

ALGORITMOS GENÉTICOS NA ENGENHARIA ELÉTRICA**GENETIC ALGORITHMS IN ELECTRICAL ENGINEERING** <https://doi.org/10.63330/aurumpub.019-002>**Joelson Lopes da Paixão**

Mestre em Engenharia Elétrica, especialista em Engenharia de Segurança do Trabalho e em Educação Básica, Tecnológica e EAD

E-mail: joelson.paixao@hotmail.com

Alzenira da Rosa Abaide

Doutora em Engenharia Elétrica, professora titular na UFSM

E-mail: alzenira@ufsm.br

RESUMO

Em face do aumento exponencial da demanda por energia elétrica, impulsionado pelo desenvolvimento tecnológico e pela urbanização acelerada, as técnicas de otimização heurísticas despontam como instrumentos cruciais na engenharia elétrica para promover a eficiência e a sustentabilidade. Este estudo explora os Algoritmos Genéticos (AGs), uma metodologia bioinspirada na evolução darwiniana, destacando sua versatilidade para resolver problemas complexos de otimização que envolvem não linearidades, restrições múltiplas e incertezas estocásticas. Por meio de uma análise teórica aprofundada, discute-se a estrutura conceitual dos AGs, incluindo seus operadores essenciais como seleção, cruzamento e mutação, além de potenciais aplicações em áreas como planejamento de sistemas de potência, controle de dispositivos elétricos, estimação de parâmetros e otimização de redes de distribuição. A literatura especializada evidencia que os AGs superam abordagens convencionais, como métodos determinísticos, em cenários multivariáveis e de alta dimensionalidade, fomentando soluções eficientes, adaptáveis e robustas que contribuem para a redução de custos operacionais e impactos ambientais. Além disso, são abordadas limitações inerentes, como o tempo computacional e a sensibilidade a parâmetros, sugerindo hibridizações com outras meta-heurísticas para aprimoramento.

Palavras-chave: Algoritmos genéticos; Otimização; Sistemas de potência; Engenharia elétrica; Meta-heurísticas.

ABSTRACT

In view of the exponential increase in electricity demand, driven by technological development and rapid urbanization, heuristic optimization techniques have emerged as crucial tools in electrical engineering to promote efficiency and sustainability. This study explores Genetic Algorithms (GAs), a methodology inspired by Darwinian evolution, highlighting their versatility in solving complex optimization problems involving nonlinearities, multiple constraints, and stochastic uncertainties. Through an in-depth theoretical analysis, the conceptual structure of GAs is discussed, including their essential operators such as selection, crossover, and mutation, as well as potential applications in areas such as power system planning, control of electrical devices, parameter estimation, and distribution network optimization. The specialized literature shows that GAs outperform conventional approaches, such as deterministic methods, in multivariable and high-dimensional scenarios, fostering efficient, adaptable, and robust solutions that contribute to reducing operational costs and environmental impacts. Furthermore, inherent limitations, such as computational time and parameter sensitivity, are addressed, suggesting hybridizations with other metaheuristics for improvement.



Keywords: Genetic algorithms; Optimization; Power systems; Electrical engineering; Metaheuristics.



1 INTRODUÇÃO

O avanço tecnológico e a busca incessante por maior conforto e qualidade de vida impulsionam o crescimento contínuo do consumo de energia elétrica em escala global, demandando inovações constantes por parte das empresas do setor para garantir um suprimento confiável, eficiente e sustentável. De acordo com dados recentes, o consumo mundial de energia elétrica cresceu em média 3% ao ano na última década, com projeções indicando um aumento de até 50% até 2050, impulsionado pela eletrificação de transportes, indústrias e residências (ANEEL, 2008).

Contudo, esse expansionismo acarreta desafios significativos, como o risco de depleção de recursos naturais não renováveis, impactos ambientais adversos – incluindo emissões de gases de efeito estufa – e elevados investimentos em novas infraestruturas de geração, transmissão e distribuição. Na engenharia elétrica, a otimização de recursos emerge como uma estratégia fundamental para mitigar esses problemas, promovendo o uso racional e eficiente da energia sem comprometer o desenvolvimento econômico e social.

Problemas de otimização em sistemas elétricos frequentemente envolvem variáveis interdependentes, restrições não lineares e incertezas estocásticas, tornando métodos tradicionais, como programação linear ou gradiente descendente, inadequados em muitos casos devido à sua suscetibilidade a mínimos locais e à incapacidade de lidar com espaços de busca discretos ou combinatórios (KATOCH; CHAUHAN; KUMAR, 2021).

