

Aplicação do Bat Algorithm na Otimização de Recursos Energéticos Distribuídos em Sistema de Distribuição

Adriana O. Mendonça* Alissa O. Reis** Helena B.S.P. Rezende***
Mayra U. Barbosa**** Vinícius A. Cabral† Ivo C. da Silva Junior‡

* Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: adriana.mendonca@engenharia.ufjf.br)

** Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: alissa.reis@engenharia.ufjf.br)

*** Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: helena.bernardes@engenharia.ufjf.br)

**** Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: mayra.barbosa@engenharia.ufjf.br)

† Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: albuquerque.vinicius@engenharia.ufjf.br)

‡ Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: ivo.junior@ufjf.edu.br)

Abstract: It is possible to notice the growing increase in the insertion of Distributed Energy Resources (DERs) in the Brazilian distribution system. Thus, this article aims to analyze the impact of allocation and optimal sizing of photovoltaic plants and battery banks through the Bat Algorithm optimization method. This simulation proposes a minimization of technical losses and voltage unbalance, moreover, the simulations were performed using OpenDSS[®] software and applied to the IEEE 34-bus distribution system. It is concluded that the insertion of DERs can effectively contribute to the reduction of technical losses with optimized allocation and penetration level.

Resumo: É possível notar o crescente aumento da inserção de Recursos Energéticos Distribuídos (REDs) no sistema brasileiro de distribuição. O presente artigo tem como objetivo analisar o impacto da alocação e dimensionamento ótimos de usinas fotovoltaicas e bancos de baterias através do método de otimização *Bat Algorithm*. Essa simulação propõe uma minimização das perdas técnicas e do desequilíbrio de tensão, realizando simulações do sistema de distribuição IEEE de 34 barras através do *software* OpenDSS[®]. Conclui-se que a inserção dos REDs pode contribuir de forma efetiva para a redução das perdas técnicas com a alocação e com o nível de penetração otimizados.

Keywords: Bat Algorithm; Computational Intelligence; DERs; IEEE34bus; Optimization; PV; Storage

Palavras-chaves: Bat Algorithm; Baterias; IEEE34 Barras; Inteligência Computacional; Otimização; PV; REDs.

1. INTRODUÇÃO

Os Recursos Energéticos Distribuídos (REDs) podem ser definidos como mecanismos de geração e/ou armazenamento de energia elétrica, situados dentro das demarcações de uma determinada concessionária de distribuição, comumente junto a instalações residenciais, atrás do medidor EPE/MME (2018). Os REDs são habilitados a subsidiar parcialmente ou integralmente a demanda local e, em casos específicos, injetar potência, inclusive, no sistema de transmissão de energia elétrica Tolmasquim and Filho (2019).

Atualmente, a inserção de REDs em sistemas de distribuição de energia tem-se ampliado significativamente. Segundo a Empresa de Pesquisa e Energia (EPE), em 2020,

as fontes de energia renováveis contribuíam em 67,83% na produção de energia primária brasileira. Sendo dessa geração renovável, 24,76% de fonte hidráulica. Também em EPE (2021) é possível observar um crescimento da fonte fotovoltaica, que em 2019 representava 0,43% e em 2020 passou a ser 0,67% das fontes renováveis.

Esses números só tendem a aumentar com o decorrer dos anos, o que ocasionará uma grande diversificação no sistema elétrico brasileiro em um horizonte próximo. Sendo assim, tecnologias mais avançadas de monitoramento, proteção, controle e otimização serão necessárias para manter o sistema operando dentro das especificações, uma vez que os fluxos de energia passam a ser multidirecionais.

Apesar desses obstáculos para a inserção dos REDs nas redes ainda serem consideráveis e alguns arquétipos de planejamento e operação tenham que ser revistos, há grandes vantagens na alocação dos REDs no sistema elétrico. Neste mesmo silogismo, pode-se citar a descentralização da oferta de energia, que tem como consequência reduzir a sobrecarga/congestionamento da rede, possibilitando assim, uma redução das perdas técnicas. Para mais, essas modificações podem trazer maior confiabilidade ao sistema elétrico desde que os REDs sejam manipulados de forma eficiente e otimizada.

Diante do fatos anteriormente apresentados, o presente artigo tem por objetivo avaliar o comportamento do sistema de distribuição em estudo, IEEE 34 barras, na presença de REDs. Para tanto, fez-se uso da técnica de inteligência computacional, *Bat Algorithm*, ao problema relativo à alocação e ao dimensionamento ótimo de REDs objetivando a minimização das perdas técnicas e a minimização do desequilíbrio das tensões.

2. REVISÃO BIBLIOGRÁFICA

Os impactos dos REDs em um sistema de distribuição podem ser avaliados sob diversos pontos de vista. Embora os sistemas fotovoltaico sejam as fontes mais utilizadas como REDs, há também os sistemas de armazenamento de energia formados por baterias, que são capazes de injetar e consumir energia no sistema de distribuição, em determinados momentos de interesse. Para a otimização dos sistemas elétricos de potência, considerando a inserção de GD e de baterias, geralmente as técnicas de inteligência computacional são as mais empregadas. Os critérios mais importantes a serem analisados nesse processo de decisão são a alocação de GD, alocação de baterias e controle de geração, com o objetivo de satisfazer a critérios específicos como a redução de perdas técnicas, redução do desequilíbrio entre as fases, redução de sobrecarga nas linhas e a minimização dos custos de geração/operação do sistema.

