



UNIVERSIDADE FEDERAL FLUMINENSE
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
TELECOMUNICAÇÕES

MATEUS CARUSO COSTA

Contribuições para o Sistema de
Monitoramento e Diagnóstico de
Transformadores a Seco com invólucro de
Proteção IP 23

NITERÓI

2023

UNIVERSIDADE FEDERAL FLUMINENSE
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
TELECOMUNICAÇÕES

MATEUS CARUSO COSTA

Contribuições para o Sistema de
Monitoramento e Diagnóstico de
Transformadores a Seco com invólucro de
Proteção IP 23

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica e de Telecomunicações. Área de concentração: Sistemas de Energia Elétrica.

Orientador:
Prof. Dr. Bruno Wanderley França

NITERÓI

2023

Ficha catalográfica automática - SDC/BEE
Gerada com informações fornecidas pelo autor

C837c Costa, Mateus Caruso
Contribuições para o Sistema de Monitoramento e
Diagnóstico de Transformadores a Seco com invólucro de
Proteção IP 23 / Mateus Caruso Costa. - 2023.
86 f.

Orientador: Bruno Wanderley França.
Dissertação (mestrado)-Universidade Federal Fluminense,
Escola de Engenharia, Niterói, 2023.

1. Aprendizado de máquina. 2. Sistema de apoio à decisão.
3. Transformador elétrico. 4. Isolamento elétrico. 5.
Produção intelectual. I. França, Bruno Wanderley,
orientador. II. Universidade Federal Fluminense. Escola de
Engenharia. III. Título.

CDD - XXX

MATEUS CARUSO COSTA

Contribuições para o Sistema de Monitoramento e Diagnóstico de Transformadores a Seco com invólucro de Proteção IP 23

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica e de Telecomunicações. Área de concentração: Sistemas de Energia Elétrica.

Aprovada em 18 de Dezembro de 2023.

BANCA EXAMINADORA

Documento assinado digitalmente
 **BRUNO WANDERLEY FRANÇA**
Data: 18/12/2023 12:02:06-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Bruno Wanderley França – Orientador, UFF

Documento assinado digitalmente
 **VITOR HUGO FERREIRA**
Data: 26/12/2023 17:45:00-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Vitor Hugo Ferreira – UFF

Documento assinado digitalmente
 **BRUNO HENRIQUES DIAS**
Data: 19/12/2023 17:53:29-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Bruno Henriques Dias – UFJF

Niterói

2023

ESCOLA DE ENGENHARIA

COORDENAÇÃO DO PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA E DE TELECOMUNICAÇÕES

Ata da sessão de julgamento de Dissertação
de Mestrado na área de concentração
Sistemas de Energia Elétrica, do aluno
MATEUS CARUSO COSTA.

Aos dezoito dias do mês de dezembro de dois mil e vinte e três, no prédio da Escola de Engenharia, reuniu-se a Comissão Examinadora, designada na forma regimental pela Coordenação do Curso, para a defesa da Dissertação de Mestrado apresentada pelo aluno MATEUS CARUSO COSTA, sob o título “**Contribuições para o Sistema de Monitoramento e Diagnóstico de Transformadores a Seco com invólucro de Proteção IP 23**”, como requisito para obtenção de grau de Mestre em Engenharia Elétrica e de Telecomunicações – área de concentração Sistemas de Energia Elétrica. A Comissão foi presidida pelo professor doutor Bruno Wanderley França. Tendo como membros da banca os professores doutores, Vitor Hugo Ferreira e Bruno Henrique Dias. Aberta a sessão pública, foi concedido ao candidato o tempo de 45 (quarenta e cinco) minutos para a exposição do trabalho, sendo a defesa seguida pela arguição de cada examinador. A seguir, a Comissão reuniu-se para deliberar sobre o texto da dissertação e sua defesa oral, concluindo pela aprovação da mesma *sem restrições*, e nos termos do Regulamento Geral dos Cursos de Pós-Graduação desta Universidade, foi lavrada a presente ata, lida e julgada, conforme vai assinada pelos membros da Comissão.

Niterói, 18 de dezembro de 2023.

Documento assinado digitalmente



BRUNO WANDERLEY FRANCA
Data: 18/12/2023 12:44:36-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Bruno Wanderley França - Orientador
Universidade Federal Fluminense - UFF

Documento assinado digitalmente



VITOR HUGO FERREIRA
Data: 26/12/2023 17:43:12-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Vitor Hugo Ferreira
Universidade Federal Fluminense - UFF

Documento assinado digitalmente



BRUNO HENRIQUES DIAS
Data: 19/12/2023 17:53:29-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Bruno Henrique Dias
Universidade Federal de Juiz de Fora - UFJF

*"O verdadeiro significado da vida é plantar árvores,
sob cujas sombras você não espera sentar."*

– Nelson Henderson

Agradecimentos

Agradeço primeiramente à Isabella, minha namorada, esposa e família, cujo apoio incondicional e infinita paciência moldaram o caminho que escolhi e que tem, neste trabalho, um marco. Você é, em grande parte, motivação, justificativa e objetivo final de todo meu desenvolvimento. Aos meus pais, Denise e Luciano, e minha avó Ciléa, que me deram a vida e me criaram no máximo de suas capacidades. Cada um de vocês moldaram parte do meu caráter e personalidade para que eu chegasse a ser quem sou hoje.

Agradeço à minha família por escolha: meus amigos Maria Júlia, Isabela, João Pedro, Fabrício, Renato, Jão e minha querida sogra Miriam. Com alguns, compartilho a vida há mais de 20 anos; com outros, há menos tempo, mas todos têm sido companheiros indispensáveis. Não tenho dúvidas de que parte do mérito deste trabalho é devido ao apoio e à presença de vocês em minha vida.

Agradeço ao meu orientador e conselheiro, Bruno França, que me ensinou não somente teoria e prática acadêmica, mas também a correr atrás e ter coragem. Deus, de fato, tem ajudado maluco. Também aos demais docentes do NITEE, em especial aos professores Guilherme Sotelo e Flávio Martins que me acompanharam acadêmica e pessoalmente nesse processo. A contribuição de cada um de vocês é notável na minha vida e carreira.

Por último, mas nem por isso menos relevantes, aos colegas do NITEE. Principalmente à Marília, Cauê, Victor e Matheus Tardin, todos vocês contribuíram direta ou indiretamente neste trabalho e espero que a gente continue formando e desenvolvendo este grupo que chamamos de família.

Resumo

Esta dissertação realiza uma análise das técnicas de tratamento de dados e aprendizado de máquina aplicadas no sistema de monitoramento e diagnóstico de transformadores a seco. Falhas de isolamento são as mais comuns em transformadores de potência, com as falhas nas bobinas representando 49% de todas as falhas. O Curto-circuito Entre Espiras (CEE) é uma das principais causas dessas falhas. A implementação de um sistema eficaz de monitoramento, juntamente com um mecanismo de tomada de decisões e gerenciamento de manutenção, resulta em redução das perdas de produção e aumento da confiabilidade do sistema elétrico.

A metodologia do sistema tem como objetivo o monitoramento online e não invasivo dos parâmetros elétricos do transformador, bem como o diagnóstico com base nos dados coletados. O sistema aplica a Transformada de Park nas correntes diferenciais do transformador e parametriza essas amostras por meio da Figura de Lissajous resultante. O sistema de apoio à decisão é composto por três modelos de aprendizado de máquina que operam em paralelo: Perceptron de Múltiplas Camadas (MLP), Máquina de Vetor de Suporte (SVM) e Árvore de Decisão. Esses modelos são treinados com uma base de dados que contém amostras sintéticas das correntes do transformador em diferentes cenários de operação. As amostras são geradas a partir do modelo computacional do transformador usando o Método dos Elementos Finitos (MEF).

O sistema é inicialmente validado por meio de um modelo simulado do transformador e, em seguida, por experimentos envolvendo a montagem de um autotransformador trifásico usado como corpo de prova. Chegou-se à conclusão de que a criação de amostras sintéticas do transformador por meio do MEF, juntamente com a abordagem de processamento de dados proposta, é adequada para estabelecer a base de treinamento dos algoritmos. O sistema treinado demonstrou eficácia na capacidade de monitorar e diagnosticar o estado operacional de transformadores de potência nos cenários abordados.

Palavras-chave: Curto-circuito Entre Espiras (CEE), Diagnóstico de Transformador de Potência, Aprendizado de Máquina, Sistema de Apoio a Decisão, Tratamento de Dados.

Abstract

This dissertation provides an analysis of data processing and machine learning techniques implemented in the monitoring and diagnostic system for dry-type transformers. Insulation faults are the most common issues in power transformers, with winding faults alone accounting for 49% of all transformer failures. Inter-turn Short Circuit (ITSC) is one of the primary causes of these winding faults. The implementation of an effective monitoring system, along with a decision-making and maintenance management mechanism, leads to a reduction in production losses and an increase in the reliability of the electrical system.

The system's methodology aims to achieve online and non-invasive monitoring of the transformer's electrical parameters and diagnostic capabilities based on collected data. The system applies the Park Transform to the transformer's differential currents and parametrizes these samples through the resulting Lissajous Figures. The decision support system comprises three machine learning models operating in parallel: Multilayer Perceptron (MLP), Support Vector Machine (SVM), and Decision Tree. These models are trained with a database containing synthetic samples of the transformer's currents under various operating conditions. The samples are generated from the transformer's computational model using the Finite Element Method (FEM).

The system is initially validated using a simulated model of the transformer and subsequently through experiments involving the assembly of a three-phase autotransformer used as a test bench. It is concluded that creating synthetic transformer samples using FEM, in conjunction with the proposed data processing approach, is suitable for establishing the training foundation for the algorithms. The trained system demonstrates effectiveness in monitoring and diagnosing the operational state of power transformers in the addressed scenarios.

Keywords: Inter-turn Short Circuit (ITSC), Power Transformer Diagnosis, Machine Learning, Decision Support System, Data Processing.

Lista de Figuras

1.1	Transformador a Seco de Média Tensão	2
1.2	Arquitetura da solução do sistema para diagnóstico de CEE.	4
2.1	Esquema de um transformador monofásico a vazio.	9
2.2	Circuito equivalente do modelo de um transformador monofásico real. . . .	12
2.3	Circuito equivalente do modelo de um transformador monofásico referido ao primário.	13
2.4	Figuras de Lissajous com razões de frequência e defasagens variadas.	18
2.5	Funções Sigmoide e Tangente Hiperbólica.	22
2.6	Exemplo do ajuste de um Hiperplano 2D na base de treinamento 3D.	24
2.7	Exemplo da variação do hiperparâmetro C em um SVM bidimensional.	25
3.1	Simulação em MEF do transformador trifásico com 10% de CEE.	29
3.2	Ilustração do plano de corte de um enrolamento para a configuração de condutores multivolta homogeneizados.	30
3.3	Implementação de CEE no enrolamento de Alta Tensão da Fase A.	30
3.4	Ligação Delta-Estrela de um transformador trifásico.	31
3.5	Exemplo de uma elipse parametrizada.	34
3.6	Estrutura do Perceptron de Múltiplas Camadas implementado.	38
3.7	Exemplo de Estrutura da Árvore de Decisão implementada para um con- junto de dados simplificado.	39
4.1	Banco trifásico simulado no PSCAD.	42
4.2	Correntes do banco trifásico no caso sadio equilibrado.	43
4.3	Figura de Lissajous das correntes i_{dD} e i_{dQ} para caso sadio e equilibrado. . .	43

4.4	Correntes do banco trifásico para 70% da carga nominal na Fase B.	44
4.5	Figuras de Lissajous da amostra para o caso de referência e os casos desequilibrados.	44
4.6	Correntes do primário e secundário do banco trifásico para 1% de CEE na Fase A.	45
4.7	Figuras de Lissajous da amostra para o caso de referência e os casos com 0.5% e 1.0% de CEE.	45
4.8	Correntes das componentes de Park x Tempo para caso com 1.0% de CEE.	46
4.9	Correntes das componentes de Park x Tempo para caso com 1.0% de CEE.	47
4.10	Banco trifásico com carga harmônica simulado no PSCAD.	47
4.11	Correntes primárias e secundárias do banco trifásico sadio com carga harmônica.	48
4.12	Figura de Lissajous das correntes i_{dD} e i_{dQ} para caso sadio com carga harmônica.	48
4.13	Correntes primárias e secundárias do banco trifásico com 1% de CEE e carga harmônica.	49
4.14	Figura de Lissajous das correntes i_{dD} e i_{dQ} com 1% de CEE e carga carga harmônica.	49
5.1	Janela gráfica na interface “Treinamento” no sistema de diagnóstico. Visualização das amostras da base de treinamento para o transformador de Média Tensão (MT). (a) Visualização das amostras de forma geométricas. (b) Distribuição dos parâmetros das elipses em <i>box plots</i>	51
5.2	Janela de texto na interface “Treinamento” no sistema de diagnóstico. Caixa de texto das estatísticas do treinamento para o transformador de MT.	51
5.3	Janela gráfica na interface “Inferência” no sistema de diagnóstico. (a) Conjunto de elipses derivadas da simulação utilizando MEF para treinamento e inferência dos modelos de ML. (b) Distribuição dos parâmetros das elipses. As curvas vermelha e verde representam amostras rotuladas como saudáveis e com CEE do conjunto de treinamento. Os dados em azul destacam um exemplo de uma amostra sendo inferida no conjunto de treinamento.	52

5.4	Janela de texto na interface “Inferência” no sistema de diagnóstico. Caixa de texto da classificação de uma amostra de exemplo para o transformador de MT.	52
5.5	Geometria 2D do autotransformador trifásico utilizado como corpo de prova em simulação via MEF.	54
5.6	Janela gráfica na interface “Treinamento” no sistema de diagnóstico. Visualização das amostras da base de treinamento para o autotransformador trifásico. (a) Visualização das amostras de forma geométricas. (b) Distribuição dos parâmetros das elipses em <i>box plots</i>	55
5.7	Janela de texto na interface “Treinamento” no sistema de diagnóstico. Caixa de texto das estatísticas do treinamento para o autotransformador trifásico.	55
5.8	Autotransformador Trifásico utilizado no experimento.	56
5.9	Autotransformador Trifásico com os enrolamentos expostos.	56
5.10	Ilustração do método de aplicação de um curto de 4,65% aplicado ao enrolamento.	57
5.11	Circuito monofásico da montagem do corpo de prova.	57
5.12	Elipses das amostras experimentais do Autotransformador Trifásico. Elipses verdes indicam amostras de caso sadio, enquanto as vermelhas indicam casos não sadios.	58
5.13	Janela gráfica da interface “Inferência” no sistema de diagnóstico. Visualização das amostras da base de treinamento e da amostra inferida no sistema. (a) Visualização das amostras de forma geométricas. (b) Distribuição dos parâmetros das elipses em <i>Box Plots</i>	58
5.14	Janela gráfica na interface “Inferência” no sistema de diagnóstico. Caixa de texto das estatísticas da inferência de uma amostra sadia do autotransformador trifásico.	59

Lista de Tabelas

3.1	Métricas para avaliação de algoritmos de classificação binária.	36
5.1	Amostras sintéticas do transformador de MT e classificação pelo sistema. .	53
5.2	Matriz de Confusão do sistema para as amostras simuladas.	53
5.3	Matriz de Confusão do MLP para as amostras experimentais.	59
5.4	Matriz de Confusão do SVM para as amostras experimentais.	59
5.5	Matriz de Confusão da Árvore de Decisão para as amostras experimentais.	59

Lista de Abreviaturas e Siglas

CA	Corrente Alternada	13
CEE	Curto-circuito entre Espiras	2
DP	Descarga Parcial	5
IA	Inteligência Artificial	6
TC	Transformador de Corrente	3
TP	Transformador de Potência	4
MEF	Método dos Elementos Finitos	6
ML	<i>Machine Learning</i>	4
MLP	Perceptron de Múltiplas Camadas	4
MT	Média Tensão	vii
RBF	<i>Radial Basis Function</i>	25
SVC	<i>Support Vector Classifier</i>	23
SVM	<i>Support Vector Machine</i>	4
SVR	<i>Support Vector Regression</i>	23
THD	Distorção Harmônica Total	46

Sumário

1	Introdução	1
1.1	Motivação e Objetivos	4
1.2	Produções Científicas	5
1.3	Estrutura dos Capítulos Seguintes	6
2	Conceituação Teórica	7
2.1	Transformadores de Potência	8
2.1.1	Transformador de Potência Monofásico	9
2.1.2	Transformador de Potência Trifásico	13
2.2	Transformada de Park	14
2.3	Figura de Lissajous	16
2.4	Algoritmos de Machine Learning	17
2.4.1	<i>Overfitting</i> e Algoritmo de <i>Early Stopping</i>	20
2.4.2	Perceptron de Múltiplas Camadas (MLP)	20
2.4.2.1	Algoritmo de Retropropagação	22
2.4.3	Máquina de Vetor Suporte (SVM)	23
2.4.3.1	Função de <i>Kernel</i>	24
2.4.3.2	Hiperparâmetro C	25
2.4.4	Árvore de Decisão	26
2.4.4.1	Critérios de Ajuste	26
3	Metodologia	28

3.1	Banco de Dados de Treinamento Sintético	28
3.2	Método do Vetor de Park aplicado para diagnóstico de Curto-Circuito entre Espiras (CEE)	30
3.2.1	Correntes Diferenciais	31
3.2.2	Transformada de Park e Figura de Lissajous	32
3.2.3	Parametrização da Elipse	33
3.3	Métricas de Avaliação para Algoritmos de Classificação Binária	34
3.4	Arquitetura dos Modelos de Machine Learning	36
3.4.1	Perceptron de Múltiplas Camadas (MLP)	37
3.4.2	Classificador de Vetor de Suporte (SVC)	38
3.4.3	Árvore de Decisão	39
4	Validação Preliminar	41
4.1	Caso Sadio e de Carga Equilibrada	41
4.2	Casos de Carga Desbalanceada	43
4.3	Caso com Curto-circuito entre Espiras	45
4.4	Carga com Distorção Harmônica	46
5	Resultados e Discussão	50
5.1	Transformador Trifásico de Média Tensão	50
5.2	Corpo de Prova: Autotransformador Trifásico	54
5.3	Discussão	60
6	Conclusões e Trabalhos Futuros	62
6.1	Conclusão	62
6.2	Pesquisas Futuras	63
	Referências	64

Capítulo 1

Introdução

Os Transformadores de Potência (TPs) desempenham um papel central na infraestrutura global de fornecimento de energia elétrica, sendo responsáveis pela transmissão e distribuição de eletricidade. Eles representam um dos ativos de maior custo em um projeto de subestação e são vulneráveis a vários tipos de falhas, que podem resultar em danos e interrupção no fornecimento de energia da planta.

Em contextos desafiadores, como as plataformas de exploração de petróleo e gás localizadas em áreas *offshore*, o bom desempenho de sua operação é ainda mais crítico. Estes equipamentos asseguram que a energia elétrica seja convertida e entregue de maneira eficiente, suprimindo as demandas energéticas necessárias para manter as operações em alto-mar. Nesse contexto, é evidente a necessidade de compreender e aprimorar o desempenho desses dispositivos, uma vez que eles desempenham papel central na confiabilidade, segurança e produtividade das atividades relacionadas ao setor de O&G.

Em específico, os transformadores a seco utilizam o ar ambiente como meio de resfriamento e isolamento. Entre suas vantagens, as mais relevantes para a indústria de O&G são os menores custos de manutenção e a ausência de óleo inflamável, garantindo menores riscos de incêndio. À medida que as plantas elétricas *offshore* se tornam mais complexas, há uma demanda crescente por transformadores a seco com maior capacidade de energia. Neste contexto, esses transformadores oferecem vantagens significativas em termos de segurança e confiabilidade [1]. Além disso, usufruem de benefícios como maior resistência mecânica, maior chance de estabelecimento próximo ao ponto de carga, não necessita de poços de infusão de transformadores para sortimento de óleo, supervisão de óleo, armazéns de combate a incêndio, divisórias corta-fogo e o mínimo grau de descargas parciais internas devido ao seu encapsulamento a vácuo. No entanto, este tipo de equipamento têm custos mais altos e limites de potência e tensão mais baixos. A Figura 1.1 mostra

um transformador a seco de média tensão, como exemplo.



Figura 1.1: Transformador a Seco de Média Tensão

Fonte: <https://www.brval.com.br/produtos/transformador-a-seco-de-media-tensao>

Porém, ao mesmo tempo que transformadores de energia são reconhecidamente ativos de alto custo, sua susceptibilidade a modos de falha representa um risco significativo de danos e interrupções no fornecimento de energia. Assim como outros equipamentos, os transformadores sofrem envelhecimento como consequência natural de sua operação. Sua consequência mais significativa é a degradação gradual do isolamento devido a efeitos térmicos e tensões mecânicas resultantes de interações eletromagnéticas entre as espiras do enrolamento. Além disso, os transformadores são suscetíveis a curtos-circuitos, que induzem tensões eletromecânicas intensas nos enrolamentos, bem como sobretensões decorrentes de manobras como energização de linha ou presença de cargas indutivas ou capacitivas. Esses fatores elevam o estresse dielétrico nos materiais isolantes e nas conexões, podendo ultrapassar seus limites de projeto.

A falha mais comum nesse tipo de equipamento é a falha de isolamento, onde as falhas nos enrolamentos representam sozinhas 49% de todas as falhas em transformadores, sendo o Curto-circuito entre Espiras (CEE) uma das causas mais significativas de falhas nos enrolamentos [2]. A propagação de falhas sob operação prolongada em estado defeituoso leva à perda de regulação, diminuição da eficiência e, em última instância, culmina em

um evento de curto-circuito, resultando em desligamento completo e danos graves aos enrolamentos do transformador.

A necessidade de sistemas de diagnóstico cada vez mais rápidos e precisos tem aumentado devido ao uso desse tipo de equipamento em redes críticas, como as plataformas de O&G, o que tem levado a um crescimento correspondente na literatura sobre o assunto [3, 4]. Monitorar efetivamente a condição operacional de tais transformadores é uma ferramenta estratégica para melhorar a confiabilidade, robustez e segurança do sistema elétrico, ao mesmo tempo em que potencialmente reduz os gastos gerais com manutenção. A manutenção preventiva se beneficia do diagnóstico da condição do isolamento para detectar problemas potenciais que possam levar a desligamentos críticos no futuro. Como resultado deste desafio, pesquisas extensas têm sido realizadas para desenvolver técnicas de diagnóstico e metodologias de monitoramento para esses dispositivos [5].

Visando uma alternativa ao encontrado na literatura, é desenvolvida uma solução para monitoramento e diagnóstico de transformadores a seco com invólucro de proteção IP23, que é replicável e apresenta hardware independente do fabricante. Os diagnósticos *online* envolvem a conexão do dispositivo desenvolvido ao transformador, com suas informações acessíveis a um computador no campo. Um programa de código aberto auxiliará o operador no processo de diagnóstico, dado que, após o tempo necessário para aquisição e análise de dados, os resultados do estado operativo do equipamento serão exibidos na tela para facilitar a avaliação e o suporte à tomada de decisão. A solução incorpora capacidades abrangentes de diagnóstico, permitindo a melhoria contínua dos algoritmos de diagnóstico e fornecendo análises confiáveis às equipes de manutenção.

A solução desenvolvida utiliza tecnologias de hardware e software de ponta para o monitoramento e diagnóstico de transformadores a seco no campo. A arquitetura do sistema, conforme ilustrado na Figura 1.2, consiste em sensores integrados ao sistema de aquisição de dados, módulos de comunicação e um notebook equipado com o sistema de diagnóstico capaz de apresentar indicadores e fazer inferências sobre a condição atual do transformador monitorado. O sistema de aquisição de dados é projetado para medir variáveis elétricas com dois objetivos principais: monitorar o equipamento e amostrar correntes para fazer inferências sobre o estado atual do dispositivo considerando CEE. Para alcançar isso, o sistema de diagnóstico processa medições de corrente obtidas de cada Transformador de Corrente (TC) localizados tanto no enrolamento primário quanto no secundário. Essas medições são então usadas para inferir o estado do transformador, especificamente se está operando normalmente ou experimentando CEE.

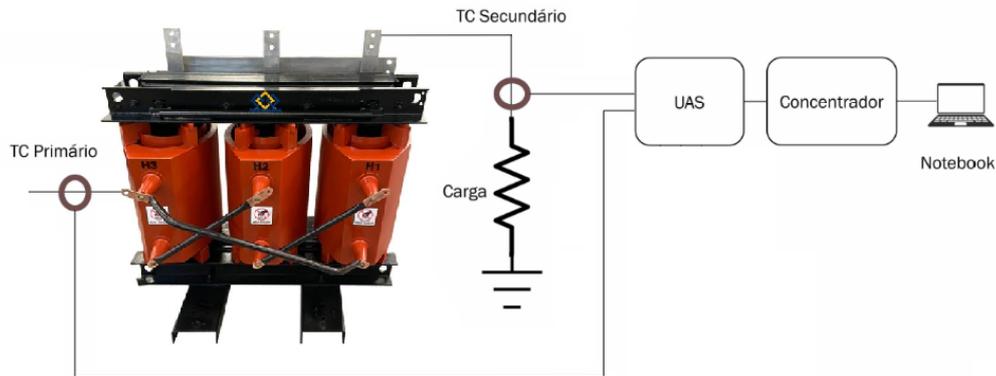


Figura 1.2: Arquitetura da solução do sistema para diagnóstico de CEE.

1.1 Motivação e Objetivos

A identificação antecipada de CEE em um Transformador de Potência (TP) a seco é um passo importante para aumentar a segurança e a confiabilidade destes equipamentos. Essa ocorrência pode ocasionar danos significativos nos enrolamentos do transformador, potencialmente levando à falha prematura e até incêndios, caso não seja detectada e tratada prontamente. Nesse contexto, modelos clássicos de *Machine Learning* (ML) para classificação têm o potencial de ser empregados na detecção de CEE em transformadores a seco, utilizando dados de corrente e tensão do transformador para identificar padrões anômalos indicativos de CEE. Dentre eles, destacam-se o Perceptron de Múltiplas Camadas (MLP), *Support Vector Machine* (SVM) e Árvore de Decisão [6, 7, 8].

