

UNIVERSIDADE FEDERAL DE SANTA CATARINA - UFSC
CURSO DE ENGENHARIA ELETRÔNICA

SEBASTIÃO INÁCIO DE MATOS FILHO

**OTIMIZAÇÃO DO PROJETO DE TRANSFORMADORES MONOFÁSICOS
UTILIZANDO ALGORITMOS GENÉTICOS**

Florianópolis

2023

Sebastião Inácio de Matos Filho

**OTIMIZAÇÃO DO PROJETO DE TRANSFORMADORES MONOFÁSICOS
UTILIZANDO ALGORITMOS GENÉTICOS**

Trabalho de Conclusão de Curso submetido ao Curso de Graduação em Engenharia Eletrônica da Universidade Federal de Santa Catarina para a obtenção do título de Bacharel em Engenharia Eletrônica.

Orientador: Prof. Jean Viane Leite

Florianópolis

2023

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Filho, Sebastião Inácio de Matos
Otimização do Projeto de Transformadores Monofásicos
Utilizando Algoritmos Genéticos / Sebastião Inácio de
Matos Filho ; orientador, Jean Vianeí Leite, 2023.
76 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia Eletrônica, Florianópolis, 2023.

Inclui referências.

1. Engenharia Eletrônica. 2. Algoritmo Genético. 3.
Transformadores Monofásicos. 4. Software de Elementos
Finitos. 5. EFCAD. I. Leite, Jean Vianeí. II. Universidade
Federal de Santa Catarina. Graduação em Engenharia
Eletrônica. III. Título.

Sebastião Inácio de Matos Filho

**OTIMIZAÇÃO DO PROJETO DE TRANSFORMADORES MONOFÁSICOS
UTILIZANDO ALGORITMOS GENÉTICOS**

Este trabalho foi julgado adequado para obtenção do Título de Bacharel em Engenharia Eletrônica e aprovado em sua forma final pela Banca Examinadora.

Florianópolis, 11 de março de 2024.

Prof^ª. Daniela Ota Hisayasu Suzuki
Coordenadora do Curso

Banca Examinadora:

Prof. Jean Viane Leite
Orientador
Universidade Federal de Santa Catarina

Prof. Gustavo Felipe Martin Nascimento
Universidade Federal de Santa Catarina

Prof. Carlos Alexandre Corrêa Wengerkievicz
Universidade Federal de Santa Catarina

AGRADECIMENTOS

Agradeço primeiramente a Deus, pela força e por ter me iluminado durante cada passo dessa jornada.

A minha família, especialmente à Antonieta, Sebastião e Cleomar, pelo amor e apoio incondicionais.

À minha namorada Cristiane, cuja presença trouxe ao mesmo tempo o caos e a paz essenciais para minha trajetória.

Aos meus amigos, por cada momento e palavras de motivação.

Ao meu orientador Jean, por ter me ajudado a finalizar este meu último desafio da graduação.

RESUMO

Transformadores monofásicos são importantes em sistemas de engenharia elétrica e eletrônica, especialmente em redes de transmissão e distribuição de energia. Este trabalho foca na otimização do volume total e redução dos custos de fabricação de dois transformadores monofásicos, utilizando algoritmos genéticos. Foram realizadas simulações 2D em um software de elementos finitos (EFCAD) para analisar a indução magnética nos transformadores. Os resultados, incluindo gráficos, tabelas comparativas e imagens de simulações, demonstram a aplicabilidade dos algoritmos genéticos na melhoria do projeto dos transformadores. Este estudo, embasado em uma revisão bibliográfica abrangente, oferece contribuições para o campo da otimização em transformadores monofásicos.

Palavras-chave: Algoritmo Genético, Otimização de Volume, Transformadores Monofásicos, Simulação 2D, Software de Elementos Finitos, EFCAD.

ABSTRACT

Single-phase transformers are crucial in electrical and electronic engineering systems, particularly in power transmission and distribution networks. This work focuses on optimizing the total volume and reducing manufacturing costs of two single-phase transformers using genetic algorithms. 2D simulations were conducted in a finite element software (EFCAD) to analyze the magnetic induction in the transformers. The results, including graphs, comparative tables, and simulation images, demonstrate the applicability of genetic algorithms in improving transformer design. This study, based on a comprehensive literature review, contributes to the field of optimization in single-phase transformers.

Keywords: Genetic Algorithm, Volume Optimization, Single-Phase Transformers, 2D Simulation, Finite Element Software, EFCAD.

LISTA DE FIGURAS

Figura 1 - Representação dos enrolamentos primários e secundários no núcleo.....	19
Figura 2 - Lâminas Padronizadas tipo E e tipo I.	36
Figura 3 - Relação entre comprimentos das lâminas padronizadas e comprimento da coluna central.	37
Figura 4 - Tabela de Densidades de Corrente Recomendadas por Faixa de Potência.	40
Figura 5 - Gráfico representando o volume do núcleo do melhor indivíduo e média de volume do núcleo da população para cada geração do Exemplo 1.	58
Figura 6 - Gráfico representando o volume do núcleo do melhor indivíduo e média de volume do núcleo da população para cada geração do Exemplo 2.	59
Figura 7 - Gráfico representando o desvio padrão da população por geração no algoritmo de otimização de volume do núcleo do Exemplo 1.....	60
Figura 8 - Gráfico representando o desvio padrão da população por geração no algoritmo de otimização de volume do núcleo do Exemplo 2.....	60
Figura 9 - Distribuição da indução magnética no núcleo do transformador do Exemplo 1 via simulação com o software EFCAD.	61
Figura 10 - Distribuição da indução magnética no núcleo do transformador do Exemplo 2 via simulação com o software EFCAD.	62
Figura 11 - Gráfico representando o custo dos materiais do melhor indivíduo e média de custos da população para cada geração do Exemplo 1.	63
Figura 12 - Gráfico representando o custo dos materiais do melhor indivíduo e média de custos da população para cada geração do Exemplo 2.	63
Figura 13 - Gráfico representando o desvio padrão da população por geração no algoritmo de otimização de custo total do Exemplo 1.	64
Figura 14 - Gráfico representando o desvio padrão da população por geração no algoritmo de otimização de custo total do Exemplo 2.	64
Figura 15 - Distribuição da indução magnética no núcleo do transformador do Exemplo 1 via simulação com o software EFCAD.	65
Figura 16 - Distribuição da indução magnética no núcleo do transformador do Exemplo 2 via simulação com o software EFCAD.	66

Figura 17 - Comparação entre volumes dos núcleos calculados com a metodologia tradicional (branco) e otimizado (colorido) para os exemplos 1 e 2.69

LISTA DE TABELAS

Tabela 1 - Grandezas de Entrada do Projeto.	52
Tabela 2 - Grandezas de Saída do Projeto.....	53
Tabela 3 - Variáveis de Inicialização do AG.	54
Tabela 4 - Limites inferiores e superiores das variáveis do AG.	55
Tabela 5 - Parâmetros de saída resultante de cada projeto otimizando o volume do núcleo.	67
Tabela 6 - Parâmetros de saída resultante para cada projeto otimizando o custo total.	68

LISTA DE SÍMBOLOS

V_1	Tensão no Enrolamento Primário
V_2	Tensão no Enrolamento Secundário
N_1	Número de Espiras no Enrolamento Primário
N_2	Número de Espiras no Enrolamento Secundário
S_j	Área da Janela do Transformador
a	Comprimento da Coluna Central
c_j	Largura da Janela
h_j	Altura da Janela
S_f	Área Frontal do Núcleo
V'_n	Volume Real do Núcleo do Transformador
M_{1cm}	Massa por Centímetro de Núcleo
ρ_{Fe}	Massa Específica do Ferro
W_1	Potência Primária
W_2	Potência Secundária
I_1	Corrente Primária
I_2	Corrente Secundária
d	Densidade de Corrente
S_g	Seção Geométrica do Núcleo
b	Comprimento do Pacote Laminado
S_m	Seção Magnética do Núcleo
f	Frequência da Rede
S_{Cu}	Seção do Cobre Enrolado
S_1	Seção do Condutor Primário
S_2	Seção do Condutor Secundário
M_{Fe}	Massa do Núcleo de Ferro
l_m	Comprimento Médio da Espira
M_{Cu}	Massa do Cobre Enrolado
M_t	Massa Total do Transformador
ρ_{Cu}	Massa Específica do Cobre

SUMÁRIO

1. INTRODUÇÃO	17
1.1 Objetivos	18
1.1.1 Objetivo Geral	18
1.1.2 Objetivos Específicos.....	18
2. TRANSFORMADORES MONOFÁSICOS.....	19
2.1 Visão Geral dos Transformadores Monofásicos	19
2.2 Princípios de funcionamento	20
3. VISÃO GERAL SOBRE ALGORITMOS GENÉTICOS	23
3.1 Aplicações em Diversos Campos.....	24
3.2 Componentes Fundamentais	25
3.3 Representação de Indivíduos nos Algoritmos Genéticos.....	27
3.4 Função de Aptidão (Fitness).....	28
3.5 Seleção de Pais	29
3.6 <i>Crossover</i> (Recombinação).....	29
3.7 Mutação	30
3.8 Tamanho da População.....	31
3.9 Critério de Parada	32
3.10 Fluxo de Execução de Algoritmos Genéticos	33
4. DO PROJETO DE TRANSFORMADORES MONOFÁSICOS.....	35
4.1 Condutores e Estruturação das Bobinas	35
4.2 Dimensionamento das Lâminas no Núcleo do Transformador.....	36
4.3 Correntes nos Enrolamentos.....	38
4.4 Área dos Condutores.....	39
4.5 Dimensionamento das Seções Geométrica e Magnética do Núcleo	40
4.6 Número de Espiras dos Enrolamentos Primário e Secundário	42
4.7 Seção do Cobre e Viabilidade da Execução.....	42
4.8 Massa do Ferro e Cobre no Transformador	43
4.9 Custo de Fabricação	44
4.10 Volume do Transformador	44
5. DESENVOLVIMENTO DO ALGORITMO DE OTIMIZAÇÃO	47
5.1 Escolha da Linguagem de Programação.....	48
5.2 Desenvolvimento do Algoritmo e Integração com o Transformador	49
6. METODOLOGIA.....	51
6.1 Parâmetros de Entrada e Saída do Projeto	52

6.2 Inicialização do Algoritmo Genético.....	54
6.3 Funcionamento do Algoritmo Genético.....	55
7. RESULTADOS	57
7.1 Otimização do Volume do Núcleo dos Transformadores	58
7.2 Otimização do Custo de Fabricação dos Transformadores.....	62
7.3 Síntese dos Resultados Finais das Otimizações	66
8. CONCLUSÃO	71
REFERÊNCIAS BIBLIOGRÁFICAS	73

1. INTRODUÇÃO

Transformadores monofásicos de potência são componentes vitais em sistemas de engenharia elétrica e eletrônica, com aplicações críticas em processos de geração, transmissão e distribuição de energia elétrica. Conforme explicado por Fitzgerald, Kingsley e Umans (2003), estes dispositivos permitem alterações eficientes nos níveis de tensão e corrente, facilitando a distribuição de energia elétrica em níveis viáveis.

No cenário industrial, como destacado por Aguiar e Camacho (2011), os transformadores são fundamentais na transferência de energia elétrica entre circuitos, realizando a redução ou elevação da tensão alternada. De acordo com Godoy (2010), os transformadores podem ser classificados como elevadores, abaixadores ou isoladores, cada um com finalidades e construções específicas.

Este trabalho tem como foco a otimização de dois transformadores monofásicos de baixa potência utilizando algoritmos genéticos, visando minimizar o volume do núcleo e reduzir os custos de fabricação. A relevância de otimizar tais equipamentos é enfatizada por Malagoli et al. (2014), que salientam a importância de desenvolver transformadores que sejam economicamente viáveis e atendam a especificações precisas.

A escolha do transformador monofásico como objeto de estudo deste trabalho foi motivada por sua ampla aplicabilidade e importância no contexto da distribuição de energia elétrica, especialmente em ambientes residenciais e de pequena escala industrial. Além disso, a otimização de transformadores monofásicos representa um desafio significativo dentro da engenharia elétrica, problema este que pode ser atacado de diversas formas.

Neste trabalho, algoritmos genéticos são empregados para a resolução do problema de otimização. Esta abordagem é uma técnica robusta e eficaz na busca de soluções ótimas em projetos complexos de engenharia. Esses algoritmos serão explorados para melhorar a eficiência e economia dos transformadores monofásicos, oferecendo uma excelente oportunidade de aplicação.

A estrutura do trabalho compreende uma introdução e revisão bibliográfica, discussão sobre algoritmos genéticos, análise dos resultados obtidos e, por fim, as conclusões.

1.1 Objetivos

1.1.1 Objetivo Geral

O objetivo principal é estudar a otimização de transformadores monofásicos de baixa potência do tipo núcleo envolvente através de algoritmos genéticos, com ênfase na minimização do volume do núcleo e na redução dos custos de fabricação.

