Com relação à conexão das usinas ao sistema de distribuição, será utilizado um transformador elevador. As principais características que devem ser informadas para a simulação são o tipo de conexão no primário e secundário, a potência nominal, os dados de reatância e resistência e as tensões de conexão. A Tabela I apresenta os dados fixos de conexão do transformador entre as usinas e o sistema de distribuição.

TABELA I DADOS DE CONEXÃO DO TRANSFORMADOR.	
Fator de Potência do Inversor	1
Tensão Primário [kV]	0,69
Conexão	Y-Y
Reatância [%]	5,75

A potência nominal do transformador é definida como sendo 20% superior à P_{pmp} , devido a possíveis sobrecargas. Já a tensão de saída do transformador pode ser 4,16 ou 24,9 kV, dependendo da localização de sua instalação.

A finalidade global da alocação e dimensionamento de usinas de geração de energia fotovoltaica (PV) é a minimização das perdas elétricas diárias do sistema, juntamente à minimização do fator de desequilíbrio de tensões do sistema. Assim, a função objetivo – FOB – foi formulada através de (20):

$$FOB = \alpha \times \frac{Perd}{Perd_{ori}} \times 100 + (1 - \alpha) \times FD\% \quad (20)$$

onde $FD\%$ é o maior fator de desequilíbrio calculado através de (21), conforme é sugerido pelo PRODIST (Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional), Módulo 8 Qualidade da Energia Elétrica, em que V_- e V_+ são os módulos das tensões fasoriais de sequência negativa e positiva, respectivamente, de cada barra do sistema. Além disso, $Perd$ são as perdas obtidas ao longo do período de simulação e $Perd_{ori}$ são as perdas no sistema original, sem inserção de REDs, ambas em kWh.

$$FD\% = \frac{V_-}{V_+} \times 100 \quad (21)$$

Além disso, α é um parâmetro que controla o impacto da perda e do desequilíbrio na composição do valor da FOB. Neste estudo, o valor de α foi definido, de forma arbitrária, em 0,7, o que implica que 70% da FOB é composta pelas perdas elétricas,

que apresenta maior variabilidade em função da variável de decisão, e 30% pelo fator de desequilíbrio.

A obtenção das tensões de sequência negativa e positiva pode ser realizada através da decomposição das tensões em sequência de fase (abc) para componentes simétricas (012), através do Teorema de Fortescue. O cálculo das tensões fasoriais \dot{V}_+ e \dot{V}_- , através dos fasores \dot{V}_a , \dot{V}_b e \dot{V}_c , é feito aplicando (22) e (23), respectivamente, em que a é o fasor $1 \angle 120^\circ$.

$$\dot{V}_+ = \frac{1}{3} (\dot{V}_a + a\dot{V}_b + a^2\dot{V}_c) \quad (22)$$

$$\dot{V}_- = \frac{1}{3} (\dot{V}_a + a^2\dot{V}_b + a\dot{V}_c) \quad (23)$$

Os indivíduos do processo de otimização foram formulados de forma que possuam dimensão $2n$, em que n é o número de barras diferentes em que serão inseridas as usinas PV. Para cada módulo, são utilizadas duas dimensões, sendo uma discreta, que representa a barra à qual o módulo PV foi alocado, e uma contínua, que define a respectiva potência P_{pmp} .

Neste estudo, as técnicas são investigadas em relação à capacidade de alocação e dimensionamento de 3 usinas PV, sendo assim, construídos indivíduos de 6 dimensões. Na Equação (24), é exemplificado um indivíduo que insere uma usina em cada uma das barras **4**, **8** e **16**, com potências iguais a, respectivamente, 1kW, 5 kW e 300 kW.

$$X = [4 \ 1 \ 8 \ 5 \ 16 \ 300] \quad (24)$$

V. ESTUDO DE CASO

As técnicas de otimização BAT, GWO e SCA, já descritas, foram utilizadas para a resolução do problema de alocação e dimensionamento de 3 usinas PV no sistema IEEE-34 barras modelado através do OpenDSS.

Os critérios de parada definidos para as técnicas foram o número máximo de iterações, o tempo de processamento e o número de estagnações da melhor solução, isto é, o número máximo de iterações sem alteração da avaliação da melhor solução. A Tabela II apresenta os critérios de parada especificados.