No início da operação do transformador, é esperado um alto índice de operações normais sem CEE, porém, prevê-se uma redução dessa probabilidade ao longo do tempo, devido à exposição do transformador a tensões operacionais e eventos climáticos. Assim, essa probabilidade torna-se um indicador essencial do estado operacional do transformador, permitindo a construção de um registro histórico detalhado, atualizado conforme novos dados são coletados ao longo da vida útil do equipamento.

Nesse contexto, esta dissertação aborda a concepção, técnicas de processamento de dados, algoritmos de ML e testes preliminares de um sistema de monitoramento e diagnóstico. O principal resultado é a criação, análise e documentação de uma solução aplicável a diversos transformadores a seco do setor de O&G. A metodologia proposta visa a replicação em diferentes especificações de transformadores, variando somente os modelos de simulação para o treinamento. A independência de hardware refere-se à capacidade da solução em aderir a protocolos padronizados, permitindo sua aplicação por diversos

fabricantes. O sistema proposto tem como objetivo fornecer diagnósticos *online* do estado operacional do transformador, proporcionando previsibilidade em relação à sua condição e oferecendo suporte às decisões durante a operação.

1.2 Produções Científicas

Até o momento, a presente dissertação serviu como base para a produção de três trabalhos científicos que exploram as técnicas de tratamento de dados e aprendizado de máquina aplicadas ao sistema de monitoramento e diagnóstico de transformadores a seco com invólucro de proteção IP23.

- **Monitoring and Diagnostic System for Dry-type Transformers Using Machine Learning Techniques.** F. Martins, Y. Lopes, B. França, V. Ferreira, G.G. Sotelo, A.A. Augusto, A.C. Colombini, A.C. Pinho, M. Mello, M. Costa, C. Nogueira, N. da Silva, A. Melo, A. Soares, Universidade Federal Fluminense; D. Fernandes, Nowy Tecnologia. <http://dx.doi.org/10.4043/32700-MS>

Este artigo foi publicado e apresentado durante a Offshore Technology Conference Brasil - OTC2023 em 26/10/2023. Nele, o sistema de diagnóstico é discutido de maneira abrangente, destacando sua aplicação na indústria de O&G. O trabalho inclui a abordagem da detecção e concentração de dados relacionados à Descarga Parcial (DP).

- **An Autonomous Machine Learning-Based System for Dry-type Transformers Inter-Turn Short Circuit Detection.** Mateus Caruso, Marília Novais e Silva, Cauê Nogueira, Arthur Zopellaro, Vitor Hugo Ferreira, Flávio G. Martins, Yona Lopes, André Pinho, Angelo Colombini, Andre Abel Augusto, Guilherme G. Sotelo e Bruno W. França.

Este artigo está submetido à revista “*Expert Systems With Applications*”, publicada pela Elsevier, sob o código ESWA-D-23-12964. Similar à presente dissertação, o artigo concentra-se no tratamento de dados e nos algoritmos de ML empregados no sistema de diagnóstico. Encontra-se atualmente em processo de revisão.

- **Monitoring and Diagnostic System for Dry-type Transformers Inter-Turn Short Circuit Detection.** Mateus Caruso, Marília Novais e Silva, Cauê Nogueira, Arthur Zopellaro, Vitor Hugo Ferreira, Flávio G. Martins, Yona Lopes, André Pinho, Angelo Colombini, Andre Abel Augusto, Guilherme G. Sotelo e Bruno W. França.

Este trabalho foi submetido como capítulo do livro *Digital Technologies for O&G and Renewable Energy – DTOGRE2024*, publicado pela Springer. Está também em etapa de revisão.

1.3 Estrutura dos Capítulos Seguintes

Esta dissertação está organizada em seis capítulos, incluindo o presente Capítulo 1. O Capítulo 2 oferece uma Revisão da Literatura, incorporando referências sobre a teoria de transformadores de potência e das técnicas de tratamento de dados abordadas, descrição teórica dos algoritmos de ML utilizados e seus respectivos parâmetros relevantes para o estudo. A Metodologia é detalhada no Capítulo 3, abrangendo a implementação dos algoritmos e métodos de avaliação do sistema. Esta aborda a criação do banco de dados sintético para treinamento, bem como os algoritmos de ML, variação de parâmetros para escolha dos modelos e técnicas de aprendizado de máquina utilizados para fins de diagnóstico.

Em seguida, o Capítulo 4 faz uma análise do tratamento de dados proposto, utilizando uma simulação simplificada para verificação preliminar da validade do mesmo em diferentes cenários operacionais. O Capítulo 5 apresenta os resultados das inferências do sistema em dois casos de validação. Inicialmente o diagnóstico é feito com base no modelo simulado de transformador prático de MT. Posteriormente, o diagnóstico é realizado em um autotransformador protótipo de bancada. Em ambos casos, os algoritmos de Inteligência Artificial (IA) são treinados com dados sintéticos gerados via Método dos Elementos Finitos (MEF). Por fim, o Capítulo 6 apresenta as conclusões com base nos resultados obtidos até o momento, além de indicar direções para pesquisas futuras. Em seguida são apresentadas as referências bibliográficas.

Capítulo 2

Conceituação Teórica

Uma ampla variedade de métodos para avaliar a condição operacional em TPs é documentada na literatura, abrangendo análises de fenômenos elétricos e químicos. Esta revisão de literatura demonstra a prevalência de pesquisas focadas em transformadores com óleo isolante, com quatro principais tecnologias de suporte de diagnóstico: análise de resposta em frequência [9], análise de gás dissolvido [10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25], análise térmica [26] e análise de descarga parcial [27, 28, 29, 30, 31]. Quanto aos transformadores a seco, duas dessas técnicas são aplicáveis, e, portanto, estudos importantes foram realizados em análise de descarga parcial e análise térmica. A integridade do material dielétrico pode ser estimada por meio de diversos testes, incluindo monitoramento de tensão, corrente, potência aparente, corrente do enrolamento, corrente de descarga à terra e temperatura do enrolamento, entre outros [32, 33, 34, 35]. No entanto, a maioria desses procedimentos diagnósticos é realizada offline, exigindo que o transformador seja retirado de serviço para teste. Essa situação é indesejável na indústria de petróleo e gás, pois pode causar desligamento parcial ou total da planta, resultando em perdas significativas de produção.

Dentro desse campo, a implementação de IA é extensivamente utilizada para aprimorar a eficiência dos sistemas de detecção de falhas em áreas relacionadas. O processo de diagnóstico se baseia em regras derivadas tanto do conhecimento experimental quanto de conjuntos de dados que representam com precisão a condição do transformador. Conseqüentemente, as informações essenciais necessárias para o desenvolvimento do sistema podem originar-se de diversas fontes. Abordagens baseadas em conhecimento envolvem autores elaborando um conjunto de regras para analisar a condição operacional do transformador com base em sua compreensão especializada do problema [28, 30, 31, 36, 37, 18, 9]. Abordagens com dados reais utilizam diretamente

dados operacionais de campo do equipamento para construir o sistema de diagnóstico [38, 39, 27, 40, 29, 41, 10, 11, 12, 13, 14, 15, 42, 16, 17, 26, 43, 19, 21, 22, 23, 24, 25]. Abordagens simuladas buscam simular fielmente a condição do transformador, gerando conjuntos de dados que são processados para construir o sistema de diagnóstico [27, 44, 17, 22].

As falhas mais comuns encontradas em TPs estão associadas a problemas de isolamento em seus enrolamentos e buchas. A deterioração do isolamento dos enrolamentos do transformador pode surgir de imperfeições na fabricação, uso de materiais isolantes de baixa qualidade ou envelhecimento natural do material isolante. Esses fatores podem levar ao CEE. A implementação de métodos diagnósticos online que se baseiam no monitoramento de variáveis elétricas tem o potencial de evitar falhas nos TPs [45, 46]. Várias estratégias de detecção online para identificar CEE por meio de monitoramento elétrico foram propostas na literatura. Essas estratégias incluem a análise de ligações de fluxo magnético dentro dos enrolamentos [47, 48], exame de padrões geométricos V-I [49, 50], utilização da transformada de Park nas correntes diferenciais do transformador [51, 52], análise de admitância de sequência positiva [53] e cálculo de correntes de sequência negativa [54]. Entre essas estratégias, o método da transformada de Park demonstrou sensibilidade excepcional na detecção de CEE e na identificação da fase com defeito específica. Uma vantagem desse método é sua independência dos parâmetros do transformador e a exigência de monitorar menos variáveis. Portanto, a decisão foi tomada de empregar o método da transformada de Park para a análise de CEE.

2.1 Transformadores de Potência

Os Transformadores de Potência (TPs) constituem elementos fundamentais no contexto do sistema elétrico de potência, desempenhando um papel de destaque na operação eficiente e confiável de sistemas de transmissão e distribuição de energia elétrica em larga escala. Trata-se de dispositivos eletromagnéticos projetados para executar duas funções básicas: elevar a tensão em subestações de geração, facilitando a transmissão eficaz da eletricidade em longas distâncias, e abaixar a tensão em subestações de distribuição, permitindo sua entrega aos consumidores finais com níveis apropriados de tensão e corrente. A capacidade intrínseca desses TPs de ajustar as grandezas elétricas enquanto preservam a eficiência da transferência de energia, faz deles componentes essenciais da infraestrutura elétrica.

Em sua essência, um transformador é um dispositivo elétrico que opera com base nos

princípios de indução eletromagnética. Este dispositivo é composto por dois ou mais enrolamentos condutores, conhecidos como enrolamento primário e enrolamento secundário, que são mutuamente acoplados por meio de um núcleo de material ferromagnético [55].

Ao se aplicar uma tensão alternada ao enrolamento primário, cria-se um campo magnético alternado dentro do núcleo, cuja amplitude é determinada pela tensão aplicada, pela frequência da fonte de tensão e pelo número de espiras no enrolamento primário. Esse campo magnético alternado, por sua vez, induz uma tensão no enrolamento secundário de acordo com os princípios da lei da indução de Faraday. A magnitude da tensão induzida no enrolamento secundário depende do número de espiras no enrolamento secundário, da intensidade do campo magnético gerado no núcleo e da frequência da tensão aplicada.

A relação de transformação entre o número de espiras no enrolamento primário e no enrolamento secundário é determinada pela proporção entre esses números de espiras e permite ajustar a magnitude da tensão de saída em relação à tensão de entrada, possibilitando uma ampla gama de aplicações em sistemas elétricos.

2.1.1 Transformador de Potência Monofásico

Um TP monofásico é um dispositivo caracterizado por um enrolamento de entrada e um enrolamento de saída, como ilustrado pela Figura 2.1. Fisicamente pode ser construído como duas ou mais bobinas de fio enroladas em torno de um núcleo ferromagnético, nos quais as relações entre as tensões e correntes são governadas por equações fundamentais.

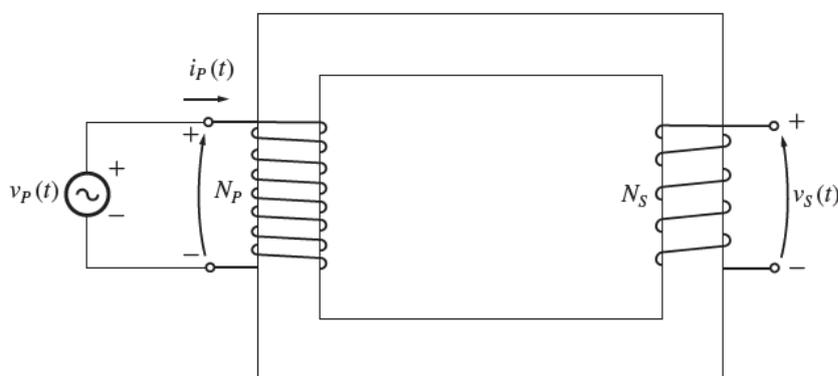


Figura 2.1: Esquema de um transformador monofásico a vazios.
Adaptado de [56]

A fundamentação do funcionamento do transformador pode ser obtida a partir da Lei de Faraday (2.1), onde λ é o fluxo concatenado no enrolamento secundário, descrito pela Equação (2.2). O fluxo concatenado λ é a soma do fluxo que passa através de cada

espira da bobina, porém não pode ser simplesmente descrito pelo fluxo multiplicado pelo número de espiras da bobina ($N\phi$) pois o fluxo é levemente alterado devido à posição da espira dentro da bobina.

$$e_{ind} = \frac{d\lambda}{dt} \quad (2.1)$$

$$\lambda = \sum_{i=1}^N \phi_i \quad (2.2)$$

Deve-se observar que a expressão λ como o produto simples entre o fluxo total e o número de espiras da bobina ($N\phi$) não é adequada, uma vez que o fluxo magnético é modificado levemente devido à disposição específica de cada espira dentro da estrutura da bobina. No entanto, é possível estabelecer a definição de um fluxo magnético médio total, representado por $\bar{\phi} = \lambda/N$. No contexto de um TP monofásico, o fluxo magnético médio em cada enrolamento, denotado como $\bar{\phi}$, pode ser expresso pela Equação (2.3), em que $v(t)$ denota a tensão e N representa o número de espiras do enrolamento. Todavia, é relevante considerar que nem todo o fluxo magnético concatenado por um enrolamento é reciprocamente compartilhado pelo outro, devido à dispersão de algumas linhas de fluxo no ambiente circundante, fenômeno conhecido como fluxo de dispersão (ϕ_D). Portanto, o fluxo médio em um enrolamento é a soma do fluxo mútuo (ϕ_M), que é compartilhado mutuamente por ambas as bobinas, e o fluxo de dispersão do enrolamento (ϕ_D).

$$\bar{\phi} = \frac{1}{N} \int v(t) dt \quad (2.3)$$

Considerando a subdivisão do fluxo médio concatenado em seus componentes de fluxo mútuo e de dispersão, podemos reescrever a Lei de Faraday, conforme expressa na Equação (2.1), para cada enrolamento do TP. Neste contexto, $e(t)$ representa a tensão induzida decorrente do fluxo mútuo, enquanto $e_D(t)$ corresponde à tensão induzida pelo fluxo de dispersão.

$$v(t) = N \frac{d\bar{\phi}}{dt} = N \frac{d\phi_M}{dt} + N \frac{d\phi_D}{dt} = e(t) + e_D(t) \quad (2.4)$$

Na análise das componentes das tensões induzidas devido ao fluxo mútuo ϕ_M , representadas por $e_p(t)$ no caso do enrolamento primário, e $e_s(t)$ para o secundário, é possível expressá-las pelas relações fornecidas na Equação (2.5). A partir dessa análise das tensões induzidas, é evidente que a relação definida pela Equação (2.6) se mantém válida.

$$e_p(t) = N_p \frac{d\phi_M}{dt}, \quad e_s(t) = N_s \frac{d\phi_M}{dt} \quad (2.5)$$

$$\frac{e_p(t)}{N_p} = \frac{d\phi_M}{dt} = \frac{e_s(t)}{N_s} \quad (2.6)$$

$$\alpha = \frac{e_p(t)}{e_s(t)} = \frac{N_p}{N_s} \quad (2.7)$$

Dessa forma, como mostrado pela Equação (2.7), é possível concluir que a relação de transformação α de um TP monofásico é definida como a razão entre o número de espiras do enrolamento primário N_p pelo número de espiras do enrolamento secundário N_s , assim como pela razão entre a tensão primária e a tensão secundária induzidas devido ao fluxo mútuo ϕ_M . Um projeto bem elaborado de TPs busca minimizar o fluxo de dispersão em ambos os enrolamentos, resultando em $\phi_M \gg \phi_D$, minimizando a tensão induzida por dispersão $e_D(t)$ na equação (2.4). Assim, a relação de transformação pode ser aproximada, conforme ilustrado na Equação (2.8). Essa relação é fundamental para estabelecer a correspondência entre as tensões primárias $v_p(t)$ e secundárias $v_s(t)$. Por outro lado, a relação entre as correntes primárias $i_p(t)$ e secundárias $i_s(t)$ segue uma proporção inversa, em conformidade com o princípio da conservação de potência $p_p(t) = p_s(t)$, expresso pela equação $v_p(t)i_p(t) = v_s(t)i_s(t)$ [56].

$$\alpha = \frac{N_p}{N_s} = \frac{v_p(t)}{v_s(t)} = \frac{i_s(t)}{i_p(t)} \quad (2.8)$$

Para a modelagem do comportamento de um transformador real, é fundamental considerar os diversos tipos de perdas que ocorrem no equipamento. As principais categorias de perdas incluem as perdas no cobre, conhecidas como perdas resistivas (I^2R), perdas por corrente parasita, perdas devido à histerese magnética e perdas relacionadas aos fluxos de dispersão.

As perdas no cobre surgem devido ao aquecimento causado pela resistência dos enrolamentos primário e secundário do transformador. As perdas por corrente parasita referem-se ao aquecimento resistivo no núcleo do transformador, resultante das correntes que circulam no núcleo. As perdas por histerese estão associadas às mudanças na configuração dos domínios magnéticos no núcleo do transformador durante cada semiciclo da operação. Essas perdas são altamente não lineares e complexas, dependendo da tensão aplicada ao transformador. Por fim, os fluxos de dispersão, representados por ϕ_D , escapam do núcleo do transformador e atravessam apenas um dos enrolamentos. Esses fluxos ge-

ram uma indutância de dispersão nas bobinas primária e secundária, introduzindo efeitos significativos no desempenho do transformador.

Considerando esses componentes, é viável desenvolver um circuito equivalente que leve em consideração as principais imperfeições associadas aos transformadores reais. Essas imperfeições serão analisadas individualmente, e seus efeitos serão incorporados ao modelo do transformador. O modelo final de um transformador monofásico real é mostrado na Figura 2.2.

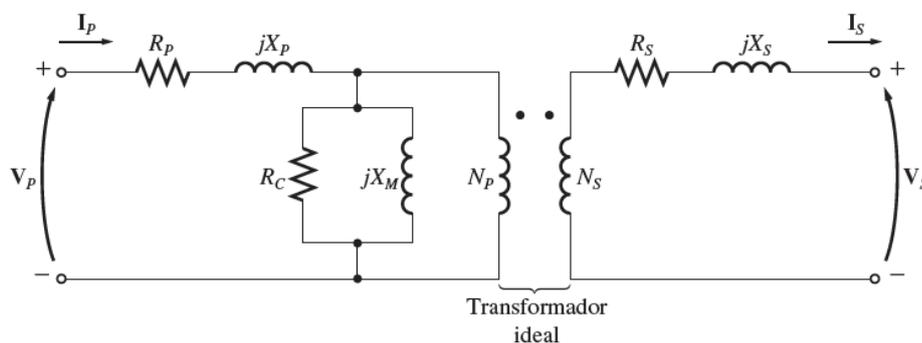


Figura 2.2: Circuito equivalente do modelo de um transformador monofásico real. Adaptado de [56]

Uma das perdas mais simples a serem modeladas são as perdas no cobre (RI^2), que se manifestam como perdas resistivas nos enrolamentos primário e secundário do transformador. Para representar essas perdas, é introduzida uma resistência R_p no circuito do lado primário do transformador e uma resistência R_s no circuito do lado secundário.

A variação do fluxo de dispersão ($\frac{d\phi_D}{dt}$) pode ser representada como uma tensão proporcional à sua taxa de variação no tempo e ao número de espiras no enrolamento. Uma vez que a maior parte do trajeto do fluxo de dispersão ocorre através do ar, que possui uma relutância significativamente maior em comparação com o núcleo, é razoável considerar o fluxo como diretamente proporcional à corrente do enrolamento. Conseqüentemente, o fluxo de dispersão pode ser modelado como um indutor, no qual a indutância é definida como o quadrado do número de espiras multiplicado pela permeância do trajeto do fluxo $L = N^2\mathfrak{P}$. No circuito equivalente mostrado pela Figura 2.2, as indutâncias do primário e secundário são representadas, respectivamente, por jX_p e jX_s .

O comportamento da corrente de magnetização (i_m) em um transformador é tal que, na região não saturada, ela é diretamente proporcional à tensão aplicada ao núcleo, mantendo um atraso de fase de 90° em relação à tensão aplicada. Isso permite que essa corrente seja modelada eficazmente por meio de uma reatância X_M , que é conectada à fonte de tensão do primário do transformador. Da mesma forma, a corrente de perdas

no núcleo (i_{h+p}) é proporcional à tensão aplicada ao núcleo e está em fase com a tensão aplicada. Assim, ela pode ser representada por uma resistência R_C , que também está conectada à fonte de tensão do primário. Vale ressaltar que, na realidade, ambas as correntes não são estritamente lineares, e, portanto, a utilização da indutância X_M e da resistência R_C representa, no máximo, aproximações dos efeitos reais associados à excitação do transformador.

Na prática, para a análise de circuitos que incorporam transformadores, é comum converter o circuito completo em um circuito equivalente que opera em um único nível de tensão. Dessa forma, o circuito equivalente é referido em relação ao seu lado primário ou secundário, dependendo da conveniência e dos objetivos da análise. Isso simplifica a análise e permite que os transformadores sejam tratados de forma mais eficaz em sistemas elétricos e eletrônicos. Neste estudo, o transformador será analisado a partir de seu circuito equivalente referido ao nível de tensão primário, conforme ilustra a Figura 2.3

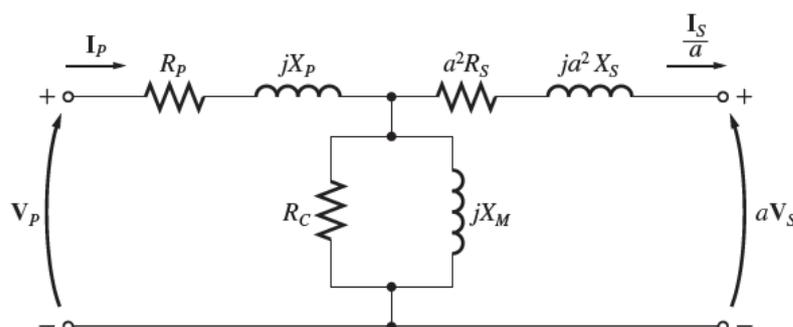


Figura 2.3: Circuito equivalente do modelo de um transformador monofásico referido ao primário.

Adaptado de [56]

2.1.2 Transformador de Potência Trifásico

Atualmente, a maioria dos principais sistemas de geração e distribuição de energia elétrica em todo o mundo adota sistemas trifásicos em Corrente Alternada (CA) como padrão. Desta forma, é fundamental aprofundar a compreensão do emprego de TPs nesse contexto. Os TP trifásicos podem ser implementados de duas maneiras distintas: a primeira opção consiste em conectar três TPs monofásicos em um arranjo trifásico, enquanto a segunda envolve a construção de um único TP trifásico que compreende três conjuntos independentes de enrolamentos em torno de um núcleo compartilhado. Assim, um TP trifásico é composto por três TPs, que podem ser conectados em configurações estrela (Y) ou delta/triângulo (Δ), tanto no lado primário quanto no secundário.

A chave para a análise de um banco de TPs trifásicos reside na inspeção de um único TP monofásico dentro do conjunto, que opera de maneira idêntica ao descrito anteriormente. Desta forma, o circuito equivalente de um transformador trifásico pode ser analisado como 3 circuitos monofásicos conforme mostrado pela Figura 2.3.

O presente estudo concentra-se principalmente na análise da configuração de ligação triângulo-estrela (Δ -Y) em TPs. Essa configuração é caracterizada por apresentar um ponto central (neutro) na ligação Y. Na ligação Δ -Y, as tensões de linha e de fase no enrolamento primário são idênticas ($V_{Lp} = V_{\phi p}$), enquanto as tensões no enrolamento secundário estão relacionadas pela proporção $V_{Ls} = \sqrt{3}V_{\phi s}$. A relação de transformação é definida pela Equação (2.9). Por característica intrínseca do tipo de ligação, a tensão secundária neste transformador é deslocada de 30° em relação à primária.

$$\alpha = \frac{\sqrt{3}V_{Lp}}{V_{Ls}} \quad (2.9)$$

2.2 Transformada de Park

A Transformada de Park é uma técnica utilizada na análise de sistemas elétricos trifásicos simétricos amplamente utilizada em aplicações de controle e proteção. É uma manipulação matemática que permite a representação do sistema trifásico por dois vetores ortogonais denominados componentes direto (D) e quadratura (Q). Os vetores direto e quadratura são obtidas por meio da transformação matemática representada na equação (2.10), que combina as grandezas elétricas de fase permitindo sua separação em dois componentes independentes defasados de 90° entre si. Nesta equação, a constante $\frac{N_{abc}}{N_{\alpha\beta}}$ pode assumir dois valores distintos: $\frac{N_{abc}}{N_{\alpha\beta}} = \frac{2}{3}$, ao se realizar uma transformação de amplitude invariável ($|\vec{i}_{dq}| = |\vec{i}_{abc}|$); $\frac{N_{abc}}{N_{\alpha\beta}} = \sqrt{\frac{2}{3}}$ caso a transformação seja aplicada de forma a manter potência invariável ($P_{dq} = P_{abc}$) [57].

$$\begin{bmatrix} i_d \\ i_q \end{bmatrix} = \frac{N_{abc}}{N_{\alpha\beta}} \begin{bmatrix} \cos(\rho) & \cos(\rho - \frac{2\pi}{3}) & \cos(\rho - \frac{4\pi}{3}) \\ \sin(\rho) & \sin(\rho - \frac{2\pi}{3}) & \sin(\rho - \frac{4\pi}{3}) \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} \quad (2.10)$$

As técnicas baseadas na transformada de Park têm sido amplamente empregadas pela literatura para o diagnóstico de falhas em equipamentos elétricos de potência, principalmente em motores de indução e transformadores. [58] apresenta uma revisão abrangente das alternativas para detectar e diagnosticar falhas em máquinas de indução. O artigo destaca o desenvolvimento de métodos de detecção de falhas online e sem a necessidade

de sensores, marcando uma mudança significativa em relação aos métodos tradicionais. Essas técnicas oferecem a capacidade de detecção de falhas em tempo real, permitindo a manutenção proativa. O artigo compara essas abordagens com base na quantidade de informações necessárias, na variedade de falhas detectáveis, na antecipação de falhas e na precisão do diagnóstico.