1.1.2 Objetivos Específicos

1. Avaliar a eficácia do emprego de algoritmos genéticos na otimização do volume do núcleo de transformadores monofásicos.
2. Avaliar o desempenho de algoritmos genéticos na otimização dos custos de fabricação dos transformadores monofásicos.
3. Implementar um algoritmo genético específico para a otimização de transformadores monofásicos.
4. Validar os resultados obtidos por meio de algoritmos genéticos com simulações 2D de indução magnética.

2. TRANSFORMADORES MONOFÁSICOS


2.1 Visão Geral dos Transformadores Monofásicos

Os transformadores monofásicos desempenham um papel essencial na distribuição e transmissão de energia elétrica, sendo amplamente utilizados em sistemas eletrônicos devido à sua eficiência e simplicidade. Eles são fundamentais na adaptação da tensão elétrica para diferentes níveis, possibilitando a transmissão eficiente de energia elétrica para variados pontos de consumo (ALEXANDER, 2012).

Este estudo focou no transformador monofásico por sua prevalência na eletrônica, embora os conceitos e metodologias aplicadas aqui possam ser expandidos para casos mais complexos, como os transformadores trifásicos.

Fitzgerald et al. (2003) explicam que o funcionamento dos transformadores monofásicos se baseia na indução eletromagnética mútua entre duas bobinas, conhecidas como enrolamento primário e secundário, que estão representadas pela Figura 1.

Figura 1 - Representação dos enrolamentos primários e secundários no núcleo.



Fonte: Martignoni (1973)

O enrolamento primário recebe a tensão de entrada, enquanto o secundário fornece a tensão de saída. A corrente alternada no enrolamento primário gera um campo magnético variável que, por sua vez, induz uma tensão no enrolamento secundário. A relação de transformação, que é a razão entre o número de espiras

nos enrolamentos primário e secundário, determina a relação entre as tensões, conforme a Equação (1).

$$\frac{V_1}{V_2} = \frac{N_1}{N_2} \quad (1)$$

Na qual:

- V_1 – Tensão no Enrolamento Primário [V];
- V_2 – Tensão no Enrolamento Secundário [V];
- N_1 – Número de Espiras no Enrolamento Primário;
- N_2 – Número de Espiras no Enrolamento Secundário.

Chapman (2011) descreve os componentes principais dos transformadores, o núcleo magnético e os enrolamentos. O núcleo direciona o fluxo magnético, buscando evitar perdas pelo chamado fluxo disperso, e é geralmente composto por chapas de ferro-silício laminado para reduzir as perdas por correntes parasitas. Os enrolamentos, feitos de fios de cobre ou alumínio isolados, são fundamentais na condução da corrente e geração do campo magnético. Ainda, um isolamento adequado é indispensável para prevenir falhas e curtos-circuitos.

Dentre as principais especificações, segundo Guru et al. (2000), pode-se citar a potência nominal, que determina a capacidade de carga do transformador, a eficiência, que é a relação entre a potência de saída e entrada, indicando as perdas energéticas, e a tensão de curto-circuito, parâmetro crítico para a proteção e dimensionamento correto do transformador.

2.2 Princípios de funcionamento

Conforme Fitzgerald et al. (2003), os transformadores operam pela indução eletromagnética mútua entre os enrolamentos primário e secundário. A variação do campo magnético no primário induz uma tensão no secundário, cuja magnitude depende da taxa de variação do fluxo magnético e do número de espiras do secundário. A lei de Lenz, destacada por Chapman (2011), afirma que a corrente

induzida no enrolamento secundário se opõe à variação do fluxo magnético que a gerou.

Autores como Guru et al. (2000) destacam que a relação entre as tensões é determinada pela relação de transformação do transformador, que é definida pela razão entre o número de espiras do enrolamento primário e o número de espiras do enrolamento secundário. Essa relação determina a amplitude da tensão de saída em relação à tensão de entrada. Por exemplo, se a relação de transformação for de 1:10, isso significa que a tensão de saída será 10 vezes maior do que a tensão de entrada.

Estes princípios são a base para compreender a funcionalidade e a importância dos transformadores na transmissão e distribuição de energia elétrica, viabilizando a conversão de tensão de maneira eficiente e atendendo às necessidades de diferentes locais de consumo.

3. VISÃO GERAL SOBRE ALGORITMOS GENÉTICOS

Os algoritmos genéticos, concebidos na perspectiva pioneira de Holland (1992), são estruturas de otimização inspiradas no processo evolutivo biológico. Eles iniciam com a geração de uma população diversificada de indivíduos, cada um representando uma solução potencial para o problema em análise. Esses indivíduos são codificados através de genes em formatos variados, como sequências binárias ou vetores numéricos, dependendo da natureza e complexidade do problema.

A eficácia de cada indivíduo é mensurada por uma função de avaliação, conhecida como função de aptidão. Esta função permite a identificação dos indivíduos mais adaptados ao problema. A seleção destes indivíduos, que segue a lógica da seleção natural, é feita com base em sua aptidão, sendo os mais adaptados propensos a serem escolhidos para a reprodução (ARANTES et al., 2017).

Um aspecto central dos algoritmos genéticos é a recombinação genética. Este processo envolve a troca de informações genéticas entre indivíduos selecionados, realizada por meio de operadores genéticos, como o *crossover*. Este mecanismo permite a combinação de características benéficas de diferentes indivíduos, resultando em descendentes que podem exibir um desempenho superior.

A mutação, outra etapa fundamental, consiste na alteração aleatória de genes individuais, introduzindo novas variações na população. Esta diversificação permite explorar novas áreas do espaço de busca, evitando que o algoritmo fique preso em soluções subótimas locais, possibilitando, assim, a descoberta de soluções globais mais eficazes.

Os algoritmos genéticos, portanto, representam uma abordagem robusta e adaptável para resolver problemas complexos, refletindo processos naturais de evolução e adaptação. Eles se destacam pela habilidade de encontrar soluções em cenários nos quais métodos tradicionais podem falhar ou serem ineficazes, especialmente em problemas que exigem uma busca extensiva em um espaço de soluções vasto e desconhecido (PACHECO, 2017).

3.1 Aplicações em Diversos Campos

Os algoritmos genéticos, notáveis por sua adaptabilidade e eficiência, transcendem o escopo da engenharia elétrica, permeando diversas áreas com sua capacidade de resolver problemas complexos e buscar soluções ótimas. A seguir, estão listadas algumas das áreas significativas em que estes algoritmos têm sido aplicados com sucesso:

Engenharia de Energia Elétrica: O uso mais imediato dos algoritmos genéticos é evidente na otimização de transformadores monofásicos. Aqui, eles desempenham um papel decisivo na calibração de parâmetros essenciais do transformador, como o tamanho do núcleo, o número de espiras e a escolha de materiais de enrolamento. Essa otimização visa melhorar a eficiência energética e a confiabilidade dos equipamentos, abordando desafios como a redução de perdas de energia e a otimização de custos de produção.

Engenharia de Telecomunicações: Fora da indústria de energia, os algoritmos genéticos também mostram sua utilidade na otimização de sistemas de telecomunicações. Eles são utilizados para projetar antenas mais eficientes, otimizar a disposição e o desempenho de dispositivos de comunicação, reduzindo interferências e aumentando a eficácia das comunicações em plataformas como satélites e redes de telecomunicações móveis. Essa aplicação é particularmente valiosa para melhorar a cobertura de rede e a qualidade do sinal em áreas densamente povoadas ou geograficamente desafiadoras.

Engenharia Mecânica: No projeto de transformadores monofásicos, considerações mecânicas, como o dimensionamento e a configuração de núcleos e enrolamentos, são de grande importância. Os algoritmos genéticos aqui auxiliam na otimização desses componentes, resultando em transformadores que não apenas atendem aos requisitos elétricos, mas também são eficientes, duráveis e seguros para operação a longo prazo.

Medicina: De forma surpreendente, a medicina também se beneficiou da aplicação de algoritmos genéticos, especialmente na otimização de tratamentos médicos. Por exemplo, no ajuste de parâmetros para tratamentos de radioterapia, os algoritmos ajudam a maximizar a eficácia do tratamento, minimizando ao mesmo tempo os efeitos colaterais. Esta aplicação é útil para desenvolver protocolos de tratamento personalizados, garantindo que os pacientes recebam a dose ótima de radiação.

Agricultura: Na agricultura, os algoritmos genéticos estão revolucionando a gestão de culturas e recursos. Eles são usados para otimizar o plantio, a

seleção de culturas e a utilização eficiente de insumos agrícolas, ajudando agricultores a tomar decisões informadas sobre estratégias de plantio, irrigação e colheita. Esta aplicação é particularmente importante para aumentar a sustentabilidade na agricultura, reduzindo o desperdício e melhorando o rendimento das colheitas (SANTANA, 2019).

Essas aplicações ilustram como os algoritmos genéticos são ferramentas poderosas e versáteis, capazes de trazer avanços significativos em várias disciplinas e indústrias. Eles não só resolvem problemas complexos de maneira eficiente, mas também contribuem para a inovação e o progresso tecnológico em campos variados (ARANTES et al., 2017).

3.2 Componentes Fundamentais

Os Algoritmos Genéticos (AGs) são inspirados na teoria evolucionária de Darwin (1859), espelhando o processo de evolução natural e a seleção natural das espécies. Esses algoritmos são caracterizados por vários componentes fundamentais, cada um contribuindo significativamente para a eficácia dos AGs em resolver uma ampla gama de problemas complexos.

O primeiro passo é a criação da população inicial. O processo de um AG começa com a formação da população inicial de soluções candidatas. Esta população é geralmente criada aleatoriamente, incorporando uma variedade de soluções possíveis. Uma população inicial diversificada é importante para abranger um amplo espectro do espaço de busca, aumentando as chances de identificar soluções ótimas.

A função de avaliação atribui um valor numérico a cada solução de acordo com sua adequação aos critérios do problema. Esta avaliação determina quais soluções serão selecionadas para reprodução, influenciando diretamente a trajetória evolutiva do algoritmo (SÁ, 2014).

A seleção de soluções, conforme explicado por Holland (1975), é um processo em que soluções com desempenho superior são escolhidas para gerar a próxima geração. Esta etapa é crucial para manter e melhorar a qualidade genética da população ao longo das gerações.

Goldberg (1989) descreve a recombinação como um processo que imita a reprodução sexual em organismos biológicos. Este operador envolve a combinação

de informações genéticas de dois ou mais indivíduos para gerar descendentes. No contexto de otimização de transformadores monofásicos, o cruzamento é uma técnica valiosa para mesclar características benéficas de diferentes soluções parentais, potencialmente levando à criação de novas soluções mais eficientes (AGUIAR, 2011).

Existem diversas técnicas de cruzamento, como o cruzamento de um ponto, cruzamento de dois pontos e cruzamento uniforme, cada uma apresentando vantagens específicas em diferentes contextos.

A mutação, segundo Storn (1997), é essencial para introduzir variações aleatórias nas soluções e manter a diversidade genética, permitindo que o AG explore novas áreas do espaço de busca e evite a convergência prematura para ótimos locais. Este operador envolve a alteração de um ou mais genes em um cromossomo, introduzindo novas características na população. A taxa de mutação regula a probabilidade de ocorrerem mutações durante a evolução (STORN, 1997).

Um AG requer um critério de parada bem definido, que pode incluir um número máximo de iterações, a obtenção de uma solução satisfatória, ou outros parâmetros relevantes (SÁ, 2014).

A evolução geracional, uma característica fundamental dos AGs, envolve a criação de novas populações através da seleção, recombinação e mutação das soluções da geração anterior, possibilitando a progressiva evolução em direção a soluções mais eficientes (SÁ, 2014).

A aplicação eficaz desses operadores genéticos exige um equilíbrio entre a exploração (busca de novas soluções) e a exploração (melhoria das soluções atuais). Uma seleção inadequada de operadores ou de seus parâmetros pode resultar em convergência prematura ou em uma busca ineficaz (PRADO, 2001).

Além dos operadores tradicionais, os algoritmos genéticos podem incluir operadores específicos para enfrentar desafios únicos de um problema. Por exemplo, podem ser empregados operadores de seleção de soluções não dominadas, visando manter um conjunto diversificado de soluções ótimas no contexto de Pareto (DEB, 2001).

Os AGs, portanto, são equipados com uma série de mecanismos que permitem a exploração efetiva do espaço de busca, identificando soluções ótimas ou aproximadas para uma variedade de desafios complexos. A combinação de seleção

baseada no desempenho, recombinação genética e mutação aleatória torna-os ferramentas poderosas em diversos contextos (SANTOS, 2016).

3.3 Representação de Indivíduos nos Algoritmos Genéticos

“Um dos componentes fundamentais dos algoritmos genéticos é a representação de indivíduos. Ela define como as soluções candidatas são codificadas e estruturadas no espaço de busca” (HOLLAND, 1975).

No contexto de problemas de otimização, como o projeto de um transformador monofásico, a representação precisa capturar todas as informações relevantes do problema (AGUIAR, 2011). Isso significa que cada solução candidata deve ser codificada de forma que permita a operação eficiente do algoritmo genético sobre ela.