Com o objetivo de reduzir as perdas totais de energia, em P. D. P. Reddy (2016), por meio de um método baseado em Vetor de Índice (VI), uma única GD é alocada e em seguida dimensionada pelo *Flower Pollination Algorithm* (FPA). Foram estudados os sistemas IEEE 15 barras, IEEE 34 barras e IEEE 69 barras. Três testes foram feitos para cada sistema, primeiro com a GD tipo I, injetando somente potência ativa, o segundo com a GD tipo II, injetando somente a potência reativa, e o terceiro com a GD tipo III, injetando a potência ativa e a reativa. Como desfecho, os testes, estáticos e realizados em MATLAB, demonstraram que as GDs tipo III sempre possuem melhores resultados na redução de perdas e melhoria do perfil de tensão.

Tendo como finalidade minimizar as perdas de energia elétrica e otimizar o perfil de tensão do sistema, em A. Ali (2017) é feita uma abordagem com foco nas variáveis envolvidas na avaliação da qualidade de um sistema GD, com o objetivo de obter a localização e o tamanho ideal da GD no sistema de distribuição. Diversas simulações foram feitas no sistema teste IEEE 34 barras no intuito de fornecer as avaliações, e em vários casos de testes reais com respeito a diversas unidade de geração de distribuição. Durante o estudo foram comparados quatro algoritmos, o recozimento simulado (SA), o algoritmo genérico (GA),

a pesquisa de vizinhança variável e o algoritmo genético híbrido (HGA). Foram encontrados resultados excelentes em todas as metodologias, entretanto constatou-se que o algoritmo HGA gera a melhor solução a um gasto de tempo de processamento mais longo.

É definido, simultaneamente na rede de distribuição, a localização e o tamanho ótimo de GD e do Compensador Estático de Distribuição (DSTATCOM) em Y. Thangaraj (2017). A finalidade da função objetivo é minimizar as perdas totais de energia no sistema, sujeitada à restrições de igualdade e desigualdade. As localizações ideais do GD e do DSTATCOM são encontradas por meio do fator de sensibilidade à perda (LSF) e do Índice de estabilidade da tensão (VSI), respectivamente. O tamanho ideal do GD e do DSTATCOM foi determinado pelo algoritmo de busca do cuckoo (CSA), recém desenvolvido e inspirado na natureza, considerando cinco casos diferentes. No intuito de analisar a viabilidade, o método apresentado foi testado nos sistemas de distribuição radial IEEE 12, 34 e 69 barras e os resultados foram comparados com outras técnicas existentes. Dessa forma, foi possível concluir que a metodologia demonstrada pode ser aplicada em larga escala em um sistema de distribuição em tempo real.

Injeti (2018) apresenta estudos com o propósito de selecionar a alocação ótima das GDs em sistemas de distribuição radial (SDR), no intuito de minimizar perdas e o custo operacional e melhorar o perfil de tensão. O *Improved Differential Search Algorithm* (IDSA) foi o método utilizado para solucionar a questão de otimização por meio da abordagem ideal de Pareto. O teste foi executado considerando as cargas como constantes e com valores de pico. O procedimento proposto é implementado no SDR padrão IEEE 33 e 69 barras e os resultados são analisados comparando com outros métodos existentes. Com isso, foi concluído que a abordagem é bastante precisa em relação ao encontro de soluções ideais.

É proposto um método que emprega uma expressão analítica baseada em índice multi-objetivo (IMO), para o cálculo da capacidade de múltiplas unidades solares fotovoltaicas (PV), em um sistema de distribuição, em K. Sepromting (2018). A técnica utiliza dos índices de perda de potência ativa e reativa e do desvio de tensão, limitando a tensão em cada barra entre $1 \pm 0,05p.u.$ É tido como objetivo reduzir as perdas energéticas, assim como melhorar o perfil de tensão e os resultados são gerados pela utilização no sistema IEEE 33 barras e a análise é estática. Correlações são feitas com o objetivo de mostrar que a alocação de múltiplos PVs alcança efeitos mais positivos, na redução de perdas e no perfil de tensão, se analisada em relação a aplicação de apenas um PV. Ademais, em casos de restrições que não permitam a instalação da GD no barramento ótimo, os pontos ótimos consecutivos já são obtidos pelo método proposto, concedendo boas soluções.

Em Y. Shi (2019) é proposto um esquema de otimização Volt/Var descentralizada (VVO) para sistemas de distribuição com alta penetração de REDs. O VVO divide o sistema em subáreas com base na sensibilidade que se enquadra em uma arquitetura de comunicação baseada em mestre-escravo. A tensão do sistema se mantém aceitável ao definir o suporte Var ideal dos inversores inteligentes, concomitantemente fornece, também, uma correção

satisfatória do fator de potência para manter a perda de energia no mínimo. O esquema é computacionalmente eficiente e apropriado para a implementação em tempo real. A simulação é executada por meio do sistema IEEE 34 barras desequilibrado e com três níveis de tensões. Conclui-se com os resultados da simulação, com alta penetração de PV com discretização temporal horária em período de 24 horas, uma eficácia considerável do esquema VVO apresentado.

O método de otimização fundamentado no *Sine-Cosine Algorithm* e na teoria do mapa do caos é aplicado em A. Selim (2020). O processo de busca aleatória é executado por meio de variações dos valores do seno e cosseno dos parâmetros do algoritmo, no intuito de encontrar a alocação ótima de módulos PV e de banco de baterias no sistema IEEE 33 barras, com os objetivos de diminuir as perdas do sistema e o desvio de tensão, garantindo a estabilidade do sistema. Durante o método são considerados as curvas de geração e de carga e as incertezas associadas a irradiação solar quando feita a simulação ao longo de um período.

