



**UFC**  
**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA ELÉTRICA**  
**CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**FRANCISCO GABRIEL FARIAS MORORÓ**

**APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL NA PROTEÇÃO DE  
TRANSFORMADORES: REVISÃO COMPARATIVA**

**FORTALEZA**

**2026**

FRANCISCO GABRIEL FARIAS MORORÓ

**APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL NA PROTEÇÃO DE  
TRANSFORMADORES: REVISÃO COMPARATIVA**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia Elétrica.

Orientador: Prof. Dr. Ernande Eugenio Campelo  
Morais

FORTALEZA

2026

BANCA EXAMINADORA

---

Prof. Dr. Ernande Eugenio Campelo Morais  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Paulo Peixoto Praça  
Universidade Federal do Ceará (UFC)

---

Davi Pessoa Melo  
Eng. Eletricista.

A Minha família e amigos, que me  
acompanham durante essa jornada chamada  
vida.

## AGRADECIMENTOS

Agradeço primeiramente a Deus, que em sua infinita magnificência permitiu a conclusão desta jornada, concedendo-me forças e perseverança para superar todos os obstáculos que se apresentaram pelo caminho.

Aos meus pais, Nataniel e Jordânia, por todo o amor incondicional, cuidado e incentivo constantes que fundamentaram minha trajetória. Ao meu avô Ribeiro (*in memoriam*), que, mesmo partindo durante minha infância, permanece como o maior exemplo de hombridade e bondade que conheci. À minha avó Lenir, uma segunda mãe, sempre zelosa, amorosa e presente. Aos meus irmãos, Isabelly e Ribeiro, que são extensões de mim; foi um privilégio crescer ao lado de vocês.

Ao meu orientador, Prof. Dr. Ernande Eugenio, pela paciência, pelas valiosas orientações e pelo companheirismo durante o desenvolvimento deste trabalho. Estendo minha gratidão aos demais membros da banca, Prof. Dr. Paulo Praça e Eng. Davi Pessoa, pela disponibilidade e pelas contribuições inestimáveis para a avaliação desta pesquisa.

Ao Departamento de Engenharia Elétrica da Universidade Federal do Ceará (UFC), pela excelência no ensino. Um agradecimento especial aos servidores Adelly Ribeiro e Mario Sergio, pela presteza e suporte administrativo sempre que necessário. A todo o corpo docente que contribuiu para minha formação, minha profunda gratidão pelos ensinamentos compartilhados e pela base técnica construída ao longo do curso.

Aos amigos de graduação Gabriel Lino, Samuel Muniz, Natália Macedo, Willian Santos, João Rodrigo, Os Thiagos Rodrigues, João Victor Bazzan e Emanuel Mota. Agradeço por eu sempre poder contar com vocês, compartilhando os momentos de alegria e dividindo o peso dos dias difíceis. Obrigado pela escuta e por me acompanharem até aqui.

## RESUMO

Este trabalho apresenta uma revisão comparativa entre os métodos tradicionais de proteção de transformadores de potência e as abordagens fundamentadas em Inteligência Artificial (IA). O objetivo principal consiste em investigar como as técnicas inteligentes podem elevar os níveis de confiabilidade, seletividade e tempo de resposta dos sistemas de proteção. A metodologia adotada possui caráter exploratório e comparativo, baseando-se em pesquisa bibliográfica e na análise técnica de estudos recentes que aplicam Redes Neurais Artificiais (ANN), Aprendizado Profundo (*Deep Learning*) e modelos híbridos. Os resultados da análise indicam que os métodos tradicionais, embora robustos e normatizados, apresentam limitações estruturais diante da saturação de transformadores de corrente e de correntes de *inrush* com baixo conteúdo harmônico. Em contrapartida, as aplicações de IA, especialmente as arquiteturas de redes convolucionais (CNN) e modelos como o *Long Short-Term Memory* (LSTM), demonstram desempenho superior, alcançando tempos de detecção reduzidos para a faixa de 1 a 5 ms e uma redução expressiva na taxa de falsos disparos. Observou-se que o uso de *autoencoders* contribui significativamente para a robustez do sistema em ambientes ruidosos e saturados. Conclui-se que a Inteligência Artificial atua como uma evolução complementar essencial para a operação segura de *smart grids* e redes elétricas modernas de alta complexidade. No entanto, a viabilidade de sua implementação em larga escala ainda depende de avanços na padronização metodológica, validação em campo e na disponibilidade de bases de dados reais e representativas.

**Palavras-chave:** proteção de transformadores; inteligência artificial; proteção diferencial; aprendizado de máquina; redes neurais

## ABSTRACT

This work presents a comparative review between traditional power transformer protection methods and Artificial Intelligence (AI) based approaches. The main objective is to investigate how intelligent techniques can enhance reliability, selectivity, and response time levels of protection systems. The adopted methodology is exploratory and comparative, based on bibliographic research and technical analysis of recent studies applying Artificial Neural Networks (ANN), Deep Learning, and hybrid models. The analysis results indicate that traditional methods, although robust and standardized, present structural limitations regarding current transformer (CT) saturation and inrush currents with low harmonic content. In contrast, AI applications, especially convolutional neural network (CNN) architectures and models such as Long Short-Term Memory (LSTM), demonstrate superior performance, achieving detection times reduced to the 1 to 5 ms range and a significant reduction in false trip rates. It was observed that the use of autoencoders contributes significantly to system robustness in noisy and saturated environments. It is concluded that Artificial Intelligence acts as an essential complementary evolution for the safe operation of smart grids and modern high-complexity power systems. However, the feasibility of its large-scale implementation still depends on advances in methodological standardization, field validation, and the availability of real and representative databases.

**Keywords:** transformer protection; artificial intelligence; differential protection; machine learning; neural networks

## LISTA DE FIGURAS

Figura 01 - Representação do transformador .....	19
Figura 02 - Representação do transformador monofásico .....	20
Figura 03 - Representação do transformador trifásico .....	21
Figura 04 - Transformador trifásico imerso em óleo isolante.....	22
Figura 05 - Transformador trifásico tipo seco .....	23
Figura 06 - Construção do transformador trifásico com núcleo envolvido .....	24
Figura 07 - Construção do transformador trifásico com núcleo envolvente .....	24
Figura 08 - Representação da conexão em Estrela entre 2 (dois) transformadores.....	25
Figura 09 - Representação da conexão Delta entre 2 (dois) transformadores.....	26
Figura 10 - Representação de sistema trifásico com transformadores em conexão Delta e utilização de transformador em zigue-zague para criação de neutro artificial e aterramento .....	26
Figura 11 - Representação de relé eletromecânico.....	30
Figura 12 - Proteção de transformadores por relés de sobrecorrente .....	31
Figura 13 - Relé diferencial amperimétrico - proteção diferencial .....	33
Figura 14 - Relé diferencial percentual.....	33
Figura 15 - Diagrama trifilar da conexão delta estrela.....	35
Figura 16 - Representação da proteção por bloqueio de harmônica .....	36
Figura 17 - Modelo de aprendizado não supervisionado .....	40
Figura 18 - Modelo de aprendizado por reforço .....	41
Figura 19 - Fluxograma de esquema de proteção baseado em proteção diferencial com IA...	45
Figura 20 - Curva característica de excitação de TC .....	59

## LISTA DE GRÁFICOS

Gráfico 01 - Componentes do transformador afetados.....	15
Gráfico 02 - Desempenho dos métodos de IA.....	64

## **LISTA DE TABELAS**

Tabela 01 - Vantagens e Limitações da proteção percentual.....	56
Tabela 02 - Desempenho comparativo de métodos de Inteligência Artificial aplicados à proteção diferencial de transformadores .....	62

## LISTA DE ABREVIATURAS E SIGLAS

ANFIS — *Adaptive Neuro-Fuzzy Inference System*

ANN — *Artificial Neural Network*

ATP — *Alternative Transients Program*

CAE — *Convolutional Autoencoder*

CELG — *Concessionária de Distribuição de Energia Elétrica de Goiás* CNN

— *Convolutional Neural Network*

DCNN — *Denoising-Classification Neural Network*

DL — *Deep Learning*

ELM — *Extreme Learning Machine*

EMTDC — *Electromagnetic Transients including DC*

FFBP — *Feed-Forward Backpropagation*

GPU — *Graphics Processing Unit*

IA — *Inteligência Artificial*

IBM — *International Business Machines Corporation*

IEC — *International Electrotechnical Commission*

IEEE — *Institute of Electrical and Electronics Engineers*

KNN — *K-Nearest Neighbors*

LSSVM — *Least Squares Support Vector Machine*

LSTM — *Long Short-Term Memory*

LVQ — *Learning Vector Quantization*

ML — *Machine Learning*

PCA — *Principal Component Analysis*

PNN — *Probabilistic Neural Network*

PSCAD — *Power Systems Computer Aided Design*

PSO — *Particle Swarm Optimization*

RSLVQ — *Robust Soft Learning Vector Quantization*

SFCL — *Superconducting Fault Current Limiter SVM*

— *Support Vector Machine*

TC — *Transformador de Corrente*

TPU — *Tensor Processing Unit*

VICUR — *Voltage-Inrush Characteristic Curve*

## SUMÁRIO

<b>1. INTRODUÇÃO</b>	<b>14</b>
1.1 Motivação	15
1.2 Objetivo Geral	16
1.3 Objetivos Específicos	16
1.4 Estrutura do Trabalho	17
1.5 Metodologia	17
<b>2. FUNDAMENTAÇÃO TEÓRICA</b>	<b>19</b>
2.1. Conceitos de transformador de potência	19
2.1.1 Núcleo Magnético	23
2.1.2 Enrolamentos	25
2.1.3 Sistema de Isolamento	27
2.1.4 Componentes Auxiliares	28
2.2. Proteções de Transformadores	29
2.2.1. Tipos de Relé	29
2.2.2. Relé de Sobrecorrente	31
2.2.3. Relé Diferencial	32
2.2.3.1 Relé diferencial amperimétrico	32
2.2.3.2. Relé diferencial percentual	33
2.2.4 Proteção Diferencial	34
2.2.4.1. Compensação das Conexões do Transformador ( $\Delta$ -Y)	34
2.2.4.2. Posicionamento do Relé Entre Duas Ligações Delta	34
2.2.4.3. Ajuste das Relações de Transformação dos TCs	35
2.2.5 Bloqueio por Harmônica	35
2.3 Introdução à Inteligência Artificial	37
2.4.1. Aprendizado de Máquina (Machine Learning — ML)	37
2.4.1.1. Aprendizado Supervisionado	38
2.4.1.2. Aprendizado Não Supervisionado	39
2.4.1.3. Aprendizado por Reforço	40
2.4.2. Aprendizado Profundo (Deep Learning — DL)	41
2.4.3. Sistemas Neuro-Fuzzy	43
<b>3. ESTADO DA ARTE</b>	<b>44</b>
3.1 Pesquisas recentes sobre IA na proteção de transformadores	44
3.1.1. Revisões e análises comparativas de IA para proteção diferencial	44
3.1.2 IA na proteção diferencial: classificadores neurais e otimização	46
3.1.3 Arquiteturas de Deep Learning: CNN, Autoencoders e modelos híbridos	47
3.1.4 Integração com relés numéricos e limitações dos métodos tradicionais	47
3.2 Comparação entre métodos tradicionais e métodos baseados em Inteligência Artificial	48
3.2.1 Métodos tradicionais de proteção de transformadores	48
3.2.2 Limitações estruturais dos métodos tradicionais	48
3.2.3 Princípios dos métodos baseados em Inteligência Artificial	49

3.3 Benefícios Relatados na Literatura (tempo de detecção, seletividade, redução de falsos disparos)	50
3.3.1 Redução do tempo de detecção	50
3.3.2 Melhora da seletividade	51
3.3.3 Redução de falsos disparos	52
<b>4. AVALIAÇÃO DOS MÉTODOS TRADICIONAIS E BASEADOS EM IA</b>	<b>53</b>
4.1 Objetivo e metodologia de avaliação	53
4.1.2 Critérios de comparação	53
4.1.3 Conjunto de estudos analisados	54
4.2 Desempenho dos métodos tradicionais de proteção diferencial	55
4.2.1 Proteção diferencial percentual com restrição harmônica	55
4.2.2 Métodos tradicionais avançados	57
4.2.3 Síntese qualitativa do desempenho dos métodos tradicionais	58
4.3 – Desempenho dos métodos baseados em IA	59
4.3.1 Redes Neurais Artificiais clássicas (ANN, PNN, modelos adaptativos)	60
4.3.2 Algoritmos de Deep Learning (CNN, LSTM, Autoencoders, modelos híbridos)	61
4.3.3 Comparações multiclasse e modelos alternativos	61
4.3.4 Síntese dos resultados obtidos pela IA	63
4.5 Discussão crítica e implicações práticas	64
4.5.1 Limitações e cuidados na interpretação dos resultados	64
4.5.2 Considerações sobre confiabilidade e requisitos normativos	65
4.5.3 Viabilidade de implementação em sistemas reais	65
a) Interoperabilidade com relés digitais	65
b) Dependência de sensores e TCs	65
c) Atualização contínua (learning lifecycle)	66
4.5.4 Implicações para smart grids e operação moderna	66
<b>5. CONCLUSÃO E TRABALHOS FUTUROS</b>	<b>67</b>
5.1 Síntese Geral do Trabalho	67
5.2 Principais Achados da Revisão	67
5.3 Avaliação Integrada dos Métodos Tradicionais e de IA	68
5.4 Conclusões Gerais	68
5.5 Limitações do Estudo	69
5.6 Trabalhos Futuros	69
<b>REFERÊNCIAS</b>	<b>71</b>

# 1. INTRODUÇÃO

O setor elétrico é a base que sustenta o desenvolvimento econômico e social da sociedade atual, sustentando desde operações domésticas até processos industriais críticos. Nesse contexto, os transformadores de potência desempenham papel essencial ao permitir a elevação ou redução de tensões em linhas de transmissão e redes de distribuição, garantindo eficiência energética, confiabilidade e estabilidade do sistema elétrico (Ugli et al. 2025). Falhas em transformadores de potência não apenas interrompem o fornecimento de energia, causando impactos econômicos, mas podem também provocar danos permanentes ao equipamento, exigindo reparos onerosos ou substituições.

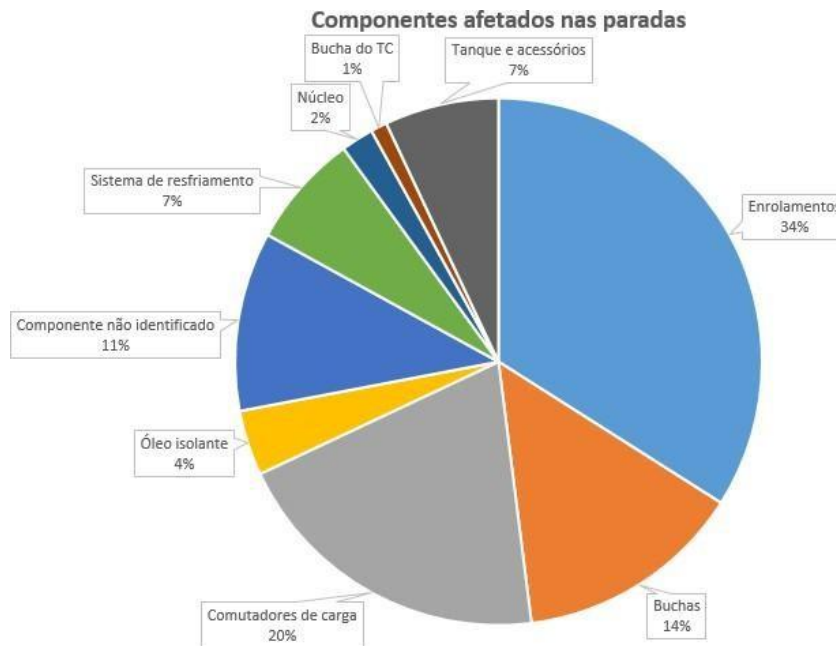
Diversas são as causas de falhas em transformadores de potência: surtos de manobra, descargas atmosféricas, degradação do isolamento devido à umidade, deformações mecânicas nos enrolamentos, ou condições elétricas adversas como curtos-circuitos. Esses fatores comprometem o núcleo magnético, os enrolamentos, as buchas e o óleo isolante, reduzindo a vida útil e a segurança operacional. Em específico, estudos apontam surtos de manobra e descargas atmosféricas como causas significativas de ruptura na isolação (Ugli et al. 2025).

