

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS GRADUAÇÃO EM
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO

Abordagens Baseadas em Processamento de Sinais e Inteligência Artificial para
Identificar a Inserção de Contato Principal e Resistivo em Disjuntores SF6

Philippe Augusto Varme Dias Liz

Itajubá, Novembro de 2024

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS GRADUAÇÃO EM
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO

Philippe Augusto Varme Dias Liz

Abordagens Baseadas em Processamento de Sinais e Inteligência Artificial para
Identificar a Inserção de Contato Principal e Resistivo em Disjuntores SF6

Dissertação submetida ao Programa de Pós-Graduação em Ciência e Tecnologia da Computação como parte dos requisitos para obtenção do Título de Mestre em Ciência e Tecnologia da Computação

Área de Concentração: Matemática da Computação

Orientador: Prof. Dr. Giovani Bernardes Vitor

Co-Orientador: Prof. Dr. Eben Ezer Prates da Silveira

Novembro de 2024
Itajubá - MG

Agradecimentos

Agradeço primeiramente à minha família, que esteve ao meu lado durante toda esta jornada. Ao meu filho Henrique, pela compreensão de que, em alguns momentos, o papai não pôde brincar como gostaria. À minha esposa, pela paciência, suporte e apoio incondicional durante este período de dedicação.

À minha mãe, que desde cedo me incentivou a valorizar os estudos, plantando em mim a semente da curiosidade e do aprendizado contínuo.

Agradeço ao professor Sandro pela oportunidade de ingressar no mestrado, permitindo que eu trilhasse este caminho de crescimento pessoal e profissional.

Ao meu orientador, pelo suporte técnico, orientação precisa e pela contribuição valiosa para a realização deste trabalho.

*Eu vi coisas que vocês não imaginariam. Naves de ataque em
chamas ao largo de Órion. Eu vi raios-c brilharem na escuridão
próximos ao Portal de Tannhäuser. Todos esses momentos se
perderão no tempo, como lágrimas na chuva.*

Roy Batty

Resumo

Os disjuntores de alta tensão desempenham um papel vital em uma subestação, facilitando a conexão e desconexão de cargas, bem como isolando o sistema durante condições de falta. Dentre os problemas relacionados aos disjuntores que operam com bancos de capacitores, um dos principais está relacionado à operação de fechamento que pode gerar altos transientes de corrente de partida, associados a altas frequências. Esses transientes podem causar danos e desgaste prematuro aos disjuntores e aos equipamentos da rede a eles conectados. Assim, o monitoramento dos principais parâmetros dos disjuntores torna-se essencial para antecipar falhas e estimar sua vida útil, resultando em ganhos econômicos, operacionais e estratégicos. Nesse sentido, este trabalho apresenta uma abordagem baseada em processamento de sinais e Inteligência Artificial (IA) para identificar os instantes de inserção do resistor de pré-inserção e do contato principal durante a operação de um disjuntor de alta tensão a SF6. Para isso, os sinais de corrente e tensão de uma subestação brasileira real são utilizados como entradas dos modelos baseados em IA, resultando em um vetor de características com 600 linhas e 82 colunas, considerando os ruídos e interferências comuns neste tipo de ambiente. Assim, a modelagem proposta considera as etapas de pré-processamento do sinal com técnicas como derivada discreta, integral, transformadas no domínio da frequência e wavelets, para reduzir ruídos e destacar características relevantes para extração de características, a geração do conjunto de dados para treinamento do modelo, a utilização de diferentes técnicas de aprendizado de máquina e a utilização de dois modelos de aprendizado de máquina para avaliação: o Perceptron Multicamadas (MLP) e o classificador AdaBoost, ambos treinados para identificar automaticamente os pontos críticos do sinal para encontrar automaticamente os pontos desejados e, por fim, a identificação dos melhores momentos para comutação controlada dos disjuntores. Os resultados demonstraram que o MLP obteve 94% de acurácia precisão, enquanto o AdaBoost alcançou 95% de acurácia precisão. As conclusões indicam que as metodologias propostas são robustas para uso em ambientes reais, permitindo prever falhas com maior confiabilidade, otimizar a manutenção e reduzir custos operacionais. Assim, o trabalho contribui diretamente para a melhoria do sincronismo de fechamento em disjuntores de alta tensão e a mitigação de transientes críticos no sistema elétrico.

Resumo

High-voltage circuit breakers play a vital role in a substation, facilitating the connection and disconnection of loads, as well as isolating the system during fault conditions. Among the problems related to circuit breakers operating with capacitor banks, one of the main issues is related to the closing operation, which can generate high inrush current transients associated with high frequencies. These transients may cause damage and premature wear to the circuit breakers and the grid equipment connected to them. Thus, monitoring the main parameters of circuit breakers becomes essential to anticipate failures and estimate their useful life, resulting in economic, operational, and strategic gains. In this context, this work presents an approach based on signal processing and Artificial Intelligence (AI) to identify the instants of insertion of the pre-insertion resistor and the main contact during the operation of a high-voltage SF6 circuit breaker. To this end, current and voltage signals from a real Brazilian substation are used as inputs to the AI-based models, resulting in a feature vector with 600 rows and 82 columns, considering the noise and interference common in this type of environment. Thus, the proposed modeling considers signal pre-processing steps with techniques such as discrete derivative, integral, frequency-domain transforms, and wavelets, to reduce noise and highlight relevant features for feature extraction, the generation of the dataset for model training, the use of different machine learning techniques, and the use of two machine learning models for evaluation: the Multilayer Perceptron (MLP) and the AdaBoost classifier, both trained to automatically identify the critical points in the signal and, finally, the identification of the best moments for controlled switching of the circuit breakers. The results showed that the MLP achieved 94% accuracy, while the AdaBoost reached 95% accuracy. The conclusions indicate that the proposed methodologies are robust for use in real-world environments, allowing for more reliable fault prediction, optimized maintenance, and reduced operational costs. Thus, the work directly contributes to improving the closing synchronism in high-voltage circuit breakers and mitigating critical transients in the electrical system.

Sumário

	Sumário	6
	Lista de ilustrações	8
	Lista de tabelas	10
1	INTRODUÇÃO	12
1.1	Contextualização e motivação	12
1.2	Problema/Desafio	13
1.3	Objetivos	13
1.3.1	Objetivo Geral	13
1.3.2	Objetivo Específico	13
1.4	Justificativa	14
1.5	Organização do trabalho	15
2	REVISÃO BIBLIOGRÁFICA	16
2.1	Trabalhos Relacionados	16
2.2	Embasamento Teórico	19
2.2.1	Disjuntor Alta Tensão SF ₆	19
2.2.1.1	Contato Resistivo e Contato Principal	20
2.2.1.2	Avaliação da Saúde dos Contatos e Sincronismo Operacional	22
2.2.2	Filtros Temporais	22
2.2.2.1	Derivada e Integral Discreta	22
2.2.2.2	Média Móvel	24
2.2.2.3	Mediana	25
2.2.2.4	Filtro Savitzky-Golay	25
2.2.3	Transformadas no Domínio da Frequência	27
2.2.3.1	Transformada de Fourier	27
2.2.3.2	Transformada Cosseno Discreta	28
2.2.3.3	Transformada de Hilbert	30
2.2.4	Filtro Butterworth	32
2.2.5	Transformada Wavelet	32
2.2.6	Aprendizado de Máquina	36
2.2.6.1	Adaptive Boosting	36
2.2.6.2	Multi-Layer Perceptron (MLP)	37
2.2.6.3	Balanceamento de Dados	38
2.2.6.3.1	Nível dos Dados	39
2.2.6.3.2	Nível do Algoritmo	39
2.2.6.3.3	Métodos Híbridos	40
2.2.6.3.4	<i>Synthetic Minority Oversampling Technique</i>	40
2.2.6.4	Práticas de Avaliação de Modelos	40
2.2.6.5	<i>Overfitting</i> e <i>Underfitting</i> em Aprendizado de Máquina	42
3	DESENVOLVIMENTO PROPOSTO	43

3.1	Metodologia de Pesquisa	43
3.1.1	Carregamento de Dados e Detecção do Ponto de Pré-inserção	44
3.1.2	Geração do Conjunto de Dados	45
3.1.3	Treinamento e Teste do Modelo	48
3.1.3.1	Ampliação e normalização dos dados	49
3.1.3.2	Perceptron multicamadas - MLP	49
3.1.3.3	Boosting Adaptativo - AdaBoost	49
3.1.4	Validação Cruzada	49
3.1.5	Análise dos tempos envolvidos nas manobras do disjuntor	51
4	RESULTADOS E DISCUSSÕES	52
4.1	Resultados Quantitativos	52
4.1.1	Análise de Treinamento e Validação dos Modelos	52
4.1.1.1	Cenário 1: Somente Derivada	52
4.1.1.2	Cenário 2: Somente Sinal Corrente	53
4.1.1.3	Cenário 3: Sinal Corrente e Tensão	53
4.1.1.4	Análise dos Cenários	53
4.1.1.4.1	Cenário Sinal Derivada	54
4.1.1.4.2	Cenário Somente Corrente.	54
4.1.1.4.3	Cenário Corrente e Tensão	55
4.1.2	Análise Estatística dos Tempos dos Disjuntores	58
5	CONCLUSÃO	63
5.0.1	Publicações Relacionadas	63
5.0.2	Trabalhos Futuros	63
	REFERÊNCIAS	65

Lista de ilustrações

Figura 1 – Tensão no barramento e no banco do disjuntor e características de fechamento.(LUZ et al., 2009)	16
Figura 2 – Características extraídas da onda de tensão. (GOLDSWORTHY et al., 2008) .	17
Figura 3 – Caraterísticas extraídas da corrente e tensão no trabalho de (SUN et al., 2018)	18
Figura 4 – Esquema do motor de acionamento e do controlador desenvolvido em (LIU et al., 2022)	18
Figura 5 – Disjuntor SF ₆ . Criado pelo autor.	20
Figura 6 – Operação de Abertura e Fechamento de um disjuntor SF ₆	21
Figura 7 – Sinal e sua derivada. Criado pelo Autor	23
Figura 8 – Sinal e sua integral. Criado pelo Autor	25
Figura 9 – Sinal filtrado pela média móvel. Criado pelo Autor	26
Figura 10 – Sinal filtrado pela mediana. Criado pelo Autor	27
Figura 11 – Sinal filtrado por Savitzky-Golay. Criado pelo Autor	28
Figura 12 – Sinal filtrado por FFT cortando frequência acima de 100 Hz. Criado pelo Autor	29
Figura 13 – Sinal filtrado por DCT. Criado pelo Autor	30
Figura 14 – Projeção Hilbert (1), sinal real (2), sinal analítico (3), plano complexo (4), criado por (FELDMAN, 2011)	30
Figura 15 – Sinal filtrado por Hilbert. Criado pelo Autor	31
Figura 16 – Sinal filtrado por Butterworth. Criado pelo Autor	33
Figura 17 – Decomposição Wavelet, criado por (HAIDER et al., 2015), adaptado para o português pelo autor.	34
Figura 18 – Wavelets Mãe, criado por (MADHU; KUMARASWAMY, 2022)	34
Figura 19 – Sinal filtrado por Wavelet mantendo apenas os coeficientes de menor nível. Criado pelo Autor	35
Figura 20 – Relação entre estatística, inteligência artificial e aprendizado de máquina. Adaptada de (RATTAN DANIEL D. PENRICE, 2022) pelo autor.	36
Figura 21 – Exemplo de rede <i>feed foward</i> (POPESCU et al., 2009)	38
Figura 22 – Exemplos de sinais de corrente.	44
Figura 23 – Metodologia proposta para o desenvolvimento deste trabalho.	44
Figura 24 – (a) Sinal sem ruído antes do contato resistivo. (b) Sinal com ruído antes do contato resistivo. (c) Derivada do sinal sem ruído antes do contato resistivo. (d) Derivada do sinal com ruído antes do contato resistivo.	45
Figura 25 – Definição da janela de busca para o contato principal. (a) a janela de busca foi definida a partir do sinal de corrente bruto, e (b) o sinal especificamente nessa janela.	46
Figura 26 – Algumas respostas do banco de filtros aplicado.	46
Figura 27 – Sinais de Corrente(linha preta) e Tensão(linha azul).	48
Figura 28 – Arquitetura do MLP desenvolvida para este trabalho. Possui 82 neurônios de entrada, 100 neurônios na camada oculta e 2 na camada de saída.	50
Figura 29 – AdaBoost com 500 classificadores fracos.	50
Figura 30 – Acurácia Entre Cenários	54
Figura 31 – Avaliação dos Modelos. a) Acurácia; b) Precisão; c) <i>F1 Score</i> ; d) <i>Recall</i> ; e) Especificidade; f) AUC-ROC	56

Figura 32 – Curva de Aprendizado do AdaBoost.	57
Figura 33 – Curva de Aprendizado do MLP.	57
Figura 34 – Sinais Marcados Automaticamente.Linha Preta: Contato resistivo; Linha Vermelha: Contato principal marcado corretamente.	58
Figura 35 – Sinal Marcado Automaticamente de Forma Errônea. Linha Preta: Contato resistivo; Linha Vermelha: Contato principal marcado erroneamente.	58
Figura 36 – Correlação dos Dados	59
Figura 37 – Distribuição do Intervalo entre Contatos.	59
Figura 38 – Corrente de Inrush ao Longo dos Anos.	60
Figura 39 – Corrente de Inrush e Fases.	60
Figura 40 – Intervalo entre o Contato Principal e o Cruzamento por Zero da Corrente.	61
Figura 41 – Intervalo entre Contato Principal e Cruzamento por Zero das Fases.	61
Figura 42 – Sincronismo entre Fases.	62

Lista de tabelas

Tabela 1 – Tabela com filtros e parâmetros.	47
Tabela 2 – Distribuição dos sinais no conjunto de dados por ano.	48
Tabela 3 – Parâmetros Utilizados na Validação Cruzada K-Fold.	51
Tabela 4 – Métricas de Desempenho dos Modelos (Somente Derivada)	53
Tabela 5 – Métricas de Desempenho dos Modelos (Somente Sinal Corrente)	53
Tabela 6 – Métricas de Desempenho dos Modelos.	53
Tabela 7 – Resumo estatístico de acurácia por cenário e modelo.	54
Tabela 8 – Distribuição dos Sinais por Ano	58

Glossário

IA	<i>Inteligência Artificial</i>
FFT	<i>Fast Fourier Transform</i>
DCT	<i>Discrete Cosine Transform</i>
AdaBoost	<i>Adaptive Boosting Classifier</i>
MLP	<i>Multilayer Perceptron</i>
FPD	<i>Function-Switching Pseudo-Differential</i>
Ht	<i>Transformada de Hilbert</i>
SMOTE	<i>Synthetic Minority Oversampling Technique</i>
SVM	<i>Support Vector Machines</i>
ROC	<i>Receiver Operating Characteristic</i>
ReLU	<i>Rectified Linear Unit</i>
SF6	<i>Hexafluoreto de enxofre</i>
RIR ou RPI	<i>Resistor de Pré-Inserção</i>
SE	<i>Subestação</i>
SEP	<i>Sistema Elétrico de Potência</i>
PID	<i>Proporcional-Integral-Derivativo</i>

1 Introdução

1.1 Contextualização e motivação

Em Sistemas Elétricos de Potência (SEP), os disjuntores desempenham um papel crítico em subestações (SE), sendo responsáveis por operações de conexão e desconexão de cargas, bem como por isolar o sistema em situações de falha. Durante condições normais de operação, esses equipamentos conduzem corrente e controlam a operação de forma confiável. Entretanto, em situações de falha, os disjuntores podem realizar manobras complexas para isolar ou eliminar erros, incluindo a interrupção de linhas de transmissão, barramentos e até subestações inteiras (GAO et al., 2021).

A ocorrência de falhas nos disjuntores representa um grande risco para a segurança do sistema elétrico e pode acarretar prejuízos financeiros significativos para os agentes do setor. Por esse motivo, o monitoramento contínuo dos principais parâmetros desse equipamento torna-se essencial para a antecipação de falhas e estimativa da vida útil, gerando benefícios econômicos, operacionais e estratégicos.

Diversos fatores podem contribuir para o surgimento de falhas em disjuntores, incluindo idade, níveis de tensão, frequência de operação e atividades de manutenção. A análise desses fatores é fundamental para aprimorar a segurança e otimizar as decisões de manutenção (HU et al., 2022). Técnicas de diagnóstico, como a análise de vibração (ZHANG et al., 2022), medição da corrente das bobinas (JI et al., 2019) e monitoramento da corrente das fases (KEZUNOVIC et al., 2005), têm demonstrado serem ferramentas valiosas na avaliação das condições operacionais dos disjuntores. Essas abordagens permitem a obtenção de informações detalhadas sem a necessidade de desmontagem do equipamento.

Entre os desafios relacionados aos disjuntores que operam em sistemas com bancos de capacitores, destaca-se o sincronismo das manobras de fechamento. Essa falta de sincronismo pode causar altos níveis de transientes de corrente de *inrush*, frequentemente associados a frequências elevadas. Tais transientes podem danificar o disjuntor, os bancos de capacitores e equipamentos adjacentes ou remotos, resultando em desgaste prematuro, impactos na gestão da manutenção e, em casos extremos, na indisponibilidade de ativos e perdas financeiras (LUZ et al., 2009).

Estas sobretensões de manobra são fenômenos críticos em sistemas de alta tensão, caracterizadas por durações típicas de 1 a 3 ciclos e determinantes para o dimensionamento de isolamentos elétricos. Esses fenômenos podem ser originados por eventos como energizações e religamentos de linhas, manobras de capacitores e reatores, e ocorrem principalmente devido ao instante de fechamento e à dispersão entre os polos dos disjuntores envolvidos (GARBELOTTI, 2006).

As sobretensões podem ser classificadas em três categorias principais: temporárias, atmosféricas e de manobra. As sobretensões temporárias, de frequência industrial e longa duração, geralmente são causadas por eventos como manobras e ferro-ressonância. Já as sobretensões atmosféricas são do tipo transitórias rápidas, decorrentes de descargas elétricas. Por fim, as sobretensões de manobra, foco deste trabalho, são as mais relevantes para sistemas de alta tensão, apresentando características oscilatórias e determinando os requisitos de isolamento de linhas de transmissão e subestações. Essas sobretensões podem resultar em elevados estresses elétricos e mecânicos para os equipamentos conectados (GARBELOTTI, 2006).

Para mitigar os efeitos negativos desses fenômenos, propõe-se o uso de dispositivos de chaveamento controlado. Esses dispositivos atuam nos circuitos de comando das bobinas dos disjuntores,

assegurando que as manobras de fechamento ocorram nos momentos mais favoráveis. O objetivo principal é minimizar as sobretensões e sobrecorrentes associadas às manobras, garantindo maior confiabilidade e eficiência na operação do sistema. Porém, o desempenho desses dispositivos depende de fatores como o tempo de resposta dos disjuntores, as condições climáticas e a precisão dos algoritmos de controle (GARBELOTTI, 2006).

Os dispositivos de chaveamento controlado oferecem vantagens em comparação com outras tecnologias de mitigação de transitórios, como resistores de pré-inserção e pára-raios. Enquanto essas tecnologias buscam limitar os efeitos das sobretensões após sua ocorrência, o chaveamento controlado atua de forma preventiva, ajustando os tempos de manobra para evitar os picos de sobretensão. Esse método, portanto, não apenas reduz os danos aos equipamentos, mas também otimiza o desempenho geral do sistema elétrico (GARBELOTTI, 2006).

1.2 Problema/Desafio

Em SEs, a verificação do sincronismo de fechamento dos disjuntores é uma prática comum durante as manutenções preventivas, visando garantir que os equipamentos operem dentro de parâmetros seguros (Agência Nacional de Energia Elétrica (ANEEL), 2023). Contudo, entre os intervalos dessas manutenções, o tempo de atuação do disjuntor pode variar devido a fatores como desgaste mecânico, condições climáticas ou flutuações na carga elétrica. Essas variações podem impedir que o disjuntor feche no momento exato em que a corrente passa pelo zero, o que é essencial para minimizar os transientes elétricos. Quando isso ocorre, surgem altos picos de corrente de *inrush* e oscilações de alta frequência, acelerando o desgaste dos contatos e demais componentes do equipamento, além de aumentar os riscos de falhas e interrupções no sistema elétrico.

Durante a operação de fechamento, dois momentos específicos são particularmente importantes: o ponto de pré-inserção e o ponto de contato principal. O ponto de pré-inserção ocorre quando o resistor de pré-inserção é ativado, reduzindo transientes iniciais de corrente e tensão, enquanto o ponto de contato principal marca o instante em que o circuito é completamente fechado, permitindo a condução plena da corrente.

Identificar esses instantes com precisão é essencial para sincronizar as manobras de fechamento, minimizando os transientes de alta frequência que podem causar danos aos disjuntores e aos equipamentos conectados. No entanto, em ambientes reais de SEs, a identificação desses pontos é desafiadora devido a ruídos, interferências, variações no tempo de atuação dos disjuntores, bem como as perturbações geradas pelas manobras de outros disjuntores incluídas no banco de capacitores, o que reforça a necessidade de abordagens robustas para monitoramento e análise.

1.3 Objetivos

1.3.1 Objetivo Geral

Visando atenuar os transitórios durante a manobra do disjuntor, o presente trabalho propõe um estudo e modelagem utilizando processamento de sinais e IA para encontrar os pontos de pré-inserção e contato principal usando como entrada os sinais de corrente e tensão dos disjuntores em uma subestação elétrica, considerando todos os ruídos e interferências geradas em um ambiente significativo de uma SE real.

1.3.2 Objetivo Específico

Para alcançar este objetivo geral, foram estabelecidos os seguintes objetivos específicos:

- Criar um *dataset* de treinamento a partir das medidas das corrente das fases dos disjuntores, implementando um banco de filtros passa-baixa, passa-alta, Transformada *Wavelets* (TW), Transformada de Fourier (TF), *Discrete Cosine Transform*(DCT), Transformada Hilbert-Huang e filtro de Savitzky-Golay para eliminar ruídos e destacar os sinais de interesse.
- Desenvolver e treinar modelos de aprendizado de máquina, incluindo o classificador de Reforço Adaptativo (do inglês *AdaBoost Classifier*) e o Perceptron de Multicamadas (do inglês *Multilayer Perceptron, MLP*), para identificar automaticamente o ponto de fechamento do conector principal a partir dos sinais de corrente pré-processados.
- Avaliar a acurácia, precisão e outras métricas de desempenho dos modelos em diferentes combinações de técnicas de pré-processamento, a fim de determinar a abordagem mais eficaz para a identificação do ponto de fechamento do conector principal.
- Aplicar e validar a solução proposta em um ambiente de testes com dados reais de disjuntores de alta tensão (345kV) da SE de Tijuco Preto, garantindo que a metodologia desenvolvida possa ser utilizada na prática para prever falhas e otimizar a manutenção.
- Realizar o cálculo dos dados históricos de tempo de operação para avaliação dos tempos característicos dos disjuntores que operam com banco de capacitores, verificando padrões de comportamento e possíveis desvios que possam impactar o seu funcionamento.

1.4 Justificativa

Os disjuntores de alta tensão desempenham um papel essencial em sistemas de transmissão e distribuição de energia elétrica, garantindo a operação segura e eficiente do sistema. No entanto, falhas nesses equipamentos podem levar a interrupções significativas no fornecimento de energia, resultando em custos elevados, tanto diretos quanto indiretos, para empresas e consumidores. Em um setor onde a confiabilidade dos ativos é fundamental, a otimização da manutenção preventiva de disjuntores é um fator crítico para garantir a continuidade operacional e evitar prejuízos financeiros.

Um dos principais desafios enfrentados pelas concessionárias é o custo variável associado à indisponibilidade dos ativos. Quando um disjuntor apresenta falhas inesperadas, não apenas os custos de reparo são elevados, mas também os custos indiretos, como multas regulatórias, penalizações contratuais e perdas decorrentes de interrupções no fornecimento. Além disso, a substituição não planejada de equipamentos frequentemente requer alocação emergencial de recursos e pode gerar atrasos na restauração do serviço. Por outro lado, manutenções realizadas de forma inadequada ou prematura aumentam os custos operacionais, reduzindo a eficiência financeira.

A identificação precisa dos instantes de entrada do resistor de pré-inserção e do contato principal do disjuntor, é essencial na determinação nos ajustes do chaveamento controlado, uma vez que permitem calcular o tempo de fechamento e avaliar o sincronismo com a corrente, informações que são essenciais para uma análise detalhada das características operacionais do equipamento. Quando analisados de maneira sistemática, esses dados podem ser usados para prever falhas potenciais, melhorar a gestão de manutenção e prolongar a vida útil dos ativos, reduzindo custos associados.

Além disso, o impacto da falta de sincronismo no fechamento de disjuntores pode resultar em danos significativos aos equipamentos conectados, como transformadores e bancos de capacitores, agravando ainda mais os custos associados à manutenção corretiva. Em sistemas de alta tensão, esse impacto é amplificado devido às elevadas correntes de inrush e aos transientes de alta frequência, que podem comprometer a integridade estrutural dos disjuntores e aumentar os riscos de falhas catastróficas.

Dessa forma, a justificativa deste trabalho reside na necessidade de desenvolver uma metodologia avançada que permita identificar automaticamente os pontos de fechamento dos conectores principais e de pré-inserção, utilizando técnicas de processamento de sinais e aprendizado de máquina. Essa abordagem não apenas melhora a precisão na identificação de falhas, mas também contribui para reduzir os custos de manutenção, aumentar a confiabilidade do sistema e minimizar os impactos financeiros associados à indisponibilidade dos ativos.

1.5 Organização do trabalho

O trabalho está organizado em 5 capítulos. No primeiro foi apresentada a introdução. No segundo são apresentados trabalhos relacionados à este e os embasamentos teóricos utilizados no desenvolvimento da pesquisa. No terceiro é apresentado a metodologia que sustentou a pesquisa e os módulos de proposta de solução para o problema apresentado. No quarto capítulo são apresentados os resultados da pesquisa. Por fim, no quinto capítulo é concluído o trabalho apresentando as discussões dos resultados, as contribuições feitas, as limitações e os trabalhos futuros.

2 Revisão Bibliográfica

A revisão bibliográfica apresentada neste capítulo é dividida em duas partes principais. A primeira parte, descrita na Seção 2.1, explora trabalhos relacionados que abordam o uso de diferentes sensores e técnicas aplicadas à análise e ao controle de disjuntores de alta tensão, com foco na mitigação de transientes e no sincronismo de manobras. Esses estudos fornecem uma base sólida para entender as abordagens existentes e identificar lacunas a serem abordadas nesta pesquisa. A segunda parte, detalhada na Seção 2.2, apresenta o embasamento teórico necessário para o desenvolvimento do trabalho, incluindo os conceitos fundamentais de processamento de sinais e aprendizado de máquina, com destaque para as técnicas utilizadas na análise dos sinais de corrente dos disjuntores. Juntas, essas seções contextualizam e fundamentam a proposta desta dissertação.

2.1 Trabalhos Relacionados

Esta seção apresenta e analisa trabalhos publicados que investigam disjuntores de alta tensão, com foco na extração de características relevantes para melhorar o sincronismo do controlador de manobra. Esses estudos fornecem uma base importante para compreender as abordagens existentes, identificar suas limitações e destacar os avanços mais recentes no monitoramento e controle de disjuntores.

Motivados por falhas em autotransformadores ocorridas entre os anos de 2005 e 2006 em uma subestação real, Luz et al. (LUZ et al., 2009) discutem o ajuste de sincronizadores na operação de fechamento de bancos de capacitores para reduzir os transientes de corrente e tensão que ocorreram durante o fechamento dos disjuntores dos bancos de capacitores, ilustrado na Figura 1. Medições manuais de transientes foram realizadas nos terminais do autotransformador, e foram feitos ajustes do sincronizador atrasando o tempo de fechamento, visando a redução das correntes transientes. Finalmente, foi observada uma diminuição significativa nas correntes máximas e nas variações de tensão, resultando em menor desgaste dos componentes auxiliares dos disjuntores, o que aumenta a confiabilidade e a longevidade de transformadores e bancos de capacitores.

