

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Matheus Clementino de Mella

**Determinação da Contribuição Harmônica em Pontos de
Acoplamento Comum de Microrredes: Uma Abordagem
Baseada em Aprendizado de Máquina**

São Carlos – SP
2025

Matheus Clementino de Mella

**Determinação da Contribuição Harmônica em Pontos de
Acoplamento Comum de Microrredes: Uma Abordagem
Baseada em Aprendizado de Máquina**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de Concentração: Sistemas Elétricos e Eletrônicos

Orientador: Prof. Dr. Ricardo Augusto Souza Fernandes

São Carlos – SP

2025



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Engenharia Elétrica

Folha de Aprovação

Defesa de Dissertação de Mestrado do candidato Matheus Clementino de Mella, realizada em 19/02/2025.

Comissão Julgadora:

Prof. Dr. Ricardo Augusto Souza Fernandes (UFSCar)

Prof. Dr. Mário Oleskovicz (USP)

Prof. Dr. Pedro Henrique Aquino Barra (UFU)

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia Elétrica.

Aos meus pais.

AGRADECIMENTOS

Agradeço primeiramente à Deus pelo dom da vida, pela saúde e pelas oportunidades oferecidas. Trabalhar e estudar ao mesmo tempo não tem sido fácil, porém Ele sempre esteve ao meu lado fornecendo coragem e energia para continuar essa jornada.

À minha família por toda atenção, suporte e confiança depositada em mim. Especialmente à minha mãe, minha inspiração de vida, por todo carinho e sacrifícios para que eu tivesse uma vida melhor.

Finalmente, ao Prof. Ricardo Augusto Souza Fernandes pela orientação acadêmica, aprendizagem, assistência, pela oportunidade de conhecer a área de *Machine Learning*, em que me identifiquei à primeira vista e decidi seguir meus estudos, apoio durante o mestrado, cuja dedicação e competência estão permitindo meu amadurecimento na vida acadêmica.

*“A imaginação é mais importante que o conhecimento. O conhecimento é limitado, enquanto a
imaginação abraça o mundo.”
(Albert Einstein)*

RESUMO

MELLA, M. C.. **Determinação da Contribuição Harmônica em Pontos de Acoplamento Comum de Microrredes: Uma Abordagem Baseada em Aprendizado de Máquina.** 78 p. Dissertação de Mestrado – Centro de Ciências Exatas e de Tecnologia, Universidade Federal de São Carlos, São Carlos, 2025.

A crescente integração de cargas não lineares e recursos distribuídos de energia em microrredes (MR) tem incrementado os níveis de distorções harmônicas nos alimentadores de distribuição. A identificação da origem dessas distorções, seja da MR ou da rede de média tensão da concessionária, é essencial para a gestão da qualidade da energia elétrica. Nesse sentido, este projeto propôs uma abordagem baseada em aprendizado de máquina para identificar o lado responsável pela localização das fontes harmônicas em sistemas de distribuição de energia elétrica, determinando se a contribuição principal para as distorções ocorre no lado da concessionária ou da MR. Para isso, foram usados os classificadores *Random Forest* e *XGBoost*. O *F1-score* foi adotado como métrica de avaliação, pois combina as métricas de precisão e recall, fornecendo uma visão equilibrada do desempenho do modelo, especialmente em cenários onde há desequilíbrio entre as classes. A metodologia foi validada por simulações no alimentador IEEE 34 barras, utilizando o software ATP, com fontes harmônicas como retificadores de 6 e 12 pulsos, *Static Frequency Converter* (SFC), *drive* de motor CC e *Thyristor-controlled Reactor* (TCR), localizadas no lado da concessionária ou da microrrede, sendo que cada simulação considerou apenas uma fonte harmônica. A base de dados gerada foi utilizada para treinar e validar os modelos, que atingiram *F1-scores* superiores a 99%, mostrando alta precisão na identificação do lado predominante nas distorções harmônicas. No entanto, o *F1-score* diminuiu conforme a distância entre a fonte e o Ponto de Acoplamento Comum (PAC) aumentava, devido à atenuação das distorções harmônicas. Mesmo assim, ambos os modelos mantiveram *F1-scores* acima de 97% para distâncias superiores a 40 km, evidenciando a robustez dos modelos. Todo o processo, incluindo a definição dos cenários, execução das simulações, estruturação da base de dados e implementação do pipeline de aprendizado de máquina, foi automatizado em *Python*. A biblioteca *Optuna* foi utilizada para otimizar os modelos, ajustando continuamente os parâmetros dos classificadores. A metodologia se mostrou eficaz para identificar o lado responsável pelas distorções harmônicas, com desempenho robusto mesmo em cenários de grandes distâncias. Os resultados indicam que a abordagem é útil no cenário simulado, considerando a localização de uma carga harmônica por vez, o que permitiu uma análise clara da localização das fontes harmônicas no sistema de distribuição.

Palavras-chave: Aprendizado de máquina, contribuição harmônica, distorção harmônica, qualidade da energia elétrica, sistemas de distribuição de energia.

ABSTRACT

MELLA, M. C.. **Harmonic Contribution Determination in Microgrids' Point of Common Coupling: A Machine Learning-Based Approach.** 78 p. Master Dissertation – Center of Exact Sciences and Technology, Federal University of São Carlos, São Carlos, 2025.

The increasing integration of nonlinear loads and distributed energy resources in microgrids (MG) has raised the levels of harmonic distortions in distribution feeders. Identifying the origin of these distortions, whether from the MG or the utility's medium-voltage network, is essential for managing the quality of electrical power. In this context, this project proposed a machine learning-based approach to identify the side responsible for the location of harmonic sources in electrical distribution systems, determining whether the main contribution to the distortions occurs on the utility side or the MG side. For this, Random Forest and XGBoost classifiers were used. The F1-score was adopted as the evaluation metric because it combines precision and recall metrics, providing a balanced view of the model's performance, especially in scenarios where there is class imbalance. The methodology was validated through simulations on the IEEE 34-bus feeder using the ATP software, with harmonic sources such as 6 and 12-pulse rectifiers, SFC, DC motor drive, and TCR, located on the utility side or the microgrid side, with each simulation considering only one harmonic source. The generated dataset was used to train and validate the models, which achieved F1-scores above 99%, showing high precision in identifying the predominant side in harmonic distortions. However, the F1-score decreased as the distance between the source and the PAC increased due to harmonic distortion attenuation. Nevertheless, both models maintained F1-scores above 97% for distances greater than 40 km, demonstrating the robustness of the models. The entire process, including scenario definition, simulation execution, dataset structuring, and machine learning pipeline implementation, was automated in Python. The Optuna library was used to optimize the models by continuously adjusting the classifiers' parameters. The methodology proved effective in identifying the side responsible for harmonic distortions, with robust performance even in large-distance scenarios. The results indicate that the approach is useful in the simulated scenario, considering the location of one harmonic load at a time, allowing a clear analysis of the location of harmonic sources in the distribution system.

Keywords: Machine learning, harmonic contribution, harmonic distortion, power quality, power distribution systems.

LISTA DE ILUSTRAÇÕES

Figura 1 – Forma de onda da corrente de uma lâmpada fluorescente compacta e seu espectro.	8
Figura 2 – Correntes harmônicas fluindo através da impedância do sistema e consequente distorção da tensão.	8
Figura 3 – Decomposição de uma forma de onda de tensão distorcida em suas componentes harmônicas.	10
Figura 4 – Diagrama esquemático e curva de magnetização do transformador (fluxo ϕ).	12
Figura 5 – Um exemplo de corrente de magnetização distorcida de transformador e seu espectro harmônico.	13
Figura 6 – Espectro harmônico típico da corrente de um forno de arco durante a fusão e durante o refino.	14
Figura 7 – Forma de onda do sinal <i>Pulse Width Modulation</i> (PWM), corrente no motor Corrente Contínua (CC) e espectro harmônico resultante.	15
Figura 8 – Formas de onda da tensão de alimentação e da corrente de uma ponte de tiristores de seis pulsos com reator no lado de corrente contínua.	16
Figura 9 – TCR e suas formas de onda.	17
Figura 10 – Harmônicos em uma corrente de TCR.	18
Figura 11 – Estrutura típica de um SFC.	18
Figura 12 – Forma de onda da tensão medida no PAC com SFC implementado.	19
Figura 13 – Diagrama de interconexão de Microrrede (MR) com a rede elétrica principal.	22
Figura 14 – Diagrama do PAC.	23
Figura 15 – Geração de um conjunto de árvores de decisão no framework <i>Random Forest</i>	29
Figura 16 – Fluxograma ilustrando o algoritmo <i>XGBoost</i>	32
Figura 17 – Circuito equivalente para o método da direção de potência ativa.	34
Figura 18 – Circuito do método da potência ativa modificado por Xu, Liu e Liu (2003)	35
Figura 19 – Circuito do método da potência ativa modificado por Xu, Liu e Liu (2003)	36
Figura 20 – Correlação entre a direção de potência ativa e os índices de sobreposição de corrente.	37
Figura 21 – Composição de uma típica carga segundo o Método da Corrente Conforme e Não-conforme.	39
Figura 22 – Representação dos circuitos para a tensão e corrente medida no PAC.	41
Figura 23 – Visão geral da metodologia proposta.	51

Figura 24 – Alimentador de teste IEEE de 34 barras com a MR definida a partir da barra 858.	52
Figura 25 – Estrutura completa do conjunto de dados para cada fase dos sinais simulados.	57
Figura 26 – Fluxo de treinamento e validação dos modelos preditivos.	57
Figura 27 – Matrizes de confusão - Resultados <i>Random Forest</i> : (a) interpretação de uma matriz de confusão genérica; (b) retificador de 6 pulsos; (c) retificador de 12 pulsos; (d) SFC; (e) acionamento de motor CC; e (f) TCR.	65
Figura 28 – Matrizes de confusão - Resultados <i>XGBoost</i> : (a) interpretação de uma matriz de confusão genérica; (b) retificador de 6 pulsos; (c) retificador de 12 pulsos; (d) SFC; (e) acionamento de motor CC; e (f) TCR.	66
Figura 29 – Diferença no sinal de corrente e na Total Harmonic Distortion (THD) em função da posição da carga harmônica no sistema: (a) Retificador de 6 pulsos alocado na barra 802 e (b) Retificador de 6 pulsos alocado na barra 832.	67
Figura 30 – Relação entre a THD e a distância da fonte harmônica até o PAC.	67
Figura 31 – <i>F1-Score</i> por segmentação de distância da fonte harmônica até o PAC para cada classificador.	68

LISTA DE TABELAS

Tabela 1 – Relação existente entre componentes simétricas e ordem harmônica.	11
Tabela 2 – Limites de distorção harmônica na tensão segundo a norma IEEE 519.	24
Tabela 3 – Limites de distorção harmônica na corrente conforme a relação I_h/I_{sc}	25
Tabela 4 – Limites para harmônicas individuais na corrente.	25
Tabela 5 – Limites das distorções harmônicas totais na tensão fundamental.	26
Tabela 6 – Limites de distorção harmônica de tensão (%) para componentes individuais ímpares.	26
Tabela 7 – Limites de distorção harmônica para componentes individuais pares.	26
Tabela 8 – Características das Fontes Harmônicas	52
Tabela 9 – Cenários analisados nas simulações, considerando diferentes fontes harmônicas em cada modo operacional e sua localização.	54
Tabela 10 – Intervalos de otimização para o modelo Random Forest	61
Tabela 11 – Intervalos de otimização para o modelo XGBoost	62
Tabela 12 – Melhores Hiperparâmetros para <i>Random Forest</i> e <i>XGBoost</i>	64
Tabela 13 – Métricas de Desempenho para <i>Random Forest</i>	64
Tabela 14 – Métricas de Desempenho para <i>XGBoost</i>	64
Tabela 15 – Desempenho da <i>Random Forest</i> por fonte harmônica e faixa de distância até o PAC	69
Tabela 16 – Desempenho do <i>XGBoost</i> por fonte harmônica e faixa de distância até o PAC	70

LISTA DE SIGLAS

ANEEL *Agência Nacional de Energia Elétrica*

ATP *Alternative Transients Program*

ANN *Artificial Neural Network*

ANFIS *Adaptive Neuro-Fuzzy Inference System*

BESS *Battery Energy Storage Systems*

CC *Corrente Contínua*

CA *Corrente Alternada*

CAE *Cross Approximation Entropy*

DFT *Discrete Fourier Transform*

DT *Decision Tree*

DBSCAN *Density-based Spatial Clustering of Applications with Noise*

DER *Distributed Energy Resource*

ERBFN *Exact Radial Basis Function Neural Network*

EAF *Electric Arc Furnace*

FFT *Fast Fourier Transform*

IEEE *Institute of Electrical and Electronics Engineers*

IEC *International Electrotechnical Commission*

MLP *Multilayer Perceptron*

MSE *Mean Squared Error*

MR *Microrrede*

MSEF *Mean Square Error of Fit*

PRODIST *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional*

PAC *Ponto de Acoplamento Comum*

PCH *Pequena Central Hidrelétrica*

PWM *Pulse Width Modulation*

QEE *Qualidade da Energia Elétrica*

RLS *Recursive Least Square*

RMS *Root Mean Square*

RMSE *Root Mean Squared Error*

SVM *Support Vector Machine*

SOFM *Self-organization Feature Map*

SFC *Static Frequency Converter*

THD *Total Harmonic Distortion*

TCR *Thyristor-controlled Reactor*

UPS *Uninterruptible Power Supply*

FFBPN *Feed Forward Back Propagation Neural Network*

CFBPN *Cascade Feed Forward Back Propagation Neural Network*

RBFN *Radial Basis Function Neural Network*

ERBFN *Exact Radial Basis Function Neural Network*

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Estado da Arte	2
1.2	Motivação	4
1.3	Objetivos	5
1.4	Organização da Dissertação	5
2	FUNDAMENTAÇÃO TEÓRICA	7
2.1	Componentes Harmônicas em Sistemas de Energia	7
2.1.1	Distorções Harmônicas	7
2.1.2	Fontes Harmônicas	11
2.1.2.1	Transformadores	12
2.1.2.2	Fornos Elétricos a Arco	13
2.1.2.3	<i>Drive</i> de Motor de Corrente Contínua (CC)	14
2.1.2.4	Retificadores Trifásicos	14
2.1.2.5	Reatores Controlados por Tiristores	16
2.1.2.6	Conversores Estáticos de Frequência	17
2.1.3	Efeitos das Distorções Harmônicas	19
2.2	Distorções Harmônicas em Microrredes e Análise de Contribuição Harmônica	21
2.3	Regulamentações e Normativas sobre Distorções Harmônicas	23
2.3.1	Diretrizes determinadas pelo <i>International Electrotechnical Commission</i> (IEC)	24
2.3.2	Diretrizes determinadas pelo <i>Institute of Electrical and Electronics Engineers</i> (IEEE)	24
2.3.3	Diretrizes da ANEEL	25
2.3.4	Desafios quanto ao cumprimento de normas e recomendações	26
2.4	Aprendizado de Máquina	27
2.4.1	Treinamento de Modelos Supervisionados	28
2.4.2	Validação de Modelos Supervisionados	28
2.4.3	<i>Random Forest</i>	28
2.4.4	<i>XGBoost</i>	31
3	REVISÃO BIBLIOGRÁFICA	33
3.1	Principais métodos para identificação da contribuição harmônica	33

3.1.1	Método da Direção de Potência Ativa	33
3.1.2	Método da Superposição Harmônica	35
3.1.3	Método da Corrente Conforme e Não-Conforme	38
3.1.4	Método da Impedância Crítica	41
3.2	Abordagens recentes usadas para determinar a contribuição harmônica	42
4	DETERMINAÇÃO DA CONTRIBUIÇÃO HARMÔNICA	49
4.1	Visão Geral	49
4.2	Simulação do Alimentador de Distribuição no ATP	50
4.2.1	Alimentador de Teste IEEE de 34 Barras	50
4.2.2	Modelagem das Fontes Harmônicas	51
4.2.3	Configuração da Simulação e Aquisição de Dados	52
4.3	Extração de Características	53
4.3.1	Características extraídas	55
4.3.2	Características relacionadas à distorção harmônica	56
4.4	Modelos Preditivos	57
4.4.1	Divisão dos Dados	57
4.4.2	Treinamento dos Modelos	58
4.4.3	Validação dos Modelos	58
4.4.3.1	Acurácia	59
4.4.3.2	Precisão	59
4.4.3.3	<i>Recall</i>	59
4.4.3.4	F1-Score	60
4.4.3.5	Matriz de Confusão	60
4.4.4	Otimização de Hiperparâmetros	60
4.5	Implementação da Metodologia	62
5	RESULTADOS E DISCUSSÕES	63
5.1	Análise Geral dos Resultados	63
5.2	Análise dos Resultados Considerando as Distâncias das Fontes Harmônicas em Relação ao PAC da MR	66
6	CONCLUSÕES	71
	REFERÊNCIAS	73

INTRODUÇÃO

O avanço da eletrônica, impulsionado pela tecnologia dos semicondutores, originou uma revolução no desenvolvimento de equipamentos eletrônicos. Esse progresso propiciou a proliferação de uma vasta gama de equipamentos essenciais para a sociedade moderna, os quais têm impacto direto no consumo e na Qualidade da Energia Elétrica (QEE) (RÖNNBERG; BOLLEN, 2016).

No entanto, apesar de suas inúmeras vantagens, esses equipamentos apresentam um comportamento elétrico não linear, ou seja, a relação entre a corrente e a tensão elétrica não segue uma proporcionalidade direta (JOHNSON; HASSAN, 2016). Exemplos desses equipamentos incluem inversores de frequência usados para a integração de fontes de energia renováveis (painéis solares, turbinas eólicas), sistemas de iluminação baseados em diodo emissor de luz (LED, do inglês *light-emitting diode*) e fontes chaveadas comumente utilizadas por microcomputadores. Esses dispositivos drenam correntes harmônicas e, devido à densidade dessas cargas alocadas nos sistemas de distribuição, é notável a consequente distorção das tensões ao longo dos alimentadores.

Nesse sentido, tem-se as distorções harmônicas como um dos distúrbios que afetam a QEE entregue aos consumidores. Cabe mencionar que as correntes harmônicas são caracterizadas por frequências múltiplas inteiras da frequência fundamental (nominal) da rede. Elevados níveis de distorções harmônicas podem acarretar no aquecimento excessivo de cabos, interferência eletromagnética, ressonância com bancos de capacitores, entre outros efeitos indesejáveis (KHAN; SINGH; MAKHIJA, 2017). Equipamentos como transformadores, motores, inversores de frequência e sistemas eletrônicos de controle são especialmente vulneráveis devido à sensibilidade a altas frequências, comprometendo assim suas vidas úteis e eficiências operacionais.

No âmbito dos consumidores industriais, os efeitos previamente mencionados implicam em custos elevados com a manutenção de equipamentos e, conseqüentemente, são repassados ao produto final de suas linhas de produção (BOLLEN, 2006). Para os consumidores residenciais,

os efeitos são menos prejudiciais; entretanto, a falha e/ou redução de vida útil de determinados equipamentos podem gerar transtornos inesperados (KHAN; SINGH; MAKHIJA, 2017).

