

AVALIAÇÃO DE TÉCNICAS META-HEURÍSTICAS APLICADAS AOS SISTEMAS ELÉTRICOS DE POTÊNCIA

Higor Matheus de Oliveira (IC)¹, Elcio Franklin de Arruda (PQ)¹

¹Universidade Federal de Itajubá (UNIFEI)

Palavras-chave: Inteligência artificial, Métodos de otimização, *Python*, Sistemas de potência, Técnicas metaheurísticas.

Introdução

Os Sistemas Elétricos de Potência (SEP) são a infraestrutura vital para o desenvolvimento social e econômico, sendo a qualidade na distribuição de energia um fator crítico [1-2]. Um dos maiores desafios neste setor é a queda de tensão em longos alimentadores, um problema que compromete a estabilidade da rede e a qualidade do fornecimento [3]. Uma solução técnica eficaz e viável é a instalação de bancos de capacitores para elevar o perfil de tensão [4]. Contudo, o sucesso dessa abordagem depende de sua alocação ótima, um problema combinatório de alta complexidade para o qual os algoritmos meta-heurísticos se mostram particularmente adequados [5-6].

Este trabalho aborda diretamente o desafio da regulação de tensão, propondo uma solução otimizada para a alocação de bancos de capacitores. O objetivo central é desenvolver e aplicar duas meta-heurísticas — Algoritmos Genéticos (AGs) e Estratégias Evolutivas (EEs) — para determinar as localizações ideais desses equipamentos. A eficácia da metodologia será validada pela melhora mensurável do perfil de tensão da rede, demonstrando uma solução robusta para o problema

Metodologia

A metodologia une a modelagem do sistema elétrico a meta-heurísticas, escolhidas pela sua eficiência em encontrar ótimas soluções para problemas complexos em tempo viável [5].

Formulação do Problema de Otimização

O problema de otimização consiste em selecionar o barramento ideal (b_k), a partir de um conjunto de candidatos elegíveis, para a instalação de um banco de capacitores com capacidade pré-definida. O objetivo é maximizar a qualidade da tensão na rede, o que é

alcançado através de uma função objetivo (FO) que minimiza o desvio das tensões em todas as barras (V_i) em relação ao valor nominal de 1,0 p.u. A solução deve satisfazer a restrição fundamental de que, após a instalação, todas as tensões no sistema permaneçam dentro dos limites operativos regulatórios, tipicamente $0,95 \text{ p.u.} \leq V_i \leq 1,05 \text{ p.u.}$

Algoritmos de Otimização Implementados

Foram desenvolvidas duas abordagens meta-heurísticas para resolver o problema de otimização formulado.

Algoritmos Genéticos (AGs)

Os Algoritmos Genéticos (AGs) são métodos de otimização inspirados na evolução natural, projetados para encontrar a melhor solução possível para problemas complexos. Sua grande vantagem é a capacidade de explorar um vasto campo de soluções ao mesmo tempo em que se concentra nas mais promissoras, evitando ficar preso em respostas boas, mas não ótimas (ótimos locais) [7-8]. Para isso, o problema é modelado como uma população de "indivíduos", onde cada um representa uma solução candidata (neste caso, um barramento da rede) e tem sua qualidade medida por uma pontuação de aptidão (*fitness*).

O algoritmo funciona de forma iterativa ao longo de gerações. Partindo de uma população inicial, operadores genéticos refinam as soluções: a seleção escolhe os indivíduos mais aptos; o cruzamento combina as características dos melhores para criar novos descendentes; e a mutação introduz variações para garantir a diversidade. Este ciclo evolutivo repete-se até que um critério de parada seja alcançado (como um número máximo de gerações), e o indivíduo com a maior pontuação de aptidão é apresentado como a solução final otimizada [9].

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




Figura 1 – Passo computacional realizado pelo AG.

Estratégias Evolutivas (EEs)

As Estratégias Evolutivas (EE) são algoritmos de otimização inspirados na teoria da seleção natural [10], que emulam a adaptação de uma população de soluções por meio de ciclos de mutação e seleção. Uma de suas principais vantagens é a capacidade de operar sem a necessidade de informações do gradiente da função objetivo, o que as torna especialmente eficazes para problemas de alta complexidade com superfícies de solução irregulares ou não deriváveis [11].

O processo funciona da seguinte maneira: uma população parental de μ indivíduos gera λ descendentes através de recombinação e mutação. A geração seguinte é formada pela seleção dos μ melhores indivíduos a partir da união de pais e filhos. Este mecanismo, conhecido como estratégia elitista ($\mu+\lambda$), garante que as melhores soluções encontradas sejam sempre preservadas, otimizando a busca. Embora os indivíduos sejam tipicamente representados por vetores de valores reais [17], nesta aplicação a estrutura foi adaptada para lidar com a variável discreta do problema — o número do barramento — conforme ilustrado na Figura 2.