Uma análise do estado da arte na detecção de curtos-circuitos entre espiras nos enrolamentos de transformadores de potência é apresentada em [2]. O estudo compara as alternativas para detectar esse tipo de defeito, considerado recorrente nos enrolamentos dos transformadores. São discutidas técnicas de diagnóstico de falhas baseadas no monitoramento de variáveis elétricas, como a análise do diagrama de locus, o uso da admitância de sequência positiva e variáveis obtidas a partir da Transformada de Park. A pesquisa destaca o surgimento de estratégias de diagnóstico online, que representam uma evolução em relação aos testes offline tradicionais.

Em [59], é apresentada uma abordagem avançada que se concentra na detecção de falhas em rolamentos por meio da análise da modulação da corrente do estator. Os experimentos abrangem tanto defeitos localizados quanto distribuídos, demonstrando a eficácia dessa técnica na detecção de falhas incipientes em rolamentos. Esta abordagem é aprofundada em [60], onde o diagnóstico de falhas em enrolamentos do estator, especificamente em unidades de armazenamento bombeado de velocidade variável, é abordado. Em [61], uma nova abordagem combina as Transformadas de Hilbert e Park para criar duas assinaturas de falha: o Vetor Espacial da Corrente do Módulo Hilbert (HMCSV) e o Vetor Espacial da Fase Hilbert (HPCSV). Essas assinaturas de falha são analisadas usando a Transformada Rápida de Fourier (FFT) para detecção de falhas mecânicas, como excentricidade da folga de ar e defeitos no rolamento da pista externa. O estudo demonstra a eficácia da Transformada de Hilbert-Park no diagnóstico de condições de falha mecânica em motores de indução.

Em [62], é apresentada uma técnica de detecção de defeitos incipientes e não invasivos em transformadores de potência. A abordagem envolve o uso de bobinas de efeito Rogowski e a Transformada Wavelet Discreta para monitorar descargas parciais e problemas sutis. Um equipamento específico é descrito, demonstrando a aplicação prática da técnica. Além disso, [63] realiza uma comparação entre dois dos métodos mais sensíveis para detectar defeitos de baixo nível entre espiras nos enrolamentos de transformadores trifásicos. Os métodos avaliados são o componente de sequência negativa e os algoritmos de proteção baseados em vetores espaciais. Os resultados indicam que a abordagem de

vetores espaciais é ligeiramente mais sensível para detectar defeitos de baixo nível entre espiras, enquanto para defeitos mais graves, a sensibilidade da detecção de falhas de ambos os métodos é similar.

O método proposto em [60] baseia-se na análise da trajetória do vetor da Transformada de Park da corrente do estator, como destaca. Durante a operação ideal sem falhas, essa trajetória forma uma circunferência perfeita, mas quando ocorre uma falha, o formato da curva resultante se apresenta como uma elipse. Este método demonstra eficácia na detecção de falhas sutis e é capaz de identificar falhas de curto-circuito no enrolamento do estator, mesmo em condições de desequilíbrio de tensão e flutuações de carga. Esta mesma abordagem é proposta por [64] como a “Ovalidade do Locus dos Vetores de Park”. É definida como uma característica de falha robusta que pode identificar falhas entre espiras nas bobinas do estator de Geradores de Indução com Rotor de Dupla Alimentação (DFIG). Esta abordagem é resistente ao desequilíbrio de tensão e flutuações de carga, tornando-a adequada para aplicações *offshore*.

Esses estudos contribuem para o avanço das técnicas de diagnóstico de falhas em transformadores de potência, promovendo a detecção precoce de defeitos e, conseqüentemente, a melhoria da confiabilidade e eficiência operacional desses equipamentos críticos no sistema elétrico. Neste contexto, a Transformada de Park em conjunto com a diferenciação das correntes elétricas trifásicas entre os enrolamentos primário e secundário se apresenta como uma abordagem comum no âmbito do diagnóstico de transformadores de potência trifásicos. Esse procedimento possibilita a simplificação da análise dos sistemas trifásicos uma vez que as grandezas elétricas são representadas em um sistema de coordenadas bidimensional (dq) no lugar do sistema tridimensional (abc) convencional.

2.3 Figura de Lissajous

As Figuras de Lissajous são um conjunto de padrões gráficos que surgem quando dois osciladores harmônicos estão interconectados e oscilam perpendicularmente entre si. Essas figuras, nomeadas em homenagem ao matemático francês Jules Antoine Lissajous, são amplamente estudadas em física, matemática e engenharia devido à sua capacidade de ilustrar relações complexas entre frequências e fases. Elas desempenham um papel fundamental na análise de sistemas dinâmicos e na caracterização de oscilações complexas.

São geradas plotando as posições dos osciladores em coordenadas cartesianas, onde um oscilador controla o eixo x e o outro o eixo y . Dependendo das frequências relativas e

das fases iniciais dos osciladores, diferentes padrões podem emergir. Estes padrões podem variar de simples elipses e círculos a figuras altamente complexas e assimétricas. A análise desses padrões fornece informações valiosas sobre as relações de fase e frequência entre os osciladores, sendo usada em áreas que vão desde a física de partículas até a eletrônica e música. As Figuras de Lissajous também têm aplicações práticas em diversas disciplinas. Na eletrônica, elas são usadas na calibração de osciloscópios e medição de diferenças de fase e frequência entre sinais. Na física, elas podem descrever o movimento harmônico de partículas carregadas em campos elétricos e magnéticos.

Considerando que as equações (2.11) e (2.12) descrevem os movimentos em cada eixo, onde A e B representam as amplitudes dos sinais, f_x e f_y são as frequências e ϕ denota a defasagem relativa entre os sinais, é possível compreender a Figura de Lissajous como o traçado resultante desses dois movimentos em quadratura [65]. Considerando ainda cada movimento como um vetor, a soma vetorial resultante também é um vetor com origem fixa em $(0, 0)$, e a extremidade desse vetor desenha a figura característica de Lissajous.

$$x(t) = A \cdot \text{sen}(2\pi f_x t) \quad (2.11)$$

$$y(t) = B \cdot \text{sen}(2\pi f_y t + \phi) \quad (2.12)$$

A figura 2.4 mostra o traçado das figuras de Lissajous para diferentes parâmetros. As linhas são definidas por diferentes razões entre as frequências e as colunas são caracterizadas por variações na defasagem entre os sinais. Essa abordagem é empregada em conjunto com a Transformada de Park, em que a componente direta é representada como $x(t)$ na Equação (2.11), e a componente em quadratura é denotada como $y(t)$ na Equação (2.12). Esse conjunto de técnicas é amplamente adotado na literatura abordada, conforme documentado em diversos estudos [2, 58, 59, 60, 61].

2.4 Algoritmos de Machine Learning

O Aprendizado de Máquina, ou *Machine Learning* (ML), é um subcampo da IA que se concentra no desenvolvimento de algoritmos e modelos que permitem aos sistemas de computador aprender e melhorar a partir de dados. Em vez de serem explicitamente programados para executar uma tarefa específica, os sistemas de ML são projetados para analisar dados, identificar padrões e tomar decisões com base nesses padrões. O foco do ML está na capacidade dos algoritmos se adaptarem e melhorarem com a exposição a dados novos e variados. Isso é feito através do treinamento do modelo em um conjunto de

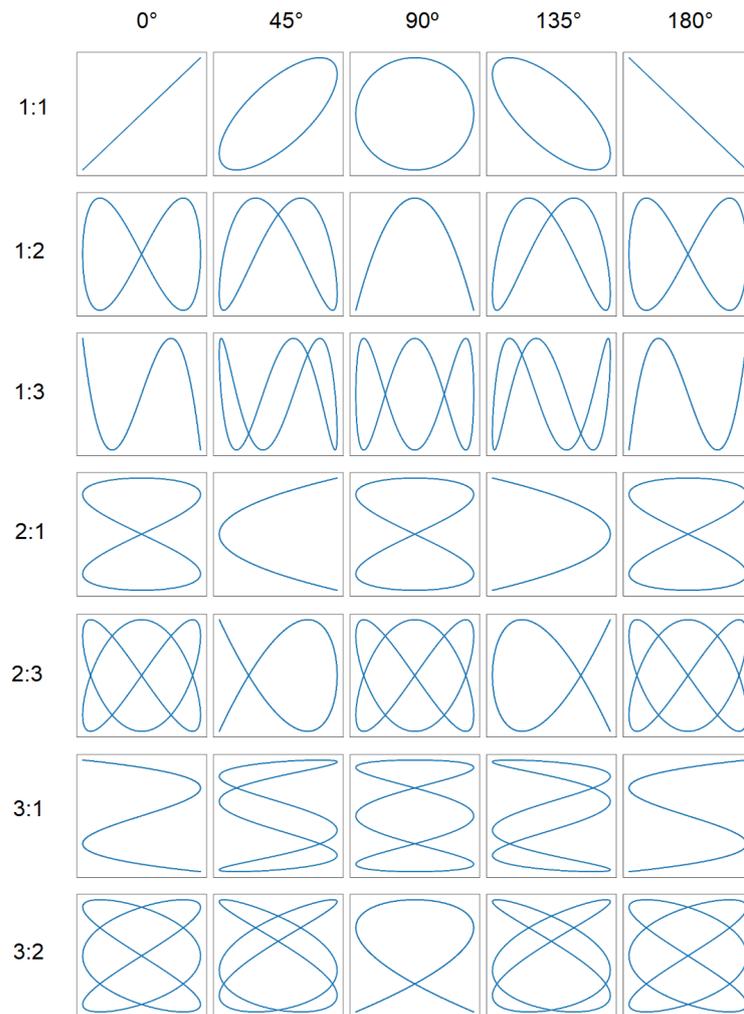


Figura 2.4: Figuras de Lissajous com razões de frequência e defasagens variadas.

dados de treinamento, onde o algoritmo ajusta seus parâmetros internos para encontrar correlações e padrões nos dados. Uma vez treinado, o modelo pode ser usado para fazer previsões ou tomar decisões sobre novos dados que não foram incluídos no conjunto de treinamento [6, 7].

O ML tem aplicações em uma ampla variedade de campos, como reconhecimento de padrões, processamento de linguagem natural, visão computacional, medicina, finanças, automação industrial, entre outras. Nesta área, os algoritmos podem ser categorizados em diferentes paradigmas de aprendizado, cada um com suas abordagens distintas. Estes são divididos entre três abordagens principais que guiam o desenvolvimento e a aplicação desses algoritmos:

- **Aprendizado supervisionado** é um tipo de aprendizado no qual o algoritmo é treinado com um conjunto de dados que inclui amostras rotuladas. Estas amostras

consistem em pares de entrada e saída, onde a saída desejada, ou rótulo, é associada a cada entrada. O objetivo do aprendizado supervisionado é que o algoritmo aprenda a mapear as entradas para as saídas, de modo que, quando apresentado a novos dados não rotulados, ele seja capaz de fazer previsões ou classificações precisas. Esta técnica será utilizada para o treinamento dos algoritmos de ML neste trabalho [66, 67].

- **Aprendizado não supervisionado** é uma abordagem na qual um algoritmo é treinado para encontrar padrões nos dados sem a orientação de rótulos ou categorias predefinidas. O objetivo é descobrir estruturas intrínsecas nos dados sem saber de antemão quais são essas estruturas. Isso pode envolver tarefas como clusterização, redução de dimensionalidade ou análise de componentes principais. Estas técnicas são frequentemente usadas em situações em que não há informações prévias sobre as categorias ou grupos que os dados podem formar. Exemplos de aplicação incluem segmentação de clientes com base em seus padrões de compra, agrupamento de documentos semelhantes em um conjunto de dados de texto e redução de dimensionalidade para visualização de dados em gráficos de dispersão [68].
- **Aprendizagem por reforço** é um tipo de aprendizado no qual o agente interage com o ambiente e aprende a tomar ações que maximizem uma recompensa cumulativa ao longo do tempo. Se assemelha ao processo de aprendizagem humano, onde as pessoas aprendem a tomar decisões através de tentativa e erro, recebendo *feedback* positivo ou negativo com base em suas ações. O agente explora o ambiente, experimentando diferentes ações e ajustando sua política com base nas recompensas recebidas. Existem diferentes tipos de aprendizagem por reforço, como os algoritmos Q-Learning, SARSA, ou métodos de aprendizado profundo, como o Deep Q-Network (DQN). Este é usado em diferentes aplicações, como jogos, robótica, controle de processos industriais, otimização de recursos, etc [69, 70].

As técnicas de ML e os métodos de aprendizado utilizados neste trabalho são implementados por meio de algoritmos de ML. As seções subsequentes apresentam os conceitos abordados de ML, além da conceituação teórica dos modelos de ML adotados. Cada modelo é descrito, incluindo seus princípios, estruturas subjacentes e contextos de aplicação.

2.4.1 *Overfitting* e Algoritmo de *Early Stopping*

O sobreajuste (*overfitting*) é um fenômeno comum em modelos de aprendizado de máquina, ocorrendo quando um modelo é treinado em um conjunto de dados específico de maneira tão detalhada que começa a capturar o ruído e os detalhes específicos desse conjunto, em vez de aprender os padrões gerais subjacentes aos dados. É um efeito indesejado porque, embora o modelo possa apresentar um desempenho excepcional nos dados de treinamento, ele pode falhar ao lidar com novos dados que não foram vistos durante o treinamento. Ou seja, o modelo se ajusta excessivamente aos dados de treinamento, perdendo a capacidade de generalização.

Para evitar o sobreajuste, são utilizadas técnicas como validação cruzada, redução da complexidade do modelo, aumento de dados (*data augmentation*) e o uso de estratégias, como o algoritmo de *Early Stopping*, que interrompe o treinamento quando o desempenho em um conjunto de validação para de melhorar, impedindo assim que o modelo se ajuste demais aos dados de treinamento.

O *Early Stopping* opera monitorando o desempenho do modelo em um conjunto de validação durante o processo de treinamento. Caso a melhoria no desempenho desse modelo no conjunto de validação se estabilize ou comece a deteriorar, interrompe-se o treinamento antes que o modelo se ajuste excessivamente aos dados de treinamento. A premissa subjacente ao *Early Stopping* é que, à medida que o treinamento avança, é esperado que o desempenho no conjunto de validação atinja um ponto máximo e, posteriormente, comece a declinar à medida que o modelo tende a sobreajustar. Assim, interromper o treinamento nesse estágio pode resultar em um modelo mais generalizado e com melhor desempenho em novos conjuntos de dados.

2.4.2 Perceptron de Múltiplas Camadas (MLP)

Os perceptrons são modelos básicos de redes neurais concebidos inicialmente para problemas de classificação binária. O modelo do perceptron é inspirado no funcionamento do neurônio biológico, consistindo em um combinador linear seguido de uma função de ativação [7]. O primeiro perceptron classificador tinha como objetivo classificar em duas classes um conjunto de estímulos aplicados utilizando uma função de ativação limitadora do tipo degrau. Assim, esse modelo constrói um mapa m -dimensional para as m variáveis de entrada, separando as regiões (classes) através de um hiperplano definido pelos pesos sinápticos w_{ij} , que podem ser ajustados a cada iteração através de uma regra para correção

de erro conhecida como Algoritmo de Convergência do Perceptron.

No entanto, sua capacidade de solução é limitada devido à sua arquitetura linear. Para superar essas limitações, foi desenvolvido o MLP, que permite resolver problemas mais complexos. O MLP consiste em uma estrutura onde são adicionadas uma ou mais camadas intermediárias de neurônios entre as camadas de entrada e saída. Cada neurônio na camada intermediária é responsável por calcular uma combinação linear dos pesos e entradas, seguido por uma função de ativação não-linear. A saída da camada intermediária é usada como entrada para a próxima camada ou para a camada de saída.

A função de ativação de um MLP é uma função matemática que determina a saída de cada neurônio da rede a partir da sua entrada. Ela é usada para regular a magnitude da saída de cada neurônio e, assim, controlar a atividade dos neurônios na rede. Algumas funções de ativação comuns em MLPs incluem a função sigmoide [71], ReLU (função de retificação linear) [72], tangente hiperbólica [73], entre outras [74]. A seleção da função de ativação adequada depende do problema a ser solucionado e do tipo de dados de entrada. Essa função é responsável por introduzir a não-linearidade na modelagem, permitindo que o MLP seja capaz de resolver problemas que possuem essa natureza.

Em específico, a função tangente hiperbólica é uma função de ativação não linear que produz saídas entre -1 e 1. É uma função *S-shaped* semelhante à sigmoide, a qual apresenta saídas entre 0 e 1. Por ser uma função ímpar, isto é, apresentando simetria tanto no eixo das abscissas quanto no das ordenadas, a função tangente hiperbólica é uma escolha adequada para problemas de classificação multi-classe, em que as saídas de múltiplas classes precisam ser distintas e separadas. A Figura 2.5 apresenta um gráfico dessas duas funções. A função tangente hiperbólica é dada pela equação (2.13) onde $\sigma(x)$ é a função sigmoide.

$$\tanh(x) = 2\sigma(2x) - 1 \quad (2.13)$$

O objetivo do treinamento do MLP é ajustar os pesos dos neurônios para que a saída da rede seja próxima dos valores alvo. Isso é realizado por meio de algoritmos de otimização, como o gradiente descendente, que ajustam os pesos de forma iterativa a partir dos erros calculados entre a saída da rede e os valores alvo. A equação (2.14) denota a atualização dos pesos sinápticos da rede, onde w_{ij} é o peso da conexão entre o neurônio i e j , Δw_{ij} é a atualização dos pesos, η é a taxa de aprendizado, δ_j é o erro do neurônio j e x_i é a entrada para o neurônio i .

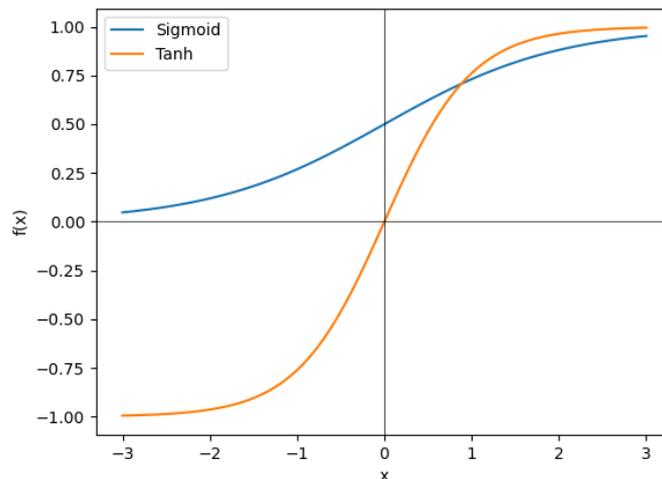


Figura 2.5: Funções Sigmoide e Tangente Hiperbólica.

$$w_{ij} = w_{ij} + \Delta w_{ij} = w_{ij} + \eta \cdot \delta_j \cdot x_i \quad (2.14)$$

O MLP é amplamente utilizado em diversas áreas, como reconhecimento de padrões, processamento de linguagem natural, análise financeira e muito mais. Devido à sua capacidade de resolver problemas não lineares, ele é amplamente utilizado para resolver problemas de aprendizado supervisionado, como classificação e regressão. Além disso, o MLP é uma rede neural robusta e pode ser treinada com grandes conjuntos de dados, tornando-o uma escolha popular para soluções de IA.

2.4.2.1 Algoritmo de Retropropagação

O algoritmo de retropropagação é uma técnica de aprendizado supervisionado amplamente utilizada para treinar redes neurais *feedforward*, como o MLP. Ele funciona através da atualização dos pesos da rede baseada no erro entre a saída prevista e a saída desejada. A ideia básica do algoritmo é propagar o erro de saída através da rede, ajustando os pesos a cada iteração, até que o erro total seja minimizado. É implementado através do cálculo do gradiente do erro em relação aos pesos da rede. O gradiente é então usado para atualizar os pesos da rede usando uma técnica de otimização, como o gradiente descendente. A atualização dos pesos é repetida várias vezes até que o erro total seja minimizado ou até que um critério de parada seja alcançado.

Um dos principais benefícios do algoritmo de retropropagação é sua eficiência e capacidade de lidar com grandes conjuntos de dados. Ele também é altamente flexível e pode ser aplicado a uma ampla gama de problemas, incluindo classificação e regressão. No en-

tanto, é importante notar que o algoritmo pode convergir para mínimos locais ou ocorrer o fenômeno do *overfitting*, ou seja, ajuste excessivo dos dados de treinamento e baixa assertividade para outros pontos, dependendo da estrutura da rede e dos hiperparâmetros usados.

Concluindo, o algoritmo de retropropagação é uma ferramenta importante para o treinamento de redes neurais *feedforward* e é amplamente utilizado em muitas aplicações de IA. Embora possa ter limitações, é uma abordagem poderosa e eficiente que permite a minimização do erro de saída da rede.

2.4.3 Máquina de Vetor Suporte (SVM)

A Máquina de Vetor Suporte, ou SVM, é uma técnica de ML poderoso e amplamente utilizado na área de aprendizado de máquina. Ele foi introduzido pela primeira vez no início dos anos 90 por Vapnik e Cortes [75], e desde então tem sido aplicado a uma ampla variedade de problemas. O conjunto de técnicas SVM é composto pelas técnicas *Support Vector Classifier* (SVC), que utiliza a metodologia do SVM para problemas de classificação, e *Support Vector Regression* (SVR) para problemas de regressão.

As SVMs baseiam-se no conceito do ajuste de um hiperplano que separe duas classes em um conjunto de dados. O hiperplano é escolhido de tal maneira que maximiza a margem, que é a distância entre o plano e os pontos de dados mais próximos de cada classe. Essa abordagem é motivada pelo fato de que o classificador de margem máxima tem fortes propriedades de generalização, o que significa que é menos provável de causar superajuste (*overfitting*) dos dados de treinamento. O problema de otimização que precisa ser resolvido para encontrar o hiperplano de margem máxima pode ser formulado como um problema de programação quadrática. Uma vez resolvido, a função de decisão da SVM é dada por uma combinação linear das variáveis de entrada considerando os parâmetros do hiperplano, que são os vetores de suporte. Vale destacar que o hiperplano ajustado é sempre de 1 dimensão inferior à dimensionalidade da base de treinamento. Ou seja, considerando uma base n -dimensional, o número de dimensões do traçado do hiperplano será $n - 1$.

Há diversas variantes do algoritmo SVM, incluindo a SVM de margem suave, que permite alguma classificação incorreta dos dados de treinamento, e a SVM de múltiplas classes, que estende o caso de classificação binária para os casos onde há mais de duas classes. Na literatura, as SVMs são aplicadas a uma ampla variedade de problemas, como, por exemplo, classificação de texto, onde as SVMs são usadas para classificar

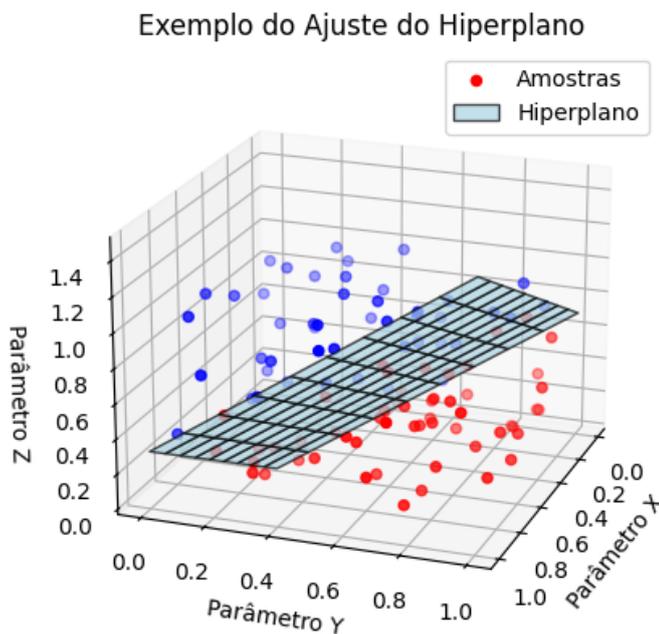


Figura 2.6: Exemplo do ajuste de um Hiperplano 2D na base de treinamento 3D.

documentos com base em seu conteúdo; para reconhecimento de imagens, onde são capazes de classificar imagens com base em suas características; e na bioinformática, onde as SVMs são usadas para prever a estrutura de proteínas e classificar sequências de DNA.

2.4.3.1 Função de *Kernel*

Uma das principais características das SVMs é a capacidade de lidar com limites de decisão não lineares através do uso da técnica de *kernel*. O *kernel* é uma função matemática que transforma os dados de entrada de um espaço original para outro espaço, conhecido como espaço de características. Esta técnica mapeia as variáveis de entrada para um espaço de dimensão superior, onde os dados podem ser separáveis linearmente. Isso é alcançado substituindo o produto interno dos recursos de entrada por uma função *kernel*, que calcula o produto escalar em um espaço de dimensão superior sem realmente calcular as coordenadas dos dados nesse espaço.

Conforme previamente mencionado, o objetivo da SVM é encontrar um hiperplano de separação que maximiza a margem entre as classes. No entanto, em muitos casos, os dados não são linearmente separáveis e, neste caso, o uso de uma função *kernel* pode transformar os dados de tal forma que eles se tornem linearmente separáveis. As funções

kernel mais comuns usadas em SVM incluem *Radial Basis Function* (RBF), polinomiais e sigmóides.