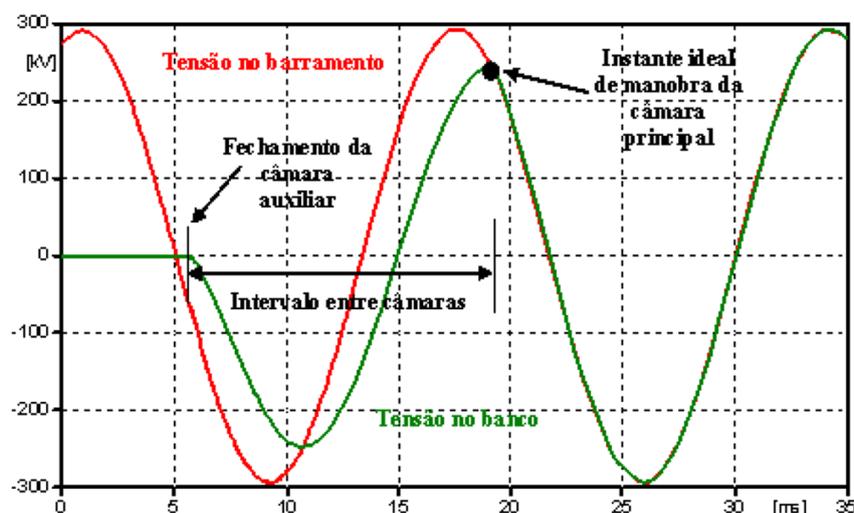


Figura 1 – Tensão no barramento e no banco do disjuntor e características de fechamento. (LUZ et al., 2009)

Com o mesmo objetivo de sincronizar o mecanismo de fechamento para reduzir transientes, Goldsworthy et al. (GOLDSWORTHY et al., 2008) desenvolveram um sistema que determina os pontos de inserção com base na forma de onda da tensão e alinha o fechamento com o tempo de operação do contato no zero de tensão. Diferentemente de outros trabalhos, este não utiliza o resistor de pré-inserção e implementa o controle ponto-sobre-a-onda (point-on-wave) para determinar o tempo e o sincronismo como ilustrado na Figura 2. O trabalho é validado por meio de experimentos de campo, comparando dados de comutação antes e depois da implementação do controle.

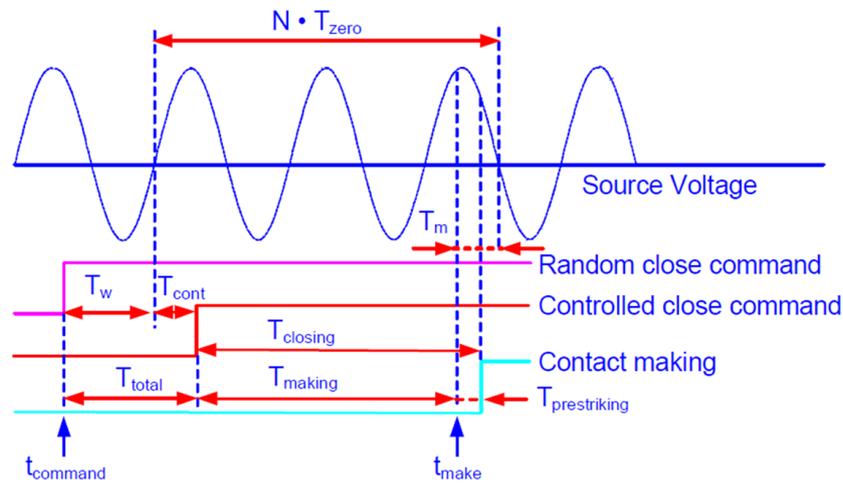


Figura 2 – Características extraídas da onda de tensão. (GOLDSWORTHY et al., 2008)

Sun et al. (SUN et al., 2018) investigam o sincronismo de comutação controlada utilizando simulações em tempo real, ajustando e analisando detalhadamente o impacto de diferentes parâmetros, como o tamanho do resistor, o ângulo de inserção e o tempo de operação do contato. Monitorando a queda de tensão entre os contatos e o aumento súbito da corrente como ilustrado na Figura 3, eles conseguem identificar o momento exato em que ocorre o fechamento, usando a taxa de decaimento dielétrico dos contatos como referência. Concluem que ajustar o ângulo de inserção e o tempo de pré-inserção é essencial para mitigar eficazmente os transientes de comutação. No entanto, todas as operações são realizadas por meio de simulações que não consideram os ruídos e interferências presentes em um sistema real.

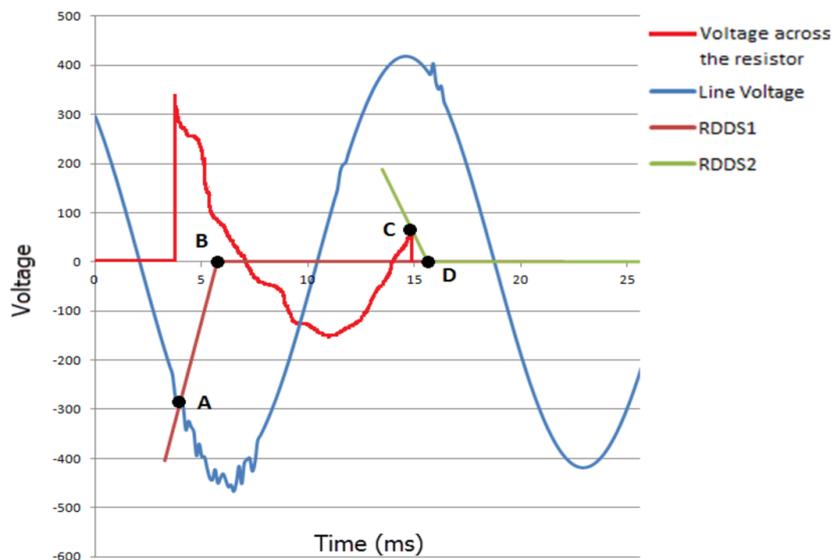


Figura 3 – Características extraídas da corrente e tensão no trabalho de (SUN et al., 2018)

Liu et al. (LIU et al., 2022) desenvolveram um motor de acionamento, e um controlador para garantir precisão no fechamento dos contatos no ponto de zero de tensão (ilustrado na Figura 4). O controlador utiliza a abordagem FPD (Pseudo-Diferencial de Troca de Funções), que ajusta dinamicamente os parâmetros de controle de acordo com a fase do movimento dos contatos, reduzindo a complexidade de cálculo típica do controle PID convencional, que depende de diferenciação direta das variáveis. Comparado ao PID (Proporcional-Integral-Derivativo), o FPD apresenta maior velocidade de resposta e menor carga computacional. O ponto de inserção é identificado monitorando a rotação do motor e o movimento dos contatos. Essa nova abordagem foi comparada a estratégias convencionais, como o controle PID e o controle de torque constante, demonstrando maior precisão e estabilidade, com erros de fechamento dentro de $\pm 0,5$ ms.

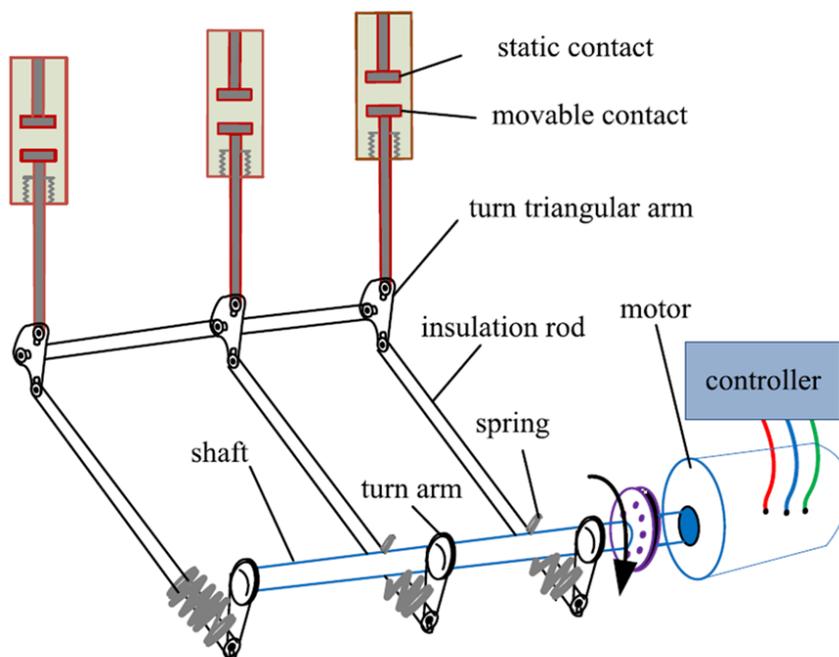


Figura 4 – Esquema do motor de acionamento e do controlador desenvolvido em (LIU et al., 2022)

Várias metodologias inteligentes têm sido utilizadas para prever e diagnosticar falhas em disjuntores. Alguns desses trabalhos são baseados em técnicas de inteligência artificial (IA) e aprendizado de máquina (AM). Os trabalhos de Razi-Kazemi et al. (RAZI-KAZEMI et al., 2014) e Razi-Kazemi (RAZI-KAZEMI, 2015) utilizam técnicas baseadas em redes neurais artificiais (ANNs) e máquinas de vetores de suporte (SVMs) para avaliar características da curva de deslocamento e da corrente das bobinas de abertura e fechamento dos disjuntores. Em Gao et al. (GAO et al., 2019) e Zhou, Xue e Zhou (2019)(ZHOU; XUE; ZHOU, 2019), sinais de vibração são avaliados utilizando técnicas de SVM e ANN. Além das técnicas de IA e AM mencionadas, existem outros métodos de processamento de sinais, como o uso da transformada de Fourier e da Wavelet, que também auxiliam na previsão e diagnóstico de falhas em disjuntores, como em Ji et al. (JI et al., 2019). Em Hosseini et al. (HOSSEINI et al., 2018), o comportamento dos sinais de corrente das bobinas do disjuntor durante as manobras é analisado. Já em Razi-Kazemi e Niayesh (RAZI-KAZEMI; NIAYESH, 2021) e Ji et al. (JI et al., 2019), diversos sinais de disjuntores são analisados utilizando técnicas de processamento de sinais.

Os estudos geralmente utilizam simulações computacionais para determinar os pontos de pré-inserção e de contato principal e, conseqüentemente, avaliar o sincronismo da fase de fechamento. No entanto, quando os dados são obtidos em ambientes reais, eles apresentam uma grande quantidade de ruído e interferências, o que dificulta a determinação dos pontos. Este trabalho propõe o uso de inteligência artificial para mitigar esse problema, permitindo que a solução seja aplicada em qualquer ambiente real onde o disjuntor esteja instalado.

2.2 Embasamento Teórico

Nesta seção, são apresentados os fundamentos teóricos que sustentam o desenvolvimento deste trabalho. São abordados conceitos essenciais relacionados ao processamento de sinais, como filtros temporais, transformadas no domínio da frequência e técnicas de filtragem avançadas, fundamentais para a análise dos sinais de corrente dos disjuntores. Além disso, são discutidos princípios do aprendizado de máquina, com foco nos algoritmos utilizados para a identificação automática dos pontos de fechamento do conector principal e de pré-inserção. Esse embasamento teórico fornece a base necessária para o entendimento e a implementação das metodologias propostas, garantindo a robustez e a aplicabilidade da solução desenvolvida.

2.2.1 Disjuntor Alta Tensão SF₆

Os disjuntores desempenham um papel fundamental em sistemas elétricos de potência, sendo responsáveis por conectar e desconectar circuitos de maneira segura e eficiente. Sua principal função é a proteção da rede elétrica, garantindo a interrupção da corrente em caso de falhas, como curtos-circuitos e sobrecargas, evitando danos aos equipamentos e riscos à segurança operacional (ITO, 2019).

Em subestações, os disjuntores são empregados na proteção e controle de bancos de capacitores, transformadores e linhas de transmissão. A operação adequada desses dispositivos é essencial para garantir a estabilidade da rede e evitar transitórios elétricos indesejados. Em particular, no caso da energização de bancos de capacitores, transientes de corrente e sobretensões podem ser gerados, exigindo técnicas avançadas de mitigação, como o uso de resistores de pré-inserção e comutação controlada (ZONDI; BOKORO; PAUL, 2015).

Os disjuntores a gás SF₆ (hexafluoreto de enxofre) são amplamente utilizados em sistemas de alta tensão devido às suas propriedades dielétricas superiores e à capacidade de extinção de arco

elétrico. Esse tipo de disjuntor substituiu tecnologias anteriores, como os disjuntores a óleo e a ar-comprimido, oferecendo maior eficiência e menor necessidade de manutenção(ITO, 2019).

A operação desses disjuntores baseia-se na interrupção da corrente elétrica dentro de uma câmara preenchida com gás SF₆. Quando ocorre a abertura dos contatos, forma-se um arco elétrico que ioniza o gás. No entanto, a recombinação rápida das moléculas de SF₆ após a extinção do arco permite um restabelecimento eficaz da rigidez dielétrica, garantindo a interrupção segura da corrente(ITO, 2019).

2.2.1.1 Contato Resistivo e Contato Principal

Para minimizar os impactos dos transitórios elétricos durante a energização de circuitos de alta tensão, os disjuntores modernos empregam um sistema de contato duplo, composto por um contato resistivo e um contato principal. Essa configuração visa reduzir as sobretensões e os picos de corrente no momento da comutação(ZONDI; BOKORO; PAUL, 2015). Na Figura 5 é possível observar os componentes de um disjuntor SF₆ e seus contatos.

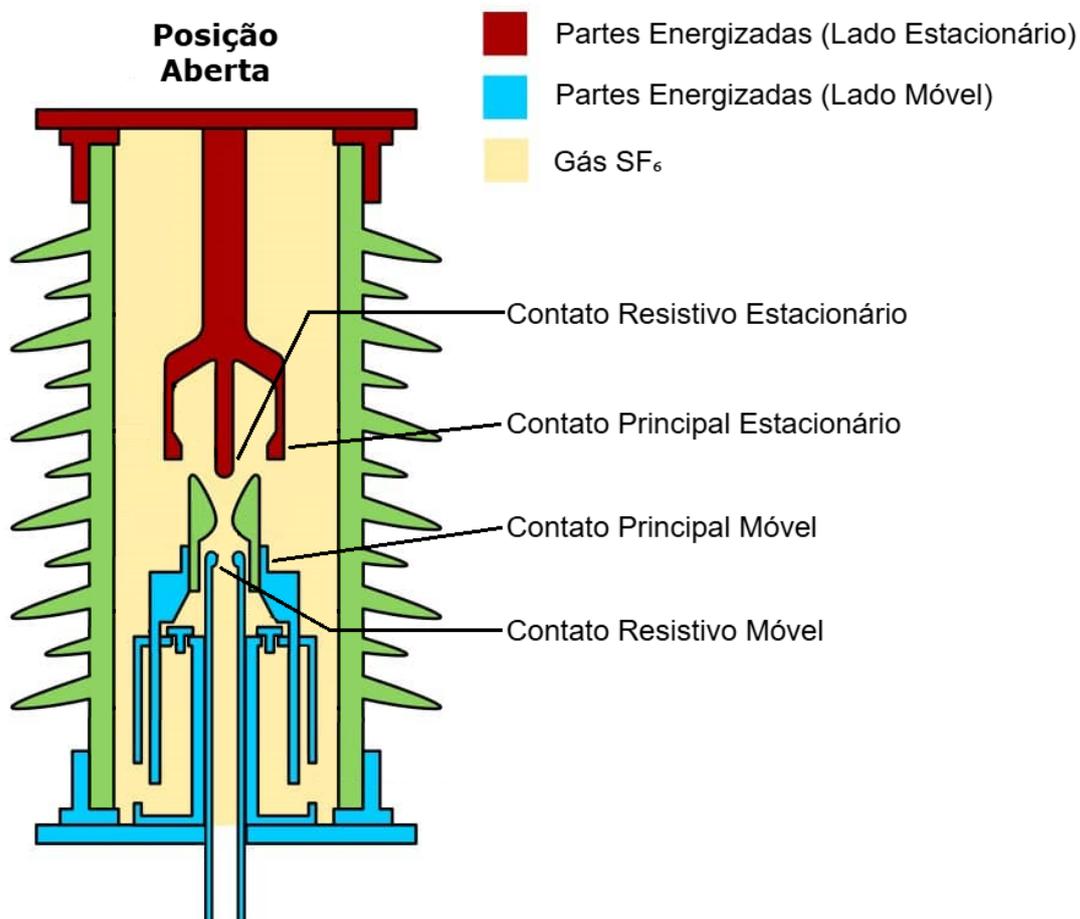


Figura 5 – Disjuntor SF₆. Criado pelo autor.

- Contato Resistivo (Pré-Inserção): Atua no instante inicial da operação, inserindo uma resistência no circuito por um curto período de tempo (tipicamente 10 a 15 milissegundos) antes da ativação do contato principal. Isso limita a corrente de inrush e suaviza a transição(ZONDI; BOKORO; PAUL, 2015).

- **Contato Principal:** Após a fase resistiva, o contato principal se fecha, garantindo a condução total da corrente elétrica sem perdas adicionais(ZONDI; BOKORO; PAUL, 2015).

A operação de abertura e fechamento é ilustrado na Figura 6 e explicado de forma detalhada a seguir.

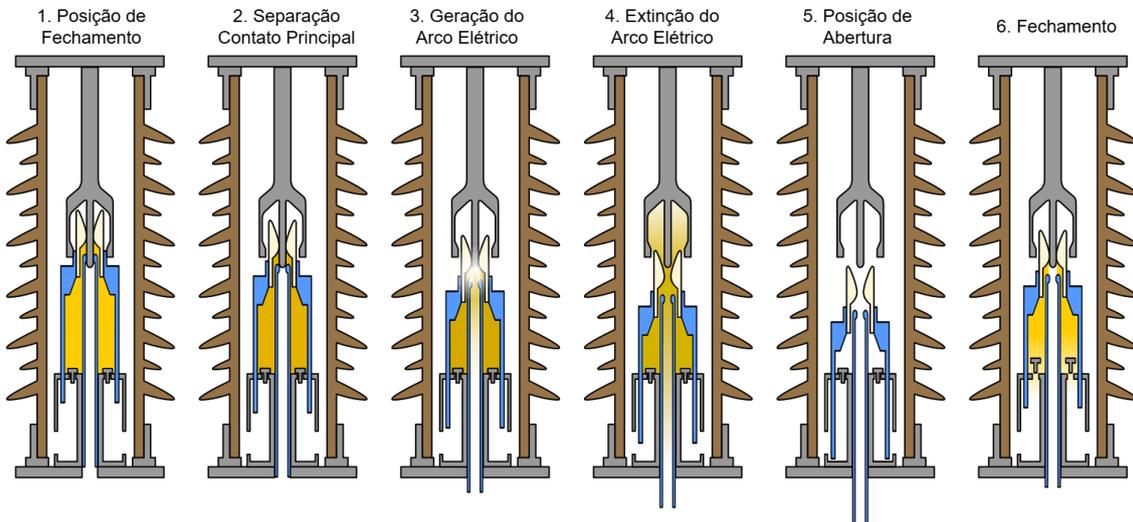


Figura 6 – Operação de Abertura e Fechamento de um disjuntor SF₆.

A abertura do disjuntor é um processo mais crítico do que o fechamento, pois envolve a interrupção de corrente, o que pode resultar na formação de um arco elétrico entre os contatos. O processo ocorre em quatro etapas principais:

- **Início da Abertura:** O comando de abertura é enviado ao mecanismo de acionamento, iniciando a separação dos contatos móveis e fixos (Passo 2 da Figura 6). À medida que os contatos começam a se afastar, a corrente continua fluindo, formando um arco elétrico entre eles devido à ionização do meio dielétrico(Passo 3 da Figura 6) (ITO, 2019).
- **Extensão e Resfriamento do Arco:** Durante a separação dos contatos, o arco elétrico se prolonga, atingindo seu pico de energia (Passo 4 da Figura 6). Nos disjuntores SF₆, o gás atua como meio dielétrico e meio de extinção do arco, pois apresenta alta capacidade de recombinação molecular e rápida recuperação da rigidez dielétrica(ITO, 2019). O gás SF₆ é forçado através da câmara de interrupção, ajudando a resfriar e extinguir o arco(ITO, 2019).
- **Interrupção da Corrente no Zero da Onda:** A corrente do circuito atravessa naturalmente zero da onda senoidal, reduzindo a intensidade do arco. Nesse instante, o gás SF₆ se recombina, restaurando a isolamento entre os contatos(ZONDI; BOKORO; PAUL, 2015). Se a abertura for sincronizada com a forma de onda da corrente, os efeitos transitórios podem ser minimizados(ZONDI; BOKORO; PAUL, 2015)
- **Restabelecimento da Rigidez Dielétrica:** Após a extinção do arco, a câmara do disjuntor deve impedir a reignição da corrente (Passo 5 da Figura 6). O gás SF₆ ajuda a restaurar rapidamente a rigidez dielétrica do meio, permitindo que a isolamento entre os contatos seja mantida(ITO, 2019).

O fechamento do disjuntor ocorre quando seus contatos móveis se deslocam para restabelecer a conexão entre os terminais do circuito. Esse processo pode ser dividido em três estágios principais:

- Início da movimentação: O mecanismo de acionamento (molas, motores ou sistemas pneumáticos) é ativado e inicia a movimentação dos contatos móveis em direção aos contatos fixos. Os resistores de pré-inserção são ativados momentaneamente antes do contato principal ser fechado(ITO, 2019).
- Contato Resistivo: os contatos resistivos fecham primeiro. Essa etapa reduz os picos de corrente ao limitar a diferença de potencial entre os contatos antes da conexão completa (Passo 6 da Figura 6)(ZONDI; BOKORO; PAUL, 2015).
- Fechamento do Contato Principal: Após um curto intervalo de tempo (normalmente 10 ms), os contatos principais se fecham, garantindo a condução total da corrente elétrica(Passo 1 da Figura 6). Se o fechamento for realizado de maneira sincronizada com a forma de onda da tensão, os impactos dos transitórios podem ser significativamente reduzidos(ZONDI; BOKORO; PAUL, 2015).

Essa estratégia é especialmente útil na energização de bancos de capacitores, pois reduz a incidência de transitórios que podem afetar a integridade dos equipamentos(ZONDI; BOKORO; PAUL, 2015).

2.2.1.2 Avaliação da Saúde dos Contatos e Sincronismo Operacional

A avaliação da condição dos contatos de um disjuntor é essencial para determinar sua confiabilidade operacional e prever falhas antes que ocorram. Um dos principais indicadores de desgaste é o sincronismo entre os contatos das diferentes fases, que deve ser mantido dentro de margens específicas para evitar transitórios elétricos indesejados. Em sistemas trifásicos, cada fase (A, B e C) deve fechar em sincronismo com uma diferença de fase de 60 graus (2,78 ms), o que é crucial para evitar transitórios indesejados de corrente e manter o equilíbrio do sistema. Essa sincronização precisa é fundamental para garantir que o disjuntor opere no momento correto da onda de tensão, minimizando correntes de inrush e evitando sobretensões prejudiciais.

No entanto, ao longo do tempo, os mecanismos dos disjuntores sofrem *drift* mecânico, fazendo com que os tempos de fechamento se desalinhem. Testes realizados com disjuntores SF₆ indicam que, após um período de operação, a variação no tempo de fechamento entre as fases pode ultrapassar 2,78 ms, comprometendo o sincronismo adequado. Esse desvio pode resultar em sobretensões e aumentar o desgaste dos contatos, reduzindo sua vida útil e elevando os riscos de falha(ZONDI; BOKORO; PAUL, 2015).

2.2.2 Filtros Temporais

2.2.2.1 Derivada e Integral Discreta

Chapra e Canale (2016) afirma que o cálculo é a matemática da variação e que conceitos matemáticos relacionados de derivação e integração estão no seu centro. Segundo MICHAELIS (2015) diferenciar significa: "*fazer ou estabelecer diferença entre; tornar(-se) distinto, diferente; apresentar(-se) ou distinguir(-se) por alguma diferença.*" O veículo fundamental da derivação é a derivada, que representa a taxa de variação de uma variável dependente com relação a uma variável independente. Esta é usada nos processamento de sinais para suavizar, alterando o ruído, detectar picos, surtos ou transitórios, realçar mudanças bruscas, analisar traços, extrair recursos, entre outros (SALINAS et al., 2018). A derivada contínua de uma função $f(x)$ é definida na Equação 2.1.

$$f'(x) = \lim_{\Delta x \rightarrow 0} \frac{f(x + \Delta x) - f(x)}{\Delta x} \quad (2.1)$$

Onde:

- $f(x + \Delta x)$: O valor da função f em um ponto ligeiramente à direita de x , deslocado por Δx .
- $f(x)$: O valor da função f no ponto atual x .
- Δx : O pequeno incremento aplicado a x .

Em processamento digital de sinais, não há função contínua, uma vez que os sinais analisados são discretos. Portanto, existe uma sequência de pontos espaçados por um intervalo Δt . Para um sinal $s[n]$ amostrado em pontos n , a derivada discreta pode ser aproximada como mostrada na Equação 2.2.

$$s'[n] = \frac{s[n + 1] - s[n]}{\Delta t} \quad (2.2)$$

Onde:

- $s[n + 1]$: O valor do sinal $s[n]$ no ponto $n + 1$, ou seja, no próximo instante de tempo.
- $s[n]$: O valor do sinal $s[n]$ no ponto atual n .
- Δt : O intervalo de tempo fixo entre dois pontos consecutivos no domínio discreto.

Se o intervalo entre as amostras é uniforme e assumimos $\Delta t = 1$, temos a Equação 2.3

$$s'[n] = s[n + 1] - s[n] \quad (2.3)$$

Na Figura 7 é possível verificar um sinal de corrente da fase de um disjuntor limitado por uma janela de tempo (explicado e detalhado na seção 3.1.2) e o resultado da técnica.

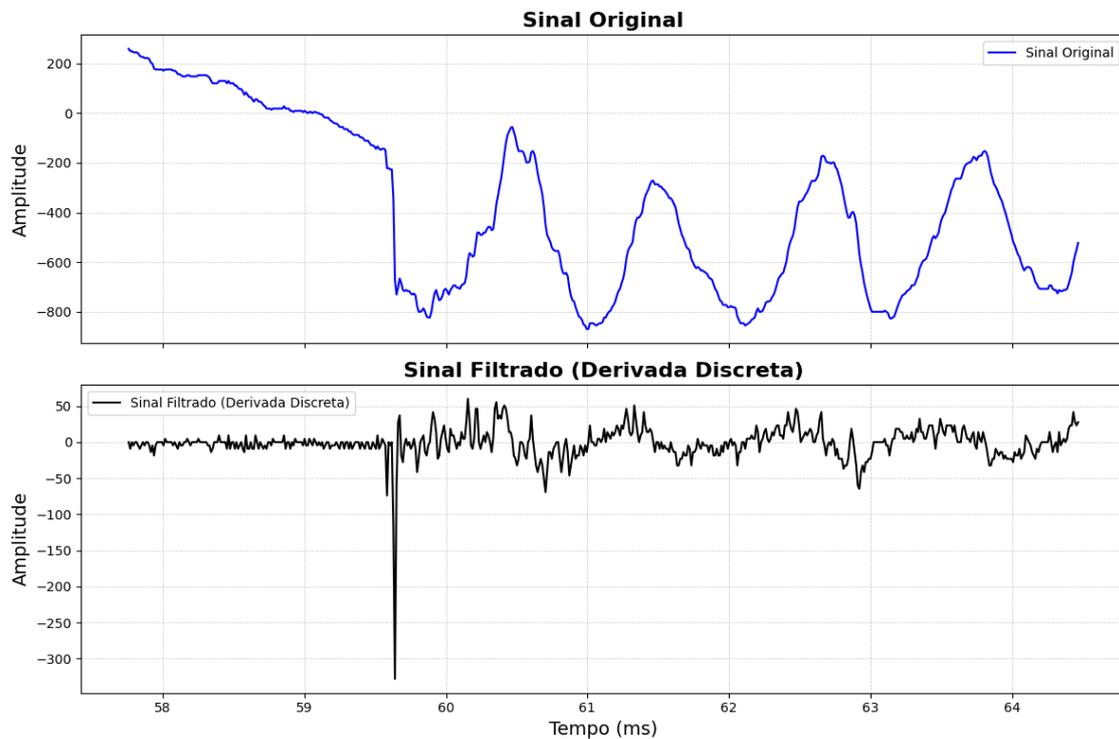


Figura 7 – Sinal e sua derivada. Criado pelo Autor

O processo inverso da derivação no cálculo é a integração. Segundo MICHAELIS (2015) integrar significa: *"Incorporar(-se) um elemento num conjunto; incluir(-se), integralizar(-se)"*. Matematicamente representada na Equação 2.4:

$$\int_a^b f(x) dx \quad (2.4)$$

Onde:

- a : O limite inferior de integração, indicando o início do intervalo.
- b : O limite superior de integração, indicando o final do intervalo.
- $f(x)$: A função que está sendo integrada, cuja área sob a curva será calculada.
- dx : O diferencial de x , que indica que a integração é realizada com respeito à variável x .