No contexto das MRs, a situação é ainda mais crítica. A crescente integração de geradores distribuídos baseados em inversores, como painéis solares e turbinas eólicas, contribui para o aumento das distorções harmônicas. Essa característica, aliada à presença de cargas não lineares, produz efeitos que podem inclusive comprometer a estabilidade e confiabilidade da MR como um todo (UDDIN *et al.*, 2023).

A crescente preocupação com os efeitos das distorções harmônicas tem motivado as agências reguladoras a estabelecer normas que limitem os níveis aceitáveis de distorção nas redes de distribuição (IEEE, 2014; ANEEL, 2021). No entanto, ainda existem lacunas quanto às diretrizes específicas sobre como identificar a fonte causadora ou de maior contribuição ao aumento dos níveis. Nesse sentido, a implementação de soluções eficazes para monitorar e tomar decisões quanto à mitigação das distorções harmônicas continua sendo um desafio para as concessionárias de energia elétrica.

A identificação precisa das fontes de harmônicos, sua localização e a quantificação de suas contribuições são passos essenciais para desenvolver estratégias de mitigação mais eficazes. Isso envolve não apenas medir a distorção harmônica na rede, mas também analisar o comportamento dinâmico das cargas e das fontes distribuídas, a fim de mapear as principais causas dessa distorção. Como a geração e o consumo de energia variam ao longo do tempo, a injeção de harmônicas na rede também pode ser variável, fazendo com que a contribuição de cada fonte para a distorção harmônica total (THD) não seja estática. Dessa forma, técnicas avançadas de monitoramento e análise, capazes de detectar com precisão as fontes de harmônicos e de estimar sua contribuição em diferentes momentos, são fundamentais nesse processo. Além disso, é importante considerar que essas fontes podem variar conforme o tipo de carga, sua distância em relação ao ponto de medição e as características inerentes aos geradores distribuídos da MR.

1.1 Estado da Arte

Nos últimos anos, diversas pesquisas têm sido conduzidas em universidades e centros de pesquisa para analisar a contribuição harmônica no PAC, buscando estabelecer claramente a responsabilidade entre consumidores e concessionárias de energia elétrica.

Em um estudo pioneiro, Liu e Xu (2000) propuseram uma técnica para quantificar a contribuição harmônica, na qual definiram um circuito equivalente para o sistema, considerando as impedâncias e as correntes harmônicas envolvidas. Contudo, é crucial determinar as contribuições individuais das partes envolvidas para compreender quais componentes do sistema estão gerando distorções harmônicas. Essa identificação é fundamental para que as entidades responsáveis, como concessionárias de energia elétrica ou órgãos reguladores, possam adotar medidas adequadas de controle e mitigação das distorções, visando aprimorar a QEE entregue

aos consumidores e à própria rede.

As abordagens propostas por [Xu et al. \(2002\)](#) para medir o efeito isolado da impedância harmônica são valiosas na determinação das responsabilidades entre consumidores e concessionárias. Esses autores apresentam dois tipos de métodos: o método de transitório (*transient-based-method*) e o método de regime permanente (*steady-state-method*). No método de transitório, distúrbios transitórios são injetados no sistema para calcular as impedâncias com base nas variações nas formas de onda de tensão e corrente. Essas variações, que estão relacionadas com a frequência, permitem estimar as impedâncias harmônicas. Esse método tem sido utilizado em outras pesquisas, como observado em [Robert et al. \(1997\)](#).

Por outro lado, o método de regime permanente, também mencionado por [Robert et al. \(1997\)](#), baseia-se na análise das formas de onda registradas antes e depois da geração de um distúrbio transitório em um capacitor conectado ao PAC. A injeção do distúrbio na rede é realizada por meio de uma fonte de corrente externa ou um componente de chaveamento. A análise é realizada através da Transformada Discreta de Fourier, que permite identificar as variações harmônicas no sistema.

Embora os métodos propostos por [Xu et al. \(2002\)](#) e [Liu e Xu \(2000\)](#) apresentem similaridades, diferem na comparação entre análises transitórias e em regime permanente. Adicionalmente, a abordagem de [Xu, Liu e Liu \(2003\)](#), que visa verificar a direção do fluxo de potência ativa para determinar a fonte dominante de distorção harmônica, não se mostrou adequada para a detecção de fontes de harmônicos. Apesar de sua utilização industrial ao longo dos anos, sua eficácia foi questionada diante de evidências concretas.

Para superar essa limitação, [Li, Xu e Tayjasanant \(2002\)](#) propõem o método da Impedância Crítica, que se baseia na direção da potência reativa como um indicador mais confiável na determinação da fonte harmônica dominante. Essa abordagem, ao contrário das técnicas anteriores, busca identificar o fluxo de potência harmônica, apontando para o consumidor ou a concessionária como a fonte dominante com base na potência reativa.

Embora muitos dos métodos existentes se concentrem na identificação do fluxo de corrente e da potência harmônica, seu foco principal reside na identificação dos elementos responsáveis e na quantificação percentual das contribuições de cada um deles. Os métodos disponíveis para calcular essas porcentagens enfrentam desafios consideráveis, incluindo complexidades na implementação e altos custos de desenvolvimento. Além disso, existe uma preocupação adicional em relação à necessidade de conhecer previamente as impedâncias do sistema, tanto na MR quanto na rede de energia. É importante ressaltar que as impedâncias são dinâmicas e podem variar em diferentes situações, adicionando uma camada adicional de complexidade à análise harmônica.

Recentemente, novas técnicas baseadas em algoritmos de aprendizado de máquina têm sido propostas, incluindo redes neurais ([MURUGAN; KUMAR, 2016](#); [UGWUAGBO et al.,](#)

2023), sistemas de inferência fuzzy (SILVA *et al.*, 2015; FERNANDES *et al.*, 2023) e árvores de decisão (FERNANDES *et al.*, 2023). Essas abordagens têm demonstrado resultados promissores, alcançando mais de 90% de precisão na estimativa das contribuições harmônicas.

Neste contexto, a presente dissertação propõe uma abordagem baseada em aprendizado de máquina, explorando *ensembles* de árvores de decisão (*Random Forest* e *XGBoost*) quanto à estimação do lado de maior contribuição harmônica entre a concessionária e uma MR. As principais inovações deste estudo em relação ao estado da arte incluem: (1) Eliminação da necessidade de conhecimento prévio sobre as impedâncias harmônicas; e (2) Estimação precisa do lado de maior contribuição, utilizando exclusivamente características extraídas das tensões e correntes trifásicas medidas no PAC da MR.

Vale destacar que, após realizar a revisão bibliográfica, nenhuma outra abordagem se propôs a avaliar a contribuição harmônica entre a rede principal (de responsabilidade da concessionária) e uma MR.

1.2 Motivação

A determinação da contribuição harmônica no PAC é um tema de importância global, refletindo a crescente preocupação com a QEE. A identificação precisa das principais fontes de distorção harmônica e sua localização no sistema de energia é essencial para que as concessionárias implementem ações corretivas eficazes, assegurando a manutenção e o aprimoramento dos níveis de qualidade estabelecidos por órgãos reguladores, como a Agência Nacional de Energia Elétrica (ANEEL) no Brasil, a IEC (IEC, 2014) e a IEEE (IEEE, 2014) internacionalmente.

Os métodos tradicionais de análise de contribuições harmônicas, como os apresentados em Liu e Xu (2000) e Xu *et al.* (2002), enfrentam limitações significativas, especialmente diante da complexidade e variabilidade dos sistemas elétricos modernos. Além de exigirem um conhecimento preciso das impedâncias do sistema—informação muitas vezes indisponível—, esses métodos apresentam dificuldades na identificação e localização das fontes de distorção. Essas restrições evidenciam a necessidade de abordagens mais avançadas para uma análise eficaz da qualidade da energia.

Nesse cenário, técnicas de aprendizado de máquina surgem como uma abordagem promissora. Esses algoritmos conseguem processar grandes volumes de dados, identificar padrões complexos e lidar com incertezas inerentes ao problema, oferecendo soluções precisas e abrangentes para a determinação das contribuições harmônicas nos PACs. Diante dos resultados positivos observados em estudos anteriores que utilizam aprendizado de máquina, novas oportunidades foram identificadas para explorar e avançar nessa direção.

Este estudo se insere na linha de pesquisa que emprega aprendizado de máquina para identificar a contribuição harmônica no PAC, visando estimar qual lado do sistema é dominante

na geração da distorção harmônica. Especificamente, busca-se determinar se a carga harmônica predominante tem origem no lado da concessionária (rede) ou na MR. Para isso, foram avaliados dois classificadores: *Random Forest* e *XGBoost*, escolhidos por suas capacidades de lidar com padrões complexos nos dados. O *Random Forest*, por ser um modelo baseado em múltiplas árvores de decisão, apresenta robustez contra *overfitting* e eficiência na análise de dados não lineares e ruidosos. Já o *XGBoost*, uma versão otimizada do *Gradient Boosting*, destaca-se por sua alta precisão e eficiência computacional, sendo capaz de captar relações sutis entre as variáveis.

1.3 Objetivos

Essa dissertação de mestrado tem como objetivo principal utilizar classificadores de aprendizado de máquina, especificamente *Random Forest* e *XGBoost*, para estimar com precisão o lado do sistema onde está a fonte harmônica de maior predominância para a distorção harmônica medida no PAC de uma MR. A principal vantagem da abordagem proposta é que tal estimativa pode ser realizada utilizando exclusivamente características extraídas dos sinais de tensão e corrente trifásicos medidos no PAC, ou seja, sem a necessidade de medições em outros nós do sistema ou de informações sobre determinadas características da rede, como, por exemplo, a impedância harmônica. Ademais, como objetivos específicos, pode-se elencar:

- Criar cenários simulados que se aproximem de situações reais de operação de uma MR. Para tanto, considerou-se realizar algumas modificações no alimentador de teste IEEE de 34 barras, em que distintas fontes harmônicas puderam ser conectadas;
- Avaliar o desempenho de distintas técnicas de aprendizado de máquina, sendo elas baseadas em *ensembles*;
- Extrair distintas características dos sinais de tensão e corrente, com o intuito de avaliar suas relevâncias para os modelos preditivos.

1.4 Organização da Dissertação

Além desse capítulo introdutório, o restante da dissertação de mestrado está organizado da seguinte forma:

- Capítulo 2 – apresenta os conceitos fundamentais relacionados às distorções harmônicas, às cargas lineares e não lineares, além das contribuições harmônicas que podem ser analisadas a partir de PACs. Por fim, o capítulo traz algumas normatizações e recomendações, bem como os princípios das técnicas de aprendizado de máquina empregadas na abordagem proposta;

- Capítulo 3 – traz uma revisão bibliográfica que versa sobre o estado da arte em termos da determinação da contribuição harmônica;
- Capítulo 4 – detalha a abordagem proposta, descrevendo suas etapas e os cenários simulados.
- Capítulo 5 – apresenta e discute os resultados obtidos por meio da abordagem proposta.
- Capítulo 6 – sumariza e destaca os avanços proporcionados pela dissertação ao estado da arte.

FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são explorados os conceitos fundamentais para uma melhor compreensão sobre as distorções harmônicas, sendo essencial para se determinar a contribuição harmônica. Além disso, são apresentadas as principais normas e recomendações que estabelecem os limites de distorção harmônica, abrangendo tanto o contexto nacional quanto internacional.

Adicionalmente, o capítulo traz um embasamento teórico sobre aprendizado de máquina, destacando a explicação dos modelos utilizados nesta pesquisa.

2.1 Componentes Harmônicas em Sistemas de Energia

Em condições ideais, as tensões e correntes em diferentes pontos de uma rede elétrica, incluindo os pontos de acoplamento entre a rede e os consumidores, deveriam ser puramente senoidais, com frequência nominal (60 Hz para o Brasil). Na prática, contudo, essas grandezas podem apresentar desvios em relação à forma senoidal. Segundo [Dugan *et al.* \(2012\)](#), tais desvios tendem a ser mais acentuados próximos aos consumidores.

Entre os diferentes tipos de perturbações que podem afetar a QEE, a distorção harmônica é uma das mais relevantes, sendo caracterizada pela presença de componentes harmônicas na corrente e na tensão do sistema ([ROSA, 2006](#)). Esse fenômeno está frequentemente associado ao uso extensivo de dispositivos baseados em eletrônica de potência, embora outras fontes, como saturação de transformadores e fenômenos de ressonância na rede, também possam contribuir para o problema. Como consequência, a distorção harmônica pode comprometer o desempenho dos equipamentos elétricos e afetar a qualidade da energia entregue aos consumidores.


2.1.1 Distorções Harmônicas

A distorção harmônica ocorre quando a forma de onda da tensão e/ou da corrente contém componentes de frequência que são múltiplos inteiros da frequência fundamental do sistema

(BAGGINI, 2008). Esse fenômeno resulta da superposição dessas componentes harmônicas com a frequência fundamental, alterando a forma original da onda senoidal.

Ao convolver o sinal de frequência fundamental com os sinais de frequência harmônica, tem-se visualmente uma forma de onda distorcida em relação a uma senoide pura. Portanto, nota-se um comportamento não linear entre tensão e corrente, sendo este o motivo pelo qual os dispositivos baseados em eletrônica de potência também são referidos como cargas não lineares ou fontes harmônicas. A Figura 1 ilustra a forma de onda e o espectro harmônico da corrente de uma lâmpada fluorescente compacta, evidenciando a presença de componentes harmônicas.

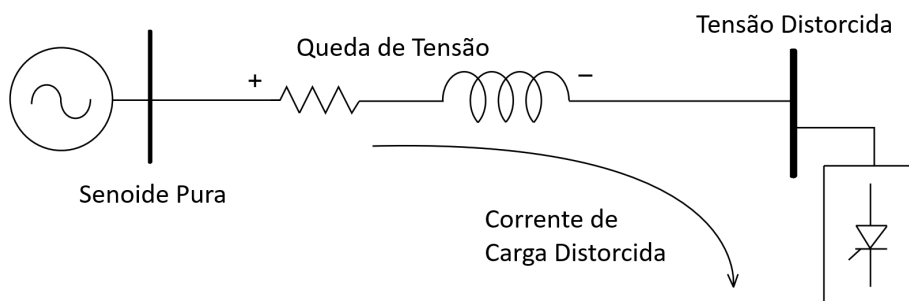
Figura 1 – Forma de onda da corrente de uma lâmpada fluorescente compacta e seu espectro.



Fonte: [Baggini \(2008\)](#).

Cargas não lineares, mesmo quando alimentadas por uma fonte de tensão puramente senoidal, drenam correntes harmônicas. Com isso, essa corrente circula por todo o sistema, causando quedas de tensão harmônicas sobre as impedâncias que se encontram ao longo do circuito. A Figura 2 exemplifica como uma carga não linear contribui para a distorção da tensão em uma rede elétrica.

Figura 2 – Correntes harmônicas fluindo através da impedância do sistema e consequente distorção da tensão.



Fonte: [Dugan et al. \(2012\)](#).

De acordo com [Dugan et al. \(2012\)](#), a presença de harmônicos nos sistemas elétricos impede a operação em condições puramente senoidais, pois introduz componentes de frequência múltipla da fundamental. Como consequência, as simplificações matemáticas comumente

utilizadas para a análise na frequência fundamental deixam de ser válidas, uma vez que o comportamento do sistema passa a depender de várias frequências simultaneamente. Isso exige abordagens mais complexas para a análise de tensões, correntes e potência, considerando a influência dos harmônicos na qualidade da energia elétrica.

Assim, para analisar uma forma de onda distorcida de tensão ou corrente, a técnica comumente utilizada é a Transformada Discreta de Fourier (*Discrete Fourier Transform* (DFT)), pois os sinais são normalmente amostrados no tempo (discretizados) por medidores de QEE. Com isso, torna-se possível decompor os sinais correspondentes a cada frequência harmônica, ou seja, obter as amplitudes e ângulos de fase de cada harmônico de corrente e/ou tensão, conforme ilustrado na Figura 3.

Vale mencionar que a Transformada de Fourier permite decompor um sinal no domínio do tempo em suas componentes harmônicas no domínio da frequência (STEIN; SHAKARCHI, 2003), conforme descrito na equação 2.1:

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt, \quad (2.1)$$

em que $X(f)$ é a Transformada de Fourier do sinal contínuo $x(t)$, representando a amplitude e a fase associadas à frequência f ; $x(t)$ é o sinal no domínio do tempo; f é a frequência em Hertz (Hz); t é a variável de tempo; e $e^{-j2\pi ft}$ é um termo matemático que identifica as frequências presentes no sinal, funcionando como uma ferramenta para decompor o sinal em suas componentes básicas.

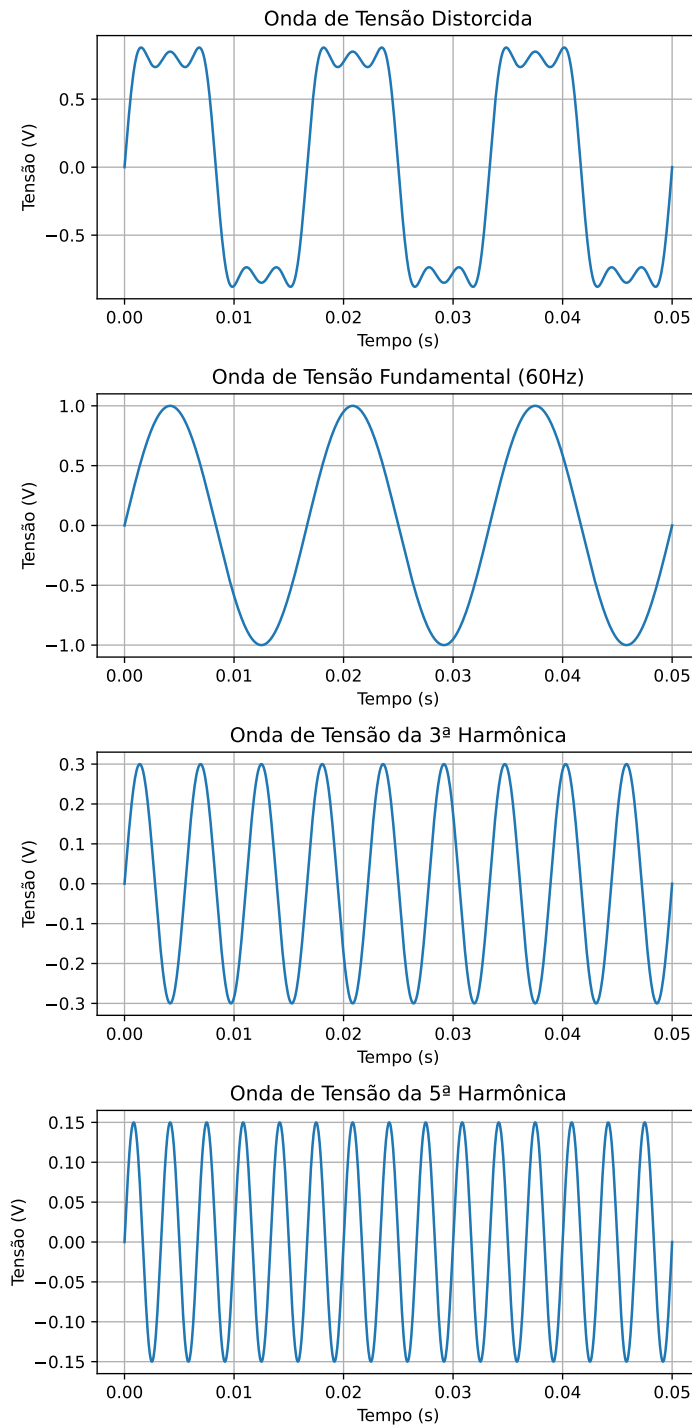
Na prática, como os sinais de tensão e de corrente são previamente amostrados e digitalizados, tem-se a DFT como técnica vastamente empregada ao processamento do sinal digital, dada pela equação 2.2:

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j\frac{2\pi kn}{N}}, \quad (2.2)$$

em que $X(k)$ é a DFT do sinal amostrado $x(n)$, que corresponde à frequência discreta k ; $x(n)$ é o sinal digitalizado no domínio do tempo; N é o número total de amostras; $e^{-j\frac{2\pi kn}{N}}$ desempenha um papel semelhante, permitindo identificar e quantificar as frequências discretas presentes no sinal; e k é o índice da frequência discreta correspondente.