Existem diversas formas de representação de indivíduos em algoritmos genéticos. Uma das mais comuns é a representação binária, em que cada indivíduo é codificado como uma sequência de bits (1s e 0s). Essa representação é amplamente utilizada em problemas de otimização e é particularmente adequada para problemas nos quais a solução pode ser decomposta em componentes discretos (KATO, 2021).

No entanto, para problemas contínuos, como a otimização de parâmetros em sistemas elétricos, a representação real é mais apropriada (GODOY, 2010). Neste caso, os indivíduos são codificados como vetores de números reais, o que permite a manipulação de variáveis contínuas de forma mais precisa. As operações genéticas, como cruzamento e mutação, devem ser adaptadas para operar eficazmente neste espaço contínuo.

A escolha da representação está intrinsecamente relacionada à codificação do espaço de busca. Uma representação inadequada pode levar a problemas de busca ineficientes, tornando o algoritmo incapaz de encontrar soluções ótimas (DEB, 2001).

Além disso, a maneira como os genes são estruturados na representação escolhida influencia diretamente a eficácia da aplicação de operadores genéticos, como cruzamento e mutação.

3.4 Função de Aptidão (Fitness)

A função de aptidão, também conhecida como função *fitness*, é responsável por avaliar a adequação das soluções candidatas em relação aos objetivos do problema, sendo projetada conforme a natureza específica deste, podendo focar na minimização ou maximização de certos valores, dependendo dos critérios estabelecidos (GOLDBERG, 1989).

Na otimização de transformadores monofásicos, a função de aptidão é estruturada para avaliar aspectos como eficiência energética e custos de fabricação. Esta abordagem está alinhada com as sugestões de Arantes et al. (2017), em que soluções que resultam em transformadores mais eficientes ou econômicos são avaliadas positivamente. Por outro lado, soluções que levam a ineficiências recebem avaliações mais baixas.

A função de aptidão guia o processo de seleção natural no algoritmo genético, influenciando quais soluções são escolhidas para continuidade e reprodução na geração subsequente. Soluções com melhores avaliações de aptidão têm uma probabilidade maior de serem selecionadas, conforme destacado por Holland (1975).

A configuração correta da função de aptidão é um desafio significativo. Ela deve equilibrar a necessidade de explorar o espaço de busca com a identificação de soluções de alta qualidade e ser escalável para se adaptar a diferentes tamanhos de espaço de busca.

Uma escolha inadequada da função *fitness* pode levar a resultados subótimos ou a um desempenho insatisfatório do algoritmo, sendo vital para garantir que o algoritmo seja capaz de explorar eficazmente o espaço de busca e identificar soluções ótimas ou aproximadas para o problema em questão. Mitchell (1998) ressalta a importância de uma função de aptidão bem projetada para o sucesso dos algoritmos genéticos, enquanto Santos (2016) destaca a necessidade de a função de aptidão ser escalonável e eficaz em diferentes contextos de aplicação.

3.5 Seleção de Pais

No âmbito dos algoritmos genéticos, a seleção de pais é um componente que influencia quais indivíduos são escolhidos para gerar a próxima geração. Este processo se concentra em favorecer a reprodução dos indivíduos mais adaptados, conforme indicado pela sua função de aptidão (*fitness*), uma prática fundamentada na teoria de Holland (1975).

Dentre as técnicas empregadas para a seleção de pais, a "seleção por roleta" é uma das mais comuns. Neste método, a probabilidade de um indivíduo ser escolhido é proporcional à sua aptidão, favorecendo assim os indivíduos com melhor desempenho. Esta abordagem ajuda a garantir que as características benéficas sejam passadas para as gerações futuras, como explicado por Mitchell (1998).

Paralelamente, a técnica de "seleção de torneio" apresenta uma dinâmica diferente, onde vários indivíduos são escolhidos aleatoriamente, e o mais apto dentre eles é selecionado para reprodução. Esta estratégia, destacada por Goldberg (1989), impõe uma pressão de seleção mais direta e é eficaz em assegurar que os indivíduos mais aptos sejam frequentemente escolhidos como pais.

Além dessas técnicas convencionais, a seleção de pais em AGs também pode incorporar métodos mais sofisticados, como seleção de *ranking* ou seleção proporcional à distância de dominância, particularmente úteis em cenários de otimização multiobjetivo, conforme discutido por Deb (2001).

Importante também é o equilíbrio entre exploração e exploração. Ao incluir pais com menor aptidão, o algoritmo pode explorar novas áreas do espaço de busca, enquanto a preferência por pais mais aptos visa a melhoria das soluções existentes, um conceito abordado por Storn e Price (1997).

Em resumo, a seleção eficiente de pais nos AGs é vital para o sucesso do processo evolutivo, especialmente em aplicações complexas como a otimização de transformadores monofásicos, onde a escolha de pais adequados pode influenciar significativamente a qualidade das soluções geradas.

3.6 Crossover (Recombinação)

A operação de crossover, ou recombinação, é um aspecto chave nos algoritmos genéticos (AGs), desempenhando um papel essencial na criação de

novos indivíduos. Essa técnica envolve a mistura de informações genéticas de dois ou mais pais, um processo que reflete a recombinação genética na reprodução biológica, destacada na literatura por Goldberg (1989).

Existem várias abordagens de crossover utilizadas em AGs, cada uma com suas características específicas. O crossover de um ponto, por exemplo, é uma técnica básica, porém eficiente, onde um ponto de corte é selecionado nos cromossomos dos pais, e as partes subsequentes são trocadas. Enquanto simples, essa abordagem pode limitar a diversidade genética que pode ser introduzida na população.

Em contraste, o crossover de dois pontos aumenta essa diversidade ao utilizar dois pontos de corte nos cromossomos, permitindo uma troca mais complexa e diversificada de material genético. Além disso, o crossover uniforme representa uma abordagem mais avançada, onde cada gene do descendente é escolhido aleatoriamente de um dos pais, como explicado por Holland (1975). Este método promove uma mistura equilibrada de material genético e é especialmente útil em cenários de otimização mais complexos.

A eficácia do crossover depende também das taxas de crossover aplicadas, que regulam a frequência com que esta operação genética ocorre. Conforme Deb (2001) descreve, a definição apropriada dessas taxas é vital para equilibrar a recombinação genética na população e ajustá-la às demandas específicas do problema de otimização.

No contexto da otimização de transformadores monofásicos, a escolha e a aplicação cuidadosa dos métodos de crossover e das taxas associadas são fundamentais. Essa seleção influencia diretamente a qualidade das soluções geradas, impactando a eficácia da otimização em termos de redução do volume total e dos custos de fabricação na aplicação deste trabalho.

3.7 Mutação

A mutação representa uma operação dos algoritmos genéticos (AGs) que desempenha um papel relevante na introdução da diversidade genética da população. Enquanto o crossover se concentra na recombinação das informações genéticas dos pais, a mutação introduz mudanças aleatórias nos cromossomos dos

indivíduos, possibilitando a exploração de novas áreas do espaço de busca, como destacado por Mitchell (1998).

Essa operação simula o processo natural de mutação genética observado em organismos vivos. No contexto de um AG, a mutação pode variar desde a alteração de um único bit em um cromossomo binário até mudanças mais complexas em cromossomos numéricos. Essas modificações, embora possam parecer menores, têm um impacto significativo na trajetória evolutiva da população de um AG (AUDET, 2021).

A definição da taxa de mutação é um aspecto crítico na eficácia de um AG. Esta taxa determina a frequência com que as mutações ocorrem e deve ser cuidadosamente balanceada. Uma taxa de mutação muito baixa pode resultar em convergência prematura, onde a população fica presa em ótimos locais, enquanto uma taxa excessivamente alta pode comprometer a estabilidade genética da população, dificultando a identificação de soluções de alta qualidade, como descrito por Sivanandam e Deepa (2008).

Além disso, a mutação desempenha um papel importante na exploração do espaço de busca. Ela permite que o AG evite ficar preso em mínimos locais, continuando a busca por soluções ótimas. Em cenários complexos, a mutação pode ser a principal fonte de novas características genéticas na população, especialmente quando o crossover por si só não é suficiente para manter a diversidade genética necessária (MITCHELL, 1998).

A aplicação da mutação é frequentemente mais intensa nos estágios iniciais da otimização, quando há uma exploração mais ampla do espaço de busca. À medida que o processo de otimização avança e a convergência para soluções de alta qualidade é desejada, a taxa de mutação pode ser ajustada para facilitar esse refinamento, uma abordagem sugerida por Storn e Price (1997).

3.8 Tamanho da População

O tamanho da população é um parâmetro que influencia na eficácia da busca por soluções ótimas. Este parâmetro, que define o número de indivíduos em cada geração do algoritmo, deve ser escolhido com atenção para garantir um desempenho eficiente na resolução de problemas específicos, conforme enfatizado por Deb (2001).

Um tamanho de população pequeno demais pode resultar em uma diversidade genética insuficiente, limitando a capacidade do AG de explorar o espaço de busca efetivamente. Isso pode causar uma convergência prematura, com o algoritmo se concentrando em ótimos locais sem alcançar soluções potencialmente melhores. Por outro lado, uma população excessivamente grande pode aumentar desnecessariamente o custo computacional sem melhorar a qualidade das soluções encontradas, um fenômeno destacado por Holland (1975).

A determinação ideal do tamanho da população depende de vários fatores, incluindo a complexidade do problema, as características do espaço de busca e as propriedades desejadas das soluções. Problemas mais complexos ou com espaços de busca amplos tendem a exigir populações maiores para uma exploração adequada, uma abordagem sugerida por Goldberg (1989).

Realizar experimentos e análises de sensibilidade para identificar o tamanho mais adequado da população é uma prática recomendada. A estratégia de manter ou ajustar o tamanho da população ao longo das gerações do AG, com base em critérios como a convergência da população ou o número de gerações, é uma tática eficaz, conforme descrito por Haupt e Haupt (2004).

3.9 Critério de Parada

O critério de parada é um aspecto que determina o momento de encerrar o processo de otimização. Este critério define as condições para finalizar a geração de novas soluções, declarando a solução final do processo. A escolha correta do critério de parada é importante tanto para identificar soluções ótimas quanto para a eficiência computacional do algoritmo, como enfatizado por Haupt e Haupt (2004).

Existem diversas estratégias para definir o critério de parada em AGs. Uma abordagem comum é estabelecer um limite máximo de gerações, encerrando o algoritmo ao atingir esse número, independente do progresso na otimização. Esta estratégia, útil em contextos com recursos computacionais limitados, foi discutida por Deb (2001).

Outra técnica envolve monitorar a convergência da população. Se não houver mudanças significativas nas soluções ao longo de várias gerações, isso pode indicar

que o AG encontrou uma solução satisfatória, conforme sugerido por Goldberg (1989).

Em cenários em que o tempo de execução é um fator crítico, um limite de tempo máximo pode ser estabelecido como critério de parada, uma prática discutida por Price, Storn e Lampinen (2005). Além disso, em problemas de otimização multiobjetivo, o critério de parada pode se basear na satisfação de objetivos específicos, conforme explorado por Das e Suganthan (2011).

Portanto, a seleção do critério de parada depende da natureza do problema, dos objetivos de otimização e das limitações de recursos. Experimentos e análises de sensibilidade são recomendados para determinar a estratégia mais eficaz para um problema específico, assegurando que o AG atinja resultados satisfatórios e eficiência computacional.

3.10 Fluxo de Execução de Algoritmos Genéticos

O fluxo de execução em algoritmos genéticos (AGs) é um processo sequencial que determina como as soluções são desenvolvidas e otimizadas para um problema específico (ALBALUSTRO, 2001).

Inicialmente, ocorre a criação da população inicial, onde soluções candidatas são geradas aleatoriamente ou através de métodos heurísticos. Cada solução na população é representada por um conjunto de genes, os quais codificam características relevantes para o problema em questão, conforme descrito por Holland (1975).

Após a inicialização, o AG passa por um ciclo evolutivo que compreende várias fases: avaliação, seleção, reprodução e substituição das soluções na população. Na fase de avaliação, as soluções são avaliadas utilizando uma função de aptidão (fitness), que mede o quão adequadas são em relação aos objetivos do problema. Soluções com maior aptidão têm maior probabilidade de serem escolhidas para reprodução, um conceito discutido por Deb (2001).

A seleção é o processo de escolha dos indivíduos mais aptos para reprodução. Existem diferentes estratégias de seleção, como seleção por roleta, seleção por torneio e seleção por ranking, cada uma com suas vantagens específicas, conforme ilustrado por Mitchell (1998).

A fase de reprodução envolve a criação de novas soluções a partir das selecionadas, empregando operadores genéticos como crossover e mutação. O crossover combina características das soluções parentais para gerar descendentes, enquanto a mutação introduz variações aleatórias, como explicado por Goldberg (1989).