No trabalho de Ribeiro et al. (2009) são analisadas falhas e defeitos em transformadores de potência imersos em óleo, com tensões entre 34,5 kV e 230 kV, pertencentes à concessionária CELG, no estado de Goiás. O levantamento, realizado ao longo de 28 anos (1979–2007), registrou 549 paradas, ou seja, impactaram no pleno funcionamento dos equipamentos. Desses registros, 75,2% das paradas foram classificadas como falhas inesperadas, enquanto 24,8% como defeitos. A análise evidenciou ainda os componentes mais afetados, conforme é visualizado na Gráfico 01. Ressalta-se que, o item indicado como “componentes não identificados” referem-se a elementos do transformador que não possuíam registros confiáveis para a devida associação.

Para mitigar os riscos, a danos nos componentes dos transformadores de potência, são aplicados sistemas de proteção elétrica, que monitoram correntes e tensões, detectam falhas e desligam o transformador quando necessário. Entre os métodos tradicionais, destacam-se a proteção diferencial, que compara correntes de entrada e saída para identificar faltas internas; o bloqueio por harmônicas, que evita disparos indevidos causados pela corrente de *inrush* durante a energização; e as lógicas temporizadas, utilizadas para coordenar a atuação da

proteção e evitar interferência entre relés (GERMANO,2008). Gráfico

### 01 - Componentes do transformador afetados



Fonte: (Ugli et al. 2025)

Recentemente, técnicas de Inteligência Artificial (IA), especialmente aprendizado de máquina (*Machine Learning*) e aprendizado profundo (*Deep Learning*), têm sido aplicadas para superar limitações da proteção diferencial tradicional. Abordagens que utilizam redes neurais convolucionais, redes recorrentes como *Long Short-Term Memory* (LSTM), redes *autoencoders*, e fusão de múltiplas características (por exemplo, análise de sinais, transformadas de *Wavelet*, sinais tempo-frequência), têm apresentado melhores resultados na detecção de falhas internas, na discriminação de fenômenos transitórios, como *inrush*, e na redução de falsos disparos. Exemplos recentes incluem algoritmos que dispensam valores pré-definidos, usando técnicas de *autoencoder* para distinguir automaticamente falhas internas durante correntes de *inrush* (Key et al, 2024), e modelos que associam conhecimento de especialista com aprendizado de rede neural para melhorar a generalização (Li & Jiao, 2021).

#### 1.1 Motivação

A motivação deste trabalho está associada à relevância dos transformadores de potência para a confiabilidade e a eficiência dos sistemas elétricos de transmissão e distribuição, uma vez que esses equipamentos desempenham papel fundamental na adequação dos níveis de

tensão ao longo da rede. Falhas em transformadores podem resultar em interrupções significativas no fornecimento de energia, impactos econômicos elevados e danos severos aos ativos.

Nesse contexto, técnicas de Inteligência Artificial existem como uma alternativa complementar aos métodos tradicionais, ao possibilitar a identificação de padrões complexos e não lineares nos sinais elétricos. Abordagens baseadas em aprendizado de máquina e *deep learning* podem reduzir significativamente o tempo de detecção de faltas e aumentar a confiabilidade da proteção.

Assim, justifica-se a realização deste trabalho, que busca avaliar criticamente o potencial da Inteligência Artificial aplicada à proteção diferencial de transformadores, contribuindo para o desenvolvimento de sistemas de proteção mais robustos e adaptados às exigências atuais do setor elétrico.

## 1.2 Objetivo Geral

Investigar e comparar os métodos tradicionais de proteção de transformadores com abordagens recentes baseadas em Inteligência Artificial, destacando os benefícios em termos de confiabilidade, seletividade, tempo de resposta e redução de falsos disparos, de modo a contribuir para a operação segura e eficiente do sistema elétrico.

## 1.3 Objetivos Específicos

- Apresentar os conceitos fundamentais de transformadores de potência, suas falhas típicas e os métodos tradicionais de proteção, incluindo a estrutura, princípios de operação e funções do relé diferencial de proteção e seus elementos auxiliares;
- Levantar e sintetizar pesquisas recentes que aplicam técnicas de IA para identificar falhas internas, diferenciar correntes transitórias de *inrush* e reduzir falsos alarmes;
- Avaliar e comparar o desempenho de métodos tradicionais e baseados em IA, considerando critérios como tempo de resposta, precisão, seletividade e robustez frente a fenômenos transitórios e condições adversas;
- Identificar os principais desafios técnicos na aplicação de IA em transformadores, incluindo generalização de modelos, disponibilidade de dados reais, variabilidade dos equipamentos e interferências elétricas.

## 1.4 Estrutura do Trabalho

O presente trabalho está organizado em 5 (cinco) seções principais, conforme descrito a seguir:

- Capítulo 01 - Introdução: Apresenta a contextualização do setor elétrico e a importância estratégica dos transformadores de potência. Define a problemática das falhas nesses equipamentos, a motivação para o uso de novas tecnologias, bem como os objetivos gerais, específicos e a metodologia exploratória adotada;
- Capítulo 02 - Fundamentação Teórica: Reúne os conceitos essenciais para a compreensão do tema, abordando o funcionamento eletromagnético e construtivo dos transformadores. Detalha os métodos tradicionais de proteção, como os relés diferenciais e de sobrecorrente, além de introduzir os paradigmas da Inteligência Artificial, incluindo Aprendizado de Máquina (*Machine Learning*), Aprendizado Profundo (*Deep Learning*) e sistemas *neuro-fuzzy*;
- Capítulo 03 - Estado da Arte: Realiza uma revisão das pesquisas recentes sobre a aplicação de IA na proteção de transformadores. Foca na utilização de arquiteturas modernas como CNN, LSTM e *Autoencoders* para superar as limitações dos métodos tradicionais, discutindo os benefícios relatados na literatura quanto ao tempo de resposta e seletividade;
- Capítulo 04 - Avaliação dos Métodos Tradicionais e Baseados em IA: Promove uma análise crítica e comparativa do desempenho operacional de ambos os métodos. Avalia critérios como acurácia, robustez frente à saturação de TCs e correntes de *inrush*, além de discutir a viabilidade de implementação prática e as implicações para o cenário de *smart grids*;
- Capítulo 05 - Conclusão e Trabalhos Futuros: Sintetiza os principais achados da revisão, reafirmando a IA como uma evolução complementar à proteção convencional. Apresenta as limitações deste estudo e propõe diretrizes para pesquisas futuras, como o desenvolvimento de bases de dados reais e esquemas híbridos de proteção.

## 1.5 Metodologia

A metodologia adotada para este trabalho é de natureza exploratória e comparativa, fundamentada em pesquisa bibliográfica e análise técnica de métodos de proteção de transformadores tradicionais, sem a utilização de Inteligência Artificial (IA), e com o uso de IA. O desenvolvimento será realizado conforme as seguintes etapas:

- Estudo teórico das proteções tradicionais de transformadores
  - Revisão dos principais modos de falha em transformadores de potência;
  - Análise dos métodos tradicionais de proteção diferencial e elementos auxiliares;
  - Descrição da arquitetura, lógica de atuação e parâmetros configuráveis do relé diferencial.
  
- Levantamento de técnicas de IA aplicadas à proteção de transformadores
  - Avaliação de artigos recentes que aplicam elementos de IA na proteção de transformadores de potência, assim como as métricas adotadas nos estudos.
  
- Análise comparativa entre métodos tradicionais e técnicas baseadas em IA
  - Comparação das capacidades de detecção de falhas internas durante correntes de *inrush*;
  - Discussão sobre as características de atuação do relé, com ênfase em seletividade e confiabilidade;
  - Levantamento das melhorias e limitações apresentadas por modelos inteligentes sob condições reais de operação.
  
- Identificação de desafios
  - Avaliação de aspectos como disponibilidade de dados reais, generalização entre equipamentos, comportamentos em transitórios e segurança cibernética;
  - Proposição de perspectivas de evolução para relés inteligentes e automação de subestações.


## 2. FUNDAMENTAÇÃO TEÓRICA

A compreensão dos princípios de funcionamento dos transformadores de potência e das técnicas empregadas em sua proteção é fundamental para a análise de sistemas elétricos de potência. Nesse contexto, são abordados os aspectos construtivos e eletromagnéticos desses equipamentos e os métodos tradicionais de proteção.

### 2.1. Conceitos de transformador de potência

Os transformadores de potência, ilustrados na Figura 01, são dispositivos eletromagnéticos baseados no princípio da indução, cuja função é a transferência de energia elétrica entre circuitos com diferentes níveis de tensão, mantendo a mesma frequência (Ugli et al., 2025). Seu funcionamento baseia-se no princípio da indução eletromagnética, em que a aplicação de tensão em um enrolamento (primário) gera um fluxo magnético que induz uma tensão correspondente em outro enrolamento (secundário) (PAULINO, 2011).

Figura 01 - Representação do transformador




Fonte: Mundo da Elétrica, s.d

Os transformadores podem ser classificados segundo diversos critérios construtivos e operacionais. Um dos parâmetros mais utilizados é o número de fases, o qual determina a forma como a energia elétrica é transferida entre os enrolamentos. Nesse contexto, a literatura estabelece três categorias principais: transformadores monofásicos, trifásicos e multifásicos (KUMAR; SAHU, 2020).

- Transformadores monofásicos

Os transformadores monofásicos, Figura 02, são projetados para operar com entrada e saída em corrente alternada monofásica. Nessa configuração, o equipamento possui um enrolamento primário, com  $N_1$  espiras, e um enrolamento secundário, com  $N_2$  espiras, ambos instalados sobre um núcleo magnético comum. A função do dispositivo é elevar ou reduzir o nível de tensão entre os dois enrolamentos. Esses transformadores são amplamente empregados em redes de distribuição residenciais, sistemas rurais e cargas individuais que não demandam alimentação trifásica.

Figura 02 - Representação do transformador monofásico



Fonte: (KUMAR; SAHU, 2020)

- Transformadores trifásicos

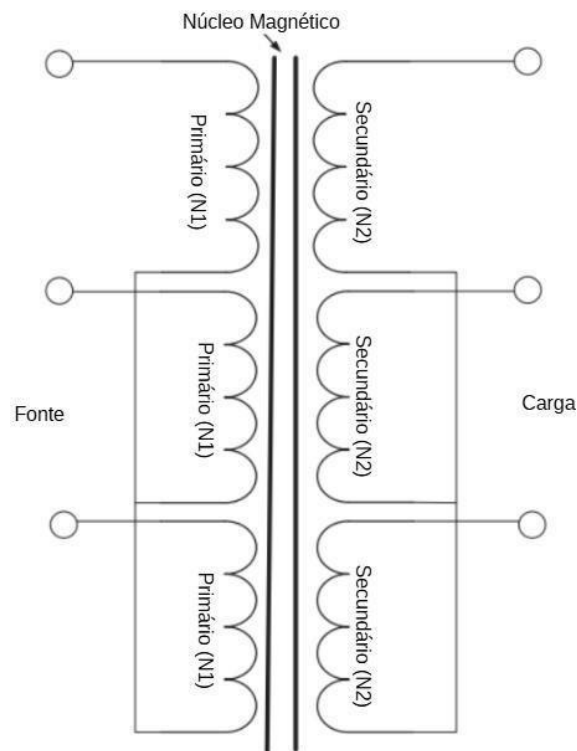
Os transformadores trifásicos, Figura 03, são constituídos por três enrolamentos primários e três enrolamentos secundários, correspondentes às fases do sistema elétrico. As conexões entre os enrolamentos podem assumir diversas configurações, conforme indicado no item 2.1.2, a depender dos requisitos do sistema. A literatura relata que transformadores trifásicos são largamente utilizados em sistemas de geração, transmissão e distribuição de energia elétrica, devido à sua adequação às redes trifásicas industriais e de grande porte (KUMAR; SAHU, 2020).

- Transformadores multifásicos

Além das formas convencionais, existem transformadores multifásicos, empregados em aplicações especiais, como testes de motores polifásicos e sistemas

experimentais. Tais equipamentos podem realizar conversões de três fases para cinco, seis ou até mais fases, sendo utilizados principalmente em contextos industriais específicos ou ambientes de pesquisa (KUMAR; SAHU, 2020).

Figura 03 - Representação do transformador trifásico



Fonte: (KUMAR; SAHU, 2020)

Em relação a parte construtiva, transformadores de potências podem ser divididos em duas categorias principais quanto ao meio isolante: transformadores imersos em líquido e transformadores do tipo seco.

- Transformadores imersos em líquido
  - Conforme a NBR 5356-1 (ABNT,2025), os transformadores imersos em líquido, Figura 04, são equipamentos cujo núcleo magnético e enrolamentos permanecem totalmente mergulhados em um meio isolante líquido, geralmente óleo mineral, óleo vegetal ou outro tipo de líquido isolante. Esse meio exerce funções essenciais para o desempenho do equipamento: prover isolamento elétrico entre componentes energizados, garantir rigidez dielétrica adequada e atuar como meio de transferência térmica, permitindo a dissipação eficiente do

calor gerado nas perdas internas do transformador.

- Transformador do tipo seco
  - A NBR 5356-11 (ABNT, 2025) classifica transformadores do tipo seco, Figura 05, como equipamentos cujo circuito magnético e enrolamentos não são imersos em líquido isolante. Nessas unidades, o isolamento é realizado por materiais sólidos, como resina epóxi, fibra de vidro, papel especial ou sistemas de encapsulamento. Além disso, o resfriamento ocorre predominantemente por circulação natural ou forçada de ar. A ausência de líquido isolante reduz o risco associado a inflamabilidade e vazamentos, tornando esses transformadores adequados para instalações internas, ambientes restritos e locais com requisitos elevados de segurança contra incêndio.

Figura 04 - Transformador trifásico imerso em óleo isolante



Fonte: BECHARA, 2010

Dessa forma, este trabalho delimita seu escopo aos transformadores trifásicos imersos em líquido, uma vez que representam não apenas o tipo predominante em subestações de média e alta tensão, mas também o foco central das pesquisas contemporâneas que aplicam

Inteligência Artificial (IA) à proteção de transformadores (GUERRA, 1992; AFRASIABI et al., 2023).

Figura 05 - Transformador trifásico tipo seco



Fonte: (WEG,2025)

### 2.1.1 Núcleo Magnético


O núcleo magnético do transformador direciona o fluxo magnético entre os enrolamentos e minimiza as perdas de energia. Ele é geralmente construído com ligas de ferro-silício laminadas, que podem ser orientadas, Grãos Orientados (GO) ou não-orientadas (GNO), de acordo com a aplicação e o custo envolvido.

- GO: possuem domínios magnéticos alinhados em um sentido preferencial, reduzindo perdas quando o fluxo magnético segue uma direção fixa. São aplicados em transformadores de alta potência, típicos em sistemas de transmissão e distribuição (Winders, 2002);
- GNO: apresentam propriedades magnéticas mais uniformes em todas as direções, sendo adequados para equipamentos de menor porte e aplicações industriais (Winders, 2002).

Além da escolha do material, a geometria do núcleo é um fator relevante. Os transformadores podem ser classificados quanto à construção do núcleo, em dois arranjos: *core-type* (núcleo envolvido) e *shell-type* (núcleo envolvente).

- Núcleo envolvido: Os enrolamentos são montados nos pilares externos, Figura 06, ficando mais expostos e facilitando procedimentos de inspeção e manutenção. Nesse arranjo, cada fase do transformador trifásico possui seus enrolamentos primário e secundário posicionados no mesmo pilar. Esse núcleo constitui o modelo mais utilizado, principalmente por oferecer simplicidade construtiva e maior facilidade de transporte (PAULINO, 2011).


Figura 06 - Construção do transformador trifásico com núcleo envolvido



Fonte: (KUMAR; SAHU, 2020)

- Núcleo envolvente: os enrolamentos são instalados no pilar central, Figura 07, circundados pelo núcleo, o que dificulta o acesso físico, mas reduz a reatância de dispersão e melhora a regulação de tensão. Essa configuração é utilizada quando se busca melhor controle de fluxos dispersos ou maior robustez mecânica.