Uma das funções de *kernel* amplamente utilizada em classificadores SVM é a função RBF. A função RBF é baseada em uma função radial que é definida em relação ao ponto central, geralmente denominado de centro radial, que é um hiperparâmetro escolhido pelo usuário. A saída da função RBF é determinada pela distância entre a entrada e o centro radial, e quanto menor a distância, maior é a saída da função. Essa função é utilizada para transformar o espaço de entrada em um espaço de características mais adequado, permitindo que o classificador SVM identifique padrões complexos no espaço de entrada e torne-se adequado para problemas de classificação não linear. O modelo matemático da função RBF é dado pela equação (2.15), onde γ é o parâmetro de regularização e r é a distância radial do ponto de amostra ao centro da função RBF.

$$\phi(r) = e^{-\gamma r^2} \quad (2.15)$$

2.4.3.2 Hiperparâmetro C

Outra característica altamente relevante para a SVM é o hiperparâmetro de regularização “Custo” ou C . Assim como a taxa de aprendizagem do MLP, é um valor que controla o compromisso entre obter uma boa classificação dos dados de treinamento e evitar o *overfitting*. Em outras palavras, o valor de C determina o quão fortemente o modelo é restringido em sua capacidade de ajustar os dados de treinamento. A Figura 2.7 ilustra a variação do hiperparâmetro C em um SVM de classificação de amostras em um plano bidimensional.

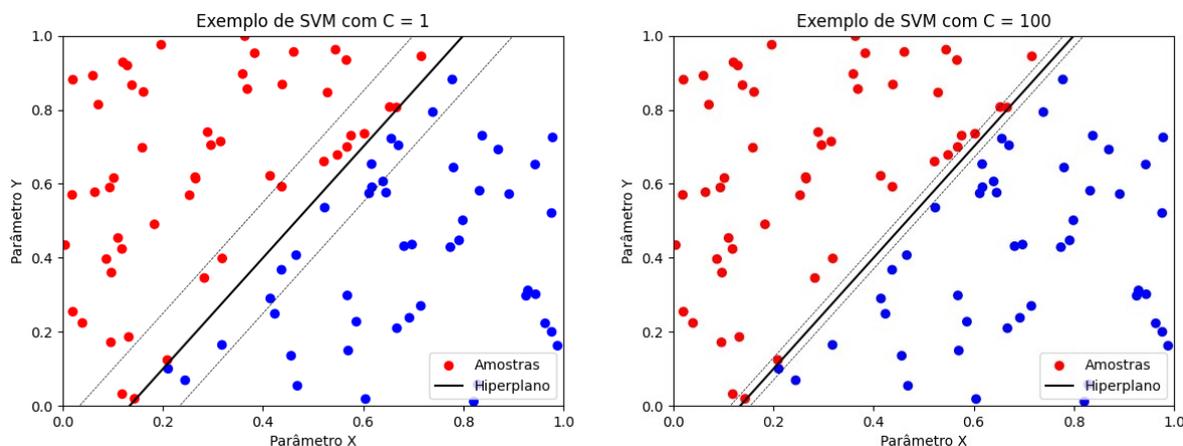


Figura 2.7: Exemplo da variação do hiperparâmetro C em um SVM bidimensional.

Um valor alto de C resulta em uma restrição fraca e, portanto, uma margem de

separação mais estreita. Isso significa que o modelo terá maior liberdade para ajustar os dados de treinamento resultando em maior risco de ocorrer o *overfitting*. Por outro lado, um valor baixo de C resulta em uma restrição forte, resultando em uma margem de separação mais larga. Neste caso, o modelo terá menos liberdade para ajustar os dados de treinamento e, portanto, será menos propenso a sofrer *overfitting*, porém com menor assertividade para os dados de treinamento. Portanto, o ajuste do valor de C é uma parte importante do processo de treinamento da SVM.

2.4.4 Árvore de Decisão

A Árvore de Decisão é um tipo de algoritmo de ML de aprendizado supervisionado para classificação ou regressão. Funciona dividindo um conjunto de dados em subconjuntos cada vez menores e mais homogêneos a cada nível da árvore [76]. Cada nó interno na árvore representa uma decisão a ser tomada com base em um conjunto de características dos dados, enquanto as folhas representam as decisões ou classificações finais.

2.4.4.1 Critérios de Ajuste

As árvores de decisão são amplamente utilizadas em tarefas de classificação e previsão, como prever se um cliente irá comprar ou não um determinado produto, e utilizam técnicas de estatística e probabilidade para encontrar relações entre as variáveis de entrada e de saída. Os critérios mais comuns de ajuste na construção de uma árvore de decisão são o *Gini Index*, a Entropia e o ganho de informação de Shannon.

O índice de Gini é um critério de avaliação utilizado na construção de árvores de decisão para determinar a qualidade da divisão dos dados em uma determinada folha. É calculado como a soma das probabilidades de erro para cada classe. A equação para o cálculo do índice de Gini é descrita por (2.16) onde $p(i, t)$ é a proporção de amostras da classe i na folha t . Quanto menor o índice de Gini, menor a impureza da divisão e, portanto, melhor a qualidade da divisão.

$$G = 1 - \sum p(i, t)^2 \quad (2.16)$$

O critério de Entropia é outro indicador da qualidade da divisão dos dados em uma árvore de decisão. A entropia é calculada como a soma das probabilidades dos dados em cada classe, multiplicadas pelo logaritmo base 2 da probabilidade da classe. A equação matemática para o cálculo da entropia é dada por (2.17) onde n é o número de classes e p_i

é a probabilidade de um determinado dado pertencer à classe i . Quanto menor a entropia mais bem separados os dados estão nas classes. A árvore de decisão visa maximizar a separação dos dados nas classes, por isso o critério de entropia é frequentemente utilizado para guiar a construção da árvore.

$$E = - \sum_{i=1}^n p_i \log_2(p_i) \quad (2.17)$$

Outro critério de seleção de atributos na construção de uma árvore de decisão é o ganho de informação de Shannon (*Shannon Information Gain*), que mede a redução da incerteza sobre uma classe dada uma divisão dos dados baseada em um atributo. A fórmula do ganho de informação de Shannon é baseada na entropia, que mede a incerteza na distribuição das classes. Quanto maior for o ganho de informação de Shannon, menor será a incerteza e, portanto, a divisão será considerada mais assertiva.

Capítulo 3

Metodologia

Nesta seção é apresentada uma visão abrangente da arquitetura do sistema de suporte à decisão, que engloba a geração de amostras sintéticas para o conjunto de dados de treinamento. Além disso, o processo de treinamento iterativo aplicado a várias técnicas de aprendizado de máquina é detalhado, com o objetivo final de identificar o modelo de melhor desempenho para cada técnica.

3.1 Banco de Dados de Treinamento Sintético

Na realização deste estudo, há a limitação inerente à falta de acesso a uma base de dados históricos abrangente que descreveria o estado de saúde do isolamento de transformadores ao longo do tempo. A aquisição um conjunto experimental para treinamento exigiria um longo período de coleta de dados. Estes dados deveriam registrar e rotular ambos os estados operativos do transformador (sadio e com CEE) em diversos níveis de carga e tensão. Além disso, este registro deve ser feito para cada modelo de transformador de potência a ser aplicado o diagnóstico.

Dada a inviabilidade de coletar um volume substancial de dados reais, é optado por uma abordagem sintética, que se baseia em simulações baseadas em MEF. Isso permite criar um conjunto de dados amplo e diversificado, que reflete cenários abrangentes de falhas de isolamento. Esta metodologia se apresenta como uma alternativa confiável na superação das limitações associadas à falta de dados reais disponíveis para treinamento dos algoritmos de aprendizado supervisionado.

A modelagem parte do levantamento das características geométricas, elétricas e magnéticas do equipamento a ser diagnosticado. O modelo simulado é submetido a diversos

cenários operacionais, como casos de operação sadia, diferentes níveis de CEE e diversas condições de carga. Essas simulações geram uma variedade suficiente de amostras abrangendo diferentes cenários de falha e condições operacionais, criando efetivamente um conjunto de dados abrangente e versátil para o processo de treinamento de ML utilizado no sistema de suporte à decisão. A Figura 3.1 ilustra a geometria 2D de um transformador trifásico a seco simulado no *software* COMSOL.

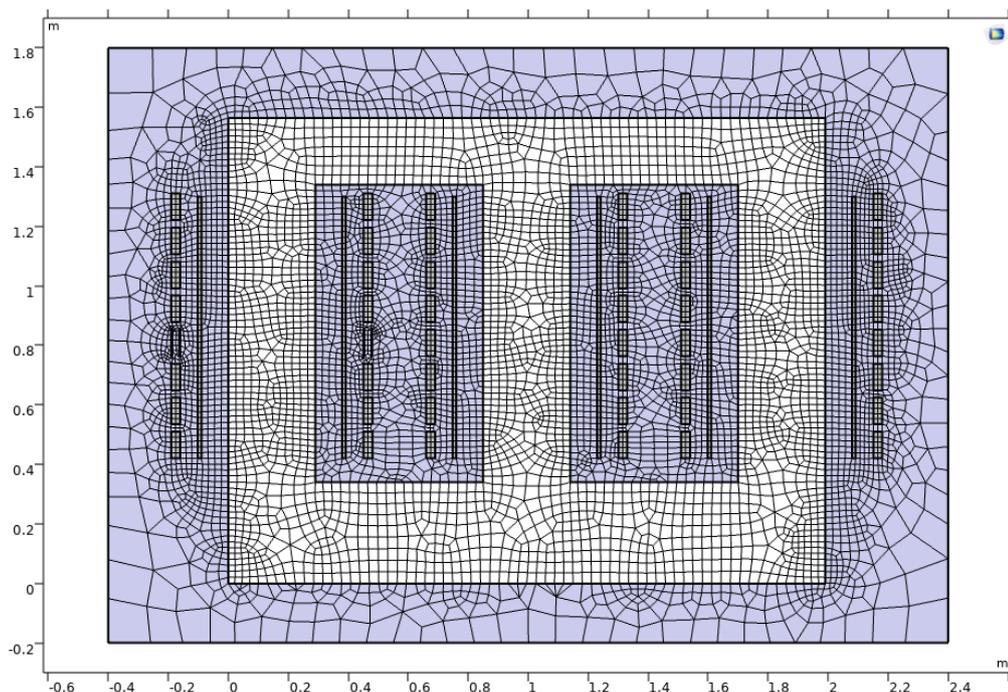


Figura 3.1: Simulação em MEF do transformador trifásico com 10% de CEE.

A modelagem dos enrolamentos, tanto em alta quanto em baixa tensão, segue a configuração de "Condutores Multivolta Homogeneizados" (*Homogeinized Multiturn Conductor*). Nessa abordagem, um corte 2D de cada bobina é representado como um retângulo sólido. No entanto, o *software* divide igualmente a área da bobina pelo número de espiras especificado. A Figura 3.2 ilustra planos de corte em um enrolamento genérico.

Nessa metodologia, a ocorrência de CEE é representada como uma interrupção dentro do retângulo correspondente à aplicação da falta, mantendo a proporção original de espiras por área. Em seguida, as extremidades são conectadas em série para completar o circuito modificado. Isso resulta na redução do número de espiras no enrolamento, emulando, assim, a ocorrência de CEE nessa bobina. A Figura 3.3 fornece uma visão detalhada da implementação de CEE em uma das fases de alta tensão do transformador.

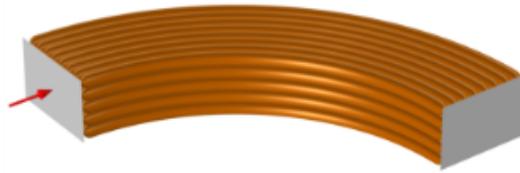


Figura 3.2: Ilustração do plano de corte de um enrolamento para a configuração de condutores multivolta homogeneizados.

Fonte: Documentação do COMSOL

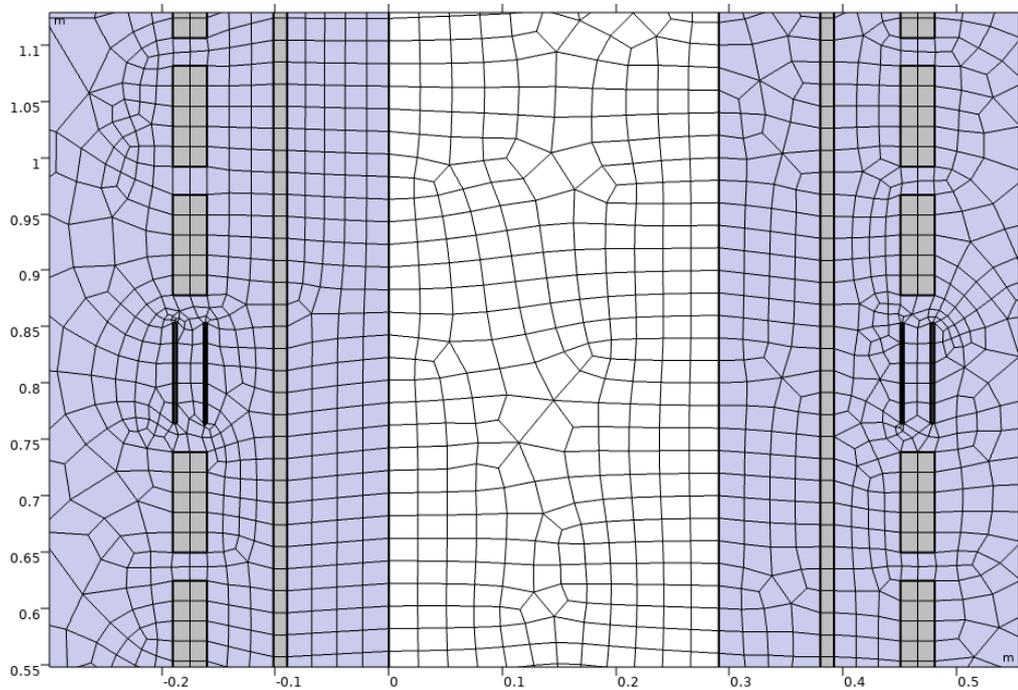


Figura 3.3: Implementação de CEE no enrolamento de Alta Tensão da Fase A.

3.2 Método do Vetor de Park aplicado para diagnóstico de Curto-Circuito entre Espiras (CEE)

Na aquisição de oscilografias trifásicas de corrente, tanto os dados provenientes de simulações quanto aqueles obtidos a partir de equipamentos instrumentados são organizados como séries temporais de amplitudes. No entanto, devido ao elevado volume de informações gerado e à complexidade envolvida na interpretação desses dados brutos, o treinamento e a inferência utilizando algoritmos de aprendizado de máquina podem se tornar inviáveis. Para enfrentar essa problemática, uma abordagem para caracterizar as

amostras de corrente, focada na detecção de CEE, envolve a representação de cada série temporal, ou seja, cada amostra, por meio de sua correspondente Figura de Lissajous.

3.2.1 Correntes Diferenciais

Para criar o gráfico dos componentes do vetor de Park, inicialmente é necessário calcular a corrente diferencial. Essa corrente, para cada fase em condição normal, pode ser obtida através do modelo do transformador referido ao nível de tensão primário, conforme mostrado na Figura 2.3. O equacionamento desta corrente para um transformador monofásico é demonstrado pela Equação (3.1). O primeiro termo corresponde a corrente do primário e o segundo a corrente do secundário referida ao primário.

$$i_d = i_p - \frac{i_s}{\alpha} \quad (3.1)$$

Considerando o transformador de potência trifásico de ligação ΔY aterrado, conforme ilustrado pela Figura 3.4. Para esta configuração, as correntes de linha podem ser representadas em fatores das correntes de fase ($i_A = i_{AB} - i_{CA}$). Dessa forma, utilizando a relação de transformação para referência das correntes secundárias ao primário, obtêm-se as correntes referidas ao primário $i'_{A,B,C}$ descritas pelas Equações (3.2), (3.3) e (3.4).

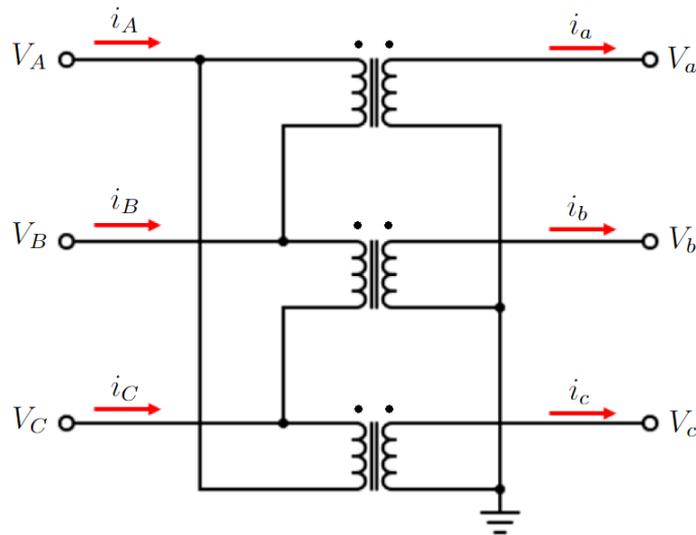


Figura 3.4: Ligação Delta-Estrela de um transformador trifásico.

$$i'_A = \frac{1}{\alpha}(i_a - i_c) \quad (3.2)$$

$$i'_B = \frac{1}{\alpha}(i_b - i_a) \quad (3.3)$$

$$i'_C = \frac{1}{\alpha}(i_c - i_b) \quad (3.4)$$

As diferenças entre as correntes reais aferidas do primário e as correntes do secundário referidas ao nível de tensão primário resultam nas correntes diferenciais do sistema $i_{dA,B,C} = i_{A,B,C} - i'_{a,b,c}$. Estas são descritas pelas Equações (3.5), (3.6) e (3.7), e consolidadas na forma matricial na Equação (3.8).

$$i_{dA} = i_A - \frac{1}{\alpha}(i_a - i_c) \quad (3.5)$$

$$i_{dB} = i_B - \frac{1}{\alpha}(i_b - i_a) \quad (3.6)$$

$$i_{dC} = i_C - \frac{1}{\alpha}(i_c - i_b) \quad (3.7)$$

$$\begin{bmatrix} i_{dA} \\ i_{dB} \\ i_{dC} \end{bmatrix} = \begin{bmatrix} i_A \\ i_B \\ i_C \end{bmatrix} - \frac{1}{\alpha} \begin{bmatrix} 1 & 0 & -1 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} \quad (3.8)$$

As correntes diferenciais são denominadas correntes em estado livre de falta [2], e são empregadas no sistema como parte do processo anterior à aplicação da Transformada de Park. Essa etapa inicial de diferenciação desempenha um papel na compensação das correntes, especialmente em cenários desequilibrados.

3.2.2 Transformada de Park e Figura de Lissajous

Em seguida, as correntes diferenciais são submetidas à Transformada de Park, conforme mostrada na equação (2.10), resultando nas correntes com componentes direta, i_d (Eq. 3.9), e em quadratura, i_q (Eq. 3.10). Devido às propriedades intrínsecas, ao se aplicar a transformada em correntes diferenciais equilibradas provenientes de um caso sadio, essas componentes são representadas por cossenos de mesma amplitude defasados em 90° uma em relação à outra. Esse caso pode ser descrito pelas Equações (3.9) e (3.10) considerando $|I_d| = |I_q|$ e $\phi = \frac{\pi}{2}$.

$$i_d = |I_d| \cdot \cos(2\pi ft) \quad (3.9)$$

$$i_q = |I_q| \cdot \cos(2\pi ft + \phi) \quad (3.10)$$

Por meio da análise das componentes dq das grandezas elétricas medidas nas máquinas, é possível identificar possíveis falhas nos enrolamentos facilitando a manutenção e

reduzindo o tempo de parada das máquinas. Além disso, estas técnicas também podem ser usadas para o projeto de sistemas de proteção e controle de máquinas elétricas, visando garantir a segurança e o desempenho desses equipamentos durante a operação.

$$\begin{bmatrix} i_{dD} \\ i_{dQ} \end{bmatrix} = \begin{bmatrix} \frac{\sqrt{2}}{\sqrt{3}} & \frac{-1}{\sqrt{6}} & \frac{-1}{\sqrt{6}} \\ 0 & \frac{-1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} i_{dA} \\ i_{dB} \\ i_{dC} \end{bmatrix} \quad (3.11)$$

O diagnóstico de CEE é baseado na análise do gráfico $I_{dQ} \times I_{dD}$. Em um transformador ideal e sadio, a representação gráfica geralmente assume a forma de um círculo perfeito centrado na origem. No entanto, a presença de CEE em qualquer fase do transformador introduz distorção na elipse. Cada fase com defeito está associada a uma inclinação específica da elipse, facilitando a identificação da fase com o CEE.

3.2.3 Parametrização da Elipse

Os parâmetros da elipse obtida a partir da transformada de Park são estimados através do algoritmo *EllipseModel* implementado pela biblioteca de processamento de imagem *Scikit-image* do *Python*. Este utiliza um estimador de mínimos quadrados para elipses 2D. O modelo funcional do estimador é descrito pelas Equações (3.12), (3.13) e (3.14), onde (x_t, y_t) representa o ponto na elipse que está mais próximo das coordenadas (x, y) . Assim, a variável d denota a distância mínima entre o ponto e a elipse [77].

O gráfico da curva de componentes de Park $I_{dD} \times I_{dQ}$ fornece a elipse cujos parâmetros podem caracterizar a amostra, uma vez que a ocorrência e agravamento de CEE causam variações nos parâmetros da elipse. O sistema considera cinco parâmetros da elipse, que são definidos em termos das coordenadas do centro da elipse (x_c, y_c) , raio principal a , raio secundário b e ângulo de rotação θ . Esses parâmetros determinam a posição, tamanho e orientação da elipse. A Figura 3.5 ilustra a representação gráfica desses parâmetros.

$$x_t = x_c + a \cos(\theta) \cos(t) - b \sin(\theta) \sin(t) \quad (3.12)$$

$$y_t = y_c + a \sin(\theta) \sin(t) + b \cos(\theta) \cos(t) \quad (3.13)$$

$$d = \sqrt{(x - x_t)^2 + (y - y_t)^2} \quad (3.14)$$

A caracterização das amostras com base em elipses geradas a partir da Transformada de Park oferece a vantagem de simplificar as bases de treinamento e teste do sistema.

Essa simplificação resulta em maior eficiência e tempos de processamento mais rápidos na aplicação. Além disso, será realizado um processo de verificação para avaliar a adequação dessa metodologia em termos de precisão e exatidão para o sistema de diagnóstico. Essa avaliação fornecerá indicações sobre a confiabilidade e eficácia da abordagem de caracterização baseada em elipses.

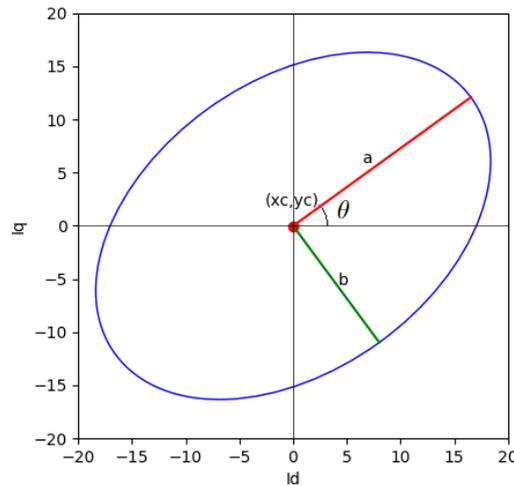


Figura 3.5: Exemplo de uma elipse parametrizada.

3.3 Métricas de Avaliação para Algoritmos de Classificação Binária

A avaliação de um problema de classificação binária pode ser conduzida utilizando a Matriz de Confusão (CM), conforme ilustrado na equação 3.15. Essa matriz é uma representação 2×2 que categoriza os dados em Verdadeiros Positivos (TP), Falsos Positivos (FP), Verdadeiros Negativos (TN) e Falsos Negativos (FN). Esta matriz fornece uma representação visual das classificações corretas e incorretas do modelo.

$$CM = \begin{bmatrix} TP & FP \\ FN & TN \end{bmatrix} \quad (3.15)$$

Com base nesses valores, podem ser calculadas diversas métricas de avaliação do algoritmo. As métricas de avaliação são medidas quantitativas usadas para avaliar o desempenho de um modelo, algoritmo ou sistema em relação a uma tarefa específica. Elas são amplamente utilizadas em diversas áreas da ciência de dados, aprendizado de máquina, estatísticas e outras disciplinas para medir o quão bem um modelo ou algoritmo está funcionando em relação aos dados de teste ou validação. Essas métricas são essenciais

para entender a eficácia de um modelo e tomar decisões informadas sobre como melhorá-lo. A literatura sugere diversas métricas para avaliar o desempenho da classificação, incluindo acurácia, precisão, revocação, especificidade e a pontuação F1. Essas métricas fornecem *insights* sobre o desempenho geral e a qualidade do modelo de classificação.

- **Acurácia:** É a métrica mais básica e amplamente usada para avaliar um sistema de classificação binária. Esta mede a proporção de todas as previsões corretas feitas pelo modelo em relação ao total de previsões feitas. A acurácia fornece uma visão geral do desempenho do modelo, mas pode não ser adequada quando os dados estão desequilibrados, com uma classe dominando a outra.
- **Precisão:** Mede a proporção de verdadeiros positivos (TP) em relação ao total de previsões positivas feitas pelo modelo, ou seja, a fração de previsões corretas para a classe positiva. A Precisão é uma métrica importante quando é crucial evitar falsos positivos, ou seja, prever erroneamente uma classe como positiva quando é negativa.
- **Sensibilidade:** Também é chamada de Revocação ou *Recall*, a Sensibilidade é a fração de exemplos da classe positiva que o modelo conseguiu identificar corretamente. É importante quando é necessário capturar a maioria dos casos positivos, minimizando os falsos negativos.
- **Especificidade:** Em essência, é a capacidade do modelo de identificar corretamente a classe negativa. É particularmente útil quando se deseja evitar falsos positivos na classe negativa.
- **Pontuação F1:** É uma métrica que combina Precisão e Sensibilidade em um único número, proporcionando um equilíbrio entre a capacidade de identificar positivos (Precisão) e a capacidade de capturar todos os casos positivos (Sensibilidade). A Pontuação F1 varia de 0 a 1, sendo 1 o melhor resultado possível. É útil quando você deseja uma métrica geral que leve em consideração tanto os falsos positivos quanto os falsos negativos.

