

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

Alisson Moraes Firmo¹ (IC), Higor Matheus de Oliveira¹ (IC), Elcio Franklin de Arruda (PQ)¹

¹Universidade Federal de Itajubá.

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

Introdução

Os sistemas elétricos de potência (SEP) são divididos em geração, transmissão e distribuição, fornecendo energia a residências, empresas e indústrias, essenciais para o desenvolvimento econômico e social [1-4]. A energia gerada por fontes como usinas eólicas e hidrelétricas é transmitida em alta tensão e distribuída aos consumidores em baixa tensão [1-4]. Falhas ocorrem de forma aleatória, e a minimização de seus impactos começa pelo monitoramento das redes elétricas e equipamentos, envolvendo detecção, correção de falhas e proteção contra sobrecargas [1-5].

O planejamento da expansão do sistema é necessário para atender à demanda crescente, incluindo a construção de novas usinas e redes [6]. Ferramentas computacionais e técnicas de otimização são fundamentais para operação eficiente dos SEPs, com destaque para os algoritmos meta-heurísticos, devido à sua capacidade de lidar com problemas complexos com múltiplos ótimos locais [8-9]. Esses algoritmos, inspirados na natureza, são adaptáveis para lidar com restrições e objetivos não lineares, sendo amplamente utilizados em SEPs [8-9].

Neste artigo, como resultado do primeiro ano do projeto, será apresentado o desenvolvimento de duas técnicas meta-heurísticas em Python para resolver problemas nos SEPs, com foco inicial na alocação de bancos de capacitores em sistemas de distribuição. Serão utilizados softwares como OpenDSS e bibliotecas Python, como py-dss-interface.

Metodologia

Considerando a diversidade de técnicas de otimização aplicáveis à solução de problemas relacionados aos sistemas elétricos de potência, é evidente a dificuldade

em selecionar uma técnica adequada para um problema específico. As meta-heurísticas são amplamente empregadas na otimização desses sistemas devido à sua capacidade de encontrar soluções próximas ao ótimo global em um tempo razoável.

Diversas técnicas de otimização, como Estratégia Evolutiva (EE), Redes Neurais Artificiais (RNAs), Algoritmos Genéticos (AGs) e busca de colônia de formigas (ACS), têm sido aplicadas para resolver problemas em sistemas de potência. Este estudo propõe mapear essas técnicas, implementá-las em softwares de simulação elétrica, como o OpenDSS, e desenvolver algoritmos em Python para sua aplicação em sistemas elétricos de potência (SEPs).

A execução do projeto se dará através das seguintes diretrizes metodológicas:

1. Estudo das ferramentas utilizadas para a elaboração do desenvolvimento dos algoritmos de otimização.
2. Proposição de um problema piloto referente aos sistemas elétricos de distribuição. Nesta etapa será estudado o problema de alocação inteligente de Bancos de Capacitores.
3. Mapeamento de técnicas meta-heurísticas. Serão mapeadas diferentes técnicas meta-heurísticas e realizada a descrição de seu processo de desenvolvimento, visando avaliar as condições computacionais de implementação em Python.
4. Desenvolvimento em Python dos algoritmos meta-heurísticos: Algoritmos Genéticos e Estratégia Evolutiva, utilizando o OpenDSS e py-dss-interface.
5. Avaliação dos resultados obtidos. As técnicas serão comparadas realizando variações nos cenários dos problemas propostos e considerando os níveis de complexidade dos problemas propostos.

Algoritmos Genéticos:

A principal motivação para o uso de Algoritmos Genéticos (AGs) está no seu potencial como técnica de otimização, combinando processos de busca direcionada e aleatória. Isso permite encontrar o ponto ótimo de uma função, mesmo quando esta apresenta não linearidade, múltiplos picos e descontinuidades. Assim, os AGs realizam uma busca eficaz, evitando a convergência para ótimos locais.

Os AGs começam com uma string relacionada aos parâmetros do problema, chamada de codificação, onde a string é formada por bits (0 ou 1). A função de avaliação, ou *fitness function*, é aplicada a cada indivíduo e avalia o quão bem ele se adapta ao problema. A população inicial é gerada aleatoriamente e evolui ao longo de gerações, usando três operadores:

- Avaliação/Seleção: Seleção dos indivíduos mais adaptados para a próxima geração.
- Cruzamento: Combinação das informações genéticas de dois indivíduos, gerando novos indivíduos.
- Mutação: Alteração de genes em uma string para introduzir variabilidade.

Esses operadores são aplicados à população, gerando novas gerações de indivíduos. Após um número definido de gerações, ou outro critério de parada, o melhor indivíduo é selecionado como solução otimizada do problema, como ilustrado na Figura 1.




Figura 1 – Diagrama de Algoritmo Genético.