Figura 07 - Construção do transformador trifásico com núcleo envolvente



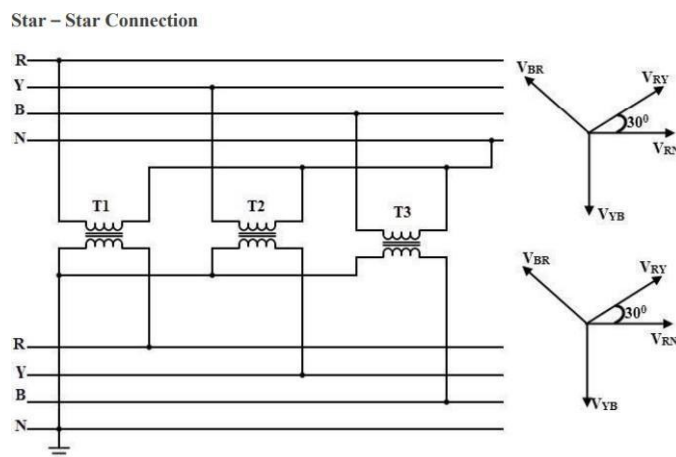
Fonte: (KUMAR; SAHU, 2020)

### 2.1.2 Enrolamentos

Os enrolamentos do transformador são condutores elétricos isolados entre si e em relação ao núcleo. Eles são responsáveis por receber a energia no primário e entregá-la no secundário. A conexão dos enrolamentos pode ocorrer em diferentes configurações:

- Estrela (Y): adequada para balanceamento de cargas trifásicas, mantendo tensão equilibrada entre fases, conforme Figura 08;

Figura 08 - Representação da conexão em Estrela entre 2 (dois) transformadores



Fonte: (ALKADHIM,2020)


- Delta ( $\Delta$ ): comum em transformadores monofásicos, permitindo circulação de correntes de desequilíbrio, conforme Figura 09;
- Zigue-Zague: usada para compensar desequilíbrios e criar pontos neutros artificiais em sistemas trifásicos (LEÃO, 2012), conforme Figura 10.

Além dessas, transformadores trifásicos podem empregar combinações entre primário e secundário, tais como:

- Y- $\Delta$  (estrela-delta) - O enrolamento em estrela, aterrado, é associado ao lado da rede, ou seja, geração ou transmissão, enquanto que o enrolamento em delta alimenta a carga. Essa configuração limita a propagação de harmônicas e reduz desequilíbrios. (Winders, 2002);


- $\Delta$ -Y (delta-estrela) - O enrolamento em delta, neste caso, é associado ao lado da rede, ou seja, geração ou transmissão, enquanto o enrolamento em estrela, aterrado, atende ao lado da carga. Essa configuração permite a circulação interna de harmônicas de sequência zero no delta e promove o isolamento das correntes de falta à terra entre os dois lados, sendo amplamente utilizada na conexão de geradores aos sistemas de transmissão. (Winders, 2002).

Figura 09 - Representação da conexão Delta entre 2 (dois) transformadores



Fonte: (ALKADHIM,2020)

Figura 10 - Representação de sistema trifásico com transformadores em conexão Delta e utilização de transformador em zigue-zague para criação de neutro artificial e aterramento



Fonte: (COSTA, 2015)

Essas combinações,  $Y-\Delta$  e  $\Delta-Y$ , determinam também o defasamento angular entre tensões primárias e secundárias, frequentemente de  $30^\circ$  (KUMAR; SAHU, 2020).

A escolha da configuração depende diretamente dos requisitos do sistema, tais como: nível de tensão, tipo de carga, presença de harmônicas, necessidade de neutro, comportamento frente a faltas e requisitos de regulação de tensão.

Conexões do tipo  $Y-\Delta$  são preferidas em aplicações de alta potência devido à facilidade de aterramento do lado estrela. Já conexões  $\Delta-Y$  são amplamente utilizadas em transformadores elevadores e abaixadores devido ao defasamento natural de  $30^\circ$  e à capacidade de reduzir efeitos de desequilíbrios de corrente (KUMAR; SAHU, 2020). Assim, a configuração escolhida impacta diretamente a eficiência, o fluxo de potência, a redução de perdas, e a confiabilidade do sistema elétrico como um todo.

### **2.1.3 Sistema de Isolamento**

O sistema de isolamento protege os enrolamentos e garante a segurança do transformador. Normalmente, ele é composto por papel celulose, que envolve os condutores, e óleo mineral, que atua como meio dielétrico e auxilia na dissipação de calor.

O desgaste do papel ou a degradação do óleo isolante comprometem a capacidade dielétrica do equipamento, aumentando o risco de falhas. Fatores como oxidação, presença de umidade e calor aceleram esse processo, tornando o monitoramento do isolamento essencial para a manutenção preventiva (PINTO; XAVIER, 2007; BAGATTOLI, 2005).

Além de atuar como meio dielétrico, o óleo isolante também funciona como um indicador das condições internas do transformador (SILVEIRA et al., 2021). Sempre que ocorre uma falha, como curto-circuitos internos, descargas parciais ou aquecimento localizado, o óleo sofre alterações físico-químicas, produzindo gases e subprodutos específicos da degradação térmica e elétrica. A magnitude e o tipo dessas substâncias (como hidrogênio, metano, etano, etileno ou acetileno) refletem o tipo de esforço elétrico ocorrido, permitindo a identificação da natureza da falha e sua gravidade por meio de ensaios laboratoriais, em especial a Cromatografia Gasosa de Gases Dissolvidos (DGA).

Dessa forma, a evolução da composição do óleo fornece um meio, não intrusivo, de monitoramento da saúde do transformador, sendo amplamente utilizada em estratégias de manutenção preditiva e determinação do estágio de envelhecimento do sistema de isolamento.

### 2.1.4 Componentes Auxiliares

Além do núcleo e dos enrolamentos, transformadores de potência incluem componentes auxiliares que monitoram o estado do equipamento e aumentam a segurança:

- **Buchas:** São responsáveis por conduzir a corrente elétrica dos enrolamentos para o meio externo, garantindo o isolamento elétrico em relação ao tanque metálico. Defeitos nesse componente podem ocasionar falhas severas, como incêndios ou explosões, comprometendo a integridade do transformador e do sistema elétrico associado (SILVEIRA et al., 2021);
- **Relé Buchholz:** Dispositivo de proteção utilizado em transformadores equipados com conservador de óleo, destinado à detecção de gases provenientes de falhas internas e ao monitoramento de deslocamentos súbitos do óleo isolante. A formação gradual de gases resulta em seu acúmulo na câmara do relé, acionando um alarme ao atingir determinado volume. Em situações de curto-circuito interno, o fluxo abrupto de óleo entre o tanque principal e o conservador aciona o mecanismo de desligamento, protegendo o equipamento contra danos mais severos. Adicionalmente, variações anormais no nível de óleo, decorrentes de vazamentos, também podem ser identificadas por esse dispositivo (PAULINO, 2011);
- **Conservador de óleo e radiadores:** O conservador de óleo tem a função de acomodar a expansão volumétrica do fluido isolante decorrente do aquecimento durante a operação, além de reduzir o contato direto do óleo com o ar, minimizando processos de oxidação e degradação. Os radiadores são responsáveis pela dissipação do calor gerado internamente, favorecendo a circulação natural ou forçada do óleo e mantendo a temperatura do transformador dentro de limites operacionais adequados (HADDAD, 2006; WEG, 2010).
- **Sensores de temperatura:** São utilizados para o monitoramento contínuo da temperatura do óleo e dos enrolamentos. Esses sensores permitem o acionamento automático de sistemas de ventilação ou o desligamento do transformador quando valores críticos são atingidos, prevenindo danos térmicos aos materiais isolantes e aos enrolamentos (FRANCISQUINI, 2006).
- **Tanque:** Atua como invólucro do núcleo e dos enrolamentos, além de servir como reservatório do óleo isolante. O tanque deve garantir vedação adequada para evitar a contaminação do fluido e suportar as variações de pressão decorrentes da expansão

térmica. Para aumentar a segurança, é equipado com válvulas de alívio de pressão, que possibilitam a liberação controlada de gases ou óleo em condições anormais de operação (SILVEIRA et al., 2021).

## **2.2. Proteções de Transformadores**

Os transformadores são equipamentos de alto valor econômico e estratégico no sistema elétrico. Quando ocorre uma falha interna, como um curto-circuito entre espiras ou entre o enrolamento e o núcleo, a energia envolvida pode ser tão elevada que a degradação do equipamento se torna irreversível em poucos milissegundos. Por isso, sistemas de proteção específicos foram desenvolvidos para detectar anomalias rapidamente e isolar o transformador antes que o dano se torne catastrófico.

O processo de isolamento só é possível graças à atuação dos relés de proteção, responsáveis por supervisionar o comportamento elétrico do transformador e disparar os mecanismos de desligamento quando detectam desvios significativos.

### **2.2.1. Tipos de Relé**

A proteção de sistemas elétricos de potência é realizada por meio de dispositivos denominados relés, responsáveis por monitorar grandezas elétricas e comandar a operação dos equipamentos de manobra quando são detectadas condições anormais.


O relé é um dispositivo que atua em resposta a variações nas condições elétricas do circuito ao qual está associado (GERMANO, 2008). A função essencial desses equipamentos é identificar, classificar e sinalizar falhas, permitindo a atuação do sistema de proteção e o seccionamento do defeito, preservando a integridade da instalação.

Do ponto de vista construtivo e funcional, os relés podem ser classificados em três categorias principais: relés eletromecânicos, relés estáticos e relés digitais ou numéricos (GERMANO, 2008).

- **Relés eletromecânicos:** considerados a tecnologia tradicional, Figura 11, operam por meio de acoplamentos magnéticos e movimentação mecânica de armaduras e contatos. Sua atuação baseia-se nos princípios de atração ou indução eletromagnética, permitindo o fechamento ou abertura de contatos conforme a corrente induzida nos enrolamentos (MASON, 1956). Apesar de robustos, apresentam limitações de velocidade, desgaste

mecânico e necessidade de manutenção periódica.

Figura 11 - Representação de relé eletromecânico



Fonte: (KINDERMANN,2005)

- Relés estáticos: utilizam componentes eletrônicos no lugar dos elementos móveis, como tiristores e acopladores ópticos. A ausência de partes mecânicas confere maior rapidez de operação, maior confiabilidade e menor exigência de manutenção. Todavia, esses dispositivos podem ser mais sensíveis a harmônicos e transitórios, demandando o uso de filtros adequados para evitar atuações indevidas (KINDERMANN, 2005).
- Relés digitais: ou numéricos, incorporam microprocessadores dedicados à proteção, medição, supervisão e controle de sistemas elétricos. Nesses dispositivos, todas as funções de proteção são implementadas por software, o que permite elevada flexibilidade no ajuste, integração com sistemas de automação, funções de autodiagnóstico e armazenamento de dados de perturbação. Os relés digitais representam o estado da arte da proteção de sistemas elétricos e constituem o padrão utilizado em novas subestações e transformadores de potência (ALMEIDA, 2000; KINDERMANN, 1999).

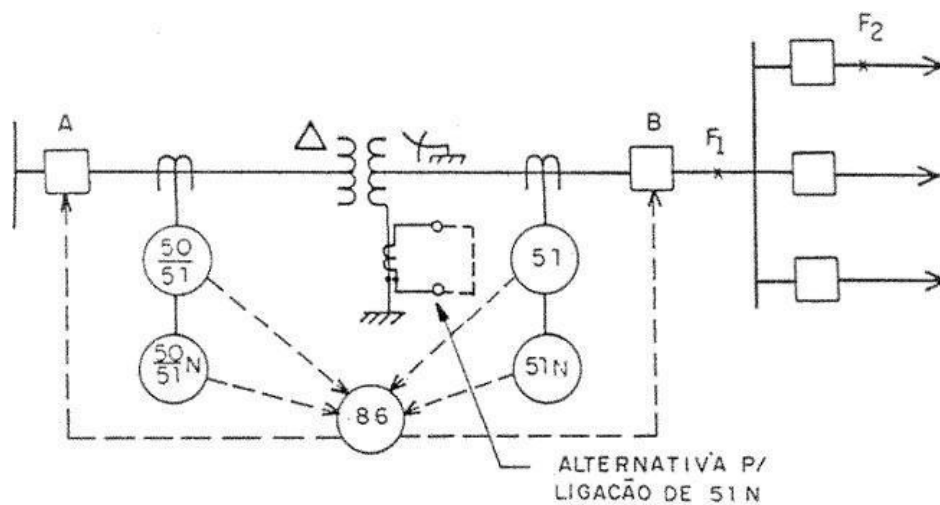
A utilização de técnicas de Inteligência Artificial em sistemas de proteção está diretamente associada ao emprego de relés digitais ou numéricos, pois esses equipamentos dispõem de recursos computacionais adequados para executar algoritmos avançados, como

redes neurais e métodos de aprendizado de máquina. Além disso, esses relés permitem a aquisição, o processamento e o armazenamento das grandezas elétricas de forma digital e em tempo real, o que torna viável a análise de padrões complexos e a tomada de decisão no contexto da proteção de sistemas elétricos de potência.

### 2.2.2. Relé de Sobrecorrente

O relé de sobrecorrente é um dispositivo que atua quando a corrente medida ultrapassa um valor previamente ajustado, podendo operar de forma instantânea ou temporizada, conforme a intensidade e a duração da anomalia no sistema elétrico. Esses relés são amplamente empregados nas funções de proteção primária, proteção de retaguarda e proteção de carcaça de transformadores de potência, Figura 12 (GERMANO, 2008).

Figura 12 - Proteção de transformadores por relés de sobrecorrente



Fonte: (GUERRA, 1992)

Em transformadores de baixa potência — tipicamente abaixo de 5 MVA — o relé de sobrecorrente pode atuar como proteção principal, uma vez que a implementação da proteção diferencial pode ser economicamente inviável nessas unidades. Entretanto, relés de sobrecorrente apresentam, em geral, menor sensibilidade, menor seletividade e maior tempo de atuação quando comparados aos relés diferenciais, sendo mais adequados a situações em que o impacto das faltas internas é menos crítico (MASON, 1956).

Nos transformadores de maior porte, os relés de sobrecorrente são empregados principalmente como proteção de retaguarda da proteção diferencial, item 2.2.4. Nessa função,

a atuação ocorre apenas se o relé diferencial falhar, estiver indisponível ou em manutenção. Para garantir seletividade, os tempos de atuação dos relés de sobrecorrente devem ser ajustados de maneira a evitar operação indevida durante faltas externas ou correntes transitórias de magnetização (*inrush*), comuns durante a energização do transformador (KINDERMANN, 1999).

### **2.2.3. Relé Diferencial**

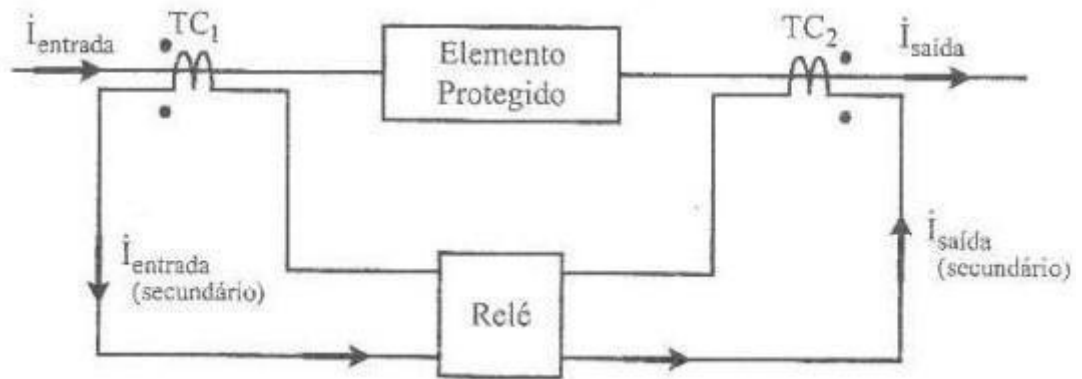
O relé diferencial é um dispositivo de proteção que compara grandezas elétricas de duas ou mais regiões de um mesmo circuito, operando quando a diferença fasorial entre essas grandezas excede um valor previamente ajustado. Esse tipo de relé é amplamente empregado na proteção de transformadores de potência de médio e grande porte, sendo economicamente recomendado para unidades com potência igual ou superior a 5 MVA (GUERRA, 1992). Em termos construtivos, os relés diferenciais dividem-se em duas categorias principais: relé diferencial amperimétrico e relé diferencial percentual (GERMANO, 2008).

#### **2.2.3.1 Relé diferencial amperimétrico**

O relé diferencial amperimétrico tem funcionamento baseado na comparação direta entre os fasores de corrente medidos nos lados primário e secundário da zona protegida. Nesse arranjo, os transformadores de corrente (TCs) são conectados de forma que a bobina do relé receba a diferença vetorial entre as correntes de entrada e saída, Figura 13. Sob condições normais de operação, ou quando ocorre um defeito externo à zona protegida, as correntes secundárias dos TCs são aproximadamente iguais e a corrente diferencial é desprezível, não havendo atuação do relé.

Entretanto, para defeitos internos, o sentido da corrente em um dos TCs se inverte, resultando em uma soma fasorial das correntes secundárias e promovendo a atuação imediata do relé (CAMINHA, 1977). Apesar de eficiente, este esquema apresenta limitações significativas, sobretudo em condições de faltas externas próximas aos TCs, onde erros de medição, saturação dos núcleos dos TCs, componentes contínuas de corrente e efeitos de magnetização inicial do transformador podem produzir correntes diferenciais não desejadas (KINDERMANN, 2007). Tais limitações justificam o desenvolvimento de métodos mais seletivos.