Como apontado por Salinas et al. (2018), o símbolo da integral é derivado da letra S, representando a relação entre integração e soma. No processamento de sinais a integral discreta se dá pelo inverso da derivada, ou seja, a soma das suas diferenças como representado na Equação 2.5.

$$S[n] = \sum_{i=0}^n s[i] \quad (2.5)$$

Onde:

- $s[i]$: O valor do sinal discreto no ponto i .
- i : O índice discreto que percorre os valores do sinal $s[i]$ desde o início ($i = 0$) até o ponto atual $i = n$.
- n : O índice atual onde o valor cumulativo $S[n]$ é calculado.

Na Figura 8 é possível verificar um sinal de corrente da fase de um disjuntor limitado por uma janela de tempo (explicado e detalhado na seção 3.1.2) e o resultado da técnica.

2.2.2.2 Média Móvel

Usada para suavizar as variações em uma série cronológica, ajudando a eliminar tendências e removendo flutuações de longo prazo, a média móvel é calculada utilizando um intervalo de tamanho k , onde, em uma sequência de n números, são considerados os k números mais recentes, incluindo o número atual, e a média desses valores é calculada (RODRIGUES, 1970). Esse cálculo é formalizado matematicamente na Equação 2.6.

$$M_i(k) = \frac{1}{k} \sum_{j=0}^{k-1} x_{i-j} \quad (2.6)$$

$M_i(k)$ representa o valor suavizado da série no ponto i , calculado usando uma média móvel de ordem k . k é o número de valores usados no cálculo da média móvel, e x_{i-j} denota o valor da série no ponto $i - j$, onde j varia de 0 até $k - 1$. Aplicando em sinais digitais o método calcula a média aritmética de uma janela de k elementos consecutivos e vai movendo esta janela ao longo do tempo, suavizando o sinal, reduzindo ruídos filtrando flutuações e destacando tendências e padrões (SHAN et al., 2022).

Na Figura 9 é possível verificar um sinal de corrente da fase de um disjuntor limitado por uma janela de tempo (explicado e detalhado na seção 3.1.2) e o resultado da técnica.

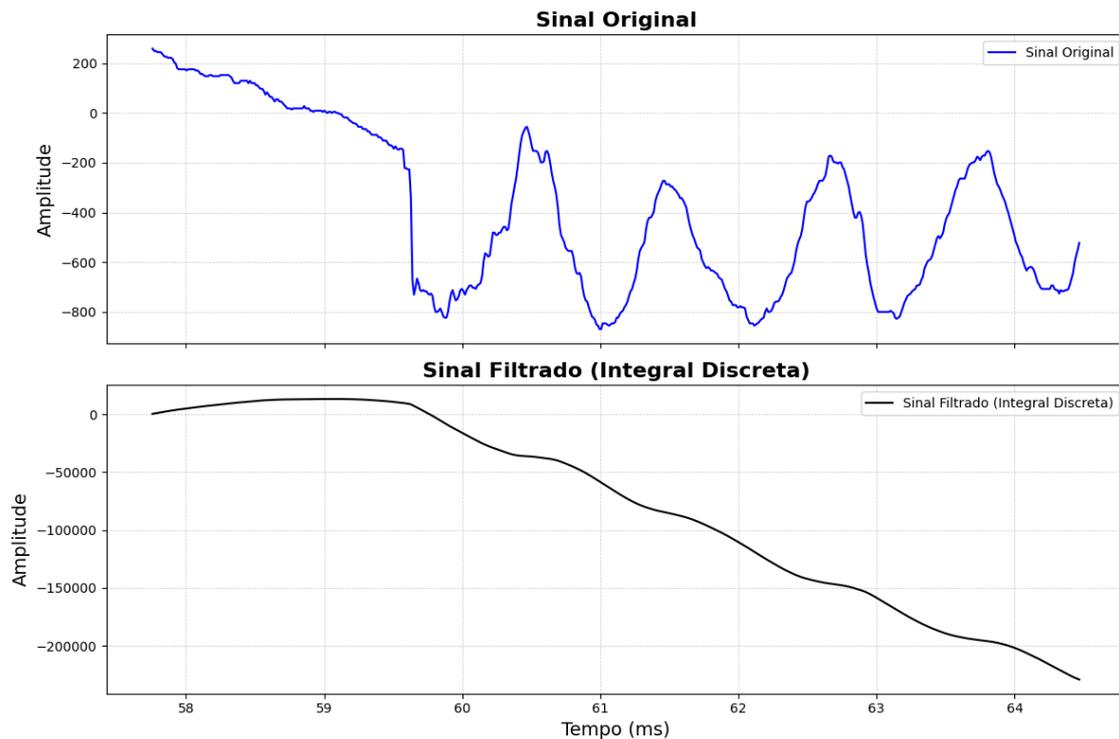


Figura 8 – Sinal e sua integral. Criado pelo Autor

2.2.2.3 Mediana

O valor central de um conjunto de tamanho ímpar ou a média aritmética dos dois valores centrais de um conjunto de tamanho par é chamada de mediana (RODRIGUES, 1970). Usado para remoção de ruídos em processamento digital, os valores por ventura ruidosos são substituídos pelo valor mediano de seus vizinhos, sendo este número determinado pelo tamanho da janela usado no filtro. Este preserva as bordas e não suaviza transições abruptas no sinal (GEORGE et al., 2018).

Na Figura 10 é possível verificar um sinal de corrente da fase de um disjuntor limitado por uma janela de tempo (explicado e detalhado na seção 3.1.2) e o resultado da técnica.

2.2.2.4 Filtro Savitzky-Golay

Criada por Savitzky e Golay (1964), o filtro digital suaviza dados através de um ajuste polinomial de mínimos quadrados em pequenas janelas de pontos de amostra do sinal (SCHAFER, 2011). Mais detalhadamente o filtro é composto de três partes principais:

1. Ajuste do Polinômio: ajusta um polinômio de ordem N a uma janela de $2M + 1$ amostras ao redor de cada ponto do sinal. O polinômio é definido na Equação 2.7:

$$p(n) = \sum_{k=0}^N a_k n^k \quad (2.7)$$

onde a_k são os coeficientes calculados para minimizar o erro entre o polinômio e as amostras do sinal.

2. Erro Quadrático Médio (Equação Normal): A minimização do erro quadrático médio gera um sistema de equações lineares para determinar os a_k , representado pela Equação 2.8:

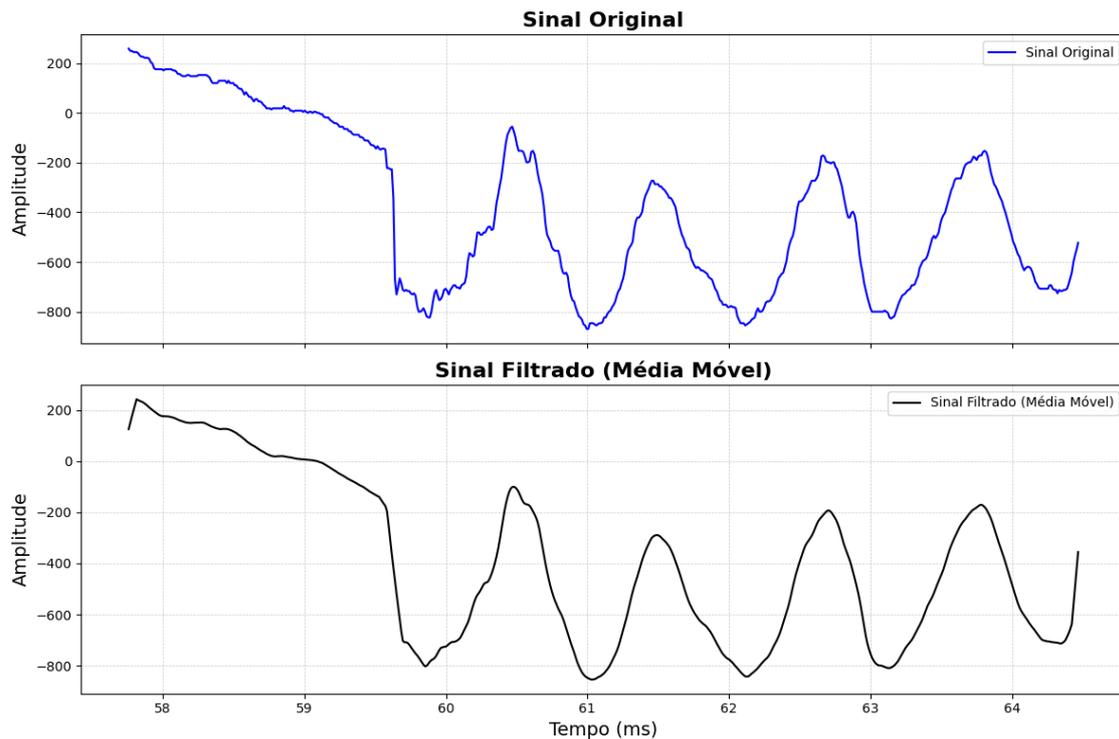


Figura 9 – Sinal filtrado pela média móvel. Criado pelo Autor

$$A^T A \mathbf{a} = A^T \mathbf{x} \quad (2.8)$$

onde A é a matriz estrutural construída a partir das potências das posições das amostras na janela, e \mathbf{x} representa as amostras do sinal.

3. Saída Filtrada (Convolução Discreta): A resposta suavizada em cada ponto do sinal, $y(n)$, pode ser obtida pela convolução discreta das amostras $x(n)$ com os coeficientes da resposta ao impulso, representado na Equação 2.9:

$$y(n) = \sum_{m=-M}^M h(m)x(n-m) \quad (2.9)$$

onde:

- $y(n)$: é o valor filtrado do sinal no ponto n .
- $x(n)$: é o valor do sinal original no ponto n .
- $h(m)$: são os coeficientes da resposta ao impulso do filtro, determinados pelo ajuste polinomial de mínimos quadrados.
- M : é o número de pontos de amostras em cada lado da janela de suavização (tamanho total da janela = $2M + 1$).
- n : é o índice do ponto atual no domínio discreto.
- m : é o índice que percorre os coeficientes e as amostras da janela.

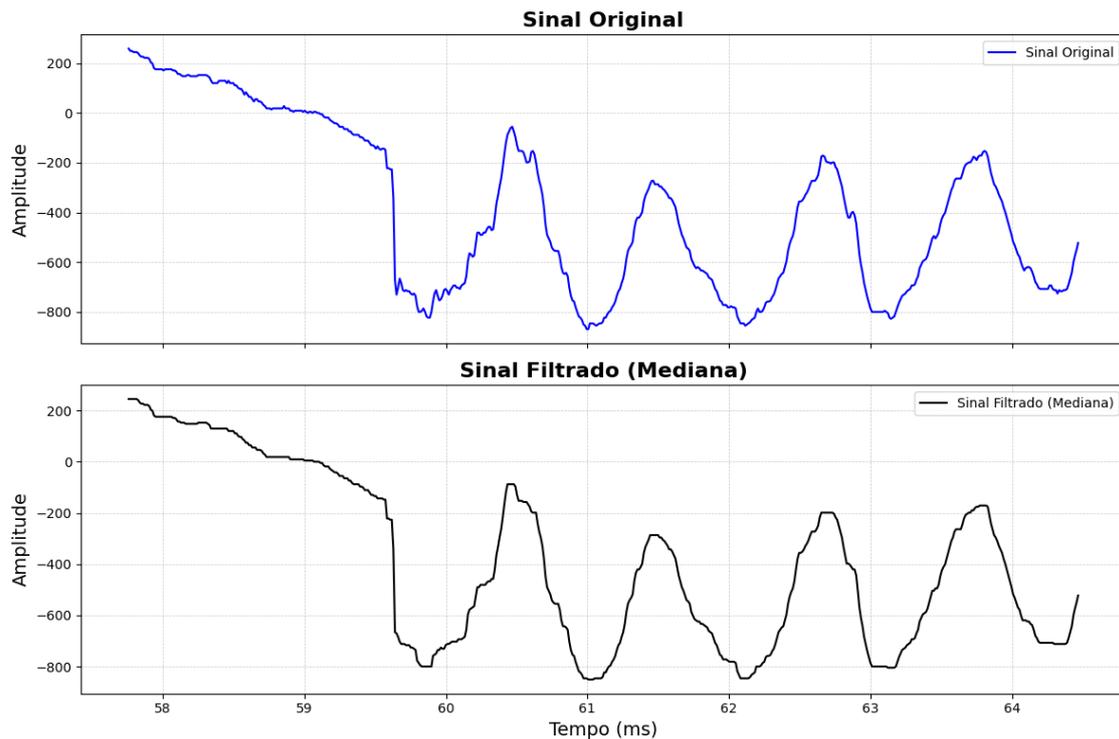


Figura 10 – Sinal filtrado pela mediana. Criado pelo Autor

Este filtro é usado principalmente para suavizar sinais ruidosos onde a preservação da forma do sinal, especialmente dos picos, é importante. Essa técnica é ideal quando se busca uma suavização que preserve os detalhes da estrutura do sinal, como amplitude e posição de picos, e é particularmente útil em contextos onde o sinal possui uma taxa de amostragem suficientemente alta em relação ao conteúdo de frequência do sinal (SCHAFER, 2011).

Na Figura 11 é possível verificar um sinal de corrente da fase de um disjuntor limitado por uma janela de tempo (explicado e detalhado na seção 3.1.2) e o resultado da técnica.

2.2.3 Transformadas no Domínio da Frequência

2.2.3.1 Transformada de Fourier

Fourier (1822) afirma em seu trabalho que qualquer função periódica pode ser expressa como a soma de senos e/ou cossenos de frequências diferentes, cada um multiplicado por um coeficiente diferente. Não importa quão complicada seja a função, se ela for periódica e satisfizer algumas condições matemáticas, ela pode ser representada por tal soma. Posteriormente esta soma foi nomeada como série de Fourier (GONZALEZ; WOODS, 2018). Para funções não periódicas e cuja área sob a curva é finita, Fourier propôs a formulação de uma integral de senos e cossenos multiplicados por uma função de ponderação, criando, assim, a Transformada de Fourier, que está representada matematicamente na Equação 2.10

$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt \quad (2.10)$$

e a sua operação inversa na Equação 2.11

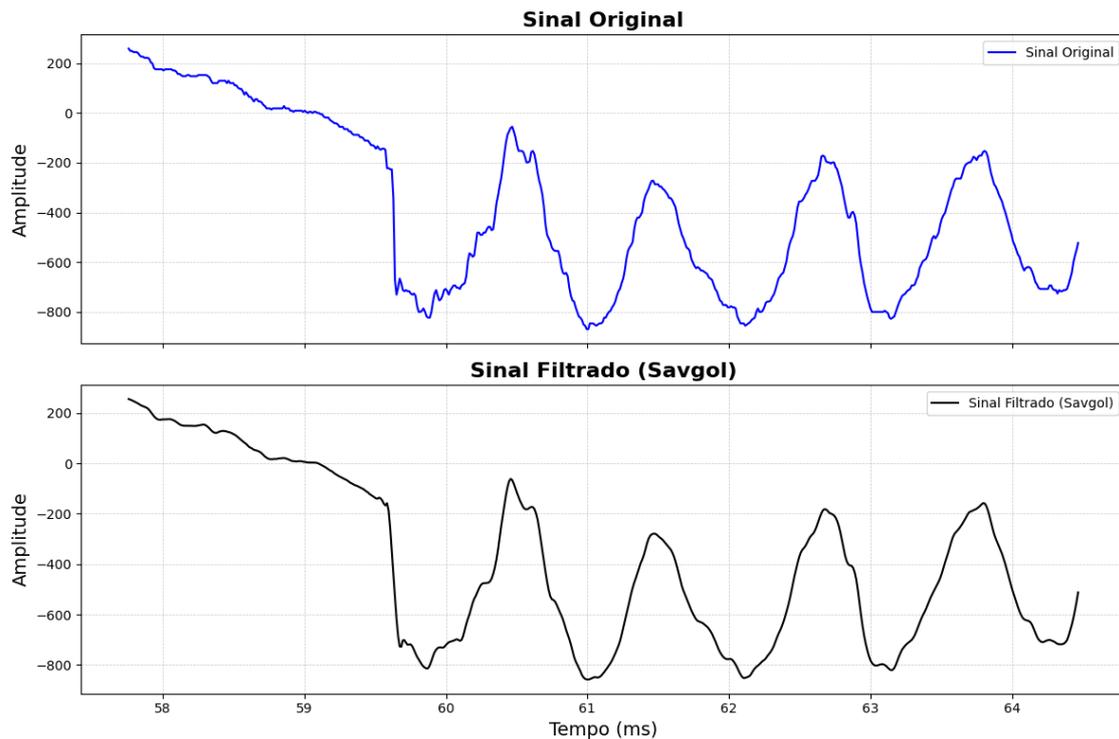


Figura 11 – Sinal filtrado por Savitzky-Golay. Criado pelo Autor

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega) e^{j\omega t} d\omega \quad (2.11)$$

Sua utilidade deve-se à possibilidade de reconstrução completa da função original através de um processo inverso sem perda de informações. Ou seja, é possível trabalhar no domínio da frequência e retornar ao domínio original mantendo a integridade dos dados. Dessa maneira é possível processar um sinal para o domínio da frequência e realizar cortes de faixas de frequência e retornar o sinal ao domínio original, filtrando, assim, frequências indesejadas (GONZALEZ; WOODS, 2018).

Com o advento dos computadores digitais na década de 60 o algoritmo *Fast Fourier Transform* revolucionou o uso em processamentos digitais, pois permite realizar a transformada de forma muito mais eficiente, reduzindo drasticamente o número de operações necessárias. Quando filtramos um sinal ou imagem de tamanho $M \times M$ é usando um kernel de tamanho $m \times m$, o número de operações necessário para uma filtragem direta (no domínio espacial) é da ordem de $MN \cdot m \cdot n$.

Já para a FFT, o número de operações necessárias para o mesmo processamento é da ordem de $2 \cdot MN \log MN$ (GONZALEZ; WOODS, 2018).

Na Figura 12 é possível verificar um sinal de corrente da fase de um disjuntor limitado por uma janela de tempo (explicado e detalhado na seção 3.1.2) e o resultado da técnica.

2.2.3.2 Transformada Cosseno Discreta

A Transformada Cosseno Discreta (do inglês *Discrete Cosine Transform*) transforma um sinal ou imagem do domínio do espaço para o domínio da frequência utilizando apenas funções base de cosseno. Uma de suas principais características é a capacidade de compactar a energia do sinal em poucos coeficientes de baixa frequência, o que faz dela uma técnica eficiente para a redução de

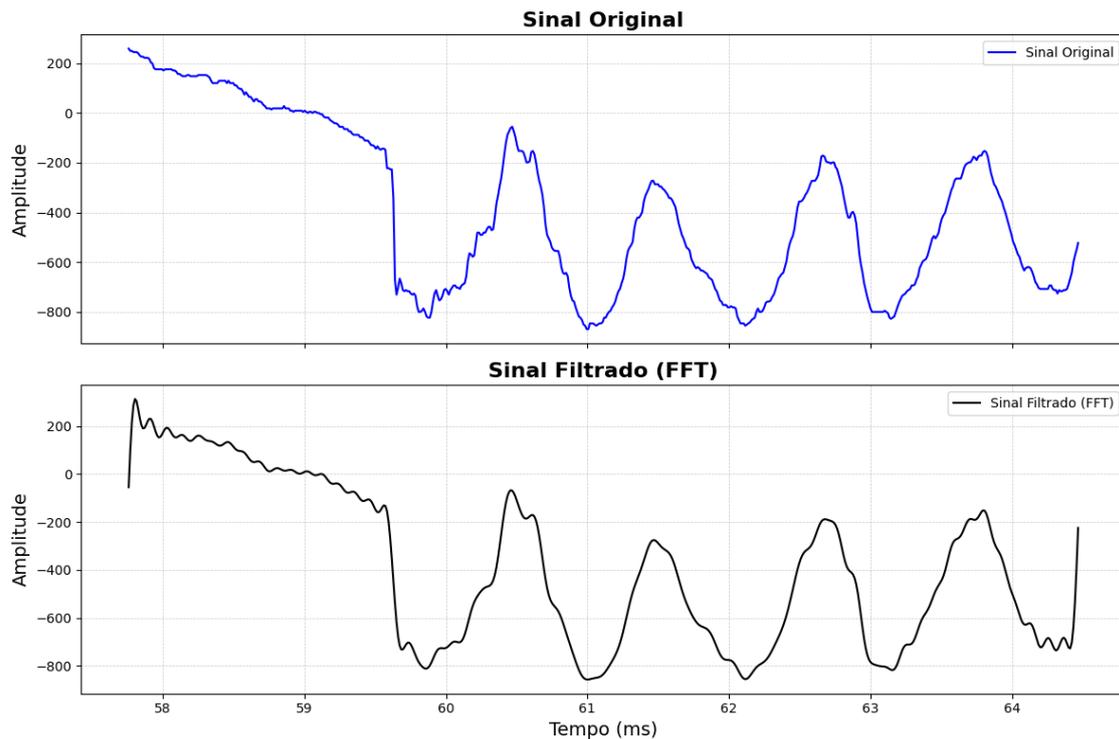


Figura 12 – Sinal filtrado por FFT cortando frequência acima de 100 Hz. Criado pelo Autor

dados com mínima perda de informação relevante. Essa propriedade é amplamente explorada em aplicações como compressão de imagem e áudio (ZHOU; CHEN, 2009).

Existem diferentes tipos de DCT, sendo os mais comuns a DCT-I, DCT-II, DCT-III e DCT-IV, sendo a DCT-II a mais utilizada, como seu uso em esquemas de compressão de imagem como o formato JPEG, sua característica faz com que grande parte da energia do sinal seja concentrada nos primeiros coeficientes, tornando os demais coeficientes menores e potencialmente descartáveis em processos de compressão. A fórmula da DCT-II está representada na Equação 2.12:

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot \cos \left[\frac{\pi}{N} \left(n + \frac{1}{2} \right) k \right], \quad k = 0, 1, \dots, N - 1 \quad (2.12)$$

E sua inversa é a DCT-III representada na Equação 2.13:

$$x(n) = \frac{1}{2} X(0) + \sum_{k=1}^{N-1} X(k) \cdot \cos \left[\frac{\pi}{N} k \left(n + \frac{1}{2} \right) \right], \quad n = 0, 1, \dots, N - 1 \quad (2.13)$$

Diferente da Transformada de Fourier, a DCT opera apenas com valores reais, o que a torna mais simples em termos de processamento computacional (ZHOU; CHEN, 2009).

Outro uso importante da DCT está em algoritmos de redução de ruído, onde ela separa componentes de baixa e alta frequência, possibilitando a remoção de ruídos indesejados sem prejudicar as principais características do sinal (SHIVAMURTI; NARASIMHAN, 2010).

Na Figura 13 é possível verificar um sinal de corrente da fase de um disjuntor limitado por uma janela de tempo (explicado e detalhado na seção 3.1.2) e o resultado da técnica.

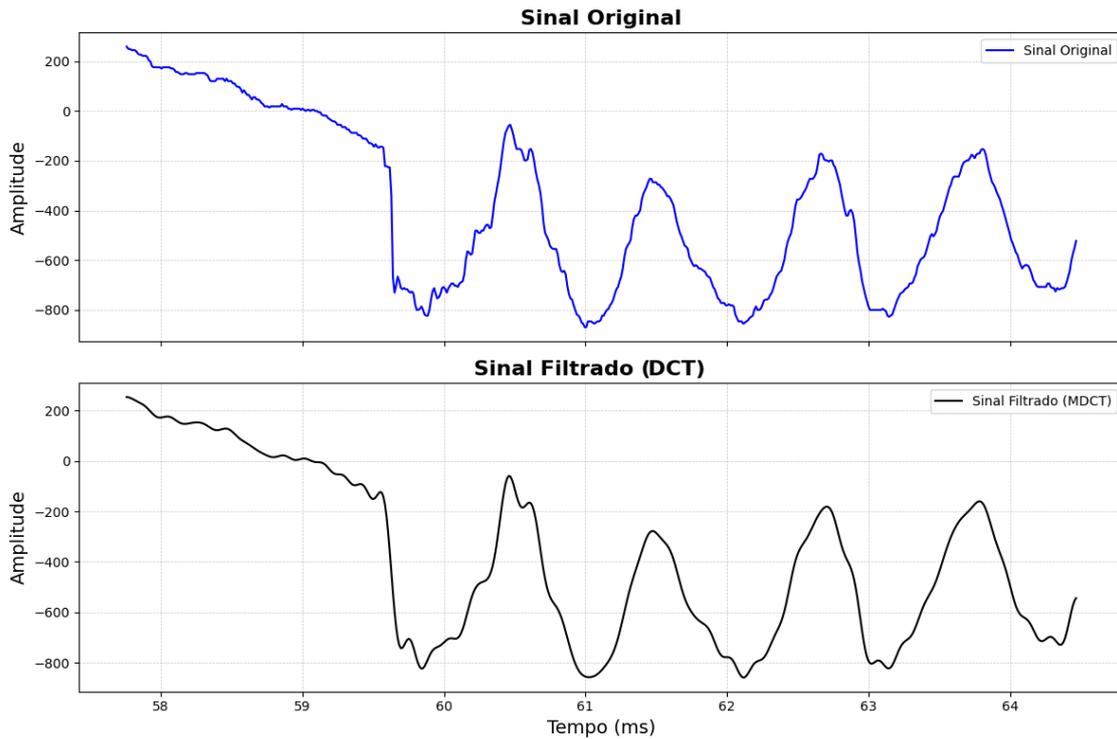


Figura 13 – Sinal filtrado por DCT. Criado pelo Autor

2.2.3.3 Transformada de Hilbert

A Transformada de Hilbert (HT) é definida como uma transformação integral que pode ser representada pela Equação 2.14:

$$\tilde{x}(t) = \frac{1}{\pi} \text{P.V.} \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (2.14)$$

onde P.V. indica o valor principal de Cauchy. Esta operação transforma um sinal real $x(t)$ em uma versão complexa, combinando o sinal original com sua transformada de Hilbert para criar um sinal analítico (FELDMAN, 2011). Como pode ser visto na Figura 14.