Nesse contexto, os Algoritmos Genéticos (AGs) despontam como uma ferramenta poderosa, inspirada nos princípios darwinianos de seleção natural, sobrevivência do mais apto e reprodução genética (GOLDBERG, 1989). Desenvolvidos inicialmente por John Holland na década de 1970, os AGs simulam processos evolutivos para explorar soluções ótimas em problemas complexos, oferecendo robustez em cenários onde métodos exatos falham. Este trabalho oferece uma visão teórica abrangente dos AGs, enfatizando sua aplicação genérica na engenharia elétrica, com sugestões de usos práticos em diversos subdomínios, visando fomentar avanços na área e contribuir para uma matriz energética mais sustentável e resiliente.

2 DESCRIÇÃO DO PROBLEMA

Na engenharia elétrica, problemas de otimização surgem em diversas subáreas, como o planejamento e a operação de sistemas de potência, nos quais o objetivo é minimizar os custos operacionais totais enquanto se atende à demanda variável de carga e se respeitam restrições físicas e regulatórias (Da Paixao et al., 2023; Paixão et al., 2025). Esses problemas podem ser descritos em termos de funções a serem minimizadas ou maximizadas, considerando limites como a capacidade dos geradores, perdas resistivas nas linhas de transmissão, estabilidade de tensão e incertezas estocásticas associadas tanto à carga quanto à geração de fontes renováveis intermitentes, como a eólica e a solar (ANEEL, 2008).

Um exemplo clássico é o problema de fluxo de potência ótimo (OPF), que busca determinar a alocação mais eficiente da geração elétrica de modo a atender à demanda, respeitando limites de tensão e de ângulos de fase, enquanto minimiza os custos de operação de cada unidade geradora. A complexidade desses problemas aumenta significativamente com a inclusão de elementos estocásticos, como variações na produção de fontes renováveis ou flutuações na demanda, exigindo abordagens robustas capazes de evitar mínimos locais e explorar soluções globais em espaços de busca de alta dimensionalidade (PEDAPENKI; SWATHI, 2017).

Outros desafios incluem o despacho econômico de carga (EDC), que aloca geração entre unidades para minimizar custos sob restrições de rampa e reserva; o planejamento de expansão de redes, que otimiza investimentos em novas linhas e subestações considerando cenários de longo prazo; e o controle de estabilidade transitória, onde se ajustam parâmetros de controladores para mitigar oscilações.

Nesses contextos, a multidimensionalidade, não convexidade e presença de variáveis discretas (como estados de chaves em redes de distribuição) desafiam métodos determinísticos tradicionais, que podem convergir para soluções subótimas ou exigir linearizações aproximadas (BISHT et al., 2021). Os AGs, ao simularem processos evolutivos populacionais, oferecem uma alternativa eficaz para navegar por esses espaços de busca complexos, promovendo diversidade de soluções e adaptabilidade a incertezas reais do sistema elétrico.

3 ALGORITMOS GENÉTICOS

Os Algoritmos Genéticos (AGs), introduzidos por John Holland em 1975, baseiam-se em mecanismos evolutivos naturais para solucionar problemas de otimização, incorporando conceitos como variação genética, seleção e herança (LINDEN, 2008). Fundamentados na teoria darwiniana, os AGs modelam a evolução de populações de soluções candidatas, onde indivíduos mais adaptados ao "ambiente" (definido pela função objetivo) têm maior chance de reproduzir e transmitir traços genéticos, permitindo a exploração de soluções globais em problemas NP-difíceis.

Essa heurística é especialmente útil em problemas multivariáveis e não lineares comuns na engenharia elétrica, onde espaços de busca vastos e irregulares demandam estratégias estocásticas robustas (ALAM et al., 2020). Vantagens incluem a capacidade de lidar com variáveis discretas e contínuas, paralelismo inerente e resistência a mínimos locais, embora desvantagens como alto custo computacional e necessidade de calibre (*tuning*) de parâmetros sejam notadas na literatura.

3.1 CONCEITOS BÁSICOS

Em AGs, soluções potenciais são representadas como cromossomos, estruturas compostas por genes que codificam variáveis do problema – por exemplo, níveis de tensão ou potências geradas em um sistema

elétrico. O genótipo refere-se à codificação abstrata (e.g., binária ou real), enquanto o fenótipo é a interpretação prática no domínio do problema, influenciada pelo ambiente externo. Essa dualidade permite uma abstração flexível, facilitando a aplicação em diversos contextos. A Tabela 1 resume as analogias entre biologia e AGs, destacando como conceitos naturais são adaptados computacionalmente.

Tabela 1 – Correspondência entre Genética Biológica e Algoritmo Genético.


Genética Biológica	Algoritmo Genético
Cromossomo	String, cromossomo
Gene	Característica
Alelo	Valor
Lócus	Posição
Genótipo	Estrutura
Fenótipo	Conjunto de parâmetros

Fonte: Adaptado de LINDEN (2008).