Entretanto, como a análise desses sinais é frequentemente realizada em dispositivos eletrônicos dedicados, como processadores digitais de sinais e microcontroladores, utiliza-se com frequência uma versão otimizada da DFT, conhecida como Transformada Rápida de Fourier (*Fast Fourier Transform* (FFT)). Essa técnica explora propriedades matemáticas específicas para reduzir significativamente o número de operações necessárias ao cálculo da DFT, tornando-a mais eficiente em termos computacionais.

Figura 3 – Decomposição de uma forma de onda de tensão distorcida em suas componentes harmônicas.



Fonte: Autoria própria.

É importante destacar que a FFT apresenta melhor desempenho quando o número de pontos na sequência de entrada é uma potência de dois (2^x), pois isso permite uma divisão eficiente dos cálculos em múltiplas etapas menores. Essa característica reduz drasticamente a complexidade algorítmica, facilitando a extração das amplitudes e ângulos de fase das componentes harmônicas de forma prática e rápida (PROAKIS; MANOLAKIS, 2006).

Segundo Baggini (2008), em um sistema trifásico equilibrado ideal, o método de com-

ponentes simétricas pode ser aplicado a cada harmônico, estabelecendo uma relação previsível entre a ordem harmônica e suas componentes positiva, negativa e zero, conforme apresentado na Tabela 1. No entanto, essa relação é válida apenas sob a hipótese de idealidade e equilíbrio perfeito do sistema. Em sistemas reais, essa correspondência pode ser alterada por diversos fatores, como desbalanceamentos de carga, variações na impedância das fases, interações com transformadores e linhas de transmissão, além da presença de inter-harmônicos.

Tabela 1 – Relação existente entre componentes simétricas e ordem harmônica.

Componentes Simétricas	Sequência Positiva	Sequência Negativa	Sequência Zero
Ordem Harmônica	1	2	3
	4	5	6
	7	8	9
	10	11	12

	$3k + 1$	$3k + 2$	$3k + 3$ para $k = 0,1,2,\dots$

Fonte: [Baggini \(2008\)](#).

Tendo como base as componentes harmônicas extraídas de determinado sinal temporal, pode-se medir o nível de distorção em relação à frequência fundamental. Para isso, tem-se um indicador denominado Distorção Harmônica Total (THD) ([BAGGINI, 2008](#)), o qual pode ser obtido por:

$$\text{THD} = \frac{\sqrt{\sum_{n=2}^N h_n^2}}{h_1} \times 100\% \quad (2.3)$$

em que h_n representa o valor eficaz (RMS, do inglês *root mean square*) das tensões ou correntes harmônicas para cada ordem harmônica n , e h_1 é o valor RMS da componente fundamental.

2.1.2 Fontes Harmônicas

As cargas não lineares, conforme mencionado, são fontes de correntes harmônicas devido à não linearidade na relação entre tensão e corrente. De acordo com [Baggini \(2008\)](#), essas cargas são classificadas em três categorias, a saber:

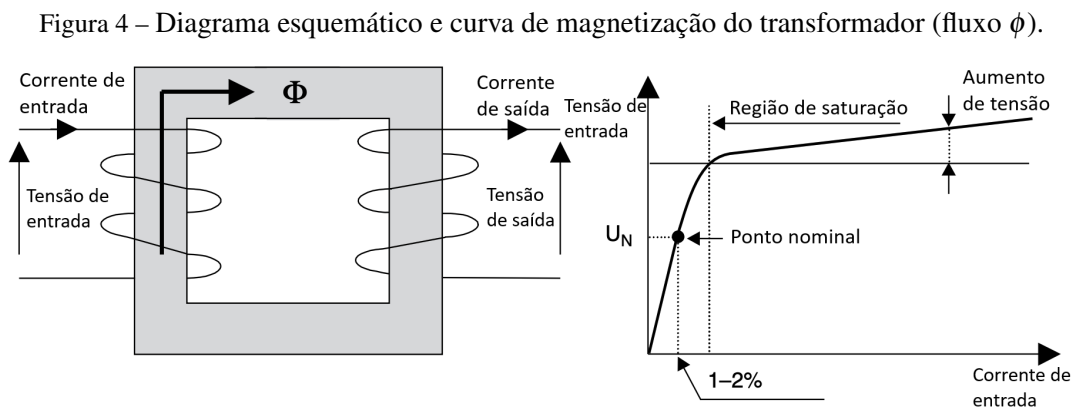
- **Categoria 1** – inclui equipamentos com núcleo magnético saturado, como reatores e transformadores. A distorção harmônica é gerada pela não linearidade do núcleo magnético;
- **Categoria 2** – inclui cargas baseadas em arco voltaico, como fornos a arco, máquinas de solda e iluminação fluorescente. A distorção harmônica da corrente provém da não linearidade do arco;

- **Categoria 3** – Composta por equipamentos eletrônicos, como conversores estáticos, computadores, fornos de micro-ondas, *no-breaks* e outros. A distorção harmônica decorre da não linearidade de componentes eletrônicos, como diodos e transistores.

A seguir, é apresentada uma breve descrição das características de algumas fontes de correntes harmônicas relacionadas às categorias supramencionadas.

2.1.2.1 Transformadores

Segundo [Baggini \(2008\)](#), os transformadores representam uma das principais fontes de harmônicos em sistemas elétricos de potência. A geração de harmônicos nesses equipamentos decorre das características magnéticas não lineares de seus núcleos. O núcleo ferromagnético de um transformador possui uma capacidade limitada de suportar densidade de fluxo magnético, independentemente de um aumento no campo magnético aplicado. A Figura 4 apresenta o diagrama esquemático e a curva de magnetização de um transformador.

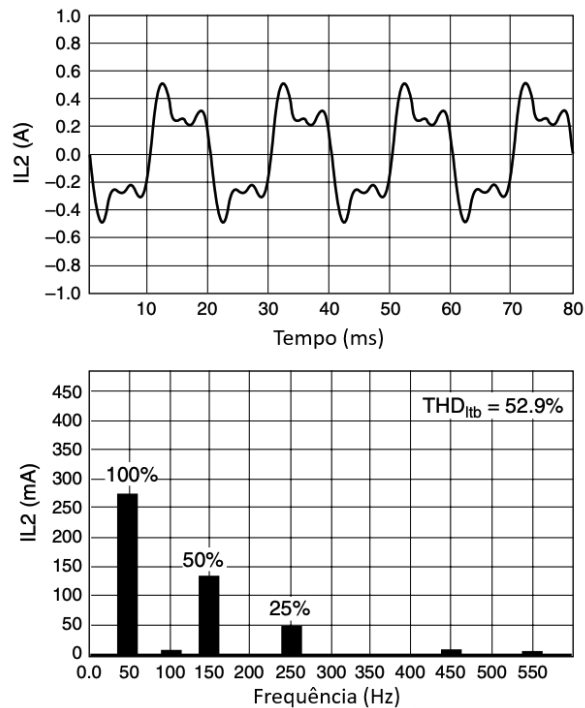


Fonte: [Baggini \(2008\)](#).

Transformadores são, em geral, projetados para operar com uma corrente de magnetização entre 1% e 2% da corrente nominal (I_N), o que corresponde ao ponto em que o transformador trabalha com a tensão nominal (U_N) ou próximo a ela. Isso é demonstrado na curva de magnetização do transformador (Figura 4), onde é possível observar a região de saturação. Quando o transformador opera acima de sua tensão nominal, ele atinge essa região, na qual uma pequena variação na tensão de alimentação gera uma variação significativa na corrente de magnetização, aumentando o conteúdo harmônico dessa corrente.

Por exemplo, com a tensão acima da tensão nominal, o valor do terceiro harmônico da corrente de magnetização pode aumentar em até 50%, conforme mostra a Figura 5. Isso pode ocorrer em condições de baixa carga ou como consequência de ligar/desligar grandes cargas de potência reativa (como reatores *shunt* ou bancos de capacitores).

Figura 5 – Um exemplo de corrente de magnetização distorcida de transformador e seu espectro harmônico.



Fonte: [Baggini \(2008\)](#).

2.1.2.2 Fornos Elétricos a Arco


Os fornos a arco são equipamentos amplamente utilizados em siderúrgicas para a fusão e o refinamento de metais, especialmente no processo de produção de aço. Conforme explica [Baggini \(2008\)](#), esses equipamentos convertem energia elétrica em energia térmica através de um arco elétrico.

A distorção das correntes em fornos a arco e, conseqüentemente, das tensões, é um problema significativo devido ao seu uso comum e à alta potência envolvida. Além disso, por questões tecnológicas, os fornos a arco estão atualmente sendo operados com um fator de potência mais baixo do que no passado. Uma das conseqüências desse fato, juntamente com os requisitos mais rigorosos em relação à compensação de potência reativa, é o aumento da potência nominal dos capacitores de compensação. Isso provoca a redução da frequência de ressonância. Como as amplitudes das altas ordens harmônicas são significativas nessa faixa do espectro, pode ocorrer uma amplificação das harmônicas na tensão de fornecimento.

As condições de descarga do arco variam nas diferentes fases do processo térmico. O maior nível de distorção da corrente ocorre durante a fase de fusão, enquanto é consideravelmente menor nas fases subsequentes ([BAGGINI, 2008](#)). Quando há a formação de uma superfície de metal líquido, o arco se torna mais curto, as flutuações da corrente diminuem e a forma de onda da corrente se aproxima de uma onda senoidal. O espectro típico de amplitude da corrente, durante a fusão e o refino, é apresentado na Figura 6. Esse espectro revela as harmônicas dominantes em 2ª, 3ª e 5ª ordens. É comum que essas amplitudes diminuam rapidamente à medida que a

frequência harmônica aumenta. Com o aumento da potência do forno, a distorção da tensão aumenta, enquanto a distorção da corrente diminui.

Figura 6 – Espectro harmônico típico da corrente de um forno de arco durante a fusão e durante o refino.



Fonte: [Baggini \(2008\)](#).

2.1.2.3 Drive de Motor de Corrente Contínua (CC)

Os *drives* de acionamento de motores CC desempenham um papel fundamental em aplicações industriais que exigem controle preciso de velocidade e de torque. Esses dispositivos utilizam conversores de energia para regular a tensão e a corrente fornecidas ao motor, adotando técnicas de modulação por largura de pulso (*Pulse Width Modulation* (PWM)) para ajustar de maneira eficiente a potência entregue ([DUGAN et al., 2012](#)).

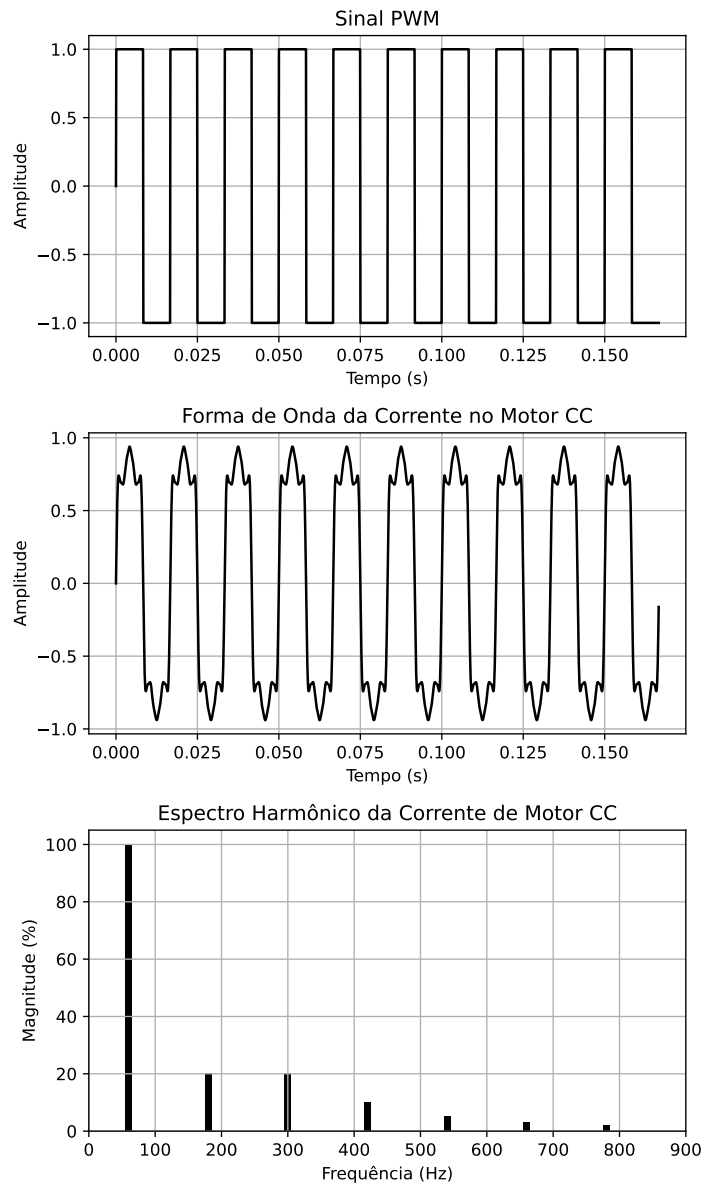
Embora a modulação PWM seja altamente eficiente, ela introduz correntes harmônicas na rede elétrica devido à comutação dos semicondutores de potência, como tiristores e transistores. Essas correntes harmônicas podem causar distorções que impactam negativamente o desempenho de outros equipamentos conectados à mesma rede, reduzindo a eficiência do sistema e comprometendo a QEE ([DUGAN et al., 2012](#)).

A Figura 7 apresenta três aspectos fundamentais do acionamento de um motor CC: a forma de onda do sinal PWM, a forma de onda da corrente medida no motor e o espectro harmônico da corrente resultante. A análise destaca a presença de harmônicas significativas, como as de ordens mais baixas (3^a e 5^a) e também as de alta frequência ([DUGAN et al., 2012](#)). Essas distorções podem prejudicar a vida útil dos equipamentos elétricos conectados e a QEE na rede. Por isso, a mitigação de harmônicas deve ser considerada como parte essencial do projeto de sistemas de acionamento de motores CC.

2.1.2.4 Retificadores Trifásicos

Os retificadores trifásicos são dispositivos essenciais na conversão de Corrente Alternada (CA) em CC, amplamente utilizados em aplicações industriais como controladores de velocidade variável, *Uninterruptible Power Supply* (UPS) e sistemas de conversão de energia CA/CC. O modelo mais comum é a ponte trifásica de seis pulsos, assim chamada por produzir seis pulsos de tensão por ciclo na saída CC, correspondentes a cada meia fase do ciclo ([BAGGINI, 2008](#)).

Figura 7 – Forma de onda do sinal PWM, corrente no motor CC e espectro harmônico resultante.



Fonte: Autoria própria.

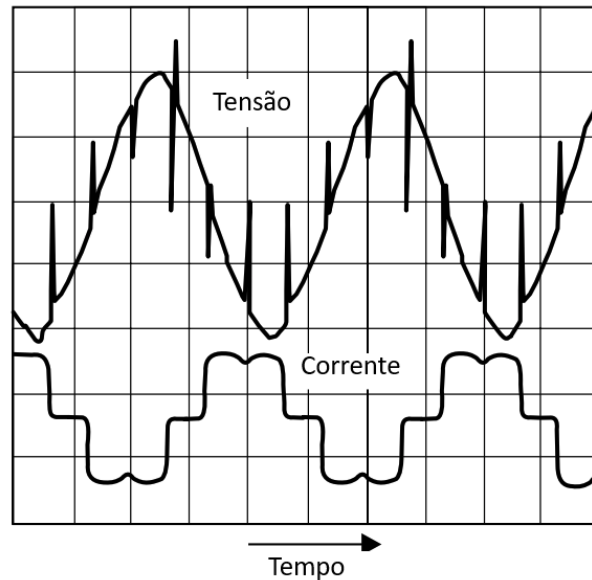
Retificador de Seis Pulsos

O retificador de seis pulsos utiliza uma ponte de tiristores ou diodos que geram correntes harmônicas de ordem $6n \pm 1$, na qual n é um número inteiro positivo. Isso implica que as principais harmônicas estão nos múltiplos de seis, alternando acima e abaixo da ordem base. Por exemplo, as componentes predominantes são a 5ª e a 7ª, seguidas pela 11ª e a 13ª, com magnitudes decrescentes de acordo com o inverso de sua ordem. Teoricamente, a 5ª harmônica equivale a 20% da corrente fundamental, enquanto a 11ª representa cerca de 9% (BAGGINI, 2008).

A Figura 8 ilustra as formas de onda da tensão e da corrente em uma ponte de tiristores de seis pulsos. Os recortes de comutação (*notching*), visíveis na forma de onda da tensão, ocorrem

devido à sobreposição momentânea das tensões durante a troca de condução entre os tiristores. Esse fenômeno pode afetar a qualidade da energia e pode ser mitigado por meio do uso de filtros harmônicos ou técnicas de modulação adequadas.

Figura 8 – Formas de onda da tensão de alimentação e da corrente de uma ponte de tiristores de seis pulsos com reator no lado de corrente contínua.



Fonte: [Baggini \(2008\)](#).

Retificador de Doze Pulsos

Retificadores de doze pulsos são empregados em sistemas que demandam menor distorção harmônica e maior qualidade de energia. Essa configuração combina duas pontes de seis pulsos conectadas em paralelo ou em série, com uma defasagem elétrica de 30 graus entre as tensões de entrada. A defasagem é obtida por transformadores com enrolamentos apropriados, como os tipos delta-estrela e delta-delta ([BAGGINI, 2008](#)).


A principal vantagem dessa configuração é a redução significativa das harmônicas de baixa ordem. As componentes deslocam-se para ordens $12n \pm 1$, como a 11ª e a 13ª, seguidas pela 23ª e a 25ª, minimizando o impacto das harmônicas na rede elétrica. Isso aumenta a eficiência do sistema e reduz os requisitos de filtragem ([BAGGINI, 2008](#)).