Após a geração de novas soluções, a população anterior é substituída pela nova. Este processo pode ser realizado de diferentes maneiras, como substituição completa ou baseada em elitismo, onde as melhores soluções são mantidas, uma abordagem sugerida por Storn e Price (1997).

O ciclo de avaliação, seleção, reprodução e substituição continua por um número definido de gerações, estabelecido pelo critério de parada. Durante este processo, espera-se que as soluções evoluam em direção às ótimas para o problema, como detalhado por Price et al. (2005).

Ao final do processo, a melhor solução ou um conjunto de soluções é identificado como o resultado da otimização. Este resultado pode representar a solução ótima ou uma aproximação dela, dependendo da qualidade da população final e do grau de convergência do algoritmo, um ponto ressaltado por Sivanandam e Deepa (2008).

4. DO PROJETO DE TRANSFORMADORES MONOFÁSICOS

Ao abordar o projeto e a otimização de transformadores monofásicos, uma compreensão aprofundada das equações fundamentais é indispensável. Estas equações não apenas ditam as características físicas e elétricas do transformador, mas também orientam as decisões de projeto para alcançar os objetivos de otimização, como a minimização do volume do núcleo e os custos de fabricação. As equações seguintes desempenham um papel fundamental nesse processo, estabelecendo um *framework* matemático que liga os conceitos teóricos de engenharia elétrica com as aplicações práticas no projeto de transformadores (CUNHA, 2022).

Essas equações abrangem uma ampla gama de aspectos, desde a relação fundamental entre tensão e corrente até as complexidades do design físico e a otimização de custos. Cada equação será detalhada não apenas em sua forma matemática, mas também em seu significado e aplicação no contexto do projeto de transformadores monofásicos. Este entendimento aprofundado é central para o desenvolvimento de soluções eficientes e econômicas, contribuindo significativamente para o avanço do setor de energia elétrica.

4.1 Condutores e Estruturação das Bobinas

A seleção de condutores e a metodologia de enrolamento das bobinas tem influência direta sobre o desempenho e eficiência de transformadores monofásicos.

Neste trabalho será considerado o uso de cobre como material de condução, por sua excelente capacidade de conduzir eletricidade e suportar altas temperaturas, sendo a integridade estrutural da bobina garantida através de um isolamento eficaz e uma disposição meticulosa sobre o carretel onde serão enroladas as bobinas, que serve de base para as camadas de fios e isolamento.


Materiais resistentes a altas temperaturas são utilizados para o isolamento dos condutores, com o esmalte se destacando por sua durabilidade e aproveitamento do espaço. A técnica de enrolamento precisa considerar o raio de curvatura dos fios, especialmente em transformadores de pequena potência onde fios mais finos são benéficos para a flexibilidade e economia de espaço (MARTIGNONI, 1973).

Na etapa da construção do carretel utilizam-se materiais como cartolina ou prespan que suportam o enrolamento das bobinas. Este suporte deve ser robusto o suficiente para manter a configuração das bobinas enquanto permite um isolamento adequado entre as camadas, o que é alcançado pela alternância entre as camadas de fios e folhas de papel isolante (MARTIGNONI, 1973). A distância de segurança entre o fim da bobina e o carretel é outro aspecto técnico que impacta diretamente na segurança e funcionalidade do transformador.

4.2 Dimensionamento das Lâminas no Núcleo do Transformador

A estruturação do núcleo de transformadores monofásicos é comumente projetada com lâminas padronizadas tipo E e tipo I, representadas na Figura 2. A formação do núcleo é realizada de maneira que o fluxo magnético seja distribuído de forma igual entre o núcleo central e as colunas laterais, o que leva a tanto as colunas laterais quanto as travessas superior e inferior possuírem largura correspondente à metade da espessura do núcleo central. Esta distribuição é projetada para minimizar a relutância magnética, o que impacta no desempenho do transformador (MARTIGNONI, 1973).

Figura 2 - Lâminas Padronizadas tipo E e tipo I.



Fonte: Martignoni (1973)

A área da janela de um transformador monofásico representa o espaço disponível para os enrolamentos do transformador e é diretamente influenciada pela geometria do núcleo. A formulação matemática para a área da janela (S_j) considera as dimensões físicas do núcleo, sendo calculada a partir da Equação (2).

$$S_j = c_j * h_j \quad (2)$$


Na qual c_j é a largura da janela e h_j é a altura da janela, usualmente medidas em mm. Esta área ajuda a definir a capacidade do transformador de conduzir correntes, impactando diretamente sua eficiência e desempenho térmico.

A área frontal do núcleo (S_f) está relacionada ao tamanho físico do transformador e às suas propriedades térmicas. Ela influencia a capacidade de dissipação de calor e a eficiência magnética do transformador, sendo esta área dada pela Equação (3), produto da largura da coluna central do transformador (a).

$$S_f = 6 * a^2 \quad (3)$$

Na Figura 3 pode-se observar a relação entre as colunas e travessas das lâminas em função do comprimento a da coluna central para núcleos padronizados.

Figura 3 - Relação entre comprimentos das lâminas padronizadas e comprimento da coluna central.



Fonte: Martignoni (1973)

O volume do núcleo é obtido a partir da área frontal multiplicada pela espessura efetiva do núcleo. Este volume é uma consideração chave para o peso do transformador e para a gestão eficiente do calor durante a operação.

Caso a espessura nominal do núcleo fosse de 1 cm, na prática, seria necessário ajustar esse valor para 0,9 cm, considerando a redução de 10% devido às camadas de isolamento de óxido entre as lâminas (MARTIGNONI, 1973), proporcionando uma estimativa aproximada do volume total real do núcleo, conforme visto em (4).

$$V'_n = 6 * a^2 * 0,9 = 5,4 * a^2 \quad (4)$$

Além disso, a massa por centímetro de núcleo é uma métrica que impacta diretamente nos custos de material. Utilizando o volume calculado e a massa específica do ferro (ρ_{Fe}), a fórmula para calcular a massa por centímetro de núcleo se dá pela Equação (5).

$$M_{1cm} = 5,4 * a^2 * \rho_{Fe} \quad (5)$$

Aqui, o peso específico do ferro pode ser tomado como 7,65 g/cm³, uma constante material que, junto com o volume do núcleo, determina a massa total do núcleo por centímetro. Este cálculo pode ser útil para estimar o custo dos materiais usados na construção do transformador e para avaliar a eficiência do uso de materiais no design geral.

Tem-se então:

- S_j – Área da Janela do Transformador [cm²];
- a – Comprimento da Coluna Central [cm];
- c_j – Largura da Janela [cm];
- h_j – Altura da Janela [cm];
- S_f – Área Frontal do Núcleo [cm²];
- V'_n – Volume Real do Núcleo do Transformador [cm³];
- M_{1cm} – Massa por Centímetro de Núcleo [kg];
- $\rho_{Fe} = 7650 \text{ kg/m}^3$ – Massa Específica do Ferro.

4.3 Correntes nos Enrolamentos

No projeto de transformadores, a compreensão e cálculo das correntes primárias e secundárias corroboram para o projeto eficiente do dispositivo. Os parâmetros como potência de saída (W_2), tensão de saída (V_2) e tensão de entrada (V_1) são os dados básicos necessários para iniciar o cálculo dessas correntes (MARTIGNONI, 1973).

A corrente secundária (I_2) é obtida diretamente pela relação entre a potência de saída e a tensão de saída, uma equação simples, mas importante no projeto do transformador, dada pela Equação (6), que relaciona a potência de saída à tensão de saída.

$$I_2 = \frac{W_2}{V_2} \quad (6)$$

Por outro lado, o cálculo da corrente primária (I_1) requer consideração das perdas no transformador. Para avaliar a potência primária (W_1), adiciona-se 10% à potência secundária, a fim de compensar as perdas, como sugerido por Martignoni (1973) e mostrado em (7).

$$W_1 = W_2 * 1,1 \quad (7)$$

Com a potência primária corrigida, a corrente primária pode então ser calculada, conforme indicado na equação (8).

$$I_1 = \frac{W_1}{V_1} \quad (8)$$

Tem-se então:

- W_1 — Potência Primária [VA];
- W_2 — Potência Secundária [VA];
- I_1 — Corrente Primária [A];
- I_2 — Corrente Secundária [A].

4.4 Área dos Condutores

A seção dos condutores é diretamente relacionada à densidade de corrente, que deve ser cuidadosamente escolhida para equilibrar a capacidade de condução de corrente e a dissipação de calor. À medida que a potência do transformador aumenta, é importante reduzir a densidade de corrente para evitar problemas de aquecimento e perdas excessivas.

Com base na Equação (9), a seção do condutor primário (S_1) é determinada pela corrente primária e pela densidade de corrente (d).

$$S_1 = \frac{I_1}{d} \quad (9)$$

Da mesma forma, a seção do condutor secundário (S_2) é calculada usando a corrente secundária e a densidade de corrente, como mostra a Equação (10).

$$S_2 = \frac{I_2}{d} \quad (10)$$

Tem-se então:

- S_1 – Área do Condutor Primário [mm²];
- S_2 – Área do Condutor Secundário [mm²];
- d – Densidade de Corrente [A/mm²].

Essas relações garantem o transporte da corrente elétrica de forma eficiente nos condutores, de forma a evitar o superaquecimento. A tabela da Figura 4 fornece as densidades de correntes recomendadas para diferentes faixas de potência do transformador, permitindo uma escolha adequada que melhore a eficiência e minimize o custo dos materiais (MARTIGNONI, 1973).

Figura 4 - Tabela de Densidades de Corrente Recomendadas por Faixa de Potência.

POTÊNCIA VA	DENSIDADE DE CORRENTE A/mm ²
500	3
500 até 1000	2,5
1000 até 3000	2

Fonte: Martignoni (1969).

4.5 Dimensionamento das Seções Geométrica e Magnética do Núcleo

O processo de seleção de um núcleo adequado para um transformador monofásico se inicia com o cálculo da seção geométrica do núcleo (S_g), que é o produto da largura da coluna central do transformador (a) e o comprimento do pacote laminado (b), como ilustrado na Equação (11).

$$S_g = a * b \quad (11)$$

No entanto, S_g representa apenas a seção geométrica e não leva em conta a espessura do material isolante entre as lâminas, que não contribui para a condução

do fluxo magnético. Para obter a seção magnética real do núcleo (S_m), é necessário ajustar a seção geométrica para considerar essas camadas isolantes, resultando em uma redução de 10% (MARTIGNONI, 1973) para obter S_m , conforme (12).

$$S_m = \frac{S_g}{1,1} \quad (12)$$

Um núcleo maior permite um menor número de espiras, enquanto um núcleo menor exigirá mais espiras, podendo não caber na janela do transformador. A escolha do núcleo, portanto, impacta diretamente o equilíbrio entre o tamanho físico do transformador e a eficiência dos enrolamentos.

Para transformadores com um circuito primário e um circuito secundário, a seção magnética do núcleo é calculada considerando a potência secundária e a frequência (f), seguindo a Equação (13) para lâminas padronizadas.

$$S_m = 7,5 \sqrt{\frac{W_2}{f}} \quad (13)$$

A forma ideal do núcleo é quase quadrada, o que maximiza a área para uma dada quantidade de material (MARTIGNONI, 1969). Assim, a largura da coluna central do núcleo é aproximadamente a raiz quadrada da seção geométrica, como visto na Equação (14).

$$a = \sim \sqrt{S_g} \quad (14)$$

Uma vez escolhida a lâmina, as seções geométrica e magnética são definidas, proporcionando os parâmetros para o dimensionamento final do núcleo do transformador.

Tem-se então:

- S_g – Seção Geométrica do Núcleo [cm²];
- b – Comprimento do Pacote Laminado [cm];
- S_m – Seção Magnética do Núcleo [cm²];
- f – Frequência da Rede [Hz].

4.6 Número de Espiras dos Enrolamentos Primário e Secundário

O número de espiras em cada enrolamento de um transformador monofásico é determinado por parâmetros que incluem a tensão do circuito, a indução máxima no ferro e a frequência de operação.

Para o enrolamento primário, o número de espiras (N_1) é calculado utilizando a tensão do circuito primário, a indução máxima no ferro (B_m), medida em T, a seção magnética do núcleo e a frequência (MARTIGNONI, 1973). A fórmula para determinar N_1 é dada pela Equação (15).

$$N_1 = \frac{V_1 * 10^8}{4,44 * B_m * S_m * f} \quad (15)$$

Para os enrolamentos secundários, a mesma fórmula é aplicada. No entanto, é necessário ajustar o número de espiras para compensar a queda de tensão, aumentando o resultado em 10% (MARTIGNONI, 1973). Assim, o número de espiras secundárias (N_2) pode ser expresso pela Equação (16).

$$N_2 = 1,1 * \frac{V_2 * 10^8}{4,44 * B_m * S_m * f} \quad (16)$$

Na qual V_2 é a tensão do circuito secundário. Esse ajuste ajuda a manter a tensão de saída nos níveis desejados, mesmo com as inevitáveis quedas de tensão que ocorrem durante a operação do transformador.