3.2 FUNCIONAMENTO DO ALGORITMO GENÉTICO

O ciclo de um AG inicia com a criação de uma população inicial aleatória, tipicamente composta por 50 a 200 indivíduos dependendo da complexidade do problema, seguida de iterações evolutivas envolvendo avaliação, seleção, cruzamento, mutação e elitismo, até atender a um critério de parada como número máximo de gerações ou convergência da fitness média. A Figura 1 ilustra esse fluxo iterativo, enfatizando o equilíbrio entre exploração (diversidade) e exploração (intensificação).

Figura 1 – Esquema de um algoritmo genético.



Fonte: Adaptado de LINDEN (2008).



A seguir são listadas as etapas juntamente com as descrições do que ocorre em cada uma:

- **Representação:** Variáveis podem ser codificadas em binário (para problemas discretos como alocação de recursos), real (para variáveis contínuas como ângulos de fase) ou inteiro. Em aplicações elétricas, representações reais são preferíveis para variáveis como tensões ou potências, evitando perda de precisão em discretizações (SOUZA et al., 2006).
- **População Inicial:** Gerada randomicamente para promover diversidade inicial, o tamanho deve equilibrar diversidade genética e custo computacional, evitando convergência prematura em populações pequenas ou sobrecarga em grandes (ISA et al., 2024). Técnicas como inicialização heurística podem ser usadas para acelerar a convergência em problemas elétricos.
- **Avaliação:** A função fitness quantifica a adequação de cada indivíduo, penalizando violações de restrições (e.g., via funções de penalidade Lagrangeanas) e premiando proximidade ao ótimo. Em sistemas elétricos, pode incluir custos de operação, perdas de transmissão e penalidades por instabilidade dinâmica ou violações de limites (PEDAPENKI; SWATHI, 2017).
- **Seleção:** Técnicas como roleta (proporcional à fitness), torneio (comparação randômica) ou ranking favorecem indivíduos com melhor fitness, preservando diversidade para evitar elitismo excessivo (KUMAR et al., 2010).
- **Cruzamento:** Operadores como um-ponto, dois-pontos ou aritmético recombina genes de pais selecionados, gerando descendentes que exploram novas combinações genéticas e potencializam sinergias (ALAM et al., 2020). Taxas típicas variam de 60-90%.
- **Mutação:** Introduz variações aleatórias com baixa probabilidade (1-10%), prevenindo estagnação em mínimos locais e mantendo diversidade genética, essencial em problemas dinâmicos como otimização em tempo real (KATOCH; CHAUHAN; KUMAR, 2021).
- **Elitismo:** Mantém os melhores indivíduos (tipicamente 1-5% da população) na próxima geração, acelerando convergência sem perda de soluções ótimas (GOLDBERG, 1989).
- **Critério de Parada:** Baseado em iterações máximas (e.g., 100-1000), estagnação da melhor fitness por N gerações ou tolerância de erro pré-definida, adaptável a restrições computacionais (LINDEN, 2008).

4 APLICAÇÕES EM ENGENHARIA ELÉTRICA

Os AGs encontram ampla aplicação na engenharia elétrica, particularmente em otimização de sistemas de potência, onde sua capacidade de lidar com não linearidades e restrições múltiplas os torna superiores a métodos clássicos. Por exemplo, no fluxo de potência ótimo (OPF), AGs minimizam perdas e



custos em redes multibarras, incorporando restrições de segurança e incertezas renováveis, alcançando reduções de até 10% em custos operacionais comparados a abordagens lineares (BISHT et al., 2021).

No despacho econômico de carga (EDC), alocam geração de forma ótima entre unidades térmicas, hidráulicas e renováveis, considerando restrições ambientais como emissões de CO₂ e econômicas como custos variáveis, com estudos demonstrando convergência mais rápida em sistemas de grande escala (PEDAPENKI; SWATHI, 2017).

Outras sugestões incluem o planejamento de expansão de redes de distribuição, onde AGs otimizam localização e dimensionamento de capacitores, transformadores e linhas para reduzir custos de investimento e perdas, integrando cenários de demanda futura e falhas (SHAHI et al., 2016). Em controle de sistemas, AGs tunam parâmetros de estabilizadores de potência síncrona (PSS) e controladores FACTS, aprimorando a resposta dinâmica a perturbações e melhorando a estabilidade angular em redes interconectadas (SOUZA et al., 2006).

Para estimação de parâmetros em sistemas elétricos, como identificação de falhas em linhas de transmissão ou modelagem de cargas, AGs fornecem soluções precisas em cenários multivariáveis e ruidosos, superando métodos de mínimos quadrados em precisão (SILVA, 2013). Hibridizações com outras heurísticas, como otimização por enxame de partículas (PSO) ou algoritmos de colônia de formigas, ampliam sua robustez em problemas estocásticos, como integração de veículos elétricos ou microrredes, reduzindo tempos de convergência em até 30% (KATOCH; CHAUHAN; KUMAR, 2021). Limitações, como sensibilidade a parâmetros iniciais e escalabilidade em sistemas muito grandes, podem ser mitigadas por calibragem (tuning) adaptativo baseado em aprendizado de máquina ou paralelismo computacional (ISA et al., 2024).