Figura 13 - Relé diferencial amperimétrico - proteção diferencial

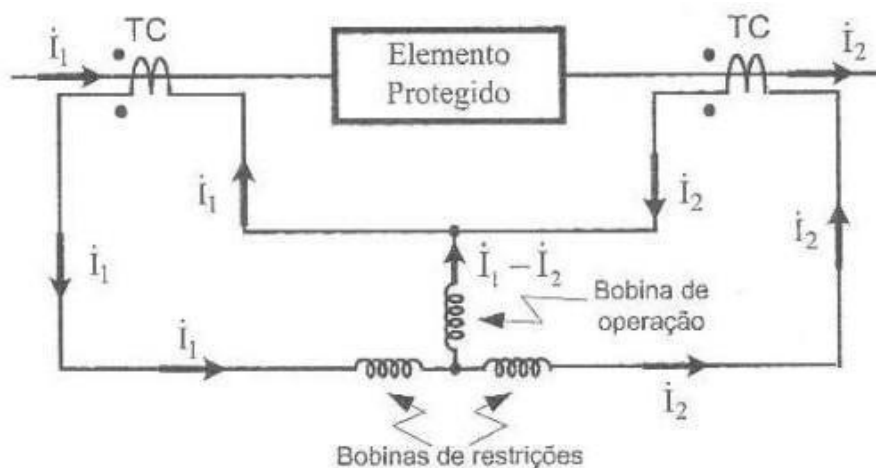


Fonte: (KINDERMANN, 2006)

### 2.2.3.2. Relé diferencial percentual

O relé diferencial percentual, Figura 08, constitui uma evolução do relé amperimétrico, incorporando mecanismos para evitar atuações indevidas durante faltas externas. Sua estrutura clássica utiliza duas bobinas: a bobina de operação, responsável por gerar o torque que aciona o relé, e a bobina de restrição, que produz torque oposto e impede a atuação quando a diferença entre as correntes é proporcionalmente pequena. Durante condições normais ou faltas externas, as correntes dos TCs são aproximadamente iguais, gerando um torque restritivo elevado e mantendo o relé desenergizado.

Figura 14 - Relé diferencial percentual



Fonte: (KINDERMANN, 2006)

Na ocorrência de um defeito interno, a mudança de direção de corrente em um dos lados

anula o torque da bobina de restrição e aumenta o torque da bobina de operação, garantindo a atuação do relé de maneira mais seletiva que o relé amperimétrico (GUERRA, 1992). Sua característica de operação é descrita por uma curva percentual que define o limite entre as regiões de operação e não operação, com declividade (*slope*) tipicamente entre 10% e 45% para transformadores de potência (KINDERMANN, 2006).

#### **2.2.4 Proteção Diferencial**

A proteção diferencial é o método mais seletivo e eficaz para a detecção de faltas internas em transformadores de potência. Seu princípio baseia-se na comparação fasorial entre as correntes que entram e saem da zona protegida; em condições normais, essas correntes são equivalentes (ajustadas pela relação de transformação), enquanto em falhas internas surge uma diferença significativa.

Entretanto, para que essa comparação seja coerente e confiável, é necessário considerar características construtivas do transformador que afetam diretamente as grandezas medidas, tais como o tipo de ligação dos enrolamentos, o deslocamento angular entre correntes, a saturação dos transformadores de corrente e os fenômenos transitórios associados à energização. Dessa forma, a correta aplicação da proteção diferencial exige a adoção de técnicas complementares, conforme as subseções a seguir.

##### **2.2.4.1. Compensação das Conexões do Transformador ( $\Delta$ -Y)**

Transformadores trifásicos com ligação delta-estrela, Figura 14, apresentam um deslocamento angular de  $30^\circ$  entre as correntes dos dois lados do equipamento. Para que o relé compare grandezas equivalentes, é necessário inverter as conexões dos TCs em relação ao transformador (GUERRA, 1992): TCs no lado delta  $\rightarrow$  conectados em estrela e TCs no lado estrela  $\rightarrow$  conectados em delta.

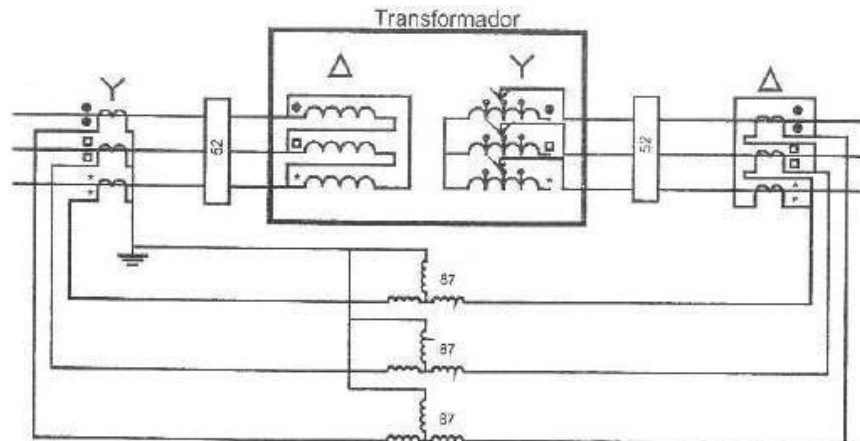
Essa conexão cruzada dos TCs é, portanto, essencial para compatibilizar os fasores antes da comparação pelo relé.

##### **2.2.4.2. Posicionamento do Relé Entre Duas Ligações Delta**

Uma regra prática recomenda que a zona diferencial deve estar “entre dois deltas”. Isso evita que correntes de sequência zero — presentes apenas em sistemas onde o neutro permite

retorno — circulem assimetricamente entre os lados, o que faria o relé comparar grandezas não equivalentes.

Figura 15 - Diagrama trifilar da conexão delta estrela



Fonte: (Kindermann, 2006)

#### 2.2.4.3. Ajuste das Relações de Transformação dos TCs

As relações de transformação dos TCs comerciais são normalizadas e não produzem correntes secundárias perfeitamente equivalentes. Essa discrepância pode gerar um “diferencial residual”, especialmente durante curtos externos de grande magnitude (Guerra, 1992). Essas diferenças são agravadas por: a saturação dos TCs, a componente contínua de curtos assimétricos, e o carregamento (Kindermann, 2006).

#### 2.2.5 Bloqueio por Harmônica

Durante a energização de um transformador, a corrente de *inrush* apresenta forte distorção harmônica devido ao regime forçado de magnetização do núcleo. Diferentemente de uma falta interna — que produz corrente essencialmente senoidal e dominada pela componente fundamental —, a *inrush* contém níveis elevados de segunda harmônica. Essa característica é amplamente utilizada pelos relés diferenciais para evitar atuações indevidas no momento da energização (Germano, 2008).


Nos relés eletromecânicos, o bloqueio por segunda harmônica é implementado por meio de uma Unidade de Restrição Harmônica (URH), um elemento auxiliar instalado em série com a unidade diferencial. A URH monitora a razão entre a componente de 2ª harmônica e a

componente fundamental da corrente diferencial.

O funcionamento, Figura 15, pode ser resumido da seguinte forma:

- Quando a corrente de 120 Hz (segunda harmônica) representa  $\leq 15\%$  da fundamental, a URH entende que a condição é compatível com um defeito interno ou operação normal, fecha seus contatos, e permite a energização.
- Durante a energização, a corrente de magnetização apresenta teor de segunda harmônica superior ao limiar, fazendo com que a URH mantenha seus contatos abertos, impedindo a atuação da proteção diferencial.

Figura 16 - Representação da proteção por bloqueio de harmônica (EDITAR CANVA)



Fonte: (KINDERMANN, 2008)

Relés digitais modernos utilizam técnicas complementares, como análise de terceira harmônica, janelas dinâmicas ou transformada de *Fourier* para melhorar a distinção entre *inrush* e faltas internas.

## 2.3 Introdução à Inteligência Artificial

A Inteligência Artificial (IA) pode ser entendida como o campo da ciência da computação voltado ao desenvolvimento de sistemas capazes de executar tarefas que, até pouco tempo, dependiam exclusivamente da inteligência humana, como reconhecimento de padrões, tomada de decisão, aprendizado a partir de experiências e adaptação a novos contextos (Russell; Norvig, 2016).

No setor elétrico, a IA vem ganhando destaque por permitir análises mais rápidas e precisas em ambientes de elevada complexidade, nos quais variáveis como corrente, tensão, temperatura, vibração e qualidade do óleo isolante interagem de forma dinâmica. Tradicionalmente, as proteções de transformadores dependem de modelos determinísticos, baseados em limiares fixos e regras pré-definidas. Embora confiáveis, esses métodos podem falhar diante de condições de operação não previstas, como transitórios atípicos ou envelhecimento de componentes.

A IA se apresenta como alternativa porque consegue aprender a partir de grandes volumes de dados históricos e de monitoramento *online*. Diferentes paradigmas podem ser aplicados.

### 2.4.1. Aprendizado de Máquina (*Machine Learning* — ML)

O *Machine Learning* (ML), ou aprendizado de máquina, constitui um dos pilares atuais da Inteligência Artificial e tem se destacado como abordagem dominante em aplicações industriais, científicas e comerciais. Sua relevância decorre da capacidade de extrair padrões a partir de dados e de realizar tarefas de decisão ou predição sem que o sistema seja explicitamente programado para cada situação (IRJET, 2019).

Historicamente, o campo emergiu na década de 1950, com trabalhos pioneiros como o programa de jogos autônomos desenvolvido por Arthur Samuel (IBM), seguido pela proposição do modelo de perceptron por Rosenblatt em 1957, considerado o primeiro modelo computacional inspirado em neurônios artificiais. Nas décadas seguintes, técnicas como nearest neighbor (1967) impulsionaram o reconhecimento de padrões, e a integração entre estatística e ciência da computação consolidou o aprendizado de máquina como área de pesquisa independente a partir dos anos 1990.

Em termos conceituais, os modelos de ML utilizam dados para ajustar parâmetros

internos capazes de representar relações entre variáveis. O processo envolve, de modo geral, duas etapas principais: treinamento, no qual o modelo aprende padrões a partir de um conjunto de dados rotulados ou não, e teste, no qual seu desempenho é avaliado em dados desconhecidos. A separação entre *training data* e *test data* é fundamental para medir a capacidade de generalização do modelo (IRJET, 2019).

A literatura classifica os algoritmos de aprendizado de máquina em três categorias principais: Aprendizado Supervisionado, Aprendizado Não Supervisionado e Aprendizado por Reforço.

#### 2.4.1.1. Aprendizado Supervisionado

O modelo aprende a partir de exemplos rotulados, nos quais cada entrada está associada a um alvo ou valor esperado. É amplamente utilizado em problemas de classificação e regressão. Entre seus métodos mais representativos destacam-se:

- *Support Vector Machines* (SVM): são algoritmos de aprendizado supervisionado baseados na Teoria da Aprendizagem Estatística (VAPNIK, 1999). Seu princípio fundamental consiste em construir um hiperplano ótimo que maximize a margem entre classes no espaço de características, garantindo boa capacidade de generalização. Para lidar com dados não linearmente separáveis, as SVM utilizam funções *kernel*, que realizam o mapeamento implícito dos dados para espaços de maior dimensão, permitindo a separação linear nesse novo domínio (HEARST, 1998; HAYKIN, 1999). As SVM destacam-se por serem robustas, eficientes e amplamente utilizadas em tarefas de classificação em diferentes áreas.
- *Análises discriminantes*: As análises discriminantes constituem um conjunto de métodos estatísticos voltados à classificação de dados a partir da identificação de padrões que separam grupos distintos. Essas técnicas buscam projetar os dados para um espaço de menor dimensão preservando a separabilidade entre as classes, o que reduz a complexidade computacional e mitiga problemas associados à alta dimensionalidade, como esparsidade e sobreajuste. Entre os métodos mais utilizados estão a:
  - *Linear Discriminant Analysis* (LDA), que busca combinações lineares de atributos capazes de maximizar a separação entre grupos;
  - *Quadratic Discriminant Analysis* (QDA), que permite fronteiras de decisão não

lineares ao considerar matrizes de covariância distintas por classe;

- Mixture Discriminant Analysis (MDA), que modela cada classe como combinação de distribuições gaussianas;
- Flexible Discriminant Analysis (FDA), que estende o modelo linear tradicional por meio de técnicas não lineares de regressão.

Esses métodos são amplamente empregados em pré-processamento, redução de dimensionalidade e tarefas de classificação supervisionada devido à sua boa interpretabilidade estatística e desempenho em dados estruturados (IRJET, 2019).

- Naïve Bayes: é um classificador probabilístico fundamentado no Teorema de Bayes, que estima a probabilidade de uma instância pertencer a determinada classe com base nas características observadas. Seu modelo assume independência condicional entre os atributos, o que simplifica os cálculos e permite alto desempenho mesmo em conjuntos de dados extensos ou de alta dimensionalidade. A partir dessas probabilidades, o algoritmo seleciona a classe mais provável para cada nova observação, sendo amplamente utilizado em tarefas de classificação supervisionada devido à sua eficiência e simplicidade de implementação.

#### 2.4.1.2 Aprendizado Não Supervisionado

O aprendizado não supervisionado, Figura 16, corresponde à classe de métodos de *machine learning* em que o modelo busca identificar estruturas, padrões ou agrupamentos em conjuntos de dados sem rótulos ou respostas previamente conhecidas. Nessa abordagem, o algoritmo aprende exclusivamente a partir das características presentes nos dados, extraindo relações internas que possam ser utilizadas posteriormente em tarefas de organização, segmentação ou redução da dimensionalidade (IRJET, 2019).

Entre as aplicações mais comuns estão *clustering* e redução de dimensionalidade, que permitem compreender a distribuição dos dados e simplificar sua representação.

Os principais algoritmos utilizados incluem *K-means clustering*, *Principal Component Analysis* (PCA), modelos hierárquicos, *Hidden Markov Models* e redes neurais em modo não supervisionado.

- *K-means clustering*: seu princípio consiste em dividir os dados em K grupos distintos, de modo que os elementos dentro de um mesmo conjunto apresentem maior

similaridade entre si do que em relação aos demais grupos. O método é baseado em centroides, ajustando iterativamente a posição desses pontos centrais até minimizar a variabilidade interna de cada *cluster*;

- *Principal Component Analysis* (PCA): é uma técnica clássica de redução de dimensionalidade, que transforma um conjunto de variáveis possivelmente correlacionadas em um novo conjunto de componentes principais, ordenados segundo a variância explicada. Essa transformação prioriza as características mais relevantes dos dados e descarta redundâncias, facilitando a visualização e o processamento de conjuntos de alta dimensionalidade;
- Redes Neurais em Modo Não Supervisionado: redes neurais também podem operar de forma não supervisionada. Nesse caso, a rede não recebe rótulos de saída e aprende a agrupar ou representar os dados com base em similaridades internas. Modelos como autoencoders e mapas auto-organizáveis são exemplos típicos, capazes de identificar padrões, reduzir dimensionalidade ou detectar estruturas latentes nos dados sem conhecimento prévio sobre as classes.

Figura 17 - Modelo de aprendizado não supervisionado



Fonte: (IRJET, 2019)

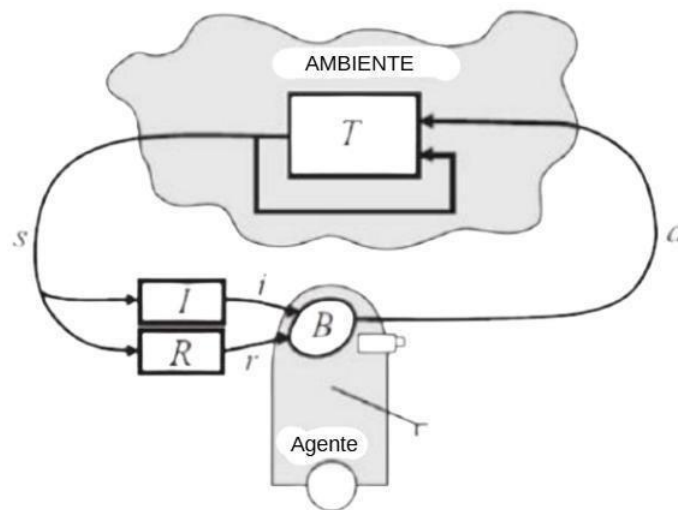
### 2.4.1.3. Aprendizado por Reforço

O aprendizado por reforço é uma abordagem em que o modelo aprende por meio da interação direta com um ambiente, Figura 10, recebendo recompensas ou penalidades conforme as ações tomadas. Diferentemente do aprendizado supervisionado — que depende de rótulos — e do não supervisionado — que identifica padrões ocultos —, o aprendizado por reforço baseia-se em um processo de tentativa e erro, no qual o agente busca maximizar recompensas cumulativas ao longo do tempo (SUTTON; BARTO, 2018).