É apresentado, em BATISTA (2020) uma abordagem para a alocação ótima de GDs em sistemas de distribuição de energia para a redução total de perdas utilizando a técnica de algoritmos genéticos. Durante o processo de otimização, os problemas da demanda das cargas e os cenários de carregamento ao longo do dia foram levadas em consideração objetivando, também, uma representação satisfatória da operação real dos sistemas de distribuição, o que torna possível uma avaliação mais minuciosa em relação a barra ideal para alocação de GD. Os sistemas teste IEEE 13, 34 e 123 foram executados para a abordagem apresentada, já que apresentam características inerentes aos sistemas de distribuição. De forma a concluir, as barras estratégicas foram obtidas para uma melhor alocação dos geradores e quais barras são ideias para tal alocação. Dessa forma, a efetividade do método foi confirmada.

Em Fasina (2021) é feito um estudo de caso analisando o impacto da GD conectada na rede de energia nigeriana em termos de perdas de rede e barramentos de tensões. A solução de Newton-Raphson é utilizada para a realização do poder de análise de fluxo. A potência de saída do gerador, as cargas de pico MW e MVAR, a tensão e as classificações de potência da linha e dados do transformador são os dados de entrada para a análise de fluxo de energia. A rede modelada é simulada tanto sem e com GD e os resultados demonstraram que sem GD algumas das magnitudes de tensão do barramento do sistema de teste estavam fora do tolerado, no qual o limite de tensão é de 0,95 pu a 1,05 pu. Entretanto, as magnitudes de tensão foram melhoradas para valores tolerados com a GD conectada. A perda de potência foi reduzida em 12,03% na rede ativa. Com isso, pode-se afirmar que o sistema de energia se torna mais seguro e eficiente.

3. BAT ALGORITHM

Assim como a própria definição da palavra sugere, otimização é o processo de se otimizar, de tornar algo ótimo, dessa forma para aproveitar da melhor maneira os recursos disponíveis é empregado uma série de procedimentos a fim de minimizar ou maximizar uma determinada função ob-

jetivo, a qual esta sujeita ou não a uma série de restrições, por meio de métodos computacionais.

A inteligência computacional está inserida nos algoritmos probabilísticos, utilizados para solucionar problemas de otimização. Estes apesar de não necessitarem de um conhecimento prévio das derivadas do problema e não precisarem de uma resposta inicial considerada, exigem um enorme esforço computacional. Portanto, sua maior eficiência está na solução de problemas multimodais.

O *Bat Algorithm* (BA) é um algoritmo evolutivo, classe essa que faz parte dos métodos probabilísticos, foi desenvolvido em 2010 por Xin-She Yang, com o propósito de otimização global Yang (2010). Tal algoritmo é baseado na capacidade de ecolocalização dos morcegos, que consiste no método que esses animais utilizam para determinar posição e distância de presas ou obstáculos por meio de ondas ultrassônicas.

No BA inicialmente são definidos três parâmetros: o número de morcegos (η), as taxas de aumento da projeção de pulsos da onda sonora (γ) e decréscimo da amplitude do pulso (α). Em seguida são inicializadas de forma arbitrária a: posição dos morcegos (X_i), frequência (fr_i), velocidade (V_i), amplitude do pulso (A_i) e taxa de emissão do pulso (r_i). Quando o morcego reconhece uma possível presa, acelera-se a taxa de emissão de pulso e reduz a amplitude, para que não se perda a preia. Posteriormente a definição dos parâmetros, avalia-se a população de morcegos. Tal avaliação é referente ao valor numérico da função objetivo da questão para cada morcego da população, desta forma torna-se viável determinar a localização do melhor morcego, denominada X_* .

Sendo assim, inicia-se o processo de busca bio-inspirado até que um critério de parada seja atingido, esse que pode ser a estagnação da melhor solução ou o número máximo de iterações. A cada nova iteração t as frequências (fr_i) são atualizadas e empregue para atualizar a velocidade (V_i^{t+1}) e a nova posição temporária do morcego i (X_i^{t+1}). Esse processo iterativo faz uso das equações (1), (2) e (3), onde β é um número arbitrário entre $[0,1]$ e a frequência do morcego i está adjacente ao valor máximo (fr_{max}) e mínimo (fr_{min}) atribuídos.

$$fr_i = fr_{min} + (fr_{max} - fr_{min}) \cdot \beta \quad (1)$$

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

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

Seguidamente a etapa de atualização das posições dos morcegos é iniciado o processo de busca local, no qual a taxa de emissão de pulso (r_i) é contraposto a um valor aleatório entre $[0,1]$. Se essa condição for cumprida ($rand > r_i$) é empregue em (4), que produz uma nova localização para o morcego (X_i^{t+1}) no que se refere ao melhor morcego (X_*^t) da população, fazendo uso de um vetor aleatório ϵ entre $[-1,1]$ de dimensão proporcional aos morcegos e da média da amplitude do pulso (A^t). Com base nos limites definidos para avaliar a validade da solução é verificada a posição do morcego (X_i^{t+1}).

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

Na sequência, avalia-se os morcegos e dá-se início ao processo iterativo para busca da solução global. Tal etapa apresenta duas condições: se a amplitude do pulso é maior que o valor randômico ($A_i^t > \text{rand}$) e, em casos de problemas de minimização, se o valor numérico da função objetivo anterior é maior que o da atual ($f(X_i^t) > f(X_i^{t+1})$). Se as condições forem cumpridas, atualiza-se a taxa de emissão de pulso e a amplitude do morcego, como apresentado em (5) e (6).