TABELA II CRITÉRIOS DE PARADA ADOTADOS PARA AS TÉCNICAS.	
Máximo de Iterações	200
Tempo Máximo [s]	3600
Máximo de estagnações	10

Cada técnica foi aplicada 20 vezes, com a população fixada em 100 indivíduos e, a cada execução, as três técnicas são inicializadas com a mesma população. Seus parâmetros iniciais são os definidos na Tabela III, com base em valores normalmente utilizados em outros trabalhos que aplicam as respectivas técnicas. Para o BAT, são apresentados os parâmetros α e λ , que interferem no comportamento das buscas locais e globais, o valor da constante a_s no SCA e do valor inicial da constante a_t que está relacionada ao coeficiente de exploração no GWO.

TABELA III
PARÂMETROS ADOTADOS PARA AS TÉCNICAS DE OTIMIZAÇÃO.

BAT		SCA		GWO	
Parâmetro	Valor	Parâmetro	Valor	Parâmetro	Valor
α	0,95	a_s	1	a_t^0	1
γ	0,05	-	-	-	-

Os dados estatísticos das FOBs obtidas por cada técnica estão apresentados na Tabela IV. É importante destacar que o sistema original, sem a inserção de REDs, apresenta perdas elétricas diárias de 4564 kWh e fator de desequilíbrio de 1,188%, totalizando um valor de FOB de 70,356%.

TABELA IV:
DISTRIBUIÇÃO DA FOB PARA CADA ALGORITMO DE OTIMIZAÇÃO.

	BAT	GWO	SCA
Máximo	41,35	59,04	40,42
Mínimo	38,41	39,42	39,06
Média	40,14	44,06	39,93
Mediana	40,02	40,75	39,89
Desvio Padrão	0,68	6,40	0,31

A distribuição das soluções obtidas por cada técnica é apresentada na Fig. 7. Quando comparadas as melhores solução obtidas por cada técnica, verifica-se que o BAT atingiu uma FOB de 38,41 %, o GWO de 39,42 % e o SCA de 39,42 %, e essa proximidade entre as soluções demonstra uma consistência nos resultados obtidos para o sistema em estudo. Essa análise também evidencia que as técnicas possuem capacidades equiparadas para a obtenção de boas soluções para o problema. As soluções obtidas apresentaram consistência na resolução do problema, com pequenas variações entre as melhores soluções obtidas, uma vez que, ao comparar a melhor solução obtida por cada técnica, verifica-se uma variação em 2% no valor da FOB.

Além disso, comparativamente ao sistema original, todas as técnicas demonstram ser técnicas capazes de serem empregadas na resolução do problema de alocação e dimensionamento de REDs em sistema de distribuição, considerando a modelagem proposta.




Fig. 7: Distribuição dos resultados de cada algoritmo.

Analisando os resultados, verifica-se que algoritmo de ecolocalização de morcegos (BAT) apresentou a melhor solução, embora esta tenha sido próxima às obtidas pelas demais técnicas, o que comprova, novamente, o potencial dessas técnicas na

resolução do problema em investigação. Também é possível verificar que o GWO apresentou um maior desvio e média devido à convergência a soluções mais distantes das normalmente encontradas. Por fim, verifica-se que o desvio do SCA foi menor, demonstrando ser uma técnica com uma menor variabilidade da solução, embora não tenha sido capaz de atingir a melhor solução encontrada pelo BAT.

Um dos aspectos importantes para ser analisado e comparado entre técnicas de otimização são seus comportamentos na busca pela melhor solução através da curva de convergência ao longo das iterações, isto é, o comportamento da melhor avaliação ao longo das iterações. O gráfico da Fig. 8 apresenta o comportamento da avaliação da melhor solução obtida por cada uma das técnicas em cada iteração ao longo do processo de otimização.

