

OTIMIZAÇÃO DA ALOCAÇÃO DE GERAÇÃO DISTRIBUÍDA ATRAVÉS DE PSOAlisson Morais Firmo (IC)¹, Elcio Franklin de Arruda (PQ)¹¹ Universidade Federal de Itajubá.

Este trabalho investiga impactos da inserção de Geração Distribuída (GD) em redes elétricas, bem como formas de inserção que melhorem parâmetros técnicos da rede, dada a crescente crise climática e as vantagens financeiras das energias renováveis. A inserção não planejada de unidades de Geração Distribuída (GD), a exemplo das solares, acarreta diversos transtornos técnicos, dentre os quais se destacam o aumento das perdas joulicas, a ocorrência de picos de tensão, a sobrecarga de equipamentos e um maior desequilíbrio entre as fases. Para resolver essa questão complexa e com diversos focos, foi desenvolvido um processo computacional em Python, usando o programa de simulação OpenDSS. O método analisa em conjunto quatro pontos técnicos: diminuir as perdas ativas, manter a tensão perto do ideal (1.0 p.u.), baixar a carga máxima dos elementos e reduzir o desequilíbrio de tensão. Por meio de um sistema de avaliação com pesos, que transforma cada ponto em uma nota, define-se a qualidade de cada possível ponto de instalação. Depois, um algoritmo de Otimização por Enxame de Partículas (PSO) é usado para achar o local que oferece o melhor resultado, considerando entre esses diversos objetivos, assegurando uma integração técnica eficaz e segura da GD. A metodologia foi validada utilizando o sistema-teste *IEEE* de 123 barras, um modelo complexo que simula desafios realistas.

Palavras-chave: Algoritmo PSO (Otimização por Enxame de Partículas). Geração Distribuída (GD). Otimização Multiobjetivo. Qualidade de Energia. Redes Elétricas.

Introdução

Dois grandes vetores estão redesenhando o mapa da energia no mundo: a urgência climática, que exige menos emissões de carbono, e o apelo econômico das fontes renováveis. Nesse novo contexto, a Geração Distribuída (GD), que consiste na produção de energia próxima ao consumidor final, ganha muita visibilidade. Integrar usinas solares ou de biomassa à rede elétrica local é o passo inicial para um sistema mais eficiente, automatizado e sustentável.

O problema é que essa integração traz desafios técnicos significativos. Se um sistema de geração for instalado de forma inadequada, ele pode prejudicar a estabilidade e a qualidade da energia entregue a todos (ANEEL, 2017). Assim, determinar o local perfeito para a Geração Distribuída é uma tarefa de otimização com múltiplos e, por vezes, contraditórios objetivos (Hadidian-Moghaddam et al., 2018). Essa busca pelo ponto ótimo visa atender simultaneamente a diversos critérios, como reduzir perdas técnicas, melhorar o perfil de tensão, evitar sobrecargas na infraestrutura e minimizar o desequilíbrio do sistema (Anwar e Pota, 2011; Murty e Kumar, 2015). Existem também outros fatores mais específicos, mas que não serão abordados

neste projeto justamente por precisarem de informações que não podem ser adquiridas por simulações.

Dado o vínculo entre esses quatro aspectos e as dificuldades que surgem, identificar a melhor posição para uma GD se transforma em um problema de otimização com diversos propósitos. Métodos que empregam algoritmos meta-heurísticos, a exemplo do Otimização por Enxame de Partículas (PSO) (Jobanputra e Kotwal, 2018), são ótimas ferramentas para explorar o vasto conjunto de soluções e achar pontos de equilíbrio que otimizem os benefícios técnicos de forma completa (Moradi e Abedini, 2010), pavimentando o caminho para uma rede de distribuição verdadeiramente modernizada.

A Otimização por Enxame de Partículas (PSO) é uma técnica de busca de soluções inspirada no comportamento social de bandos de pássaros.

Funciona assim: um conjunto de "partículas" (soluções candidatas) é espalhado pelo espaço do problema. Cada partícula ajusta seu movimento com base em duas informações principais: a melhor solução que ela mesma já encontrou e a melhor solução encontrada por todo o grupo. Essa inteligência coletiva permite que o enxame explore a área de busca de forma eficiente e convirja para a melhor solução possível para o problema

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

(Kennedy e Eberhart, 1995).