Essas métricas são a base da avaliação do desempenho de sistemas de classificação binária e serão utilizadas na avaliação do sistema proposto. A escolha da métrica adequada depende dos objetivos e das necessidades do problema em questão. A Tabela 3.1 fornece uma visão matemática de como cada uma destas métricas é obtida a partir das classificações do sistema binário.

Métrica	Equação
Acurácia	$\frac{TP+TN}{TP+TN+FP+FN}$
Precisão	$\frac{TP}{TP+FP}$
Recall	$\frac{TP}{TP+FN}$
Especificidade	$\frac{TN}{TN+FP}$
Pontuação F1	$\frac{2TP}{2TP+FP+FN}$

Tabela 3.1: Métricas para avaliação de algoritmos de classificação binária.

3.4 Arquitetura dos Modelos de Machine Learning

Após a criação da base de dados para treinamento e a devida parametrização das amostras, o procedimento segue uma metodologia específica. Inicialmente as características das amostras são normalizadas, removendo a média e as redimensionando para variância unitária.

Em seguida, a base de dados é dividida em dois subconjuntos, onde 75% das amostras são reservados para o treinamento e 25% para a validação, mantendo a proporção de padrões para cada classe. Em outras palavras, se houver 200 registros de operação normal e 300 registros de operação com curto entre espiras, o conjunto de treinamento incluirá 150 registros normais e 225 registros com curto entre espiras. Os restantes 50 registros normais e 75 registros com curto entre espiras serão destinados à validação. A seleção das amostras para cada grupo é feita de forma aleatória para evitar qualquer viés na escolha do modelo mais apropriado.

O treinamento de cada algoritmo é realizado usando os dados do subconjunto de treinamento, sendo avaliado por meio das métricas de desempenho obtidas a partir do subconjunto de teste. A principal contribuição desse processo é o diagnóstico do estado operativo do transformador em relação à presença de CEE. Para alcançar essa finalidade, o sistema utiliza três algoritmos de ML em paralelo. Os três algoritmos compartilham a mesma base de treinamento, permitindo ao sistema escolher o modelo mais adequado com base nas métricas de avaliação obtidas no subconjunto de teste.

A abordagem de usar múltiplos modelos de ML em paralelo traz diversas vantagens à classificação das amostras e ao suporte à tomada de decisão em sistemas de ML, em comparação com a utilização de um único modelo. Entre as vantagens, destaca-se a capacidade de reduzir o viés e a variância, aprimorando o desempenho global do sistema.

Além disso, o sistema adquire maior robustez, pois a falha de um modelo em cenários ou tipos de dados específicos pode ser compensada por outros modelos, tornando-o menos suscetível a erros isolados. Como diferentes modelos podem aprender características distintas dos dados, a combinação de modelos proporciona uma visão mais abrangente das informações, aumentando a capacidade de generalização do sistema. No processo de treinamento, a utilização de múltiplos modelos contribui para a redução do *overfitting*, uma vez que modelos sobreajustados geralmente geram previsões divergentes em relação aos modelos mais equilibrados, tornando menos provável a seleção de modelos sobreajustados. Por fim, cada algoritmo de ML tem suas qualidades em tarefas específicas. Ao utilizar diversos modelos, é possível combinar essas vantagens e, assim, aumentar a probabilidade de escolher o modelo mais apropriado para um conjunto de dados específico.

A metodologia de treinamento consiste em iterativamente expor cada modelo de ML ao subconjunto de treinamento. Durante cada iteração, os parâmetros das respectivas arquiteturas dos modelos são ajustados de forma variada, com o objetivo de avaliar suas métricas de desempenho. Isso permite identificar o modelo que apresenta o melhor desempenho para cada técnica. Utilizando subconjuntos de treinamento e teste, a metodologia visa encontrar a configuração ótima que resulta na maior acurácia. Dessa forma, assegura-se a seleção dos modelos de maior desempenho para cada técnica de ML implementada.

3.4.1 Perceptron de Múltiplas Camadas (MLP)

O classificador que utiliza MLPs é treinado de forma iterativa. Em cada etapa do treinamento, as derivadas parciais da função de perda em relação aos parâmetros do modelo são calculadas para, em seguida, atualizar esses parâmetros. A Figura 3.6 apresenta a estrutura do MLP implementado, composto por cinco neurônios de entrada, cada um recebendo um dos cinco parâmetros da elipse considerados (conforme ilustrado na Figura 3.5).

Na arquitetura do MLP, define-se um limite mínimo de 1 e máximo de 20 neurônios na camada oculta. A função de ativação utilizada para esses neurônios é a tangente hiperbólica (Equação 2.13). Em vez do tradicional algoritmo estocástico de gradiente descendente para a atualização dos pesos sinápticos, adota-se o algoritmo Adam, que combina as vantagens do Adaptive Gradient Algorithm (AdaGrad) e do Root Mean Square Propagation (RMSProp) [78, 79]. Além disso, incorpora-se o algoritmo de Early Stopping, reservando 20% da base de dados para essa finalidade. O treinamento do MLP é limitado a 30.000 épocas, tanto para o treinamento padrão quanto para o algoritmo de Early

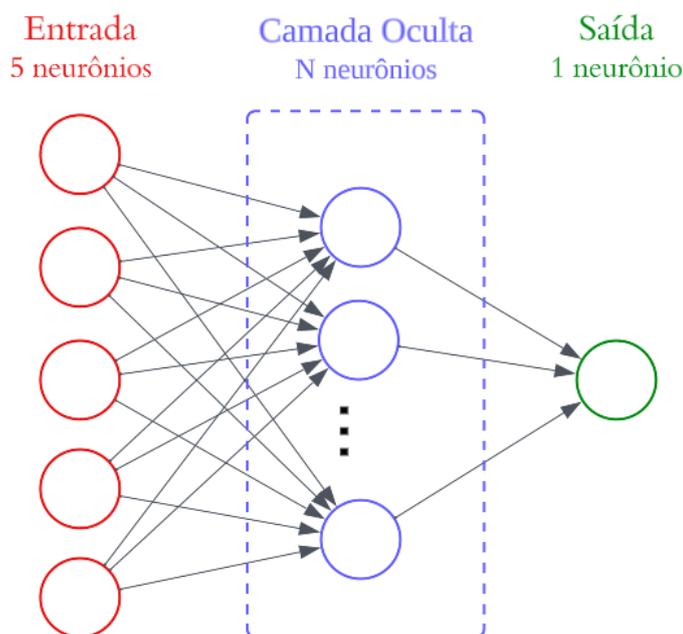


Figura 3.6: Estrutura do Perceptron de Múltiplas Camadas implementado.

Stopping. O sistema emprega um loop iterativo, treinando MLPs com diferentes números de neurônios na camada oculta (de 1 até 20), buscando identificar o modelo com a melhor acurácia no conjunto de validação (25% da base destinada ao treinamento). Este modelo é selecionado como o modelo final.

3.4.2 Classificador de Vetor de Suporte (SVC)

O SVC é uma técnica particular da SVM utilizado especificamente para classificação. É utilizado para realizar tarefas de classificação em que os dados de entrada são divididos em diferentes classes ou categorias. Seguindo a metodologia da SVM, o algoritmo busca encontrar um hiperplano que melhor separa essas classes no espaço de características. O SVC é frequentemente utilizado em problemas de classificação binária, em que há apenas duas classes, mas também pode ser estendido para problemas de classificação de múltiplas classes.

O algoritmo SVC utiliza a RBF como função de *kernel*, com seus parâmetros determinados automaticamente. São testados valores de C no conjunto [1, 10, 50, 100 e 1000], onde um valor maior de C implica em uma maior complexidade na superfície de decisão ajustada. Para cada valor de C , uma SVC é treinada considerando os dados de treinamento, seguindo uma abordagem semelhante à apresentada para o MLP. O modelo treinado é avaliado em um conjunto de validação, construído de maneira análoga.

Assim como no caso do MLP, a SVC com o melhor ajuste para o conjunto de validação é selecionada para a fase de inferência. O algoritmo é configurado para fornecer a resposta probabilística da amostra pertencer à classe positiva, que, neste caso, corresponde à operação sadia.

3.4.3 Árvore de Decisão

De maneira análoga ao que foi apresentado para o MLP e a SVC, a validação cruzada é empregada para construir a árvore de decisão mais adequada para o conjunto de treinamento, considerando cada uma das métricas. Cada modelo é avaliado no conjunto de validação, e a árvore com melhor desempenho para esse conjunto é escolhida para a fase de inferência.

A geração e seleção do melhor modelo de Árvore de Decisão é realizada de forma iterativa, por meio do treinamento e avaliação da precisão de três critérios de divisão distintos: índice Gini, Entropia e Ganho de Informação de Shannon. A Figura 3.7 é uma representação gráfica das decisões tomadas pelo modelo de Árvore de Decisão treinada com dados simplificados de um equipamento estudado. Esta Árvore pode ser usada para tomar decisões com base em dados de entrada. Cada nó da Árvore representa um teste em uma característica específica dos dados, e os ramos que saem dos nós indicam os possíveis resultados desse teste.

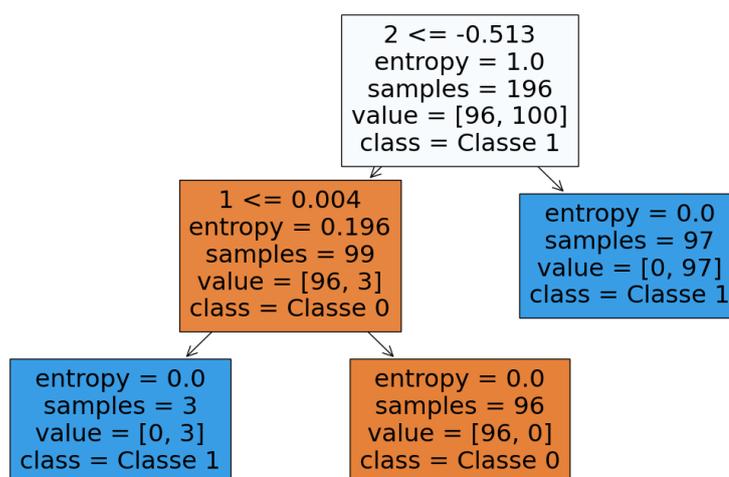


Figura 3.7: Exemplo de Estrutura da Árvore de Decisão implementada para um conjunto de dados simplificado.

Neste exemplo, a Árvore de Decisão é binária, o que significa que cada nó de decisão possui um ramo para o teste “Verdadeiro” e outro para “Falso”. O primeiro nó de decisão testa a característica 2 e verifica se é menor ou igual a -0.513 . Se for Falso a árvore segue o ramo direito. Se for Verdadeiro a árvore segue o ramo esquerdo, onde há outro teste, que verifica se a característica 1 é menor ou igual a 0.00 . Este teste retornando Verdadeiro torna a decisão final da árvore como classe 1. Se este for Falso, a árvore faz uma previsão da classe 0. No ramo direito do primeiro nó de decisão, não há teste adicional. A árvore faz uma previsão da classe 1 diretamente.

Em resumo, esta Árvore de Decisão somente toma decisões com base nas características 2 e 1. Se a característica 2 for menor ou igual a -0.51 , ela se move para a esquerda e, em seguida, verifica se a característica 1 é menor ou igual a 0.00 . Com base nesses testes, a árvore faz previsões das classes 0 e 1. Se a característica 2 for maior do que -0.51 , a árvore faz uma previsão direta da classe 1. Esta é uma Árvore de Decisão feita a partir de uma base bastante simplificada, porém as Árvores mais complexas podem ter muitos nós e ramificações, tornando a interpretação mais detalhada.

Capítulo 4

Validação Preliminar

Neste capítulo, a análise do tratamento de dados proposto é realizada de forma simplificada por simulações utilizando o software PSCAD. Esta é feita em diversos cenários operacionais, estudando como a variação de número de espiras envolvidas no CEE, o balanceamento de cargas e a inserção de harmônicos afetam a característica geométrica final da Figura de Lissajous da amostra.

4.1 Caso Sadio e de Carga Equilibrada

Como caso de referência, investiga-se uma situação de operação sadia e carga distribuída igualmente entre as fases. O transformador considerado é o delta-estrela (ΔY), conforme apresentado na Figura 3.4. Ao empregar o circuito equivalente referente ao lado primário, as correntes são $i_p(t)$ para a corrente no lado primário, $i_s(t)$ para a corrente no lado secundário e $i_m(t)$ para a corrente de magnetização. Mediante a aplicação da Lei dos Nós, obtém-se a relação (4.1).

$$i_p(t) = i_m(t) + \frac{i_s(t)}{\alpha} \quad (4.1)$$

Ao substituir a Equação (4.1) na Equação (4.2), alcança-se a relação (4.3). Essa expressão evidencia que, em uma condição sadia e com carga balanceada, a corrente diferencial é atribuída exclusivamente à corrente de magnetização do transformador.

$$i_d(t) = i_p(t) - \frac{1}{\alpha} i_s(t) \quad (4.2)$$

$$i_d(t) = i_m(t) + \frac{i_s(t)}{\alpha} - \frac{i_s(t)}{\alpha} \quad (4.3)$$

No cenário analisado, é razoável presumir que as correntes de magnetização estejam equilibradas, possibilitando considerá-las na forma descrita pela Equação (4.4), em que I_m representa a magnitude das correntes de magnetização e ω denota a velocidade angular do sistema. Em seguida, aplicamos a Transformada de Park (Eq. 3.11), resultando na equação 4.5. Observa-se que i_{dD} e i_{dQ} são cossenoides com a mesma amplitude e frequência, porém defasados em 90° . Ao serem representados na figura de Lissajous, esses sinais formam um círculo perfeito com raio igual à amplitude dos cossenos.

$$\begin{bmatrix} i_{mA} \\ i_{mB} \\ i_{mC} \end{bmatrix} = \begin{bmatrix} \sqrt{3} I_m \cos(\omega t) \\ \sqrt{3} I_m \cos(\omega t - \frac{2\pi}{3}) \\ \sqrt{3} I_m \cos(\omega t + \frac{2\pi}{3}) \end{bmatrix} \quad (4.4)$$

$$\begin{bmatrix} i_{dD} \\ i_{dQ} \end{bmatrix} = \begin{bmatrix} \frac{\sqrt{2}}{\sqrt{3}} & \frac{-1}{\sqrt{6}} & \frac{-1}{\sqrt{6}} \\ 0 & \frac{-1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \sqrt{3} I_m \cos(\omega t) \\ \sqrt{3} I_m \cos(\omega t - \frac{2\pi}{3}) \\ \sqrt{3} I_m \cos(\omega t + \frac{2\pi}{3}) \end{bmatrix} \quad (4.5)$$

$$\begin{bmatrix} i_{dD} \\ i_{dQ} \end{bmatrix} = \begin{bmatrix} \sqrt{2} I_m \cos(\omega t) - \frac{I_m \cos(\omega t - \frac{2\pi}{3})}{\sqrt{2}} - \frac{I_m \cos(\omega t + \frac{2\pi}{3})}{\sqrt{2}} \\ 0 - \frac{\sqrt{3}}{\sqrt{2}} I_m \cos(\omega t - \frac{2\pi}{3}) + \frac{\sqrt{3}}{\sqrt{2}} I_m \cos(\omega t + \frac{2\pi}{3}) \end{bmatrix} \quad (4.6)$$

$$\begin{bmatrix} i_{dD} \\ i_{dQ} \end{bmatrix} = \begin{bmatrix} \frac{3\sqrt{2}}{2} I_m \cos(\omega t) \\ \frac{-3\sqrt{2}}{2} I_m \sin(\omega t) \end{bmatrix} = \begin{bmatrix} \frac{3\sqrt{2}}{2} I_m \cos(\omega t) \\ \frac{3\sqrt{2}}{2} I_m \cos(\omega t + \frac{\pi}{2}) \end{bmatrix} \quad (4.7)$$

Para simplificar a investigação, o caso de referência desenvolvido é simulado no software PSCAD como um banco de transformadores trifásicos, conforme representado na Figura 4.1. Cada transformador possui uma potência nominal de 10 kVA, com relação de transformação de 10/1 kV e está conectado na configuração ΔY . As correntes trifásicas de linha são apresentadas na Figura 4.2, enquanto sua respectiva Figura de Lissajous é ilustrada na Figura 4.3.

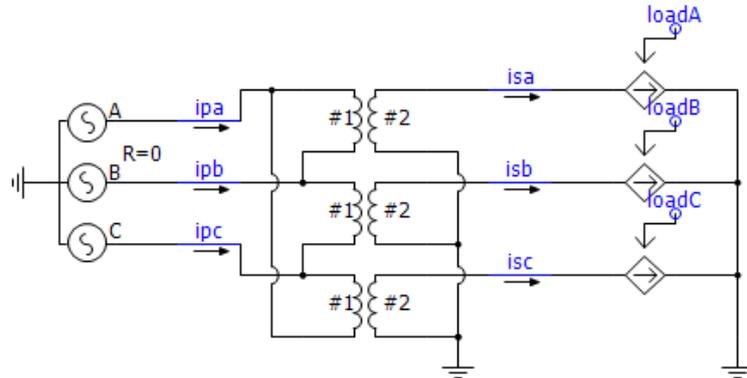


Figura 4.1: Banco trifásico simulado no PSCAD.

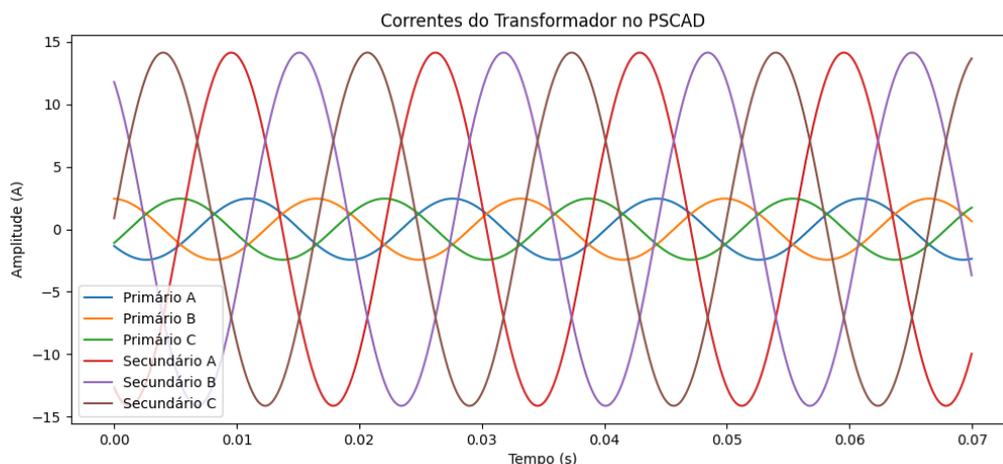


Figura 4.2: Correntes do banco trifásico no caso sadio equilibrado.

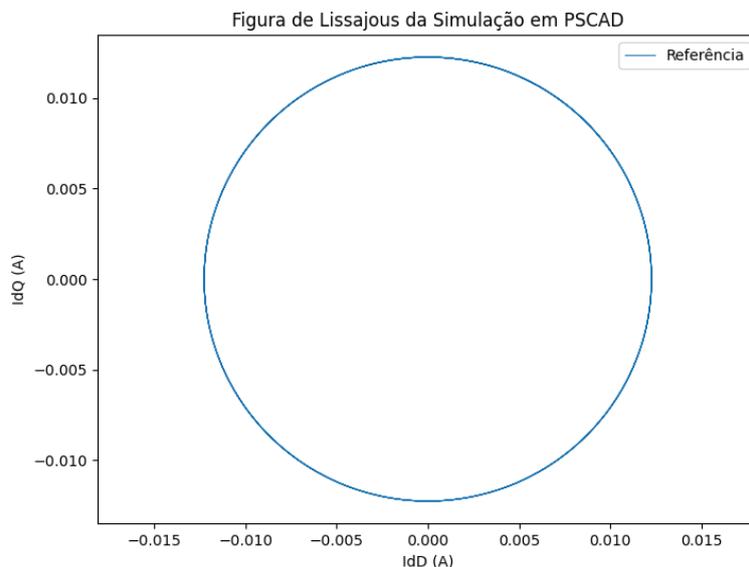


Figura 4.3: Figura de Lissajous das correntes i_{dD} e i_{dQ} para caso sadio e equilibrado.

4.2 Casos de Carga Desbalanceada

A análise do cenário de funcionamento sadio com desequilíbrio na carga é conduzida por meio de simulações no PSCAD, seguindo a mesma abordagem anterior. Foram introduzidas variações de carga na fase B do banco trifásico, expressas percentualmente em relação à carga nominal (referência) nos valores de 10, 30, 50, 70, 90, 110 e 130%. Como exemplo, as correntes de primário e secundário do banco trifásico para um caso de 70% da carga nominal na fase B são representadas na Figura 4.4. As figuras de Lissajous para o caso de referência e para os casos desequilibrados são apresentadas na Figura 4.5.

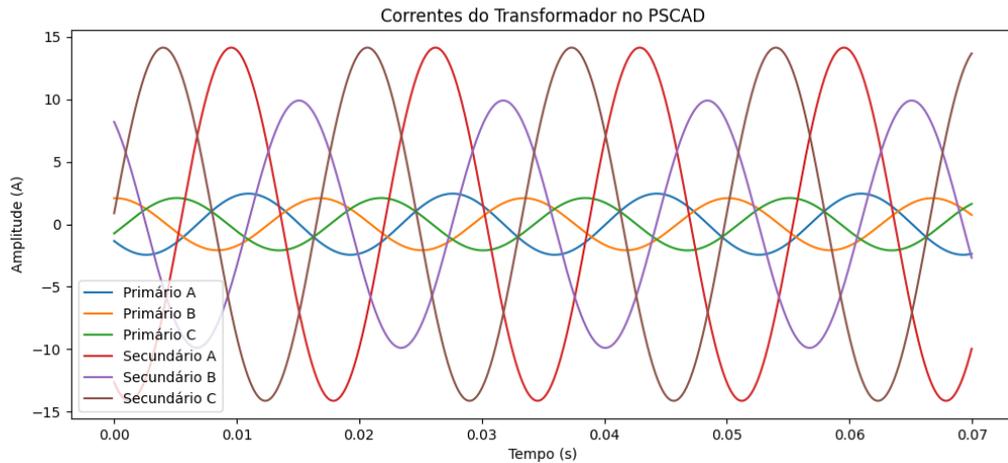


Figura 4.4: Correntes do banco trifásico para 70% da carga nominal na Fase B.

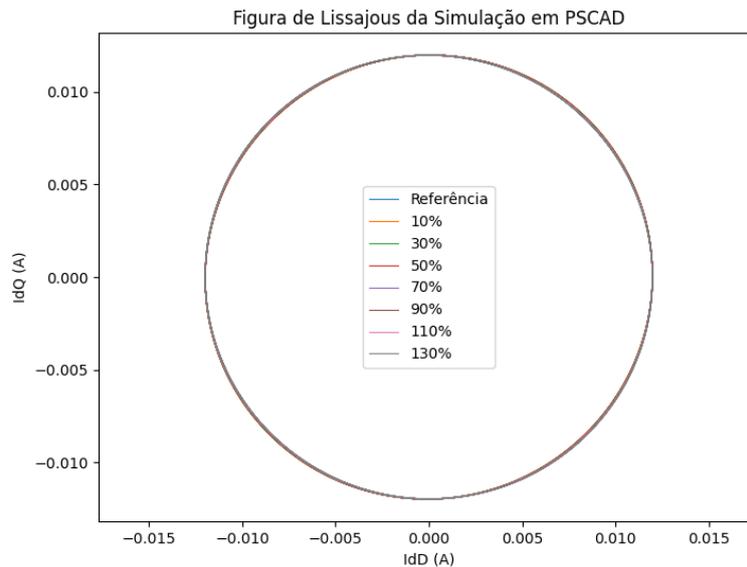


Figura 4.5: Figuras de Lissajous da amostra para o caso de referência e os casos desequilibrados.

Observa-se que, mesmo diante dos níveis de desequilíbrio de carga aplicados, a abordagem de tratamento de dados proposta preserva a natureza circular da Figura de Lissajous. A Figura 4.5 evidencia a sobreposição dos casos de referência e dos casos com desequilíbrio. Embora a definição dos limites nos quais o tratamento de dados compensa o desequilíbrio de carga não esteja dentro do escopo deste trabalho, é razoável considerar essa compensação dentro dos limites operacionais do equipamento.

4.3 Caso com Curto-circuito entre Espiras

Nos casos não sadios, a análise é realizada emulando o CEE pela alteração da relação de transformação de apenas uma das fases. Nessa análise, é implementado um curto de 0.5% e 1% no lado de alta tensão da fase A do banco trifásico. Da mesma forma, as correntes do transformador são visualizadas na Figura 4.6 e as Figuras de Lissajous são apresentadas na Figura 4.7.