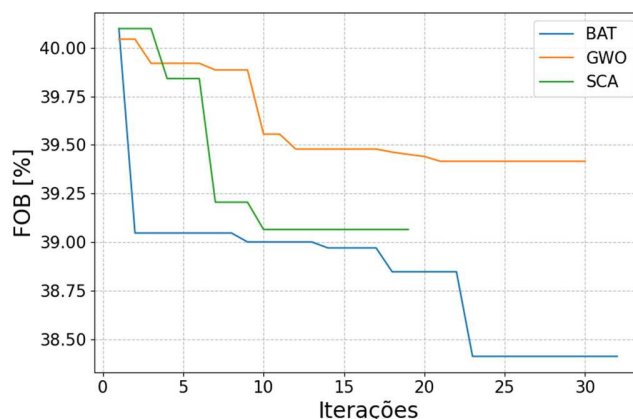


Fig. 8: Curva de convergência da melhor solução obtida por cada técnica

Como é possível perceber, o BAT apresenta uma queda rápida logo no início do processo iterativo e os seus processos de refinamento, que caracterizam a busca local, apresentam bom desempenho na obtenção de melhores soluções. Além disso, as três técnicas foram interrompidas devido à estagnação da melhor solução, sendo que o SCA atingiu a estagnação antes das demais técnicas. Por fim, verifica-se que, para as simulações selecionadas e apresentadas no gráfico, desde o início do processo iterativo, as três técnicas já conseguem atingir valores que apresentam melhorias significativas no sistema em relação ao sistema original. As iterações seguintes geram uma redução em cerca de 4% no valor da FOB, associados aos ajustes realizados pelas técnicas ao longo do processo iterativo. Essa redução de 4%, caso seja aplicada integralmente a uma variação das perdas elétricas, proporcionam uma redução de cerca de 250 kWh para 24h de simulação.

A solução obtida pelo BAT tem avaliação no valor de 38,41%, o que equivale a perdas elétricas diárias de 2470 kWh e 1,746% de desequilíbrio máximo. O indivíduo obtido pela técnica caracteriza o sistema representado na Fig. 9.




Fig. 9. Representação da melhor solução no sistema IEEE-34 barras.

Comparativamente ao sistema original, verifica-se uma redução de 45,9% das perdas elétricas. Em relação ao desequilíbrio, verifica-se que a melhor solução aumenta em 0,558% no valor de $FD\%$. Apesar de ter apresentado esse pequeno aumento, a aplicação do $FD\%$ na função multiobjetivo garante que a inserção de REDs não causará grandes distorções e desbalanceamentos entre as fases.

Com a finalidade de avaliar a solução obtida pelo BAT, foi feita uma análise de sensibilidade visando a identificação do comportamento das perdas elétricas e do desequilíbrio de tensão em função da variação do valor de P_{pmp} selecionado para a respectiva usina. Os gráficos da variação das perdas e do desequilíbrio referente à usina localizada na barra 844 (1483 kW) são apresentados na Fig. 10. Nas Fig. 11 e 12 são apresentados os gráficos referentes às usinas localizadas nas barras de 888 (787 kW) e 822 (555 kW) respectivamente. Em todos os gráficos, a melhor solução obtida ao longo do processo de otimização é representada através do ponto em vermelho, permitindo comparar as perdas e o desequilíbrio do sistema otimizado com as soluções vizinhas.




Fig. 10. Perdas elétricas e desequilíbrio em função da potência da usina na barra 844.




Fig. 11. Perdas elétricas e desequilíbrio em função da potência da usina na barra 888.




Fig. 12. Perdas elétricas e desequilíbrio em função da potência da usina na barra 822

Analisando os gráficos, pode-se verificar que a solução obtida está localizada em uma região que minimiza as perdas elétricas, uma vez que esta possui maior peso no cálculo da FOB. No entanto, na Fig. 11 verifica-se que menores perdas poderiam ter sido obtidas, levando a um aumento do desequilíbrio de tensão entre fases. Assim, pode-se confirmar que ambos os critérios foram bem considerados na resolução do problema, uma vez que o ponto obtido se encontra em um mínimo local, como os gráficos demonstram.

VI. CONCLUSÕES

A inserção dos REDs em sistemas de distribuição tem sido cada vez mais expressiva com o desenvolvimento de tecnologias o que pode proporcionar grandes melhorias à operação do sistema quando instalados de forma planejada e com uma visibilidade do sistema como um todo. Este trabalho teve como objetivo comparar 3 técnicas de otimização – BAT, SCA e GWO – na resolução de um problema de alocação e dimensionamento de 3 usinas PV no sistema IEEE-34 barras.

Os resultados obtidos demonstraram que as técnicas foram eficazes na obtenção de soluções factíveis e que reduzem consideravelmente as perdas elétricas, além de contribuir para o balanceamento entre as fases de sistemas de distribuição, comumente desequilibrados.