Metodologia

Para solucionar a questão de onde alocar de forma otimizada a Geração Distribuída (GD), foi desenvolvido um modelo computacional que combina a simulação de sistemas de energia com técnicas de otimização meta-heurística. A codificação foi feita inteiramente em Python, uma linguagem versátil que oferece diversos recursos valiosos para processamento e exibição de dados, como as bibliotecas NumPy e Matplotlib. Para simular o sistema, foi empregado o OpenDSS, um *software* gratuito voltado para redes de distribuição, e controlado por meio da biblioteca py-dss-interface, que integrou a otimização ao ambiente de simulação. Para confirmar que o método funciona bem, usando uma geração padrão de 150 KW como exemplo, foram feitos testes no sistema *IEEE* de 123 barras, um modelo padrão usado no setor, conhecido por ser complexo, ter uma estrutura de rede peculiar e cargas variáveis, o que o torna um cenário de teste interessante e próximo da realidade.

O foco da metodologia está em abordar o problema não por uma única perspectiva, mas como um desafio de otimização com múltiplos objetivos. A qualidade de cada possível alocação do GD é avaliada com base em um conjunto de quatro parâmetros técnicos fundamentais, considerados indispensáveis para o funcionamento eficaz e saudável da rede. Estes parâmetros são: a minimização das perdas elétricas ativas totais, a manutenção do perfil de tensão o mais próximo possível do valor nominal de 1.0 PU, a minimização do carregamento máximo em qualquer linha ou transformador e, por fim, a minimização do desequilíbrio de tensão entre as fases. Para que critérios de naturezas e unidades tão distintas pudessem ser combinados, foi desenvolvido um sistema de pontuação universal. Inicialmente, o sistema realiza um estudo detalhado de sensibilidade para identificar o comportamento do sistema em todos os contextos imagináveis, definindo, assim, os limites de operação, ou seja, os valores mais altos e mais baixos que cada medida pode atingir.

Partindo dessa avaliação de desempenho, cada resultado obtido em simulação é transformado em uma nota padronizada de 1 a 100, onde a maior nota sempre indica o resultado mais favorável. A combinação dessas várias notas em um único índice de qualidade é feita por meio de uma soma com pesos. Uma "Nota Final" é

calculada atribuindo pesos em porcentagem a cada um dos quatro critérios, definidos pelo usuário e que mostram a importância de cada objetivo. Essa Nota Final Ponderada representa o que o algoritmo de Otimização por Enxame de Partículas (*PSO*) tenta aumentar. Ao buscar diminuir o valor negativo dessa nota, o enxame de partículas investiga as soluções possíveis, as barras candidatas e, em várias tentativas, encontra a posição que melhor equilibra todos os objetivos definidos. Uma versão adaptada do *PSO* foi criada para permitir uma análise visual detalhada desse processo, registrando todo o histórico do enxame para gerar gráficos de sua evolução com o tempo.

Resultados e discussão

Nesta seção, são apresentados e analisados os resultados obtidos através da aplicação da ferramenta de otimização desenvolvida. Foram conduzidos múltiplos testes no sistema *IEEE* 123 barras com o objetivo de validar a eficácia do algoritmo e, principalmente, de investigar o impacto da variação dos pesos estratégicos na determinação da solução ótima. A análise foca nos *trade-offs* (relações de compromisso) entre os quatro critérios de avaliação: perdas, tensão, carregamento e desequilíbrio.

Para cada cenário estratégico de otimização, os hiperparâmetros do algoritmo de Otimização por Enxame de Partículas foram ajustados para garantir uma convergência robusta e eficiente. A alteração nos pesos da função objetivo cria diferentes "paisagens" de solução, que se beneficiam de dinâmicas de busca distintas. Sendo assim, a cada teste, o número de partículas e o número de iterações foram adaptados para assegurar uma exploração adequada do espaço de busca sem custos computacionais excessivos.

Adicionalmente, os coeficientes que governam o movimento do enxame — o peso de inércia (w), o cognitivo ($c1$) e o social ($c2$) — foram refinados para encontrar o equilíbrio ideal entre a velocidade de convergência e a capacidade de evitar ótimos locais. Essa abordagem de ajuste fino assegura que o resultado de cada cenário (foco em perdas, segurança, etc.) represente o verdadeiro potencial de otimização encontrado pelo *PSO* sob condições de busca bem calibradas para aquele desafio específico.

O primeiro teste foi realizado configurando-se um cenário de otimização equilibrada, onde todos os quatro objetivos receberam a mesma importância. Os pesos foram definidos como: 0,25 para todos os parâmetros.

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

Esta configuração busca uma solução de compromisso geral, que não necessariamente se destaca em um único critério, mas que apresenta um bom desempenho em todos eles. A Figura 1 ilustra o processo de convergência do enxame de partículas para este cenário. É possível observar a exploração inicial do espaço de soluções na Iteração 0 e a gradual concentração das partículas nas regiões de maior nota ao longo das iterações subsequentes.