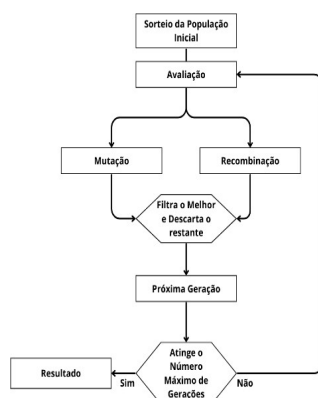


Figura 2 – Passo computacional realizado pela EE.

Ferramentas Computacionais

A implementação prática da metodologia foi realizada integrando os algoritmos de otimização (AG e EE), desenvolvidos em Python, com o simulador de sistemas de distribuição *OpenDSS*, utilizado para a análise do fluxo de potência. A comunicação entre as ferramentas foi viabilizada pela biblioteca *py-dss-interface*, que permitiu a automação do processo. A cada iteração, o algoritmo em Python gerava uma solução candidata (um barramento), instruiu o *OpenDSS* a simular a inserção do capacitor nesse local e, em seguida, recebia os resultados de tensão para avaliar a aptidão da solução. Esse ciclo de "gerar-simular-avaliar" foi repetido continuamente até a convergência do algoritmo para a solução ótima.

Sistema de estudo (IEEE – 37 Barras)

As simulações foram conduzidas no sistema-teste de distribuição IEEE 37 barras, um modelo de referência internacional baseado em um alimentador trifásico real de 4,8 kV. A principal característica do sistema é sua configuração em delta, que, somada a cargas desiguais, resulta em um perfil inerentemente desequilibrado. Em sua configuração-base, detalhada na Figura 3, o sistema não possui bancos de capacitores, utilizando apenas um regulador de tensão na subestação [12-13]. Essas condições o tornam um cenário desafiador e representativo, ideal para a validação dos algoritmos de otimização propostos.

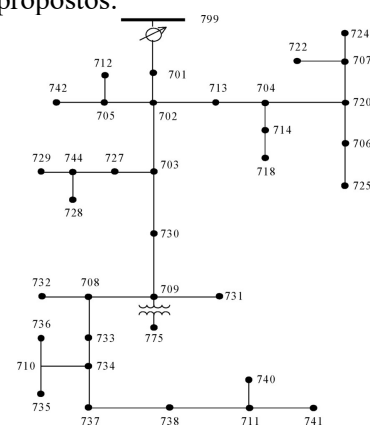


Figura 3 – Diagrama unifilar simplificado do sistema IEEE 37 barras.

Análise do Caso Base (Sem Compensação)

A primeira etapa da análise consistiu em simular o fluxo de potência do sistema IEEE 37 barras em sua configuração original, sem a instalação de nenhum banco

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

de capacitores. Essa simulação define a linha de base do problema. Conforme será detalhado na seção de resultados, o perfil de tensão do caso base apresenta uma média inferior ao valor nominal ideal e uma dispersão significativa entre os barramentos, confirmando a necessidade de medidas corretivas.

Resultados e discussão

O problema de estudo consistiu na alocação ótima de um único banco de capacitores de 1000 kVAr na rede IEEE 37 barras. O objetivo da otimização foi a melhoria do perfil de tensão em todos os barramentos do sistema, sendo um método aplicado para cada técnica (AG e EE).

Parametrização e Análise de Convergência do Algoritmo Genético (AG)

O Algoritmo Genético foi configurado com seleção por roleta, taxa de mutação de 0,047 e um operador de crossover que gera dois descendentes por recombinação. A Figura 4, que ilustra a convergência do algoritmo para uma função de maximização, exibe um comportamento característico: um rápido aumento na qualidade da solução nas gerações iniciais, seguido por flutuações que representam a fase de exploração do espaço de busca. Por fim, a curva se estabiliza, indicando que o algoritmo convergiu para uma região de solução ótima.




Figura 4 – Resultado do Algoritmo Genético.

Parametrização e Análise de Convergência da Estratégia Evolutiva (EE)

A Estratégia Evolutiva foi implementada com recombinação aleatória, gerando três descendentes por mutação para cada pai, e utilizando um critério de seleção elitista ($\mu+\lambda$) para preservar os melhores indivíduos. A Figura 5 ilustra a convergência do algoritmo para uma função de minimização, revelando um comportamento distinto do AG. A trajetória é notavelmente mais suave e monotônica, com melhorias constantes e graduais. Essa

estabilidade, sem as flutuações abruptas vistas anteriormente, é atribuída diretamente ao mecanismo elitista, que garante a preservação das melhores soluções e promove um refinamento consistente a cada geração.




Figura 5 – Resultado da Estratégia Evolutiva.

Análise Comparativa dos Resultados de Alocação

Para testar a robustez, ambos os algoritmos foram executados cinco vezes de forma independente. O Algoritmo Genético (AG) demonstrou maior variabilidade, identificando um conjunto mais amplo de barramentos ótimos: {799, 733, 775, 730, 709, 706, 711}. Em contrapartida, a Estratégia Evolutiva (EE) apresentou maior consistência, convergindo predominantemente para as soluções {799, 733, 775}. A interseção dos resultados, com ambos os métodos apontando para os barramentos 799, 733 e 775, fornece um forte indicativo de que estas são, de fato, as localizações mais eficazes para a instalação de capacitores na rede.