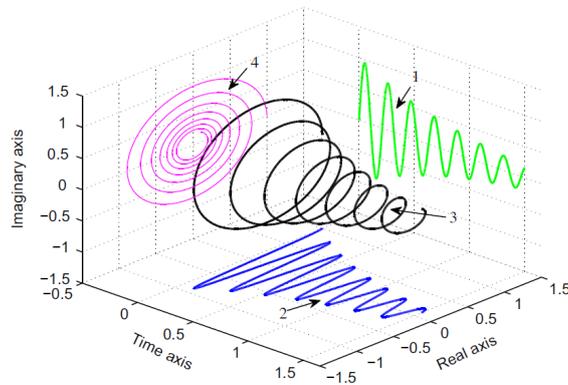


Figura 14 – Projeção Hilbert (1), sinal real (2), sinal analítico (3), plano complexo (4), criado por (FELDMAN, 2011)

A transformada desloca a fase dos componentes espectrais do sinal em $\pm\pi/2$ sem modificar

suas amplitudes, resultando em uma representação que facilita a extração da amplitude e da fase instantâneas (FELDMAN, 2011).

A representação analítica gerada pela Equação 2.15:

$$z(t) = x(t) + i\tilde{x}(t) \quad (2.15)$$

permite a obtenção da amplitude instantânea, dada pela Equação 2.16:

$$A(t) = \sqrt{x^2(t) + \tilde{x}^2(t)} \quad (2.16)$$

e da fase instantânea dada pela Equação 2.17:

$$\phi(t) = \tan^{-1} \left(\frac{\tilde{x}(t)}{x(t)} \right) \quad (2.17)$$

A derivada da fase fornece a frequência instantânea, representada na Equação 2.18:

$$\omega(t) = \frac{d\phi(t)}{dt} \quad (2.18)$$

Seu uso em processamento de sinais digitais são diversos, frequentemente implementada por meio da Transformada de Fourier, onde o espectro de frequência é manipulado para aplicar o deslocamento de fase e, em seguida, é realizada a transformada inversa. Outro uso é extração da envoltória do sinal que representa a amplitude instantânea ao longo do tempo, o que resulta no sinal mais suavizado, sem as oscilações rápidas da frequência (FELDMAN, 2011).

Na Figura 15 é possível verificar um sinal de corrente da fase de um disjuntor limitado por uma janela de tempo (explicado e detalhado na seção 3.1.2) e o resultado da técnica.

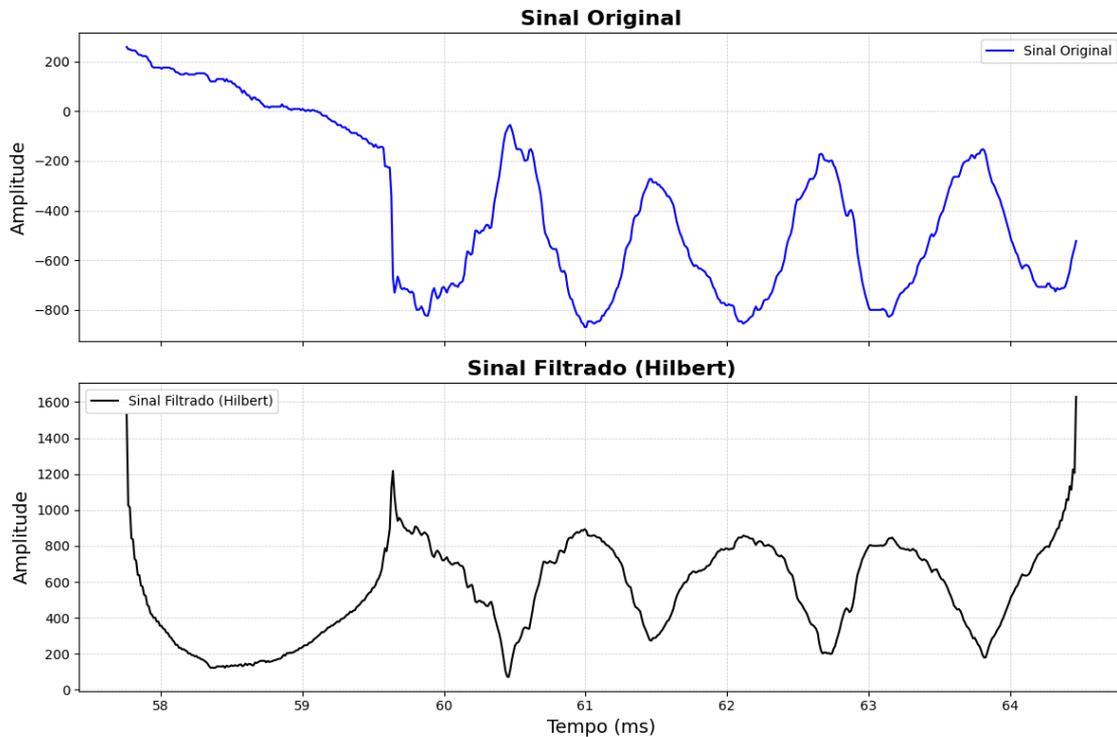


Figura 15 – Sinal filtrado por Hilbert. Criado pelo Autor

2.2.4 Filtro Butterworth

Definida por Stephen Butterworth em 1930 (SHOURAN; ELGAMLI, 2020), o filtro Butterworth foi projetado para proporcionar uma resposta uniforme na faixa passante, garantindo que as frequências abaixo da frequência de corte sejam transmitidas com mínima distorção. Desta forma ele tem uma resposta de magnitude o mais plana possível na banda passante, o que significa que ele não apresenta ondulações e o torna conhecido como um filtro de magnitude maximamente plano (SHOURAN; ELGAMLI, 2020). Por esta razão ele é muito utilizado em aplicações de processamento de sinais onde uma transição suave é desejada.

A fórmula que define a resposta de magnitude de um filtro está representada na Equação 2.19:

$$|H(f)| = \frac{1}{\sqrt{1 + \left(\frac{f}{f_c}\right)^{2n}}} \quad (2.19)$$

Nesta fórmula, $|H(f)|$ representa a magnitude da resposta do filtro, f é a frequência do sinal, f_c é a frequência de corte, e n é a ordem do filtro. A ordem do filtro (n) influencia diretamente a atenuação: quanto maior a ordem, mais íngreme é a transição entre a banda passante e a banda de rejeição. Isso significa que, em um filtro de Butterworth de ordem mais alta, as frequências acima de f_c são atenuadas de forma mais acentuada, o que aumenta a precisão do filtro na remoção de componentes indesejados (GONZALEZ; WOODS, 2018).

Desta forma é possível utilizá-lo como filtro de passa-baixa permitindo a passagem de frequências abaixo de f_c sem atenuação significativa, enquanto atenua progressivamente as frequências acima desse ponto. Essa propriedade o torna ideal para situações em que a integridade da banda passante é importante, e uma atenuação suave das altas frequências é desejada, sem ondulações indesejadas.

Na Figura 16 é possível verificar um sinal de corrente da fase de um disjuntor limitado por uma janela de tempo (explicado e detalhado na seção 3.1.2) e o resultado da técnica.

2.2.5 Transformada Wavelet

Wavelets são funções de energia finita e integral nula, vide Equação 2.20:

$$\int_{-\infty}^{\infty} \psi(t) dt = 0. \quad (2.20)$$

Caracterizam-se por serem localizadas tanto no tempo quanto na frequência, o que as torna ferramentas eficientes para a análise de sinais com componentes não estacionários e oferecendo uma análise mais detalhada e localizada em comparação com a Transformada de Fourier (CAUMO, 2006; LAI, 2012; RAHMAN; HAQUE, 2012). São utilizadas para decompor sinais em componentes com diferentes níveis de detalhe, facilitando a análise de sinais complexos. As wavelets podem ser simétricas ou assimétricas, suaves ou não, dependendo da aplicação desejada (CAUMO, 2006).

Matematicamente ela permite representar uma função complexa $f(t)$ por meio de uma soma ponderada de versões escaladas e transladadas de uma wavelet mãe $\psi(t)$. A forma contínua da transformada é dada pela Equação 2.21 (CAUMO, 2006):

$$W(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \psi^* \left(\frac{t-b}{a} \right) dt, \quad (2.21)$$

onde:

- a é o parâmetro de escala (dilatação/compressão),
- b é o parâmetro de translação (deslocamento no tempo),

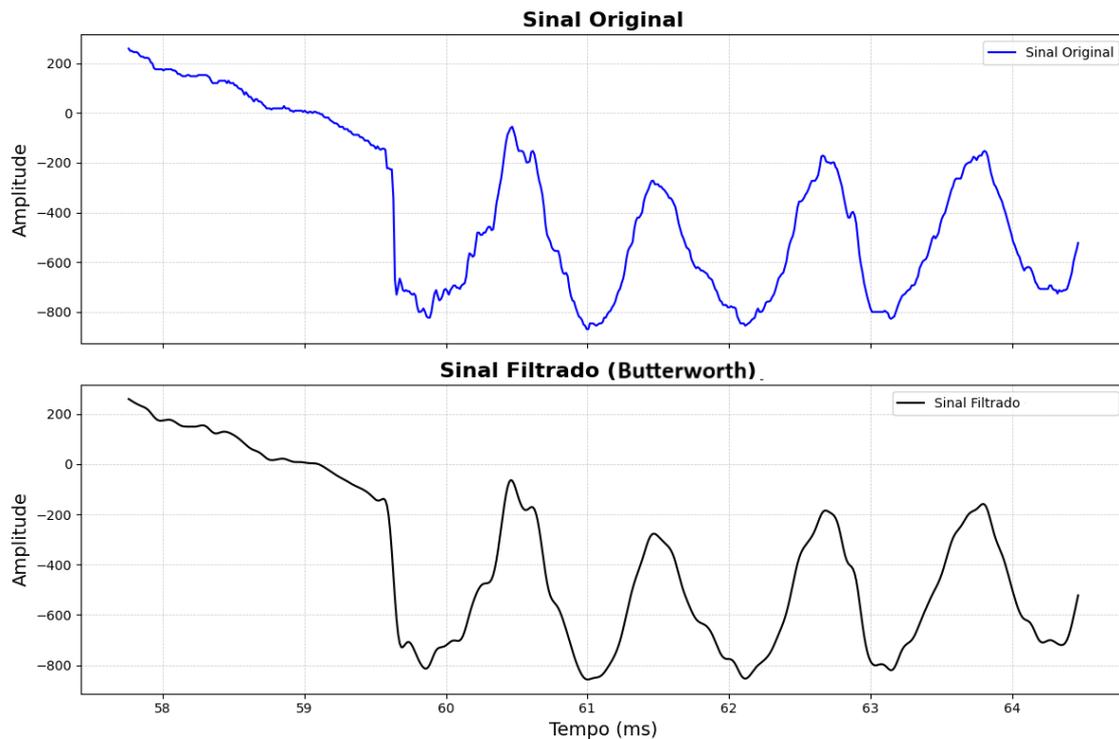


Figura 16 – Sinal filtrado por Butterworth. Criado pelo Autor

- $\psi^*(t)$ é a wavelet conjugada complexa.

A reconstrução do sinal a partir de suas componentes wavelet é feita pela transformada inversa de wavelets, representada na Equação 2.22:

$$f(t) = \frac{1}{C_\psi} \int_0^\infty \int_{-\infty}^\infty W(a,b) \psi_{a,b}(t) \frac{da db}{a^2}, \quad (2.22)$$

onde C_ψ é uma constante de admissibilidade que depende da função $\psi(t)$ (CAUMO, 2006).

As wavelets são aplicadas em filtragem de sinais através da decomposição multirresolução, que divide o sinal em componentes de diferentes níveis de detalhe como ilustrado na Figura 17. Isso facilita a remoção de ruídos e a preservação de informações relevantes, sendo especialmente útil em sinais e imagens ruidosas (GONZALEZ; WOODS, 2018; RAHMAN; HAQUE, 2012).

Existem diversos tipo de famílias de wavelets mãe, algumas ilustradas na Figura 18, onde cada tipo tem sua característica específica, algumas delas são:

- **Haar:** Simples e eficaz para detecção de bordas (LAI, 2012).
- **Daubechies:** Com mais momentos de vanishing, oferecem melhor representação de sinais (GONZALEZ; WOODS, 2018).
- **Symlets:** Uma versão mais simétrica das Daubechies (LAI, 2012; GONZALEZ; WOODS, 2018).
- **Coiflets:** Com momentos nulos na wavelet e na função de escala (LAI, 2012).

As wavelets têm uma ampla aplicação em processamento de sinais, como:

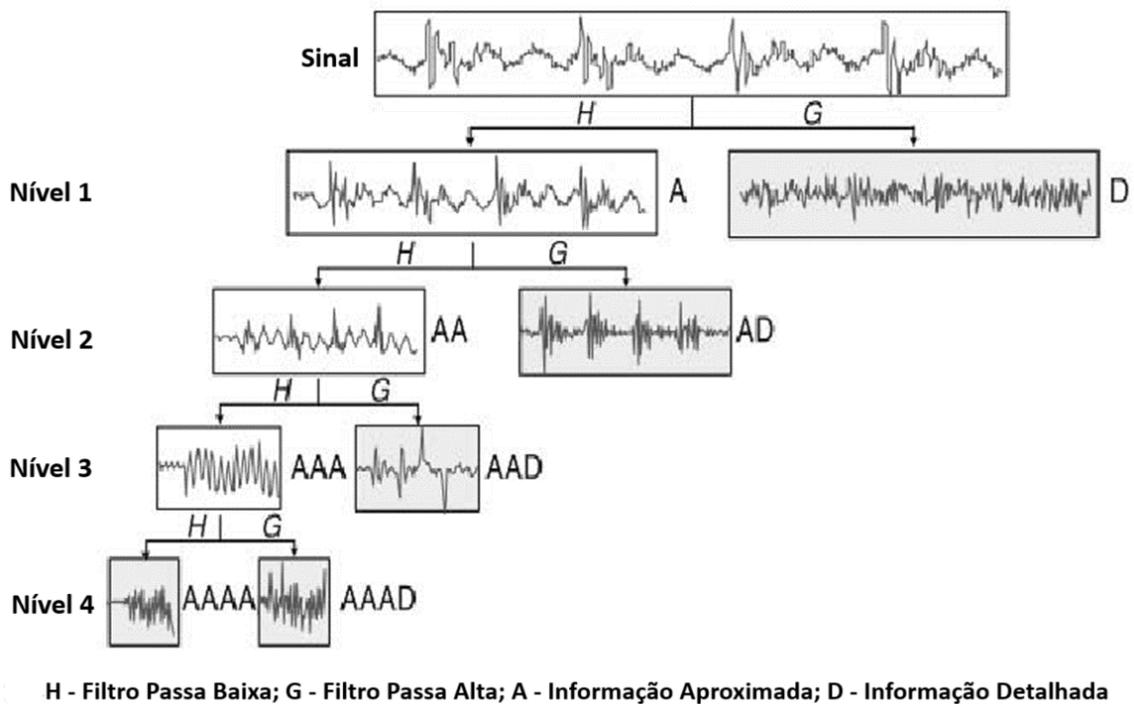


Figura 17 – Decomposição Wavelet, criado por (HAIDER et al., 2015), adaptado para o português pelo autor.

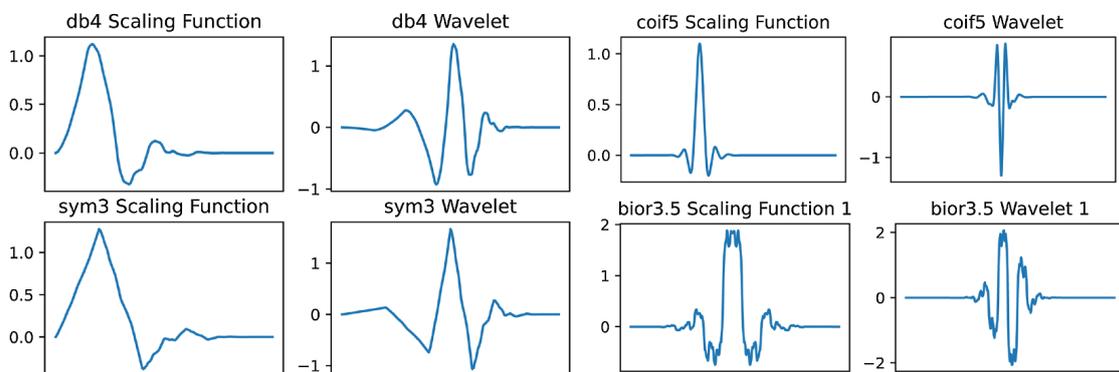


Figura 18 – Wavelets Mãe, criado por (MADHU; KUMARASWAMY, 2022)

- **Filtragem de Ruído:** Ao decompor o sinal em escalas diferentes, é possível identificar e eliminar componentes de alta frequência (ruído) mantendo as partes importantes do sinal. O processo envolve a aplicação da transformada de wavelets, remoção dos detalhes ruidosos e posterior reconstrução do sinal por meio da transformada inversa (CAUMO, 2006).
- **Compressão de Dados:** Devido à sua capacidade de representar sinais de forma compacta, as wavelets são usadas em algoritmos de compressão, como o JPEG-2000, que utiliza transformadas de wavelets para compressão de imagens (CAUMO, 2006).
- **Detecção de Anomalias:** A análise de sinais com wavelets permite identificar pontos de descontinuidade e eventos anômalos, sendo aplicável em áreas como a análise de sinais sísmicos e eletrocardiográficos (CAUMO, 2006).

Na Figura 19 é possível verificar um sinal de corrente da fase de um disjuntor limitado por uma janela de tempo (explicado e detalhado na seção 3.1.2) e o resultado da técnica para três tipos diferentes de wavelet mãe.

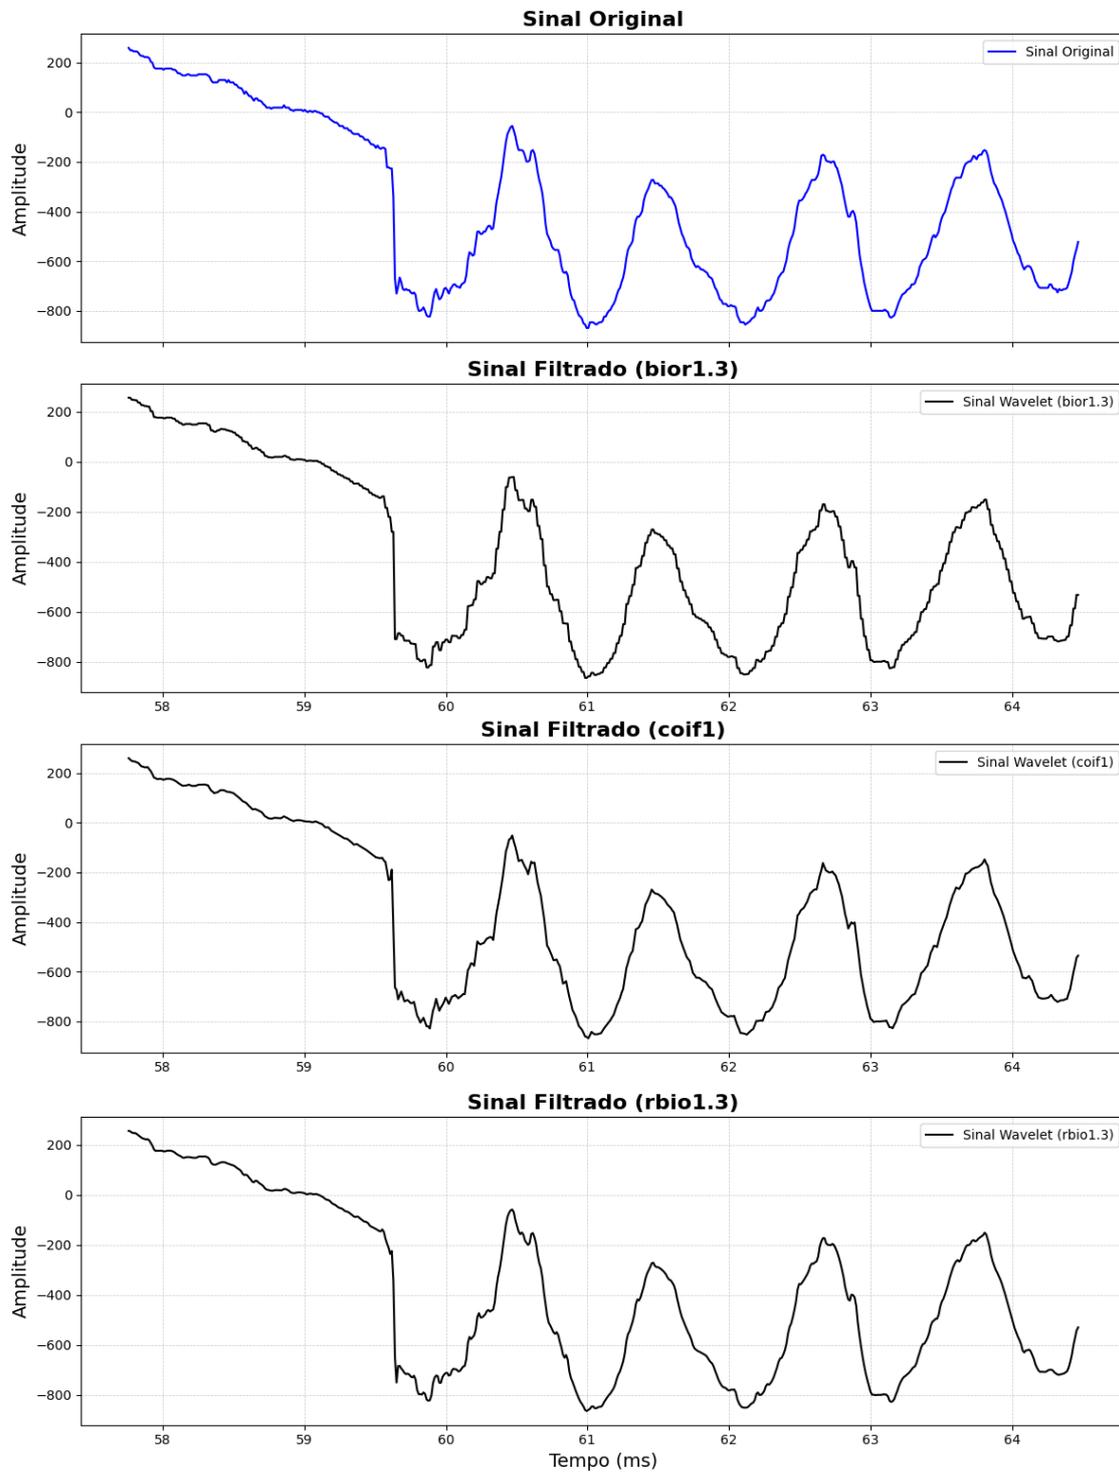


Figura 19 – Sinal filtrado por Wavelet mantendo apenas os coeficientes de menor nível. Criado pelo Autor

2.2.6 Aprendizado de Máquina

O aprendizado de máquina é um campo da inteligência artificial que envolve o desenvolvimento de algoritmos capazes de aprender padrões a partir de dados e fazer previsões ou decisões baseadas nestes. Com o avanço do poder de processamento e a maior disponibilidade de grandes volumes de dados, as aplicações de aprendizado se expandiram significativamente (SIMON; ALIFERIS, 2024; RATTAN DANIEL D. PENRICE, 2022; YING, 2019).

Basicamente é uma disciplina de inteligência artificial construída sobre a base de estatísticas clássicas como bem ilustrada na Figura 20, com a capacidade de lidar com operações matemáticas de alta dimensão e dados complexos para encontrar relações não lineares. A técnica é geralmente classificada em três tipos principais:

- **Aprendizado Supervisionado:** Modelos treinados com dados de entrada e saída rotulados para encontrar um mapeamento que minimize a diferença entre a saída prevista e a real.
- **Aprendizado Não Supervisionado:** Envolve a busca de padrões em dados não rotulados, identificando agrupamentos ou estruturas subjacentes sem uma variável de saída específica.
- **Aprendizado por Reforço:** O algoritmo aprende por tentativa e erro, interagindo com um ambiente para maximizar uma recompensa acumulada (SIMON; ALIFERIS, 2024; RATTAN DANIEL D. PENRICE, 2022).

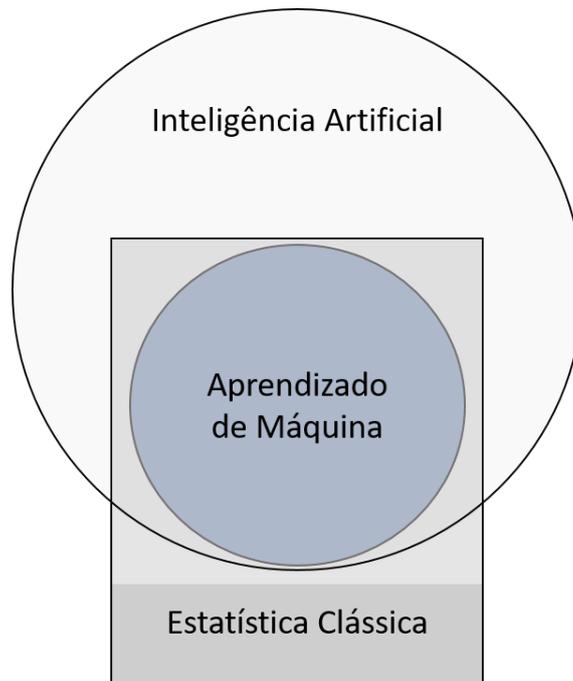


Figura 20 – Relação entre estatística, inteligência artificial e aprendizado de máquina. Adaptada de (RATTAN DANIEL D. PENRICE, 2022) pelo autor.

2.2.6.1 Adaptive Boosting

O *Adaptive Boosting* é um algoritmo de aprendizado de máquina desenvolvido por Freund e Schapire para melhorar a precisão de modelos de aprendizado fracos ao combiná-los em um classificador mais robusto e eficaz. Basicamente aplica iterativamente um algoritmo de aprendizado fraco em diferentes versões ponderadas do conjunto de treinamento. A cada iteração, os exemplos

mal classificados recebem pesos maiores, fazendo com que o próximo classificador dê mais atenção a esses casos difíceis (SCHAPIRE, 2013; WYNER et al., 2017; AN; KIM, 2010).

O AdaBoost começa atribuindo pesos iguais a todas as instâncias do conjunto de dados. Em cada iteração, o algoritmo realiza os seguintes passos:

- Treinamento de um classificador fraco $h_t(x)$ nos dados ponderados.
- Calcula o erro do classificador seguindo a Equação 2.23:

$$\epsilon_t = \sum_{i=1}^N w_i \cdot I(y_i \neq h_t(x_i)) \quad (2.23)$$

onde w_i são os pesos das instâncias e I é uma função indicadora que vale 1 para uma classificação incorreta e 0 para correta.

- Calcula a importância do classificador, vide Equação 2.24:

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \epsilon_t}{\epsilon_t} \right) \quad (2.24)$$

Classificadores com menor erro recebem um peso maior na combinação final.

- Atualiza os pesos das instâncias, como na Equação 2.25:

$$w_i \leftarrow w_i \exp(\alpha_t \cdot I(y_i \neq h_t(x_i))) \quad (2.25)$$

Os pesos são normalizados para manter a soma igual a 1, garantindo que o próximo classificador fraco foque nas instâncias mal classificadas (SCHAPIRE, 2013; WYNER et al., 2017).

A saída final do modelo é uma combinação ponderada dos classificadores fracos, vide Equação 2.26:

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right) \quad (2.26)$$

Isso resulta em um modelo que tem maior precisão do que qualquer um dos classificadores fracos isoladamente, e é capaz de ajustar sua decisão com base nos pesos atribuídos a cada classificador e nos dados de entrada (SCHAPIRE, 2013; AN; KIM, 2010; WYNER et al., 2017). O Adaboost tem características importantes como a melhora da margem de confiança na predições, o que melhora o desempenho de generalização (SCHAPIRE, 2013) e, apesar da técnica adicionar complexidade ao modelo, estudos mostram que ele é resistente ao *overfitting* quando o conjunto de dados tem baixo ruído (WYNER et al., 2017). Por outro lado, o algoritmo é sensível a *outliers* e ruídos nos dados de treinamento. Isso ocorre porque o algoritmo atribui pesos crescentes a exemplos que são constantemente classificados de forma incorreta, o que pode incluir *outliers*. Como resultado, o modelo pode ser influenciado por esses exemplos ruidosos (SCHAPIRE, 2013; AN; KIM, 2010).