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

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

Ao decorrer do processo de busca iterativo, a taxa de emissão de pulso (r_i) cresce e a amplitude do pulso (A_i) diminui, através da taxa de diminuição α . Com valores altos de amplitude tem-se uma maior probabilidade de aceitar novas soluções. Assim como para valores baixos de amplitude, no qual uma solução ruim provavelmente não é aceita. Desta forma, a busca local é intensificada.

On *Bat Algorithm*, assim como outras técnicas de busca evolucionária, pode ser empregado em problemas de programação binária ou inteira e com regiões multimodais Furtado L. (2015) e sua ampla utilização na literatura mostra seu destaque e sua eficiência.

4. FORMULAÇÃO DO PROBLEMA

O software utilizado para o cálculo das perdas e dos desequilíbrios de tensão neste estudos foi o OpenDSS, desenvolvido pelo *Electric Power Research Institute* (EPRI), que permite a modelagem de sistemas de distribuição trifásicos balanceados. E o software empregado para a comunicação com o OpenDSS foi o *Spyder*, para que por ele fosse aplicada a linguagem *Python* de programação utilizada. A comunicação entre o OpenDSS e o *Python* é exercida por meio do pacote *win32com*, que permite a automação e a execução dos códigos.

4.1 Definição da Função Objetivo

O propósito da função objetivo (FOB) utilizada é a minimização das perdas elétricas do sistema e do desequilíbrio de tensão entre as fases. De acordo com o que é mostrado na Equação (7), é possível verificar a formulação da FOB, onde α representa o peso das perdas e do desequilíbrio no valor da FOB.

$$FOB = \alpha \times \frac{Perd}{Perd_{ori}} \times 100 + (1 - \alpha) \times FD\% \quad (7)$$

A variável α nesse estudo foi considerada 0,70, assim, 70% da FOB depende das perdas elétricas e 30% depende do desequilíbrio de tensão. O termo $FD\%$, empregado na expressão, equivale ao fator de desequilíbrio calculado através da Equação (8), assim como o Módulo 8 do PRO-DIST propõe, onde V_- e V_+ são os módulos das tensões fasoriais de sequência negativa e positiva, respectivamente. Enquanto, $Perd$ representa as perdas obtidas ao longo do período de simulação e $Perd_{ori}$ equivale às perdas no sistema original, sem inserção de REDs, ambas em kWh.

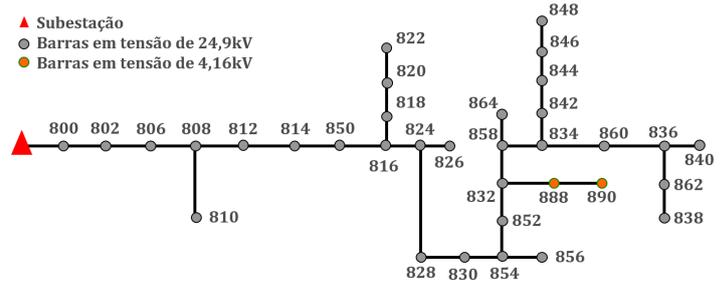


Figura 1. Sistema IEEE-34 barras em estudo

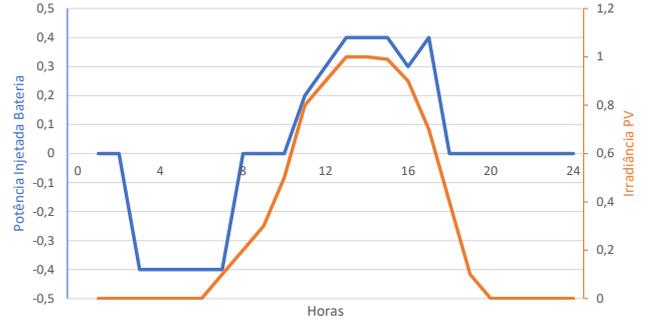


Figura 2. Curvas consideradas para o PV e bateria.

$$FD\% = \frac{V_-}{V_+} \times 100 \quad (8)$$

É possível calcular os valores de V_- e V_+ por meio da decomposição das tensões em sequência de fase (abc) para componentes simétricos (012), mediante o Teorema de Fortescue. Nas Equações (9) e (10), é mostrado, respectivamente, o cálculo das tensões fasoriais V_+ e V_- , através dos fasores \dot{V}_a , \dot{V}_b e \dot{V}_c , onde a é o fasor $1 \angle 120^\circ$.

$$\cdot V_+ = \frac{1}{3} (\dot{V}_a + a\dot{V}_b + a^2\dot{V}_c) \quad (9)$$

$$\cdot V_- = \frac{1}{3} (\dot{V}_a + a^2\dot{V}_b + a\dot{V}_c) \quad (10)$$

4.2 Sistema utilizado

O sistema apresentado e trabalhado neste artigo é o IEEE 34 barras. Este sistema é composto por 32 barras de 24,9 kV e duas barras de 4,29 kV, como é possível verificar na Fig. 1.

Na simulação que envolve fotovoltaicos e bancos de baterias é exigido que seja fornecido o comportamento da irradiância do PV e de carga/descarga da bateria. Com isso, as curvas que serão utilizadas podem ser conferidas na Fig. 2 que apresentam dentro de um período de 24 horas, mas que foram reproduzidas pelos 4 dias de simulação. A aplicação de curvas fixas, definidas de forma arbitrária, 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.