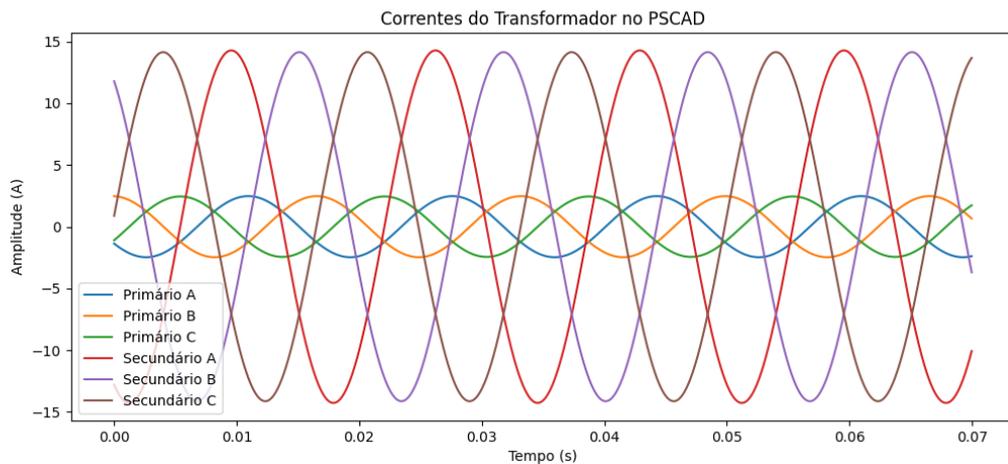


Figura 4.6: Correntes do primário e secundário do banco trifásico para 1% de CEE na Fase A.

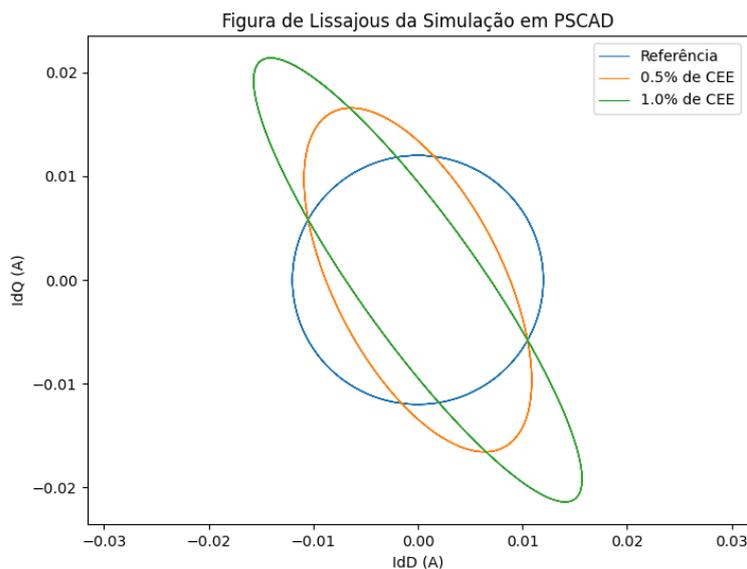


Figura 4.7: Figuras de Lissajous da amostra para o caso de referência e os casos com 0.5% e 1.0% de CEE.

A Figura 4.8 mostra as correntes i_{dD} e i_{dQ} provenientes da Transformada de Park da

amostra com 1% de CEE na fase A. É relevante observar que, neste cenário, as amplitudes das componentes da Transformada de Park se mostraram desiguais, assim como a defasagem aproximou-se de 26.2° . Em virtude dessas alterações, a Figura de Lissajous se apresenta como uma elipse, diferenciando-se da forma circular observada anteriormente.

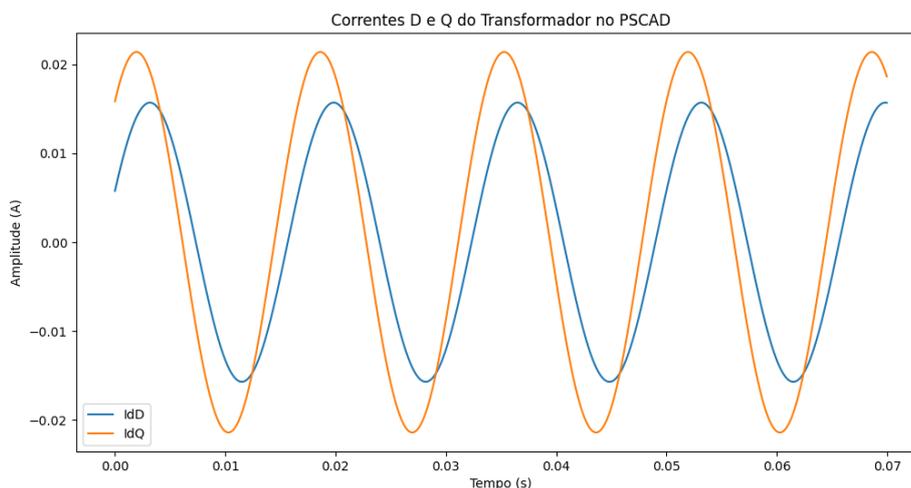


Figura 4.8: Correntes das componentes de Park x Tempo para caso com 1.0% de CEE.

Adotando a mesma metodologia do caso sadio, a carga da fase B é variada com o objetivo de coletar amostras representativas de 10%, 30%, 50%, 70%, 90%, 110% e 130% da nominal. Simultaneamente, também é implementado o CEE de 1% no lado de alta tensão na fase A. As figuras de Lissajous referentes ao caso de referência e aos casos desequilibrados com CEE são apresentadas na Figura 4.9. Da mesma forma, não se observa uma variação perceptível entre as Figuras de Lissajous nos casos com CEE equilibrado e desequilibrado ao analisar esse cenário. Isso reforça a eficácia da metodologia em relação ao desequilíbrio de carga.

4.4 Carga com Distorção Harmônica

Para avaliar a metodologia em casos de carga com distorção harmônica, é inserido um conversor trifásico alimentando uma carga resistiva. Essa configuração é ilustrada na Figura 4.10.

A Figura 4.11 apresenta o perfil das correntes do primário e secundário do banco trifásico. A corrente demandada pelo conversor controlado exibe uma Distorção Harmônica Total (THD) de aproximadamente 25.78%. Já a Figura 4.12 exibe as figuras de Lissajous para a referência de carga livre de harmônicos, o traçado da amostra a partir das correntes

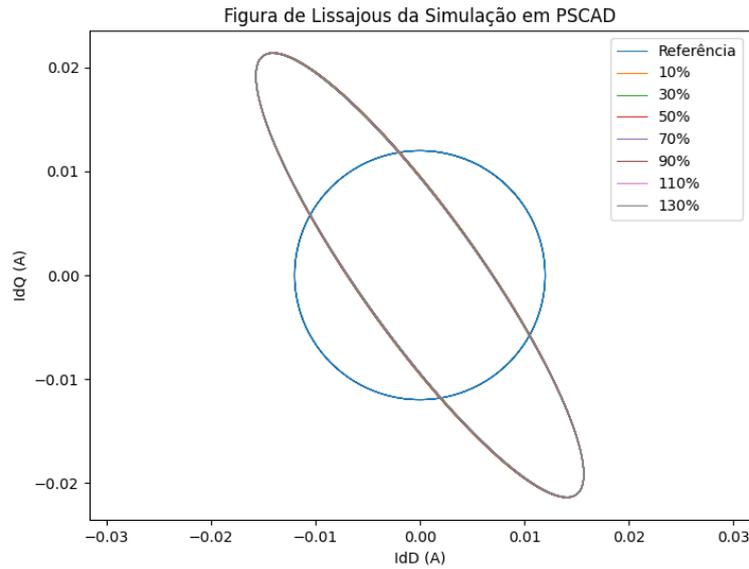


Figura 4.9: Correntes das componentes de Park x Tempo para caso com 1.0% de CEE.

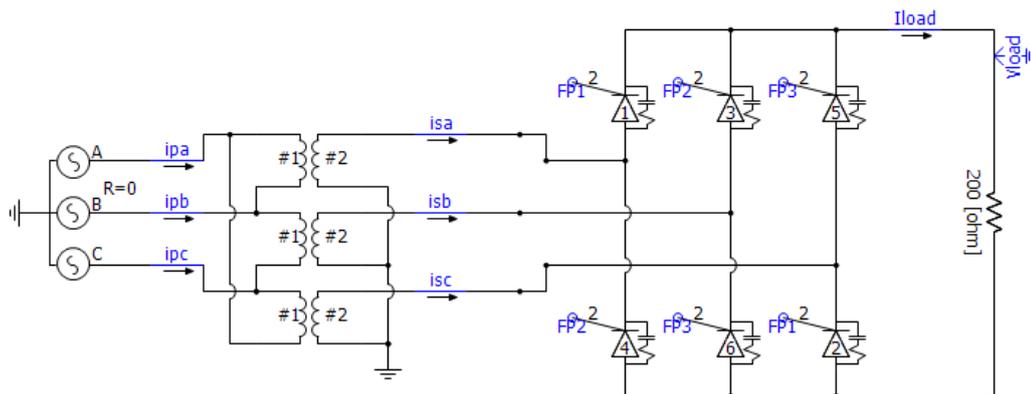


Figura 4.10: Banco trifásico com carga harmônica simulado no PSCAD.

e a elipse parametrizada pelo traçado da amostra.

Da mesma forma que nos casos anteriores, observa-se novamente uma sobreposição praticamente completa dos traçados das elipses. No traçado diretamente obtido a partir da transformada das correntes, é possível notar um leve comportamento harmônico. No entanto, esse comportamento é anulado pela parametrização da amostra em uma elipse.

Por fim, a mesma configuração de carga harmônica é avaliada, mas agora com a introdução de 1% de CEE na fase A. O perfil das correntes é exibido na Figura 4.13, e as figuras de Lissajous para o caso de referência e da amostra real e parametrizada são apresentadas na Figura 4.14. Este cenário demonstra uma distorção na elipse semelhante àquela observada no caso linear, conforme ilustrado na Figura 4.7, possibilitando o diagnóstico

da amostra pelo sistema.

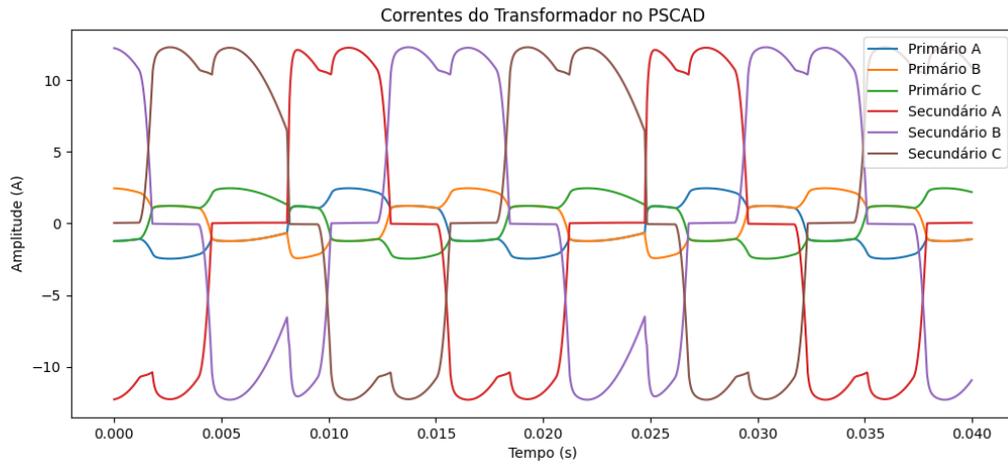


Figura 4.11: Correntes primárias e secundárias do banco trifásico sadio com carga harmônica.

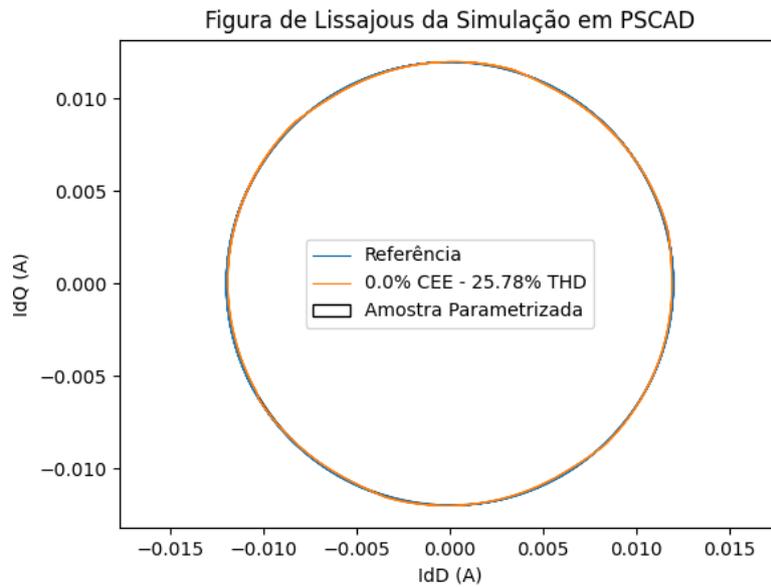


Figura 4.12: Figura de Lissajous das correntes i_{dD} e i_{dQ} para caso sadio com carga harmônica.

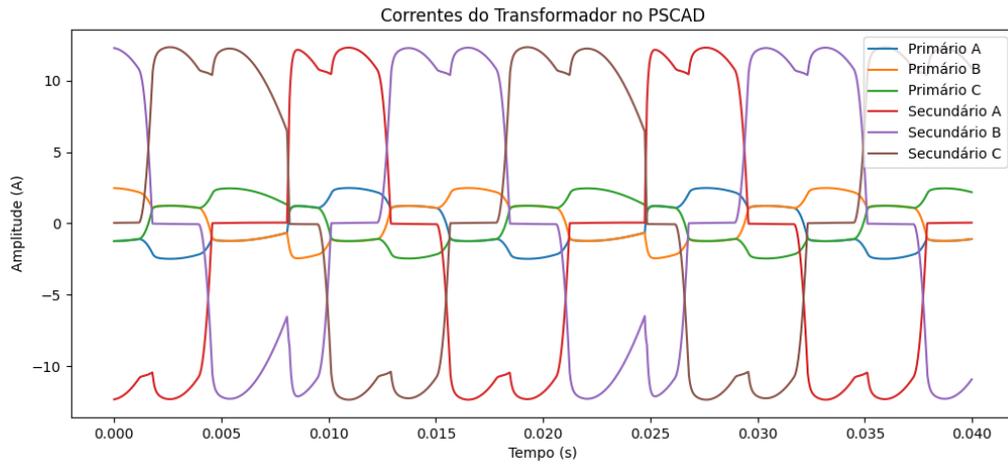


Figura 4.13: Correntes primárias e secundárias do banco trifásico com 1% de CEE e carga harmônica.

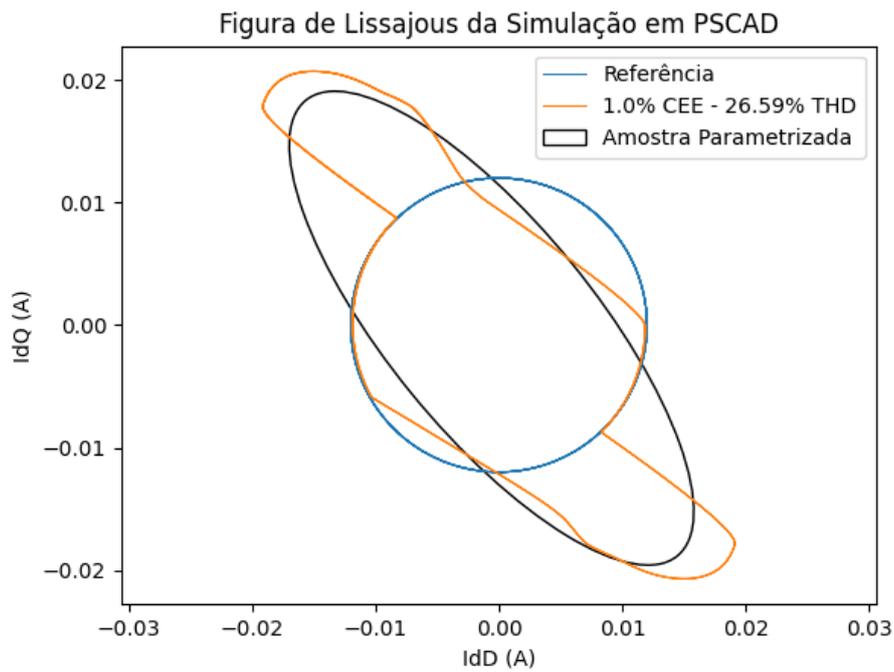


Figura 4.14: Figura de Lissajous das correntes i_{dD} e i_{dQ} com 1% de CEE e carga harmônica.

Capítulo 5

Resultados e Discussão

Neste capítulo são descritos os procedimentos de validação aos quais o sistema foi submetido, juntamente com os resultados e métricas de avaliação obtidos nessas avaliações. O capítulo incorpora também capturas de tela do sistema, geradas durante os estágios de treinamento e inferência das amostras.

5.1 Transformador Trifásico de Média Tensão

A validação inicial do sistema de diagnóstico se deu através da modelagem do TP trifásico de MT. Este tem valores nominais de 2.5 MVA e 13800/690 V, e foi modelado utilizando MEF como mostrado pelas Figuras 3.1 e 3.3.

O conjunto de dados de treinamento consistiu em 1534 amostras rotuladas, obtidas variando parâmetros operacionais, como o número de espiras envolvidas na falha (0, 5 e 10%), a fase da aplicação do CEE, a posição do defeito dentro da bobina, a tensão primária e o nível de carga elétrica. A base de treinamento pode ser visualizada em seus gráficos de elipses na Figura 5.1(a) e a distribuição de seus parâmetros na Figura 5.1(b).

Durante o processo de treinamento, o desempenho de cada modelo é avaliado usando as métricas apresentadas na Tabela 3.1. As estatísticas do treinamento são mostradas pelo sistema como pode ser visto na Figura 5.2. Com exceção do MLP, a matriz de confusão mostrou classificações precisas, sem falsos positivos ou falsos negativos para nenhum dos modelos. Os resultados de validação apresentaram desempenho similar aos resultados de treinamento, atingindo 100% de acurácia nestes casos. Com base nessas métricas, o modelo SVM foi identificado como o modelo de melhor desempenho no conjunto de validação.

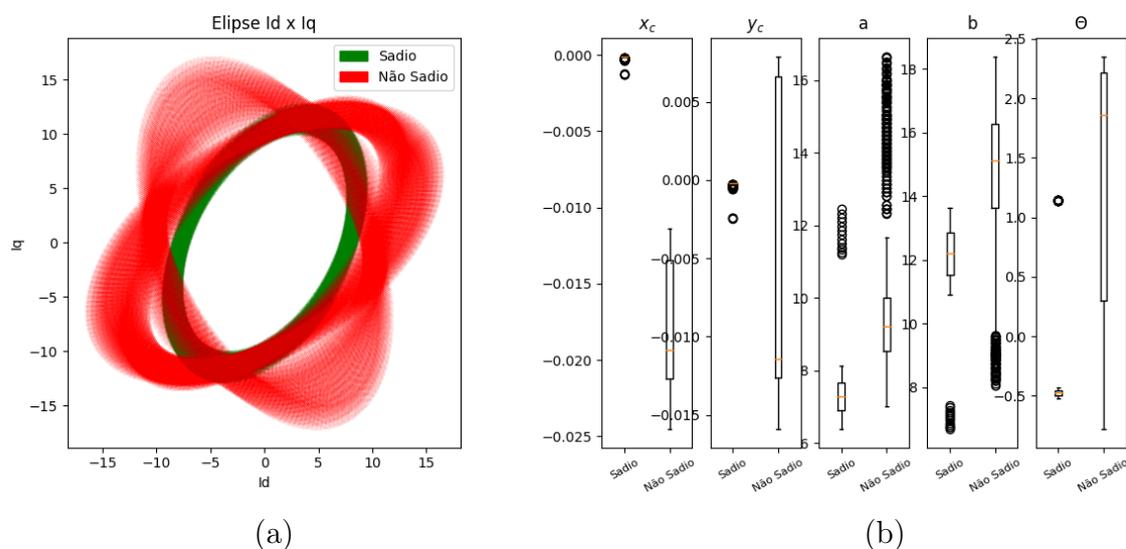


Figura 5.1: Janela gráfica na interface “Treinamento” no sistema de diagnóstico. Visualização das amostras da base de treinamento para o transformador de MT. (a) Visualização das amostras de forma geométrica. (b) Distribuição dos parâmetros das elipses em *box plots*.

Estatísticas do Treinamento						
	MLP		SVM		Árvore de Decisão	
	Não Sadio	Sadio	Não Sadio	Sadio	Não Sadio	Sadio
Não Sadio	963	0	963	0	963	0
Sadio	12	175	0	187	0	187
Acurácia	0.989565		1.0		1.0	

Estatísticas da Validação						
	MLP		SVM		Árvore de Decisão	
	Não Sadio	Sadio	Não Sadio	Sadio	Não Sadio	Sadio
Não Sadio	319	0	319	0	319	0
Sadio	1	64	0	65	0	65
Acurácia	0.997396		1.0		1.0	

Modelo com maior acurácia para o conjunto de validação: SVM

Figura 5.2: Janela de texto na interface “Treinamento” no sistema de diagnóstico. Caixa de texto das estatísticas do treinamento para o transformador de MT.

Para esta avaliação, 17 amostras sintéticas foram geradas fora do conjunto de treinamento para serem usadas para inferência. Assim como o conjunto de treinamento, estas amostras foram criadas variando parâmetros de operação do transformador. Essa coleção de novas amostras consiste predominantemente em casos não incluídos no conjunto de treinamento, permitindo avaliar a capacidade dos algoritmos de generalização.

No sistema, os resultados são apresentados por meio de representações gráficas da elipse da amostra e da alocação paramétrica de seus coeficientes no conjunto de treinamento. Além disso, os resultados de inferência são apresentados em forma de texto, incluindo as probabilidades atribuídas por cada modelo a cada classe para a amostra dada, a classificação atribuída por cada modelo e a classe final atribuída pelo modelo de melhor

desempenho determinado durante a fase de treinamento. A alocação de uma amostra inferida no conjunto de treinamento é mostrada na Figura 5.3(a), enquanto as magnitudes de seus parâmetros são indicadas pelas linhas azuis na Figura 5.3(b). A Figura 5.4 mostra a caixa de texto que descreve a classificação do sistema da amostra exemplificada.

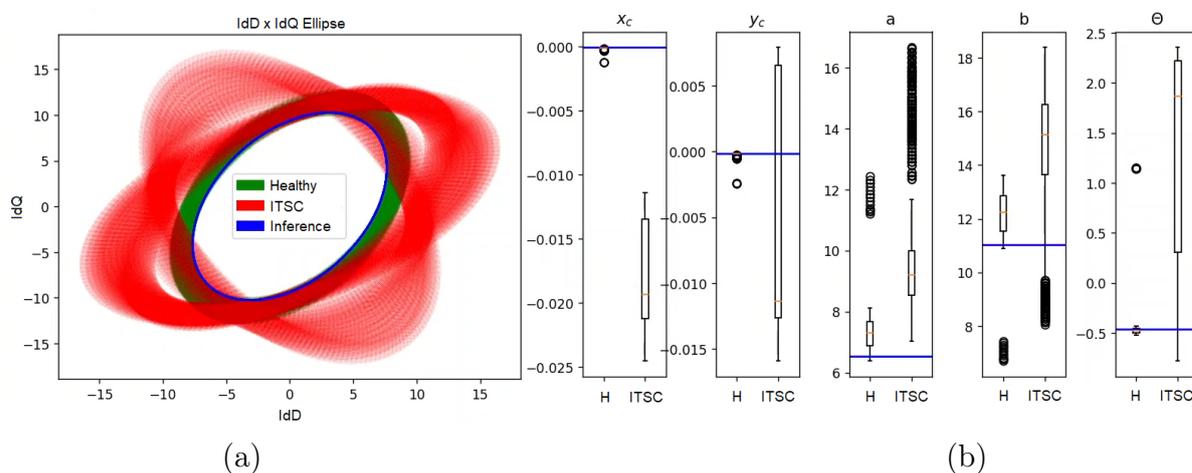


Figura 5.3: Janela gráfica na interface “Inferência” no sistema de diagnóstico. (a) Conjunto de elipses derivadas da simulação utilizando MEF para treinamento e inferência dos modelos de ML. (b) Distribuição dos parâmetros das elipses. As curvas vermelha e verde representam amostras rotuladas como saudáveis e com CEE do conjunto de treinamento. Os dados em azul destacam um exemplo de uma amostra sendo inferida no conjunto de treinamento.

Probabilidade do registro pertencer à classe:	MLP	SVM	Árvore de Decisão
Não Sadio	0.363931	0.061772	0.0
Sadio	0.636069	0.938228	1.0
Atribuição de Classe	MLP	SVM	Árvore de Decisão
Não Sadio			
Sadio	X	X	X
Classe atribuída pelo modelo de melhor desempenho na fase de ajuste:			
SVM -> Sadio			

Figura 5.4: Janela de texto na interface “Inferência” no sistema de diagnóstico. Caixa de texto da classificação de uma amostra de exemplo para o transformador de MT.

Neste exemplo específico, o algoritmo de SVM classificou a amostra inferida como sadia. Essa classificação é apoiada pela observação visual das indicações em azul na Figura 5.3(a) (elipse) e na Figura 5.3(b). A amostra inferida, destacada em azul, demonstra maior proximidade com as elipses verdes que representam a classe sadia (“*Healthy*”) do que com as elipses vermelhas que representam a classe com CEE (“*ITSC*”). Um padrão semelhante é observado para os coeficientes, que estão predominantemente dentro da faixa associada à classe sadia. Essas informações visuais visam auxiliar o usuário a compreender a indicação de classe fornecida pelos modelos de aprendizado de máquina.