2.2.6.2 Multi-Layer Perceptron (MLP)

Os *Multilayer Perceptrons (MLPs)* são uma das arquiteturas mais conhecidas e utilizadas em redes neurais artificiais. Consistem em uma estrutura de camadas interconectadas: uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A principal característica dos MLPs é que eles podem resolver problemas não linearmente separáveis, o que não é possível com perceptrons de uma única camada (DELASHMIT; MANRY et al., 2005; POPESCU et al., 2009).

Os MLPs operam de forma "feed-forward", ou seja, os sinais são transmitidos em uma única direção, da entrada para a saída, sem loops (DELASHMIT; MANRY et al., 2005; POPESCU et al.,

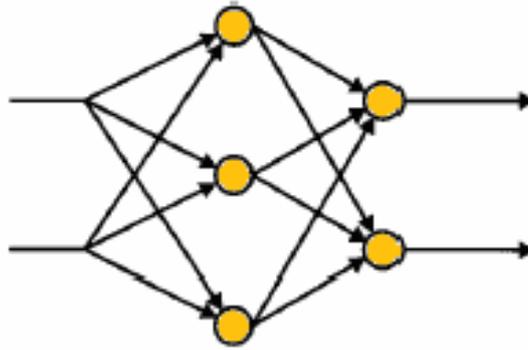


Figura 21 – Exemplo de rede *feed forward* (POPESCU et al., 2009)

2009) como ilustrado na Figura 21. Cada camada contém nós (neurônios) que realizam uma soma ponderada dos sinais de entrada, seguidos por uma função de ativação não linear, como a função sigmoide, conforme Equação 2.27:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.27)$$

ou a tangente hiperbólica, vide Equação 2.28:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.28)$$

Essas funções de ativação introduzem não linearidade, permitindo que a rede aprenda padrões complexos (POPESCU et al., 2009).

O treinamento deste tipo de rede neural é geralmente realizado pelo algoritmo de retropropagação de erro, que minimiza a diferença entre a saída desejada e a saída real, ajustando os pesos da rede por meio do gradiente descendente. O erro por época é atualizado a cada iteração e os gradientes são calculados para ajustar os pesos da camada de saída e das camadas ocultas (DELASHMIT; MANRY et al., 2005; POPESCU et al., 2009). Ele também tem a propriedade de serem aproximadores universais, ou seja, podem aproximar qualquer função contínua com um número suficiente de neurônios em suas camadas ocultas. Essa característica os torna amplamente aplicáveis em problemas de classificação e regressão (DELASHMIT; MANRY et al., 2005; POPESCU et al., 2009). Porém, o treinamento da rede pode ser demorado, exigindo milhares de épocas para problemas complexos. Técnicas como o método do momento e taxas de aprendizado variáveis podem acelerar o processo de treinamento e melhorar a convergência (POPESCU et al., 2009). A inicialização adequada dos pesos também é crucial para evitar problemas de saturação dos neurônios e gradientes nulos, que impedem o aprendizado eficaz (POPESCU et al., 2009).

2.2.6.3 Balanceamento de Dados

Existe um problema quando as classes de um conjunto de dados de treinamento possuem distribuições muito desiguais. Esta diferença dificulta a tarefa de classificação, pois os algoritmos tendem a favorecer a classe majoritária, resultando em baixa performance na detecção de elementos da classe minoritária. Em muitas aplicações, como diagnósticos médicos ou detecção de fraudes, a classe minoritária geralmente representa o caso de maior interesse (HAIXIANG et al., 2017). Os desafios relacionados a dados desbalanceados incluem a dificuldade em distinguir a classe minoritária da maioritária, a possibilidade de tratar elementos minoritários como ruído, e o impacto de exemplos sobrepostos e de baixa densidade no espaço das características (HAIXIANG et al., 2017; VLUYMANS, 2019). Essas dificuldades afetam não apenas o desempenho do modelo, mas também a interpretação de métricas de avaliação, que podem apresentar resultados distorcidos

ao priorizar a classe majoritária (HAIXIANG et al., 2017). Para enfrentar os desafios impostos por dados desbalanceados, diferentes técnicas têm sido propostas, classificadas em três categorias principais: técnicas no nível dos dados, abordagens no nível do algoritmo e métodos híbridos. Essas técnicas são projetadas para melhorar a representatividade da classe minoritária sem prejudicar o desempenho geral do modelo.

2.2.6.3.1 Nível dos Dados

As abordagens no nível dos dados são particularmente populares por sua versatilidade, já que podem ser aplicadas antes do treinamento do modelo, independentemente do algoritmo utilizado. Elas incluem:

- **Undersampling:** reduz a quantidade de exemplos da classe majoritária para equilibrar a proporção entre as classes. Técnicas simples incluem a seleção aleatória de exemplos da classe majoritária para exclusão. Apesar de melhorar o balanceamento, o undersampling pode remover exemplos importantes, reduzindo a variabilidade dos dados e potencialmente prejudicando o desempenho do modelo em dados complexos (HAIXIANG et al., 2017).
- **Oversampling:** aumenta o tamanho da classe minoritária. Métodos básicos incluem a replicação aleatória de exemplos minoritários. No entanto, isso pode levar ao sobreajuste, onde o modelo aprende padrões redundantes em vez de generalizar para novos dados. Para mitigar esse problema, técnicas como o SMOTE (Synthetic Minority Oversampling Technique) geram exemplos sintéticos ao invés de duplicar diretamente os existentes (HAIXIANG et al., 2017; FERNÁNDEZ et al., 2018).
- **Híbridos:** As abordagens híbridas combinam as vantagens do undersampling e do oversampling. Um exemplo é realizar oversampling para gerar novos exemplos minoritários e, em seguida, aplicar undersampling para limpar exemplos redundantes ou menos informativos da classe majoritária. Essa estratégia busca maximizar a representatividade das classes sem perder informações cruciais (VLUYMANS, 2019).

2.2.6.3.2 Nível do Algoritmo

As abordagens no nível do algoritmo modificam diretamente os modelos para lidar com dados desbalanceados. Algumas estratégias incluem:

- **Modelos Sensíveis a Custo:** Incorporam custos diferenciados para erros de classificação, penalizando mais fortemente erros na classe minoritária. Isso é comumente implementado em algoritmos como Support Vector Machines (SVM) e árvores de decisão (HAIXIANG et al., 2017).
- **Métodos Baseados em Ensemble:** Algoritmos como Random Forests e Boosting são ajustados para lidar com desbalanceamento, seja por meio da integração de técnicas de balanceamento no processo de amostragem ou pela criação de modelos especializados para a classe minoritária. Exemplos incluem SMOTEBoost, que combina o SMOTE com o algoritmo Boosting, criando instâncias sintéticas antes de ajustar os modelos baseados em ensemble (HAIXIANG et al., 2017).

2.2.6.3.3 Métodos Híbridos

Os métodos híbridos combinam as abordagens nos níveis de dados e algoritmos, explorando o melhor de ambos os mundos.

2.2.6.3.4 *Synthetic Minority Oversampling Technique*

O *Synthetic Minority Oversampling Technique* (SMOTE) é classificado como uma técnica no nível dos dados dentro da categoria de oversampling. Ele se destaca como uma abordagem avançada e amplamente utilizada para lidar com o desbalanceamento de classes. Diferentemente do oversampling tradicional, que apenas duplica exemplos da classe minoritária, o SMOTE introduz exemplos sintéticos, evitando a redundância e mitigando o risco de sobreajuste (FERNÁNDEZ et al., 2018). Opera criando exemplos sintéticos entre os pontos existentes da classe minoritária, usando interpolação linear no espaço das características. Ele seleciona um exemplo minoritário aleatoriamente e calcula seus vizinhos mais próximos (k-NN). Novos exemplos são então gerados ao longo das linhas que conectam o ponto selecionado aos seus vizinhos, garantindo diversidade sem duplicação exata. Essa técnica se baseia na relação das características do espaço amostral, em vez de simplesmente replicar dados (HAIXIANG et al., 2017; FERNÁNDEZ et al., 2018).

2.2.6.4 Práticas de Avaliação de Modelos

Para garantir a eficácia, a precisão e a generalização dos modelos em diferentes cenários a avaliação do modelo de aprendizado é parte crucial de seu desenvolvimento. As métricas de avaliação medem como o modelo está funcionando em termos de previsões corretas e incorretas e oferece uma visão ampla sobre a qualidade das suas previsões. A escolha destas métricas de avaliação deve ser guiada pelo contexto do problema e pelas características dos dados envolvidos (FLACH, 2019).

A matriz de confusão é uma tabela que apresenta, resumidamente, os resultados das previsões de um modelo de classificação, comparando as previsões feitas pelo modelo com os valores reais. Ela é composta por quatro elementos principais:

- **Verdadeiros Positivos (TP):** Casos em que o modelo previu corretamente a classe positiva.
- **Verdadeiros Negativos (TN):** Casos em que o modelo previu corretamente a classe negativa.
- **Falsos Positivos (FP):** Casos em que o modelo previu incorretamente a classe positiva quando a classe real era negativa (erro do tipo I).
- **Falsos Negativos (FN):** Casos em que o modelo previu incorretamente a classe negativa quando a classe real era positiva (erro do tipo II).

Com base na matriz de confusão, várias métricas de avaliação podem ser derivadas para avaliar o desempenho do modelo de forma detalhada (YACOUBY; AXMAN, 2020).

- **Acurácia:** A acurácia mede a proporção de previsões corretas em relação ao total de previsões feitas. É uma métrica útil quando as classes estão balanceadas, conforme Equação 2.29.

$$\text{Acurácia} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (2.29)$$

No entanto, em conjuntos de dados desbalanceados, a acurácia pode ser enganosa, pois um modelo que sempre prevê a classe majoritária pode ter uma alta acurácia, mas baixo desempenho em capturar a classe minoritária (FLACH, 2019).

- **Precisão (*Precision*):** A precisão, também conhecida como valor preditivo positivo, mede a proporção de exemplos corretamente classificados como positivos entre todos os exemplos que foram classificados como positivos pelo modelo, conforme Equação 2.30.

$$\text{Precisão} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2.30)$$

A precisão é especialmente importante em cenários onde os falsos positivos devem ser minimizados, como em diagnósticos médicos (FLACH, 2019; SIMON; ALIFERIS, 2024).

- **Recall:** O *recall*, ou sensibilidade, mede a capacidade do modelo de identificar corretamente todos os exemplos positivos. É a proporção de verdadeiros positivos em relação ao total de exemplos que realmente pertencem à classe positiva, conforme Equação 2.31.

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2.31)$$

O recall é fundamental em casos em que os falsos negativos devem ser minimizados, como na detecção de doenças graves, onde é mais importante capturar todos os casos positivos (FLACH, 2019; YACOUBY; AXMAN, 2020).

- **F1-Score:** O *F1-score* é a média harmônica entre a precisão e o recall, proporcionando um equilíbrio entre ambas as métricas. Ele é útil quando é necessário considerar tanto a precisão quanto o recall em um único valor. Representada na Equação 2.32.

$$\text{F1} = 2 \cdot \frac{\text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (2.32)$$

O *F1-score* é mais informativo que a acurácia em cenários com classes desbalanceadas, pois equilibra a importância dos verdadeiros positivos e falsos negativos (FLACH, 2019; YACOUBY; AXMAN, 2020).

- **Especificidade:** Mede a proporção de verdadeiros negativos corretamente identificados em relação ao total de exemplos que realmente pertencem à classe negativa. Representada na Equação 2.33.

$$\text{Especificidade} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (2.33)$$

A especificidade é relevante em contextos onde é importante evitar falsos positivos, como em testes de triagem (YACOUBY; AXMAN, 2020).

- **Área sob a Curva ROC (AUC-ROC):** A AUC representa a capacidade do modelo de distinguir entre as classes positiva e negativa. Uma curva ROC (*Receiver Operating Characteristic*) é traçada com o eixo x representando a taxa de falsos positivos e o eixo y a taxa de verdadeiros positivos. Representada na Equação 2.34.

$$\text{AUC} = \int_0^1 \text{TPR}(\text{FPR}) \, d\text{FPR} \quad (2.34)$$

Um modelo com AUC próximo de 1 é considerado excelente, enquanto um AUC de 0,5 indica que o modelo não tem capacidade de discriminação (equivalente a uma escolha aleatória) (YACOUBY; AXMAN, 2020).

Essas métricas permitem uma análise detalhada e criteriosa do desempenho dos modelos, garantindo que os resultados sejam interpretados corretamente em diferentes contextos (YING, 2019; ANGUITA et al., 2012; ZHANG; LIU, 2023).

2.2.6.5 *Overfitting* e *Underfitting* em Aprendizado de Máquina

Overfitting e *underfitting* são problemas críticos no treinamento de modelos de aprendizado de máquina que afetam sua capacidade de generalização. Entender a diferença entre esses fenômenos e as estratégias para evitá-los é fundamental para desenvolver modelos eficazes. O *overfitting* ocorre quando um modelo aprende com grande precisão os detalhes, ruídos e características do conjunto de treinamento, se ajustando muito bem aos dados de treinamento, o que resulta em excelente desempenho, porém baixa capacidade de generalização. Ou seja, o modelo está capturando padrões específicos do conjunto de treinamento que não se repetem em outros dados o que faz ele ser bom somente em prever aqueles casos (JABBAR; KHAN, 2015; FLACH, 2019). O *underfitting*, por outro lado, ocorre quando um modelo não é treinado o suficiente para capturar a variabilidade dos dados, resultando em baixo desempenho tanto no conjunto de treinamento quanto nos conjuntos de teste (JABBAR; KHAN, 2015). Para evitar estes problemas vários métodos podem ser empregados para sua mitigação:

- **Early Stopping** O método de *early stopping* é uma técnica de regularização em que o treinamento do modelo é interrompido assim que o erro no conjunto de validação começa a aumentar, mesmo que o erro no conjunto de treinamento continue a diminuir. Essa abordagem ajuda a evitar que o modelo se ajuste excessivamente aos dados de treinamento (YING, 2019; FLACH, 2019).
- **Métodos de Penalização** A adição de termos de penalidade na função de custo, como a regularização L1 ou L2, impõe uma restrição na magnitude dos pesos dos parâmetros do modelo. Isso ajuda a reduzir a complexidade do modelo, evitando o *overfitting* ao restringir os pesos dos parâmetros, conforme Equação 2.35:

$$\text{Função de custo regularizada} = E_{\text{train}} + \lambda \sum_i w_i^2 \quad (2.35)$$

onde λ controla o grau de penalização aplicado (YING, 2019).

- **K-fold Cross-Validation** A **validação cruzada** é uma técnica essencial para a avaliação de modelos de aprendizado de máquina, que divide o conjunto de dados em k subconjuntos iguais. Em cada iteração, um subconjunto serve como conjunto de validação enquanto os $k - 1$ restantes são usados para treinamento, garantindo que cada observação seja utilizada para ambos os propósitos. Essa abordagem diminui o viés na estimativa de erro e promove maior estabilidade nos resultados, sendo comum a escolha de $k = 5$ ou $k = 10$ para um equilíbrio entre viés e variância. No entanto, o KCV pode ter um alto custo computacional, especialmente com modelos complexos ou grandes volumes de dados (ANGUITA et al., 2012).

3 Desenvolvimento Proposto

3.1 Metodologia de Pesquisa

A manobra controlada de disjuntores geralmente é verificada durante o período de manutenção dos ativos nas empresas de energia no Brasil, que ocorre normalmente a cada 6 anos, ou durante a manutenção corretiva. No intervalo entre uma verificação e outra, devido a diferentes fatores, podem ocorrer variações no tempo de operação do disjuntor. Ele pode não fechar no tempo ideal, o que pode levar a um desgaste acelerado do ativo e reduzir sua vida útil. A identificação dos momentos de inserção de contato é atualmente realizada visualmente por um especialista em manobra controlada. Essa tarefa se torna complexa ao considerar um sistema real operando na subestação, sujeito a diversas interferências e ruídos, como, por exemplo, os altos transitórios gerados, bem como os distúrbios gerados pelo efeito back-to-back da manobra controlada no banco de capacitores.

Em um sinal comum como o da Figura 22(a), sem ruído e interferência, é fácil identificar visualmente os pontos de pré-inserção, círculo vermelho (1), e contato principal, círculo azul (2). No entanto, diversos sinais contêm ruídos ou interferências, que podem ser causados por leituras defeituosas, interferência de outros bancos de disjuntores fechados ou até mesmo de outras fases do mesmo banco, e quando ocorre o efeito back-to-back, causando altos transitórios. Alguns exemplos podem ser vistos no lado direito da Figura 22. Como pode ser observado, a identificação do contato principal apresenta desafios em sua localização. Mesmo sem ruídos ou interferências, o ponto pode não ser muito claro e objetivo, então qualquer pequeno incidente no sinal dificulta bastante sua localização. A Figura 22 mostra os problemas encontrados nos dados obtidos, como altos transitórios no sinal e interferências de outras fases fechadas, no identificador b) antes do contato resistivo contem picos e antes do contato principal também, no identificador c) o começo do sinal que deveria ser uma linha reta tem uma interferência que causa uma onda, além de picos após o contato principal, o mesmo acontece no c) que tem muitos transitórios após o contato principal e estes são causados pelos fechamentos das outras fases do disjuntor. O uso de filtros para suavizar e remover ruídos tem mostrado alguma eficácia, pois em cada caso de ruído ou interferência, um filtro de sinal se sai melhor que outro. Assim, foi necessário utilizar recursos mais avançados para a identificação dos pontos.

O fluxograma na Figura 23 apresenta a metodologia proposta para o desenvolvimento deste trabalho. O desenvolvimento foi dividido em 4 módulos, caracterizados por carregamento de dados e detecção do ponto de pré-inserção, geração do conjunto de dados, treinamento e teste do modelo, e análise dos disjuntores operando com banco de capacitores. O primeiro é responsável por ler o arquivo onde os sinais brutos de corrente e tensão dos disjuntores foram salvos, aplicando um pré-filtragem para detectar o ponto de pré-inserção. O segundo foi estruturado para transformar um desafio de processamento de sinal em um problema de classificação, construindo um conjunto de dados usando diferentes filtros voltados à extração de características sob ruído e várias interferências presentes para detectar o ponto de contato principal. O terceiro módulo foi desenvolvido para construir dois classificadores clássicos presentes na literatura para realizar a identificação do contato principal. Após definir o modelo eficiente, o último módulo é responsável por extrair os tempos e outras informações dos disjuntores para verificar o sincronismo e outras informações como corrente de inrush, etc. As subseções a seguir explicarão em detalhes o que foi desenvolvido em cada módulo.

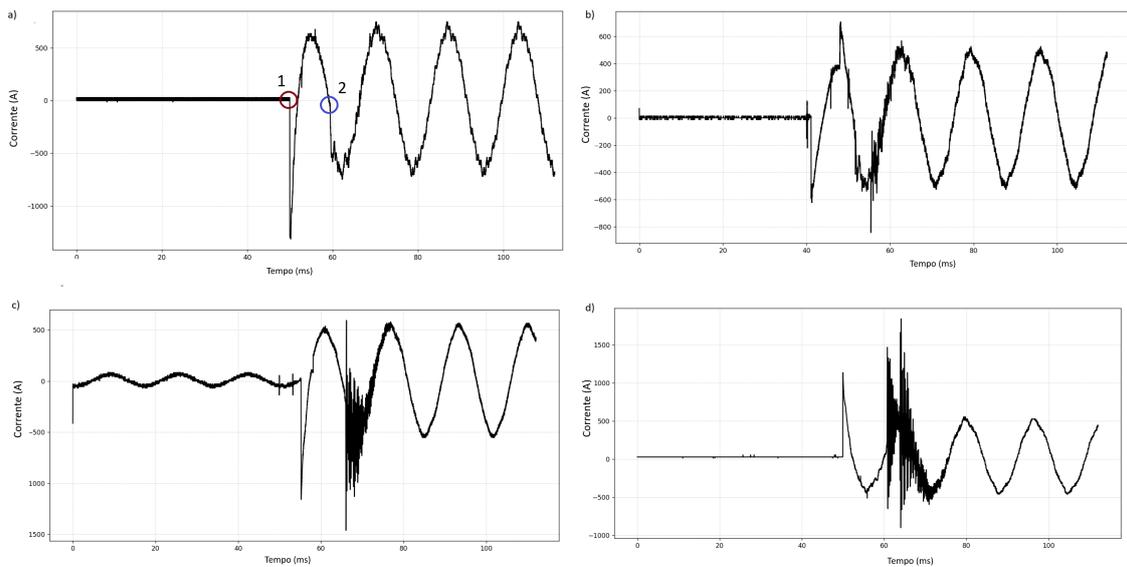


Figura 22 – Exemplos de sinais de corrente.

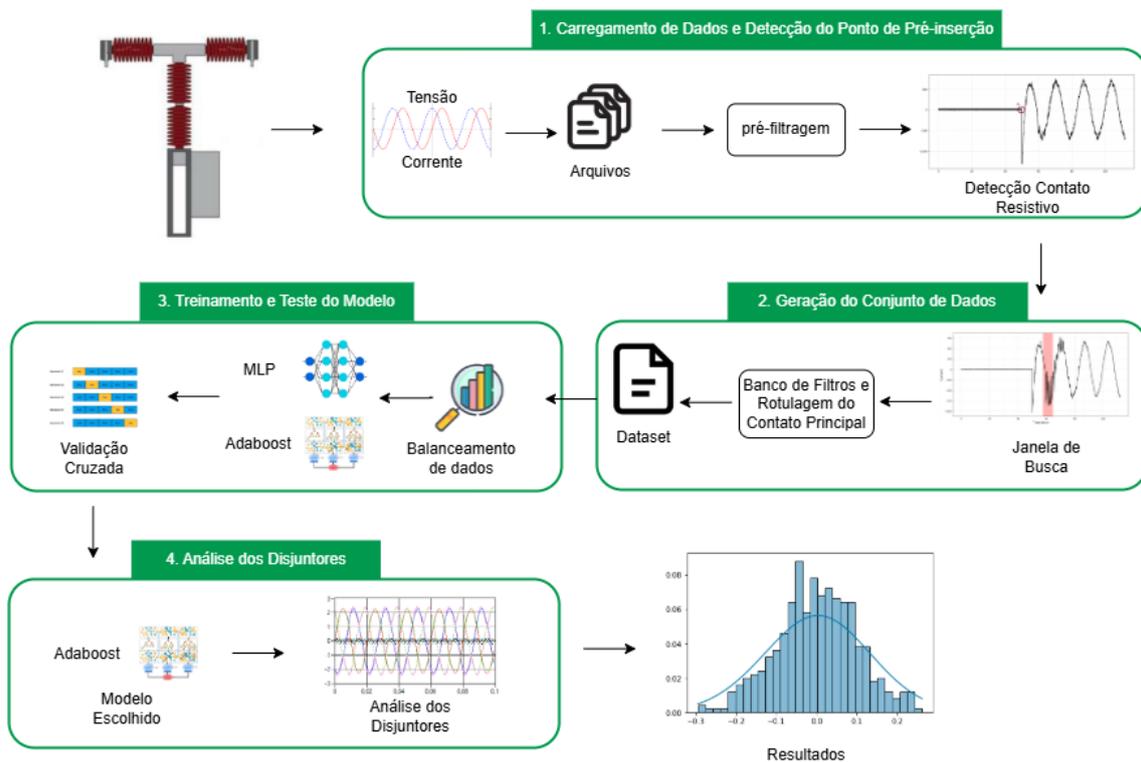


Figura 23 – Metodologia proposta para o desenvolvimento deste trabalho.

3.1.1 Carregamento de Dados e Detecção do Ponto de Pré-inserção

A captura de dados dos bancos de capacitores ocorre cada vez que um banco é operado. Cada disjuntor possui três fases que são operadas de forma síncrona. O arquivo gerado contém a corrente de todos os bancos e de todas as fases, e por fim inclui a tensão de linha da fase A para a fase C.

Cada arquivo contém em seu nome a data e hora em que a operação ocorreu e o nome do banco que foi operado. Portanto, é possível pelo menos determinar quando a operação ocorreu e qual banco foi operado. Esses arquivos apresentam dois problemas principais:

- Arquivos corrompidos: que não podem ser lidos.
- Arquivos com o nome do banco incorreto: ao analisar a corrente do banco indicado no arquivo, fica claro que este não foi o banco operado, exigindo que cada banco seja verificado para identificação. Para este trabalho, arquivos com este problema foram descartados.

O contato de pré-inserção pode ser encontrado, na maioria dos casos, calculando a derivada do sinal. Por exemplo, a Figura 24(a) e a Figura 24(c) apresentam o sinal bruto de corrente e sua saída do filtro de derivada. É possível ver que a primeira variação é precisamente o contato de pré-inserção. No entanto, em alguns casos, apenas a derivada falha devido ao ruído e interferência que ocorrem momentos antes do ponto de pré-inserção, como no exemplo de sinal com ruído mostrado em 24(b). Assim, sua derivada apresenta grandes variações anteriores ao contato de pré-inserção, exigindo uma pré-filtragem. Portanto, um filtro de média móvel, representado pela Equação 2.6, foi utilizado neste caso com $k = 10$, o que significa que o filtro considera os últimos 10 pontos da série. Este filtro suaviza o sinal, removendo o ruído prévio e mostrando-se eficaz para todos os casos de teste.

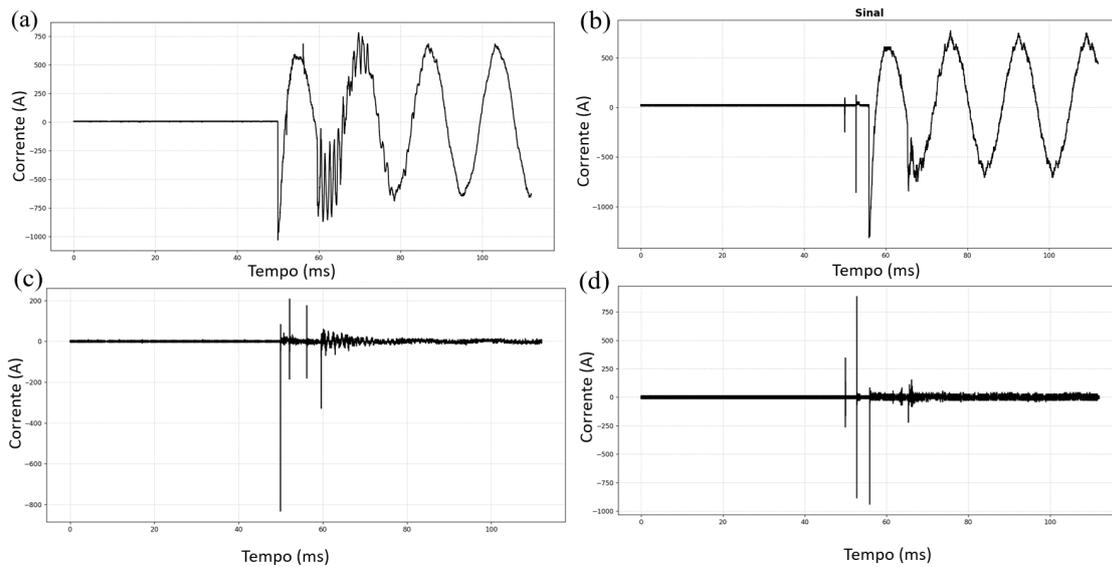


Figura 24 – (a) Sinal sem ruído antes do contato resistivo. (b) Sinal com ruído antes do contato resistivo. (c) Derivada do sinal sem ruído antes do contato resistivo. (d) Derivada do sinal com ruído antes do contato resistivo.

3.1.2 Geração do Conjunto de Dados

O contato principal é mais desafiador de identificar em sinais com ruído e interferência. Mesmo com a aplicação de filtros para suavizar o sinal, como no caso do contato de pré-inserção, os resultados obtidos não são satisfatórios. Ao processar os sinais através de um banco de filtros e organizar cada ponto dos sinais sequencialmente, torna-se possível construir um conjunto de dados de treinamento. Essa abordagem transforma o desafio em um problema de classificação, permitindo que um modelo de Machine Learning seja treinado para identificar o contato principal com maior precisão.