5. ESTUDO DOS CASOS

Por meio da técnica de otimização BA, já descrita anteriormente, o processo de otimização foi executado no sistema

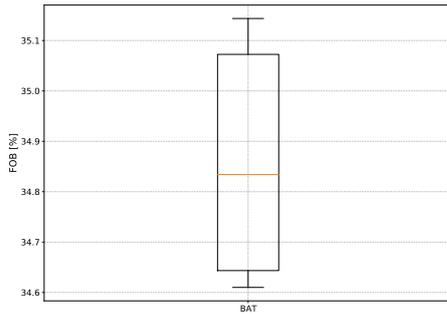


Figura 3. Distribuição das funções objetivos.

IEEE 34 barras com seus respectivos critérios de parada e características iniciais definidas, que serão mencionadas a seguir junto com os resultados obtidos através das simulações.

5.1 Otimização e dimensionamento de usinas fotovoltaicas

Na otimização de usinas PV, no intuito de avaliar o desempenho da técnica na resolução do problema, foram consideradas 3 usinas PV, uma população de 100 morcegos e a simulação foi executada 10 vezes. O processo iterativo foi programado para ser interrompido ao atingir 200 iterações ou ser a melhor solução a ser estagnada por 10 iterações seguidas. Os limites mínimos e máximos das potências das usinas consideradas foram definidos como 200 e 4000 kW, respectivamente. Já os parâmetros α e λ , que são responsáveis por definir o comportamento do algoritmo, foram mantidos como $\alpha = 0,95$ e $\lambda = 0,05$. Todas essas informações podem ser verificadas também na Tabela 1.

Tabela 1. Dados da otimização da alocação e dimensionamento de usinas PV.

Número de usinas	3	Parâmetro α	0,95
Iterações	200	Parâmetro λ	0,05
População	100	Potência Mínima	200kW
Simulações	10	Potência Máxima	4000kW
Estagnação	10		

São apresentadas na Fig. 3 a distribuição das FOBs da simulação das 10 execuções definidas. Já na Tabela 2 é possível analisar os dados estatísticos dos resultados referentes as FOBs e aos tempos de simulação.

Tabela 2. Dados estatísticos das FOBs e dos tempos de simulação.

	FOBs [%]	Tempo [min]
Máximo	35,27	51,42
Mínimo	34,60	21,28
Médio	34,95	35,44
Mediana	35,13	38,20
Desvio Padrão	0,26	9,14

O comportamento da convergência da melhor solução ao longo do processo iterativo é ilustrado na Fig. 4. O processo foi interrompido antes de atingir o número máximo de iterações, já que ocorreu a estagnação da melhor solução, como pode ser verificado na imagem. Inclusive, observando os primeiros pontos da curva, pode-se analisar que o algoritmo encontra rapidamente soluções que aprimoram o desempenho do sistema.

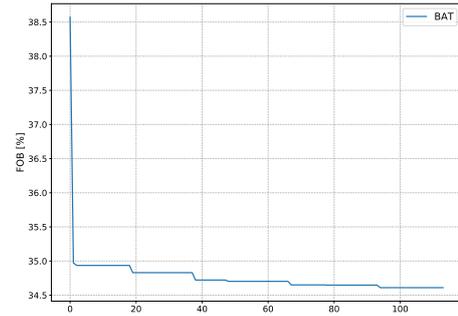


Figura 4. Curva de convergência da otimização de usinas PV.

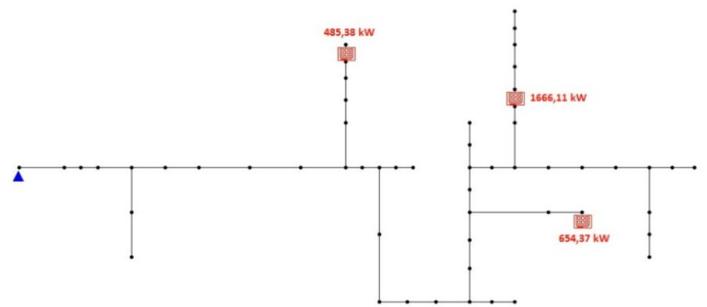


Figura 5. Sistema após a otimização da alocação e dimensionamento de usinas PV.

Na Tabela 3 e na Fig. 5 são apresentadas o dimensionamento e alocação ótimos das usinas, destaca-se que a representação foi obtida através da interface do OpenDSS-G e, portanto, algumas barras internas do sistema podem ser visualizadas, embora estas não tenham sido consideradas como possíveis locais de alocação das usinas. Enquanto, na Tabela 4 é analisado um comparativo entre sistema original e o sistema otimizado em relação às perdas elétricas, o nível de desequilíbrio e o valor da função objetivo (FOB). O comportamento do sistema antes e depois da inserção das usinas, sob o aspecto da potência injetada pela subestação, pode ser avaliado na Fig. 6. Ademais, pode-se verificar o comportamento da potência total injetada pelas usinas PV.

Tabela 3. Alocação e dimensionamento ótimos.

Barra	Potência [kW]
890	637,13
844	1.688,25
822	488,35

Tabela 4. Comparação entre o sistema base e o otimizado.