Estratégia evolutiva:

Estratégias evolutivas são técnicas de otimização

inspiradas na seleção natural, utilizadas em problemas complexos de diversas áreas, como engenharia e ciência da computação. Elas simulam a adaptação de populações ao longo de gerações, onde soluções são tratadas como "indivíduos" que passam por mutação, recombinação e seleção. Diferente dos algoritmos tradicionais, essas estratégias não exigem gradientes, sendo úteis em problemas com superfícies de solução irregulares.

No algoritmo, a população $P(t)$, composta por μ indivíduos, gera novos indivíduos $P'(t)$ por recombinação e $P''(t)$ por mutação. A próxima geração $P(t+1)$ é composta pelos μ melhores indivíduos, selecionados com base em seu desempenho na função objetivo (FO). Este algoritmo, pertencente à categoria $(\mu+\lambda)$, garante que indivíduos promissores não sejam descartados, preservando a qualidade das soluções e maximizando a eficiência da busca.

Os indivíduos são representados por vetores numéricos (x_i, y_i, z_i) , encapsulando atributos que definem seu desempenho na solução do problema, conforme a Figura 2.




Figura 2 – Diagrama de Estratégia Evolutiva.

Resultados e discussão

Através de uma rotina em python, utilizando a biblioteca *py_dss_interface*, para simular uma rede elétrica no *software* OpenDSS, foram desenvolvidas as técnicas de otimização AG e EE descritas na seção anterior. As técnicas foram submetidas à busca da solução do problema de alocação de bancos de capacitores (um banco de 1000 KVar para cada método) em redes de distribuição com o objetivo de melhorar o perfil de tensão em todas as barras da rede. Foi utilizada a rede

IEEE 13 barras.

O AG desenvolvido utilizou a técnica da roleta no processo de seleção das futuras gerações, 0.047 de taxa de mutação e o *crossover* como recombinação, gerando 2 filhos para o processo de seleção para as próximas gerações.

O monitoramento da evolução do melhor indivíduo no AG, ao longo das gerações, é apresentado na Figura 3.




Figura 3 – Evolução algoritmo genético.

O gráfico mostra que, nas primeiras gerações, o algoritmo genético (AG) gera soluções de qualidade crescente, como esperado, já que a função objetivo de maximização busca o indivíduo com maior avaliação. Inicialmente, o AG explora o espaço de busca de forma ampla, resultando em oscilações na curva, reflexo da experimentação de diferentes soluções antes de convergir para o valor ótimo.

O algoritmo EE utilizou uma taxa de recombinação aleatória, gerando 3 filhos por indivíduo por mutação e a seleção dos melhores indivíduos ($\mu+\lambda$) para a próxima geração.

A Figura 4 ilustra a evolução da melhor solução encontrada pela EE ao longo das gerações, considerando uma função objetivo de minimização.




Figura 4 – Evolução estratégia evolutiva.

A análise do gráfico da estratégia evolutiva (EE) revela um padrão de convergência distinto do algoritmo

genético (AG). Enquanto o AG busca maximizar as soluções, a EE foi configurada para minimizá-las, além disso, apresenta uma trajetória mais suave e contínua, com melhorias constantes. A EE permite um refinamento gradual das soluções, mantendo um progresso consistente à medida que as gerações avançam. Suas operações de seleção, recombinação e mutação garantem tanto a preservação das melhores características quanto a diversidade, evitando estagnações. A estabilidade no gráfico indica que a EE minimiza flutuações abruptas, favorecendo uma busca eficiente pela solução ótima.

Ao analisar os resultados do algoritmo genético (AG) e da estratégia evolutiva (EE) para o posicionamento de bancos de capacitores, observa-se uma diferença na variabilidade das localidades selecionadas. Ambos os algoritmos foram executados cinco vezes, e o AG apresentou maior variabilidade, com barramentos como 799, 733, 775, 730, 709, 706 e 711. Já a EE demonstrou menor variabilidade, concentrando-se nos barramentos 799, 733 e 775. Apesar dessa diferença, ambos os métodos coincidem nas barras 799, 733 e 775 indicando que são as melhores posições, ou melhor, um grande potencial para otimizar a eficiência da rede elétrica. Essa tendência pode ser ainda mais clara quando são analisados gráficos que mostram a média das tensões em cada geração — como por exemplo no AG e o desvio padrão das tensões para os dois métodos, ver Figura 6.




Figura 5 - Média das tensões AG.




Figura 6 - Desvio padrão das tensões (AG e EE)
O gráfico de médias das tensões por geração, ver Figura

5, demonstra a evolução da qualidade da tensão, com melhorias visíveis pela curva verde, enquanto a linha vermelha representa a média inicial. O Algoritmo Genético (AG) e a Estratégia Evolutiva (EE) aproximam a tensão da faixa ideal de 0.95 a 1.05 pu, com um desvio padrão baixo indicando estabilidade no sistema, ver figura 6. A coincidência das barras selecionadas reflete a eficácia das posições na otimização. Os bancos de capacitores não apenas melhoram a média, mas também reduzem a variabilidade das tensões.