Esse paradigma é amplamente aplicado em áreas como robótica, automação, jogos,

sistemas autônomos e navegação, onde o comportamento ótimo precisa ser aprendido progressivamente e ajustado dinamicamente. No processo de aprendizagem, o agente executa ações no ambiente, observa o novo estado e recebe um *feedback* avaliativo. Com isso, o modelo ajusta sua política de decisão, privilegiando ações que historicamente levaram a resultados mais favoráveis.

Figura 18 - Modelo de aprendizado por reforço



Fonte: (IRJET, 2019)

Em síntese, trata-se de um método que não possui conhecimento prévio sobre o objetivo final, mas desenvolve autonomamente estratégias para alcançá-lo, ajustando seu comportamento com base nas respostas fornecidas pelo ambiente.

#### 2.4.2. Aprendizado Profundo (*Deep Learning* — DL)

O aprendizado profundo (*Deep Learning* — DL) constitui um ramo avançado da Inteligência Artificial que evoluiu diretamente dos métodos tradicionais de aprendizado de máquina. Sua principal característica é o uso de redes neurais profundas, compostas por múltiplas camadas ocultas, capazes de aprender representações hierárquicas e progressivamente mais abstratas dos dados. Essa estrutura em camadas permite que o modelo capture relações complexas e não lineares, tornando o DL adequado para problemas complexos e para bases de dados volumosas e heterogêneas (Shrestha; Mahmood, 2019).

Ao contrário das abordagens clássicas de *Machine Learning*, que dependem fortemente

de etapas manuais de engenharia de atributos, o DL permite a extração automática de características relevantes diretamente de dados brutos. Essa capacidade decorre do fato de que cada camada da rede aprende uma função de transformação dos dados: as camadas iniciais extraem padrões simples — como variações básicas, tendências temporais ou bordas em imagens — enquanto as camadas mais profundas aprendem estruturas complexas, tais como relações temporais não lineares, dependências de longo prazo ou padrões espaciais de alta abstração. Esse aprendizado hierárquico reduz substancialmente a intervenção humana e favorece modelos mais robustos e generalizáveis.

O avanço e a disseminação do DL foram possibilitados por três fatores principais:

- A disponibilidade crescente de *big data*, essencial para treinar arquiteturas profundas;
- A evolução de *hardware* especializado, especialmente GPUs e TPUs, que aceleram o treinamento;
- O desenvolvimento de técnicas modernas de otimização e regularização, que tornam o treinamento mais estável e eficiente (Shrestha; Mahmood, 2019).

Modelos de DL têm se destacado em áreas como visão computacional, processamento de sinais, previsão de séries temporais e reconhecimento de padrões, alcançando desempenho frequentemente superior ao de técnicas tradicionais. Redes neurais convolucionais (CNNs), redes recorrentes (RNNs) e arquiteturas mais recentes, como *Transformers*, exemplificam o potencial do DL na modelagem de dados complexos.

Contudo, modelos profundos exigem recursos computacionais significativos, longos tempos de treinamento e grandes conjuntos de dados anotados. Além disso, por serem altamente parametrizados, tendem a apresentar menor interpretabilidade, o que pode dificultar a explicação das decisões tomadas — aspecto crítico em domínios sensíveis, como sistemas elétricos de potência. Outro ponto de atenção é o risco de *overfitting*, especialmente quando os dados disponíveis são insuficientes ou pouco representativos. Apesar dessas limitações, o DL permanece como uma das abordagens mais promissoras e eficazes da IA contemporânea, sobretudo em aplicações que exigem análise de padrões complexos, detecção de anomalias e modelagem avançada de fenômenos dinâmicos — características essenciais para estudos relacionados a sistemas elétricos e proteção de transformadores de potência.

### 2.4.3. Sistemas *Neuro-Fuzzy*

A lógica *fuzzy* estende a lógica clássica ao permitir graus contínuos de pertinência entre 0 e 1, possibilitando representar incertezas e termos linguísticos vagos de forma próxima ao raciocínio humano. Essa flexibilidade torna os sistemas *fuzzy* úteis quando o conhecimento disponível é impreciso, heurístico ou parcialmente subjetivo.

Os sistemas neuro-fuzzy integram essa capacidade de representação interpretável com o poder de aprendizado das redes neurais. Em sua forma mais conhecida, como *Adaptive Neuro-Fuzzy Inference System* (ANFIS), a rede ajusta automaticamente parâmetros das funções de pertinência e das regras *fuzzy* a partir de dados, combinando aprendizagem supervisionada, otimização e inferência baseada em regras. Assim, o modelo preserva a explicabilidade das regras *fuzzy* ao mesmo tempo em que incorpora generalização e adaptação.

Os sistemas *neuro-fuzzy* vêm sendo amplamente empregados em áreas como diagnóstico médico, previsão de séries temporais, controle industrial, processamento de imagens e sistemas elétricos, destacando-se por sua robustez em cenários com incertezas, ruído e não linearidades complexas (Kar et al, 2014).

A combinação entre regras interpretáveis e mecanismos de aprendizado torna essa abordagem especialmente vantajosa quando há necessidade simultânea de desempenho, transparência e incorporação de conhecimento especializado, características desejáveis em aplicações de proteção de sistemas elétricos.

## 3. ESTADO DA ARTE

O emprego de técnicas de Inteligência Artificial na proteção de transformadores de potência apresenta-se como uma alternativa aos métodos convencionais, especialmente frente a fenômenos transitórios. Essas abordagens exploram capacidades avançadas de processamento e análise de sinais, com o objetivo de aumentar a confiabilidade, a seletividade e a rapidez na identificação de faltas, motivando o desenvolvimento de diferentes estratégias e modelos aplicados a esse contexto.

### 3.1 Pesquisas recentes sobre IA na proteção de transformadores

Nos últimos anos, a aplicação de IA na proteção de transformadores de potência tem se intensificado, impulsionada pela necessidade de sistemas mais seletivos, rápidos e robustos diante de fenômenos complexos como correntes de *inrush*, saturação de transformadores de corrente (TCs), ruídos externos e condições dinâmicas de operação. Métodos tradicionais, como restrição harmônica e relés diferenciais percentuais, embora amplamente consolidados, apresentam limitações em situações não lineares e transitórias. Relés numéricos ainda se baseiam em comparações de grandezas pré-definidas, mantendo vulnerabilidades em condições adversas (GERMANO, 2008).

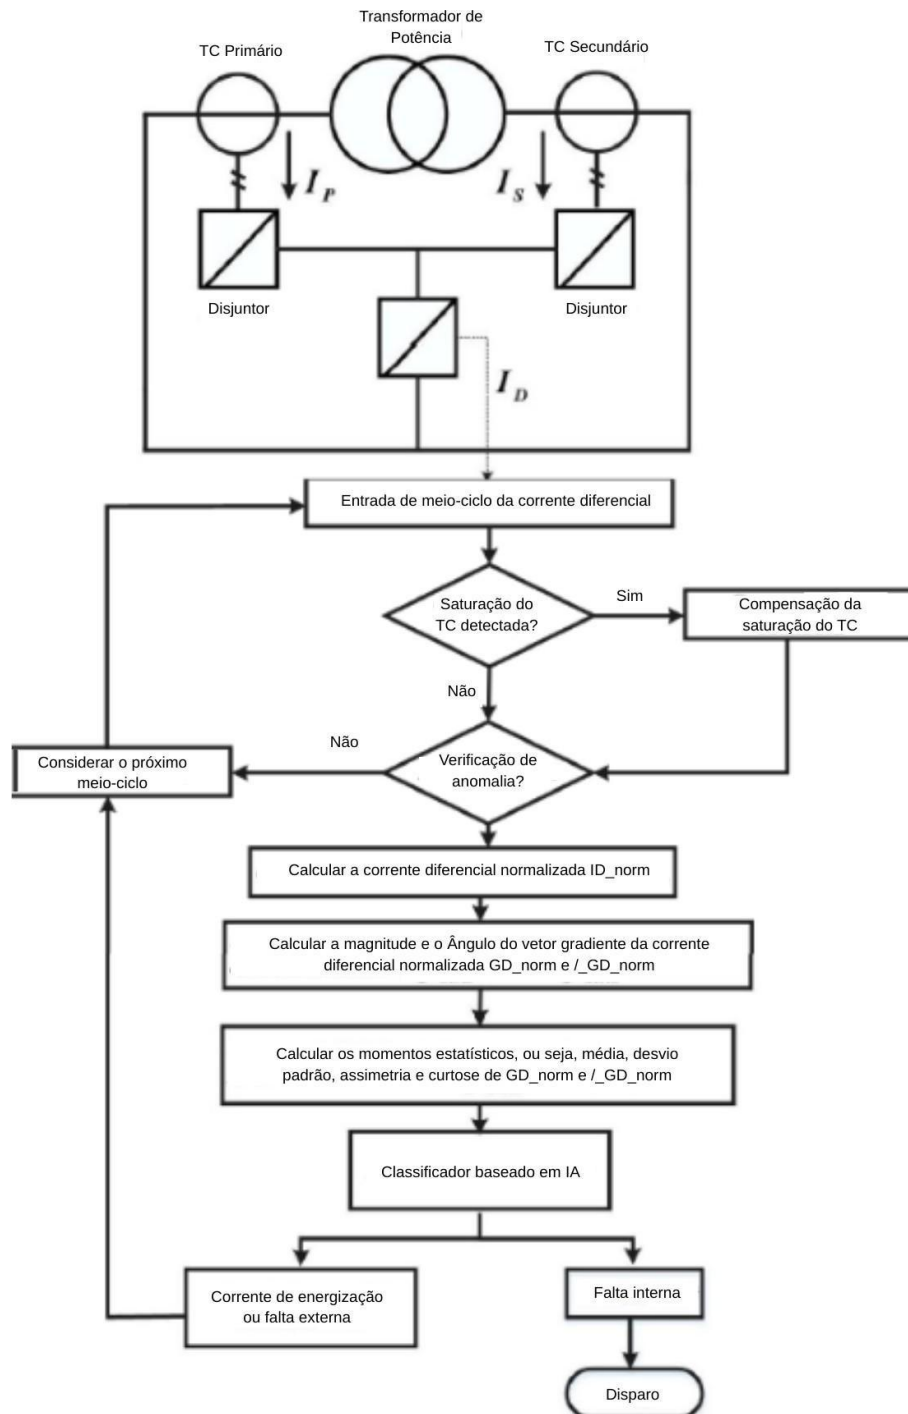
#### 3.1.1. Revisões e análises comparativas de IA para proteção diferencial

No trabalho de Afrasiabi et al. (2023), Figura 18, o estudo avaliou diferentes métodos — incluindo redes neurais, classificadores probabilísticos, técnicas híbridas e abordagens baseadas em reconhecimento de padrões — sob condições críticas, como saturação de TCs, presença de capacitores série e uso de limitadores supercondutores de corrente de falta (SFCL). A pesquisa demonstrou que abordagens baseadas em IA apresentam desempenho superior aos métodos convencionais ao distinguir *inrush* de faltas internas, principalmente pela capacidade de extrair características do sinal sem depender de parâmetros previamente ajustados.

Em Afrasiabi et al. (2023) sintetizam o princípio da proteção diferencial por meio de um critério geral de operação, expresso pela relação entre corrente diferencial e corrente de restrição. A lógica estabelece que uma condição anômala é identificada quando a corrente diferencial excede uma fração da corrente de restrição, definida pelo parâmetro SD, usualmente entre 15% e 40%, em função do tempo de resposta e filosofia do relé, conforme a Equação 01.

$$\frac{|I_p - I_s|}{I_p + I_s} \geq S_D \quad (1)$$

Figura 19 - Fluxograma de esquema de proteção baseado em proteção diferencial com IA



Fonte: (Afrasiabi et al. 2023)

Onde:

- $I_p$ : Corrente medida no primário;
- $I_s$ : Corrente medida no secundário.

O excedente do critério indica a ocorrência de uma das três possibilidades: *inrush*, falta interna ou falta externa severa.

Após identificar que uma condição anômala ocorreu, realiza-se a normalização da corrente diferencial ao longo de uma janela de meio ciclo. Essa normalização reduz a sensibilidade a variações de amplitude e facilita o uso dos sinais por classificadores inteligentes, conforme Equação 02.

$$I_{Dnorm}(k) = \frac{I_p(k) - I_s(k)}{\max(|I_p(k) - I_s(k)|)} \quad (2)$$

Onde:

- $I_{Dnorm}$ : Representa a corrente diferencial normalizada correspondente a fase na qual a anomalia foi identificada.

Essa etapa é fundamental, pois produz uma forma de onda adimensional e comparável, independente do nível de carregamento, facilitando operações posteriores de filtragem e extração de feições.

### 3.1.2 IA na proteção diferencial: classificadores neurais e otimização

Entre os primeiros métodos baseados em aprendizado de máquina, tem-se o uso da utilização de *Probabilistic Neural Network* (PNN) otimizada via *Particle Swarm Optimization* (PSO) (TRIPATHY; MAHESHWARI; VERMA, 2007). O classificador é alimentado por razões entre tensão e frequência e por amplitudes de corrente diferencial, dispensando análise harmônica convencional. No estudo de Tripathy, Maheshwari e Verma (2007), o desempenho do modelo proposto foi comparado ao de redes neurais tradicionais (FFBP), à PNN convencional e ao método clássico de restrição por segunda harmônica. A versão otimizada da PNN apresentou maior sensibilidade e precisão, sobretudo na detecção de falhas internas com pouca margem de separação entre padrões — evidenciando que técnicas probabilísticas podem superar limites impostos pelos relés diferenciais convencionais.

### 3.1.3 Arquiteturas de *Deep Learning*: CNN, *Autoencoders* e modelos híbridos

Em Li et al. (2023) introduz um *Denoising-Classification Neural Network* (DCNN) que combina um *autoencoder* convolucional (CAE) e uma rede neural convolucional (CNN) em um processo colaborativo. O CAE remove saturação e ruídos presentes na curva tensão de excitação versus corrente diferencial (*V-I curve*), enquanto a CNN utiliza a versão limpa do sinal para classificar entre falta interna e inrush. Os resultados mostraram grande redução na taxa de disparos indevidos, mesmo com dados escassos, ao focar nos trechos “não saturados” da curva — regiões que apresentam forte capacidade discriminante. Esse enfoque evidencia uma tendência recente: modelos que aprendem diretamente a estrutura física dos sinais, em vez de extrair apenas características pontuais.

Outro trabalho que se destaca é o de Abdulhasan et al. (2024), baseado em *stacked denoising autoencoders*. O método elimina a necessidade de limiares fixos e se ajusta automaticamente a diferentes condições operacionais, reforçando a tendência de sistemas autoadaptativos, que aprendem diretamente a partir das formas de onda.

### 3.1.4 Integração com relés numéricos e limitações dos métodos tradicionais

Os relés numéricos, amplamente utilizados desde os anos 1990, já incorporavam técnicas digitais avançadas, especialmente para filtragem de harmônicas e compensação de discrepâncias entre TCs (GERMANO, 2008; ZIEGLER, 2005). Esses equipamentos aumentaram significativamente a precisão da proteção diferencial e reduziram a incidência de atuações indevidas. Entretanto, mesmo com processadores modernos, relés digitais ainda se baseiam em lógica determinística — comparação de fasores, inclinação percentual e bloqueio harmônico — que permanece limitada em condições altamente não lineares (Kasztenny e Kezunovic, 1998).

Nesse contexto, a IA surge como evolução natural, permitindo:

- aprendizado automático de características relevantes;
- capacidade de generalização para cenários não vistos;
- maior robustez contra ruído e saturação, redução da dependência de parâmetros fixos e ajustes manuais;
- incorporação de informações completas da forma de onda.

## **3.2 Comparação entre métodos tradicionais e métodos baseados em Inteligência Artificial**

A comparação entre abordagens tradicionais e técnicas modernas baseadas em Inteligência Artificial (IA) evidencia diferenças fundamentais na forma como cada método interpreta, processa e classifica eventos transitórios e faltas internas no transformador. Para organizar essa análise, este tópico é dividido em quatro subtópicos: fundamentos dos métodos tradicionais, limitações estruturais desses métodos e princípios de funcionamento dos métodos baseados em IA.