A Tabela 5.1 apresenta um resumo dos resultados de classificação do sistema para as 17 amostras simuladas. Os dados na tabela incluem informações sobre as amostras: Número, Carga (pu) e Espiras em curto-circuito (pu); e os resultados da inferência: Probabilidade de ser sadio, probabilidade de ser não sadio e classe final atribuída pelo sistema à amostra. A Tabela 5.2 mostra a Matriz de Confusão das inferências para amostras simuladas.

Amostra	Carga [pu]	CEE [%]	Prob. Sadio	Prob. CEE	Classe
1	0.9	0.000	0.99	0.01	Sadio
2	1.0	0.000	1.00	0.00	Sadio
3	1.1	0.000	0.99	0.01	Sadio
4	1.0	0.417	1.00	0.00	Sadio
5	1.0	0.833	1.00	0.00	Sadio
6	1.0	1.250	0.99	0.01	Sadio
7	1.0	1.667	0.99	0.01	Sadio
8	1.0	2.083	0.32	0.68	Não Sadio
9	1.0	2.500	0.26	0.74	Não Sadio
10	1.0	3.750	0.12	0.88	Não Sadio
11	1.0	5.000	0.09	0.91	Não Sadio
12	1.0	6.250	0.04	0.96	Não Sadio
13	1.0	7.500	0.03	0.97	Não Sadio
14	1.0	8.750	0.01	0.99	Não Sadio
15	1.0	10.000	0.03	0.97	Não Sadio
16	1.0	11.250	0.04	0.96	Não Sadio
17	1.0	12.080	0.04	0.96	Não Sadio

Tabela 5.1: Amostras sintéticas do transformador de MT e classificação pelo sistema.

Sistema de Diagnóstico		Classe Real	
		Sadio	Não Sadio
Atribuição	Sadio	3	4
	Não Sadio	0	10
Acurácia		76.47%	

Tabela 5.2: Matriz de Confusão do sistema para as amostras simuladas.

A acurácia geral do sistema é de 76.47% para as amostras geradas. Porém, é notável que o sistema demonstra habilidade de generalização ao lidar com falhas que envolvem mais de 2% das espiras do enrolamento, obtendo uma taxa de classificação correta de 100% para essas amostras. Entretanto, todas as classificações incorretas foram observadas para as amostras com CEE afetando menos de 2% das espiras.

5.2 Corpo de Prova: Autotransformador Trifásico

O sistema de diagnóstico sofreu a primeira rodada de avaliação experimental por meio da montagem de um corpo de prova composto por um autotransformador trifásico variável. Este equipamento tem potência nominal de 2 kVA é configurado para uma relação de 220/32 V. Para este ensaio foi escolhido um autotransformador variável pois sua característica construtiva permite o acesso físico à partes eletricamente expostas dos enrolamentos para a inserção de CEE.

Segundo a metodologia proposta, é criada a modelagem computacional em MEF do equipamento. Este modelo é submetido a diversas situações de operação do equipamento. Estas situações são variadas em casos de funcionamento sadio e com CEE, para vários cenários de carga. Estas amostras sintéticas são colecionadas na base de treinamento que é utilizada pelos algoritmos de diagnóstico. A modelagem escolhida é a de um corte transversal no eixo da altura do núcleo toroidal, pois permite a assimetria na distribuição das correntes do enrolamento que representa o curto entre espiras. A base de dados sintéticos para treinamento é obtida através da simulação em elementos finitos cuja geometria é mostrada pela Figura 5.5.

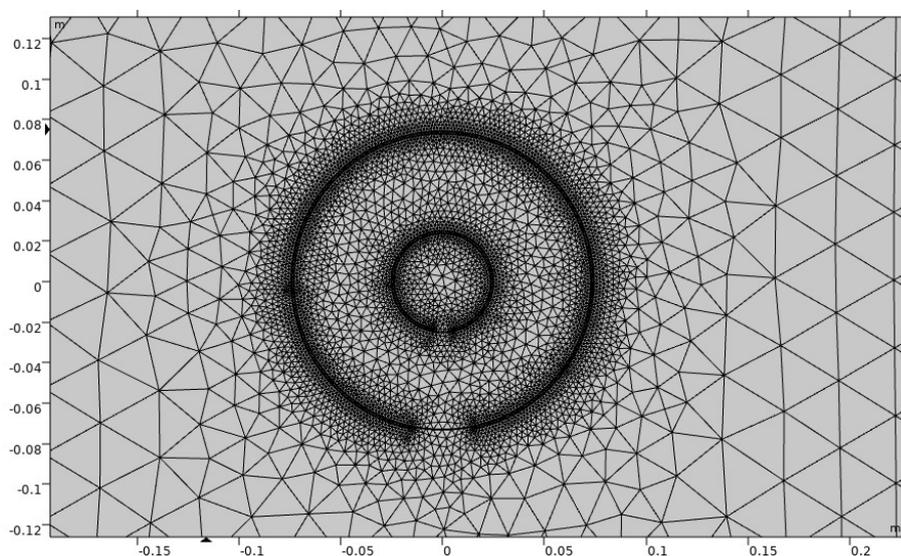


Figura 5.5: Geometria 2D do autotransformador trifásico utilizado como corpo de prova em simulação via MEF.

A interface “Treinamento” do sistema é mostrada pelas Figuras 5.6 e 5.7. A base de amostras de treinamento (Figura 5.6(a)) é composta por 372 amostras, obtidas a partir da variação do nível de carga do autotransformador simulado e da inserção de CEE em diferentes posições e fases. São parametrizados 7 valores de carga, 5 números de espiras em curto para os casos não sadios. Estes defeitos são aplicados em 2 posições diferentes em

cada uma das 3 fases, totalizando 210 amostras não sadias. A base de casos sadios é feita pela simulação do equipamento em 162 níveis diferentes de carga. Durante o treinamento do sistema, a SVM foi identificada como o modelo de maior acurácia para inferência, apresentando 100% de acurácia na base de validação, como mostrado na Figura 5.7.

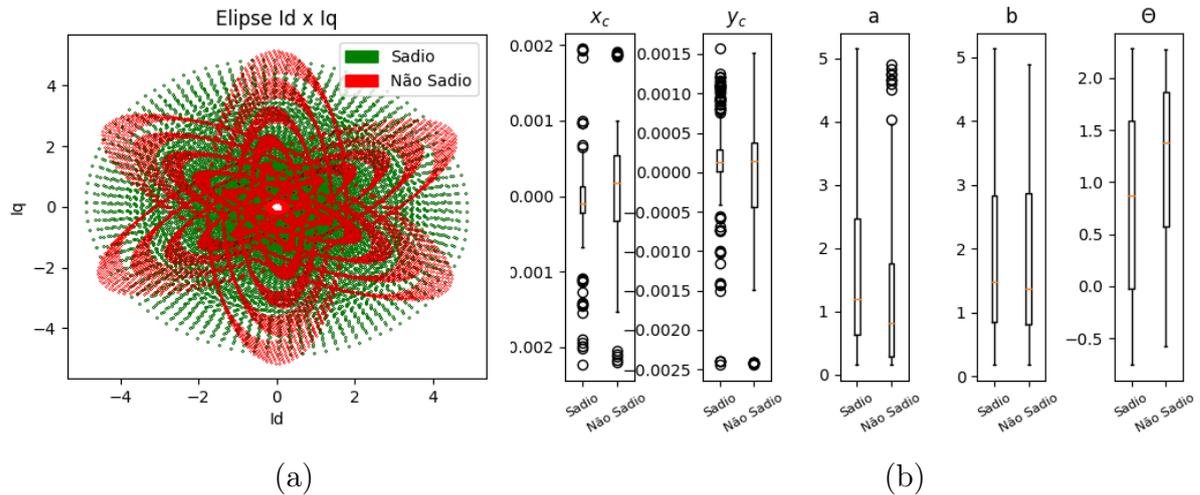


Figura 5.6: Janela gráfica na interface “Treinamento” no sistema de diagnóstico. Visualização das amostras da base de treinamento para o autotransformador trifásico. (a) Visualização das amostras de forma geométricas. (b) Distribuição dos parâmetros das elipses em *box plots*.

Estatísticas do Treinamento						
	MLP		SVM		Árvore de Decisão	
	Não Sadio	Sadio	Não Sadio	Sadio	Não Sadio	Sadio
Não Sadio	160	0	Não Sadio	160	0	0
Sadio	0	119	Sadio	0	119	119
Acurácia	1.0		Acurácia		1.0	
Estatísticas da Validação						
	MLP		SVM		Árvore de Decisão	
	Não Sadio	Sadio	Não Sadio	Sadio	Não Sadio	Sadio
Não Sadio	50	0	Não Sadio	50	0	0
Sadio	0	43	Sadio	0	43	43
Acurácia	1.0		Acurácia		1.0	
Modelo com maior acurácia para o conjunto de validação: SVM						

Figura 5.7: Janela de texto na interface “Treinamento” no sistema de diagnóstico. Caixa de texto das estatísticas do treinamento para o autotransformador trifásico.

Em seguida, são coletadas experimentalmente amostras tanto de situações sadias quanto de situações em falha, utilizadas para inferência no sistema. A Figura 5.8 mostra o equipamento com a caixa de proteção, enquanto a Figura 5.9 sem a caixa, permitindo uma visualização mais detalhada. O CEE é emulado ao se criar um caminho de corrente entre as espiras designadas como o pontos de início e final do curto-circuito. Isto implica que as espiras entre estes pontos não conduzem corrente elétrica. A relação entre o nú-

mero de espiras que não conduzem corrente e o número total de espiras é o que determina o percentual de espiras em curto.

A Figura 5.10 apresenta uma visão detalhada da parte do enrolamento do autotransformador que é acessível às escovas e onde o CEE é aplicado durante o experimento. A Figura 5.11 mostra o circuito monofásico equivalente utilizado em cada fase na montagem experimental. Para cada valor de carga, o CEE é aplicado em 2 pontos da parte da bobina correspondente à alta tensão, indicados por A e B na Figura 5.11.

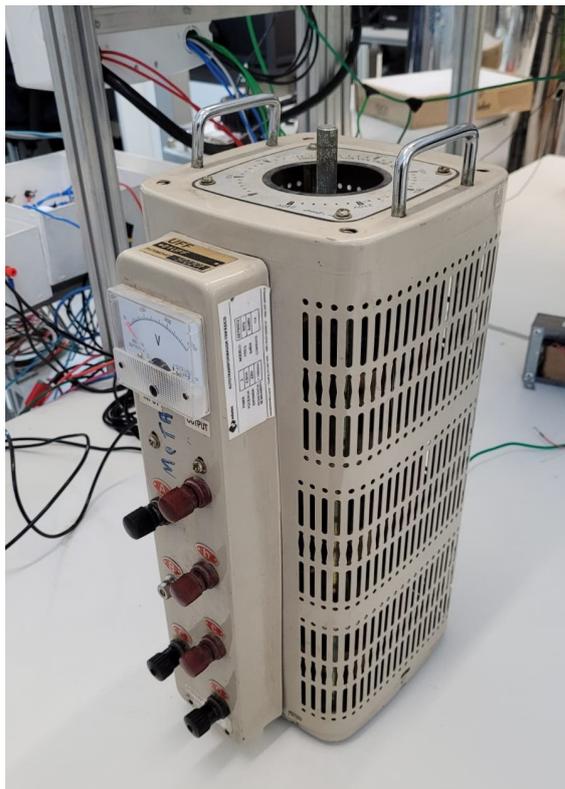


Figura 5.8: Autotransformador Trifásico utilizado no experimento.

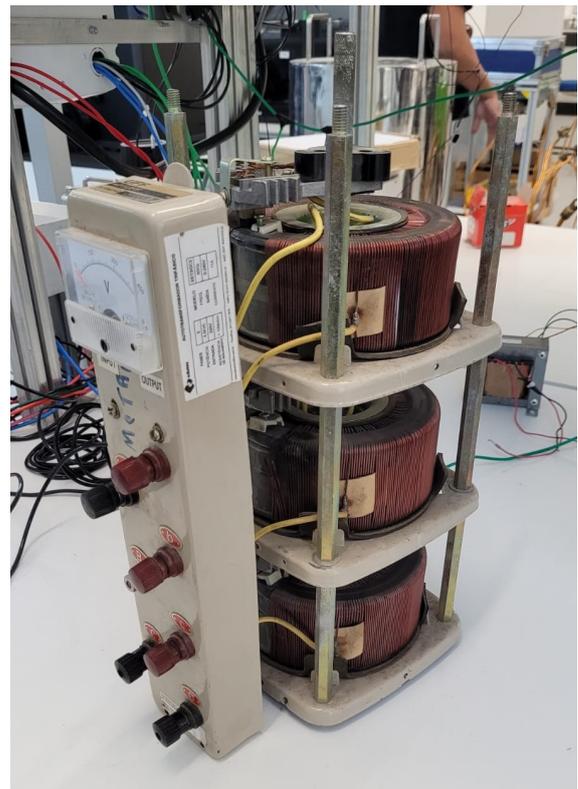


Figura 5.9: Autotransformador Trifásico com os enrolamentos expostos.

Posteriormente, amostras experimentais foram coletadas para inferência, incluindo cenários sadios e com falhas. Para a coleta das amostras dos casos de funcionamento sadio, foram variados apenas os níveis de carga nos valores de 0.5 pu, 1.0 pu e 1.1 pu, por meio do uso de um resistor variável. As correntes foram aquisitadas utilizando um osciloscópio de múltiplos canais isolados.

Para a criação dos casos de funcionamento em falha, além dos níveis de carga, foram variados o nível de CEE, com 2, 4 e 8 espiras em curto, e a posição da aplicação do CEE. Os dados coletados a partir dessas variações totalizam 21 amostras experimentais para inferência, incluindo casos de funcionamento sadio e casos com CEE. As elipses obtidas a partir dessas coletas são mostradas na Figura 5.12. É importante destacar que



Figura 5.10: Ilustração do método de aplicação de um curto de 4,65% aplicado ao enrolamento.

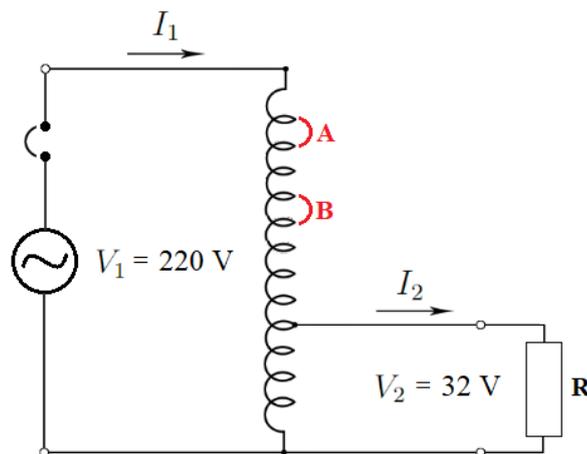


Figura 5.11: Circuito monofásico da montagem do corpo de prova.

o uso de um banco de testes com características físicas realistas e a aquisição de dados experimentais contribuem para a validação e confiabilidade do sistema proposto.

Posteriormente, a precisão da tomada de decisão do sistema de diagnóstico foi avaliada, confirmando sua eficácia no diagnóstico de CEE no autotransformador. A Figura 5.13 mostra a interface gráfica do sistema durante a inferência de uma amostra sadia do autotransformador trifásico. Na Figura 5.13(a), as amostras sadias e com CEE são representadas pelas elipses verdes e vermelhas, respectivamente. A elipse azul representa os dados experimentais de uma amostra sadia ao ser inferida no sistema. A Figura 5.13(b) apresenta os parâmetros das amostras em forma de *box plots*, alocando os parâmetros da amostra experimental como linhas azuis. A Figura 5.14 mostra as estatísticas detalhadas

da classificação da amostra pelo sistema, incluindo a probabilidade do registro pertencer a cada classe, a atribuição que cada algoritmo deu à amostra e a classe final atribuída pelo sistema.

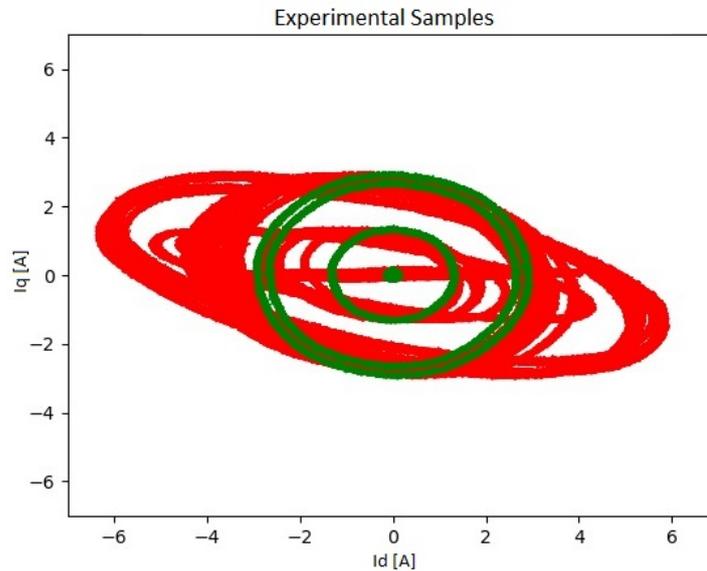


Figura 5.12: Elipses das amostras experimentais do Autotransformador Trifásico. Elipses verdes indicam amostras de caso sadio, enquanto as vermelhas indicam casos não sadios.

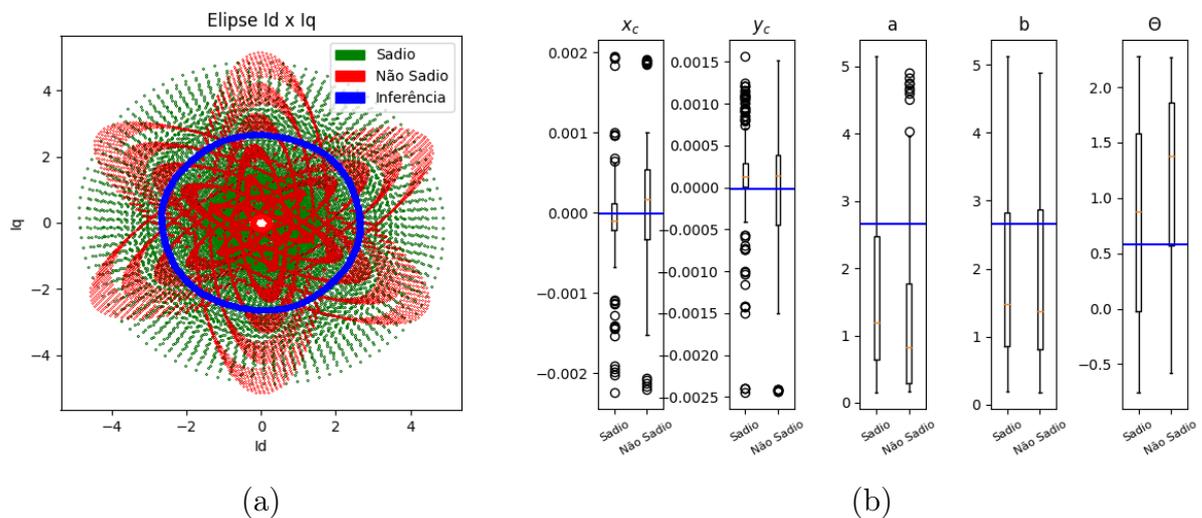


Figura 5.13: Janela gráfica da interface “Inferência” no sistema de diagnóstico. Visualização das amostras da base de treinamento e da amostra inferida no sistema. (a) Visualização das amostras de forma geométrica. (b) Distribuição dos parâmetros das elipses em *Box Plots*.

O procedimento de inferência de cada uma das 21 amostras é realizado e as classificações do sistema são resumidas pelas Tabelas 5.3, 5.4 e 5.5 na forma de Matrizes de Confusão. Os resultados obtidos a partir da inferência de amostras usando diferentes modelos de aprendizado de máquina fornecem evidências da eficácia do sistema de

diagnóstico proposto na classificação das amostras coletadas.

Probabilidade do registro pertencer à classe:		MLP	SVM	Árvore de Decisão
Não Sadio		0.103291	0.059212	0.0
Sadio		0.896709	0.940788	1.0
Atribuição de Classe		MLP	SVM	Árvore de Decisão
Não Sadio				
Sadio		X	X	X
Classe atribuída pelo modelo de melhor desempenho na fase de ajuste:				
SVM -> Sadio				

Figura 5.14: Janela gráfica na interface “Inferência” no sistema de diagnóstico. Caixa de texto das estatísticas da inferência de uma amostra sadia do autotransformador trifásico.

MLP		Classe Real	
		Sadio	Não Sadio
Atribuição	Sadio	3	17
	Não Sadio	0	1
Acurácia		19.05%	

Tabela 5.3: Matriz de Confusão do MLP para as amostras experimentais.

SVM		Classe Real	
		Sadio	Não Sadio
Atribuição	Sadio	2	0
	Não Sadio	1	18
Acurácia		95.23%	

Tabela 5.4: Matriz de Confusão do SVM para as amostras experimentais.

Árvore de Decisão		Classe Real	
		Sadio	Não Sadio
Atribuição	Sadio	3	0
	Não Sadio	0	18
Acurácia		100.0%	

Tabela 5.5: Matriz de Confusão da Árvore de Decisão para as amostras experimentais.

O SVM, identificado como o modelo de melhor desempenho durante a fase de treinamento, alcançou uma precisão de 95.23% na inferência de amostras experimentais válidas, com apenas uma amostra classificada erroneamente. Também o desempenho do modelo de Árvore de Decisão foi notável, alcançando 100.0% de acurácia nas amostras experimentais. Por outro lado, o MLP demonstrou alto nível de classificações incorretas, com somente 19.05% de acurácia.

5.3 Discussão

O sistema utiliza três modelos de aprendizado de máquina em simultâneo, embora não haja uma comparação direta entre os processos de treinamento. Não são aplicadas técnicas específicas de *ensemble learning*, como *Random Forests*, *Gradient Boosting Machines (GBM)*, *Adaboost*, *Bagging* e *Stacking*. Em vez disso, o sistema treina os modelos implementados separadamente e exibe os resultados individuais. Durante o treinamento, a única comparação realizada ocorre entre os algoritmos, identificando aquele que obteve a maior precisão no conjunto de validação. O treinamento do sistema é sempre realizado com a base de dados sintéticos gerados por meio de simulações com MEF. Posteriormente, o sistema treinado é aplicado para fazer inferências com dados reais coletados.

A representação da morfologia da nuvem de dados evidencia uma notável diferença entre as Figuras 5.1 e 5.6. Embora ambas as visualizações sejam constituídas por um gráfico de dispersão dos pontos adquiridos, a representação dos dados no transformador de MT simulado é realizada com um maior número de ciclos, resultando em uma nuvem mais compacta. Por outro lado, a simulação no autotransformador variável foi conduzida com um menor número de ciclos, devido a considerações de simplicidade. Esta abordagem resulta em um espaçamento maior entre os pontos no gráfico.

Os padrões gráficos exibidos pelas telas do sistema de diagnóstico demonstram distribuições bidimensionais (Figura 5.1(a)) e unidimensionais (Figura 5.1(b)). Apesar dessa representação, o sistema realiza uma análise em um espaço 5-D, composto pelos 5 parâmetros da elipse considerados. A despeito da impossibilidade de visualizar esse espaço, o sistema é capaz, por meio de cálculos matemáticos, de identificar as estruturas que distinguem os casos sadios dos casos não sadios nesse espaço multidimensional.

Na validação do sistema com dados simulados, os modelos de ML demonstraram capacidade de generalização satisfatória para as amostras geradas externamente à base de treinamento. É notada a facilidade da classificação das amostras cujos parâmetros de operação são semelhantes aos do conjunto de treinamento. Entretanto a detecção encontra desafios em amostras com baixo nível de CEE, destacando a importância de se expandir o conjunto de treinamento, abrangendo amostras que exibem estes níveis específicos de CEE. Isto aumentará a capacidade dos modelos de fazer inferências precisas para eventos semelhantes.

Já na validação experimental, foi notada uma maioria de classificações corretas tanto pelo SVM quanto pela Árvore de Decisão. Porém o algoritmo do MLP apresentou difi-

culdades na classificação da maioria das amostras, atingindo somente 19.05% de acurácia. A análise destas inferências indicam um possível *overfitting* durante o treinamento, o que faz o algoritmo se especializar nas amostras da base de treinamento. Isto reduz significativamente a capacidade de generalização do algoritmo.

Apesar destes efeitos, é comprovada a capacidade do tratamento de dados proposto em caracterizar as amostras para o fim do diagnóstico de CEE. Em sua grande maioria, os algoritmos foram capazes de classificar os registros com base no treinamento na base sintética, destacando a eficácia do método. Além disso, os resultados obtidos enfatizam a robustez do sistema ao incorporar múltiplos algoritmos de aprendizado de máquina. Esta técnica permite que o diagnóstico do equipamento se baseie em uma análise combinada das respostas dos classificadores, ao invés de estar limitado às características específicas de um único algoritmo. Os esforços de melhoria do sistema são contínuos ao longo do desenvolvimento projeto, visando o aprimoramento do sistema de inferência. Esta abordagem facilitará uma melhor adaptação dos modelos a cenários da vida real e contribuirá para aprimorar a confiabilidade e a precisão das inferências feitas, enfatizando a natureza preventiva da aplicação.

Capítulo 6

Conclusões e Trabalhos Futuros

Este capítulo resume as principais contribuições do estudo, apresenta conclusões sobre a eficácia da metodologia proposta para o sistema de detecção de curto-circuito entre espiras em transformadores a seco. Também inclui recomendações para pesquisas futuras, como possíveis aprimoramentos no sistema proposto e áreas para estudos posteriores.