	Sistema Base	Sistema Otimizado
Perdas [kWh]	18.252,60	8.921,13
Desequilíbrio [%]	1,19	1,30
FOB [%]	70,36	34,60

5.2 Alocação e dimensionamento de bancos de baterias

Essa otimização por sua vez, foi baseada em três bancos de baterias e contou com os mesmos parâmetros da simulação anterior, como pode ser verificado na Tabela 5. Já os

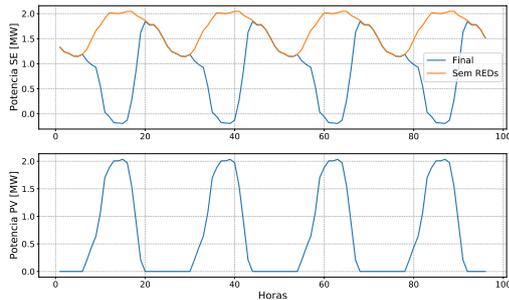


Figura 6. Potência injetada pela Subestação e pelas usinas PV.

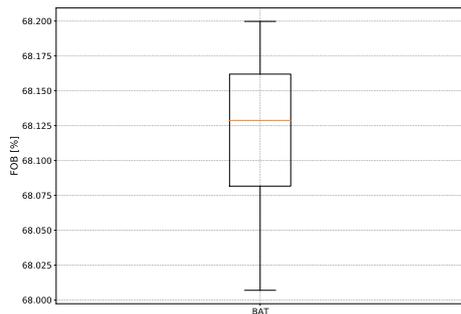


Figura 7. Distribuições das funções objetivos.

limites de potência mínima e máxima dos bancos, foram definidos como 100 e 1500 kW, respectivamente.

É apresentada na Fig. 7 a distribuição das FOBs das 10 execuções definidas. Enquanto, na Tabela 6 é possível verificar os dados estatísticos dos resultados referentes as FOBs e aos tempos de simulação.

A Fig. 8, ilustrada a curva de convergência da melhor solução ao longo do processo iterativo. Pode ser constatado que o processo iterativo foi interrompido ao atingir o número máximo de interações e que o sistema não conseguiu atingir um desempenho muito melhor depois da otimização. Esse fato pode ser esclarecido devido ao sistema IEEE 34 barras não possuir nenhuma outra fonte, o que tem como consequência o banco de baterias impactar positivamente o sistema quando está descarregando e negativamente quando está carregando, visto que a SE deverá fornecer energia neste caso.

Tabela 5. Dados da otimização da alocação e dimensionamento de bancos de baterias.

Número de bancos	3	Parâmetro α	0.95
Iterações	200	Parâmetro λ	0.05
População	100	Potência Mínima	100 kW
Simulações	10	Potência Máxima	1500 kW
Estagnação	10		

Tabela 6. Dados estatísticos das FOBs e dos tempos de simulação.

	FOBs [%]	Tempo [min.]
Máximo	68,46	47,20
Mínimo	67,96	5,69
Médio	68,15	28,01
Mediana	68,13	26,66
Desvio Padrão	0,16	13,53

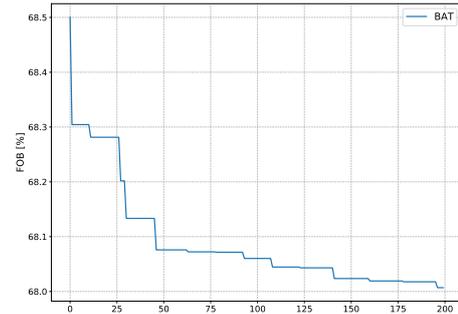


Figura 8. Curva de convergência da otimização de bancos de baterias.

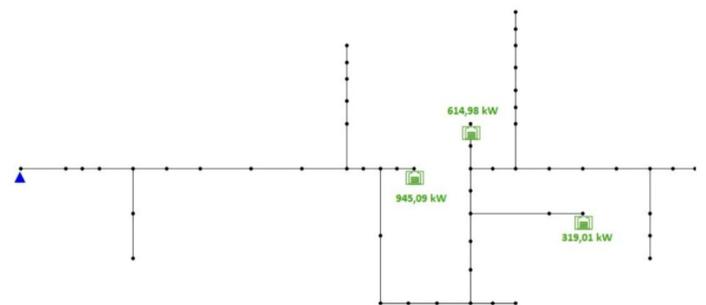


Figura 9. Sistema após a otimização da alocação e dimensionamento de bancos de baterias.

Na Tabela 7 e na Fig. 9 são apresentadas o dimensionamento e alocação ótimos dos bancos de baterias. Pode-se ver na Tabela 8 a comparação entre as perdas elétricas, o nível de desequilíbrio e o valor da função objetivo (FOB) do sistema original e do sistema otimizado.

Tabela 7. Alocação e dimensionamento ótimos.

Barra	Potência [kW]
890	317,53
864	658,32
856	795,48

O comportamento do sistema antes e após a inserção dos bancos de baterias é demonstrado na Fig. 10 sob o aspecto da potência injetada pela subestação. Além do mais, é possível, também, verificar o comportamento da energia armazenada nos três bancos ao longo do período de simulação.

5.3 Alocação e dimensionamento de bancos de bateria com três usinas fotovoltaicas

Com a inserção de três usinas fotovoltaicas resultantes da otimização do item 5.1, foi feita a otimização da alocação e dimensionamento para a adição de mais três bancos de bateria, no qual contou com os mesmos parâmetros da simulação anterior, como exibido na Tabela 5.

Tabela 8. Comparação entre o sistema base e o otimizado.

	Sistema Base	Sistema Otimizado
Perdas [kWh]	18.252,60	17.947,41
Desequilíbrio [%]	1,19	1,19
FOB [%]	70,36	69,18

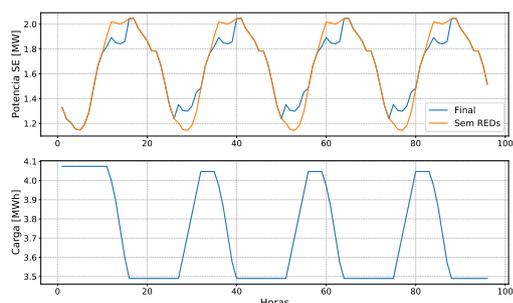


Figura 10. Potência injetada pela Subestação e carga armazenada nos bancos.