### **3.2.1 Métodos tradicionais de proteção de transformadores**

As metodologias convencionais de proteção baseiam-se em critérios determinísticos e restrições pré-ajustadas, privilegiando segurança sob condições operativas normais. Entre as técnicas mais difundidas encontram-se a proteção percentual-diferencial, os esquemas de restrição ou bloqueio harmônico, além de abordagens complementares baseadas em análise de forma de onda, diferença de fase e compensação de TCs, conforme discutido em publicações clássicas da área (Guzman et al., 2005; Blackburn; Domin, 2015).

A proteção percentual-diferencial compara a corrente diferencial com uma corrente de restrição proporcional à carga, acionando quando a primeira excede um valor relacionado ao *slope* de operação, frequentemente complementado por características de dupla inclinação para lidar com assimetrias e saturação de TCs, segundo relatado em manuais e estudos técnicos da indústria.

Já os métodos de restrição harmônica utilizam o conteúdo de segunda harmônica da corrente de *inrush* como elemento-chave para evitar atuações indevidas, explorando a diferença espectral entre correntes de energização e correntes de falta interna, conforme amplamente discutido em estudos industriais e normas técnicas.

### **3.2.2 Limitações estruturais dos métodos tradicionais**

Embora amplamente utilizados, os métodos tradicionais apresentam limitações inerentes ao seu caráter determinístico e ao uso de parâmetros fixos, que não se ajustam automaticamente às condições reais de operação, além disso, verifica-se que:

- o *inrush* moderno pode apresentar baixo teor de segunda harmônica devido ao uso de

aços de núcleo de baixa histerese;

- a saturação de TCs distorce o sinal, reduzindo a eficácia dos critérios harmônicos;
- variações transitórias e condições altamente dinâmicas desafiam a seletividade dos algoritmos tradicionais;
- a necessidade de *retuning* após mudanças no sistema (*tap*, carga, chaveamentos) pode comprometer a eficiência da proteção.

### 3.2.3 Princípios dos métodos baseados em Inteligência Artificial

Os métodos baseados em Inteligência Artificial (IA) diferem significativamente das abordagens tradicionais ao empregarem algoritmos capazes de aprender padrões complexos dos sinais elétricos, em vez de dependerem de limiares fixos ou análises harmônicas. Estudos recentes demonstram que essas técnicas podem identificar anomalias mesmo sob condições adversas, como saturação de TCs, *inrush* com baixo conteúdo harmônico e ruídos transitórios. Diversas classes de modelos têm sido aplicadas à proteção de transformadores:

- Redes neurais convolucionais (CNNs), capazes de extrair automaticamente características relevantes das formas de onda, têm sido empregadas com sucesso para diferenciar *inrush* de faltas internas, conforme demonstrado em trabalhos que utilizam arquiteturas CAE–CNN e classificadores convolucionais otimizados (Li et al., 2022).
- Modelos híbridos, como CNNs combinadas com redes LSTM, têm apresentado alta precisão na detecção de faltas internas sob condições dinâmicas, explorando tanto componentes espectrais quanto dependências temporais, segundo estudos baseados em transformadores de grande porte (Atyiah; Karimi; Moradi, 2024).
- *Autoencoders* e *denoising autoencoders* (DAE) são utilizados para reconstruir sinais filtrando distorções causadas por saturação ou ruído, fornecendo características mais limpas para classificadores subsequentes, conforme relatado em pesquisas recentes que propõem arquiteturas empilhadas para proteção diferencial (Abdulhasan et al., 2024).
- *Probabilistic Neural Networks* (PNN), otimizadas por métodos como *Particle Swarm Optimization*, têm sido empregadas como classificadores rápidos e robustos para distinguir eventos transitórios de faltas internas, evitando dependência exclusiva de restrição harmônica (Tripathy; Maheshwari; Verma, 2007).
- Redes neurais multicamadas e modelos ANNs adaptativos, treinados com dados de *inrush* e faltas simulados, têm demonstrado capacidade de reduzir atuações indevidas em energizações e responder mais rapidamente que relés convencionais (Ahmad et al.,

2019).

Além disso, abordagens de IA empregam técnicas de extração automática de características, como gradiente da corrente diferencial, estatísticas de sinal e transformações no domínio da frequência ou tempo–frequência, permitindo reconstruir informações complexas sem regras manuais, como descrito em estudos comparativos recentes (Afrasiabi et al., 2023).

### **3.3 Benefícios Relatados na Literatura (tempo de detecção, seletividade, redução de falsos disparos)**

A literatura recente demonstra que tanto os métodos tradicionais aprimorados quanto, principalmente, as abordagens baseadas em Inteligência Artificial (IA) têm contribuído para avanços relevantes na proteção diferencial de transformadores. Entre os benefícios mais citados, destacam-se: redução do tempo de detecção, melhora da seletividade e redução de falsos disparos. Esses ganhos derivam, sobretudo, da capacidade das técnicas modernas de extrair múltiplas características do sinal e/ou reconhecer padrões complexos associados às condições de *inrush*, saturação de transformadores de corrente e faltas internas.

#### **3.3.1 Redução do tempo de detecção**

Estudos recentes têm demonstrado reduções expressivas no tempo necessário para que o sistema de proteção identifique uma condição anormal. Métodos tradicionais dependem, em grande parte, de estimativas harmônicas, as quais exigem frações significativas de um ciclo elétrico para assegurar medições estáveis, muitas vezes um ciclo completo ou mais.

Por outro lado, técnicas modernas baseadas em análise temporal rápida ou aprendizado profundo conseguem identificar padrões característicos de falta interna em intervalos muito inferiores, pois:

- utilizam janelas curtas de amostragem;
- extraem características instantâneas ou gradientes do sinal, e;
- reconhecem assinaturas típicas já aprendidas durante o treinamento.

Trabalhos recentes mostram que modelos baseados em *deep learning*, incluindo arquiteturas híbridas CNN–LSTM, conseguem classificar eventos em poucos milissegundos, mesmo sob condições de *inrush* ou saturação severa de TC, conforme observado em avaliações comparativas envolvendo transformadores de grande porte (Atiyah; Karimi; Moradi, 2024;

Abdulhasan et al., 2024). Outros estudos baseados em extração eficiente de características (*gradient vectors* e parâmetros estatísticos) também relatam janelas inferiores a meio ciclo, conforme discutido na literatura (Mohammadpour; Dashti; Shaker, 2020).

Assim, observa-se uma tendência clara: quanto mais o método aprende diretamente do sinal, menor o tempo necessário para tomar a decisão.

### 3.3.2 Melhora da seletividade

A seletividade consiste na capacidade do sistema de proteção isolar exclusivamente a zona onde ocorre a falta, evitando desligamentos desnecessários. Os métodos tradicionais apresentam desempenho satisfatório em grande parte das situações, mas podem ser impactados por:

- *inrush* com baixa componente harmônica;
- saturação assimétrica de TCs;
- ruídos externos ou transitórios dinâmicos;
- sobreexcitação e condições de fluxo remanescente.

A literatura indica que técnicas modernas, especialmente as fundamentadas em IA, apresentam seletividade superior, pois: analisam múltiplas características simultaneamente, ampliando o espaço de decisão; distinguem padrões sutis entre “*inrush* incomum” e “falta interna fraca” sem depender exclusivamente de harmônicos; operam mesmo em cenários onde o método harmônico tradicional perde confiabilidade.

Estudos empregando *Discrete Wavelet Transform*, análise da zona não saturada do VICUR (*Voltage-Inrush Characteristic Curve*), *autoencoders* convolucionais e classificadores recorrentes apontam ganhos consistentes na capacidade discriminatória (Li et al., 2022; Hatata et al., 2023). De modo geral, métodos híbridos combinando múltiplos critérios — por exemplo, *slope* diferencial + estatísticas + IA, apresentam desempenho significativamente superior ao uso isolado de um único critério.

### 3.3.3 Redução de falsos disparos

A diminuição de disparos indevidos é um benefício central apontado na literatura.

Métodos tradicionais, quando dependentes exclusivamente de restrição harmônica, podem:

- falhar em situações onde o inrush apresenta baixos níveis de harmônicos;
- atuar indevidamente sob saturação profunda de TCs;
- interpretar ruídos transitórios como indício de falta interna.

Os métodos baseados em IA têm apresentado reduções expressivas nas taxas de falso disparo, pois conseguem capturar padrões mais complexos do comportamento eletromagnético do transformador.

Estudos baseados em CNNs, CNN–LSTM e PNN otimizadas mostram taxas elevadas de acerto e redução significativa de operações indevidas em condições de energização e sobreexcitação. Testes conduzidos com dados simulados e experimentais indicam que modelos bem treinados são mais robustos a ruído e saturação do que os critérios harmônicos clássicos.

# 4. AVALIAÇÃO DOS MÉTODOS TRADICIONAIS E BASEADOS EM IA

## 4.1 Objetivo e metodologia de avaliação

Este capítulo tem como propósito avaliar, de forma crítica, o desempenho dos métodos tradicionais de proteção diferencial de transformadores em comparação com técnicas baseadas em Inteligência Artificial (IA). A questão central que se busca responder é se, e em que condições, a adoção de métodos baseados em IA se justifica frente aos esquemas convencionais de proteção diferencial com restrição harmônica e características percentuais, amplamente discutidos em normas e manuais técnicos (IEEE, 2011; GUERRA, 2008; KINDERMANN, 2006).

A avaliação não se baseia em novas simulações, mas em uma análise comparativa de estudos publicados, que aplicam tanto técnicas tradicionais quanto algoritmos de IA em transformadores de diferentes potências, topologias de ligação e condições de operação.

### 4.1.2 Critérios de comparação

Para tornar a avaliação consistente, são adotados critérios de comparação alinhados tanto à proteção clássica quanto aos estudos recentes de IA. Em termos gerais, os métodos serão analisados segundo três grupos de critérios:

#### 1. Desempenho operacional

- Acurácia global de classificação (percentual de casos corretamente identificados como falta interna, *inrush*, falta externa etc.), muitas vezes designada como *accuracy* nos estudos de IA (AFRASIABI et al., 2023; SILVA et al., 2021);
- Sensibilidade, entendida como a capacidade do esquema de atuar sempre que houver falta interna na zona protegida, conceito tradicional na literatura de proteção;
- Segurança e seletividade, relacionadas à não atuação em condições normais ou em faltas externas, e à correta limitação da atuação à zona protegida (GUERRA, 2008; AFRASIABI et al., 2023);
- Taxa de falsos disparos.

## 2. Desempenho dinâmico e robustez

- Tempo de detecção/atuação, medido em milissegundos ou frações de ciclo, comparando-se, por exemplo, relés diferenciais convencionais com bloqueio harmônico e algoritmos baseados em ANN e CNN;
- Comportamento frente a correntes de *inrush* (inclusive de baixo conteúdo harmônico);
- Resiliência à saturação de TCs, sobre-excitação e presença de dispositivos como SFCL e compensação série, que podem distorcer as correntes diferenciais e comprometer os critérios clássicos de proteção;

## 3. Aspectos de implementação e aplicabilidade prática

- Complexidade de parametrização e ajuste, particularmente relevante para esquemas tradicionais com múltiplos patamares de inclinação, limiares harmônicos e tempos de retardo;
- Necessidade e disponibilidade de base de dados para treinamento no caso de modelos de IA, incluindo quantidade e diversidade de cenários simulados ou medidos;
- Requisitos computacionais e integração em relés numéricos comerciais, tema discutido em trabalhos sobre proteção digital e aplicações de IA em redes inteligentes.

### 4.1.3 Conjunto de estudos analisados

A avaliação desenvolvida neste capítulo baseia-se em um conjunto representativo de trabalhos que aplicam tanto métodos tradicionais quanto técnicas de IA à proteção diferencial de transformadores de potência. De forma resumida, destacam-se:

- Silva et al. (2021), que propõem uma proteção diferencial baseada em rede neural artificial (ANN) aplicada a três transformadores de 100, 40 e 18 MVA, comparando diretamente o desempenho da ANN com o esquema convencional de restrição harmônica, em cenários de *inrush*, sobre-excitação, saturação de TCs e faltas internas e externas;
- Tripathy, Maheshwari e Verma (2007), que introduzem uma proteção diferencial baseada em Probabilistic Neural Network (PNN) otimizada por *particle swarm*

*optimization*, comparando-a com redes neurais de retropropagação e com o método harmônico clássico;

- Afrasiabi et al. (2023), que realizam uma análise comparativa abrangente de diferentes técnicas de IA (ANN, PNN, SVM, KNN, LVQ, RSLVQ, *Random Forest*, entre outras) aplicadas à proteção diferencial de transformadores, avaliando acurácia, *security* e *safety* sob condições de saturação de TCs, presença de SFCL e compensação série;
- Ahmad et al. (2019), que desenvolvem um relé diferencial adaptativo baseado em ANN, projetado para evitar mau operação durante energização, comparando seu desempenho em termos de tempo de resposta e redução de disparos indevidos com o método de bloqueio pela segunda harmônica;
- Li et al. (2022), Atiyah; Karimi; Moradi (2024) e Abdulhasan et al. (2024), que representam a geração de métodos de *deep learning*, empregando arquiteturas CAE–CNN, CNN–LSTM e *autoencoders* empilhados para melhorar a proteção diferencial em cenários complexos;
- Trabalhos clássicos e normativos que descrevem e fundamentam os métodos tradicionais, como Guerra (2008), Kindermann (2006), IEEE Std C37.91 (2011) e publicações técnicas de fabricantes de relés, que servem como base de comparação para os resultados obtidos com IA.

## 4.2 Desempenho dos métodos tradicionais de proteção diferencial

Nesta seção são avaliados, de forma qualitativa, os principais esquemas tradicionais de proteção diferencial de transformadores, com ênfase na proteção percentual com restrição harmônica e em algumas extensões clássicas baseadas em forma de onda e ângulo de fase. A análise é baseada em trabalhos de proteção de sistemas elétricos e em estudos específicos de desempenho desses esquemas em condições típicas de operação e de falta.

### 4.2.1 Proteção diferencial percentual com restrição harmônica

A proteção diferencial percentual constitui o método tradicional mais amplamente utilizado para transformadores de potência. Sua lógica básica consiste em comparar a corrente diferencial (soma vetorial das correntes secundárias dos TCs que delimitam a zona protegida) com uma corrente de restrição, função das correntes medidas nos lados do transformador. A atuação ocorre quando a corrente diferencial ultrapassa uma fração (*slope*) da corrente de restrição, usualmente com um nível mínimo de *pick-up* para evitar atuação indevida em correntes pequenas (GUERRA, 2008; BLACKBURN; DOMIN, 2015).

Em relés modernos, a característica de operação é tipicamente percentual com dupla inclinação (*dual-slope*):

- uma primeira inclinação, mais baixa, oferece maior sensibilidade para correntes de falta moderadas;
- uma segunda inclinação, mais elevada, aumenta a segurança frente à saturação de TCs e condições assimétricas, limitando a atuação quando a corrente de restrição é elevada (KINDERMANN, 2006; GUZMAN et al., 2005).

Tabela 01 - Vantagens e Limitações da proteção percentual

<b>Vantagem</b>	<b>Descrição</b>
Princípio simples e seletivo	Atua somente quando há diferença significativa entre as correntes que entram e saem da zona protegida, oferecendo elevada seletividade para faltas internas.
Alta sensibilidade a faltas internas	Sensível a defeitos de baixa magnitude dentro do transformador, especialmente em enrolamentos e conexões internas.
Imune a faltas externas	Não deve operar quando correntes externas atravessam os TCs de forma simétrica, mantendo a operação segura.
Uso consolidado em relés modernos	Amplamente implementado em IEDs, com compensações internas para saturação de TCs, defasamentos e discrepâncias de transformação.
<b>Limitação</b>	<b>Descrição</b>
Vulnerável ao inrush de magnetização	A corrente de energização pode ultrapassar o limiar diferencial e acionar o relé indevidamente. Necessita da lógica harmônica para bloquear.
Dependência da saturação dos TCs	Uma forte saturação em um dos lados pode gerar corrente diferencial artificial, levando a disparos indevidos.
Desempenho degradado quando há baixo conteúdo harmônico no inrush	Transformadores modernos, com aços de baixa histerese, podem gerar inrush pobre em 2ª harmônica, reduzindo a eficácia do bloqueio harmônico.
Complexidade quando há conexões mistas ( $\Delta$ -Y / Y- $\Delta$ )	Exige compensações internas no relé e inversão das conexões dos TCs. Implementação inadequada gera desbalanceamento.