4.7 Seção do Cobre e Viabilidade da Execução

Afim de se determinar a viabilidade da execução do projeto de um transformador, deve-se calcular a seção do cobre enrolado e comparar com a seção da janela.

A seção do cobre é obtida pela soma do produto do número de espiras primárias pela seção do condutor primário com o produto do número de espiras secundárias pela seção do condutor secundário, expressa pela Equação (17).

$$S_{Cu} = N_1 * S_1 + N_2 * S_2 \quad (17)$$

Para que o transformador seja viável, o fio esmaltado utilizado nas bobinas deve caber na janela do núcleo. Isso é verificado pela relação entre a seção da

janela (S_j) e a seção do cobre. A montagem é considerada possível se essa relação for maior ou igual a 3, como visto na Equação (18).

$$\frac{S_j}{S_{Cu}} \geq 3 \quad (18)$$

Se a relação for menor que 3, o projeto do transformador precisa ser revisto, considerando-se um núcleo maior para acomodar a bobina devidamente (MARTIGNONI, 1973).

Tem-se então:

- S_{Cu} – Seção do Cobre Enrolado [cm^2];
- S_1 – Seção do Condutor Primário [cm^2];
- S_2 – Seção do Condutor Secundário [cm^2].

4.8 Massa do Ferro e Cobre no Transformador

O cálculo da massa dos materiais utilizados permite estimar os custos de fabricação do transformador, como o ferro para o núcleo e o cobre para os enrolamentos, pois irão ajudar a estimar os custos dos materiais e a logística necessária para a fabricação.

A massa do núcleo de ferro (M_{Fe}) é calculada pela multiplicação da massa por centímetro de comprimento do núcleo (M_{1cm}) pela largura da coluna central do núcleo, conforme a Equação (19).

$$M_{Fe} = M_{1cm} * b \quad (19)$$

Para calcular a massa total do cobre enrolado (M_{Cu}), é necessário determinar o comprimento médio da espira (l_m), que é dado pela soma das larguras da coluna central do núcleo e da altura do enrolamento, mais a contribuição da profundidade da bobina. A fórmula para o comprimento da espira média é dada pela Equação (20).

$$l_m = 2 * a + 2 * b + 0,5 * a * \pi \quad (20)$$

A massa do cobre é então calculada multiplicando-se a seção total do cobre S_{Cu} , obtida das equações de seção dos condutores, pelo comprimento da espira média e pela massa específica do cobre (ρ_{Cu}), conforme a Equação (21).

$$M_{Cu} = \frac{S_{Cu} * l_m * \rho_{Cu}}{100} \quad (21)$$

Tem-se então que a massa total do transformador pode ser calculada a partir da soma da massa do ferro e da massa do cobre, seguindo a Equação (22).

$$M_t = M_{Fe} + M_{Cu} \quad (22)$$

Tem-se então:

- M_{Fe} – Massa do Núcleo de Ferro [kg];
- l_m – Comprimento Médio da Espira [cm];
- M_{Cu} – Massa do Cobre Enrolado [kg];
- M_t – Massa Total do Transformador [kg];
- $\rho_{Cu} = 8920 \text{ kg/m}^3$ – Massa Específica do Cobre.

4.9 Custo de Fabricação

O custo total de fabricação de um transformador (C_t) é a soma em dólares do custo do ferro (C_{Fe}) e do cobre (C_{Cu}), que são os principais materiais utilizados, podendo ser calculado por (23).

$$C_t = C_{Fe} + C_{Cu} = (M_{Fe} * Cot_{Fe}) + (M_{Cu} * Cot_{Cu}) \quad (23)$$

Essa abordagem considera as massas dos materiais e suas respectivas cotações de mercado médias por quilo em dólares, US\$2,31 para a cotação do ferro (Cot_{Fe}) e US\$8,50 para a cotação do cobre (Cot_{Cu}), fornecendo uma estimativa realista do custo de produção.

4.10 Volume do Transformador

A formulação para calcular o volume total do transformador leva em conta tanto as áreas ocupadas pelo núcleo quanto pelos enrolamentos, além de considerar a configuração específica do transformador.

Para calcular o volume do núcleo (V_n) de um transformador, consideramos a área frontal do núcleo (S_f) e sua espessura, aqui representada por (b), chegando à Equação (24).

$$V_n = S_f * b \quad (24)$$

Como visto na seção 4.2, o volume real do núcleo pode ser obtido multiplicando a área frontal pela profundidade efetiva do núcleo, que é ajustada para contabilizar a camada de óxido presente nas lâminas do núcleo. A profundidade efetiva (p_{ef}) é aproximadamente 90% da profundidade nominal (MARTIGNONI, 1973).

A equação para o volume ajustado do núcleo é dada pela Equação (25).

$$V'_n = V_n * p_{ef} = 0,9V_n \quad (25)$$

Para calcular o volume dos enrolamentos, consideramos o comprimento médio de uma espira e a área da janela do transformador. O comprimento médio de uma espira (l_m) é uma medida da extensão física da espira ao redor do núcleo do transformador. A área da janela (S_j) refere-se ao espaço dentro do núcleo do transformador onde os enrolamentos são alocados.

O comprimento médio de uma espira é calculado considerando as dimensões do núcleo do transformador, o que envolve a medição da distância percorrida por uma espira ao redor do núcleo. Este valor afeta diretamente a resistência dos enrolamentos e, conseqüentemente, as perdas no cobre.

A área da janela é determinada pelas dimensões internas do núcleo do transformador onde os enrolamentos são alojados. Esta área determina o espaço disponível para os enrolamentos e, portanto, influencia a capacidade total e a eficiência do transformador.

O volume dos enrolamentos (V_w) pode então ser calculado multiplicando-se o comprimento médio de uma espira pela área da janela (S_j), como mostrado na Equação (26).

$$V_w = l_m * S_j = l_m * c_j * h_j \quad (26)$$

Este cálculo fornece uma estimativa do espaço ocupado pelos enrolamentos no transformador, o que é crucial para a análise de projeto e a otimização de custos.

Tem-se então:

- V_n — Volume do Núcleo do Transformador [cm³];
- V_w — Volume dos Enrolamentos [cm³];

5. DESENVOLVIMENTO DO ALGORITMO DE OTIMIZAÇÃO

Esta etapa centra-se na definição das características do problema, codificação das soluções, escolha dos operadores genéticos e definição dos parâmetros do algoritmo.

Mitchell (1998) salienta que a representação eficaz das soluções é o ponto de partida para o desenvolvimento de algoritmos genéticos. A forma de codificação impacta diretamente a eficácia do algoritmo em identificar soluções de alta qualidade. Dependendo da natureza do problema, as soluções podem ser representadas de maneiras variadas, como representações binárias, vetoriais ou simbólicas, e a escolha de uma representação eficiente é relevante para manipular os genes de forma eficaz durante as operações genéticas.

Posteriormente, definem-se os operadores genéticos, incluindo seleção, recombinação e mutação. Eiben e Smith (2015) enfatizam que a seleção é responsável por determinar quais indivíduos serão escolhidos para reprodução, com base em sua aptidão. Estratégias de seleção variam, incluindo seleção por roleta, seleção por torneio e seleção por classificação, cada uma adaptada às especificidades do problema e aos objetivos desejados.

Davis (1991) ressalta a importância de escolher adequadamente os operadores de recombinação, como recombinação de um ou mais pontos de corte. Esta abordagem permite a criação de novas soluções através da combinação de características promissoras de diferentes indivíduos.

Além disso, os parâmetros do algoritmo, como tamanho da população, número máximo de gerações, taxa de cruzamento e taxa de mutação, devem ser cuidadosamente definidos, pois são fundamentais para o desempenho e a convergência do algoritmo (FERRAZ, 2017).

Na análise dos resultados, é essencial avaliar a qualidade das soluções, a convergência do algoritmo, a eficiência computacional e a comparação com outras técnicas de otimização. A qualidade das soluções é medida pela aptidão em relação ao objetivo da otimização, enquanto a convergência do algoritmo é avaliada pela variação da aptidão média da população ao longo das gerações, como sugerido por Das e Suganthan (2011).

A eficiência computacional, destacada por Brest et al. (2006), refere-se ao tempo necessário para alcançar soluções desejadas, equilibrando qualidade e

tempo de execução. Comparar o desempenho do algoritmo com outras técnicas é também fundamental, utilizando métricas como taxa de convergência e qualidade das soluções.

5.1 Escolha da Linguagem de Programação

A seleção de uma linguagem de programação adequada é determinante no projeto de transformadores monofásicos, especialmente ao se desenvolver algoritmos genéticos. A linguagem escolhida deve fornecer um ambiente eficiente de desenvolvimento, suportar as estruturas de dados necessárias e permitir uma implementação precisa do algoritmo genético.

Embora várias linguagens de programação sejam apropriadas para implementar algoritmos genéticos, para este projeto específico, optou-se pelo MATLAB (MATLAB, 2019). MATLAB é amplamente reconhecido em ambientes acadêmicos e de pesquisa por suas excelentes capacidades de análise numérica e estatística, o que é essencial para o processamento e análise de dados complexos associados a transformadores monofásicos.

MATLAB oferece um ambiente de desenvolvimento integrado com uma vasta gama de ferramentas e funções específicas para cálculos matemáticos avançados, o que possibilita o desenvolvimento de algoritmos genéticos eficientes. Sua interface de usuário intuitiva e linguagem de programação de alto nível facilitam a implementação e a experimentação com diferentes abordagens algorítmicas. Além disso, o MATLAB proporciona uma visualização gráfica poderosa, permitindo uma representação clara dos resultados do algoritmo genético (BECKER et al., 2010).

Embora outras linguagens como Python e Java sejam populares por sua simplicidade e portabilidade, o MATLAB se destaca em aplicações de engenharia elétrica e eletrônica devido às suas funcionalidades específicas para análise de engenharia e simulação. Isso torna o MATLAB uma escolha ideal para este projeto, onde precisão, eficiência e análise de dados complexos são fundamentais.

5.2 Desenvolvimento do Algoritmo e Integração com o Transformador

Neste projeto, a ênfase foi colocada no desenvolvimento de um algoritmo genético em MATLAB, visando a otimização de transformadores monofásicos com foco no volume do núcleo e custos de fabricação. A integração efetiva entre o algoritmo e o modelo do transformador é essencial para a aplicabilidade prática dos resultados de otimização.

O algoritmo foi cuidadosamente projetado para ajustar as variáveis do projeto, como número de espiras e outros aspectos físicos da geometria do transformador, com o objetivo de otimizar o volume de seu núcleo e reduzir os custos de fabricação. Essa abordagem assegura que os resultados gerados pelo algoritmo sejam diretamente aplicáveis no projeto do transformador (SANTOS, 2017).

Uma parte importante deste processo é a utilização dos resultados do algoritmo para simulações no software EFCAD (BASTOS; SADOWSKI, 2008). Este passo ajuda na validação das otimizações realizadas, permitindo análises detalhadas de indução magnética e outras simulações relevantes para o projeto do transformador. O uso do EFCAD integra-se perfeitamente ao fluxo de trabalho, fornecendo uma ponte entre os cálculos de otimização e a aplicação prática no design de transformadores.

Assim, a interação contínua entre o algoritmo genético e o transformador, culminando no uso do EFCAD para simulações finais, garante que as melhorias identificadas sejam efetivamente implementadas no projeto final do transformador, destacando a eficácia do método de otimização escolhido (RODRIGUES, 2018).

Na abordagem clássica de projeto de transformadores de núcleo envolvido, a área da seção transversal da perna central do transformador é o parâmetro inicial do projeto. Como se trata de uma área retangular, duas dimensões deverão ser definidas, a largura da perna central (a) e a profundidade do núcleo (b), definindo o número de lâminas que deverão ser empilhadas.

A abordagem clássica utiliza lâminas de dimensões padronizadas, com dimensões proporcionais à largura da perna central do transformador (Figura 3). Essa configuração limita a combinação entre a largura e profundidade das lâminas, devendo o projetista escolher a combinação mais adequada. A padronização de lâminas é dividida entre lâminas curtas, cuja largura da perna central (a) varia de 1,5 cm a 5 cm com incremento de 0,5 cm e lâminas longas com largura da perna central

(a) com dimensões de 4 e 5 cm. O núcleo construído com lâminas curtas possuirá altura de $2,5a$ enquanto que a altura do núcleo com lâminas longas será de $4a$.

A combinação entre largura da perna central e profundidade deverá ser revista após o cálculo dos enrolamentos para garantir que as bobinas do primário e secundário caibam nas janelas do núcleo.

Neste trabalho optou-se por manter a estrutura proporcional das dimensões das lâminas padronizadas, porém a largura da perna central (a) e a profundidade do núcleo (b) não ficam restritas às dimensões padronizadas e busca-se dimensões que minimizem o volume do núcleo e o custo total dos materiais.

O algoritmo de otimização buscará a combinação ideal de largura (a) e profundidade (b) que garanta o menor volume e menor custo de materiais, assegurando que o transformador desempenhe seus valores nominais e seja de construção possível.