5 CONSIDERAÇÕES FINAIS

Este estudo delineou os princípios teóricos dos Algoritmos Genéticos e suas aplicações na engenharia elétrica, destacando sua capacidade de lidar com complexidades inerentes a sistemas de potência, como não linearidades, incertezas e restrições multifacetadas. Os AGs não apenas otimizam recursos operacionais, reduzindo custos e perdas, mas também contribuem para a sustentabilidade energética ao facilitar a integração de fontes renováveis e a resiliência de redes inteligentes. Evidências da literatura reforçam sua superioridade em problemas reais, onde métodos tradicionais falham, promovendo soluções inovadoras e adaptáveis.

No entanto, desafios como o equilíbrio entre exploração e exploração, e o impacto do ruído computacional, sugerem a necessidade de avanços em variantes paralelas ou híbridas. Pesquisas futuras devem investigar integrações com inteligência artificial moderna, como aprendizado profundo para autocalibre (*auto-tuning*) de parâmetros ou redes neurais para representação de fitness, visando lidar com



incertezas crescentes em redes inteligentes e sistemas ciber-físicos. A versatilidade dos AGs os torna essenciais para inovações na engenharia elétrica, pavimentando o caminho para uma transição energética mais eficiente e ecológica.



REFERÊNCIAS

- ANEEL. Energia disponível no Brasil e no mundo. Brasília: Aneel, 2008. Disponível em: <http://www2.aneel.gov.br/arquivos/pdf/atlas_par1_cap2.pdf>. Acesso em: 07 out. 2024.
- ALAM, T. et al. Genetic algorithm: reviews, implementations, and applications. *International Journal of Engineering Pedagogy*, v. 10, n. 6, p. 57-77, 2020.
- BISHT, V. S.; JOSHI, N.; JETHI, G. S.; BHAKUNI, A. S. A review on genetic algorithm and its application in power system engineering. In: MALIK, H. et al. (ed.). *Metaheuristic and evolutionary computation: algorithms and applications*. Singapore: Springer, 2021. p. 97-118. (Studies in Computational Intelligence, v. 916). DOI: https://doi.org/10.1007/978-981-15-7571-6_5. Disponível em: <https://link.springer.com/chapter/10.1007/978-981-15-7571-6_5>. Acesso em: 4 out. 2025.
- DA PAIXAO, Joelson Lopes *et al.* Energy Storage Management In A Microgrid For EV Fast-Charging. 2023 15th Seminar on Power Electronics and Control, SEPOC 2023, 2023. DOI: <https://doi.org/10.1109/SEPOC58810.2023.10322635>
- GOLDBERG, D. E. Genetic algorithms in search, optimization, and machine learning. Reading: Addison-Wesley, 1989.
- ISA, F. M. et al. A review of genetic algorithm: operations and applications. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, v. 34, n. 2, p. 168-181, 2024.
- KATOCH, S.; CHAUHAN, S. S.; KUMAR, V. A review on genetic algorithm: past, present, and future. *Multimedia Tools and Applications*, v. 80, p. 8091-8126, 2021.
- KUMAR, M. et al. Genetic algorithm: review and application. *SSRN Electronic Journal*, 2010.
- LINDEN, R. Algoritmos genéticos: uma importante ferramenta da inteligência computacional. Rio de Janeiro: Brasport, 2008.
- PAIXÃO, Joelson Lopes *et al.* Optimized Strategy for Energy Management in an EV Fast Charging Microgrid Considering Storage Degradation. *Energies*, 2025. DOI: <https://doi.org/10.3390/en18051060>
- PEDAPENKI, K. K.; SWATHI, G. Application of genetic algorithm in electrical engineering. *International Journal of Pure and Applied Mathematics*, v. 114, n. 8, p. 115-124, 2017.
- SHAHI, B. et al. A Review Over Genetic Algorithm and Application of Wireless Network Systems. *Procedia Computer Science*, [S. l.], v. 78, p. 431-438, 2016. DOI: <https://doi.org/10.1016/j.procs.2016.02.085>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877050916000879>>. Acesso em: 1 out. 2025.
- SILVA, E. Algoritmo genético: ferramenta computacional em estimativas de sinais periódicos, aperiódicos e caóticos. 2013. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Itajubá, Itajubá, 2013.
- SOUZA, S. A. et al. Parameter estimation for an electric power system using genetic algorithms. *IEEE Latin America Transactions*, v. 4, n. 1, p. 47-54, 2006.