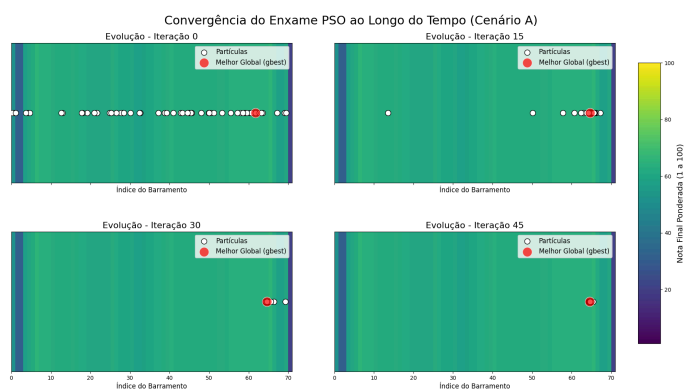


Figura 1 – Teste final do cenário A

O resultado final encontrado pelo algoritmo apontou o Barramento 152 como a localização ótima, atingindo uma Nota Final Ponderada de 65,43. Os indicadores técnicos individuais para esta solução foram:

- Perdas Elétricas: 95,3422 kW (Nota: 45,50)
- Nível de Tensão: 1,0017 PU (Nota: 96,47)
- Carregamento Máximo: 157,10% (Nota: 87,19)
- Desequilíbrio de Tensão: 0,723% (Nota: 32,55)

A análise deste resultado demonstra que o barramento escolhido representa, de fato, uma solução de compromisso. Ele pode não ser o ponto de menores perdas absolutas nem o de melhor perfil de tensão, mas equilibra os quatro objetivos de forma a maximizar a pontuação geral, servindo como nosso ponto de referência para as análises seguintes.

No segundo cenário, a estratégia foi alterada para priorizar agressivamente a eficiência energética, atribuindo um peso significativamente maior à minimização das perdas elétricas. Os pesos foram configurados como: perdas = 0.70, tensão = 0.10, carregamento = 0.10 e desequilíbrio = 0.10.

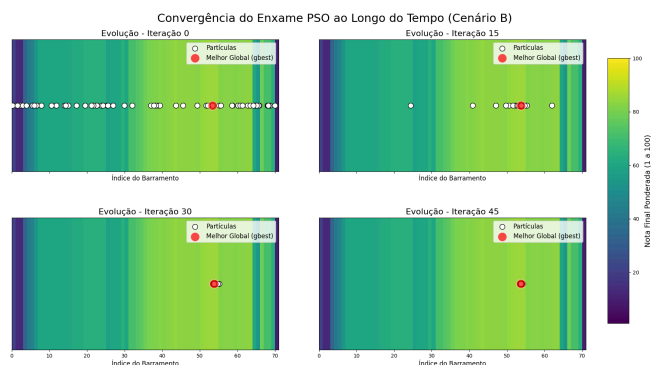


Figura 3 – Teste final do cenário B

Como esperado, a mudança na função objetivo levou o algoritmo a uma solução diferente, indicando o Barramento 95 como o ponto ótimo. Observa-se que as perdas foram reduzidas para 94,5653 kW um valor inferior ao do cenário equilibrado. Contudo, essa melhoria na eficiência teve um custo: o Nível de Tensão deteriorou-se, atingindo 1,0399 PU. Este resultado evidencia um *trade-off* clássico no planejamento da alocação de GD: o ponto que minimiza as perdas não é, necessariamente, o que garante a melhor performance em outros indicadores técnicos, como a segurança dos equipamentos.

O terceiro teste investigou um cenário em que a prioridade máxima é a segurança operacional e a preservação dos ativos da rede, uma perspectiva comum para concessionárias que operam sistemas próximos de seus limites de capacidade. A estratégia, portanto, foi configurada para favorecer esmagadoramente a solução que minimizasse o estresse sobre as linhas e transformadores, em detrimento da máxima eficiência. Os pesos foram ajustados para refletir essa prioridade: perdas=0.10, tensão=0.10, carregamento=0.80 e desequilíbrio=0.00.