2.1.2.5 Reatores Controlados por Tiristores

Os Reatores Controlados por Tiristores (TCRs) são compostos por reatores em série com pares bidimensionais de tiristores. A corrente nos reatores pode ser controlada continuamente, ajustando o ângulo de disparo dos tiristores, o que permite controlar facilmente a potência reativa absorvida ([MATHUR; VARMA, 2002](#)). Esses dispositivos são amplamente utilizados em instalações industriais e grandes subestações, onde contribuem para a estabilização de tensão, redução de sobretensões temporárias, melhoria da estabilidade, amortecimento de oscilações

de potência e balanceamento de carga (GOMEZ-EXPOSITO ANTONIO CONEJO, 2018). A estrutura do TCR e sua forma de onda estão mostradas na Figura 9.

Figura 9 – TCR e suas formas de onda.



Fonte: Gomez-Exposito Antonio Conejo (2018).

O ângulo de disparo do tiristor (α) no TCR normalmente varia entre 90° e 180° , sendo definido a partir do cruzamento com zero da tensão nos terminais do tiristor. Quando $\alpha = 90^\circ$, os tiristores entram em condução imediatamente após o cruzamento por zero da tensão, permitindo a passagem completa da corrente senoidal pelo TCR. Já em $\alpha = 180^\circ$, os tiristores não conduzem, resultando em corrente nula.


Para valores intermediários de α , a condução ocorre apenas em parte do semiciclo, o que provoca distorções na forma de onda da corrente. Como essas distorções são simétricas nos semiciclos positivo e negativo, apenas harmônicos de ordens ímpares são gerados (MATHUR; VARMA, 2002). Além disso, diferentes componentes harmônicas surgem para cada valor de α , sendo que a amplitude relativa de cada harmônico em relação à corrente nominal depende diretamente do ângulo de disparo, conforme ilustrado na Figura 10.

2.1.2.6 Conversores Estáticos de Frequência

Os Conversores Estáticos de Frequência (SFCs, do inglês *Static Frequency Converters*) são dispositivos eletrônicos de potência amplamente utilizados em aplicações industriais e sistemas de potência, como a partida de motores síncronos, o controle de velocidade de máquinas elétricas e a interconexão de redes com frequências distintas (WANG; JIANG, 2011). A principal função do SFC é converter energia de corrente alternada (CA) de uma frequência para outra de forma eficiente e controlada.

Um SFC é composto por um retificador que converte a corrente alternada em corrente contínua, um circuito intermediário que armazena e suaviza a energia utilizando elementos como indutores ou capacitores, e um inversor que reconverte a energia em corrente alternada com a frequência desejada. Em sistemas modernos, o controle eletrônico, baseado em técnicas

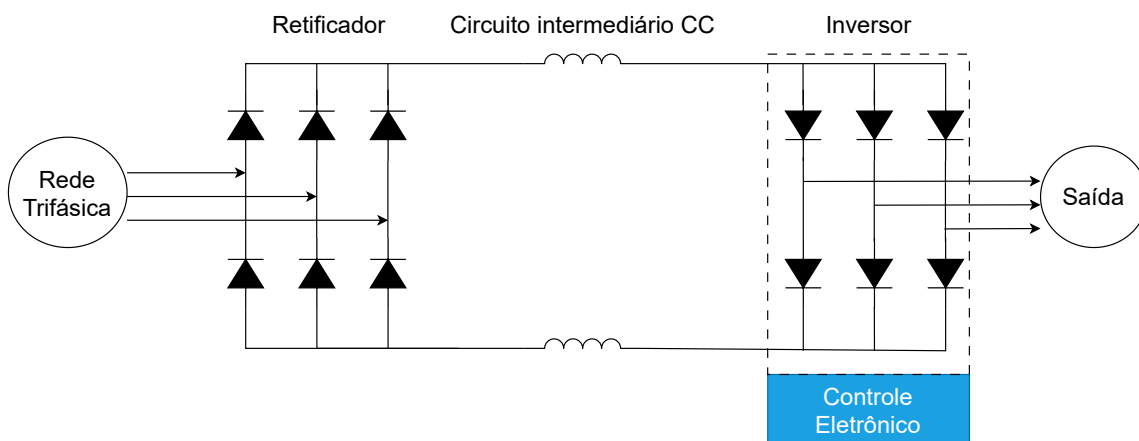
Figura 10 – Harmônicos em uma corrente de TCR.



Fonte: Mathur e Varma (2002).

de PWM, é amplamente utilizado para ajustar dinamicamente a frequência e a amplitude da tensão de saída, garantindo maior precisão e flexibilidade operacional (WANG; JIANG, 2011). A Figura 11 ilustra a estrutura típica de um SFC.


Figura 11 – Estrutura típica de um SFC.



Fonte: Autoria própria.

Apesar de suas vantagens, os SFCs apresentam o problema de injeção de correntes harmônicas na saída, principalmente devido à operação do retificador e do inversor. Essas harmônicas podem causar distorções na forma de onda da tensão, impactando a qualidade de energia no sistema conectado. A Figura 12 apresenta a forma de onda da tensão medida no PAC com um SFC implementado, destacando a presença de distorções harmônicas (WANG; JIANG, 2011).

Figura 12 – Forma de onda da tensão medida no PAC com SFC implementado.



Fonte: Wang e Jiang (2011).

2.1.3 Efeitos das Distorções Harmônicas

As tensões e as correntes harmônicas em sistemas elétricos de potência causam diversos impactos negativos, afetando tanto os equipamentos quanto a infraestrutura do sistema. Esses efeitos incluem a redução da vida útil dos dispositivos, falhas operacionais e custos elevados de manutenção.

Além disso, as distorções harmônicas aumentam as perdas energéticas, pois elevam a circulação de correntes não fundamentais no sistema, intensificando o efeito Joule nos condutores e transformadores. Esse fenômeno resulta em maior dissipação de calor, reduzindo a eficiência energética e exigindo sistemas de resfriamento mais robustos. Como consequência, há um aumento no consumo de energia e nos custos operacionais (ARRILLAGA; WATSON, 2003).

As distorções harmônicas também comprometem significativamente a economia industrial, visto que dispositivos eletrônicos e equipamentos modernos são altamente sensíveis a esses distúrbios.

Nas máquinas rotativas, a presença de harmônicos pode causar vibrações excessivas, aquecimento anômalo e esforços adicionais nos rolamentos e no eixo da máquina. Esses efeitos resultam em maior desgaste mecânico, aumento no consumo de energia e redução da eficiência do sistema. Além disso, a elevação da temperatura devido às perdas adicionais no estator e no rotor acelera o envelhecimento do isolamento, impactando a confiabilidade e a vida útil do equipamento. Em aplicações industriais, esses problemas podem levar a paradas não programadas, aumentando os custos operacionais e afetando a produtividade (ARRILLAGA; WATSON, 2003).

Nos transformadores, as perdas por correntes parasitas aumentam proporcionalmente ao quadrado da ordem harmônica, causando superaquecimento que acelera a degradação do isolamento e reduz a vida útil do equipamento. Adicionalmente, harmônicos de sequência zero podem circular nos enrolamentos conectados em delta, intensificando as perdas e exigindo maior esforço do sistema de resfriamento (ARRILLAGA; WATSON, 2003).

Nas instalações elétricas, o condutor neutro é especialmente vulnerável, pois as correntes

harmônicas de sequência zero, oriundas das fases do sistema, somam-se nesse condutor. Essa sobrecarga gera perdas adicionais pelo efeito Joule, causando aquecimento que, em casos extremos, pode levar a falhas térmicas, derretimento do condutor ou até incêndios (DAS, 2015).

Os sistemas de medição, como relés e medidores, também sofrem os efeitos das distorções harmônicas. Essas interferências podem tornar as medições de tensão e corrente imprecisas, levando a leituras incorretas e comprometendo o funcionamento dos dispositivos de proteção. Isso pode resultar tanto em disparos indevidos quanto na falha em detectar situações críticas (DAS, 2015). Além disso, equipamentos eletrônicos como controladores, inversores e sistemas de automação são especialmente sensíveis a esses distúrbios. Problemas como mau funcionamento, aumento na taxa de falhas e reinicializações frequentes podem ocorrer, afetando diretamente a produtividade em ambientes industriais e comerciais.

Os medidores de faturamento também são impactados pelas distorções harmônicas, principalmente devido à ausência de um protocolo universal padronizado para a medição de energia elétrica. Cada fabricante desenvolve algoritmos próprios para o processamento dos sinais de tensão e corrente, o que pode resultar em diferenças nos métodos de cálculo e, conseqüentemente, em discrepâncias na energia medida. Em Rodrigues (2009), experimentos demonstram que medidores de diferentes fabricantes podem registrar valores significativamente distintos ao serem submetidos ao mesmo sinal com conteúdo harmônico, evidenciando a influência dos algoritmos de medição na quantificação do consumo energético. Essas variações podem afetar diretamente a tarifação elétrica, gerando distorções nos custos tanto para consumidores quanto para concessionárias de energia.

Nos sistemas elétricos, as correntes harmônicas geram aquecimento excessivo e perdas adicionais nos cabos, sendo o efeito pelicular um dos principais responsáveis por esses impactos. Esse fenômeno, intensificado em frequências mais elevadas, faz com que a corrente elétrica se concentre na superfície do condutor, reduzindo sua área útil efetiva. Como consequência, há um aumento da resistência elétrica e um desgaste acelerado do material. Além disso, as distorções harmônicas podem degradar o isolamento dos cabos, provocando rupturas dielétricas que comprometem a integridade das linhas (DAS, 2015).

O efeito pelicular refere-se à tendência das correntes alternadas de se concentrarem nas camadas externas do condutor à medida que a frequência aumenta. Embora seja geralmente desprezível na frequência fundamental, torna-se significativo em frequências superiores a 350 Hz, conforme indicado por Baggini (2008). Esse comportamento resulta em perdas adicionais por aquecimento e impacta diretamente a eficiência do condutor e o desempenho do sistema. O grau de penetração da corrente pode ser estimado pela equação:

$$\delta = \sqrt{\frac{2\rho}{\mu\omega}} \quad (2.4)$$

na qual δ representa o grau de penetração, ρ é a resistividade do material do cabo, μ a permeabilidade magnética e ω a frequência angular.

Além das perdas nos cabos, os harmônicos também elevam a probabilidade de ressonâncias entre bancos de capacitores e o sistema elétrico. Essa interação amplifica os níveis de distorção harmônica, sobrecarrega os capacitores e reduz sua vida útil. Em situações extremas, as ressonâncias podem provocar falhas catastróficas ou até explosões nos capacitores, comprometendo a estabilidade do sistema elétrico (DAS, 2015).

A ressonância ocorre quando a frequência de excitação de um sistema coincide com sua frequência natural, resultando em uma amplificação significativa da resposta. No contexto da ressonância harmônica, esse fenômeno se manifesta quando a frequência de um harmônico coincide com a frequência natural da rede elétrica. Essa rede é composta por elementos resistivos (cabos), indutivos (transformadores e reatores) e capacitivos (bancos de capacitores), os quais influenciam diretamente o comportamento das ressonâncias (BAGGINI, 2008).

A ressonância harmônica pode ser classificada em dois tipos principais: série e paralela. Na ressonância série, as reatâncias capacitiva e indutiva se anulam, reduzindo a impedância do sistema ao valor da resistência elétrica. Isso resulta em uma amplificação da corrente elétrica e, conseqüentemente, em um aumento da distorção harmônica. Quando a frequência de um harmônico coincide com a frequência ressonante do sistema, a corrente harmônica sofre amplificação adicional, exacerbando a distorção e podendo levar a sobrecargas nos equipamentos.

Por outro lado, na ressonância paralela, a admitância do sistema diminui, promovendo a amplificação da tensão. Quando a frequência de um harmônico coincide com a frequência ressonante do sistema, a tensão harmônica é amplificada significativamente. Esse aumento pode intensificar a distorção da rede e comprometer a estabilidade do sistema, especialmente em dispositivos sensíveis conectados a ele (BAGGINI, 2008).

Tanto a ressonância série quanto a paralela podem gerar efeitos prejudiciais consideráveis, incluindo aquecimento excessivo, falhas em equipamentos, aumento das perdas elétricas e redução da vida útil dos componentes. Portanto, a análise e mitigação desses fenômenos são essenciais para garantir a confiabilidade e segurança dos sistemas elétricos.


2.2 Distorções Harmônicas em Microrredes e Análise de Contribuição Harmônica

Microrredes (MRs) são sistemas autônomos e interconectados que integram cargas, fontes distribuídas de energia e/ou sistemas de armazenamento, possibilitando o fornecimento de energia de maneira controlada, eficiente e local (LASSETER, 2002). Além de oferecerem maior resiliência e flexibilidade, as MRs podem operar tanto conectadas à rede principal quanto ilhadas, garantindo a continuidade no fornecimento de energia em situações adversas, como

falhas na rede elétrica (OLIVARES *et al.*, 2014).

Sua implementação permite uma gestão eficiente da geração e do consumo de energia, reduzindo as emissões de carbono e promovendo o conceito de redes inteligentes (*smart grids*). A Figura 13 ilustra um diagrama simplificado de uma MR conectada à rede elétrica principal, destacando suas possíveis aplicações em contextos industriais, comerciais e residenciais.

Figura 13 – Diagrama de interconexão de MR com a rede elétrica principal.



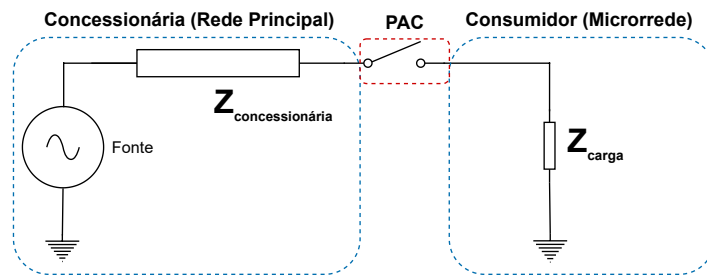
Fonte: Autoria própria.

Embora as MRs ofereçam benefícios significativos, como a redução de emissões, maior confiabilidade no fornecimento de energia e flexibilidade operacional, sua operação apresenta desafios técnicos, especialmente no que se refere à QEE. A presença de geradores distribuídos baseados em inversores, bem como cargas não lineares pode acarretar no aumento dos níveis de distorções harmônicas para patamares indesejáveis (KHAN; VIJAY; DOOLLA, 2022).

Um aspecto crítico na análise de distorções harmônicas é o Ponto de Acoplamento Comum (PAC), que conecta a MR à rede da concessionária. O PAC é o local onde a QEE é monitorada e onde as distorções harmônicas são avaliadas em conformidade com os limites regulatórios estabelecidos por normas técnicas (LIU; XU, 2000). A Figura 14 apresenta um diagrama do PAC.

Assim, para assegurar a QEE fornecida, existem regulamentações que estabelecem limites máximos aceitáveis para a THD da tensão, os quais serão detalhados na próxima seção. No entanto, quando os níveis de THD ultrapassam esses limites, emerge um desafio complexo: a determinação da origem das distorções harmônicas, ou seja, identificar o responsável pela maior contribuição à distorção harmônica vista do PAC.

Figura 14 – Diagrama do PAC.



Fonte: Autoria própria.

As MRs, devido à natureza não linear de suas componentes, tendem a drenar correntes harmônicas que irão se propagar através do PAC e afetar a rede principal. Por outro lado, a rede da concessionária também pode contribuir para o nível de distorção observado no PAC, especialmente em sistemas que já apresentam níveis de distorção elevados. Essa dualidade dificulta a avaliação precisa de qual parte do sistema apresenta a maior contribuição pela distorção harmônica medida no PAC (PFAJFAR; BLAZIC; PAPIC, 2008).

Nos últimos anos, estudos focados em incentivos financeiros foram propostos com o intuito de manter os níveis de distorção harmônica dentro dos limites aceitáveis (MCEACHERN *et al.*, 1995). Tais estudos atribuem responsabilidades às fontes que contribuem significativamente para a THD. Entretanto, a eficácia deles depende diretamente da capacidade de medir e identificar, com precisão, a origem das distorções harmônicas. Essa identificação é particularmente desafiadora em MRs devido à complexidade de suas configurações em termos de componentes e do tipo de condição operacional da mesma.

Ademais, sem uma identificação precisa da origem dessas distorções, ações corretivas podem ser ineficazes ou até injustas, atribuindo responsabilidades incorretas a uma das partes. Para mitigar esses problemas, são necessárias abordagens robustas que considerem o comportamento dinâmico do sistema e a interação entre a MR e a rede principal.

Portanto, o desafio de gerenciar as distorções harmônicas em MRs reside tanto na mitigação dos impactos dessas distorções quanto na atribuição precisa de responsabilidades. Técnicas avançadas de monitoramento e controle, combinadas com regulamentações claras, são essenciais para garantir a operação eficiente e sustentável de MRs, promovendo um equilíbrio justo entre consumidores e concessionárias.

2.3 Regulamentações e Normativas sobre Distorções Harmônicas

Conforme previamente destacado, a QEE é fundamental para garantir o funcionamento adequado e seguro dos sistemas elétricos, especialmente no contexto de MRs. Assim, para

assegurar a QEE entregue aos consumidores, diversas regulamentações e normativas foram desenvolvidas em âmbito nacional e internacional. Muitas delas estabelecem limites claros para distorções harmônicas. Portanto, o cumprimento dessas normativas é essencial não apenas para proteger os equipamentos conectados à rede, mas também para preservar a confiabilidade e a eficiência do sistema elétrico como um todo.

Diversas organizações têm desempenhado um papel central na elaboração de diretrizes sobre QEE. Entre elas, destacam-se o IEC, o IEEE e a ANEEL.

2.3.1 Diretrizes determinadas pelo IEC

O IEC é reconhecido globalmente pela padronização de normas técnicas. No contexto das distorções harmônicas, o IEC define limites para a emissão de correntes harmônicas de equipamentos elétricos. Normas como a IEC 61000-3-2 (IEC, 2014) e IEC 61000-3-4 (IEC, 1998) especificam os níveis máximos permitidos de emissões harmônicas. Essas normas são amplamente utilizadas em projetos de MRs, garantindo que os equipamentos respeitem limites adequados de distorção.

2.3.2 Diretrizes determinadas pelo IEEE

O IEEE estabelece diretrizes para o controle de harmônicos em sistemas elétricos, com destaque para a norma IEEE 519 (IEEE, 2014). Essa norma define critérios para a qualidade da energia elétrica, abordando:

- **Fontes de harmônicos** – identificação de equipamentos que geram distorções, como inversores de frequência, retificadores e cargas não lineares;
- **Limites de distorção** – valores aceitáveis para a THD e harmônicas individuais na tensão e na corrente, conforme mostrado nas Tabelas 2 e 3;
- **Métodos de análise** – diretrizes para a avaliação de sistemas sujeitos a correntes harmônicas e recomendações para mitigação dessas distorções.

Tabela 2 – Limites de distorção harmônica na tensão segundo a norma IEEE 519.

Nível de Tensão	Harmônicas Individuais (%)	THD (%)
$V < 69 \text{ kV}$	3,0	5,0
$69 \text{ kV} \leq V < 161 \text{ kV}$	1,5	2,5
$V \geq 161 \text{ kV}$	1,0	1,5

Fonte: IEEE (2014).