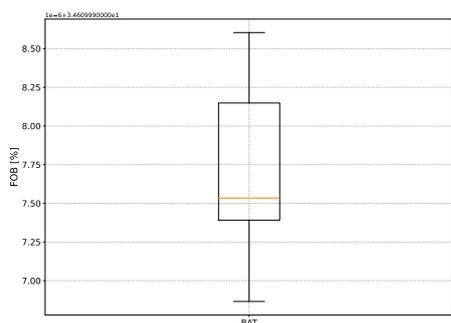


Figura 11. Distribuições das funções objetivos.

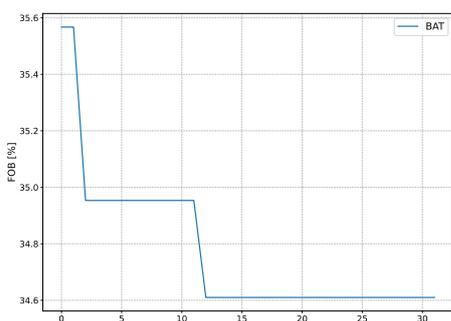


Figura 12. Curva de convergência da otimização de bancos de baterias com a inserção de PVs.

A Fig. 11 mostra as distribuições das FOBs das 10 execuções definidas e a Tabela 9 exibe os dados estatísticos dos resultados referentes as FOBs e aos tempos de simulação.

Tabela 9. Dados estatísticos das FOBs e dos tempos de simulação.

	FOBs [%]	Tempo [min.]
Máximo	34,61	1.472,76
Mínimo	34,61	536,56
Médio	34,61	959,85
Mediana	34,61	965,27
Desvio Padrão	5,61E-07	306,78

A Fig. 12 mostra a curva de convergência resultante da melhor solução ao longo do processo iterativo. É possível visualizar que o processo foi interrompido antes de atingir o número máximo de iterações pois ocorreu a estagnação da melhor solução. E pode-se concluir que o algoritmo encontrou rapidamente soluções próximas do resultado final.

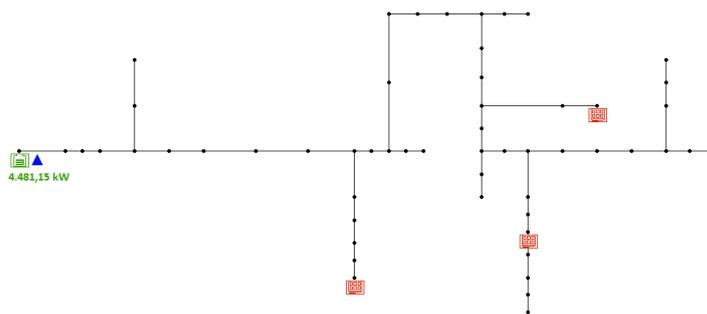


Figura 13. Sistema após a otimização da alocação e dimensionamento de bancos de baterias.

A Tabela 10 e a Fig. 13 apresentam a localização dos bancos de baterias com sua potência total, pois o processo iterativo inseriu os três bancos de bateria na mesma barra, a subestação. E na Tabela 11 tem-se a comparação entre as perdas elétricas, o nível de desequilíbrio e o valor da função objetivo (FOB) do sistema original e do sistema otimizado.

Tabela 10. Alocação e dimensionamento ótimos.

Barra	Dimensionamento [kW]
800	1.486,28
800	1.499,29
800	1.495,58

Tabela 11. Comparação entre o sistema base e o otimizado.

	Sistema Base	Sistema Otimizado
Perdas [kWh]	18.252,60	8.922,52
Desequilíbrio [%]	1,19	1,31
FOB [%]	70,36	34,61

Por último, a Fig. 14 exibe o comportamento do sistema antes e após a inserção dos bancos de baterias sob o aspecto da potência injetada pela subestação. O primeiro gráfico mostra a potência que a subestação está injetando no sistema, com e sem REDs. O segundo gráfico, em verde, exibe a curva das três baterias simuladas, porém, como foi definida a mesma curva de potência para as três baterias, as curvas estão sobrepostas. Interessante verificar que quando a curva está negativa representa que ela está consumindo energia da rede, carregando. E quando a curva está positiva, a bateria está injetando potência na rede. No terceiro gráfico é exibida a potência injetada no sistema pelos PVs. E no último gráfico, tem-se a carga armazenada nas baterias, durante o período de simulação.

6. CONCLUSÃO

O presente trabalho teve como objetivo analisar o impacto da geração fotovoltaica e bancos de baterias no sistema de distribuição IEEE34 barras através de um algoritmo de inteligência computacional. O estudo foi realizado no software OpenDSS via *Python*, utilizando a técnica de otimização *Bat Algorithm* na resolução do problema de alocação e dimensionamento.