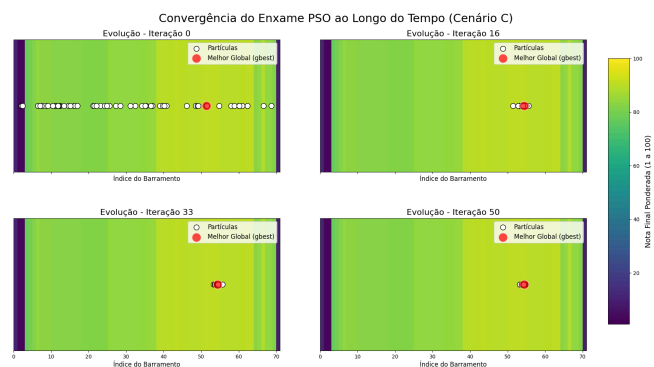


Figura 3 – Teste final do cenário C

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

A mudança drástica nos pesos levou o algoritmo a convergir novamente para a barra 95, conforme ilustrado pela Figura 3. Ao analisar os indicadores técnicos, a estratégia da otimização se torna evidente: o carregamento máximo na rede foi de apenas 156,99%, o menor valor entre todos os cenários testados. A ferramenta identificou um local que efetivamente alivia a rede ou cuja injeção de potência se distribui por caminhos de menor impedância, evitando sobrecarregar qualquer componente. Este teste é particularmente revelador, pois demonstra a capacidade da ferramenta de tomar decisões conservadoras. Para uma operadora de distribuição, esta seria a escolha prudente para garantir a confiabilidade do sistema e potencialmente adiar a necessidade de investimentos caros em reforços de rede, sacrificando a eficiência de curto prazo em troca da segurança e da longevidade da infraestrutura a longo prazo.

Conclusões

A análise comparativa dos três cenários demonstra que não existe uma única "melhor" localização para a Geração Distribuída, mas sim uma localização ótima que é dependente da estratégia e das prioridades do planejador da rede. A ferramenta desenvolvida provou ser eficaz em identificar e quantificar os complexos *trade-offs* entre eficiência energética (perdas) e a integridade técnico-operacional da rede (tensão, carregamento, desequilíbrio). Ao permitir a fácil manipulação dos pesos dos objetivos, o sistema se torna um poderoso instrumento de apoio à decisão, permitindo que diferentes políticas de planejamento sejam simuladas e seus impactos, compreendidos de forma clara e objetiva antes da implementação de um projeto. Dessa forma, a metodologia transforma objetivos estratégicos, muitas vezes abstratos, como "aumentar a segurança da rede" ou "melhorar o desempenho", em decisões de projeto que podem ser medidas e justificadas. Além de indicar uma conexão ideal, a solução demonstra os efeitos dessa opção em vários aspectos, fornecendo uma visão completa, essencial para a organização de redes cada vez mais complexas e dinâmicas. A aptidão para efetuar uma avaliação de sensibilidade, alterando as prioridades estratégicas, possibilita que as empresas e os planejadores explorem o impacto de variadas abordagens de gestão e normas. Concluindo, a ferramenta criada não só aborda um desafio técnico de alocação, como também atua como ponto de partida para a discussão estratégica. Assim,

viabilizando o desenvolvimento de redes de distribuição mais flexíveis e eficientes, prontas para a evolução contínua do setor energético.

Agradecimentos

Agradeço à Universidade Federal de Itajubá (UNIFEI) pela oportunidade de realizar esta Iniciação Científica e pelo apoio financeiro através da bolsa concedida, fundamental para minha dedicação a este projeto, o que tornou a pesquisa possível.

Ao meu orientador, Professor Dr. Elcio Franklin de Arruda, por me introduzir ao mundo da pesquisa científica. Agradeço pela paciência, pelo conhecimento compartilhado e por toda a orientação, que foram fundamentais para meu desenvolvimento como futuro pesquisador.

A minha família e aos meus amigos, pelo apoio constante e incentivo durante toda esta jornada.

Referências

- ANEEL. (2017), “Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST Módulo 8 – Qualidade de Energia Elétrica, Procedimentos de Distribuição de Energia.
- Hadidian-Moghaddam, M.J., Arabi-Nowdeh, S., Bigdeli, M. and Azizian, D. (2018), “A multi-objective optimal sizing and siting of distributed generation using ant lion optimization technique”, *Ain Shams Engineering Journal*, Ain Shams University.
- Anwar, A. and Pota, H.R. (2012), “Optimum capacity allocation of DG units based on unbalanced three-phase optimal power flow”, 2012 *IEEE Power and Energy Society General Meeting*.
- Murty, V.V.S.N. and Kumar, A. (2015), “Optimal placement of DG in radial distribution systems based on new voltage stability index under load growth”, *International Journal of Electrical Power & Energy Systems*.
- Jobanputra, J. and Kotwal, C. (2018), “Optimal Power Dispatch using Particle Swarm Optimization”, *Proceedings - 2018 International Conference on Smart Electric Drives and Power System, ICSEDPS 2018*.
- Moradi, M.H. and Abedini, M. (2010), “Optimal multidistributed generation location and capacity by genetic algorithms”, *PEOCO 2010 - 4th International Power Engineering and Optimization Conference, Program and Abstracts*
- Kennedy, J., & Eberhart, R. (1995). *Particle Swarm Optimization*. In *Proceedings of ICNN'95 - International Conference on Neural Networks*.