Análise Comparativa do perfil de Tensão

A eficácia da solução é quantificada na Figura 6, que compara o perfil de tensão da rede antes e depois da otimização. No caso base (linha vermelha), a tensão média era de aproximadamente 0,98 p.u. Após a alocação do capacitor conforme a solução do Algoritmo Genético (linha verde), a média elevou-se para um patamar próximo do ideal de 1,0 p.u., o que confirma uma melhora significativa na qualidade e eficiência da energia entregue.




Figura 6 – Média das tensões AG.

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

A Figura 7 complementa a análise, mostrando a redução do desvio padrão das tensões após a otimização com AG e EE. Ambos os métodos foram eficazes não apenas em ajustar as tensões para a faixa regulatória ideal, mas também em diminuir sua dispersão. Um desvio padrão menor indica um perfil de tensão mais uniforme em toda a rede, o que resulta em um sistema eletricamente mais estável e robusto.




Figura 7 – Desvio padrão das tensões (AG e EE).

Os resultados demonstram que a alocação ótima de capacitores resolveu o problema de regulação de tensão. A análise confirma que a solução não apenas eleva a média das tensões a níveis ideais (Figura 6), mas também minimiza sua variabilidade na rede (Figura 7). Isso garante que todos os consumidores recebam uma tensão mais uniforme e de melhor qualidade, validando a eficácia das localizações encontradas pelas meta-heurísticas.

Conclusões

Ao concluir este trabalho de Iniciação Científica, fica evidente o desempenho distinto e complementar das meta-heurísticas aplicadas. O Algoritmo Genético (AG) provou ser uma poderosa ferramenta de exploração global, apesar de sua maior variabilidade, enquanto a Estratégia Evolutiva (EE) demonstrou alta consistência e repetibilidade. A principal contribuição desta pesquisa é a validação cruzada dos resultados: a convergência de ambas as metodologias, com suas abordagens de busca fundamentalmente diferentes, para um subconjunto comum de soluções confere alta confiabilidade às localizações ótimas encontradas. Isso não só valida a solução proposta, mas também reitera a capacidade das meta-heurísticas de fornecerem respostas robustas para desafios de otimização em Sistemas Elétricos de Potência.

Agradecimentos

Agradeço ao meu orientador, Professor Elcio Franklin de Arruda, pela condução segura e apoio técnico inestimável. Estendo minha gratidão à Universidade Federal de Itajubá (UNIFEI) e ao seu Programa de Iniciação Científica, pelo ambiente, pelos recursos e, em especial, pelo indispensável apoio financeiro. Por fim, agradeço aos meus familiares e amigos por todo o suporte emocional e incentivo, e a todos que, direta ou indiretamente, contribuíram para a concretização deste projeto.

Referências

- [1] STEVENSON Jr., William D. Elementos de Análise de Sistemas de Potência. Rio de Janeiro: McGraw-Hill do Brasil, 1986.
- [2] MONTICELLI, A. Fluxo de carga em redes de energia elétrica. 1. ed. São Paulo: Edgard Blucher, 1983.
- [3] GLOVER, J. D.; OVERBYE, T. J.; SARMA, M. S. Power System Analysis & Design. 5. ed. CL-Engineering, 2011.
- [4] ZANETTA JR., L. C. Fundamentos de Sistemas Elétricos de Potência. São Paulo: Livraria da Física, 2008.
- [5] KAGAN, N. et al. Introdução aos sistemas de distribuição de energia elétrica. 2. ed. São Paulo: Blucher, 2010.
- [6] KAGAN, N. et al. Métodos de otimização aplicados a sistemas elétricos de potência. 1. ed. São Paulo: Blucher, 2009.
- [7] M. B. Carvalho e A. Yamakami, “Meta-heurística híbrida de sistema de colônia de formigas e algoritmo genético para o problema do caixeiro viajante,” *Trends Comput. Appl. Math.*, vol. 9, no. 1, pp. 31-40, 2008.
- [8] R. C. Bansal, “Optimization methods for electric power systems: An overview,” *Int. J. Emerg. Electr. Power Syst.*, vol. 2, no. 1, 2005.
- [9] G. H. dos S. Costa e E. F. de Arruda, “Alocação otimizada de unidades de geração distribuída...,” Trabalho de Conclusão de Curso, Dept. Eng. Elétrica, Univ. Federal de Itajubá, Itajubá, MG, Brasil, 2019.
- [10] I. Rechenberg, *Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution*. Stuttgart, Germany: Frommann-Holzboog, 1973.
- [11] H.-P. Schwefel, *Numerical Optimization of Computer Models*. Chichester, UK: John Wiley & Sons, 1981.
- [12] K. P. Schneider, B. A. Mather, B. C. Pal, *et al.*, “Analytic Considerations and Design Basis for the IEEE Distribution Test Feeders,” *IEEE Trans. Power Syst.*, vol. 32, no. 4, pp. 2603-2611, Jul. 2017.
- [13] W. H. Kersting, “Radial distribution test feeders,” in *Proc. 2001 IEEE Power Eng. Soc. Winter Meeting*, Columbus, OH, USA, 2001, pp. 908-912.