Para isso, o seguinte processo foi realizado. Sabe-se que o fabricante do disjuntor estabelece valores padrão para os tempos de contato e variações permitidas em disjuntores em bom funcionamento. O tempo entre a pré-inserção e o contato principal é de aproximadamente 10 ms (FANTOZZI, 1995; ZONDI; BOKORO; PAUL, 2015). Assim, usar esse tempo como referência a partir do contato de pré-inserção permite determinar uma variação, formando uma janela de busca onde o contato principal pode estar. Essa variação foi definida como 8 ms, uma variação maior do que o considerado saudável, o que foi necessário para incluir casos em que o disjuntor pode estar defeituoso. Na Figura 25, a janela em vermelho à esquerda fornece o contexto para o sinal completo, e à direita mostra a janela em detalhe.

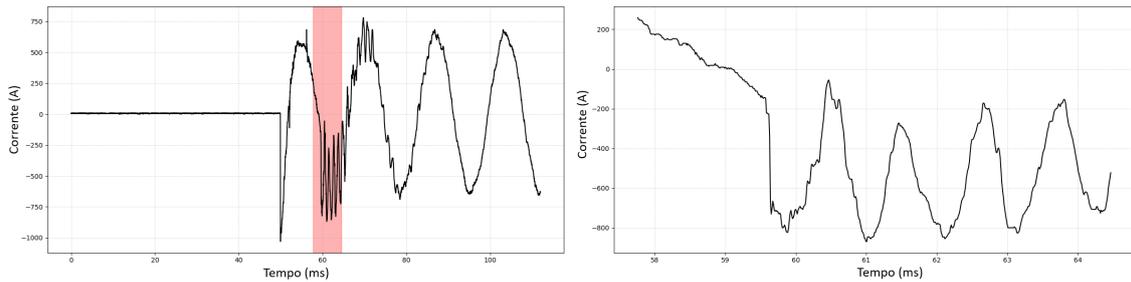


Figura 25 – Definição da janela de busca para o contato principal. (a) a janela de busca foi definida a partir do sinal de corrente bruto, e (b) o sinal especificamente nessa janela.

Subsequentemente, cada amostra do sinal dentro dessa janela de busca é considerada como uma candidata a ser o ponto do contato principal. Nesse sentido, a extração de características foi conduzida para caracterizar as propriedades que podem distinguir este contato principal sob a influência de ruídos e interferências, conforme mencionado anteriormente. Assim, vários filtros com diferentes parâmetros foram aplicados para o processo de extração de características. A Tabela 1 resume o banco de filtros utilizado e os parâmetros aplicados.

Na Figura 26, podemos observar o sinal original e alguns exemplos dos filtros aplicados. Note que, embora cada filtro suavize o sinal, cada um apresenta um certo padrão no momento do contato.

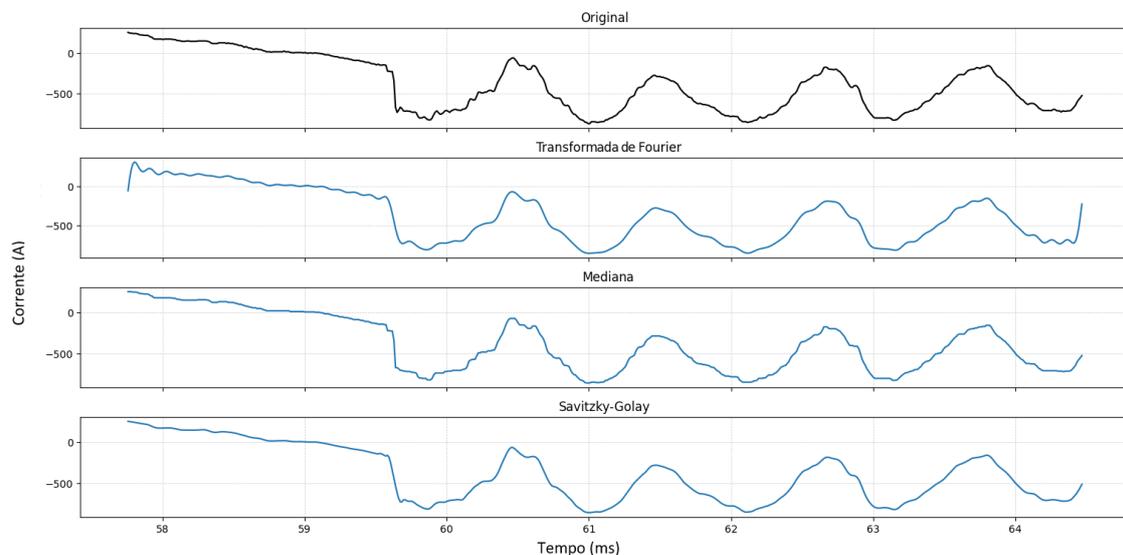


Figura 26 – Algumas respostas do banco de filtros aplicado.

Filtro	Parâmetros
Derivada (SALINAS et al., 2018)	Ordem 1
Integral (SALINAS et al., 2018)	Ordem 1
Média Móvel (SHAN et al., 2022)	Convolução com uma janela de tamanho 10
Mediana (GEORGE et al., 2018)	Usando uma janela de tamanho 10
Savitzky-Golay (SAVITZKY; GOLAY, 1964)	Com um polinômio de grau 2 e uma janela de tamanho 10
Transformada de Fourier (FOURIER, 1822; GONZALEZ; WOODS, 2018)	Filtrando frequências acima de 100 Hz
Transformada Cosseno Discreta (ZHOU; CHEN, 2009)	Com normalização ortogonal e removendo componentes de alta frequência, zerando a metade superior dos coeficientes
Transformada de Hilbert (FELDMAN, 2011)	Calculando o envelope do sinal e obtendo o sinal através da magnitude da transformada
Butterworth (SHOURAN; ELGAMLI, 2020)	Com uma frequência de corte de 100 Hz e ordem 4
Wavelet (CAUMO, 2006)	Decompondo o sinal com diferentes wavelets e mantendo apenas os coeficientes de menor nível. Foram utilizadas wavelets Biortogonal, Coiflet, Meyer Discreta e Biortogonal Reversa

Tabela 1 – Tabela com filtros e parâmetros.

Embora a tensão seja fase-a-fase e não de cada fase individualmente, é possível identificar um padrão quando ocorrem os pontos de pré-inserção e de contato principal, como mostrado na Figura 27, onde a tensão é representada pela linha azul. Portanto, decidiu-se incluir a tensão junto aos sinais de corrente, ambos filtrados pelo banco de filtros, no conjunto de dados de treinamento para melhorar a eficácia da identificação. O resultado é um vetor de características com 600 linhas, onde cada linha representa um momento do sinal, e 82 colunas que correspondem aos filtros (41 do sinal de corrente e 41 da tensão). Ou seja, os sinais são processados através do banco de filtro cada saída de um filtro, que sempre tem o mesmo tamanho do sinal original, são anexados à uma linha de uma matriz. Esta matriz é transposta para que neste momento cada coluna seja correspondente a um filtro e cada linha um momento do sinal. Então temos 82 *features* para 600 momentos de sinais.

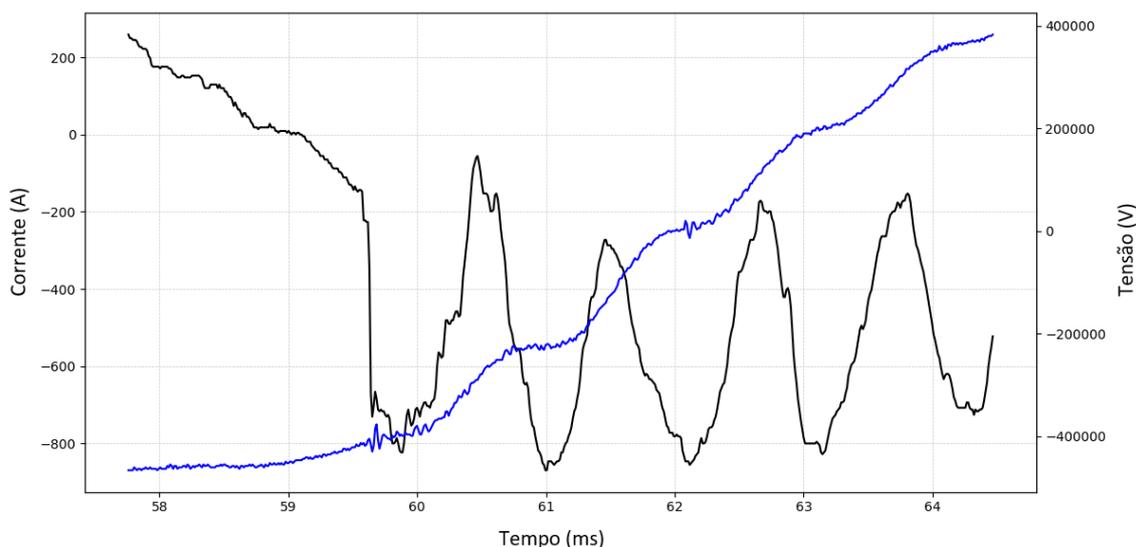


Figura 27 – Sinais de Corrente(linha preta) e Tensão(linha azul).

Os pontos de contato principal foram rotulados manualmente, um por um, para garantir anotações precisas no conjunto de dados de treinamento. O conjunto de dados criado contém um total de 1.042.199 pontos de dados, dos quais 1.737 foram rotulados como pontos de contato principal (valor 1) e os restantes como não correspondendo ao contato principal (valor -1). Desta maneira transformamos o problema de identificação do ponto em um problema de classificação, onde cada ponto do sinal tem seus valores de filtro e a marcação para identificar se é o contato principal ou não. Esses pontos vêm de 1.737 sinais, distribuídos por ano conforme:

Ano	Número de Sinais
2010	394
2011	584
2019	675
2020	84

Tabela 2 – Distribuição dos sinais no conjunto de dados por ano.

3.1.3 Treinamento e Teste do Modelo

Esta seção apresenta uma visão geral dos métodos utilizados para o treinamento e teste dos modelos. Inicia-se com a ampliação e normalização dos dados, cobrindo técnicas de balanceamento de dados e a normalização aplicada. Em seguida, são detalhadas as arquiteturas dos modelos Multilayer Perceptron (MLP) e Adaptive Boosting (AdaBoost), incluindo os parâmetros de treinamento e o uso de validação cruzada k-fold. As métricas de desempenho dos modelos, como precisão, recall e F1-score, são apresentadas, juntamente com a validação estatística através do teste de Wilcoxon. Por fim, é realizada uma análise dos comportamentos dos disjuntores, detalhando cálculos para os tempos de pré-inserção e contato principal, corrente máxima de inrush e sincronismo de fases, suportados por equações e figuras.

3.1.3.1 Ampliação e normalização dos dados

Os dados foram preparados por meio de técnicas de balanceamento e normalização para garantir a qualidade dos dados durante o treinamento do modelo. Para o balanceamento de dados, foi aplicada uma combinação de undersampling e SMOTE (Synthetic Minority Over-sampling Technique)(FERNÁNDEZ et al., 2018). Inicialmente, o undersampling foi utilizado para reduzir o número de amostras incorretas, ou seja os pontos que não são o contato principal. Em seguida, o SMOTE foi aplicado para aumentar o número de amostras corretas que originalmente eram 3.000, igualando-o ao número de pontos incorretos, resultando em um conjunto final de 5.000 pontos que caracterizam o contato principal e o mesmo número de pontos que não o caracterizam.

Para a normalização dos dados, foi aplicado o método de padronização utilizando a técnica Standard Scaler(RAJU et al., 2020), que transforma cada variável X de forma que sua média seja zero e seu desvio padrão seja um, conforme a Equação 3.1:

$$X_{\text{normalizado}} = \frac{X - \mu}{\sigma} \quad (3.1)$$

onde μ representa a média dos valores de X e σ o desvio padrão. Este passo garante que todas as variáveis estejam na mesma escala, melhorando a eficácia do modelo de aprendizado de máquina.

3.1.3.2 Perceptron multicamadas - MLP

O MLP é uma rede neural feedforward composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A rede desenvolvida neste trabalho possui uma camada de entrada com 82 neurônios, uma camada oculta com 100 neurônios e uma camada de saída com 2 neurônios, como ilustrado na Figura 28, que apresenta uma arquitetura simples, mas eficaz, para uma rede neural multicamadas. A rede e o treinamento foi feito utilizando o *MLPClassifier* da biblioteca *sklearn* do *python*. Com 100 neurônios na camada oculta e uma função de ativação não linear, como ReLU, o MLP pode capturar relações complexas nos dados. O treinamento é realizado utilizando o algoritmo de retropropagação, que ajusta os pesos com base no erro em cada iteração(DELASHMIT; MANRY et al., 2005; POPESCU et al., 2009).

3.1.3.3 Boosting Adaptativo - AdaBoost

O AdaBoost é um modelo de ensemble que combina múltiplas árvores de decisão fracas para formar um classificador robusto. Ele utiliza um conjunto de classificadores fracos, árvores de decisão de profundidade 1 chamadas stumps, e itera sobre elas para reduzir os erros, aumentando o peso dos dados classificados incorretamente em cada iteração. Neste trabalho, o modelo desenvolvido utiliza 500 estimadores, o que significa que gera 500 classificadores fracos, como ilustrado na Figura 29, combinando-os em sequência. A rede e o treinamento foi feito utilizando *AdaBoostClassifier* da biblioteca *sklearn* do *python*. Cada novo classificador tenta corrigir os erros do conjunto anterior, ajustando-se iterativamente (SCHAPIRE, 2013; WYNER et al., 2017; AN; KIM, 2010).

3.1.4 Validação Cruzada

Para obter uma avaliação robusta do desempenho do modelo, foi utilizada a técnica de validação cruzada. Esse método permite que o modelo seja testado em diferentes subconjuntos dos dados, reduzindo o risco de overfitting ou underfitting e garantindo que o desempenho observado não seja específico a uma única divisão entre treino e teste. Neste trabalho, foi empregada a Validação Cruzada K-Fold, onde cada subconjunto serve como conjunto de teste uma vez, enquanto os K-1 subconjuntos restantes formam o conjunto de treinamento. Este processo é repetido K vezes,

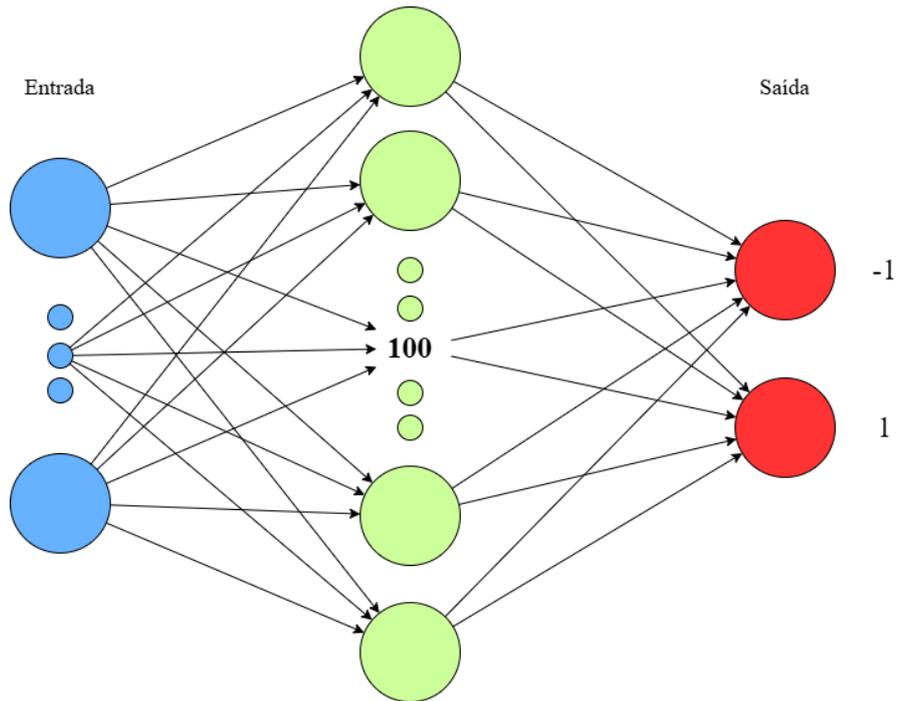


Figura 28 – Arquitetura do MLP desenvolvida para este trabalho. Possui 82 neurônios de entrada, 100 neurônios na camada oculta e 2 na camada de saída.

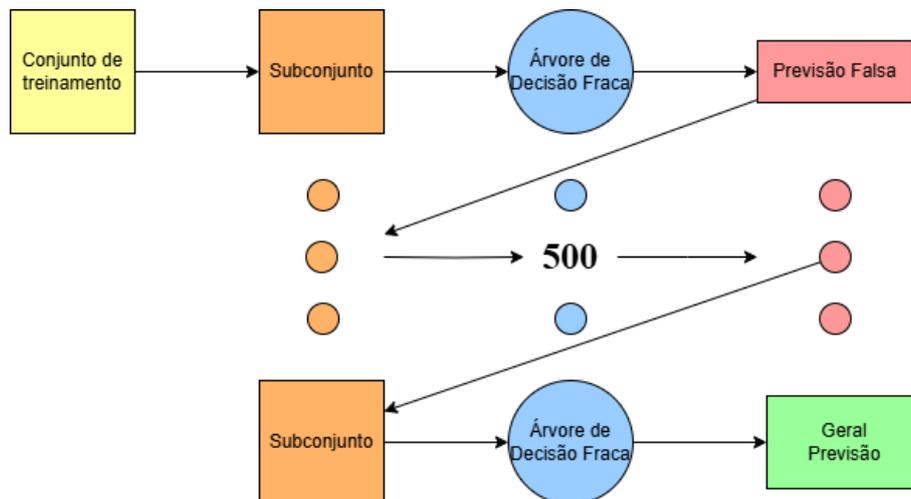


Figura 29 – AdaBoost com 500 classificadores fracos.

garantindo que cada instância dos dados seja usada tanto para treinamento quanto para teste. O número de divisões ($K=10$) foi escolhido por ser amplamente utilizado em estudos relacionados e recomendado como uma configuração padrão em validações cruzadas para dados de aprendizado de máquina (ZHANG; LIU, 2023). Além disso, para garantir a reprodutibilidade dos experimentos, foi utilizado um seed fixo (valor 42) no processo de geração das divisões entre treino e teste. O seed é um valor inicial que configura o gerador de números pseudoaleatórios, permitindo que o mesmo conjunto de dados seja dividido de forma idêntica em execuções diferentes. Isso é particularmente importante para comparar resultados de diferentes modelos ou técnicas, assegurando que quaisquer diferenças observadas sejam devidas às características dos modelos e não a variações aleatórias nas divisões dos dados. Os parâmetros utilizados para a Validação Cruzada K-Fold para ambos os modelos são apresentados na Tabela 3.

Parâmetro	Valor
Número de divisões (K-Fold)	10
Seed para reprodutibilidade	42

Tabela 3 – Parâmetros Utilizados na Validação Cruzada K-Fold.

3.1.5 Análise dos tempos envolvidos nas manobras do disjuntor

Para determinar o intervalo de tempo entre o a entrada do resistor de pré-inserção e o contato principal, o tempo do contato de pré-inserção ($T_{\text{pré-inserção}}$) foi subtraído do tempo do contato principal ($T_{\text{principal}}$), conforme apresentado na Equação 3.2:

$$\Delta T_{\text{pré-inserção}} = T_{\text{principal}} - T_{\text{pré-inserção}} \quad (3.2)$$

onde $T_{\text{principal}}$ representa o momento em que o contato principal se fecha, e $T_{\text{pré-inserção}}$ é o tempo em que ocorre o contato de pré-inserção.

O valor da corrente de inrush foi obtido encontrando o pico do sinal de corrente no momento do fechamento do contato principal. O valor de I_{inrush} é descrito pela Equação 3.3:

$$I_{\text{inrush}} = \max(I(t)) \quad (3.3)$$

Para determinar o intervalo de tempo entre o contato principal e a passagem por zero da corrente, o sinal de corrente foi analisado para identificar os pontos de cruzamento com zero mais próximos ao tempo do contato principal, $T_{\text{principal}}$. O processo envolve verificar tanto os cruzamentos anteriores quanto os posteriores a $T_{\text{principal}}$, selecionando o ponto mais próximo. Esse intervalo é calculado pela seguinte relação na Equação 3.4:

$$\Delta T_{\text{zero}} = \min(|T_{\text{principal}} - T_{\text{zero,esquerda}}|, |T_{\text{principal}} - T_{\text{zero,direita}}|) \quad (3.4)$$

onde $T_{\text{zero,esquerda}}$ e $T_{\text{zero,direita}}$ representam os tempos dos cruzamentos com zero mais próximos antes e depois de $T_{\text{principal}}$, respectivamente.

Em sistemas trifásicos, cada fase (A, B e C) deve fechar em sincronismo com uma diferença de fase de 60 graus (2,78 ms), o que é crucial para evitar transitórios indesejados de corrente e manter o equilíbrio do sistema. Para avaliar o sincronismo no fechamento dos contatos principais entre as fases A, B e C, foram calculados os intervalos de tempo entre os momentos de fechamento dos contatos principais de cada fase. O sincronismo é definido pelas diferenças de tempo entre os contatos principais das fases adjacentes, conforme mostrado nas Equações 3.5 e 3.6:

$$\Delta T_{\text{sincronismo,AB}} = T_{\text{principal,B}} - T_{\text{principal,A}} \quad (3.5)$$

$$\Delta T_{\text{sincronismo,BC}} = T_{\text{principal,C}} - T_{\text{principal,B}} \quad (3.6)$$

Um total de 4.795 arquivos foram analisados, cada um contendo o sinal de três fases e a tensão do barramento, resultando em 14.385 sinais. Foram calculados o tempo do contato de pré-inserção, o tempo do contato principal, a diferença entre eles, o tempo de sincronismo do contato principal com o cruzamento por zero da corrente, o valor máximo da corrente do sinal e o sincronismo entre as fases.

4 Resultados e Discussões

4.1 Resultados Quantitativos

Esta seção apresenta e discute os resultados obtidos a partir da análise dos sinais de corrente dos disjuntores, abrangendo tanto o desempenho dos modelos de treinamento e validação quanto a análise estatística dos tempos de operação dos disjuntores. A análise está dividida em duas subseções principais: a primeira examina a eficácia dos modelos utilizados, incluindo métricas quantitativas e qualitativas das detecções realizadas, enquanto a segunda subseção explora aspectos temporais e de corrente dos eventos, como o tempo entre a pré-inserção e o contato principal, corrente máxima de inrush e o sincronismo das fases A, B e C. Para maior clareza, tabelas e figuras são apresentadas para ilustrar as variáveis avaliadas, proporcionando uma visão abrangente do comportamento dos disjuntores em diferentes condições de operação.

4.1.1 Análise de Treinamento e Validação dos Modelos

A rede MLP desenvolvida possui uma única camada oculta com 100 neurônios, configurada com a função de ativação ReLU (*Rectified Linear Unit*). Na camada de saída, composta por 2 neurônios que representam as classes 1 e 1, foi utilizada a função de ativação softmax, que transforma as saídas em probabilidades associadas a cada classe. A taxa de aprendizado inicial foi definida como 0.001 e permaneceu constante ao longo do processo de treinamento. O algoritmo de otimização utilizado foi o Adam, que combina as vantagens do gradiente estocástico com adaptações de momento. O número máximo de épocas foi fixado em 300, e o critério de parada baseou-se na variação mínima na perda, com uma tolerância de 0.0001. A taxa de regularização foi definida como 0.0001, e um valor de momento de 0.9 foi aplicado para suavizar as atualizações dos pesos. O modelo também foi configurado para permitir parada antecipada caso não houvesse melhora significativa na perda em 10 iterações consecutivas.

O modelo AdaBoost foi configurado para usar o algoritmo SAMME.R, que ajusta os pesos das amostras com base na taxa de erro acumulada de cada estimador fraco. A taxa de aprendizado foi definida como 1.0, mantendo o impacto de cada estimador uniforme durante o processo de treinamento. O número máximo de estimadores foi definido como 500, indicando que o AdaBoost adicionará até 500 estimadores fracos para melhorar o desempenho do modelo final. O estimador base padrão utilizado foi uma árvore de decisão, e o parâmetro random state foi definido como 42 para garantir a reprodutibilidade dos resultados.

A avaliação do desempenho dos modelos foi conduzida com três cenários distintos: (1) sinal de corrente processado somente pela derivada, (2) sinal de corrente processado pelo banco de filtros, e (3) sinais de corrente e tensão, ambos processados pelo banco de filtros. Os três cenários foram avaliados com base em todos os parâmetros mencionados na Seção 3.4.1,

4.1.1.1 Cenário 1: Somente Derivada

Utilizando somente a derivada como filtro e conseqüentemente com apenas uma característica do dataset de treinamento a acurácia média ficou em torno de 82-83%, com desempenho similar para Precisão, F1 Score e Recall. Com relação ao índice "Área sob a Curva"(AUC-ROC) apresentou valores consistentes, entre 87% e 89%, o que sugere que processando apenas pela derivada, apesar de útil, não fornece informações suficientes para uma separação clara entre classes. Este cenário foi

o que apresentou métricas mais modestas em relação aos demais, seus valores podem ser visto em detalhes na Tabela 4.

Tabela 4 – Métricas de Desempenho dos Modelos (Somente Derivada)

Modelo	Acurácia	Precisão	F1 Score	Recall	Especificidade	AUC-ROC
AdaBoostClassifier	0.8233	0.8241	0.8233	0.8233	0.8093	0.8785
MLPClassifier	0.8244	0.8251	0.8244	0.8244	0.8279	0.8748

4.1.1.2 Cenário 2: Somente Sinal Corrente

O processamento de somente o sinal de corrente pelo banco de filtros resultou em um salto significativo nas métricas. Com 41 características do conjunto de dados, a Acurácia média atingiu cerca de 90-92%, com melhorias proporcionais em Precisão e F1 Score. A AUC-ROC aumentou para a faixa de 95-97%, indicando maior confiabilidade na distinção entre classes. Seus valores médios podem ser vistos na Tabela 5

Tabela 5 – Métricas de Desempenho dos Modelos (Somente Sinal Corrente)

Modelo	Acurácia	Precisão	F1 Score	Recall	Especificidade	AUC-ROC
AdaBoostClassifier	0.9104	0.9110	0.9104	0.9104	0.9238	0.9636
MLPClassifier	0.9269	0.9272	0.9268	0.9269	0.9333	0.9703

4.1.1.3 Cenário 3: Sinal Corrente e Tensão

A inclusão do sinal de tensão, processado pelo mesmo banco de filtros, forneceu o melhor desempenho global. Com 82 características do conjunto de dados, 41 da corrente e 41 da tensão, a Acurácia ultrapassou 95%, com valores semelhantes para Precisão, F1 Score e Recall. A AUC-ROC alcançou um patamar superior a 98%, demonstrando que a combinação dos dois sinais fornece informações complementares muito importantes para a eficácia dos modelos. Além disso, a Especificidade, que avalia a capacidade de prever corretamente as classes negativas, também apresentou aumento significativo, reforçando a superioridade deste conjunto de dados. Seus valores médios após a validação cruzada podem ser vistos na Tabela 6.

Tabela 6 – Métricas de Desempenho dos Modelos.

Modelo	Acurácia	Precisão	F1 Score	Recall	Especificidade	AUC-ROC
AdaBoost	0.9523	0.9524	0.9523	0.9523	0.9540	0.9857
MLP	0.9468	0.9470	0.9468	0.9468	0.9449	0.9842

4.1.1.4 Análise dos Cenários

Os resultados mostram que o pré-processamento dos sinais tem um impacto direto e significativo no desempenho dos modelos. A estratégia de combinar corrente e tensão processadas oferece o melhor desempenho, enquanto o uso apenas da derivada limita a eficácia dos modelos, o que pode ser analisada de forma resumida na Figura 30.