6.1 Conclusão

O objetivo desta dissertação foi consolidar o conhecimento das técnicas empregadas no desenvolvimento do sistema de diagnóstico para transformadores de potência a seco com classificação IP23, com ênfase nos Curtos-circuitos Entre Espiras (CEE). Um destaque inovador deste sistema está na criação de uma base de dados de treinamento que se utiliza de amostras sintéticas geradas através de simulações com o Método dos Elementos Finitos (MEF). Essa metodologia elimina a necessidade exclusiva de dados históricos experimentais de equipamentos específicos, ampliando a capacidade de treinamento do sistema. O uso de amostras sintéticas oferece diversas vantagens, incluindo a capacidade de criar uma variedade de cenários de falhas, controlar variáveis experimentais e reduzir a dependência de dados históricos específicos.

Adicionalmente, a dissertação investiga a técnica de processamento de dados adotada, na qual as oscilografias de corrente do equipamento são apresentadas como Figuras de Lissajous para análise. Para os algoritmos de diagnóstico, a utilização de algoritmos de aprendizado de máquina, como Perceptron de Múltiplas Camadas (MLP), Classificador de Vetor de Suporte (SVC) e Árvore de Decisão, possibilita a classificação precisa de amostras sadias e com CEE. A incorporação de amostras sintéticas simuladas por MEF na base de dados de treinamento permite ao sistema generalizar e inferir de maneira confiável

além dos dados disponíveis. Estas abordagens combinadas aprimoram a eficácia do sistema de diagnóstico, tornando-o adaptável a diferentes configurações de transformadores e reduzindo a necessidade da demorada e dispendiosa coleta de dados de transformadores individuais.

Os resultados da pesquisa evidenciam a eficácia e o potencial da metodologia proposta para o sistema de diagnóstico. O desenvolvimento e validação bem-sucedidos deste sistema de diagnóstico contribuem para o campo de diagnóstico de transformadores, oferecendo suporte para a tomada de decisões na operação e manutenção de transformadores a seco. Isto permite uma abordagem proativa para a manutenção e minimização do tempo de inatividade.

6.2 Pesquisas Futuras

Os estudos realizados nesta dissertação apontam a possibilidade da realização de novas rodadas de validação experimental, principalmente no que se refere à relevância do ambiente de validação. O avanço experimental do protótipo, sua implementação em campo e a realização de novas etapas de validação e ajuste é um aspecto fundamental para eficácia do sistema em redes reais de potência.

Em relação à metodologia de tratamento de dados proposta, fica claro que a abordagem é eficaz nos cenários estudados. No entanto, é interessante investigar o desempenho do sistema em situações de operação não abordadas, principalmente para definir os limites de operação do sistema. Tais cenários podem envolver elevados níveis de desequilíbrio entre as fases, eventos transitórios, como partidas de motores e comutações de carga, ou cenários de baixa carga onde a característica não linear do núcleo se torna predominante.

Além disso, ficou evidente o trabalhoso processo de comissionamento do equipamento para a geração da base de dados de treinamento. Embora a utilização do MEF para a construção de bases prototípicas do sistema tenha sido fundamental para a concepção, é um procedimento demorado e oneroso. A exploração de outras metodologias para a criação da base de treinamento diretamente a partir de dados de placa pode se provar uma alternativa interessante, considerando a natureza modular do sistema. Uma possibilidade é a modelagem do transformador usando circuitos de relutância em plataformas de código aberto, como o Python.

Referências

- [1] KUMAR, P.; VERMA, P. Review Paper on Diagnostics Study of Dry Transformer. *CEUR Workshop Proceedings*, p. 9, 2021.
- [2] LEAL, G.; MEIRA, M.; BOSSIO, G.; ÁLVAREZ, R.; VERUCCHI, C. Detection of inter-turn short circuits in power transformers windings: State of the art. *2020 IEEE Congreso Bienal de Argentina, ARGENCON 2020 - 2020 IEEE Biennial Congress of Argentina, ARGENCON 2020*, Institute of Electrical and Electronics Engineers Inc., 12 2020.
- [3] LIMA, F. M.; AUGUSTO, A. A.; FERREIRA, H. Teoria da informação no desenvolvimento de redes neurais para diagnóstico de falhas em transformadores defasadores. *Congresso Brasileiro de Automática*, 2022.
- [4] NAFISI, H.; DAVARI, M.; ABEDI, M.; GHAREHPETIAN, G. B. Using fuzzy artmap neural network for determination of partial discharge location in power transformers. *2009 IEEE Bucharest PowerTech: Innovative Ideas Toward the Electrical Grid of the Future*, 2009.
- [5] LEI, C.; LI, L.; YANG, L.; WANG, Y. Design of dry-type transformer online monitoring and fault diagnosis system. *2020 IEEE 4th Conference on Energy Internet and Energy System Integration: Connecting the Grids Towards a Low-Carbon High-Efficiency Energy System, EI2 2020*, Institute of Electrical and Electronics Engineers Inc., p. 1010–1013, 10 2020.
- [6] BISHOP, C. M. *Pattern Recognition and Machine Learning*.: Springer Science and Business Media, LLC, 2006.
- [7] HAYKIN, S. S. *Neural networks and learning machines*. 3rd. ed.: Prentice Hall/Pearson, 2009. 906 p. ISBN 9780131471399.
- [8] FERREIRA, V. *Desenvolvimento de Modelos Neurais Autônomos para Previsão de Carga Elétrica*. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2008.
- [9] AKHAVANHEJAZI, M.; GHAREHPETIAN, G. B.; FARAJI-DANA, R.; MORADI, G. R.; MOHAMMADI, M.; ALEHOSEINI, H. A. A new on-line monitoring method of transformer winding axial displacement based on measurement of scattering parameters and decision tree. *Expert Systems with Applications*, v. 38, n. 7, p. 8886–8893, 7 2011. ISSN 09574174.
- [10] FAN, J.; WANG, F.; SUN, Q.; BIN, F.; YE, H.; LIU, Y. An Online Monitoring System for Oil Immersed Power Transformer Based on SnO2 GC Detector with a New Quantification Approach. *IEEE Sensors Journal*, Institute of Electrical and Electronics Engineers Inc., v. 17, n. 20, p. 6662–6671, 10 2017. ISSN 1530437X.

- [11] ŽARKOVIĆ, M.; STOJKOVIĆ, Z. Analysis of artificial intelligence expert systems for power transformer condition monitoring and diagnostics. *Electric Power Systems Research*, Elsevier Ltd, v. 149, p. 125–136, 8 2017. ISSN 03787796.
- [12] FAN, J.; FU, C.; YIN, H.; WANG, Y.; JIANG, Q. Power transformer condition assessment based on online monitor with SOFC chromatographic detector. *International Journal of Electrical Power and Energy Systems*, Elsevier Ltd, v. 118, 6 2020. ISSN 01420615.
- [13] SOUAHLIA, S.; BACHA, K.; CHAARI, A. MLP neural network-based decision for power transformers fault diagnosis using an improved combination of Rogers and Dornenburg ratios DGA. *International Journal of Electrical Power and Energy Systems*, v. 43, n. 1, p. 1346–1353, 12 2012. ISSN 01420615.
- [14] AIZPURUA, J. I.; STEWART, B. G.; MCARTHUR, S. D.; LAMBERT, B.; CROSS, J. G.; CATTERSON, V. M. Improved power transformer condition monitoring under uncertainty through soft computing and probabilistic health index. *Applied Soft Computing Journal*, Elsevier Ltd, 2019. ISSN 15684946.
- [15] YANG, X.; CHEN, W.; LI, A.; YANG, C.; XIE, Z.; DONG, H. BA-PNN-based methods for power transformer fault diagnosis. *Advanced Engineering Informatics*, Elsevier Ltd, v. 39, p. 178–185, 1 2019. ISSN 14740346.
- [16] SILVA, A. C. M. E. D.; CASTRO, A. R. G.; MIRANDA, V. Transformer failure diagnosis by means of fuzzy rules extracted from Kohonen Self-Organizing Map. *International Journal of Electrical Power and Energy Systems*, v. 43, n. 1, p. 1034–1042, 12 2012. ISSN 01420615.
- [17] ILLIAS, H. A.; CHAI, X. R.; BAKAR, A. H. A. Hybrid modified evolutionary particle swarm optimisation-time varying acceleration coefficient-artificial neural network for power transformer fault diagnosis. *Measurement: Journal of the International Measurement Confederation*, Elsevier B.V., v. 90, p. 94–102, 8 2016. ISSN 02632241.
- [18] NING, L.; WU, W.; ZHANG, B.; ZHANG, P. A time-varying transformer outage model for on-line operational risk assessment. *International Journal of Electrical Power and Energy Systems*, v. 33, n. 3, p. 600–607, 3 2011. ISSN 01420615.
- [19] ELSISI, M.; TRAN, M.; MAHMOUD, K.; MANSOUR, D.-E. A.; LEHTONEN, M.; DARWISH, M. M. Effective IoT-based deep learning platform for on-line fault diagnosis of power transformers against cyberattacks and data uncertainties. *Measurement*, v. 190, p. 110686, 2 2022. ISSN 02632241. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0263224121015475>>.
- [20] HUA, Y.; SUN, Y.; XU, G.; SUN, S.; WANG, E.; PANG, Y. A fault diagnostic method for oil-immersed transformer based on multiple probabilistic output algorithms and improved DS evidence theory. *International Journal of Electrical Power & Energy Systems*, Elsevier BV, v. 137, p. 107828, 5 2022. ISSN 01420615.
- [21] SILVA, D. G. T. D.; SILVA, H. J. B. D.; MARAFÃO, F. P.; PAREDES, H. K. M.; GONÇALVES, F. A. S. Enhanced health index for power transformers diagnosis. *Engineering Failure Analysis*, Elsevier Ltd, v. 126, 8 2021. ISSN 13506307.

- [22] LOPES, S. M. d. A.; FLAUZINO, R. A.; ALTAFIM, R. A. C. Incipient fault diagnosis in power transformers by data-driven models with over-sampled dataset. *Electric Power Systems Research*, Elsevier Ltd, v. 201, 12 2021. ISSN 03787796.
- [23] VELÁSQUEZ, R. M. A.; LARA, J. V. M. Root cause analysis improved with machine learning for failure analysis in power transformers. *Engineering Failure Analysis*, Elsevier Ltd, v. 115, 9 2020. ISSN 13506307.
- [24] MORAIS, D. R.; BENCZ, E.; ROLIM, J. G. Condition assessment of power transformers through the integration of historical and on-line data in a multi-agent system. *Journal of Control, Automation and Electrical Systems*, Springer New York LLC, v. 25, n. 1, p. 93–102, 2014. ISSN 21953899.
- [25] ISLAM, M. M.; LEE, G.; HETTIWATTE, S. N. A nearest neighbour clustering approach for incipient fault diagnosis of power transformers. *Electrical Engineering*, Springer Verlag, v. 99, n. 3, p. 1109–1119, 9 2017. ISSN 14320487.
- [26] KUNICKI, M.; BORUCKI, S.; ZMARZŁY, D.; FRYMUS, J. Data acquisition system for on-line temperature monitoring in power transformers. *Measurement: Journal of the International Measurement Confederation*, Elsevier B.V., v. 161, 9 2020. ISSN 02632241.
- [27] SEO, J.; MA, H.; SAHA, T. Probabilistic Wavelet Transform for Partial Discharge Measurement of Transformer. *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 22, n. 2, 2015.
- [28] RODRÍGUEZ-SERNA, J. M.; ALBARRACÍN-SÁNCHEZ, R.; GARNACHO, F.; ÁLVAREZ, F.; ORTEGO, J. Partial Discharges Measurements for Condition Monitoring and Diagnosis of Power Transformers: A Review. *6th International Advanced Research Workshop on Transformers (ARWtr)*, 2019.
- [29] WALCZAK, K.; SIKORSKI, W. Non-contact high voltage measurement in the on-line partial discharge monitoring system. *Energies*, MDPI, v. 14, n. 18, 9 2021. ISSN 19961073.
- [30] XIE, B.; ZHAO, D.; HONG, T. Transformer Monitoring and Protection in Dynamic Power Systems – A Review. *Frontiers in Energy Research*, Frontiers Media S.A., v. 8, 7 2020. ISSN 2296598X.
- [31] FARIA, J. R.; LIMA, D. M.; CARDOSO, F. J. A smart multi-sensor for the diagnosis of distribution transformers. *2018 IEEE SENSORS*, p. 1–4, 2018.
- [32] WERLE, P.; BORSI, H.; GOCKENBACH, E. Diagnosing the insulation condition of dry type transformers using a multiple sensor partial discharge localization technique. *Conference Record of IEEE International Symposium on Electrical Insulation*, p. 166–169, 2002. ISSN 01642006.
- [33] N. A. Muhamad; S.A.M. Ali. LabVIEW with Fuzzy Logic Controller Simulation Panel for Condition Monitoring of Oil and Dry Type Transformer Controller. *World Academy of Science, Engineering and Technology*, 2006.

- [34] SRINIVASAN, M.; PARAMASIVAM, S.; KRISHNAN, A. Low cost digital measurement system for determination of temperature rise in dry type transformer. *Int. J. Instrumentation Technology*, v. 1, n. 1, p. 72–83, 2011.
- [35] GOCKENBACH, E.; WERLE, P.; BORSI, H. Monitoring and diagnostic systems for dry type transformers. *IEEE International Conference on Conduction and Breakdown in Solid Dielectrics*, p. 291–294, 2001.
- [36] MEIRA, M.; RUSCHETTI, C. R.; ÁLVAREZ, R. E.; VERUCCHI, C. J. Power transformers monitoring based on electrical measurements: State of the art. *IET Generation, Transmission and Distribution*, Institution of Engineering and Technology, v. 12, n. 12, p. 2805–2815, 7 2018. ISSN 17518687.
- [37] WANI, S. A.; RANA, A. S.; SOHAIL, S.; RAHMAN, O.; PARVEEN, S.; KHAN, S. A. Advances in DGA based condition monitoring of transformers: A review. *Renewable and Sustainable Energy Reviews*, Elsevier Ltd, v. 149, 10 2021. ISSN 18790690.
- [38] KRUGER, M. DIAGNOSIS AND FAULT FINDINGS ON POWER TRANSFORMERS Line Impedance and Mutual Coupling of electrical power lines View project. 2014. Disponível em: <<https://www.researchgate.net/publication/269463325>>.
- [39] PREVOST, T. Transformer Bushing Monitoring Detect Bushing and Insulation Defects Before they Can Cause a Failure Peak Measure Transformer Seminar Wilsonville OR. p. 1–39, 8 2014.
- [40] POWER, T. Committee of the I.; SOCIETY, E. *IEEE Guide for Application for Monitoring Equipment to Liquid-Immersed Transformers and Components Sponsored by the Transformers Committee IEEE Power and Energy Society.*, 2012.
- [41] RAGHAVAN, A.; KIESEL, P.; TEEPE, M.; CHENG, F.; CHEN, Q.; KARIN, T.; JUNG, D.; MOSTAFAVI, S.; SMITH, M.; STINSON, R.; KITTRELL, B.; SHIN, J.; LEE, S.; LACARRUBBA, N. Low-cost embedded optical sensing systems for distribution transformer monitoring. *IEEE Transactions on Power Delivery*, Institute of Electrical and Electronics Engineers Inc., v. 36, n. 2, p. 1007–1014, 4 2021. ISSN 19374208.
- [42] HENRIQUES, H. O.; BARBERO, A. P.; RIBEIRO, R. M.; FORTES, M. Z.; XAVIER, O. S.; PEQUENO, M. A.; VABO, C. G. Proposal of fault prediction system for underground installations. *Measurement: Journal of the International Measurement Confederation*, Elsevier B.V., v. 81, p. 232–240, 3 2016. ISSN 02632241.
- [43] CHANDRAN, L. R.; BABU, G. S. A.; NAIR, M. G.; ILANGO, K. A review on status monitoring techniques of transformer and a case study on loss of life calculation of distribution transformers. *Materials Today: Proceedings*, Elsevier Ltd, v. 46, p. 4659–4666, 2019. ISSN 22147853.
- [44] ZHAO, J.; YUE, X. Condition monitoring of power transmission and transformation equipment based on industrial internet of things technology. *Computer Communications*, Elsevier B.V., v. 157, p. 204–212, 5 2020. ISSN 1873703X.
- [45] LEAL, G.; MEIRA, M.; VERUCCHI, C.; RUSCHETTI, C.; BOSSIO, G. Comparison of online techniques for the detection of inter-turn short-circuits in transformers.

- 2021 19th Workshop on Information Processing and Control, RPIC 2021*, Institute of Electrical and Electronics Engineers Inc., 2021.
- [46] MEIRA, M.; RUSCHETTI, C. R.; ÁLVAREZ, R. E.; VERUCCHI, C. J. Power transformers monitoring based on electrical measurements: state of the art. *IET Generation, Transmission & Distribution*, v. 12, n. 12, p. 2805–2815, jul. 2018. ISSN 1751-8695, 1751-8695. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1049/iet-gtd.2017.2086>>.
- [47] KANG, Y.-C.; LEE, B.-E.; ZHENG, T.-Y.; KIM, Y.-H.; CROSSLEY, P. Protection, faulted phase and winding identification for the three-winding transformer using the increments of flux linkages. *IET Generation, Transmission & Distribution*, v. 4, n. 9, p. 1060, 2010. ISSN 17518687. Disponível em: <<https://digital-library.theiet.org/content/journals/10.1049/iet-gtd.2010.0094>>.
- [48] KANG, Y.; LEE, B.; KANG, S.; CROSSLEY, P. Transformer protection based on the increment of flux linkages. *IEE Proceedings - Generation, Transmission and Distribution*, v. 151, n. 4, p. 548, 2004. ISSN 13502360. Disponível em: <<https://digital-library.theiet.org/content/journals/10.1049/ip-gtd20040378>>.
- [49] ZHAO, X.; YAO, C.; ZHOU, Z.; LI, C.; WANG, X.; ZHU, T.; ABUSIADA, A. Experimental Evaluation of Transformer Internal Fault Detection Based on $V - I$ Characteristics. *IEEE Transactions on Industrial Electronics*, v. 67, n. 5, p. 4108–4119, maio 2020. ISSN 0278-0046, 1557-9948. Disponível em: <<https://ieeexplore.ieee.org/document/8730484/>>.
- [50] Chenguo Yao; Zhongyong Zhao; Yu Chen; Xiaohan Chen; Chengxiang Li; Wei Li; Jian Wang. Detection of internal winding faults in power transformers based on graphical characteristics of voltage and current. *2014 ICHVE International Conference on High Voltage Engineering and Application*, IEEE, Poznan, Poland, p. 1–4, set. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/7035475/>>.
- [51] OLIVEIRA, L. M. R.; CARDOSO, A. J. M. A Permeance-Based Transformer Model and Its Application to Winding Interturn Arcing Fault Studies. *IEEE Transactions on Power Delivery*, v. 25, n. 3, p. 1589–1598, jul. 2010. ISSN 0885-8977, 1937-4208. Disponível em: <<http://ieeexplore.ieee.org/document/5406040/>>.
- [52] VENIKAR, P. A.; BALLAL, M. S.; UMRE, B. S.; SURYAWANSHI, H. M. Condition assessment of transformer by park's vector and symmetrical components to detect inter turn fault. *2013 IEEE 1st International Conference on Condition Assessment Techniques in Electrical Systems (CATCON)*, IEEE, Kolkata, India, p. 163–168, dez. 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6737491/>>.
- [53] EISSA, M. M.; SHEHAB-ELDIN, E. H.; MASOUD, M. E.; ABD-ELATIF, A. S. Digital technique for power transformer fault detection based on positive sequence admittance approach. *2008 12th International Middle-East Power System Conference*, IEEE, Aswan, Egypt, p. 517–522, mar. 2008. Disponível em: <<http://ieeexplore.ieee.org/document/4562348/>>.

- [54] VAHEDI, A.; BEHJAT, V. Online monitoring of power transformers for detection of internal winding short circuit faults using negative sequence analysis. *European Transactions on Electrical Power*, v. 21, n. 1, p. 196–211, jan. 2011. ISSN 1430144X. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1002/etep.431>>.
- [55] FITZGERALD, A. E.; KINGSLEY, C.; UMANS, S. D. *Máquinas Elétricas: Com Introdução à Eletrônica de Potência*. 6. ed. Brasil: Bookman, 2006. 603 p.
- [56] CHAPMAN, S. J. *Fundamentos de Máquinas Elétricas*. 5. ed. Brasil: AMGH, 2013. 700 p.
- [57] ELECTRONICS, I. for P.; DRIVES, R. A. U. E.; QI, F.; SCHARFENSTEIN, D.; WEISS, C.; MÜLLER, C.; SCHWARZER, U. *Motor Handbook*. [S.l.], março 2019. Acessado em 01/09/2023 às 19h57. Disponível em: <https://www.infineon.com/dgdl/Infineon-motorcontrol_handbook-AdditionalTechnicalInformation-v01_0-EN.pdf?fileId=5546d4626bb628d7016be6a9aa637e69>.
- [58] VERUCCHI, C. J.; ACOSTA, G. G.; BENGER, F. A. *A REVIEW ON FAULT DIAGNOSIS OF INDUCTION MACHINES*. 2008. 113-121 p.
- [59] ZAREI, J.; POSHTAN, J. An advanced park's vectors approach for bearing fault detection. *Tribology International*, v. 42, n. 2, p. 213–219, 2009. ISSN 0301-679X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0301679X08001291>>.
- [60] LI, W.; QIAO, J.; WANG, Y.; LIU, R.; LV, T.; YIN, X. Fault diagnosis method of stator windings short circuit for variable speed pumped storage unit based on park transform. *2022 5th International Conference on Energy, Electrical and Power Engineering (CEEPE)*, p. 507–512, 2022.
- [61] Ben Salem, S.; BACHA, K.; CHAARI, A. Support vector machine based decision for mechanical fault condition monitoring in induction motor using an advanced hilbert-park transform. *ISA Transactions*, v. 51, n. 5, p. 566–572, 2012. ISSN 0019-0578. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S001905781200081X>>.
- [62] Erik Leandro Bonaldi; Luiz Eduardo Borges da Silva; Levy Ely de Lacerda de Oliveira; Germano Lambert-Torres; Felipe dos Santos Moreira; Giscard F. C. Veloso. *Deteção de Defeitos em Transformadores de Potência Utilizando o Sinal de Corrente do Aterramento.*, 2013.
- [63] OLIVEIRA, L. M.; CARDOSO, A. J. Comparing power transformer turn-to-turn faults protection methods: Negative sequence component versus space-vector algorithms. *IEEE Transactions on Industry Applications*, Institute of Electrical and Electronics Engineers Inc., v. 53, p. 2817–2825, 5 2017. ISSN 00939994.
- [64] WEI, S.; ZHANG, L.; FU, Y.; ZHANG, K.; LI, Z. Early fault detection based on the park's vector locus ovality for inter-turn faults in stator windings of the offshore wind dfig. *Zhongguo Dianji Gongcheng Xuebao/Proceedings of the Chinese Society of Electrical Engineering*, v. 37, p. 3001–3009, 05 2017.

- [65] GREENSLADE THOMAS B., J. All about Lissajous figures. *The Physics Teacher*, v. 31, n. 6, p. 364–370, 09 1993. ISSN 0031-921X. Disponível em: <<https://doi.org/10.1119/1.2343802>>.
- [66] CUNNINGHAM, P.; CORD, M.; DELANY, S. J. Supervised learning. In: _____. *Machine Learning Techniques for Multimedia: Case Studies on Organization and Retrieval*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 21–49. ISBN 978-3-540-75171-7. Disponível em: <https://doi.org/10.1007/978-3-540-75171-7_2>.
- [67] NASTESKI, V. An overview of the supervised machine learning methods. *Horizons*, v. 4, p. 51–62, 2017. Disponível em: <<https://api.semanticscholar.org/CorpusID:171520859>>.
- [68] HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. Unsupervised learning. In: _____. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York, NY: Springer New York, 2009. p. 485–585. ISBN 978-0-387-84858-7. Disponível em: <https://doi.org/10.1007/978-0-387-84858-7_14>.
- [69] WIERING, M.; OTTERLO, M. *Reinforcement Learning: State-of-the-art*. 1. ed. Springer Berlin, Heidelberg, 2012. XXXIV, 638 p. (Adaptation, Learning, and Optimization). ISBN 978-3-642-27644-6 (Hardcover), 978-3-642-44685-6 (Softcover), 978-3-642-27645-3 (eBook). Disponível em: <<https://link.springer.com/book/10.1007/978-3-642-27645-3>>.
- [70] DAYAN, P.; NIV, Y. Reinforcement learning: The good, the bad and the ugly. *Current Opinion in Neurobiology*, v. 18, n. 2, p. 185–196, 2008. ISSN 0959-4388. Cognitive neuroscience. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0959438808000767>>.
- [71] SPECHT, D. F. Probabilistic neural networks for classification, mapping, or associative memory. Publ by IEEE, p. 525–532, 1988.
- [72] HARA, K.; SAITO, D.; SHOUNO, H. Analysis of function of rectified linear unit used in deep learning. *Proceedings of the International Joint Conference on Neural Networks*, Institute of Electrical and Electronics Engineers Inc., v. 2015-September, 9 2015.
- [73] KALMAN, B.; KWASNY, S. Why tanh: choosing a sigmoidal function. [*Proceedings 1992/ IJCNN International Joint Conference on Neural Networks*, v. 4, p. 578–581 vol.4, 1992.
- [74] KALOEV, M.; KRASSTEV, G. Comparative analysis of activation functions used in the hidden layers of deep neural networks. *2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*, p. 1–5, 2021.
- [75] CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995.
- [76] BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R.; STONE, C. *Classification and Regression Trees*. Wadsworth, 1984.

-
- [77] OY, R. H.; FLUSSER, J. Numerically stable direct least squares fitting of ellipses. 1998.
- [78] KINGMA, D. P.; BA, J. *Adam: A Method for Stochastic Optimization*. arXiv, 2014. Disponível em: <<https://arxiv.org/abs/1412.6980>>.
- [79] ZHANG, Z. Improved adam optimizer for deep neural networks. *2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS)*, p. 1–2, 2018.