As funções objetivo buscam minimizar o custo dos materiais (F_1) e o volume do núcleo do transformador (F_2) como indicado em (27) e (28).

$$F_1 = \min ((M_{Fe} * Cot_{Fe}) + (M_{Cu} * Cot_{Cu})) \quad (27)$$

$$F_2 = \min (V_N) \quad (28)$$

6. METODOLOGIA

O estudo consistiu em uma investigação aprofundada sobre o uso de Algoritmos Genéticos (AGs) para otimizar o projeto de um transformador monofásico, com foco na minimização do volume do núcleo do transformador e nos custos de fabricação.

Primeiramente, foi adotado um código de software em Matlab, desenvolvido por Ávila (2002), que implementava um algoritmo genético de "otimização mono-objetivo". Este algoritmo utilizava um conjunto de parâmetros para definir as características do transformador e buscava encontrar um conjunto de soluções ótimas.

O algoritmo empregou a abordagem da "fronteira de Pareto" para identificar soluções ótimas que fossem não-dominadas, ou seja, soluções em que não existia outra solução que fosse superior em ambos os objetivos. Para atingir esse objetivo, o algoritmo utilizou operadores genéticos, como seleção, cruzamento e mutação, para gerar uma nova geração de soluções a cada iteração. A avaliação de cada solução foi realizada para determinar se ela estava na fronteira de Pareto.

A partir desse código base fornecido, foi desenvolvido um código personalizado em Matlab, que descrevia os parâmetros de dimensionamento específicos para dois exemplos de projeto de transformador encontrados no livro "Transformadores" de Alfonso Martignoni (1973). Os exemplos escolhidos foram:

Exemplo 1 (página 84):

- Frequência de Rede de 50 Hz.
- Potência Secundária (W_1) de 300 VA.
- Tensão no Secundário (V_2) de 220 V.
- Tensão no Primário (V_1) de 120 V.

Exemplo 2 (página 88):

- Frequência de Rede de 50 Hz.
- Potência Secundária (W_1) de 1000 VA.
- Tensão no Primário (V_1) de 220 V.
- Tensão no Secundário (V_2) de 24 V.

Os resultados obtidos por meio deste código personalizado foram avaliados de maneira dimensional, considerando as grandezas de entrada e saída, bem como de maneira gráfica, com simulações da indução magnética dos transformadores realizadas via método de elementos finitos em 2D, utilizando o software EFCAD do laboratório GRUCAD da UFSC.

Nesse contexto, este método proporcionou uma compreensão profunda das equações, dos parâmetros físicos e dos processos envolvidos no projeto e otimização de transformadores monofásicos por meio de algoritmos genéticos. Essa abordagem promissora abre caminho para a melhoria do desempenho e eficiência desses dispositivos essenciais em diversas aplicações industriais e de distribuição de energia elétrica.

6.1 Parâmetros de Entrada e Saída do Projeto

Os parâmetros iniciais são estabelecidos para refletir as necessidades operacionais e econômicas do transformador. A indução magnética máxima foi fixada em 1,13 T, com a seleção de lâminas de ferro silício para compor o núcleo, devido às suas boas propriedades magnéticas e eficiência em termos de custo para frequências de 50 Hz. Esta escolha de material alia desempenho e viabilidade econômica, servindo como a base para as etapas subsequentes de projeto.

A Tabela 1 mostra as variáveis de entrada utilizadas junto com suas unidades de medida.

Tabela 1 - Grandezas de Entrada do Projeto.

(continua)

Variável	Símbolo	Valor (Projeto 1)	Valor (Projeto 2)
Tensão Primária (V)	V_1	120	220
Tensão Secundária (V)	V_2	220	24
Potência Secundária (VA)	W_2	300	1000
Frequência da Rede (Hz)	f	50	50
Massa Específica do Cobre (kg/m ³)	ρ_{Cu}	8920	8920
Massa Específica do Núcleo (kg/m ³)	ρ_{Fe}	7650	7650

Tabela 2 - Grandezas de Entrada do Projeto.

(conclusão)

Densidade de Corrente nos Condutores (A/mm ²)	d	2,63	2,5
Indução Magnética Máxima do Núcleo (T)	B_m	1,13	1,13
Coefficiente de Preenchimento	k_f	0,95	0,95

Fonte: autor (2023)

A otimização dos projetos dos transformadores utilizando Algoritmos Genéticos tem como resultado diversas grandezas de saída. Estas grandezas servem como indicadores do desempenho operacional, da eficiência energética e da viabilidade econômica e logística do transformador projetado.

A Tabela 2 a seguir sumariza as grandezas de saída resultantes que são utilizadas para a avaliação dos designs otimizados, exibindo seu símbolo e unidade de medida.

Tabela 3 - Grandezas de Saída do Projeto.

(continua)

Variável	Símbolo
Largura da Coluna Central (cm)	a
Profundidade do Núcleo (cm)	b
Largura de Janela (cm)	c_j
Altura da Janela (cm)	h_j
Número de Espiras Primárias	N_1
Número de Espiras Secundárias	N_2
Perdas nos Condutores de Cobre (W)	W_{Cu}
Perdas no Núcleo (W)	W_{Fe}
Perdas Totais (W)	W_t
Rendimento (%)	η
Massa Total dos Condutores de Cobre (Kg)	M_{Cu}
Massa Total do Núcleo (Kg)	M_{Fe}
Massa Total (Kg)	M_t
Volume Total do Núcleo (cm ³)	V_n
Volume Total Real do Núcleo (cm ³)	V'_n
Custo Total dos Condutores de Cobre (US\$)	C_{Cu}

Tabela 4 - Grandezas de Saída do Projeto.

(conclusão)

Custo Total do Núcleo (US\$)	C_{Fe}
Custo Total (US\$)	C_t

Fonte: autor (2023)

6.2 Inicialização do Algoritmo Genético

A inicialização do algoritmo genético (AG) se baseia em parâmetros que orientam o espaço de busca para soluções viáveis e otimizadas. Essas variáveis, tais como o número de indivíduos na população, o número de gerações, as probabilidades de cruzamento e mutação, bem como o número de variáveis de entrada, são estabelecidas visando equilibrar a exploração do espaço de busca com a eficiência computacional, sendo apresentadas na Tabela 3.

Tabela 5 - Variáveis de Inicialização do AG.

Variável	Símbolo	Valor
Número de Indivíduos	n_{ind}	500
Número de Gerações	n_{gen}	100
Probabilidade de Cruzamento	p_{cruz}	25%
Probabilidade de Mutação	p_{mut}	50%
Número de Variáveis de Entrada	n_{var}	2

Fonte: autor (2023)

A definição dos limites operacionais das variáveis do AG é um passo que garante que o algoritmo permaneça focado em regiões do espaço de soluções que sejam práticas e realizáveis (ÁVILA, 2002). A largura da coluna central e a profundidade do núcleo são as dimensões críticas do transformador onde são impostos os limites inferiores e superiores. Esses limites não são arbitrários, mas derivados de considerações de projeto, padrões de segurança e experiência prática, assegurando que as soluções propostas pelo AG sejam não apenas otimizadas, mas também aplicáveis no mundo real.

Tais limites são exibidos na Tabela 4.

Tabela 6 - Limites inferiores e superiores das variáveis do AG.

Variável	Limite Inferior (cm)	Limite Superior (cm)
<i>a</i>	2,00	8,00
<i>b</i>	2,00	8,00

Fonte: autor (2023)

6.3 Funcionamento do Algoritmo Genético

O AG opera através de uma simulação do processo evolutivo natural, iterativamente selecionando, cruzando e mutando as variáveis de projeto para encontrar a combinação ótima que atenda à função objetivo estabelecida. A função objetivo é escolhida para refletir as prioridades do projeto, que são a minimização do volume do núcleo e dos custos de fabricação.

O algoritmo é projetado para evoluir ao longo de várias gerações, cada uma avaliada por sua 'fitness', ou adequação, até que uma solução ideal seja identificada ou até que o processo de busca atinja um ponto de terminação predeterminado.

Os resultados obtidos serão discutidos em detalhes no capítulo seguinte, com uma comparação das soluções encontradas.

7. RESULTADOS

No Capítulo 3, foi descrita a metodologia empregada para aplicar o algoritmo genético com o foco em aperfeiçoar individualmente variáveis específicas relacionadas ao transformador. Este processo originou dois projetos separados, cada um com seu próprio conjunto de parâmetros e metas de otimização. As formulações matemáticas usadas para modelar as características do transformador - particularmente aquelas que se referem ao volume do núcleo e custos de fabricação - foram baseadas em princípios consistentes, que foram explorados e fundamentados no Capítulo 5.

Essa abordagem permitiu a execução de análises independentes, com cada projeto tendo como alvo uma única métrica de desempenho. Isso proporcionou uma compreensão clara do impacto de cada variável de saída sobre a configuração geral do transformador, estabelecendo assim uma base sólida para a otimização subsequente e para a avaliação comparativa dos resultados obtidos.

Esta seção não apenas compila os resultados gerais obtidos a partir da otimização, mas também avalia o desempenho abrangente do algoritmo genético.

Especificamente, foram analisados o volume do núcleo e os custos de fabricação do melhor candidato de cada subprojeto, assim como as médias dessas variáveis minimizadas ao longo das gerações. Além disso, a consistência e a variação das soluções produzidas pelo algoritmo foram exploradas por meio do cálculo do desvio padrão da função objetivo para cada geração, proporcionando uma visão mais aprofundada sobre a estabilidade e confiabilidade do processo de otimização.

A implementação do algoritmo foi realizada no software MATLAB, o que possibilitou a definição precisa dos parâmetros do transformador e a execução dos operadores genéticos essenciais. Com isso, foi possível gerar uma população inicial robusta e diversificada de soluções potenciais. Os esforços concentraram-se, então, na minimização do volume do núcleo e dos custos de fabricação para os exemplos de transformadores especificados no Capítulo 6, respeitando as limitações físicas e elétricas intrínsecas a esses dispositivos.

Os resultados alcançados são apresentados por meio de várias grandezas de saída. Estas incluem as perdas no núcleo e no cobre, as correntes de operação no

primário e no secundário, as tensões correspondentes, a massa total, a eficiência energética, o volume do núcleo e os custos de fabricação associados aos materiais.

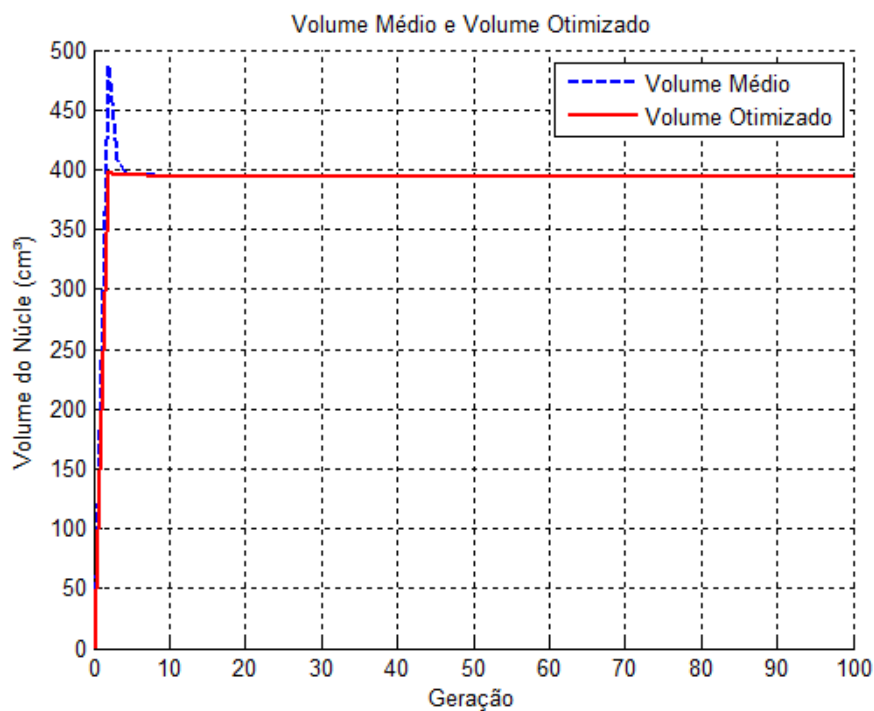
Tais grandezas são de suma importância para a avaliação do desempenho dos transformadores propostos e são decisivas no suporte ao processo de tomada de decisões no estágio de projeto e manufatura.

7.1 Otimização do Volume do Núcleo dos Transformadores

Os resultados iniciais, ilustrados nas Figuras 1 e 2, demonstraram a eficácia do processo de otimização na convergência para o volume ótimo do núcleo dos transformadores.