De forma detalhada os valores médios, desvios padrão, mínimos e máximos de acurácia em cada cenário estão apresentados na Tabela 4.1.1.4.

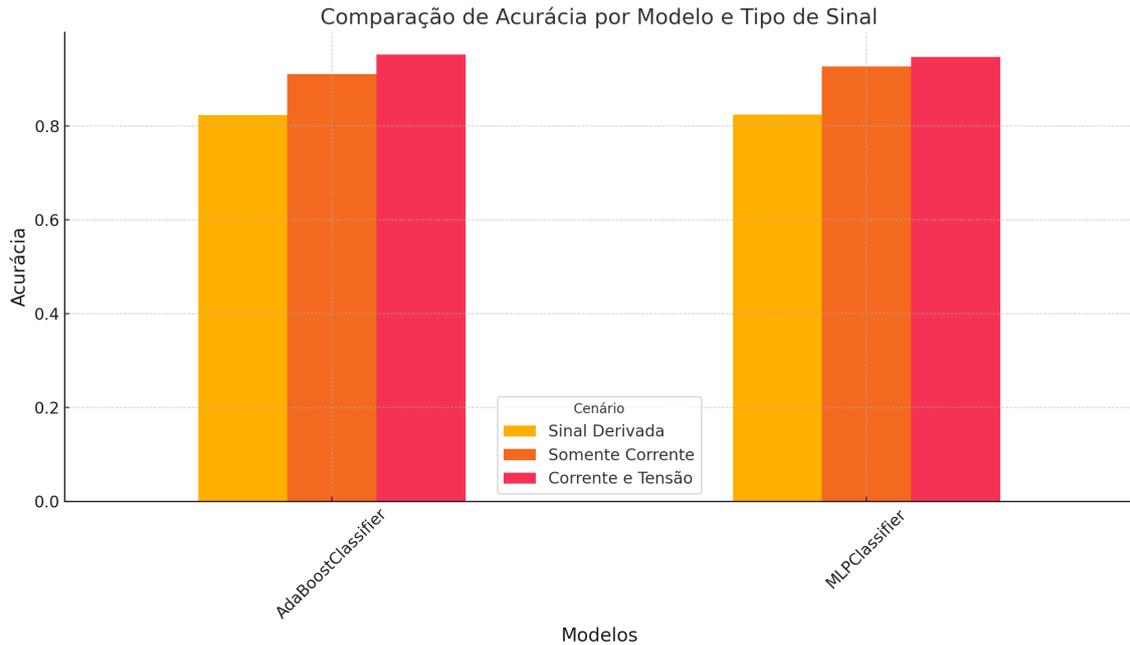


Figura 30 – Acurácia Entre Cenários

Cenário	Modelo	Média (%)	Desvio Padrão (%)	Mínimo (%)	Máximo (%)
Sinal Derivada	AdaBoostClassifier	82,33	0,60	81,60	83,40
Sinal Derivada	MLPClassifier	82,44	0,68	80,80	83,20
Somente Corrente	AdaBoostClassifier	91,04	1,22	89,02	92,77
Somente Corrente	MLPClassifier	92,69	1,70	90,46	95,95
Corrente e Tensão	AdaBoostClassifier	95,23	0,55	94,10	95,90
Corrente e Tensão	MLPClassifier	94,68	0,72	93,60	95,80

Tabela 7 – Resumo estatístico de acurácia por cenário e modelo.

A análise dos resultados abaixo permite identificar tendências claras de desempenho entre os cenários e modelos avaliados.

4.1.1.4.1 Cenário Sinal Derivada

Neste cenário, ambos os modelos apresentaram desempenho inferior. O *AdaBoostClassifier* alcançou média de 82,33% e o *MLPClassifier* apresentou média de 82,44%, com desvios padrão de 0,60% e 0,68%, respectivamente. Apesar de o *MLPClassifier* ter um desempenho ligeiramente superior, a diferença entre os modelos é pequena. Este cenário demonstrou ser o menos eficaz, possivelmente pela limitação das características no conjunto de dados.

4.1.1.4.2 Cenário Somente Corrente.

O desempenho neste cenário foi intermediário entre os dois anteriores. O *AdaBoostClassifier* apresentou média de 91,04%, com desvio padrão de 1,22%, enquanto o *MLPClassifier* teve média superior de 92,69%, mas com maior variabilidade (desvio padrão de 1,70%). Isso sugere que a corrente sozinha é mais informativa do que a derivada, mas a ausência das informações de tensão impacta negativamente os resultados quando comparados ao cenário *Corrente e Tensão*.

4.1.1.4.3 Cenário Corrente e Tensão

Este cenário apresentou os melhores resultados de acurácia para ambos os modelos. O *AdaBoostClassifier* obteve média de acurácia de 95,23% e desvio padrão de 0,55%, enquanto o *MLPClassifier* obteve média de 94,68% e desvio padrão de 0,72%. Esses resultados indicam que a combinação de corrente e tensão oferece maior discriminação para os modelos, além de garantir maior estabilidade nos valores obtidos pelo *AdaBoostClassifier*.

A partir dos resultados apresentados, observa-se que o cenário Corrente e Tensão oferece o melhor desempenho para ambos os modelos. O cenário Somente Corrente pode ser uma alternativa viável em contextos onde informações de tensão não estão disponíveis, apresentando um desempenho intermediário. Por outro lado, o cenário Sinal Derivada apresentou o pior desempenho, sugerindo que não é adequado para as tarefas avaliadas. Assim, foi definido o a avaliação entre os dois modelos utilizando o banco de filtro e combinando os sinais de corrente e tensão.

A Figura 31 ilustra o resultado do terceiro cenário onde podemos ver que o *AdaBoostClassifier* obteve melhor desempenho em todas as métricas de classificação. A acurácia média foi de 95,23%, enquanto o *MLPClassifier* alcançou 94,68%, indicando uma ligeira superioridade do *AdaBoost*. Essa tendência também foi observada nas outras métricas: o *AdaBoost* apresentou valores médios de 95,24% para Precisão, 95,23% para F1 Score, 95,20% para Recall, e 95,12% para Especificidade, todos superiores aos valores médios do *MLPClassifier* (94,70%, 94,68%, 94,65% e 94,31%, respectivamente). Essa diferença, embora pequena, destaca o potencial do *AdaBoost* para aplicações que requerem maior precisão e robustez. Adicionalmente, a métrica AUC-ROC foi ligeiramente superior no *AdaBoost* (98,54% contra 98,50% do *MLPClassifier*), indicando uma melhor capacidade do modelo em distinguir entre classes positivas e negativas em diferentes limiares.

O desvio padrão das métricas foi menor para o *AdaBoostClassifier*, sugerindo maior consistência no desempenho ao longo dos folds. Por exemplo, o desvio padrão da acurácia do *AdaBoost* foi de 0,54%, comparado a 0,72% do *MLP*. Essa estabilidade é ser relevante em cenários onde resultados previsíveis e confiáveis são essenciais.

O teste de Wilcoxon foi conduzido para comparar as métricas gerais de desempenho entre os modelos. O teste resultou em uma estatística de teste de 0.0 e um valor p de 0.03125, indicando uma diferença estatisticamente significativa entre o desempenho dos dois modelos ao nível de significância de 5%. Esse resultado sugere que os modelos *AdaBoost* e *MLP* não apresentam desempenhos compatíveis em todas as métricas avaliadas, com o *AdaBoost* demonstrando uma ligeira vantagem geral nesta análise.

A curva de aprendizado ilustra a estabilidade dos modelos em termos de acurácia. O eixo x em cada curva de aprendizado representa o tamanho do conjunto de treinamento, a fração ou número de amostras usadas para treinar o modelo em cada ponto. A linha de treinamento indica a acurácia do modelo no conjunto de treinamento para cada tamanho de treinamento, e a linha de validação mostra a acurácia do modelo em um conjunto de validação separado. Quando as linhas de treinamento e validação estão próximas e estáveis, o modelo alcança um bom equilíbrio, capturando padrões de forma eficaz sem overfitting aos dados de treinamento.

A curva do *AdaBoost*, mostrada na Figura 32, demonstra desde o início que a acurácia no conjunto de treinamento é extremamente alta. Essa linha permanece estável conforme o tamanho do conjunto de treinamento aumenta, indicando que o modelo está ajustando perfeitamente o conjunto de treinamento desde o início.

Inicialmente, a acurácia no conjunto de validação é significativamente inferior à acurácia de treinamento, sugerindo subajuste inicial e à medida que o tamanho do conjunto de treinamento cresce, a acurácia de validação aumenta rapidamente, convergindo para valores próximos à acurácia de

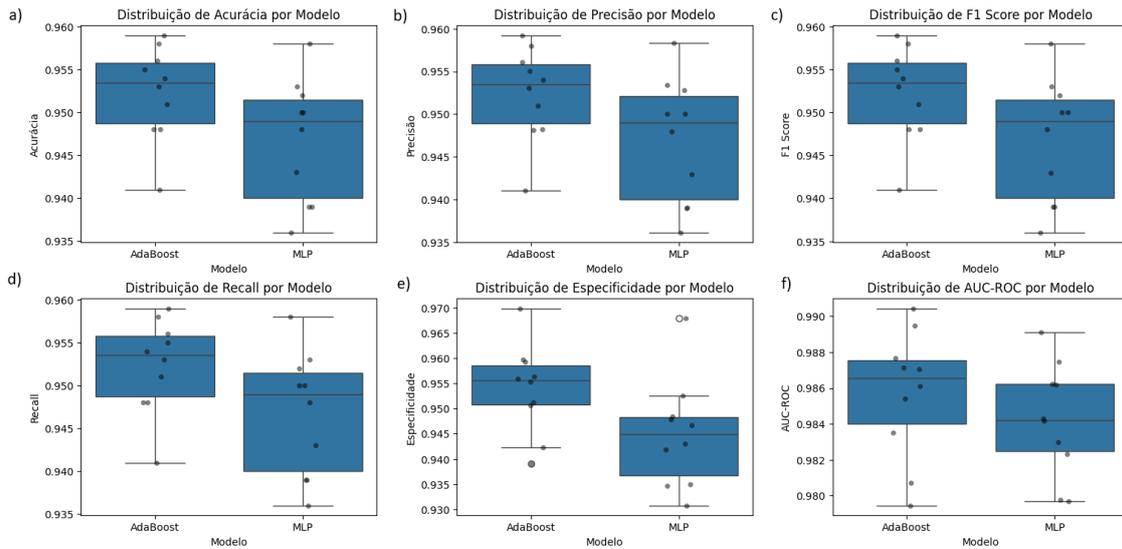


Figura 31 – Avaliação dos Modelos. a) Acurácia; b) Precisão; c) *F1 Score*; d) *Recall*; e) Especificidade; f) AUC-ROC

treinamento. Isso indica que o modelo se beneficia de mais dados para generalização. Para tamanhos maiores de conjunto de treinamento, por volta de 8000, o gap entre as curvas de treinamento e validação se reduz significativamente. Isso demonstra que o modelo está generalizando bem para novos dados com um volume maior de treinamento. Em síntese, o modelo sofre de sobreajuste inicial ao conjunto de treinamento (alta acurácia de treinamento), mas melhora gradualmente em termos de generalização com mais dados

A curva do MLP, mostrada na Figura 33, semelhante ao AdaBoost, a acurácia no conjunto de treinamento começa alta. Com o aumento do tamanho do conjunto de treinamento, a acurácia de treinamento diminui levemente, o que pode indicar a transição para um modelo menos sobreajustado. Inicialmente, a acurácia no conjunto de validação é baixa, no entanto, há um crescimento constante da acurácia de validação com o aumento do tamanho do conjunto de treinamento, convergindo gradualmente para a acurácia de treinamento, mas de forma mais lenta em comparação ao AdaBoost. O gap entre as curvas de treinamento e validação é maior para o MLP, indicando que o modelo apresenta maior dificuldade em generalizar para novos dados, especialmente com conjuntos de treinamento menores. Portanto, o modelo enfrenta maior dificuldade para generalizar em conjuntos de treinamento pequenos, mas melhora substancialmente com o aumento dos dados.

Para a sensibilidade ao tamanho do conjunto de treinamento, o AdaBoost demonstra melhor capacidade de generalização com conjuntos de treinamento menores, enquanto o MLP se beneficia mais significativamente de conjuntos maiores. Sobre a estabilidade o AdaBoost apresenta curvas mais estáveis e uma convergência mais rápida, sugerindo que o modelo é menos sensível a flutuações no tamanho do conjunto de dados. O MLP, por outro lado, requer um conjunto de treinamento maior para alcançar desempenho competitivo.

Assim, pelos resultados das avaliações o modelo AdaBoost foi selecionado para a identificação do contato principal. A Figura 34 mostra os resultados das identificações automáticas, onde a linha preta representa o contato de pré-inserção e o vermelho indica o contato principal. O sinal "a" tem bastante ruído antes do pré contato o que é um dificultador para identificar este o contato resistivo e posteriormente a definição de janelas, mas a solução proposta conseguiu eliminar estes ruídos e identificar com sucesso os dois pontos. O mesmo acontece com o sinal "b" que ainda

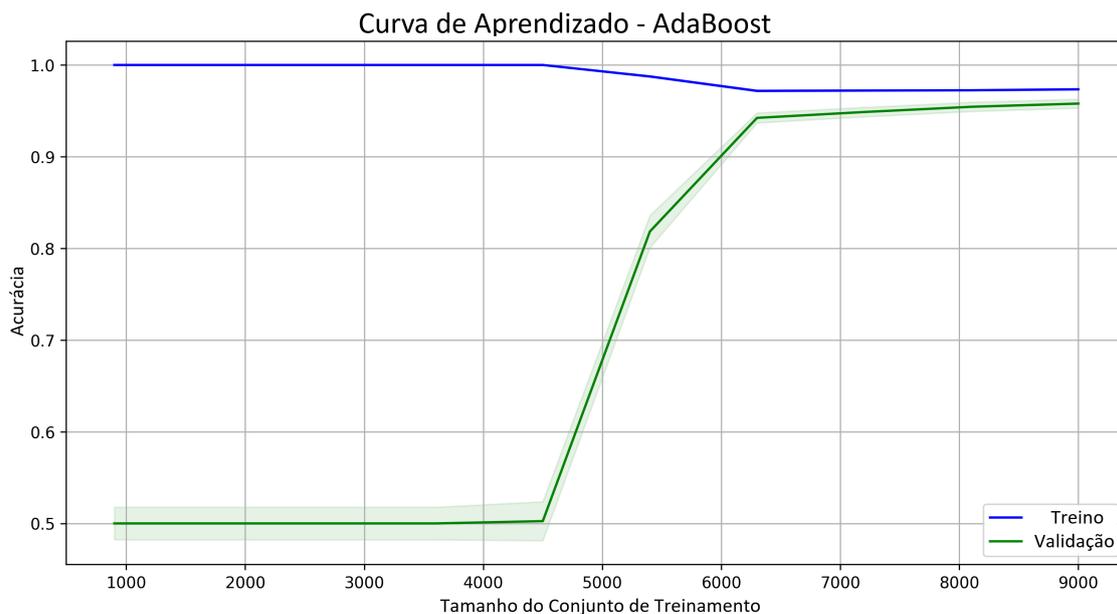


Figura 32 – Curva de Aprendizado do AdaBoost.

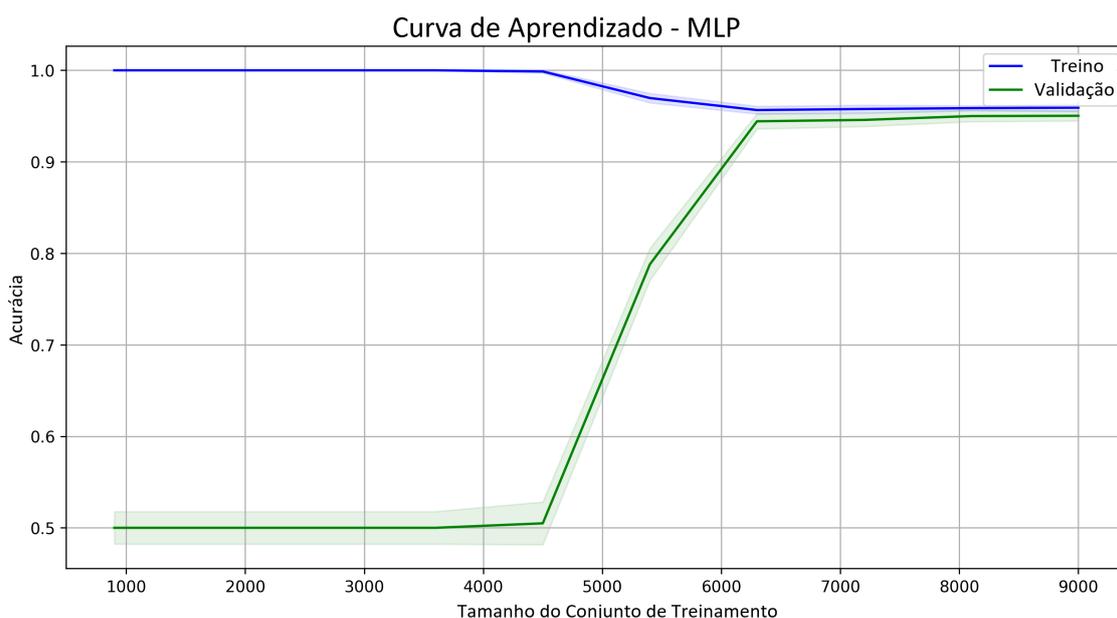


Figura 33 – Curva de Aprendizado do MLP.

contem um ruído considerável antes do contato principal. O sinal "c" tem grandes transitórios causado pela entrada do contato principal das outras fases, mas mesmo assim o contato principal foi corretamente identificado. Por último o sinal "d" contém ruídos por todo o sinal, o que muito dificulta a identificação do ponto principal, até mesmo manualmente, porém também foi identificado corretamente. A Figura 35 mostra um tipo de sinal que a solução construída costuma errar, repare que um pouco antes do real contato principal acontece um ruído que não abaixa de forma rápida, o que forma uma pequena onda que tem uma forma muito semelhante quando o contato principal acontece, o sinal "a" da Figura 34 contém um ruído semelhante, mas o alto transitório que acontece

Ano	Quantidade Sinais
2010	5766
2011	7191
2019	1143
2020	285

Tabela 8 – Distribuição dos Sinais por Ano

após o contato principal ajudou na diferenciação.

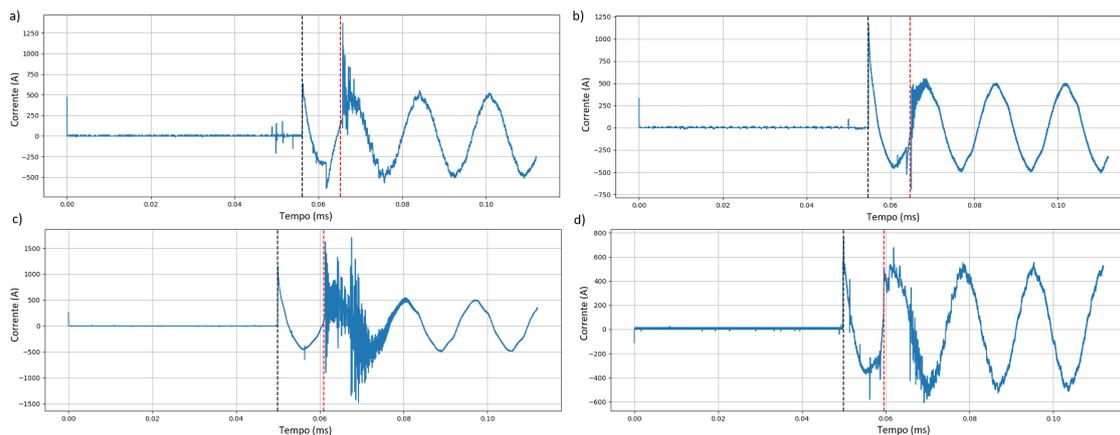


Figura 34 – Sinais Marcados Automaticamente. Linha Preta: Contato resistivo; Linha Vermelha: Contato principal marcado corretamente.

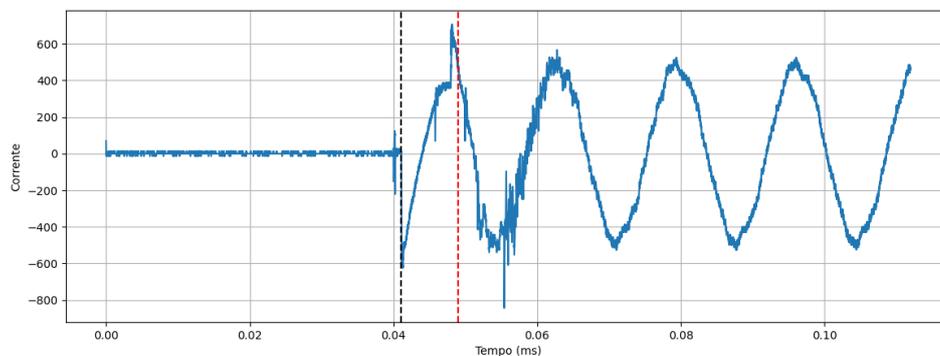


Figura 35 – Sinal Marcado Automaticamente de Forma Errônea. Linha Preta: Contato resistivo; Linha Vermelha: Contato principal marcado erroneamente.

4.1.2 Análise Estatística dos Tempos dos Disjuntores

Foram analisados 14.385 sinais obtidos de uma subestação real, separadas por períodos como mostrado na Tabela 8. Foram obtidos o tempo de pré-inserção, tempo do contato principal, tempo de intervalo entre os contatos, a corrente de inrush, e o tempo de atraso para o zero. Todos estes tempos foram obtidos usando as equações explicadas no capítulo 3.

A correlação entre os dados ilustrada na Figura 36 nos mostra que existe uma relação linear muito forte entre o tempo de pré-contato e o tempo de contato principal (Valor de correlação próximo

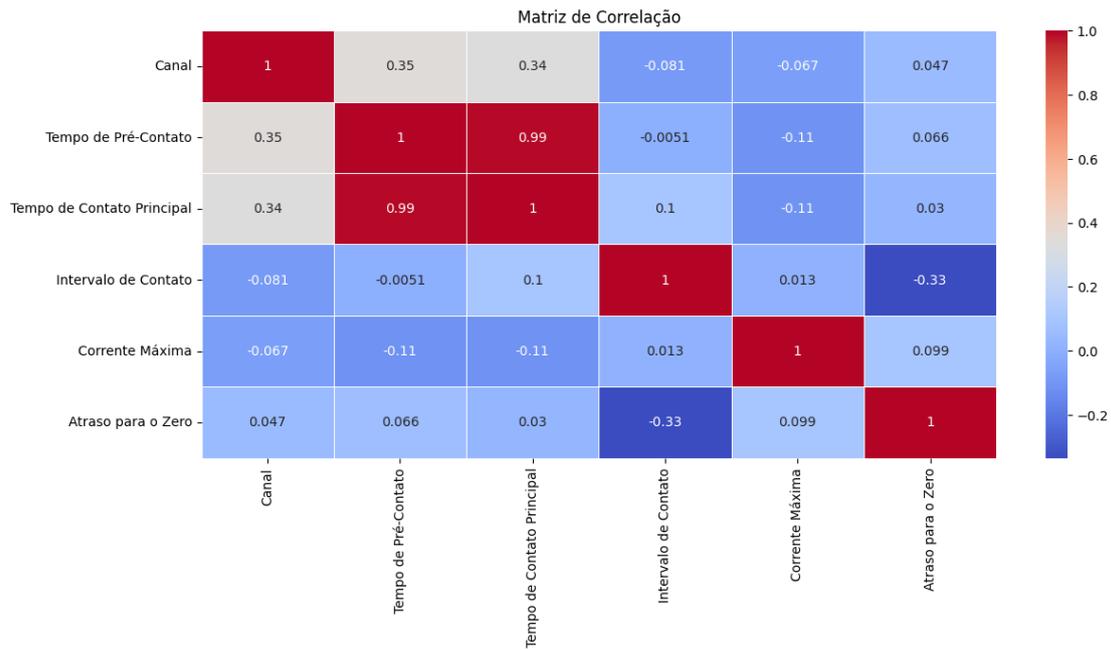


Figura 36 – Correlação dos Dados

de 0.99) isso indica que alterações em uma destas variáveis refletem diretamente no tempo da outra. Porém os outros valores de correlação ficaram muito baixos mostrando pouco ou quase nenhuma relação direta nesta amostra de dados analisada. .

O intervalo entre os contatos, que de acordo com o fabricante deve permanecer em torno de 10 ms, esteve dentro da faixa esperada na maioria dos casos(FANTOZZI, 1995; ZONDI; BOKORO; PAUL, 2015). No entanto, um número significativo de casos apresentou valores entre 9 ms e 10 ms. Esses valores podem ser vistos na Figura 37.

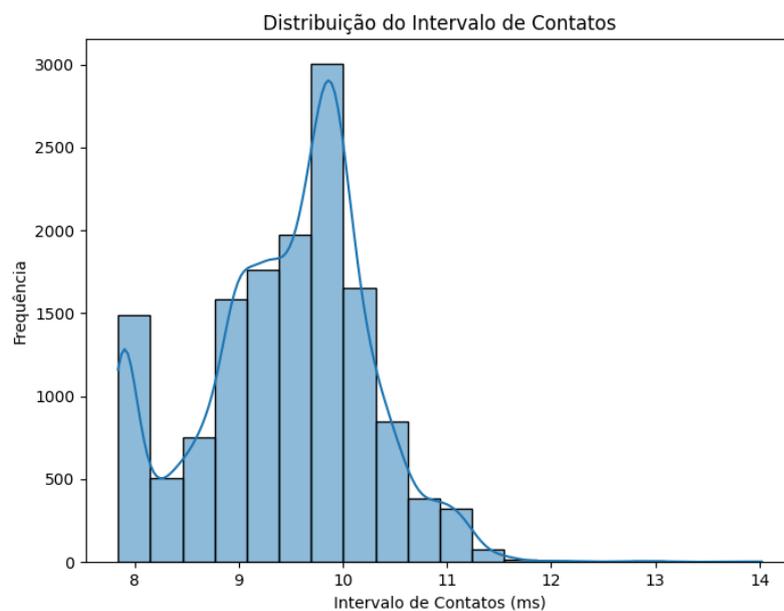


Figura 37 – Distribuição do Intervalo entre Contatos.

Ao analisar a corrente de inrush, pode-se observar na Figura 38 que, nos dados mais recentes, esse valor máximo foi significativamente reduzido, possivelmente indicando algum tipo de melhoria no equipamento ou mecanismo de controle para prevenir correntes de pico nos disjuntores.

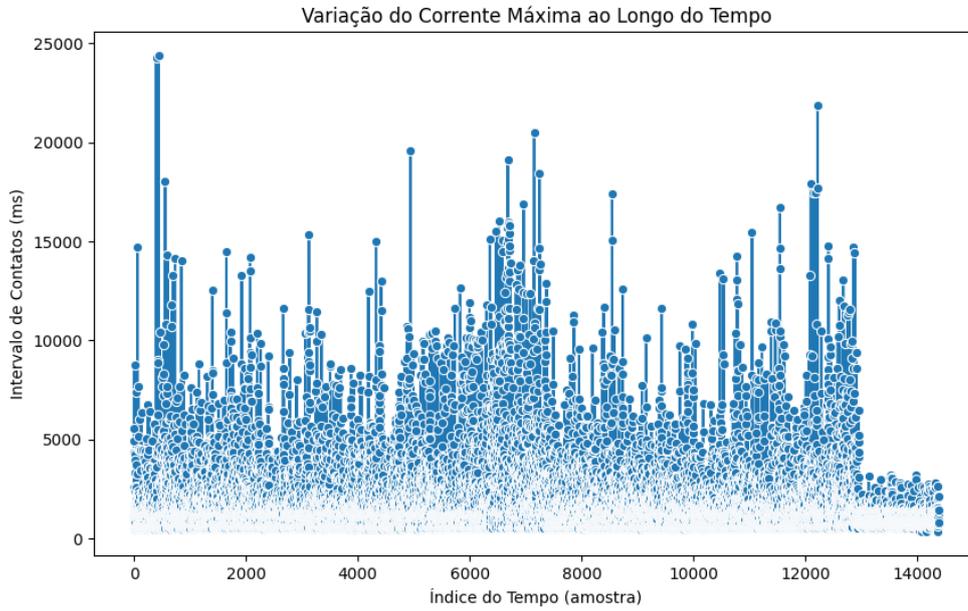


Figura 38 – Corrente de Inrush ao Longo dos Anos.