Não identifica padrões temporais do sinal	Trabalha apenas com grandezas instantâneas ou RMS, não reconhece comportamento dinâmico da corrente.
---	--

Para garantir segurança durante a energização e a sobreexcitação, esses esquemas são complementados por unidades de restrição ou bloqueio harmônico, que analisam o teor de segunda harmônica da corrente diferencial. Em regime de *inrush*, o conteúdo relativo de segunda harmônica tende a ser significativamente maior do que em faltas internas, o que leva o relé a bloquear a atuação sempre que a relação entre harmônica e componente fundamental excede um valor de referência pré-ajustado (IEEE, 2011; GUERRA, 2008).

Em condições típicas de operação, a combinação entre característica percentual *dual-slope* e restrição harmônica proporciona elevada dependabilidade e boa segurança para a maioria das faltas internas e externas, sendo por isso a solução de referência em normas e práticas de engenharia. Contudo, trabalhos recentes apontam limitações em cenários específicos:

- *inrush* com baixo teor de segunda harmônica, associado a materiais magnéticos mais modernos ou a configurações construtivas particulares, pode reduzir a eficácia do bloqueio harmônico;
- saturação severa de TCs pode distorcer a forma de onda de forma assimétrica, gerando correntes diferenciais aparentes que desafiam a característica percentual e a lógica de restrição (KINDERMANN, 2006; IEEE, 2011);
- a necessidade de ajustes fixos de limiar harmônico e inclinações implica um compromisso entre sensibilidade e segurança, nem sempre trivial de otimizar em sistemas com grande variabilidade de condições operativas.

#### 4.2.2 Métodos tradicionais avançados

Além da lógica percentual com restrição harmônica, diversas propostas clássicas buscam aperfeiçoar a discriminação entre *inrush* e faltas internas mantendo ainda uma estrutura essencialmente determinística, sem uso de IA. Entre essas abordagens destacam-se:

- Técnicas de reconhecimento de forma de onda (*wave-shape recognition*), que exploram características temporais da corrente diferencial, como a presença de intervalos de baixa corrente ou patamares específicos de distorção durante o *inrush*, em contraste com a forma mais abrupta e simétrica das correntes de falta. Esses métodos analisam

diretamente a evolução da corrente ao longo de janelas curtas de amostragem, complementando ou substituindo parcialmente a análise harmônica (HOSNY; SOOD, 2014);

- Critérios baseados em ângulo de fase, que comparam o defasamento entre correntes e tensões ou entre as correntes dos diferentes lados do transformador. A lógica geral é que a relação de fase entre as grandezas tende a diferir de maneira característica entre inrush, falta interna e falta externa, permitindo estabelecer regiões de operação e de bloqueio (TAJDINIAN et al., 2022);
- Métodos combinados, que utilizam simultaneamente a componente harmônica, a forma de onda e o ângulo de fase, muitas vezes implementados em relés numéricos como funções auxiliares de supervisão da proteção diferencial tradicional (GERMANO, 2008; IEEE, 2011).

De modo geral, esses métodos avançados apresentam desempenho superior aos esquemas baseados unicamente em limiares harmônicos, sobretudo em situações em que o teor de segunda harmônica é insuficiente para justificar o bloqueio, ou quando a saturação do TC degrada a estimativa espectral. No entanto, a literatura também aponta algumas limitações:

- maior complexidade de implementação e parametrização, com necessidade de definir janelas temporais, limiares de tolerância e regiões de operação para diferentes tipos de eventos (HOSNY; SOOD, 2014);
- sensibilidade a ruídos de medição e distorções não modeladas, o que pode exigir filtragem adicional e aumentar o esforço de engenharia para validação em campo;
- ausência de padronização ampla: muitos desses critérios são propostos em trabalhos acadêmicos ou em implementações específicas de fabricantes, mas não alcançam o mesmo nível de consolidação que a proteção diferencial percentual com restrição harmônica.

#### **4.2.3 Síntese qualitativa do desempenho dos métodos tradicionais**


Com base nas referências clássicas e nos trabalhos que comparam diretamente métodos tradicionais com abordagens baseadas em IA, pode-se traçar um quadro geral do desempenho dos esquemas convencionais de proteção diferencial:

- Dependabilidade: a proteção diferencial percentual, devidamente ajustada, apresenta alta capacidade de detecção de faltas internas na zona protegida, especialmente quando

associada a características dual-slope e a supervisão por sobrecorrente de retaguarda (GUERRA, 2008);

- Segurança e seletividade: a introdução da restrição por segunda (e eventualmente quinta) harmônica garante, em grande parte das aplicações, boa imunidade a inrush e sobre-excitação. Entretanto, trabalhos recentes evidenciam casos em que energizações com baixo conteúdo harmônico ou saturação intensa de TCs, conforme saturação indicada na Figura 19, podem levar a situações de difícil ajuste, exigindo compromisso entre segurança e sensibilidade (KINDERMANN, 2006; SILVA et al., 2021);

Figura 20 - Curva característica de excitação de TC



Fonte: (ALMEIDA, 2006)

- Tempo de atuação: o uso de análise harmônica e janelas de medição de meia a um ciclo implica, na prática, tempos de decisão da ordem de dezenas de milissegundos, compatíveis com as exigências de proteção de transformadores, mas superiores aos tempos reportados para algumas abordagens modernas baseadas em IA, que operam com janelas significativamente menores;
- Robustez a condições adversas: apesar de consolidados, os métodos tradicionais mostram sensibilidade a condições extremas, como CTs fortemente saturados, inrush com características não usuais, presença de SFCL ou compensação série, o que tem motivado a pesquisa de alternativas mais adaptativas (AFRASIABI et al., 2023).

#### 4.3 – Desempenho dos métodos baseados em IA

A aplicação de técnicas de Inteligência Artificial (IA) em proteção diferencial de

transformadores tem avançado de forma significativa na última década, especialmente devido ao aumento da capacidade de processamento, da disponibilidade de ferramentas de simulação (ATP, PSCAD/EMTDC) e do interesse em soluções adaptativas que superem limitações típicas dos métodos tradicionais. As principais abordagens encontradas na literatura podem ser agrupadas em três categorias: RNAs clássicas, técnicas de aprendizado profundo (Deep Learning) e modelos comparativos multiclasse. Cada classe apresenta benefícios e limitações próprias, refletidas nos resultados reportados por diversos estudos.

#### 4.3.1 Redes Neurais Artificiais clássicas (ANN, PNN, modelos adaptativos)

As Redes Neurais Artificiais constituem uma das abordagens mais consolidadas em proteção diferencial avançada. Estudos baseados em ANN demonstram sua capacidade de discriminar padrões complexos relacionados a correntes de *inrush*, sobreexcitação, saturação de TCs e faltas internas. Diversas pesquisas apontam que ANNs treinadas adequadamente conseguem superar métodos convencionais de restrição harmônica.

- Desempenhos reportados na literatura:
  - Um estudo brasileiro aplicou RNA a três transformadores de 18, 40 e 100 MVA simulados em ATP, gerando mais de 1200 casos por unidade; a ANN apresentou desempenho superior ao relé diferencial convencional, principalmente na redução de falsos disparos em energização (SILVA et al., 2021).
  - O uso de *Probabilistic Neural Networks* (PNN) otimizado por *Particle Swarm Optimization* também demonstrou resultados promissores ao distinguir entre *inrush* e faltas internas, superando redes *backpropagation* e o método harmônico tradicional (TRIPATHY; MAHESHWARI; VERMA, 2007).
  - Metodologias adaptativas baseadas em ANN, treinadas com harmônicas como elemento de restrição, apresentaram tempo de atuação próximo de 1 ms, contra 4,5 ms de relés com restrição de segunda harmônica (AHMAD et al., 2019).
  
- Principais conclusões que podem ser observados a partir da literatura técnica atual:
  - ANNs reduzem significativamente a taxa de falsas operações.
  - O tempo de detecção é inferior ao dos relés tradicionais.
  - O desempenho melhora à medida que cresce o conjunto de treinamento.
  - A principal limitação é a dependência de dados representativos e a dificuldade

de generalização entre transformadores distintos.

### 4.3.2 Algoritmos de Deep Learning (CNN, LSTM, Autoencoders, modelos híbridos)

A literatura recente demonstra que métodos de aprendizado profundo superam ANNs clássicas por sua capacidade de extrair automaticamente características relevantes dos sinais, sem depender de pré-processamento extensivo.

- Evidências de alto desempenho incluem:
  - Uma abordagem baseada em CNN-1D combinada com LSTM apresentou elevada precisão para diferenciar *inrush* e falta interna mesmo em condições de distorção severa (ATIYAH; KARIMI; MORADI, 2024).
  - Um modelo baseado em *stacked denoising autoencoders* demonstrou ser particularmente eficiente ao eliminar ruído, saturação e componentes transitórias antes da classificação final (ABDULHASAN et al., 2024).
  - Uma metodologia CAE-CNN (Li et al., 2022) remove características saturadas da curva tensão versus corrente (VICUR), permitindo que a CNN extraia apenas padrões relevantes associados às faltas internas.
- Principais conclusões integradas:
  - CNNs são altamente eficientes para análise de forma de onda.
  - *Autoencoders* aumentam robustez em ambientes ruidosos.
  - Modelos híbridos CNN-LSTM lidam bem com padrões temporais típicos de *inrush* e saturação.
  - O desempenho se mantém mesmo com harmônicas reduzidas, onde o método tradicional falha.

### 4.3.3 Comparações multiclasse e modelos alternativos

O artigo comparativo de Afrasiabi et al. (2023) analisou extensivamente sete técnicas de IA aplicadas à proteção diferencial, incluindo:

1. SVM - *Support Vector Machine* ou Máquina de Vetores de Suporte;
2. PNN - *Probabilistic Neural Network* ou Rede Neural Probabilística;
3. LVQ / RSLVQ - *Learning Vector Quantization* ou Quantização por Vetores de Aprendizado / *Robust Soft Learning Vector Quantization* ou Quantização por Vetores de Aprendizado Suave e Robusta;
4. KNN - *K-Nearest Neighbors* ou K Vizinhos mais próximos;
5. ELM - *Extreme Learning Machine* ou Máquina de Aprendizado Extremo;
6. ANN - *Artificial Neural Network* ou Rede Neural Artificial;
7. LSSVM - *Least Squares Support Vector Machine* ou Máquina de Vetores de Suporte por Mínimos quadrados.

Os resultados do estudo comparativo indicam que as técnicas de Inteligência Artificial apresentam comportamentos distintos conforme o princípio de classificação adotado. Métodos baseados em métricas de distância, como KNN e LVQ, demonstraram menor eficiência global, especialmente em cenários caracterizados pela saturação dos transformadores de corrente, nos quais a distorção das formas de onda compromete a extração de características discriminantes. Em contrapartida, abordagens como PNN e SVM alcançaram desempenho satisfatório, desde que precedidas por etapas criteriosas de pré-processamento e ajuste de parâmetros, evidenciando certa dependência da qualidade dos dados de entrada. Destacam-se, ainda, os modelos com maior capacidade de aprendizado, como CNN e ELM, que apresentaram as maiores taxas de acerto entre as técnicas avaliadas, mantendo desempenho consistente mesmo sob condições severas de operação.

Tabela 02 - Desempenho comparativo de métodos de Inteligência Artificial aplicados à proteção diferencial de transformadores

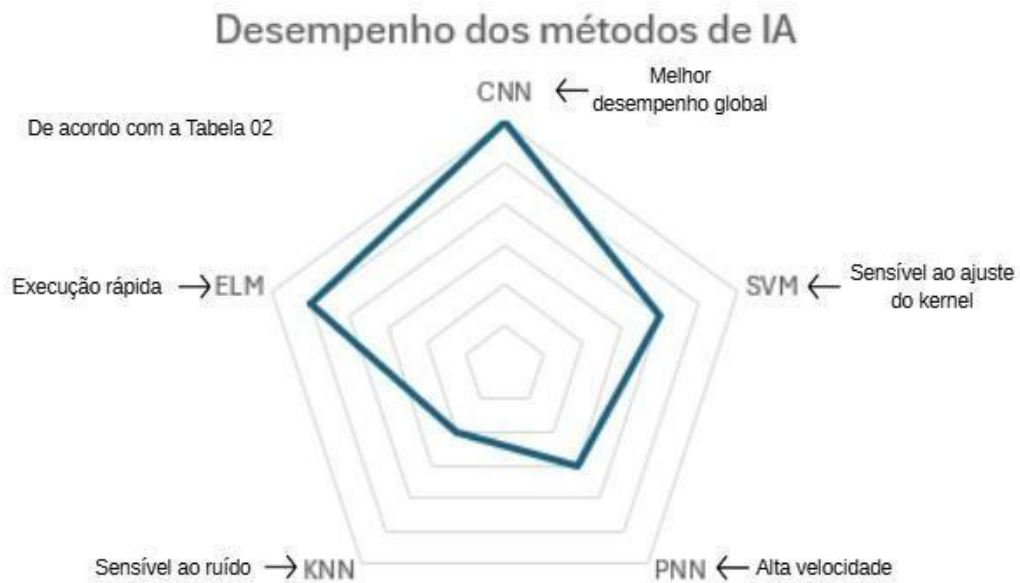
<b>Método</b>	<b>Acurácia (%)</b>	<b>Segurança</b>	<b>Dependabilidade</b>
CNN	99%	Alta	Alta
SVM	97–98%	Média/Alta	Alta
PNN	96–97%	Alta	Média
KNN	<95%	Média	Baixa
ELM	98%	Alta	Alta

Fonte:  
(Afrasiabi et al,  
2023)

De forma geral, os resultados mostram que as abordagens baseadas em IA preservam sua eficácia mesmo na presença de saturação de TCs, compensação série e limitadores de corrente de falta (SFCL), cenários nos quais os métodos tradicionais de proteção diferencial apresentam limitações amplamente reconhecidas na literatura (Afrasiabi et al., 2023).

Além disso, superou amplamente o método harmônico tradicional em todos os cenários avaliados. A comparação e o desempenho pode ser verificado de acordo com o Tabela 02 e o Gráfico 02.

Gráfico 02 - Desempenho dos métodos de IA



Fonte: Autoria própria

#### 4.3.4 Síntese dos resultados obtidos pela IA

A revisão integrada das fontes mostra que as técnicas de IA apresentam desempenho superior aos métodos tradicionais (especialmente os baseados em 2ª harmônica e *slope*) em praticamente todas as métricas relevantes:

- Benefícios consolidados (com base na literatura indireta):
  - Redução expressiva do tempo de atuação (1–5 ms, ANN *deep learning*).
  - Melhor seletividade, especialmente em transformadores modernos com *inrush* de baixo conteúdo harmônico.
  - Alta confiabilidade sob saturação do TC, devido à extração automática de padrões.
  - Diagnóstico preciso em situações complexas, como *sympathetic inrush* e *overexcitation*.
  - Redução consistente de disparos indevidos, conforme relatado em diversos estudos.

A principal limitação comum, reportada pelos autores, é a necessidade de bases de dados amplas e representativas para treinamento, além da dificuldade de generalizar modelos entre diferentes unidades transformadoras.

## 4.5 Discussão crítica e implicações práticas

A análise dos resultados apresentados nas seções anteriores demonstra que os métodos baseados em Inteligência Artificial (IA) apresentam vantagens técnicas significativas quando comparados aos esquemas tradicionais de proteção diferencial de transformadores. No entanto, a adoção prática dessas técnicas requer uma avaliação cuidadosa de suas limitações, de seus requisitos e do contexto em que serão aplicadas. Isso é fundamental para evitar conclusões excessivamente otimistas e garantir que a evolução tecnológica seja incorporada de forma segura, gradual e rastreável.

### 4.5.1 Limitações e cuidados na interpretação dos resultados

Apesar de apresentarem desempenho superior na maioria dos estudos analisados, as técnicas baseadas em IA dependem de:

- Bases de dados representativas — A generalização do modelo só é válida se o conjunto de treinamento incluir fenômenos diversos, como inrush fraco, saturação severa de TCs, sobreexcitação, faltas de baixa impedância, condições assimétricas, ruído e distorções não harmônicas. Estudos experimentais mostram que modelos treinados com bases limitadas podem apresentar sobreajuste e queda de desempenho em condições reais (Afrasiabi et al., 2023).
- Coerência entre simulação e campo — A maior parte dos resultados promissores foi obtida em ambientes simulados (ATP, PSCAD/EMTDC), nos quais condições externas e ruídos são representados de maneira idealizada. Alguns trabalhos destacam que diferenças entre transformadores reais podem introduzir incertezas não vistas no treinamento (Silva et al., 2020).
- Requerimento computacional — Arquiteturas profundas (CNN, LSTM, autoencoders) exigem hardware adequado para resposta em tempo real. Embora o tempo de inferência seja baixo (1–4 ms em diversos estudos), a implementação do pipeline completo precisa ser cuidadosamente validada.