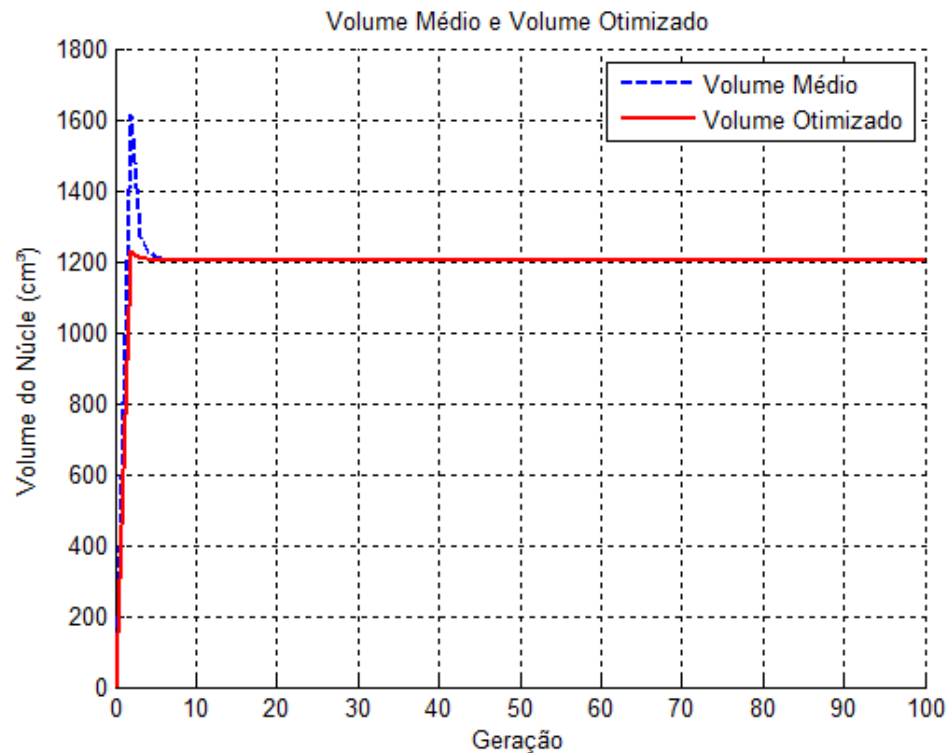
Na Figura 5, são apresentados os volumes do núcleo dos melhores resultados para cada geração do Exemplo 1, enquanto a Figura 6 exibe os dados correspondentes ao Exemplo 2. Ambas as figuras também exibem a média do volume do núcleo da população, destacando o progresso e a estabilização das dimensões ao longo do processo.

Figura 5 - Gráfico representando o volume do núcleo do melhor indivíduo e média de volume do núcleo da população para cada geração do Exemplo 1.



Fonte: autor (2023).

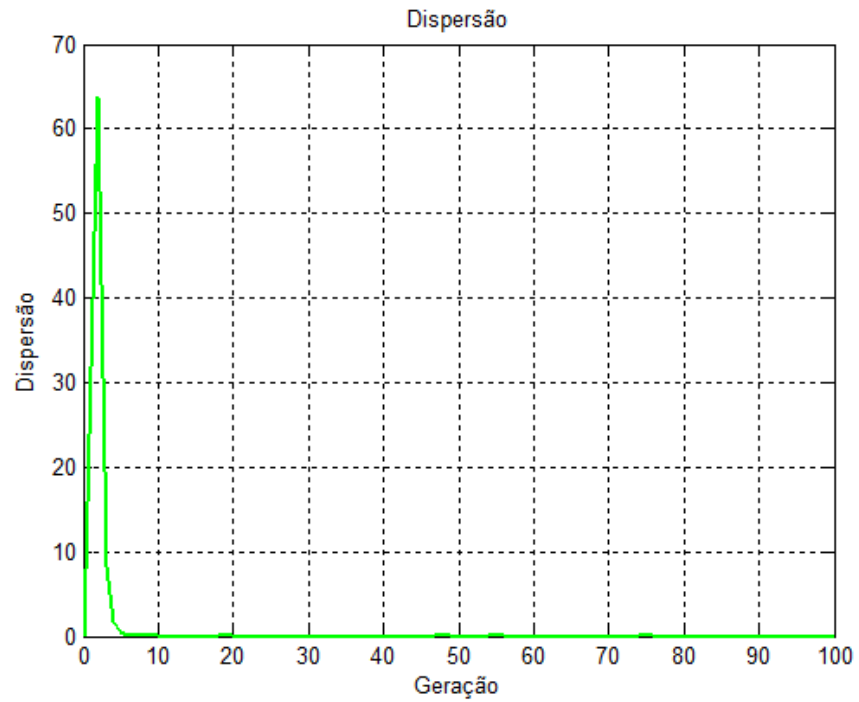
Figura 6 - Gráfico representando o volume do núcleo do melhor indivíduo e média de volume do núcleo da população para cada geração do Exemplo 2.



Fonte: autor (2023).

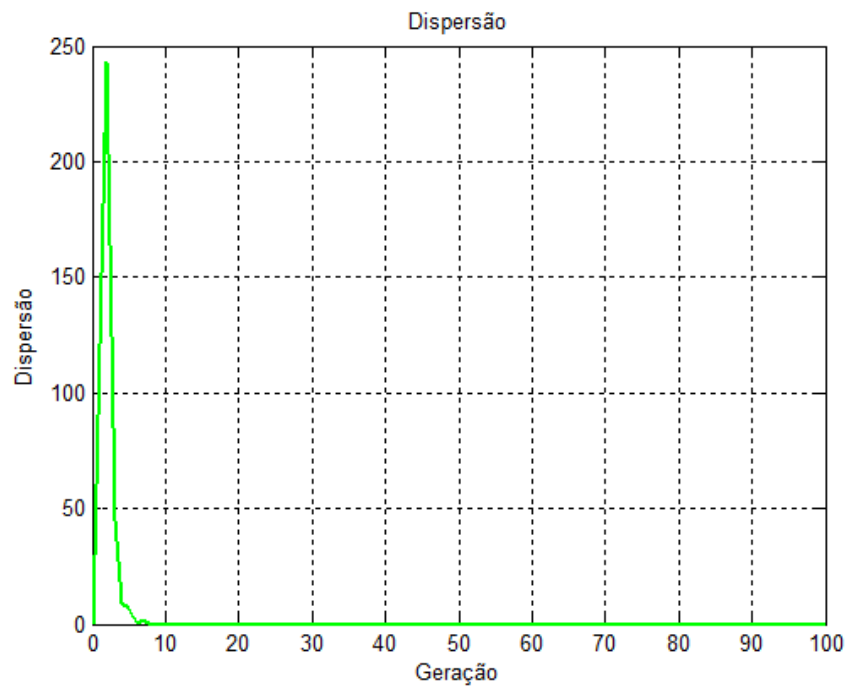
Analisando o desvio padrão das dimensões ao longo das gerações, notou-se uma diminuição significativa, sinalizando uma homogeneização das características dos transformadores dentro da população. Esse padrão de convergência sugere que as soluções estão se agrupando em torno de um volume considerado ideal dentro do espaço de busca, como observado nas Figuras 7 e 8 para os dois exemplos de projeto analisados.

Figura 7 - Gráfico representando o desvio padrão da população por geração no algoritmo de otimização de volume do núcleo do Exemplo 1.



Fonte: autor (2023).

Figura 8 - Gráfico representando o desvio padrão da população por geração no algoritmo de otimização de volume do núcleo do Exemplo 2.




Fonte: autor (2023).

A fim de examinar a distribuição do campo magnético nos transformadores após a otimização, recorreu-se a simulações computacionais 2D utilizando o software EFCAD (BASTOS; SADOWSKI, 2008), uma ferramenta especializada no campo da simulação de dispositivos eletromagnéticos.

Os resultados de ambas as simulações, para os projetos otimizados, são apresentados nas Figuras 9 e 10 abaixo.


Dada a simetria da geometria do transformador, somente metade da estrutura foi modelada. Os cálculos foram realizados considerando o núcleo com material ferromagnético não linear, com saturação em torno de 1,5 T. Os cálculos foram realizados com o modo estático, estando os dois enrolamentos com corrente nominal.

Figura 9 - Distribuição da indução magnética no núcleo do transformador do Exemplo 1 via simulação com o software EFCAD.



Fonte: autor (2023).

Figura 10 - Distribuição da indução magnética no núcleo do transformador do Exemplo 2 via simulação com o software EFCAD.



Fonte: autor (2023).


As cartas de campo mostradas acima indicam que ambos os transformadores trabalham no joelho da curva de magnetização, o que otimiza o uso do material ferromagnético.

7.2 Otimização do Custo de Fabricação dos Transformadores

Nos gráficos apresentados nas Figuras 11 e 12, são exibidos os custos dos materiais para os melhores resultados de cada geração e a média do custo total da população.

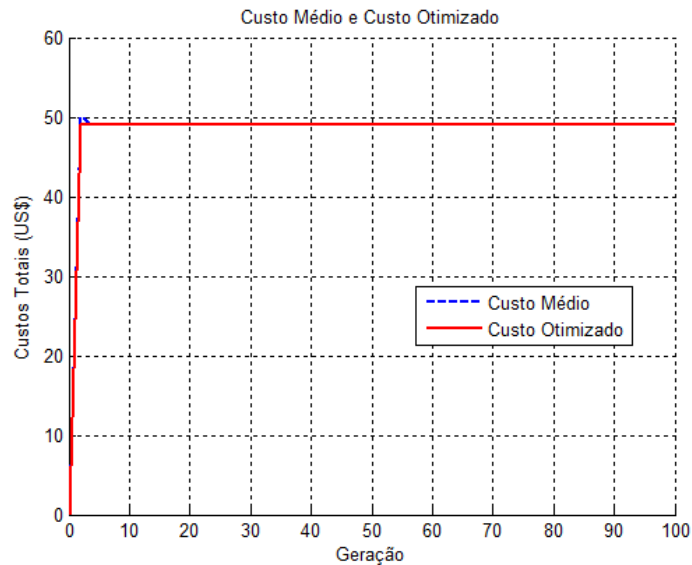
A Figura 11 ilustra os resultados da otimização para o Exemplo 1, enquanto a Figura 12 apresenta o desempenho para o Exemplo 2. Nestes gráficos, é possível observar não apenas a evolução dos custos ao longo das gerações, mas também a estabilização dos valores que indicam uma convergência para um ótimo de custo.

Figura 11 - Gráfico representando o custo dos materiais do melhor indivíduo e média de custos da população para cada geração do Exemplo 1.



Fonte: autor (2023).

Figura 12 - Gráfico representando o custo dos materiais do melhor indivíduo e média de custos da população para cada geração do Exemplo 2.




Fonte: autor (2023).

A análise dos desvios padrões ao longo das gerações forneceu *insights* adicionais sobre a variabilidade dos resultados e a consistência do processo de otimização. Foi observado que o desvio padrão diminuiu ao longo das gerações,


sugerindo que a população está convergindo para soluções cada vez mais homogêneas e custo-eficientes, como visto nas Figuras 13 e 14 para cada exemplo de projeto respectivamente.

Figura 13 - Gráfico representando o desvio padrão da população por geração no algoritmo de otimização de custo total do Exemplo 1.



Fonte: autor (2023).


Figura 14 - Gráfico representando o desvio padrão da população por geração no algoritmo de otimização de custo total do Exemplo 2.



Fonte: autor (2023).


Utilizando o software EFCAD (BASTOS; SADOWSKI, 2008), para densidades de corrente específicas de $2,63 \text{ A/mm}^2$ e $2,5 \text{ A/mm}^2$ respectivamente para cada exemplo, confirmou-se que a indução magnética na região central do núcleo atingiu valores ótimos em torno de $1,2 \text{ T}$ para o Exemplo 1 e $1,3 \text{ T}$ para o Exemplo 2, respectivamente, com as simulações presentes nas Figuras 15 e 16.

Figura 15 - Distribuição da indução magnética no núcleo do transformador do Exemplo 1 via simulação com o software EFCAD.



Fonte: autor (2023).

Figura 16 - Distribuição da indução magnética no núcleo do transformador do Exemplo 2 via simulação com o software EFCAD.



Fonte: autor (2023).

As curvas das figuras 15 e 16 foram calculadas na região central do transformador.

7.3 Síntese dos Resultados Finais das Otimizações

As Tabelas 5 e 6 a seguir consolidam as respostas finais, destacando as principais variáveis de saída dos Exemplos 1 e 2 obtidas pelos cálculos de Martignoni (1973) e também pelos algoritmos genéticos ao otimizar os projetos quanto ao volume total e custos de fabricação dos transformadores, refletindo a precisão e eficácia da metodologia adotada.

Tabela 7 - Parâmetros de saída resultante de cada projeto otimizando o volume do núcleo.