Outro ponto a destacar é a corrente de inrush em relação às fases, mostrado na Figura 39, onde a primeira fase apresenta valores mais altos do que as outras fases, e a última fase apresenta valores mais baixos.

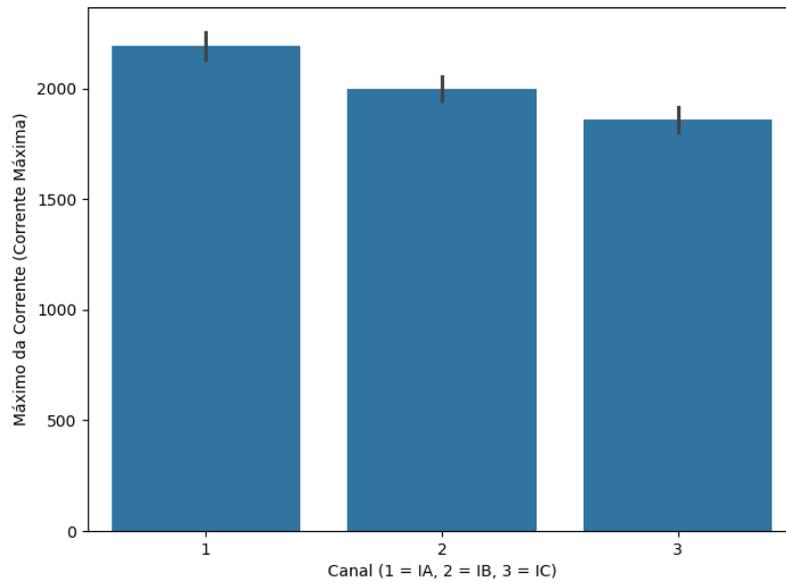


Figura 39 – Corrente de Inrush e Fases.

Ao analisar o intervalo entre o contato principal e o cruzamento por zero da corrente, pode-se

observar na Figura 40 que o sincronismo está correto na maioria dos dados, sendo os outliers um ponto de atenção.

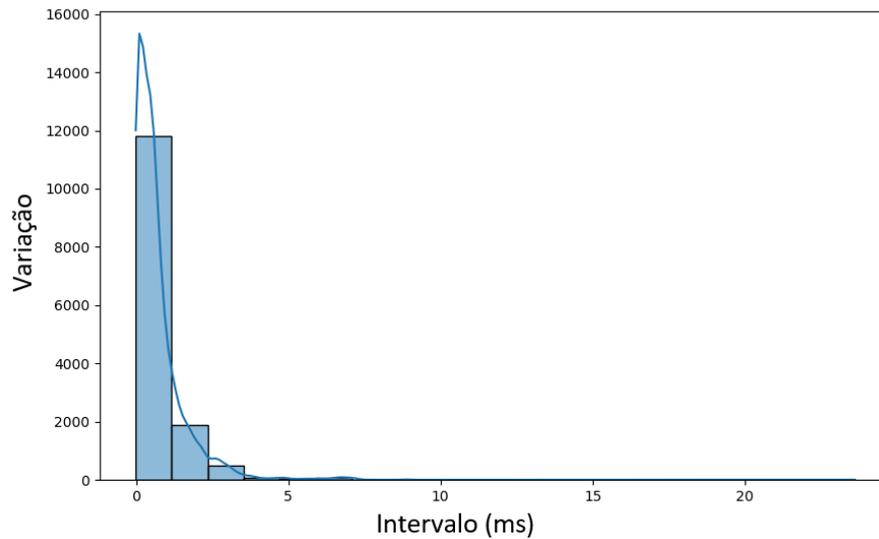


Figura 40 – Intervalo entre o Contato Principal e o Cruzamento por Zero da Corrente.

Agrupando por canal, observa-se que a fase B está mais fora de sincronismo do que as outras fases, como evidenciado na Figura 41.

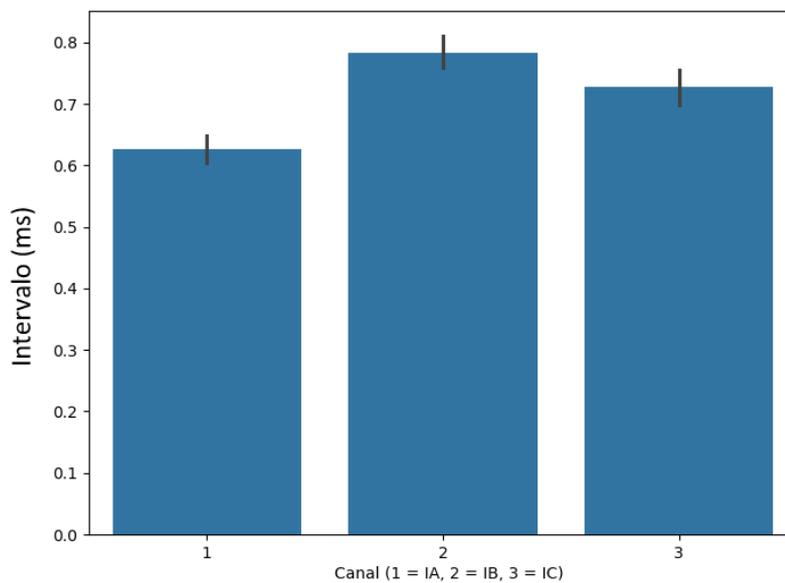


Figura 41 – Intervalo entre Contato Principal e Cruzamento por Zero das Fases.

O sincronismo entre as fases é ilustrado na Figura 42, onde um valor médio evidente pode ser observado, indicando que o sincronismo geralmente está dentro de níveis saudáveis. Os outliers destacam um ponto de atenção que pode indicar potenciais problemas.

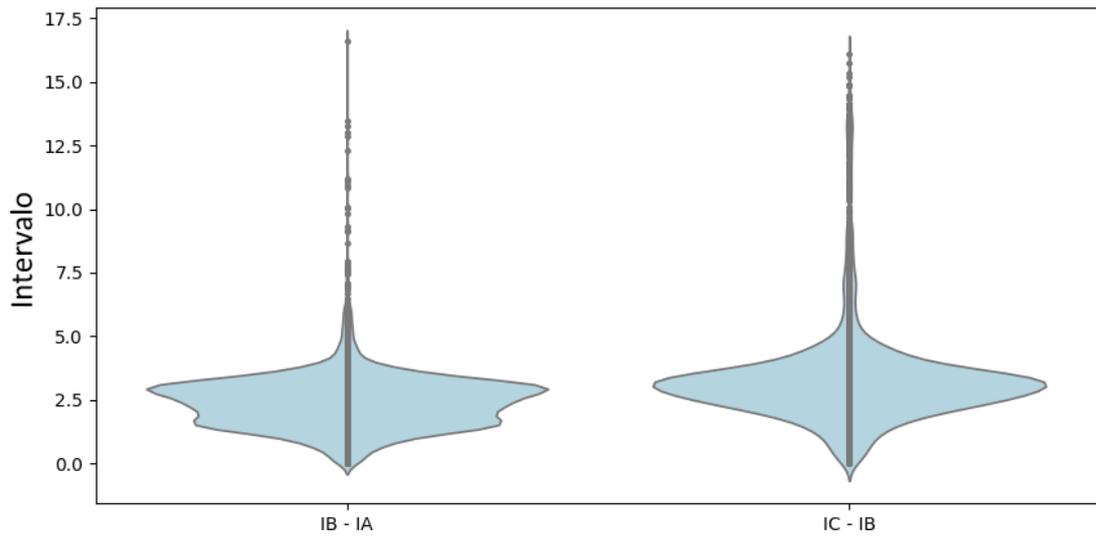


Figura 42 – Sincronismo entre Fases.

5 Conclusão

Este trabalho abordou um desafio importante na área disjuntores de alta tensão: a identificação precisa dos pontos de pré-inserção e contato principal em manobras de fechamento. A complexidade deste problema reside na necessidade de lidar com sinais ruidosos e ambientes de operação que podem comprometer a precisão das análises convencionais. O objetivo foi desenvolver uma abordagem que possa ser usada como subsídio para tomadas de decisões em relação a manutenção preditiva, garantindo maior confiabilidade e eficiência na operação deste aparelhos.

Para enfrentar esse desafio, foi construído uma solução que combina processamento de sinais com diversas técnicas de filtragem e modelos de inteligência artificial. Dados de corrente e tensão coletados em ambientes reais que sofrem de grandes ruídos e interferências foram processados e os resultados obtidos mostraram que o método proposto alcançou uma acurácia superior a 93% na identificação dos instantes de entrada em operação do contato principal, comprovando sua eficácia mesmo em cenários com altos níveis de ruído.

A principal contribuição deste trabalho é a demonstração de que a integração de métodos de processamento de sinais e aprendizado de máquina pode ser aplicada com sucesso para melhorar a identificação de características em sinais de corrente e tensão em disjuntores de alta tensão. Essa metodologia também pode ser estendida e adaptada para diferentes tipos de sinais extraídos dos disjuntores, como a vibração.

5.0.1 Publicações Relacionadas

Os principais resultados desta dissertação foram publicados no artigo (LIZ et al., 2025), no qual são detalhados a metodologia, a abordagem baseada em inteligência artificial e processamento de sinais, bem como a avaliação do desempenho dos modelos propostos na identificação dos instantes de pré-inserção e contato principal em disjuntores de alta tensão SF₆.

5.0.2 Trabalhos Futuros

Como trabalhos futuros, propõe-se explorar o uso de arquiteturas de redes neurais mais complexas, como redes neurais convolucionais (CNNs), para aprimorar ainda mais a precisão e a capacidade de generalização dos modelos na identificação dos instantes de pré-inserção e contato principal. Além disso, a incorporação da solução em sistemas de monitoramento em tempo real pode representar uma expansão promissora, permitindo respostas imediatas a variações críticas, detecção precoce de potenciais falhas e ajuste dinâmico dos controladores de manobra.

Outra linha de investigação consiste na integração de novos sinais para complementar a análise das condições dos disjuntores. Entre os sinais que podem ser utilizados para extrair características adicionais da saúde dos equipamentos, destacam-se:

- Corrente das bobinas de comando: A análise das correntes das bobinas de fechamento e abertura pode fornecer informações sobre a condição do acionamento mecânico do disjuntor, permitindo a contabilização precisa dos tempos de atuação do equipamento e a detecção de possíveis anomalias no mecanismo de acionamento.
- Monitoramento do deslocamento dos contatos móveis: A medição do deslocamento dos contatos durante as manobras permite estimar sua posição física ao longo do tempo. Esses

dados podem ser utilizados para validar correlações com as análises baseadas em sinais elétricos e reforçar a confiabilidade dos diagnósticos.

- Monitoramento dos sinais de vibração mecânica: A captura e o processamento digital dos sinais de vibração durante as operações de abertura e fechamento dos disjuntores podem fornecer informações correlatas à condição mecânica do equipamento, identificando desgastes e possíveis falhas estruturais.
- Monitoramento dos sinais dos motores de acionamento: A avaliação da corrente e tensão dos motores responsáveis pela operação do disjuntor pode indicar alterações no comportamento da carga, servindo como um indicador de degradação do mecanismo do equipamento.
- Monitoramento do gás SF₆: A análise de parâmetros como ponto de orvalho, pressão, temperatura e densidade do gás SF₆ pode fornecer informações sobre sua degradação e auxiliar na detecção de falhas relacionadas à isolação do disjuntor.

A incorporação desses sinais ao modelo proposto pode resultar em uma abordagem ainda mais robusta para o monitoramento da saúde dos disjuntores, contribuindo para a melhoria da manutenção preditiva e para a confiabilidade do sistema elétrico como um todo.

Referências

- Agência Nacional de Energia Elétrica (ANEEL). *Regras dos Serviços de Transmissão de Energia Elétrica: Módulo 4 – Prestação dos Serviços*. [S.l.], 2023. Disponível em: <https://www2.aneel.gov.br/cedoc/aren20221020_2_2.pdf>. Acesso em: 20 jan. 2025. Citado na página 13.
- AN, T.-K.; KIM, M.-H. A new diverse adaboost classifier. In: IEEE. *2010 International conference on artificial intelligence and computational intelligence*. [S.l.], 2010. v. 1, p. 359–363. Citado 2 vezes nas páginas 37 e 49.
- ANGUITA, D. et al. The 'k'in k-fold cross validation. In: *ESANN*. [S.l.: s.n.], 2012. v. 102, p. 441–446. Citado 2 vezes nas páginas 41 e 42.
- CAUMO, L. *Application and Calculation of the Derivative of Industrial Process Signals*. Dissertação (Master's dissertation) — Federal University of Rio Grande do Sul, Porto Alegre, Brasil, março 2006. Citado 4 vezes nas páginas 32, 33, 34 e 47.
- CHAPRA, S. C.; CANALE, R. P. *Métodos Numéricos para Engenharia*. 7^a. ed. [S.l.]: McGraw Hill Brasil, 2016. Citado na página 22.
- DELASHMIT, W. H.; MANRY, M. T. et al. Recent developments in multilayer perceptron neural networks. In: *Proceedings of the seventh annual memphis area engineering and science conference, MAESC*. [S.l.: s.n.], 2005. v. 7, p. 33. Citado 3 vezes nas páginas 37, 38 e 49.
- FANTOZZI, G. V. Selecting a capacitor-switching overvoltage control method effective in preventing nuisance tripping of adjustable-speed drives. In: *EEI ES&E Committee Meeting, Clearwater Beach, Florida*. [S.l.: s.n.], 1995. Citado 2 vezes nas páginas 46 e 59.
- FELDMAN, M. Hilbert transform in vibration analysis. *Mechanical Systems and Signal Processing*, v. 25, n. 3, p. 735–802, 2011. ISSN 0888-3270. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0888327010002542>>. Citado 4 vezes nas páginas 8, 30, 31 e 47.
- FERNÁNDEZ, A. et al. Smote for learning from imbalanced data: progress and challenges, marking the 15-year anniversary. *Journal of artificial intelligence research*, v. 61, p. 863–905, 2018. Citado 3 vezes nas páginas 39, 40 e 49.
- FLACH, P. Performance evaluation in machine learning: The good, the bad, the ugly, and the way forward. *Proceedings of the AAAI Conference on Artificial Intelligence*, v. 33, n. 01, p. 9808–9814, Jul. 2019. Disponível em: <<https://ojs.aaai.org/index.php/AAAI/article/view/5055>>. Citado 3 vezes nas páginas 40, 41 e 42.
- FOURIER, J. *La Théorie Analytique de la Chaleur*. Paris, France: Chez Firmin Didot, père et fils, 1822. Citado 2 vezes nas páginas 27 e 47.
- GAO, W. et al. A newly designed diagnostic method for mechanical faults of high-voltage circuit breakers via ssae and ielm. *IEEE Transactions on Instrumentation and Measurement*, v. 70, p. 1–13, 2021. Citado na página 12.
- GAO, W. et al. Mechanical faults diagnosis of high-voltage circuit breaker via hybrid features and integrated extreme learning machine. *IEEE Access*, v. 7, p. 60091–60103, 2019. Citado na página 19.
- GARBELOTTI, M. V. *Sistema digital para manobra sincronizada de disjuntores - estudo e especificação funcional*. Tese (Dissertação (Mestrado em Sistemas de Potência)) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2006. Acesso em: 2024-11-25. Disponível em: <<https://doi.org/10.11606/D.3.2006.tde-05092006-133417>>. Citado 2 vezes nas páginas 12 e 13.

GEORGE, G. et al. A survey on various median filtering techniques for removal of impulse noise from digital image. In: *2018 Conference on Emerging Devices and Smart Systems (ICEDSS)*. [S.l.: s.n.], 2018. p. 235–238. Citado 2 vezes nas páginas 25 e 47.

GOLDSWORTHY, D. et al. Controlled switching of hvac circuit breakers: Application examples and benefits. In: *2008 61st Annual Conference for Protective Relay Engineers*. [S.l.: s.n.], 2008. p. 520–535. Citado 2 vezes nas páginas 8 e 17.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 4. ed. Harlow, Essex, England: Pearson Education Limited, 2018. ISBN 978-1-292-22304-9. Disponível em: <<https://www.pearsonglobaleditions.com>>. Citado 5 vezes nas páginas 27, 28, 32, 33 e 47.

HAIDER, I. et al. Feature extraction for identification of extension and flexion movement of wrist using emg signals. In: . [S.l.: s.n.], 2015. Citado 2 vezes nas páginas 8 e 34.

HAIXIANG, G. et al. Learning from class-imbalanced data: Review of methods and applications. *Expert Systems with Applications*, v. 73, p. 220–239, 2017. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417416307175>>. Citado 3 vezes nas páginas 38, 39 e 40.

HOSSEINI, M. et al. Current-based trip coil analysis of circuit breakers for fault diagnosis. In: *2018 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)*. [S.l.: s.n.], 2018. p. 1–6. Citado na página 19.

HU, W. et al. A general model, estimation, and procedure for modeling recurrent failure process of high-voltage circuit breakers considering multivariate impacts. *Reliability Engineering & System Safety*, v. 220, p. 108276, 2022. ISSN 0951-8320. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0951832021007493>>. Citado na página 12.

ITO, H. (Ed.). *Switching Equipment*. 1. ed. Springer Cham, 2019. XL, 584 p. (CIGRE Green Books). ISSN 2367-2625. ISBN 978-3-319-72537-6. Disponível em: <<https://doi.org/10.1007/978-3-319-72538-3>>. Citado 4 vezes nas páginas 19, 20, 21 e 22.

JABBAR, H.; KHAN, R. Z. Methods to avoid over-fitting and under-fitting in supervised machine learning (comparative study). *Computer Science, Communication and Instrumentation Devices*, Res. Publ Singapore, v. 70, n. 10.3850, p. 978–981, 2015. Citado na página 42.

JI, T. et al. Multi-mapping fault diagnosis of high voltage circuit breaker based on mathematical morphology and wavelet entropy. *CSEE Journal of Power and Energy Systems*, v. 5, n. 1, p. 130–138, 2019. Citado 2 vezes nas páginas 12 e 19.

KEZUNOVIC, M. et al. Automated monitoring and analysis of circuit breaker operation. *IEEE Transactions on Power Delivery*, v. 20, n. 3, p. 1910–1918, 2005. Citado na página 12.

LAI, M.-J. Popular wavelet families and filters and their use. In: _____. *Computational Complexity: Theory, Techniques, and Applications*. New York, NY: Springer New York, 2012. p. 2168–2225. ISBN 978-1-4614-1800-9. Disponível em: <https://doi.org/10.1007/978-1-4614-1800-9_137>. Citado 2 vezes nas páginas 32 e 33.

LIU, A. et al. A novel control strategy of phase-controlled switching technology for vacuum circuit breaker. *IEEE Access*, v. 10, p. 43571–43582, 2022. Citado 2 vezes nas páginas 8 e 18.

LIZ, P. A. V. D. et al. Ai-driven signal processing for sf6 circuit breaker performance optimization. *Energies*, v. 18, n. 2, 2025. ISSN 1996-1073. Disponível em: <<https://www.mdpi.com/1996-1073/18/2/377>>. Citado na página 63.

LUZ, G. S. et al. Adjustment of synchronizers in the closing maneuver of the capacitor banks of the tijuco preto substation. *XIII 401 Eriac-Ibero-American Regional Meeting of CIGRÉ, Puerto Iguazú, Argentina, Maio de 2009*, 2009. Citado 3 vezes nas páginas 8, 12 e 16.

MADHU, A.; KUMARASWAMY, S. Atresnet: Residual atrous cnn with multi-scale feature representation for low complexity acoustic scene classification. *Circuits, Systems, and Signal Processing*, v. 41, 07 2022. Citado 2 vezes nas páginas 8 e 34.

- MICHAELIS. *Dicionário Brasileiro da Língua Portuguesa*. 2015. Acesso em: 10 jul. 2024. Disponível em: <<https://michaelis.uol.com.br>>. Citado 2 vezes nas páginas 22 e 24.
- POPESCU, M.-C. et al. Multilayer perceptron and neural networks. *WSEAS Transactions on Circuits and Systems*, World Scientific and Engineering Academy and Society (WSEAS) Stevens Point . . . , v. 8, n. 7, p. 579–588, 2009. Citado 4 vezes nas páginas 8, 37, 38 e 49.
- RAHMAN, M. S.; HAQUE, M. A. Introduction to a novel wavelet. In: *2012 International Conference on Informatics, Electronics Vision (ICIEV)*. [S.l.: s.n.], 2012. p. 628–631. Citado 2 vezes nas páginas 32 e 33.
- RAJU, V. G. et al. Study the influence of normalization/transformation process on the accuracy of supervised classification. In: *IEEE. 2020 Third International Conference on Smart Systems and Inventive Technology (ICSSIT)*. [S.l.], 2020. p. 729–735. Citado na página 49.
- RATTAN DANIEL D. PENRICE, D. A. S. P. Artificial intelligence and machine learning: What you always wanted to know but were afraid to ask. *Gastro Hep Advances*, v. 1, p. 70–78, 2022. Citado 2 vezes nas páginas 8 e 36.
- RAZI-KAZEMI, A. Applicability of auxiliary contacts in circuit breaker online condition assessment. *Electric Power Systems Research*, v. 128, p. 53–59, 2015. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779615001972>>. Citado na página 19.
- RAZI-KAZEMI, A. A.; NIAYESH, K. Condition monitoring of high voltage circuit breakers: Past to future. *IEEE Transactions on Power Delivery*, v. 36, n. 2, p. 740–750, 2021. Citado na página 19.
- RAZI-KAZEMI, A. A. et al. Circuit-breaker automated failure tracking based on coil current signature. *IEEE Transactions on Power Delivery*, v. 29, n. 1, p. 283–290, 2014. Citado na página 19.
- RODRIGUES, M. da S. *Dicionário Brasileiro de Estatística*. 2. ed. Rio de Janeiro: IBGE, 1970. Disponível em: <<http://www.ipeadata.gov.br/doc/IBGE%20DICIONARIO%20DE%20ESTATISTICA.pdf>>. Citado 2 vezes nas páginas 24 e 25.
- SALINAS, M. et al. A computational fractional signal derivative method. *Modelling and Simulation in Engineering*, v. 2018, n. 1, p. 7280306, 2018. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1155/2018/7280306>>. Citado 3 vezes nas páginas 22, 24 e 47.
- SAVITZKY, A.; GOLAY, M. J. E. Smoothing and differentiation of data by simplified least squares procedures. *Analytical Chemistry*, American Chemical Society, v. 36, n. 8, p. 1627–1639, jul. 1964. ISSN 0003-2700. Disponível em: <<https://doi.org/10.1021/ac60214a047>>. Citado 2 vezes nas páginas 25 e 47.
- SCHAFER, R. W. What is a savitzky-golay filter? [lecture notes]. *IEEE Signal Processing Magazine*, v. 28, n. 4, p. 111–117, 2011. Citado 2 vezes nas páginas 25 e 27.
- SCHAPIRE, R. E. Explaining adaboost. In: _____. *Empirical Inference: Festschrift in Honor of Vladimir N. Vapnik*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 37–52. ISBN 978-3-642-41136-6. Disponível em: <https://doi.org/10.1007/978-3-642-41136-6_5>. Citado 2 vezes nas páginas 37 e 49.
- SHAN, Z. et al. A novel adaptive moving average method for signal denoising in strong noise background. *European Physical Journal Plus*, v. 137, p. 50, 2022. Disponível em: <<https://doi-org.ez38.periodicos.capes.gov.br/10.1140/epjp/s13360-021-02279-x>>. Citado 2 vezes nas páginas 24 e 47.
- SHIVAMURTI, M.; NARASIMHAN, S. V. Analytic discrete cosine harmonic wavelet transform(adchwt) and its application to signal/image denoising. In: *2010 International Conference on Signal Processing and Communications (SPCOM)*. [S.l.: s.n.], 2010. p. 1–5. Citado na página 29.

SHOURAN, M.; ELGAMLI, E. Design and implementation of butterworth filter. *International Journal of Innovative Research in Science Engineering and Technology*, v. 9, p. 7975, 09 2020. Citado 2 vezes nas páginas 32 e 47.

SIMON, G. J.; ALIFERIS, C. (Ed.). *Artificial Intelligence and Machine Learning in Health Care and Medical Sciences: Best practices and pitfalls*. 1. ed. Cham, Switzerland: Springer Cham, 2024. XXVI, 810 p. (Health Informatics). Published: 05 March 2024, eBook published: 04 March 2024. The Editor(s) and The Author(s) 2024. ISSN 1431-1917. ISBN 978-3-031-39354-9. Disponível em: <<https://doi.org/10.1007/978-3-031-39355-6>>. Citado 2 vezes nas páginas 36 e 41.

SUN, R. et al. A study of synchronous breaker switching with preinsertion resistor for capacitors banks. *IEEE Transactions on Power Delivery*, v. 33, n. 2, p. 821–829, 2018. Citado 3 vezes nas páginas 8, 17 e 18.

VLUYMANS, S. Learning from imbalanced data. In: _____. [S.l.: s.n.], 2019. p. 81–110. ISBN 978-3-030-04662-0. Citado 2 vezes nas páginas 38 e 39.

WYNER, A. J. et al. Explaining the success of adaboost and random forests as interpolating classifiers. *Journal of Machine Learning Research*, v. 18, n. 48, p. 1–33, 2017. Citado 2 vezes nas páginas 37 e 49.

YACOUBY, R.; AXMAN, D. Probabilistic extension of precision, recall, and f1 score for more thorough evaluation of classification models. In: EGER, S. et al. (Ed.). *Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems*. Online: Association for Computational Linguistics, 2020. p. 79–91. Disponível em: <<https://aclanthology.org/2020.eval4nlp-1.9>>. Citado 2 vezes nas páginas 40 e 41.

YING, X. An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, IOP Publishing, v. 1168, n. 2, p. 022022, feb 2019. Disponível em: <<https://dx.doi.org/10.1088/1742-6596/1168/2/022022>>. Citado 3 vezes nas páginas 36, 41 e 42.

ZHANG, J. et al. Fault diagnosis of high voltage circuit breaker based on multi-sensor information fusion with training weights. *Measurement*, v. 192, p. 110894, 2022. ISSN 0263-2241. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0263224122001786>>. Citado na página 12.

ZHANG, X.; LIU, C.-A. Model averaging prediction by k-fold cross-validation. *Journal of Econometrics*, Elsevier, v. 235, n. 1, p. 280–301, 2023. Citado 2 vezes nas páginas 41 e 50.

ZHOU, J.; CHEN, P. Generalized discrete cosine transform. In: *2009 Pacific-Asia Conference on Circuits, Communications and Systems*. [S.l.: s.n.], 2009. p. 449–452. Citado 2 vezes nas páginas 29 e 47.

ZHOU, Y.; XUE, Y.; ZHOU, K. Failure analysis of arc ablated tungsten-copper electrical contacts. *Vacuum*, v. 164, p. 390–395, 2019. ISSN 0042-207X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0042207X19304154>>. Citado na página 19.

ZONDI, S.; BOKORO, P.; PAUL, B. Emtf-based analysis of pre-insertion resistor and point on wave switching methodology. In: IEEE. *AFRICON 2015*. [S.l.], 2015. p. 1–5. Citado 6 vezes nas páginas 19, 20, 21, 22, 46 e 59.