A IEEE 519 também define limites para a distorção harmônica na corrente elétrica, considerando a relação entre a corrente harmônica injetada e a corrente de curto-circuito no PAC, conforme apresentado na Tabela 3.

Tabela 3 – Limites de distorção harmônica na corrente conforme a relação I_h/I_{sc} .

Relação I_h/I_{sc}	THD de Corrente (%)
$< 20\%$	5,0
$20\% \leq I_h/I_{sc} < 50\%$	8,0
$50\% \leq I_h/I_{sc} < 100\%$	12,0
$100\% \leq I_h/I_{sc} < 1000\%$	15,0
$\geq 1000\%$	20,0

Fonte: IEEE (2014).

Além dos limites globais para a THD, a norma estabelece restrições específicas para componentes harmônicos individuais na corrente elétrica, dependendo da ordem harmônica (h), como ilustrado na Tabela 4.

Tabela 4 – Limites para harmônicas individuais na corrente.

Ordem Harmônica (h)	Máximo Permitido (% da I_{sc})
$h = 3, 5, 7, 9, 11, 13$	4,0
$h = 15, 17, 19, 21, 23, 25$	2,0
$h > 25$	0,6

Fonte: IEEE (2014).

Os valores apresentados visam garantir que a qualidade da energia elétrica seja mantida dentro de padrões aceitáveis, minimizando os impactos das distorções harmônicas em sistemas industriais e comerciais. A implementação dessas diretrizes contribui para a redução de perdas, aumento da vida útil dos equipamentos e melhoria da confiabilidade do sistema elétrico.

2.3.3 Diretrizes da ANEEL

No Brasil, a ANEEL estabelece diretrizes para a QEE por meio dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST), que definem limites para as distorções harmônicas em diferentes níveis de tensão. O Módulo 8 do PRODIST (PRODIST, 2021) trata especificamente das distorções harmônicas, diferenciando limites para THD e harmônicas individuais, além de segmentar as ordens pares e ímpares.

A regulamentação específica que as distorções harmônicas devem ser controladas para garantir a confiabilidade e a qualidade da energia elétrica fornecida aos consumidores. Para isso, são estabelecidos limites máximos para a distorção harmônica total (THD) e para cada componente harmônica individualmente, conforme apresentado nas tabelas a seguir.

Além do limite para a distorção total, o PRODIST define valores máximos para as componentes harmônicas individuais, diferenciando entre ordens pares e ímpares, como mostrado nas tabelas abaixo.

Além dos limites numéricos, o PRODIST também especifica metodologias para medição e análise das distorções harmônicas, garantindo que os níveis de THD sejam avaliados de forma

Tabela 5 – Limites das distorções harmônicas totais na tensão fundamental.

Tensão Nominal do Barramento	THD de Tensão (%)
$V_n \leq 2,3 \text{ kV}$	10,0
$2,3 \text{ kV} < V_n < 69 \text{ kV}$	8,0
$69 \text{ kV} \leq V_n < 230 \text{ kV}$	5,0

Fonte: PRODIST (2021).

Tabela 6 – Limites de distorção harmônica de tensão (%) para componentes individuais ímpares.

Ordem	$V_n \leq 2,3 \text{ kV}$	$2,3 \text{ kV} < V_n < 69 \text{ kV}$	$69 \text{ kV} \leq V_n < 230 \text{ kV}$
3 ^a a 9 ^a	7,5	6,0	4,0
11 ^a a 15 ^a	5,0	4,0	2,5
17 ^a a 21 ^a	4,0	3,0	2,0
23 ^a a 33 ^a	2,0	1,5	1,0

Fonte: PRODIST (2021).

Tabela 7 – Limites de distorção harmônica para componentes individuais pares.

Ordem	$V_n \leq 2,3 \text{ kV}$	$2,3 \text{ kV} < V_n < 69 \text{ kV}$	$69 \text{ kV} \leq V_n < 230 \text{ kV}$
2 ^a a 8 ^a	2,5	2,0	1,0
10 ^a a 16 ^a	1,5	1,0	0,75
18 ^a a 22 ^a	1,0	0,75	0,5
24 ^a a 34 ^a	0,5	0,3	0,2

Fonte: PRODIST (2021).

padronizada. Essas diretrizes são fundamentais para assegurar que consumidores e concessionárias de energia cumpram as exigências regulatórias, minimizando impactos negativos na rede elétrica e nos equipamentos conectados.

2.3.4 Desafios quanto ao cumprimento de normas e recomendações

Embora as normas estabeleçam limites para a THD, elas não especificam de forma clara a responsabilidade sobre a origem dessas distorções. Isso gera um desafio técnico significativo, especialmente em PACs, onde tanto a MR quanto a rede principal podem contribuir para o nível de THD. Ademais, a atribuição de responsabilidades é crucial para mitigar disputas entre concessionárias e operadores de MRs.

Conforme mencionado, diversos métodos tradicionais têm sido propostos para lidar com essa questão, mas enfrentam limitações devido à complexidade do sistema e à dificuldade de obtenção precisa das impedâncias envolvidas. Nesse contexto, considerando que estudos recentes demonstraram bons resultados ao aplicar aprendizado de máquina para a identificação da contribuição harmônica, o presente trabalho adota essa abordagem como alternativa para superar os desafios existentes.

2.4 Aprendizado de Máquina

Nesse trabalho, foi adotada uma abordagem baseada em aprendizado de máquina para determinar o lado de maior contribuição harmônica às distorções medidas no PAC da MR. Portanto, na sequência, são apresentados os conceitos fundamentais relacionados a aprendizado de máquina e que permeiam as técnicas usadas nesta dissertação.

A princípio, é importante destacar que o aprendizado de máquina corresponde a uma subárea da inteligência artificial que se concentra no desenvolvimento de algoritmos e modelos que capacitam sistemas computacionais a aprender e tomar decisões com base em dados, eliminando a necessidade de programação explícita para a execução de tarefas específicas (JHAVERI *et al.*, 2022). Assim, as técnicas de aprendizado de máquina podem ser divididas em:

1. **Aprendizado Supervisionado** – os modelos são treinados usando um conjunto de dados rotulados, onde cada exemplo inclui uma entrada (ou conjunto de características) e a saída desejada (rótulo ou alvo). O objetivo é aprender uma função que relacione as entradas às saídas, de modo que o modelo possa realizar previsões precisas para novos dados não rotulados (JHAVERI *et al.*, 2022);
2. **Aprendizado Não Supervisionado** – os modelos são treinados em conjuntos de dados não rotulados, buscando descobrir estruturas ou padrões ocultos nos dados, como agrupamentos (*clustering*) ou redução de dimensionalidade (JHAVERI *et al.*, 2022);
3. **Aprendizado Semi-supervisionado** – combina elementos de aprendizado supervisionado e não supervisionado. Nessa abordagem, o modelo é treinado utilizando um pequeno conjunto de dados rotulados e um grande conjunto de dados não rotulados. A ideia principal é aproveitar a estrutura presente nos dados não rotulados para melhorar o desempenho do modelo, reduzindo a necessidade de rotulação manual de grandes volumes de dados (JHAVERI *et al.*, 2022);
4. **Aprendizado por Reforço** – os modelos aprendem por meio de interações com um ambiente, realizando ações que maximizam uma recompensa cumulativa ao longo do tempo. Esses modelos são frequentemente utilizados em tarefas de controle (JHAVERI *et al.*, 2022).

Considerando essas categorias de aprendizado de máquina, nessa dissertação optou-se por uma abordagem baseada no aprendizado supervisionado, ou seja, houve a necessidade prévia de realizar uma etapa de rotulação das medições realizadas no PAC da MR. Tal rotulação foi realizada para atribuir de forma manual uma classe, ou seja, se a fonte harmônica de maior predominância às distorções estava no lado da MR ou da rede principal.

Foram escolhidos os modelos *Random Forest* e *XGBoost* devido à sua alta precisão, robustez e capacidade de resolver problemas complexos de classificação. Esses modelos são

eficazes na identificação de características relevantes, o que contribui para a estimação precisa das contribuições harmônicas no sistema.

No entanto, é fundamental monitorar o risco de *overfitting*, um fenômeno em que o modelo se ajusta excessivamente aos dados de treinamento, capturando padrões espúrios e perdendo capacidade de generalização para novos dados. Esse problema é especialmente relevante em conjuntos de dados com muitas variáveis ou ao utilizar hiperparâmetros que aumentem a complexidade do modelo. Para mitigar esse risco, técnicas como validação cruzada e regularização são empregadas ao longo do processo de modelagem.

Na sequência, são explanados os conjuntos de dados usados para o treinamento e a validação, bem como os algoritmos empregados.

2.4.1 Treinamento de Modelos Supervisionados

Para realizar o treinamento desses modelos, inicialmente deve-se utilizar um conjunto de dados rotulado, conforme previamente mencionado. Portanto, deve-se conhecer a relação entre o dado de entrada e o rótulo de saída. Com isso, uma parcela (entre 60% e 80%) desse conjunto de dados deve ser necessariamente usada no treinamento do modelo.

Durante essa fase, o modelo ajusta seus parâmetros com base nos dados de entrada e nos rótulos correspondentes. O objetivo é aprender as relações e padrões entre as variáveis de entrada e saída, minimizando o erro entre as predições do modelo e os rótulos reais. Essa etapa é crucial, pois é onde o modelo aprende e se adapta aos dados, podendo, no entanto, entrar em *overfitting*, ou seja, caso os dados não garantam a generalização do modelo.

2.4.2 Validação de Modelos Supervisionados

Após realizado o treinamento do modelo, o restante dos dados rotulados é usado para validar o modelo, ou seja, para avaliar o desempenho do mesmo quanto à generalização de seu ajuste. Nesse caso, os rótulos não são apresentados ao modelo, conforme feito no treinamento. Porém, são usados para confrontar com as respostas do modelo para os dados de entrada, permitindo que métricas de avaliação de desempenho possam ser usadas.

Ainda é possível observar a ocorrência de *overfitting* na validação, pois o modelo normalmente apresentará uma excelente convergência quanto ao ajuste de seus hiperparâmetros no treinamento, porém não será hábil a apresentar respostas coerentes com o esperado para o conjunto de validação. Portanto, diz-se que o modelo não tem capacidade de generalização.

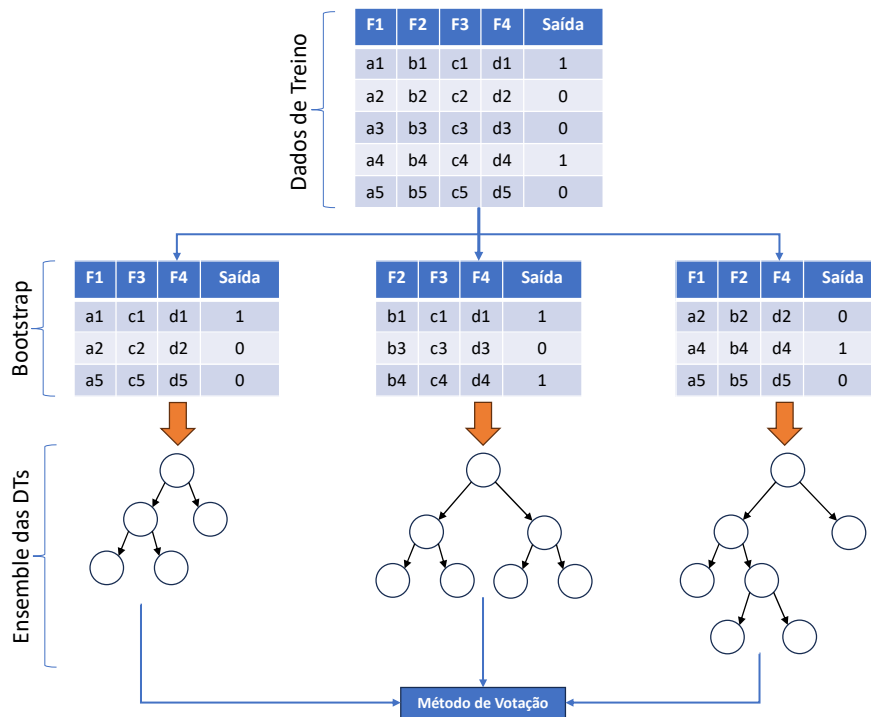
2.4.3 Random Forest

Uma *Random Forest* é um algoritmo de aprendizado supervisionado que se baseia em um conjunto de árvores de decisão (*Decision Trees* (DTs)). Este algoritmo pertence à classe dos

métodos de *ensemble*, que combinam os resultados de múltiplos modelos para produzir previsões mais robustas e precisas do que uma única árvore de decisão isolada (BREIMAN, 2001). A *Random Forest* foi projetada para superar limitações dos modelos de árvore, como o excesso de ajuste (*overfitting*), que é comum em árvores de decisão profundas e complexas (BREIMAN, 2001).

O processo de treinamento na *Random Forest* ocorre em três etapas principais: a criação das árvores individuais com amostras de *bootstrap*, o uso de um *ensemble* com seleção aleatória de características, e a votação para determinar a classe final. Esse processo é ilustrado na Figura 15, onde se observa a utilização do *bootstrap* e do *ensemble* de DTs.

Figura 15 – Geração de um conjunto de árvores de decisão no framework *Random Forest*.



Fonte: Autoria própria.

Para criar o conjunto de árvores, a *Random Forest* utiliza uma técnica de *bootstrap*, na qual diversas amostras são extraídas aleatoriamente do conjunto de dados original com reposição (EFRON; TIBSHIRANI, 1994). Esse processo gera múltiplas amostras de treinamento diferentes, permitindo que cada árvore de decisão seja treinada em uma versão única e ligeiramente alterada dos dados. Essa variação nos dados de treinamento reduz a correlação entre as árvores e aumenta a capacidade do modelo de generalizar para dados novos. Cada árvore na *Random Forest* é treinada de forma independente das demais, sendo construída a partir de uma estrutura de divisão recursiva, onde cada nó é separado com base em uma função de ganho de informação, como a entropia ou o índice de Gini (EFRON; TIBSHIRANI, 1994).

Durante a construção de cada árvore, a *Random Forest* seleciona aleatoriamente um subconjunto de características para avaliar em cada nó. Essa técnica, conhecida como *ensemble*,

serve para reduzir a correlação entre as árvores, pois árvores diferentes consideram distintas combinações de características para suas divisões (LIAW; WIENER, 2002). Ao mitigar a influência de características dominantes, a *Random Forest* produz árvores de decisão que se concentram em aspectos distintos dos dados, diminuindo assim o risco de *overfitting*, uma vez que cada árvore se torna menos sensível a variáveis específicas.

Após o treinamento, cada árvore na *Random Forest* realiza uma predição individual para uma nova instância de entrada. A classe final é determinada pelo voto majoritário, ou seja, a classe mais comum entre as predições de todas as árvores é escolhida como a predição final do modelo. Essa abordagem de votação cria um efeito de suavização, onde as flutuações e incertezas de cada árvore são equilibradas pela contribuição de múltiplas árvores, resultando em uma predição mais precisa e estável (BREIMAN, 2001).

Os principais parâmetros da *Random Forest* que impactam seu desempenho incluem:

- **Número de árvores** ($n_estimators$) – determina a quantidade de árvores no conjunto. Um número maior de árvores tende a aumentar a estabilidade e a precisão do modelo, embora também eleve o custo computacional;
- **Profundidade máxima da árvore** (max_depth) – define o número máximo de divisões em cada árvore. Profundidades maiores permitem que o modelo capture relações complexas, mas podem levar ao *overfitting*;
- **Número de características a considerar em cada Divisão** ($max_features$) – controla a quantidade de variáveis analisadas para a divisão de cada nó. Esse parâmetro é crucial para reduzir a correlação entre as árvores, promovendo maior diversidade no conjunto.
- **Mínimo de amostras para divisão** ($min_samples_split$) – especifica o número mínimo de amostras necessárias para realizar uma divisão em um nó. Valores altos podem resultar em árvores menos complexas e mais generalizáveis, enquanto valores baixos aumentam a profundidade das árvores, podendo levar ao *overfitting*;
- **Mínimo de amostras na folha** ($min_samples_leaf$) – define o número mínimo de amostras que um nó folha deve ter. Um valor maior exige mais dados para que um nó seja considerado uma folha, o que pode ajudar a reduzir o *overfitting* em amostras pequenas.

A *Random Forest* possui características vantajosas frente a outras técnicas, como: robustez contra *overfitting*; alta precisão e generalização; capacidade de calcular a importância das variáveis; e resiliência a dados ruidosos e ausentes.

2.4.4 XGBoost

O *XGBoost* (*eXtreme Gradient Boosting*) é um algoritmo baseado em *gradient boosting*, conhecido por sua eficiência e desempenho (CHEN; GUESTRIN, 2016). Ao contrário da *Random Forest*, que constrói árvores de forma independente, o *XGBoost* cria árvores sequencialmente, ajustando-se aos erros das anteriores. Esse processo progressivo permite que o modelo aprenda padrões complexos, minimizando os resíduos (diferenças entre as previsões e os valores reais) em cada iteração.

Uma característica importante do *XGBoost* é sua capacidade de aplicar regularização L1 e L2, o que ajuda a controlar a complexidade do modelo e reduzir o risco de *overfitting*, especialmente em conjuntos de dados com alta dimensionalidade (ALI *et al.*, 2023). A regularização ajuda a simplificar as árvores e melhora a generalização em dados novos.

Além disso, o *XGBoost* se destaca pela eficiência computacional, utilizando processamento paralelo para acelerar o treinamento e otimizações para lidar com dados esparsos e valores ausentes.