Saídas	Martignoni Exemplo 1	AG Exemplo 1	Martignoni Exemplo 2	AG Exemplo 2
a (cm)	5	6,0405	5	5,7261
b (cm)	4	2,0025	6,5	4,1082
c_j (cm)	2,5	3,0202	2,5	2,863
h_j (cm)	7,5	9,0607	7,5	8,5892
N_1	264	437	298	411
N_2	532	880	36	49
W_{Cu} (W)	20,51	35,32	50,43	64,20
W_{Fe} (W)	8,33	4,17	20,31	12,83
W_t (W)	28,84	39,50	70,75	77,03
η (%)	91,27	88,36	93,39	92,84
M_{Cu} (kg)	1,35	2,1019	3,32	4,22
M_{Fe} (kg)	4,21	2,1086	10,27	6,49
M_t (kg)	5,56	4,2106	13,59	10,71
V_n (cm ³)	600	438,39	1.462,50	1.212,30
V'_n (cm ³)	540	394,55	1.316,25	1.091,07
C_{Cu} (US\$)	11,48	17,86	28,22	35,93
C_{Fe} (US\$)	9,72	4,87	23,72	14,99
C_t (US\$)	21,20	22,73	51,94	50,92

Fonte: autor (2023)

Tabela 8 - Parâmetros de saída resultante para cada projeto otimizando o custo total.

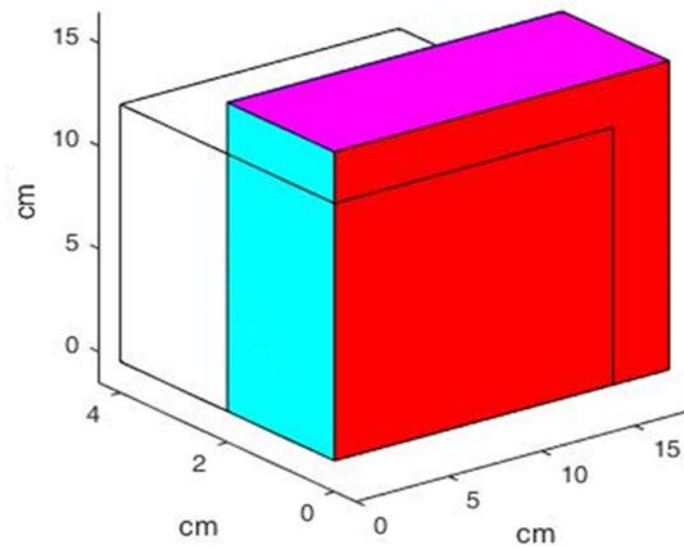
Saídas	Martignoni Exemplo 1	AG Exemplo 1	Martignoni Exemplo 2	AG Exemplo 2
a (cm)	5	8	5	5,9998
b (cm)	4	3,5389	6,5	5,4598
c_j (cm)	2,5	4	2,5	2,9999
h_j (cm)	7,5	12	7,5	8,9997
N_1	264	186	298	296
N_2	532	376	36	35
W_{Cu}	20,51	20,99	50,43	51,96
W_{Fe}	8,33	7,37	20,31	17,06
W_t	28,84	28,36	70,75	69,02
η (%)	91,27	91,36	93,39	93,54
M_{Cu} (kg)	1,35	1,25	3,32	3,42
M_{Fe} (kg)	4,21	3,72	10,27	8,62
M_t (kg)	5,56	4,97	13,59	12,04
V_n (cm ³)	600	1.358,93	1.462,50	1.768,85
V'_n (cm ³)	540	1.223,04	1.316,25	1.591,97
C_{Cu} (US\$)	11,48	10,62	28,22	29,08
C_{Fe} (US\$)	9,72	8,60	23,72	19,92
C_t (US\$)	21,20	19,22	51,94	49,00

Fonte: autor (2023)


Estes resultados evidenciam a eficácia do algoritmo genético em otimizar as variáveis de saída dos projetos, demonstrando sua capacidade em promover melhorias significativas e direcionadas nas especificações dos transformadores.

As figuras a seguir mostram a diferença de volume ocupado pelos núcleos dos transformadores calculados com a metodologia tradicional, em branco, e uma possível variação otimizada pelo seu volume, colorida. Os núcleos estão sobrepostos para permitir a comparação dos volumes ocupados.

Figura 17 - Comparação entre volumes dos núcleos calculados com a metodologia tradicional (branco) e otimizado (colorido) para os exemplos 1 e 2.



a) Comparação entre volumes para o transformador do núcleo do exemplo 01.



b) Comparação entre volumes para o transformador do núcleo do exemplo 02.

Observa-se que os núcleos otimizados pelo volume são mais elevados e largos, porém mais estreitos, possibilitando uma redução volumétrica e de massa significativa. Considerações sobre o emprego dos transformadores em situações com restrições de massa e volume devem ser consideradas quando da otimização dos dispositivos.

8. CONCLUSÃO

Ao finalizar este estudo sobre a otimização de transformadores monofásicos utilizando algoritmos genéticos, é evidente o alcance significativo dos objetivos propostos. A partir da abordagem teórica e prática detalhada nos Capítulos 3 e 4, este trabalho demonstrou como a aplicação de algoritmos genéticos pode efetivamente otimizar aspectos cruciais do projeto de transformadores, dada sua capacidade em refinar critérios essenciais em seu design e possibilitando a otimização de parâmetros como o volume do núcleo e custos de fabricação.

O Capítulo 5 centrou-se no estudo e aprimoramento do algoritmo genético desenvolvido originalmente por Ávila (2002), destinado à otimização dos transformadores monofásicos. Esta fase foi caracterizada pelo desenvolvimento cuidadoso de estratégias de otimização, selecionando operadores genéticos apropriados e ajustando parâmetros para garantir a eficácia do algoritmo.

A metodologia implementada, explorada no Capítulo 6, demonstrou a habilidade dos algoritmos genéticos em explorar extensivamente o espaço de soluções. Isso permitiu encontrar configurações ótimas que equilibram de forma eficaz o volume do núcleo e os custos de fabricação. A otimização focou em dois objetivos principais: reduzir o volume do núcleo e minimizar os custos de fabricação dos transformadores. Os resultados, apresentados no Capítulo 7, confirmaram a eficiência desta abordagem.

Os transformadores resultantes de cada exemplo de projeto não apenas atenderam aos critérios de volume do núcleo e custo, mas também respeitaram todas as restrições físicas e elétricas inerentes a esses dispositivos, evidenciando a aplicabilidade e eficiência do método. As simulações de indução magnética, realizadas com o software EFCAD, validaram as escolhas de design, assegurando que os níveis de indução magnética permanecessem dentro dos parâmetros desejados para o funcionamento efetivo dos transformadores.

Este trabalho destacou o potencial dos algoritmos genéticos como uma ferramenta poderosa e eficiente para a otimização de transformadores monofásicos, não apenas contribuindo significativamente para o avanço científico e tecnológico no setor de energia elétrica, mas também abrindo novos caminhos para pesquisas futuras e aplicações práticas. Os resultados promissores obtidos indicam a viabilidade de utilizar essa abordagem para melhorar continuamente a eficiência

operacional e econômica de transformadores e outros dispositivos eletromagnéticos, além de ampliar a aplicação de algoritmos genéticos para resolver desafios complexos de projeto e fabricação em diversas áreas da engenharia, promovendo o desenvolvimento de soluções mais sustentáveis e econômicas.

Finalmente, embora o foco deste estudo tenha sido o transformador monofásico, devido à sua prevalência em aplicações de engenharia eletrônica, a metodologia apresentada demonstra potencial para ser adaptada na otimização de transformadores trifásicos e outras configurações. Pesquisas futuras poderiam explorar essas possibilidades, potencialmente ampliando o impacto e a aplicabilidade dos algoritmos genéticos na engenharia.

REFERÊNCIAS BIBLIOGRÁFICAS

MARTIGNONI, Alfonso. Transformadores. Porto Alegre: Editora Globo, 1973.

CHAPMAN, S. J. Electric Machinery Fundamentals. 5. ed. New York: McGraw-Hill, 2011.

GURU, Bhag S. et al. Electric Machinery and Transformers. 3. ed. Oxford: Oxford University Press, 2000.

AGUIAR, A. L.; CAMACHO, J. R. Transformadores de Potência. Universidade Federal de Uberlândia, Faculdade de Engenharia Elétrica, Uberlândia-MG, Brasil. 2011.

ARANTES, Jesimar da Silva et al. Heuristic and Genetic Algorithm Approaches for UAV Path Planning under Critical Situation. International Journal On Artificial Intelligence Tools. [S. L.], p. 1760008. fev. 2017.

DARWIN, Charles. A origem das espécies. Londres: Murray, 1859.

ALBALUSTRO, A. K. Formação de células em sistemas de manufatura: uma abordagem usando algoritmos genéticos. Universidade Federal de Santa Catarina, 2001.

ALEXANDER, C. K.; SADIKU, M. N. O. Circuitos com Acoplamento Magnético. In: Fundamentos de Circuitos Elétricos. 5a ed. [s.l.] McGraw Hill, 2012.

AUDET, C. et al. Performance indicators in multiobjective optimization. European Journal of Operational Research, v. 292, n. 2, p. 397–422, 2021.

ÁVILA, S. L. Algoritmos Genéticos Aplicados na Otimização de Antenas Refletores. Dissertação (Mestrado em Engenharia Elétrica), Programa de Pós-Graduação em Engenharia Elétrica, Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis - SC, 2002.

ÁVILA, S. L. Otimização Multiobjetivo e Análise de Sensibilidade para Concepção de Dispositivos: Aplicação: Síntese de Antenas Refletores para Comunicação via Satélite. 2006. 148 p. Tese (Doutorado) - Curso de Engenharia Elétrica, Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2023.

MATLAB. Versão 2019. Natick, Massachusetts: The MathWorks Inc., 2019. Disponível em: <<http://www.mathworks.com>>. Acesso em: [março de 2023].

BASTOS, J. P. A.; SADOWSKI, N. Finite Element 2D System for Electromagnetic and Thermal Field Analysis: Electromagnetic Fields Computer Aided Design Manual. Florianópolis, v. 8, n. 121, p.2-76, 2008.

BECKER, A. J. et al. Noções Básicas de Programação em MATLAB. Santa Maria, 2010.

CUNHA, V. Otimização de custos de aquisição e estocagem de matéria-prima em empresas de food service. XXIX Congresso Brasileiro de Custos. João Pessoa, 2022.

DAS, S.; SUGANTHAN, P. N. Differential evolution: a survey of the state-of-the-art. IEEE Transactions on Evolutionary Computation, 15(1), 4-31. 2011.

DEB, K. Otimização multiobjetivo utilizando algoritmos evolutivos. John Wiley & Sons. 2001.

FERRAZ, B. A. Métodos Computacionais de Otimização. Dissertação (Mestrado Profissional em Matemática), Programa de Pós-Graduação em Matemática, Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro - SP, 2017.

FITZGERALD, A. E.; KINGSLEY JUNIOR, C.; UMANS, S. D. Electric Machinery. 6. ed. Nova Iorque: McGraw-Hill, 688 p. (McGraw-Hill series in electrical engineering. Power and energy).2003.

GODOY, M. V. Transformadores de Potência. Universidade de Pernambuco, Departamento de Engenharia Elétrica, Vol. 1, (pp. 1-26), Recife-PE, Brasil.2010.

GOLDBERG, D. E. Genetic Algorithms in Search, Optimization, and Machine Learning. Nova Iorque: Addison-Wesley Professional, 1989. 432 p.

HAUPT, R. L.; HAUPT, S. E. Algoritmos genéticos práticos. John Wiley & Sons. 2004.

HOLLAND, J. H. Adaptação em sistemas naturais e artificiais. University of Michigan Press. 1975.

KATO, R. Algoritmos Genéticos. Revista Brasileira de Bioinformática, 2021.

MALAGOLI, J. A.; CAMACHO, J. R.; FERREIRA DA LUZ, M. V. Projeto de Rotor de Máquina de Indução Trifásica Usando o Algoritmo de Evolução Diferencial. Simpósio Brasileiro de Micro-ondas e Optoeletrônica e Congresso Brasileiro de Eletromagnetismo, Vol. 1, (pp. 1-6), Curitiba-PR, Brasil. 2014.

MITCHELL, M. Uma introdução aos algoritmos genéticos. MIT Press. 1998.

NIX, A.; VOSE, M. Modeling Genetic Algorithms with Markov Chains. Annals of Mathematics and Artificial Intelligence. 1992.

PACHECO, M. A. C. Algoritmos genéticos: princípios e aplicações. Pontifícia Universidade Católica do Rio de Janeiro, 2017.

PRADO, O. G. Computação evolutiva empregada na reconstrução de árvores filogenéticas. Universidade Estadual de Campinas, 2001.

PRICE, K. V.; STORN, R. M.; LAMPINEN, J. A. Evolução diferencial: uma abordagem prática para otimização global. SPRINGER. 2005.

SÁ, A. G. C. Evolução automática de algoritmos de redes bayesianas de classificação. Universidade Federal de Minas Gerais, 2014.

SIVANANDAM, S. N.; DEEPA, S. N. Introdução aos algoritmos genéticos. Springer. 2008.

STORN, R.; PRICE, K. Evolução diferencial - Uma heurística simples e eficiente para otimização global em espaços contínuos. *Journal of Global Optimization*, 11(4), 341-359. 1997.