Foram obtidos resultados com redução de 2470 kWh de perdas diárias de energia, equivalente a 54% das perdas elétricas do sistema original, sem inserção das usinas PV. A melhor solução obtida foi submetida a uma análise de sensibilidade, que permite avaliar o comportamento das perdas e do desequilíbrio

em função do nível de penetração de cada uma das fontes inseridas no sistema.

Devido ao desenvolvimento de novas tecnologias que aumentam a atratividade, a viabilidade e a ocorrência de outras fontes de geração de energia em sistema de distribuição, a aplicação das técnicas desenvolvidas para a alocação de banco de baterias, geradores despacháveis e fontes eólicas, bem como a consideração de outros aspectos elétricos, como o desequilíbrio de tensão e sobrecarregamento de linhas, são temas para dar a continuidade neste estudo em trabalhos futuros.

AGRADECIMENTOS

Os autores gostariam de agradecer ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), ao Instituto Nacional de Energia Elétrica (INERGE), ao Programa de Pós-Graduação em Engenharia Elétrica (PPEE) e a Pró-Reitoria de Pós-Graduação e Pesquisa (PROPP) da Universidade Federal de Juiz de Fora pelo apoio no desenvolvimento deste trabalho.

APÊNDICE

De forma a permitir a reprodução do presente estudo, os dados de entrada utilizados para a construção dos gráficos da fig. 4, 5 e 6 são apresentados nessa seção.

A curva da temperatura T e da potência no ponto de máxima potência P_{pmp} é construída com base nos dados apresentados na Tabela V.

TABELA V:
DADOS DE P_{pmp} EM FUNÇÃO DA TEMPERATURA.

T [°C]	0	25	75	100
P_{pmp} [pu]	1,2	1,0	0,8	0,6

A curva de eficiência em função da potência injetada é construída de forma arbitrária através dos dados apresentados na Tabela VI.

TABELA VI:
DADOS DA EFICIÊNCIA EM FUNÇÃO DA POTÊNCIA INJETADA.

Eficiência	0,86	0,9	0,93	0,97
P	0,1	0,2	0,4	1,0

Já as curvas de irradiância e de temperatura em escala horária são apresentadas na Tabela IV.

TABELA IV:
DADOS DAS CURVAS HORÁRIAS DE TEMPERATURA E IRRADIÂNCIA

Hora	Irradiância	Temp. [°C]	Hora	Irradiância	Temp. [°C]
1	0	25	13	1	60
2	0	25	14	1	60
3	0	25	15	0,99	55
4	0	25	16	0,9	40
5	0	25	17	0,7	35
6	0	25	18	0,4	30
7	0,1	25	19	0,1	25
8	0,2	25	20	0	25
9	0,3	35	21	0	25
10	0,5	40	22	0	25