Os principais hiperparâmetros que influenciam o desempenho do *XGBoost* incluem:

- **Número de árvores (*n_estimators*)** – define quantas árvores serão construídas. Um número maior pode melhorar a precisão, mas aumenta o risco de *overfitting* se não for controlado adequadamente;
- **Profundidade máxima das árvores (*max_depth*)** – determina a profundidade máxima das árvores. Maior profundidade permite capturar interações mais complexas, mas pode levar ao *overfitting*.
- **Taxa de aprendizado (*learning_rate*)** – controla o quanto cada árvore ajusta as previsões anteriores. Taxas menores favorecem um aprendizado mais gradual e podem melhorar a generalização;
- **Fração de amostras (*subsample*)** – define a fração de amostras usadas para treinar cada árvore, introduzindo aleatoriedade para reduzir o risco de *overfitting*;
- **Fração de colunas por árvore (*colsample_bytree*)** – define a fração de colunas usadas para construir cada árvore, aumentando a diversidade e reduzindo a correlação entre as previsões;
- **Redução mínima na função de perda (*gamma*)** – controla a redução mínima na função de perda necessária para realizar uma divisão. Valores maiores tornam o modelo mais conservador, gerando árvores menos complexas;
- **Regularização L1 (*reg_alpha*)** – controla a regularização L1, favorecendo modelos mais esparsos e reduzindo o impacto de variáveis irrelevantes;

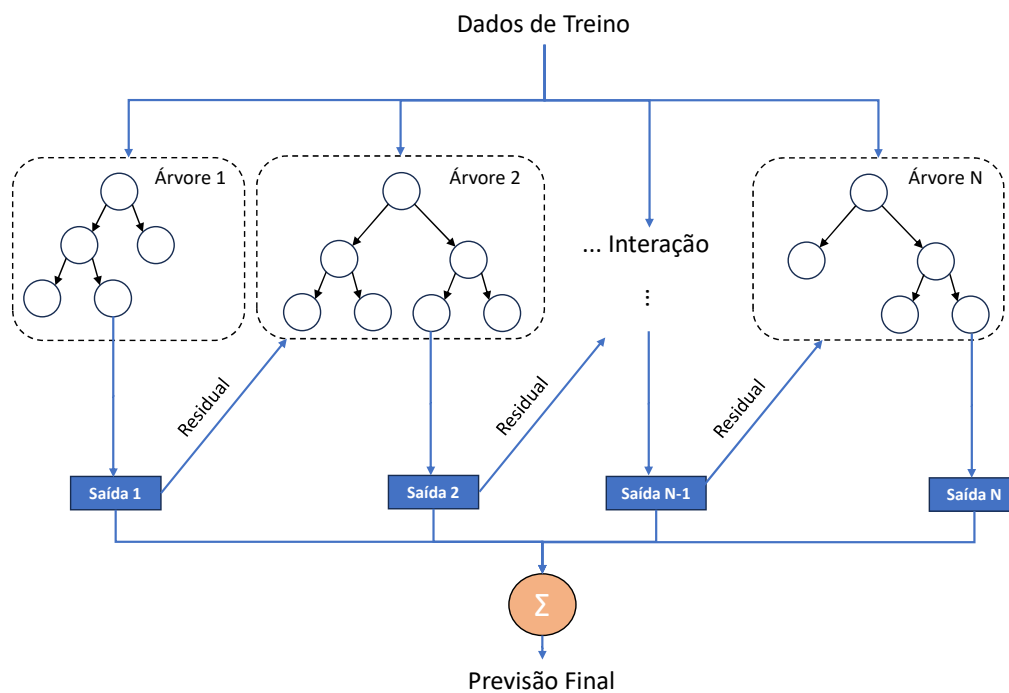
- **Regularização L2 (*reg_lambda*)** – controla a regularização L2, prevenindo *overfitting* ao limitar a magnitude dos coeficientes.

O *XGBoost* combina as previsões de todas as árvores construídas, ajustando-as ponderadamente para maximizar a precisão. Isso permite capturar interações complexas entre variáveis e gerar previsões precisas.

Entre as vantagens do *XGBoost*, destacam-se a capacidade de lidar com dados ausentes de maneira eficiente, o suporte à regularização e o alto desempenho em grandes volumes de dados (ALI *et al.*, 2023).

A Figura 16 ilustra o fluxo do algoritmo, demonstrando como cada árvore ajusta as previsões com base nos resíduos das anteriores.

Figura 16 – Fluxograma ilustrando o algoritmo *XGBoost*.



Fonte: Autoria própria.

REVISÃO BIBLIOGRÁFICA

A identificação das fontes de harmônicos em sistemas elétricos de potência é um desafio em curso, ou seja, ainda está sendo estudado e não foi completamente esclarecido. Diversos métodos foram propostos com o objetivo de analisar as contribuições harmônicas em PACs de sistemas de distribuição de energia elétrica.

Este capítulo realiza uma revisão bibliográfica sobre as principais produções científicas na área de pesquisa. O intuito é destacar as técnicas empregadas para determinar a responsabilidade e contribuição quanto às distorções harmônicas.

3.1 Principais métodos para identificação da contribuição harmônica

3.1.1 Método da Direção de Potência Ativa

O Método da Direção de Potência Ativa, desenvolvido por [Cristaldi e Ferrero \(1995\)](#), é amplamente discutido na literatura como uma abordagem eficaz para a localização de componentes harmônicos em sistemas de energia. Este método baseia-se na premissa de que determinadas componentes harmônicas possuem uma parcela ativa, o que permite identificar a direção da injeção de potência harmônica. Para uma melhor compreensão, a Figura 17 apresenta um circuito no qual as variáveis Z_u e I_u representam, respectivamente, a impedância e a fonte de corrente da concessionária, enquanto Z_c e I_c simbolizam o lado do consumidor. Para cada ordem harmônica de interesse, os autores propuseram um circuito equivalente, com parâmetros distintos para a concessionária e o consumidor, conforme ilustrado na referida figura.

No contexto do PAC, são realizadas medições de tensão e corrente para determinar a direção da potência ativa. A potência harmônica é calculada pela seguinte expressão:

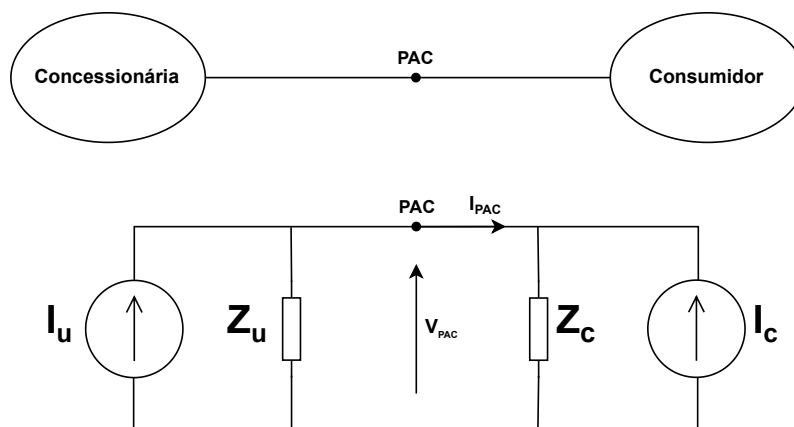
$$P = \text{Re} (V_{pac} \cdot \dot{I}_{pac}^*), \quad (3.1)$$

em que Re representa a parte real do número complexo resultante da multiplicação dos fasores de corrente I_{pac} e de V_{pac} , e o sobrescrito (*) indica o conjugado complexo. O método baseia-se na análise da forma de onda da potência ativa P , e as conclusões podem ser interpretadas da seguinte forma:

- Se $P > 0$, indica que a concessionária tem uma participação mais significativa ou equivalente na injeção dos componentes harmônicos de ordem h ;
- Se $P < 0$, sugere que o consumidor é o principal responsável pela injeção desses componentes harmônicos.

Embora [Cristaldi e Ferrero \(1995\)](#) não mencione explicitamente o caso em que $P = 0$, é possível inferir que, nesse cenário, não seria possível determinar a contribuição de cada lado, uma vez que a ausência de fluxo de potência ativa (ou seja, $P = 0$) indica que não há um envolvimento claro da concessionária ou do consumidor na injeção dos componentes harmônicos. A análise do método se concentra na identificação das fontes harmônicas, considerando os casos de $P > 0$ e $P < 0$ como indicadores de qual lado da rede tem maior responsabilidade na injeção de harmônicos.

Figura 17 – Circuito equivalente para o método da direção de potência ativa.



Fonte: Adaptado de [Xu, Liu e Liu \(2003\)](#).

Com base na explanação prévia, o Método da Direção de Potência Ativa pode ser formulado, sendo capaz de identificar as principais fontes de distorções harmônicas em um PAC e destacar as componentes harmônicas com maior impacto na distorção total. Contudo, é importante ressaltar que esse método não permite quantificar de forma precisa a contribuição de cada parte envolvida — consumidor e fornecedor — na distorção harmônica.

Esse método apresenta similaridades com a abordagem proposta por [Tanaka e Akagi \(1995\)](#), que também utiliza a direção da corrente e da potência para determinar o lado responsável pela contribuição harmônica, mas com base no cálculo instantâneo da potência ativa.

Em contrapartida, [Li, Xu e Tayjasant \(2002\)](#) sugerem substituir o cálculo de potências ativas pelo de potências reativas como alternativa metodológica. Além disso, a revisão bibliográfica realizada neste estudo aponta para a existência de outros procedimentos voltados à atribuição de responsabilidade pelas distorções no PAC.

Embora o Método da Direção de Potência Ativa tenha sido considerado, no passado, uma abordagem promissora para identificar distorções harmônicas em PACs entre concessionárias e consumidores, ele foi alvo de diversas críticas. Atualmente, não é amplamente reconhecido como o procedimento mais eficaz para atender às demandas do setor elétrico.


3.1.2 Método da Superposição Harmônica

Nesta subseção, exploram-se os princípios fundamentais do Método da Superposição Harmônica, uma técnica concebida por [Xu, Liu e Liu \(2003\)](#). Este método, enraizado em um princípio matemático amplamente reconhecido e comum na análise de circuitos elétricos, possibilita distribuir contribuições de várias fontes para uma corrente ou tensão em um ponto específico de uma rede elétrica.

Apesar de ser tradicionalmente aplicado à análise de circuitos lineares, é relevante notar que, mesmo diante das não linearidades presentes em distorções harmônicas, algumas fontes bibliográficas sugerem e aplicam esse método na análise de sistemas com esse tipo de distorção.

Com isso, a validade do método de direção de potência ativa é questionada por [Xu, Liu e Liu \(2003\)](#). A decomposição da corrente I_{pac} em dois componentes escalares reforça tal questionamento. Os autores afirmam que, para realizar a decomposição de I_{pac} , é necessário, inicialmente, decompor o circuito apresentado na Figura 17 em dois circuitos, como demonstrado na Figura 18.

Figura 18 – Circuito do método da potência ativa modificado por [Xu, Liu e Liu \(2003\)](#).



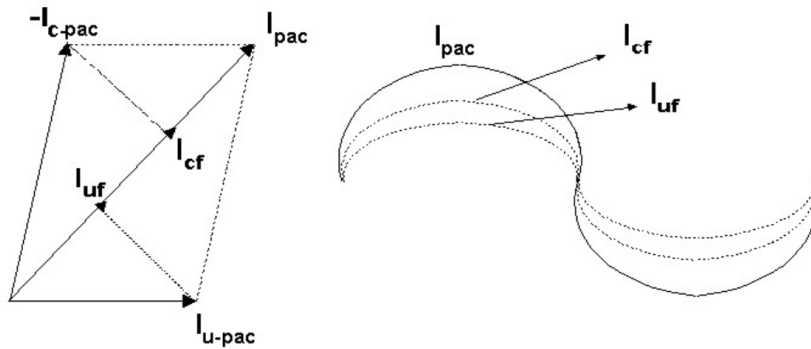
Fonte: Adaptado de [Xu, Liu e Liu \(2003\)](#).

A corrente I_{pac} , pelo princípio da superposição, é encontrada por:

$$I_{pac} = I_{u-pac} + (-I_{c-pac}). \quad (3.2)$$

Os fasores de corrente da equação (3.2) podem ser analisados por meio da decomposição ilustrada na Figura 19.

Figura 19 – Circuito do método da potência ativa modificado por Xu, Liu e Liu (2003).



Fonte: Adaptado de Xu, Liu e Liu (2003).

O módulo do fasor de corrente I_{pac} pode ser expresso como a soma de dois escalares:

$$|I_{pac}| = I_{cf} + I_{uf}, \quad (3.3)$$

em que, I_{cf} e I_{uf} representam as projeções em fase dos fasores I_{c-pac} e I_{u-pac} sobre I_{pac} .

As equações (3.2) e (3.3) podem ser reformuladas em termos da tensão medida no PAC. Dessa forma, para situações em que os valores das fontes de corrente do circuito equivalente não são conhecidos, é possível utilizar a tensão das fontes de tensão equivalentes, conforme apresentado na equação (3.4):

$$I_{pac} = \frac{E_u - E_c}{Z_u + E_c}, \quad (3.4)$$

em que E_u representa a fonte de tensão para o lado da concessionária e E_c representa a fonte de tensão referente ao lado do consumidor.

A argumentação de Xu, Liu e Liu (2003) destaca que os escalares I_{cf} e I_{uf} são os parâmetros que realmente caracterizam as contribuições de harmônicos de cada lado (consumidor e concessionária). Assim, em um exemplo monofásico, se a corrente I_{pac} tiver um módulo de 10 A, e os escalares em fase I_{cf} e I_{uf} forem 3 e 7 A, respectivamente, pode-se inferir, pelo método de Xu, Liu e Liu (2003), que a contribuição do lado da concessionária é de 30%, enquanto o consumidor contribui com 70%.

Com o propósito de evidenciar que o método da Direção da Potência Ativa pode resultar em interpretações equivocadas, Xu, Liu e Liu (2003) conduziram um teste no circuito baseado pela Figura 17, utilizando os seguintes parâmetros:

$$I_u = 1 \angle 0^\circ pu, \quad Z_u = 1 + j \cdot 8 pu,$$

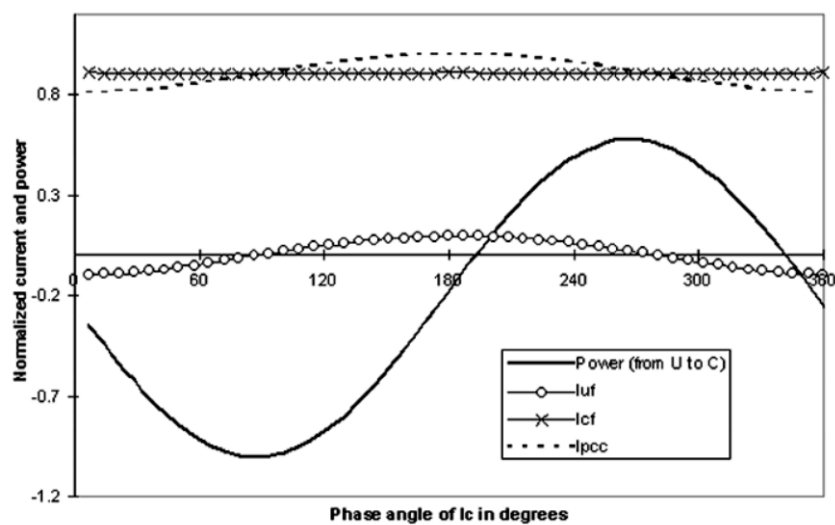
$$I_c = 3 \angle \theta pu, \quad Z_c = 5 + j \cdot 25 pu,$$

em que θ varia de 0° a 360° . Na Figura 20, os gráficos da potência P e dos escalares I_{uf} e I_{cf} são apresentados em função da variação de θ . Se o método da direção de potência ativa estivesse correto, então as seguintes relações seriam válidas:

- Se $P > 0$ então $I_{uf} > I_{cf}$
- Se $P < 0$ então $I_{uf} < I_{cf}$

A Figura 20 ilustra a variação da potência harmônica normalizada, da corrente e de seus componentes em relação ao ângulo de fase. A normalização foi realizada dividindo as correntes e a potência por seus valores máximos respectivos, colocando-os na faixa de -1 a 1 para facilitar a comparação gráfica. Observa-se claramente na figura que a condição previamente mencionada nem sempre é verdadeira. Por exemplo, I_{cf} é consistentemente maior que I_{uf} , sugerindo que o lado do consumidor deve ser considerado como o principal contribuinte para a corrente harmônica. A potência harmônica, no entanto, pode fluir em ambas as direções. Quando o ângulo ultrapassa 190° , a direção da potência contradiz o princípio da superposição. Dado que não há garantia de que o ângulo de fase entre I_u e I_c esteja em uma faixa específica, conclui-se que o método da direção de potência ativa não é apropriado para a determinação da contribuição harmônica.

Figura 20 – Correlação entre a direção de potência ativa e os índices de sobreposição de corrente.



Fonte: Xu, Liu e Liu (2003).

No âmbito da metodologia da Superposição, proposta por Xu, Liu e Liu (2003), pode-se afirmar que, em sua essência, ela surge como um procedimento inicialmente coerente para a tarefa

de atribuir responsabilidades entre a concessionária e o consumidor. Os resultados apresentados, conforme destacado em [Xu e Liu \(1999\)](#) e [Liu e Xu \(2000\)](#), oferecem indicadores percentuais que expressam as contribuições das partes envolvidas. Apesar dos resultados positivos observados no processo avaliado, é importante notar que os principais desafios na aplicação prática do Método da Superposição estão associados à determinação das impedâncias do sistema, especialmente aquelas relacionadas à carga, uma vez que essas tendem a ser altamente dinâmicas.

3.1.3 Método da Corrente Conforme e Não-Conforme

Outra metodologia alternativa no âmbito da contribuição harmônica é denominada por Método da Corrente Conforme e Não-conforme, proposta por ([SRINIVASAN, 1996](#)). Essa abordagem fundamenta-se em um princípio físico que permite subdividir a corrente total entre a fonte de suprimento e a carga em duas parcelas distintas. A primeira é chamada de corrente conforme, a qual está completamente alinhada com as condições impostas pela tensão de suprimento. A segunda parcela é chamada de corrente não-conforme e está associada à natureza da carga sendo suprida.

O primeiro artigo sobre o Método da Corrente Conforme e Não-conforme ([SRINIVASAN, 1996](#)) propõe uma divisão das cargas supridas em duas categorias principais:

- **Grupo I** – cargas que não introduzem distorções adicionais às já presentes na fonte de tensão de suprimento.
- **Grupo II** – cargas que geram distorções adicionais às presentes na tensão de suprimento original.

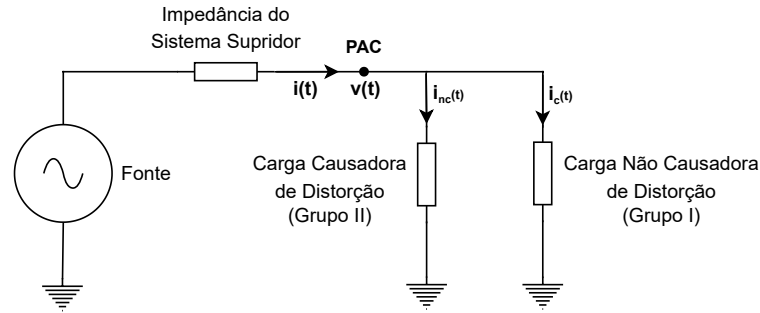
A publicação também faz uma hipótese simplificada, sugerindo que as cargas do Grupo I possuem a mesma impedância para todas as frequências analisadas. No entanto, essa condição pode ser inconsistente com os princípios elétricos, especialmente quando a carga contém elementos indutivos e capacitivos. No caso das cargas do Grupo II, elas podem ser ainda subclassificadas em três tipos:

- **Cargas Desejáveis** – reduzem os níveis relativos de harmônicos presentes na rede;
- **Cargas Indesejáveis** – amplificam os níveis relativos dos harmônicos presentes na rede;
- **Cargas Geradoras de Distorção** – produzem uma corrente distorcida, mesmo quando a tensão de suprimento é puramente senoidal. Consequentemente, essas correntes harmônicas podem causar distorções nas tensões de suprimento.

Com base nesses conceitos, pode-se conceber um circuito equivalente simplificado conforme ilustrado na Figura 21. Nesse circuito, há um suprimento representado por uma fonte

de tensão (senoidal ou não), uma impedância representativa da rede elétrica e uma carga genérica que engloba os dois grupos de consumidores discutidos anteriormente (Grupo I e Grupo II).

Figura 21 – Composição de uma típica carga segundo o Método da Corrente Conforme e Não-conforme.