Diante dos resultados obtidos, considerando a geração fotovoltaica, percebe-se uma melhora significativa na função

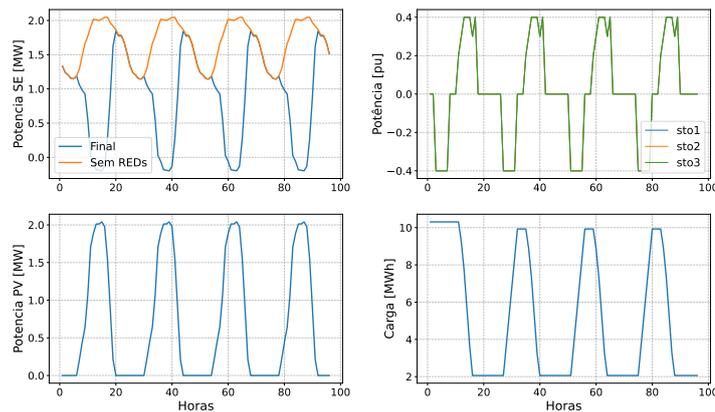


Figura 14. Potência injetada pela Subestação e carga armazenada nos bancos.

objetivo (minimização das perdas técnicas e desvio de tensão) que chega a ser inferior a 50% da função objetivo do sistema base (sem nenhum RED presente). Em relação a alocação e dimensionamento de bancos de baterias foi possível verificar uma melhora do sistema de distribuição (função objetivo) em cerca de 2% em relação ao sistema base. Já para a simulação computacional que analisa a otimização e dimensionamento de bancos de baterias e geração fotovoltaica foi possível perceber que a função objetivo otimizada foi semelhante a da primeira análise, considerando apenas a geração fotovoltaica. Ou seja, a otimização dos bancos de bateria, junto a geração fotovoltaica, para o sistema em estudo, não trouxe impacto significativo.

Como propostas para trabalhos futuros tem-se de analisar e acrescentar um processo de otimização da curva de carga e descarga das baterias, a fim de melhorar o comportamento das mesmas e avaliar o impacto dessas curvas otimizadas na função objetivo. Outra proposta seria de analisar o impacto de outros recursos energéticos distribuídos, como geradores despacháveis, fontes eólicas e carros elétricos, assim como considerar outros aspectos elétricos para a formulação da função objetivo, como o sobrecarregamento dos alimentadores do sistema de distribuição. E por fim, outra perspectiva de estudo/análise seria simulações de sistemas de distribuição maiores/reais para uma melhor análise dos possíveis impactos. Desta forma, com o crescente aumento da inserção de REDs na distribuição, pode-se melhor planejar e otimizar sua inserção, a fim de se obter uma melhor operação dos sistemas como um todo.

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 da Universidade Federal de Juiz de Fora (PPEE), a Agência Nacional de Energia Elétrica (ANEEL), a Petrobras e a Pró-Reitoria de Pós-Graduação e Pesquisa (PROPP) da Universidade Federal de Juiz de Fora pelo apoio no desenvolvimento do presente trabalho.

REFERÊNCIAS

- A. Ali, P. Sanjeevikumar, B.T.e.T.M. (2017). *Electric Power Grids Distribution Generation System For Optimal Location and Sizing - An Case Study Investigation by Various Optimization Algorithms*, volume 10. Energies.
- A. Selim, S.K.e.F.J. (2020). “efficient optimization technique for multiple dg allocation in distribution networks”. *Applied Soft Computing*, 86, 105–938.
- BATISTA, Rodrigo Viana; DE ARAUJO, L.R.P.D.R. (2020). Alocação Ótima de geradores distribuídos para redução de perdas em sistemas elétricos de distribuição considerando incertezas da demanda. *Anais da Sociedade Brasileira de Automática*, 2(n.1).
- EPE (2021). Balanço energético nacional 2021: Ano base 2020. <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-601/topico-596/BEN2021.pdf>. [acessado em 01 de fevereiro de 2022].
- EPE/MME (2018). *Recursos Energéticos Distribuídos 2050*. Empresa de Pesquisa e Energia, Nota Técnica PR 08/18, Rio de Janeiro.
- Fasina, T., A.B.A.A.e.I.I. (2021). Impact of distributed generation on the nigerian power network. *Indonesian Journal of Electrical Engineering and Computer Science*, 21(3), 1263–1270.
- Furtado L., Neto W. A., M.A.J.I.S.O.L.R.M.A.L.M. (2015). Bat search algorithm aplicado na localização de robôs móveis.
- Injeti, S.K. (2018). A pareto optimal approach for allocation of distributed generators in radial distribution systems using improved differential search algorithm. *Journal of Electrical Systems and Information Technology*, 5(3), 908–927.
- K. Seeprompting, e.a. (2018). Optimal grid-connected with multi-solar pv placement and sizing for power loss reduction and voltage profile improvement. *International Symposium on Communications and Information Technologies (ISCIT), IEEE*, 479–483.
- P. D. P. Reddy, V.V.R.e.T.G.M. (2016). Application of flower pollination algorithm for optimal placement and sizing of distributed generation in distribution systems. *Journal of Electrical Systems and Information Technology*, 3(1), 14–22.
- Tolmasquim, M.T. and Filho, M.M. (2019). *Recursos Energéticos Distribuídos e suas potencialidades*. Synergia, Rio de Janeiro.
- Y. Shi, M.B. (2019). A gradient based decentralized volt/var optimization scheme for distribution systems with high der penetration. *IEEE PES GTD Grand International Conference and Exposition Asia (GTD Asia), IEEE*, 2019, 649–654.
- Y. Thangaraj, K.R.e.D.K.R. (2017). Optimal allocation of dg and dstatcom in radial distribution system using cuckoo search optimization algorithm. *Modelling and Simulation in Engineering*, vol.2017(número), 11.
- Yang, X.S. (2010). “a new metaheuristic bat-inspired algorithm”. *In Nature inspired cooperative strategies for optimization (NICSO 2010)*, 65–74.