11	0,8	45	23	0	25
12	0,9	50	24	0	25

REFERÊNCIAS

- [1] EPE/MME, "Recursos Energéticos Distribuídos 2050", Empresa de Pesquisas Energéticas, Nota Técnica PR 08/18, 2018.
- [2] Mauricio Tiomno Tolmasquim e Marciano Morozowski Filho "Recursos Energéticos Distribuídos e suas potencialidades", Rio de Janeiro, Synergia, 2019.
- [3] EPE/MME, "Balanco Energetico Nacional: Relatório Síntese, ano base 2019", Rio de Janeiro: Ministerio de Minas e Energia, 2020.
- [4] International Renewable Energy Agency, "Renewable energy auctions: status and trends beyond price", International Renewable Energy Agency, Abu Dhabi, 2019.
- [5] S. Kansal, "Cost-Benefit analysis for Optimal DG Placement in Distribution Systems", International Journal of Ambient Energy, mar. de 2015.
- [6] S. Vadhera e S. Mahajan, "Optimal allocation of dispersed generation unit in a network system", em 2016 International Conference on Microelectronics, Computing and Communications (MicroCom), IEEE, 2016, pp. 1-5.
- [7] K. Kumar e M. Ansari, "A systematic approach for employment of distributed energy resources using genetic algorithm", em 2016 7th India International Conference on Power Electronics (IICPE), IEEE, 2016, pp. 1-5.
- [8] S. Sudabattula e M. Kowsalya, "Optimal allocation of wind based distributed generators in distribution system using Cuckoo Search Algorithm", Procedia Computer Science, vol. 92, 2016, pp. 298-304.
- [9] P. D. P. Reddy, V. V. Reddy e T. G. Manohar, "Application of flower pollination algorithm for optimal placement and sizing of distributed generation in Distribution systems", Journal of Electrical Systems and Information Technology, vol. 3, n.o 1, 2016, pp. 14-22
- [10] T. H. Khoa, P. Nallagownden, Z. Baharudin e V. N. Dieu, "One rank cuckoo search algorithm for optimal placement of multiple distributed generators in distribution networks", em TENCON 2017-2017 IEEE Region 10 Conference, IEEE, 2017, pp. 1715-1720.
- [11] A. Ali, P. Sanjeevikumar, B. Twala e T. Marwala, "Electric Power Grids Distribution Generation System For Optimal Location and Sizing - An Case Study Investigation by Various Optimization Algorithms", Energies, vol. 10, jul. de 2017.
- [12] M. A. Tolba, V. N. Tulsy e A. A. Z. Diab, "Optimal allocation and sizing of multiple distributed generators in distribution networks using a novel hybrid particle swarm optimization algorithm", em 2017 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus), IEEE, 2017, pp. 1606-1612.
- [13] Y. Shi e M. Baran, "A Gradient based Decentralized Volt/Var Optimization Scheme for Distribution Systems with High DER Penetration", em 2019 IEEE PES GTD Grand International Conference and Exposition Asia (GTD Asia), IEEE, 2019, pp. 649-654.
- [14] A. Selim, S. Kamel e F. Jurado, "Efficient optimization technique for multiple DG allocation in distribution networks", Applied Soft Computing, vol. 86, 2020, p. 105-938.
- [15] Shaheen, A. M., Elsayed, A. M., El-Sehiemy, R. A., e Abdelaziz, A. Y., "Equilibrium optimization algorithm for network reconfiguration and distributed generation allocation in power systems". Applied Soft Computing, v. 98, 2021, p. 106867.
- [16] Batista, Rodrigo Viana; De Araujo Leandro R.; Penido, Débora RR. "Alocação Ótima De Geradores Distribuídos Para Redução De Perdas Em Sistemas Elétricos De Distribuição Considerando Incertezas Da Demanda". Anais da Sociedade Brasileira de Automática, v. 2, n. 1, 2020.
- [17] Olivieri, B. P. Otimização do Projeto de Pontes Protendidas Pré Moldadas pelo Método dos Algoritmos Genéticos. Dissertação de Mestrado, Universidade Federal do Rio de Janeiro/ COPPE, Rio de Janeiro, 2004.
- [18] Ricardo Linden. "Algoritmos genéticos" (2a edição). Brasport, 2008.
- [19] M. Dorigo, 1992. Optimization, Learning and Natural Algorithms, PhD thesis, Politecnico di Milano, Italy.
- [20] Kennedy, J.; Eberhart, R. (1995). «Particle Swarm Optimization». Proceedings of IEEE International Conference on Neural Networks. IV. pp. 1942-1948.
- [21] X.-S. Yang, "A new metaheuristic bat-inspired algorithm", in Nature inspired cooperative strategies for optimization (NICSO 2010), Springer, 2010, pp. 65-74

- [22] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey wolf optimizer," *Advances in Engineering Software*, vol. 69, pp. 46–61, 2014.
- [23] S. Mirjalili, "SCA: a sine cosine algorithm for solving optimization problems", *KnowledgeBased Systems*, vol. 96, pp. 120–133, 2016
- [24] Oliveira, L. M. Programação Diária da Operação de Sistemas Termoelétricos de Geração via Otimização Seno-Cosseno Híbrido. Tese (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora. Juiz de Fora, p 54-58. 2019.
- [25] Arêdes, C., Junior, I. C. S.Mendonça, I. M., Dias, B. H. and Oliveira, L. W. (2014). Planejamento estático da expansão de sistemas de transmissão de energia elétrica via eco localização XLVI Simpósio Brasileiro de Pesquisa Operacional, pp. 3144–3149.
- [26] Furtado, L., Neto, W. A., Menezes, A., Junior, I. C. S., Olivi, L. R., Marcato, A. L. M. Bat Search Algorithm Aplicado na Localização de Robôs Móveis. SBAI 2015
- [27] Capacity Factor Optimization of an Offshore Wind Farm via Computational Intelligence Gustavo Rebello, Frederico Panoeiro, Vinicius Cabral, Frederick Marliere, Ivo Junior and Leonardo Oliveira CLAGTEE 2019