Fonte: Autoria própria.

Na Figura 21, tem-se as seguintes variáveis: $v(t)$ é a tensão instantânea medida no PAC; $i(t)$ é a corrente instantânea total medida no PAC; $i_c(t)$ representa a corrente de suprimento da carga do Grupo I ou corrente conforme; e $i_{nc}(t)$ é a corrente de alimentação da carga do Grupo II ou corrente não-conforme. Analisando o circuito no domínio do tempo, tem-se que a relação entre a corrente total $i(t)$, a corrente conforme $i_c(t)$ e a corrente não-conforme $i_{nc}(t)$ pode ser expressa por:

$$i(t) = i_c(t) + i_{nc}(t). \quad (3.5)$$

No domínio da frequência, utilizando a simbologia fasorial e considerando a aplicabilidade para qualquer frequência ω , tem-se:

$$\dot{I}(\omega) = \dot{I}_c(\omega) + \dot{I}_{nc}(\omega). \quad (3.6)$$

Com base na hipótese estabelecida pela metodologia, que determina uma relação constante entre qualquer tensão harmônica e sua respectiva corrente, a parcela de corrente conforme pode ser calculada por:

$$\dot{I}_c(\omega) = y \cdot \dot{V}(\omega), \quad (3.7)$$

em que y é uma constante complexa que expressa a razão entre as tensões e correntes para todas as frequências harmônicas. É importante destacar que a corrente não-conforme para a frequência fundamental (ω_1) é nula ($\dot{I}_{nc}(\omega_1) = 0$), pois a carga não poder gerar potência ativa na frequência fundamental. Com isso, a relação complexa y pode ser obtida usando a seguinte equação:

$$\dot{I}_c(\omega_1) + \dot{I}_{nc}(\omega_1) = y \cdot \dot{V}(\omega_1), \quad (3.8)$$

resultando assim em:

$$y = \frac{\dot{I}(\omega_1)}{\dot{V}(\omega_1)}. \quad (3.9)$$

Nesse sentido, substituindo a equação (3.9) em (3.7), torna-se possível obter a seguinte expressão para a corrente conforme, a qual é válida para qualquer frequência ω :

$$\dot{I}_c(\omega) = \frac{\dot{I}(\omega_1)}{\dot{V}(\omega_1)} \cdot \dot{V}(\omega). \quad (3.10)$$

Uma vez obtidas as correntes harmônicas totais medidas no PAC e também calculadas as parcelas correspondentes das componentes harmônicas associadas à corrente conforme, torna-se factível a obtenção das correntes harmônicas não-conformes. A correlação entre tais componentes de correntes é estabelecida por:

$$\dot{I}_{nc}(\omega) = \dot{I}(\omega) - \frac{\dot{I}(\omega_1)}{\dot{V}(\omega_1)} \cdot \dot{V}(\omega). \quad (3.11)$$

Nesse sentido, as equações anteriores podem ser substituídas pelo conjunto de expressões abaixo:

$$v(t) = \sum_{k=1}^n V_k \sin(k\omega_1 t + \theta_k), \quad (3.12)$$

$$i(t) = \sum_{k=1}^n I_k \sin(k\omega_1 t + \varphi_k), \quad (3.13)$$

$$i_c(t) = \sum_{k=1}^n \frac{I_1}{V_1} V_k \sin[k\omega_1 t + \theta_k + k(\varphi_1 - \theta_1)], \quad (3.14)$$

$$i_{nc}(t) = i(t) - i_c(t), \quad (3.15)$$

sendo V_k a amplitude da tensão de ordem harmônica k ; I_k a amplitude da corrente de ordem harmônica k ; V_1 a amplitude da tensão fundamental; I_1 a amplitude da corrente fundamental; θ_k é o ângulo de fase da tensão harmônica k ; φ_k é o ângulo de fase da corrente harmônica k ; ω_1 é a frequência angular da componente fundamental do sistema.

A partir da explicação desse método, observa-se que a parte não distorcida do fluxo de corrente da concessionária para o consumidor é composta pela componente fundamental mais os harmônicos. Por outro lado, o fluxo da corrente distorcida segue do consumidor para a concessionária, porém, não inclui a componente de frequência fundamental, contendo apenas os componentes harmônicos. No método proposto por [Srinivasan \(1996\)](#), a carga do consumidor, representada por y , permanece constante para as demais frequências harmônicas, o que pode


resultar em resultados insatisfatórios ao ser aplicado a sistemas reais. Portanto, a utilização do método desses autores é mais apropriada para simulações em sistemas hipotéticos (com frequência constante), permitindo análises comparativas com outros métodos de determinação da contribuição harmônica.

3.1.4 Método da Impedância Crítica

Uma abordagem apresentada por [Li, Xu e Tayjasanant \(2002\)](#) visou a quantificação das contribuições harmônicas provenientes de cada fonte para a distorção da tensão do sistema. Essa abordagem baseou-se nos conceitos dos circuitos equivalentes de Thèvenin e Norton, buscando avaliar os efeitos das correntes harmônicas introduzidas tanto pela concessionária quanto pelas cargas não lineares do sistema. Notavelmente, o método desenvolvido por [Li, Xu e Tayjasanant \(2002\)](#) representa uma evolução do método proposto por [Liu e Xu \(2000\)](#). Para estimar as contribuições relativas das entidades concessionária e consumidor, [Li, Xu e Tayjasanant \(2002\)](#) adotaram uma perspectiva que considera o fluxo de potência reativa da componente harmônica. A escolha do fluxo de potência reativa mostrou-se mais precisa para a identificação das fontes de harmônicas. Diversas análises matemáticas e simulações têm atestado a eficácia desse método na determinação da contribuição harmônica, conforme demonstrado por [Xu, Liu e Liu \(2003\)](#) e [Chen et al. \(2004\)](#).

Ao examinar em mais detalhes a abordagem proposta por [Li, Xu e Tayjasanant \(2002\)](#), observa-se que ela se inicia a partir da corrente medida no PAC. Com essa informação, um modelo equivalente ao circuito de Norton foi construído, como ilustrado na Figura 22a, servindo como base para estimar a contribuição harmônica das correntes. Para estimar a contribuição harmônica das tensões, os autores empregaram uma abordagem aproximada, utilizando um modelo equivalente de Thèvenin, conforme apresentado na Figura 22b.

Figura 22 – Representação dos circuitos para a tensão e corrente medida no PAC.



Fonte: Adaptado de ([LI; XU; TAYJASANANT, 2002](#)).

Definidos os sistemas equivalentes, calcula-se as potências ativa P e reativa Q :

$$P = E_u I \cos \theta = \frac{E_u E_c}{Z} \cdot \sin \delta, \quad (3.16)$$

$$Q = E_u I \sin \theta = \frac{E_u}{Z} \cdot (E_c \cos \delta - E_u). \quad (3.17)$$

As correntes harmônicas da concessionária e do consumidor são representadas pelas variáveis I_c e I_u na Figura 22a, respectivamente. Da mesma forma, os índices c e u também são usados nas variáveis Z e E , que denotam a impedância e a tensão harmônica, respectivamente. As medições de corrente e tensão feitas no PAC são expressas por I_{PAC} e V_{PAC} .

Mediante simplificações nas equações (3.16) e (3.17), juntamente com informações previamente conhecidas sobre as impedâncias Z_u e Z_c , é viável determinar as contribuições harmônicas atribuíveis à concessionária e ao consumidor no PAC. É importante notar que cargas de natureza predominantemente indutiva ou capacitiva apresentam características diferentes, o que se reflete em equações específicas para cada caso.

O método introduzido por [Li, Xu e Tayjasant \(2002\)](#) emprega abordagens mais avançadas, embora exija o entendimento antecipado das impedâncias do consumidor, obtido por meio da relação entre as fontes de tensão da concessionária e do consumidor. Este método se aplica de maneira simples a situações monofásicas. Entretanto, é válido ressaltar que a técnica proposta por [Li, Xu e Tayjasant \(2002\)](#) gera resultados aceitáveis, mas possui limitações ao considerar apenas a relação entre as fontes de tensão da concessionária e do consumidor, sem contemplar eventuais relações entre as impedâncias de ambos os lados.

3.2 Abordagens recentes usadas para determinar a contribuição harmônica

Como demonstrado anteriormente, os métodos amplamente reconhecidos e pioneiros serviram como base para o desenvolvimento de abordagens recentes. Os trabalhos de [Hou *et al.* \(2019\)](#), [Guo, Chen e Jin \(2019\)](#) propuseram meios para determinar a impedância harmônica em sistemas de distribuição. No entanto, observa-se que a avaliação das características de impedância, tanto dos consumidores quanto da concessionária, permanece um desafio em aberto.

[Safargholi, Malekian e Schufft \(2018\)](#), [Safargholi Farhad e Schufft \(2018\)](#) utilizaram fontes e impedâncias equivalentes de Thevenin da concessionária e dos consumidores para determinar a contribuição harmônica. Esses estudos indicam como calcular as contribuições harmônicas quando os equivalentes de Thevenin são conhecidos. No entanto, o desafio na medição das contribuições da distorção harmônica no PAC se dá pela determinação dos circuitos equivalentes de Thevenin tanto do lado da concessionária quanto do lado do consumidor.

Observou-se, contudo, que muitas dessas abordagens requerem a disponibilidade de modelos equivalentes de tensão para todas as fontes harmônicas. Visto que a obtenção direta desses parâmetros do modelo não é viável, recorre-se a técnicas numéricas para sua estimativa. Nesse contexto, abordagens não experimentais ganharam destaque na pesquisa ([ŠPELKO; PAPIČ; DJOKIC, 2018](#)). Tais abordagens envolvem a estimativa de modelos equivalentes para as fontes harmônicas, utilizando as tensões e correntes medidas no PAC. A confiabilidade dessas

estimativas está diretamente associada à precisão na determinação dos parâmetros das fontes harmônicas.

Zhang e Yang (2004), Sahoo, Sharma e Rath (2011), Jia *et al.* (2013), Matos *et al.* (2016), Wu *et al.* (2018), Sun *et al.* (2021) introduziram métodos de regressão linear para estimar esses parâmetros. Entretanto, esses métodos operam sob a suposição de que as tensões e impedâncias equivalentes das fontes harmônicas permanecem constantes, o que pode resultar em erros significativos diante das variações nas condições operacionais do sistema. Portanto, a aplicação desses métodos em cenários do mundo real apresentava desafios substanciais. Outras abordagens, baseadas no algoritmo de mínimos quadrados recursivos (*Recursive Least Square (RLS)*) (JR. *et al.*, 2009; HAN *et al.*, 2014), foram propostas. Embora capazes de estimar parâmetros que variam com o tempo em resposta a mudanças nas fontes harmônicas, esses métodos utilizam fatores de esquecimento constantes, o que pode resultar em problemas de acúmulo de covariância e estimativas não confiáveis.

Para enfrentar essas questões, um novo método de estimação foi proposto por Park *et al.* (2020). Esse método combinou um esquema de detecção de mudança de parâmetro com o algoritmo RLS, incorporando um fator de esquecimento variável. No entanto, todos esses métodos existentes dependem de dados de medição para a estimação de parâmetros, o que resulta em um problema relacionado ao desempenho da estimação degradada de forma significativa na presença de dados atípicos. Esses valores atípicos podem ocorrer por várias razões e causar erros substanciais.

Portanto, para melhorar o desempenho da estimação de parâmetros, torna-se crucial adotar um método eficaz para identificar e remover valores atípicos dos dados de medição. Algumas técnicas estatísticas, como suavização de dados e filtragem média, foram propostas para a remoção de valores atípicos (GUPTA *et al.*, 2014; CHEN; LI; WANG, 2018; ZOU; DJOKIC, 2020). No entanto, esses métodos se mostraram ineficazes, principalmente quando os dados de medição são limitados e os parâmetros equivalentes das fontes harmônicas mudam frequentemente.

Ao analisar os métodos mencionados, é evidente que muitos deles se concentram na identificação do fluxo de corrente e potência harmônica. No entanto, o foco principal desses métodos reside na identificação dos elementos responsáveis, bem como na quantificação percentual das contribuições de cada um deles. Os métodos disponíveis para calcular essas porcentagens enfrentam desafios consideráveis, incluindo complexidades na implementação. Além disso, surge uma preocupação adicional em relação à necessidade de conhecer previamente as impedâncias harmônicas do sistema, tanto no âmbito do consumidor quanto da concessionária. É importante ressaltar que as impedâncias harmônicas são dinâmicas e podem variar em diferentes situações, o que acrescenta uma camada adicional de complexidade à análise harmônica.

Diante dessas limitações, abordagens baseadas em técnicas de aprendizado de máquina têm ganhado destaque. Entre elas, podem ser citadas as redes neurais (MAZUMDAR *et al.*, 2008;

HUANG; LIN, 2015; MURUGAN; KUMAR, 2016), sistemas de inferência *fuzzy* (SILVA *et al.*, 2015; FERNANDES *et al.*, 2023), árvores de decisão (FERNANDES *et al.*, 2023) e algoritmos de clusterização (SHA *et al.*, 2019).

Mazumdar *et al.* (2008) descreveram o desenvolvimento de uma ferramenta inteligente baseada em Redes Neurais Artificiais (*Artificial Neural Network* (ANN)) para avaliar a contribuição harmônica de clientes em redes de distribuição elétrica, especialmente em sistemas com cargas não lineares. O projeto utilizou um Perceptron Multicamadas (*Multilayer Perceptron* (MLP)), composto por duas redes: a ANN1, responsável por identificar as características da carga do cliente, e a ANN2, que estimou a corrente harmônica em um cenário ideal.

A pesquisa foi realizada com dados reais coletados por meio do medidor AVO Megger PA-9Plus, que registrou as correntes e tensões de um cliente com cargas não lineares. O estudo se concentrou em distorções harmônicas típicas em sistemas que incluem motoredutores, fontes de alimentação comutadas e outros equipamentos eletrônicos que geram harmônicos, com ênfase nas ordens ímpares, como a 5^a, 7^a, 11^a e 13^a.

A ANN1 foi treinada até que o erro quadrático médio (*Mean Squared Error* (MSE)) convergisse para um valor inferior a 2×10^{-2} , com o erro quadrático médio da raiz (*Root Mean Squared Error* (RMSE)) resultando em um valor abaixo de 0.1414, o que indicou boa precisão na modelagem. A ANN2 foi responsável pela estimativa da corrente harmônica, utilizando os pesos aprendidos pela ANN1 para simular um cenário ideal, sem distorções.

Os resultados indicaram que o modelo foi eficaz em prever a contribuição harmônica real dos clientes, o que possibilita a aplicação do método em sistemas de diagnóstico de qualidade de energia, oferecendo uma solução prática para o monitoramento e controle de distorções harmônicas em redes elétricas.

Em Huang e Lin (2015), os autores utilizaram uma rede de Mapa de Características Auto-Organizável (*Self-organization Feature Map* (SOFM)) em combinação com a transformação wavelet de sinais de tensão e corrente para classificar múltiplas fontes harmônicas em sistemas de distribuição elétrica.

O estudo fez uso da transformação wavelet de Morlet para extrair características dos sinais de tensão e corrente, seguido pela implementação do SOFM para classificar os padrões de transformação V-I, separando as cargas normais das não lineares. Como modelo de comparação, a Máquina de Vetores de Suporte (*Support Vector Machine* (SVM)) foi utilizada para avaliar a eficácia do SOFM.

Para a análise dos sinais, a transformação wavelet foi empregada para identificar as características harmônicas dos sinais de tensão e corrente. O SOFM foi treinado com 61 padrões representando diferentes fontes harmônicas. O estudo foi realizado em um pequeno sistema de distribuição elétrica, onde um forno de arco elétrico (*Electric Arc Furnace* (EAF)) foi conectado a transformadores, simulando um ambiente industrial.

As simulações incluíram cargas não lineares, como retificadores (6-pulsos e 12-pulsos) e EAF, com dados obtidos de tensões e correntes operacionais. Em um estudo de caso, as características de operação do EAF foram analisadas para observar a produção de correntes harmônicas e distorções.

Os resultados mostraram que o valor do erro quadrático médio de ajuste (*Mean Square Error of Fit* (MSEF)) foi inferior a 0.10, indicando um bom ajuste do modelo. A taxa de acurácia atingiu 100% em algumas configurações do treinamento com SVM, demonstrando precisão nas classificações. Além disso, o SOFM convergiu rapidamente em menos de 30 iterações, evidenciando sua eficiência. As cargas foram agrupadas em 6 classes distintas, destacando a capacidade do modelo de diferenciar entre várias fontes harmônicas.

Em [Murugan e Kumar \(2016\)](#), os autores propuseram um sistema de redes neurais para identificar as fontes harmônicas e suas contribuições em um sistema elétrico, a partir de medições realizadas no PAC, sem a necessidade de desconectar as cargas.

Para isso, os autores implementaram quatro tipos de redes neurais: Rede Neural Perceptron Multicamadas com Propagação Direta e Retropropagação (*Feed Forward Back Propagation Neural Network* (FFBPN)), Rede Neural Perceptron Multicamadas em Cascata com Propagação Direta e Retropropagação (*Cascade Feed Forward Back Propagation Neural Network* (CFBPN)), Rede Neural de Função de Base Radial (*Radial Basis Function Neural Network* (RBFN)) e Rede Neural de Função de Base Radial Exata (*Exact Radial Basis Function Neural Network* (ERBFN)). Essas redes foram treinadas com amostras de um ciclo de corrente distorcida, utilizando 99 neurônios de entrada e 6 neurônios de saída, para representar as distorções harmônicas do sistema.

O sistema testado incluiu cinco cargas, sendo duas lineares (motores de indução de 5.4 HP e 10 HP) e três não lineares (dois drives de corrente contínua de 5 HP e 20 HP, e um conversor com carga resistiva de 1500 Ω). As medições foram feitas em um sistema trifásico de 400 V e 50 Hz, com amostras de tensões e correntes no PAC.

A métrica principal utilizada foi a THD, que foi calculada para verificar a contribuição harmônica das diferentes fontes. Para avaliar o desempenho dos modelos, foram também calculados o erro absoluto e o erro relativo, além do RMSE, que quantifica a diferença entre os valores reais e as previsões feitas pelas redes neurais.

Os resultados mostraram que o RMSE para as diferentes cargas variou entre 0.0055 e 0.0130, com a rede ERBFN apresentando os menores valores de erro e o melhor desempenho geral. No entanto, de maneira geral, todos os modelos testados apresentaram um bom desempenho na identificação das fontes harmônicas e na previsão das distorções harmônicas e por sua vez a contribuição.

[Silva et al. \(2015\)](#) propuseram uma abordagem baseada em sistemas de inferência *fuzzy* para a determinação das contribuições harmônicas em PACs entre consumidores e concessio-

nárias em sistemas de distribuição de energia elétrica. O método consistiu na utilização de oito sistemas *fuzzy* para estimar as contribuições individuais dos harmônicos de ordens 3^a, 5^a, 7^a e 9^a. As simulações foram conduzidas no software *Alternative Transients Program* (ATP), permitindo modelar o sistema elétrico e analisar variações de carga.