Conclusões

Neste trabalho de Iniciação Científica, foi analisada a aplicação de métodos meta heurísticos como: Algoritmos Genéticos (AGs) e Estratégias Evolutivas (EEs) nos Sistemas Elétricos de Potência (SEPs). Os AGs mostraram-se eficientes na exploração do espaço de soluções, evitando ótimos locais, mas com maior variabilidade nas execuções devido à sua natureza estocástica. Já as EEs apresentaram uma convergência mais estável e consistente, com menor variabilidade e uma trajetória mais suave de melhorias contínuas.

Por fim, a análise conjunta das duas abordagens revelou que, apesar das diferenças no comportamento de convergência, ambas as técnicas identificaram posições coincidentes para a alocação de bancos de capacitores, como observado nos barramentos comuns entre as execuções. Isso reforça a validade das soluções encontradas e confirma a capacidade das meta-heurísticas de fornecerem respostas eficazes para problemas complexos de otimização em SEPs.

Agradecimentos

Gostaríamos de expressar nossa sincera gratidão a todos aqueles que contribuíram para a realização deste trabalho. Primeiramente, agradecemos ao nosso orientador, Elcio Franklin de Arruda, pela orientação constante, pelas valiosas sugestões e pelo apoio durante todas as etapas da pesquisa. Sua dedicação e experiência foram essenciais para o desenvolvimento deste projeto.

Agradeço também à Universidade Federal de Itajubá, que, por meio do Programa de Iniciação Científica, proporcionou os recursos e o ambiente necessário para a realização deste estudo.

Somos gratos à UNIFEI e à Fapemig, pelo apoio financeiro, sem o qual este projeto não teria sido possível. Por fim, agradecemos nossas famílias e amigos pelo suporte emocional e incentivo durante todo o

processo.

A todos, o nosso mais sincero agradecimento.

Referências

- [1] STEVENSON Jr., William D. Elementos de Análise de Sistemas de Potência. Rio de Janeiro: McGraw-Hill do Brasil, 1986.
- [2] GLOVER, J. D.; OVERBYE, T. J.; SARMA, M. S. Power System Analysis & Design. 5. ed. CL-Engineering, 2011.
- [3] ZANETTA JR., L. C. Fundamentos de Sistemas Elétricos de Potência. São Paulo: Livraria da Física, 2008.
- [4] MONTICELLI, A. Fluxo de carga em redes de energia elétrica. 1. ed. São Paulo: Edgard Blucher, 1983.
- [5] KAGAN, N. et al. Introdução aos sistemas de distribuição de energia elétrica. 2. ed. São Paulo: Blucher, 2010.
- [6] SIMON, Sishaj Pulikottil et al. "POWER SYSTEM PLANNING AND OPERATION." In: Applications of Modern Heuristic Optimization Methods in Power and Energy Systems. IEEE, 2020, p. 39-225. DOI: 10.1002/9781119602286.ch3.
- [7] ARRUDA, Elcio Franklin de. Estimativa de estados de distorções harmônicas em sistemas elétricos de potência utilizando estratégias evolutivas. 2008. Tese (Doutorado em Sistemas de Potência) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2008. DOI: 10.11606/T.3.2008.tde-25092008-121620.
- [8] KAGAN, N. et al. Métodos de otimização aplicados a sistemas elétricos de potência. 1. ed. São Paulo: Blucher, 2009.
- [9] BANSAL, R. C. Optimization methods for electric power systems: An overview. International Journal of Emerging Electric Power Systems, v. 2, n. 1, 2005.
- [10] COSTA, G. H. dos S.; ARRUDA, E. F. de. Alocação otimizada de unidades de geração distribuída ao longo de um sistema de distribuição e ajuste inteligente de equipamentos para otimização de parâmetros da operação. Trabalho de Conclusão de Curso, UNIFEI, 2019.
- [11] GOODFELLOW, Ian. Deep Learning. 2016.
- [12] CARVALHO, M. B.; YAMAKAMI, A. Meta-heurística híbrida de sistema de colônia de formigas e algoritmo genético para o problema do caixeiro viajante. Trends in Computational and Applied Mathematics, v. 9, n. 1, p. 31-40, 2008.
- [13] SANTA CATARINA, Adair. SIMULATED ANNEALING. 2018.
- [14] Schneider, K. P., Mather, B. A., Pal, B. C., Ten, C. W., Shirek, G. J., Zhu, H., Fuller, J. C., Pereira, J. L. R., Ochoa, L. F., de Araujo, L. R., Dugan, R. C., Matthias, S., Paudyal, S., McDermott, T. E., & Kersting, W. (2017). "Analytic Considerations and Design Basis for the IEEE Distribution Test Feeders." *IEEE Transactions on Power Systems*, vol. PP, no. 99, pp. 1-1.