### 4.5.2 Considerações sobre confiabilidade e requisitos normativos

Métodos tradicionais permanecem amplamente utilizados porque são totalmente aderentes às práticas normativas IEEE/IEC, possuem histórico comprovado em campo e são transparentes e interpretáveis. Já algoritmos de IA ainda enfrentam desafios como:

- ausência de normas consolidadas para validação e certificação;
- dificuldade de auditoria, já que modelos como CNNs operam em espaços latentes não diretamente interpretáveis;
- necessidade de mecanismos de *fallback*, garantindo que uma falha no modelo não comprometa a proteção.

Assim, a IA tende a atuar como complemento, não substituto imediato, dos elementos tradicionais. Esse é um ponto enfatizado por projetos que integram IA com lógica harmônica e percentual — criando esquemas híbridos mais robustos (Afrasiabi et al., 2023; Li *et al.*, 2022).

#### 4.5.3 Viabilidade de implementação em sistemas reais

Para aplicações práticas em subestações reais, algumas condições devem ser observadas:

##### a) Interoperabilidade com relés digitais

A maioria dos relés comerciais já possui unidades DSP capazes de realizar pré-processamento. Entretanto, IA embarcada exige novos ciclos de firmware e validação.

##### b) Dependência de sensores e TCs

Embora IA seja robusta a distorções, condições extremas de saturação, mau casamento de TCs e ruídos podem comprometer a acurácia do modelo.

##### c) Atualização contínua (*learning lifecycle*)

Modelos de IA precisam ser re-treinados periodicamente para incorporar:

- mudanças topológicas,
- novos perfis de carga,
- novos equipamentos,
- condições climáticas ou estacionais.

Isso implica políticas de manutenção diferentes das usadas com métodos clássicos.

#### 4.5.4 Implicações para *smart grids* e operação moderna

Os sistemas modernos — com renováveis, fluxos bidirecionais, transitórios diversos e comportamento rápido — pressionam os métodos tradicionais, que foram projetados para sistemas mais estáveis.

Em contrapartida:

- IA lida bem com ambientes dinâmicos;
- CNN, LSTM e *autoencoders* conseguem capturar distorções e padrões não lineares;
- Algoritmos adaptativos podem se reajustar a novos cenários operacionais.

Assim, a literatura sugere que a IA não apenas resolve problemas clássicos (*inrush* x falta interna), mas também se mostra mais adequada para sistemas futuros com alto grau de complexidade.

# 5. CONCLUSÃO E TRABALHOS FUTUROS

## 5.1 Síntese Geral do Trabalho

O presente trabalho teve como propósito avaliar o estado da arte dos métodos tradicionais e das técnicas baseadas em Inteligência Artificial (IA) aplicadas à proteção diferencial de transformadores de potência. A motivação surgiu da constatação de que transformadores constituem elementos estratégicos do sistema elétrico e exigem esquemas de proteção robustos e seletivos, principalmente frente a fenômenos complexos como correntes de *inrush*, saturação de transformadores de corrente (TCs) e condições transitórias de operação. A partir desse cenário, buscou-se investigar se abordagens de IA apresentam vantagens significativas em relação às metodologias convencionais, particularmente no que se refere à confiabilidade, à redução de falsos disparos e à capacidade de identificação precisa de faltas internas.

Para isso, o estudo delimitou-se aos transformadores trifásicos imersos em líquido, considerando que esse tipo concentra a maior parte das aplicações práticas na transmissão e distribuição e é o principal objeto de pesquisa em proteção diferencial. Foram analisados os fundamentos dos relés tradicionais, suas limitações e, posteriormente, os avanços recentes da IA, integrando também fontes clássicas. Por fim, foi realizada uma avaliação crítica entre ambos os paradigmas, de forma qualitativa, considerando desempenho reportado, princípios de funcionamento e implicações práticas de implementação.

## 5.2 Principais Achados da Revisão

A revisão revelou que diversos estudos recentes têm demonstrado ganhos importantes no uso de técnicas de IA para proteção de transformadores, sobretudo em situações adversas onde os métodos tradicionais enfrentam limitações estruturais. Pesquisas baseadas em redes neurais convolucionais, arquiteturas híbridas (CNN-LSTM, CAE-CNN), modelos probabilísticos e redes neurais clássicas têm apresentado tempos de detecção reduzidos, maior seletividade e significativa diminuição de atuações indevidas, especialmente em condições de *inrush* com baixo conteúdo harmônico, cenários que desafiam o bloqueio harmônico

convencional. Esses resultados foram relatados, por exemplo, em estudos que compararam IA com relés diferenciais convencionais sob saturação de TCs, compensação série e presença de supercondutores limitadores de corrente de falta.

Além disso, verificou-se que as abordagens de aprendizado profundo conseguem extrair características relevantes diretamente das formas de onda, reduzindo a dependência de parâmetros pré-ajustados e proporcionando robustez frente a distorções. A literatura também enfatiza que métodos baseados em IA apresentam boa generalização quando treinados com bases amplas de dados simulados, incluindo casos raros como energização solidária e sobreexcitação.

### **5.3 Avaliação Integrada dos Métodos Tradicionais e de IA**

A análise consolidada dos capítulos anteriores indica que os métodos tradicionais continuam essenciais devido à sua maturidade, previsibilidade e alinhamento às normas e práticas consolidadas na engenharia de proteção. As técnicas de característica percentual, restrição harmônica e compensações de TC fornecem elevada confiabilidade em condições típicas de operação e possuem modelos comportamentais bem compreendidos pelos operadores.

Entretanto, as limitações desses métodos tornam-se evidentes em cenários de maior complexidade, especialmente quando há saturação severa de TCs, variações transitórias rápidas, *inrush* com baixos níveis harmônicos e condições operativas não previstas nos ajustes. Nesses casos, as abordagens baseadas em IA demonstram capacidade superior de discernimento, pois analisam múltiplos atributos simultaneamente e aprendem padrões não lineares presentes nos sinais.

A avaliação integrada permite concluir que, em vez de substituir completamente os métodos tradicionais, as técnicas de IA representam uma evolução complementar. Os métodos clássicos oferecem a base normativa e operacional que garante segurança mínima, enquanto a IA potencializa a capacidade adaptativa e de diagnóstico avançado, sobretudo quando integrados a arquiteturas híbridas de proteção.

### **5.4 Conclusões Gerais**

A investigação demonstrou que a Inteligência Artificial tem contribuído de forma

significativa para o aprimoramento da proteção de transformadores de potência, apresentando desempenho superior em aspectos críticos como tempo de detecção, seletividade e redução de falsos disparos. Os estudos recentes apontam que redes neurais convolucionais, *autoencoders* e modelos híbridos conseguem identificar faltas internas em janelas temporais muito curtas, da ordem de milissegundos, e com elevada precisão mesmo em condições adversas.

Ao mesmo tempo, verificou-se que os métodos tradicionais permanecem indispensáveis e robustos, sendo amplamente utilizados com sucesso em sistemas reais. Contudo, seus limites operacionais tornam-se mais evidentes à medida que as redes elétricas evoluem para configurações mais complexas, com maior penetração de fontes distribuídas e variações dinâmicas. A IA surge, nesse contexto, como ferramenta especializada para lidar com cenários de baixa previsibilidade e exigir menor dependência de ajustes fixos.

Ainda que os resultados de IA sejam promissores, a literatura indica que sua aplicação prática em larga escala depende de avanços em três frentes: disponibilidade de bases de dados reais para treinamento, validação independente em campo e padronização metodológica para garantir interpretabilidade e segurança operacional. Assim, conclui-se que a IA representa um caminho sólido e promissor para o futuro da proteção de transformadores, mas que sua adoção deve ocorrer de forma gradual, supervisionada e integrada com as práticas convencionais.

### **5.5 Limitações do Estudo**

As principais limitações identificadas na execução deste trabalho foram:

- A análise foi predominantemente qualitativa, baseada em resultados divulgados na literatura, sem implementação prática em relés comerciais;
- Os estudos revisados apresentam metodologias distintas de simulação, o que dificulta comparações quantitativas diretas;
- A ausência de bases de dados de campo limita a avaliação da IA sob condições reais e não idealizadas;
- O escopo foi restringido a transformadores trifásicos imersos em líquido, não abordando particularidades dos transformadores a seco;
- O trabalho concentrou-se em proteção diferencial, não explorando outras funções relevantes como sobrecorrente direcional ou buchholz digital.

### **5.6 Trabalhos Futuros**

Com base nos achados e limitações identificadas, recomenda-se que pesquisas futuras avancem nas seguintes direções:

1. Desenvolvimento de base de dados real brasileira contendo registros de faltas internas, *inrush*, sobreexcitação e eventos transitórios, permitindo treinamento e validação de modelos de IA sob condições reais.
2. Desenvolvimento de esquemas híbridos IA + lógica tradicional, buscando aproveitar a robustez dos métodos clássicos e a adaptabilidade da IA.
3. Avaliação de segurança cibernética em relés com IA, considerando vulnerabilidades associadas a modelos treináveis.
4. Criação de protocolos padronizados de teste para permitir comparação justa entre diferentes arquiteturas de IA.
5. Análise custo-benefício da adoção de IA na proteção, considerando CAPEX, OPEX e impacto regulatório junto à ANEEL/ONS.

# REFERÊNCIAS

ABDULHASAN, W. et al. *Deep Learning-Based Algorithm for Internal Fault Detection of Power Transformers during Inrush Current at Distribution Substations*. *Energies*, v. 17, n. 4, 2024.

KEY, Sopheap; SON, Gyu-Won; NAM, Soon-Ryul. *Deep Learning-Based Algorithm for Internal Fault Detection of Power Transformers during Inrush Current at Distribution Substations*. *Energies*, v. 17, n. 4, art. 963, 2024.

BECHARA, Ricardo. *Análise de falhas de transformadores de potência*. 2010. Dissertação (Mestrado em Engenharia Elétrica) — Escola Politécnica da Universidade de São Paulo, São Paulo, 2010.

ATHAMNEH, A. A.; ALQUDAH, A. M. *Transformer Inrush Current and Internal Fault Discrimination Using Multitypes of Convolutional Neural Network Techniques*. *Journal of Electrical and Computer Engineering*, 2024.

ATIYAH, W. A.; KARIMI, S.; MORADI, M. *A Novel Approach for Diagnosing Transformer Internal Defects and Inrush Current Based on IDCNN and LSTM Deep Learning*. *Journal of Electrical Systems*, v. 20, n. 4s, 2024.

BLACKBURN, J. L.; DOMIN, T. J. *Protective Relaying: Principles and Applications*. 4. ed. Boca Raton: CRC Press, 2015.

ENSINA, A. *Modelos preditivos múltiplos e estruturas de seleção dinâmica de regressores para localização de faltas em linhas de transmissão*. *Applied Energy*, [s. 1.], 2024.

GERMANO, André Dantas. *Estudo da proteção diferencial de transformadores*. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica) — Universidade Federal de Campina Grande, Campina Grande, nov. 2008.

GUZMAN, A.; ALTUVE, H.; TZIOUVARAS, D. *Power Transformer Protection Improvements With Numerical Relays*. Apresentado em CIGRE Study Committee B5 Colloquium, Calgary, 14–16 Sept. 2005. Schweitzer Engineering Laboratories, Inc.

HAMOODI, A. N.; IBRAHIM, M. A.; SALIH, B. M. *An Intelligent Differential Protection of*

*Power Transformer Based on Artificial Neural Network*. Bulletin of Electrical Engineering and Informatics, [s. l.], 2023.

HATATA, A. Y. et al. *Recurrent Neural Networks Based Differential Protection of Power Transformers*. Egyptian Research Journal of Engineering and Technology, Mansoura University, 2023.

HOSNY, A.; SOOD, V. K. *Transformer differential protection with phase angle difference based inrush restraint*. Electrical Power Systems Research, v. 115, p. 57–64, 2014.

IEC 60076. *Power transformers — série de partes*. International Electrotechnical Commission, 2006–2019.

IEC 60255. *Measuring relays and protection equipment*. International Electrotechnical Commission, (partes relevantes).

IET GTD. *Efficient method for discrimination between inrush current and internal faults in power transformers based on the non-saturation zone*. IET Generation, Transmission & Distribution, 2016.

LI, J. et al. *Advanced Fault Detection in Power Transformers Using Improved Wavelet Analysis and LSTM Networks Considering Current Transformer Saturation and Uncertainties*. Algorithms, v. 17, n. 9, 2024.

MARTINEZ-VELASCO, J. A. et al. *Revisões bibliográficas sobre diagnóstico de falhas em sistemas de transmissão e distribuição usando IA*. Energies, [s. l.], 2025.

MOHAMMADPOUR, H.; DASHTI, R.; SHAKER, H. R. *A New Practical Approach for Discrimination between Inrush Currents and Internal Faults in Power Transformers*. Technology and Economics of Smart Grids and Sustainable Energy, v. 5, art. 5, 2020.

“*Transformer Inrush Currents and Internal Faults Identification in Power Transformers Using Wavelet Energy Gradient*.” Journal of Control, Automation and Electrical Systems, v. 27, p. 339–348, 2016.

SILVA, Hudson Bonifácio dos. *Diagnóstico e manutenção preditiva em transformadores de potência utilizando inteligência artificial*. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Minas Gerais, Belo Horizonte, 2024.

VIALI, Leandro Garcia Alves et al. *Uma análise da utilização de smart grids no sistema elétrico brasileiro*. Caderno Pedagógico, v. 22, n. 1, p. e13341, 2025.

WEDAGEDARA, Harshana et al. *Non-Parametric Machine Learning Modeling of Tree-Caused Power Outage Risk to Overhead Distribution Powerlines*. Applied Sciences, v. 14, n. 4991, 2024.

ZHANG, Y. et al. *A Denoising-Classification Neural Network for Power Transformer Protection*. Protection and Control of Modern Power Systems, v. 7, art. 52, 2022.

MUNDO DA ELÉTRICA. *Tipos de transformadores*. Disponível em: <https://www.mundodaeletrica.com.br/tipos-de-transformadores/>. Acesso em: 21 nov. 2025.

WEG Equipamentos Elétricos S.A. Transformador a Seco Médio (até 3 000 kVA). Disponível em: [https://www.weg.net/catalog/weg/BR/pt/Geração%2C-Transmissão-e-Distribuição/Transformadores-a-Seco/Médio-%28Até-3-000-kVA%29/Transformador-a-Seco-Médio-%28Até-3-000-kVA%29/p/MKT\\_WTD\\_DRYTYPETRANSFORMER\\_MEDIUM](https://www.weg.net/catalog/weg/BR/pt/Geração%2C-Transmissão-e-Distribuição/Transformadores-a-Seco/Médio-%28Até-3-000-kVA%29/Transformador-a-Seco-Médio-%28Até-3-000-kVA%29/p/MKT_WTD_DRYTYPETRANSFORMER_MEDIUM). Acesso em: 30 nov. 2025.

PAULINO, Marcelo. Princípios básicos de transformadores de potência. In: Manutenção de transformadores. São Paulo: O Setor Elétrico, 2014. Fascículo 96, Capítulo I.

SILVEIRA, Leonardo Gervásio e; SILVA, Luis Carlos da; JESUS, Aurea Messias de; BATISTA, Elisson Andrade. Transformadores de Potência: Ensaio e Proteção. Brazilian Journal of Development, Curitiba, v. 7, n. 6, p. 59954-59975, jun. 2021. DOI: 10.34117/bjdv7n6-400.

GUERRA, F. C. F. Proteção de Sistemas Elétricos. Campina Grande: Ed. da Universidade Federal de Campina Grande, 1992. 59p.

WINDERS, John J., Jr. *Power transformers: principles and applications*. New York: Marcel Dekker, 2002.

ZIEGLER, Gerhard. Numerical differential protection: principles and applications. 2. ed. Erlangen: Siemens AG, 2005.

ABDUGAFFAR UGLI, Abdullaev Abduvokhid et al. A review on power transformer failures: analysis of failure types and causative factors. Indonesian Journal of Electrical Engineering and

Computer Science, v. 38, n. 2, p. 713–722, maio 2025.

RIBEIRO, C.J. et al. Falhas e defeitos ocorridos em transformadores de potência do sistema elétrico da CELG, nos últimos 28 anos: um estudo de caso. 2008. Dissertação (Mestrado em Engenharia Elétrica) — Escola de Engenharia Elétrica e de Computação, Universidade Federal de Goiás, Goiânia, 2008.

KINDERMANN, Geraldo. Proteção de sistemas elétricos de potência. Florianópolis: Edição do autor, 1999. v. 1.

KINDERMANN, Geraldo. Proteção de sistemas elétricos de potência. Florianópolis: Edição do autor, 2005. v. 2.