O modelo do sistema incluiu medições de tensões e correntes nos PACs e em uma ramificação onde um banco de capacitores foi alocado. As medições foram realizadas em dois momentos distintos: antes e após a comutação do banco de capacitores. Foram extraídas diversas características elétricas, incluindo os valores eficazes de tensão, o fator de interferência telefônica para tensão e corrente no PAC e no banco de capacitores, além do fator de crista da tensão pré-comutação.

Para validação do método, foram gerados 480 cenários considerando variações de carga e níveis de harmônicos provenientes tanto do lado do consumidor quanto da concessionária. As simulações incorporaram a modelagem dinâmica das cargas, permitindo a análise das alterações de impedância em diferentes condições operacionais.

Os resultados demonstraram a eficácia da abordagem na quantificação das responsabilidades das partes envolvidas na contribuição para a distorção harmônica. O erro médio entre os valores estimados pelos sistemas *fuzzy* e os resultados das simulações variou entre 1% e 10%. Além disso, a metodologia proposta apresentou a vantagem de não exigir conhecimento prévio das impedâncias da rede e do consumidor, possibilitando maior flexibilidade em diferentes condições operacionais. O estudo reforça a aplicabilidade de sistemas *fuzzy* para a gestão da qualidade da energia elétrica, contribuindo para a identificação precisa das fontes de distorção harmônica e auxiliando na formulação de políticas tarifárias equitativas.

Já em [Fernandes et al. \(2023\)](#), foi proposta uma abordagem baseada na combinação de árvores de decisão (DTs) e sistemas de inferência neuro-*fuzzy* para a identificação e quantificação das contribuições harmônicas em sistemas de distribuição de energia elétrica. O método foi estruturado em duas etapas principais: a extração de características dos sinais elétricos medidos nos PACs e a classificação das contribuições harmônicas. As características extraídas incluíram o valor eficaz, fator de pico, fator de forma e a THD.

Na etapa de classificação, foram empregados algoritmos baseados em árvores de decisão para identificar a origem das distorções harmônicas—se provenientes da concessionária, do consumidor ou de ambos. Para estimar a magnitude das contribuições harmônicas, utilizou-se sistemas de inferência neuro-*fuzzy* adaptativa (*Adaptive Neuro-Fuzzy Inference System* (ANFIS)). O modelo do sistema foi validado por meio de 1.073 simulações no ATP, abrangendo cenários variados, incluindo variações na carga e na magnitude harmônica em diferentes fontes. A impedância equivalente da rede foi definida como 0,2 Ω e 2,7 mH, e os sinais foram amostrados a uma taxa de 256 amostras por ciclo.

Os resultados demonstraram a alta eficácia da abordagem proposta. Os classificadores

baseados em árvores de decisão atingiram uma acurácia superior a 99% na identificação do lado responsável pela contribuição harmônica. Já os modelos ANFIS apresentaram erros quadráticos médios entre 1.1×10^{-2} e 3.0×10^{-9} na estimativa das contribuições. O estudo reforça a viabilidade da metodologia para diagnóstico da identificação pela responsabilidade harmônicas em PACs, contribuindo para a melhoria da qualidade da energia elétrica fornecida aos consumidores.

Por fim, o estudo desenvolvido por [Sha et al. \(2019\)](#) propõe um algoritmo avançado para determinar a contribuição harmônica de múltiplas fontes no sistema elétrico, com o objetivo de mitigar a poluição harmônica e resolver disputas sobre a qualidade da energia. Para isso, a metodologia combina a entropia de aproximação cruzada (*Cross Approximation Entropy (CAE)*), utilizada para filtrar flutuações harmônicas de fundo, e o algoritmo de agrupamento *Density-based Spatial Clustering of Applications with Noise (DBSCAN)*, empregado para detectar variações na impedância do sistema. A abordagem inicia-se com a aplicação da CAE para selecionar os dados mais relevantes de tensão e corrente no PAC, garantindo maior precisão na estimativa da impedância harmônica. Em seguida, o DBSCAN agrupa os dados filtrados e identifica alterações na impedância, permitindo o cálculo da contribuição harmônica de cada fonte. As simulações, realizadas em um cenário onde a impedância do sistema foi alterada com a adição de capacitores, demonstraram que o método alcançou uma taxa de erro máxima de 7,91% e uma precisão superior a 92%. A avaliação do algoritmo foi feita por meio da comparação com métodos tradicionais, evidenciando sua superioridade na determinação das contribuições harmônicas. Além de aprimorar a precisão dessas estimativas, a proposta se destaca por sua eficácia na gestão da qualidade da energia elétrica, permitindo um controle mais eficiente da poluição harmônica e reduzindo conflitos entre consumidores e concessionárias.

A partir da análise dos diversos estudos mencionados ([MAZUMDAR et al., 2008](#); [HUANG; LIN, 2015](#); [MURUGAN; KUMAR, 2016](#); [SILVA et al., 2015](#); [FERNANDES et al., 2023](#); [SHA et al., 2019](#)), pode-se concluir que as metodologias que utilizam aprendizado de máquina têm se mostrado eficazes na identificação e quantificação das contribuições harmônicas em sistemas de distribuição elétrica, especialmente em contextos com cargas não lineares. A aplicação de técnicas como ANN, SOFM, sistemas neuro-*fuzzy*, e outras metodologias como a CAE e o algoritmo de agrupamento DBSCAN, permitiram a obtenção de resultados precisos na estimativa de correntes harmônicas e na classificação das fontes harmônicas.

Os principais resultados indicam que, para a maioria dos métodos, a precisão na classificação e estimativa das distorções harmônicas foi elevada, com RMSE relativamente baixos, variando entre 0.0055 e 0.1414, dependendo do modelo e dos dados analisados. Além disso, o uso de dados reais e a combinação de diferentes técnicas, como a transformação wavelet, possibilitaram a criação de modelos robustos para o diagnóstico da qualidade da energia elétrica.

Destaca-se também a importância da flexibilidade desses modelos em diferentes condições operacionais, já que vários estudos não exigem conhecimento prévio sobre a impedância da rede ou do consumidor. Além disso, alguns métodos, como os sistemas *fuzzy* e os classificadores

baseados em árvores de decisão, apresentaram alta acurácia e bom desempenho na identificação das fontes de distorção harmônica, mesmo em cenários complexos e com variações na carga.

Portanto, essas abordagens demonstram claramente a viabilidade da aplicação de técnicas de aprendizado de máquina na análise de distorções harmônicas e no estudo das contribuições harmônicas no PAC, corroborando com a proposta desta dissertação.

DETERMINAÇÃO DA CONTRIBUIÇÃO HARMÔNICA

Este capítulo apresenta de forma detalhada o processo metodológico adotado nesta dissertação, abordando desde a estruturação das etapas até a execução das simulações, a determinação das contribuições harmônicas e a aplicação dos modelos de aprendizado de máquina.

4.1 Visão Geral

Conforme discutido no Capítulo 3, diversas abordagens têm sido propostas para identificar a responsabilidade pela distorção harmônica no PAC. No entanto, até o momento não foi identificada qualquer produção científica que tratasse especificamente o PAC entre a rede da concessionária e uma MR. Apesar disso, as abordagens que consideram a contribuição entre concessionária e consumidor ainda enfrentam desafios significativos devido à complexidade de se obter, de forma antecipada, as impedâncias harmônicas que compõem o sistema. Essas impedâncias podem variar por diversos fatores, como mudanças nas cargas, alterações na topologia da rede, operação de equipamentos, entre outras (YANG *et al.*, 2011).

As abordagens baseadas em aprendizado de máquina eliminam a necessidade desse conhecimento prévio, permitindo identificar a responsabilidade pela distorção harmônica sem a exigência de informações detalhadas sobre as impedâncias do sistema elétrico. Isso torna a metodologia mais flexível e aplicável a diferentes esquemas elétricos, desde que o modelo seja devidamente treinado com dados representativos. Além disso, ao dispensar a necessidade de medições complexas, essas técnicas viabilizam uma implementação mais acessível e adaptável a diversas configurações da rede. Com base nessa premissa, este trabalho propõe uma abordagem fundamentada em técnicas de aprendizado de máquina, explorando algoritmos baseados em *ensembles*, os quais também não foram encontrados na literatura correlata.

O desenvolvimento de modelos de aprendizado de máquina geralmente envolve duas

fases principais: treinamento e validação. Durante a fase de treinamento, os dados de entrada e saída são definidos, e algoritmos de aprendizado de máquina são utilizados para construir um modelo que maximize o desempenho quanto à classificação de padrões nos dados. Já na fase de validação, o modelo treinado é aplicado para realizar estimativas com base em novos dados.

A metodologia proposta implementa dois classificadores de aprendizado de máquina distintos (*Random Forest* e *XGBoost*) com o objetivo de estimar qual lado — rede principal ou MR — possui a fonte harmônica dominante. Neste trabalho, a fonte harmônica dominante é definida como a única fonte harmônica relevante presente no sistema, ou seja, aquela cuja localização foi previamente estabelecida nas simulações.

O foco principal está na fase de treinamento, em que diversas simulações são realizadas para incluir fontes harmônicas dominantes em diferentes pontos do sistema elétrico (tanto no lado da concessionária quanto da MR). Os sinais trifásicos de tensão e corrente gerados nessas simulações são coletados no PAC e, em seguida, processados por meio de técnicas de extração de características para definir as variáveis de entrada.

Com os dados de entrada definidos e o conhecimento prévio sobre o lado em que cada carga foi posicionada, é possível construir a variável de saída, a qual indica o lado onde está a fonte harmônica. Assim, o conjunto de dados completo é formado, possibilitando o treinamento dos classificadores propostos.

Após a construção do conjunto de dados, ele é dividido em conjuntos de treinamento e validação. Os classificadores são treinados com os dados de treinamento, ajustando-se para minimizar os erros de predição. Em seguida, os modelos são validados com dados não vistos para avaliar seu desempenho. Um ajuste fino é realizado para otimizar os modelos e alcançar os melhores resultados possíveis. A Figura 23 sintetiza as etapas principais desta pesquisa, enquanto detalhes mais aprofundados são apresentados nas seções subsequentes.

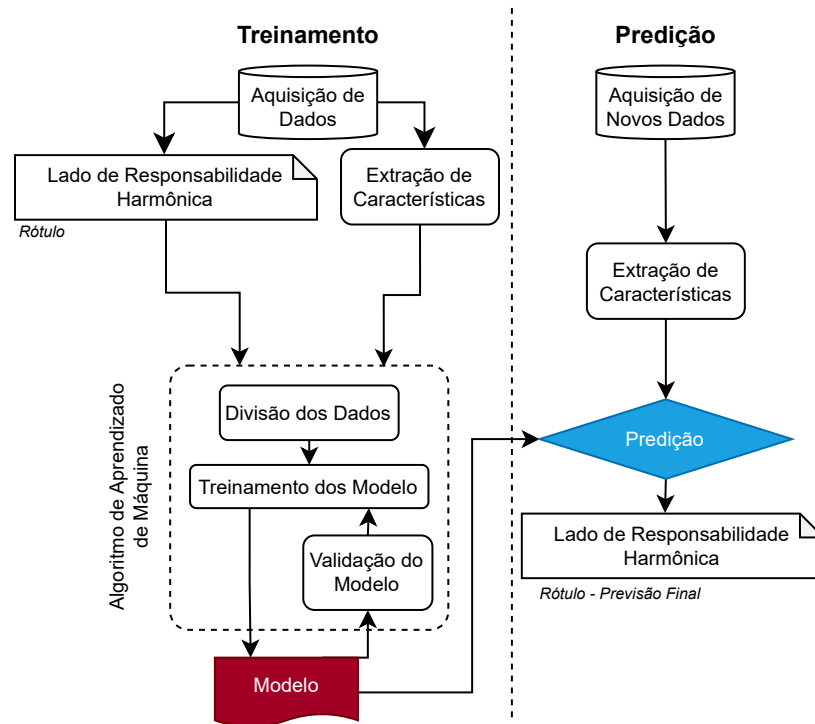
4.2 Simulação do Alimentador de Distribuição no ATP

Esta seção descreve os aspectos de modelagem do alimentador de distribuição de teste e das fontes harmônicas, implementados no software ATPDraw/ATP (PRIKLER; HOIDALEN, 2009) para simulações subsequentes. A carga do alimentador foi mantida de acordo com as especificações apresentadas em Schneider *et al.* (2018).

4.2.1 Alimentador de Teste IEEE de 34 Barras

As tensões e correntes trifásicas no PAC, usadas como variáveis de entrada no modelo de aprendizado de máquina, foram obtidas por meio de simulações realizadas sob diversos cenários. O alimentador de teste IEEE modificado de 34 barras, baseado em um alimentador real localizado no estado do Arizona, foi utilizado nesta análise. Conhecido por suas características de extensão

Figura 23 – Visão geral da metodologia proposta.



Fonte: Autoria própria.

e baixa carga, o alimentador foi modificado para simular a inclusão das fontes harmônicas em diferentes pontos do sistema, com o objetivo de gerar dados que seriam usados no modelo de aprendizado de máquina. As barras do alimentador foram simuladas levando em consideração as distâncias reais entre elas, o que torna a simulação mais próxima da realidade.

A Figura 24 apresenta o diagrama unifilar deste alimentador, com a MR configurada a partir da barra 858. A MR inclui uma Pequena Central Hidrelétrica (PCH) de 1.860 kVA, localizada na barra 846, e um sistema fotovoltaico (PV) de 300 kWp, conectado à barra 836, que utiliza inversores para injetar energia na rede. Essa configuração reflete uma aplicação prática de fontes de energia renovável integradas em um sistema de distribuição realista, inspirado em cenários reais de redes de distribuição, como o alimentador de Arizona.

4.2.2 Modelagem das Fontes Harmônicas

Fontes harmônicas, representando cargas não lineares, foram introduzidas em diversas barras trifásicas, tanto no lado da rede principal quanto no lado da MR. As características dessas fontes harmônicas simuladas estão resumidas na Tabela 8.

As fontes harmônicas consideradas incluem retificadores de 6 e 12 pulsos, conversores estáticos de frequência (SFC), acionamentos de motores CC e reatores controlados por tiristores (TCR). As características dessas fontes, apresentadas no Capítulo 2, foram modeladas com base

atender à demanda interna. Neste modo, a MR depende da rede para suprir sua carência energética.

- **Modo de Exportação de Energia:** A MR fornece energia à rede principal. Esse modo ocorre quando a geração das fontes renováveis excede a demanda interna, resultando em um excedente de energia que é exportado para a rede.
- **Modo Neutro:** Não há troca de energia entre a MR e a rede principal. A geração das fontes renováveis é suficiente para suprir toda a demanda da MR, sem necessidade de importação ou exportação de energia.

Cada simulação envolveu a análise de cenários operacionais em que uma fonte harmônica foi alocada, seja no lado da concessionária ou no lado da MR. A Tabela 9 apresenta os cenários analisados, mostrando os diferentes modos operacionais (importação, exportação ou neutro) e as fontes harmônicas associadas, bem como o local de inserção dessas fontes (concessionária ou MR).

A Tabela 9 apresenta a alocação das fontes harmônicas em diferentes modos operacionais (importação, exportação e neutro) e em dois locais distintos: a concessionária e a MR. Para cada condição operacional, simulações foram realizadas para avaliar a eficácia da abordagem proposta, levando em consideração a localização das fontes harmônicas nos 25 barramentos trifásicos da rede. Desses, 16 barramentos estão situados no lado da concessionária (800, 802, 806, 808, 812, 814, 850, 816, 824, 828, 830, 854, 852, 832, 888 e 890), enquanto 9 estão no lado da MR (MR) (834, 836, 840, 842, 844, 846, 848, 860 e 862). Em cada cenário, foi considerada a inclusão de uma única fonte harmônica, a qual foi utilizada no modelo para identificar sua localização.

Em relação aos dados de medição, a análise envolveu a coleta de tensões e correntes trifásicas no PAC, localizado dentro da MR. Esses dados foram obtidos para um único ciclo de 60 Hz, com uma taxa de amostragem de 7.680 Hz, o que resultou em 128 amostras por ciclo.

Adicionalmente, variações de até 30% na potência aparente ($S_{3\phi}$) das fontes harmônicas foram simuladas para cada cenário, com cada carga harmônica sendo simulada 50 vezes em cada barramento. Essa abordagem garantiu uma ampla diversidade de cenários, possibilitando a abrangência de diversas condições operacionais possíveis. Como resultado, obteve-se um banco de dados composto por 18.750 sinais trifásicos de tensão e corrente.

Essa abordagem permitiu a geração de um conjunto de dados robusto, adequado para o treinamento e validação dos modelos de aprendizado de máquina.

4.3 Extração de Características

Como mencionado anteriormente, o conjunto de dados utilizado neste estudo é composto por sinais trifásicos de tensão e corrente adquiridos com uma taxa de amostragem de 7.680 Hz,

Tabela 9 – Cenários analisados nas simulações, considerando diferentes fontes harmônicas em cada modo operacional e sua localização.

Modo Operacional	Fonte Harmônica Considerada	Localização
Importação	Retificador de 6 Pulsos	Concessionária
Importação	Retificador de 12 Pulsos	Concessionária
Importação	Conversor Estático de Frequência (SFC)	Concessionária
Importação	Acionamento de Motor CC	Concessionária
Importação	Reator Controlado por Tiristores (TCR)	Concessionária
Importação	Retificador de 6 Pulsos	MR
Importação	Retificador de 12 Pulsos	MR
Importação	Conversor Estático de Frequência (SFC)	MR
Importação	Acionamento de Motor CC	MR
Importação	Reator Controlado por Tiristores (TCR)	MR
Exportação	Retificador de 6 Pulsos	Concessionária
Exportação	Retificador de 12 Pulsos	Concessionária
Exportação	Conversor Estático de Frequência (SFC)	Concessionária
Exportação	Acionamento de Motor CC	Concessionária
Exportação	Reator Controlado por Tiristores (TCR)	Concessionária
Exportação	Retificador de 6 Pulsos	MR
Exportação	Retificador de 12 Pulsos	MR
Exportação	Conversor Estático de Frequência (SFC)	MR
Exportação	Acionamento de Motor CC	MR
Exportação	Reator Controlado por Tiristores (TCR)	MR
Neutro	Retificador de 6 Pulsos	Concessionária
Neutro	Retificador de 12 Pulsos	Concessionária
Neutro	Conversor Estático de Frequência (SFC)	Concessionária
Neutro	Acionamento de Motor CC	Concessionária
Neutro	Reator Controlado por Tiristores (TCR)	Concessionária
Neutro	Retificador de 6 Pulsos	MR
Neutro	Retificador de 12 Pulsos	MR
Neutro	Conversor Estático de Frequência (SFC)	MR
Neutro	Acionamento de Motor CC	MR
Neutro	Reator Controlado por Tiristores (TCR)	MR

correspondendo a 128 amostras por ciclo para a frequência nominal de 60 Hz. No total, foram considerados 18.750 sinais, cada um contendo 128 amostras. Devido à grande quantidade de dados, a etapa de extração de características torna-se essencial para a classificação de padrões, pois permite preservar informações relevantes do sinal enquanto reduz sua dimensionalidade, facilitando o processo de modelagem.

A partir desses sinais, foram extraídas as seguintes variáveis: Valor eficaz (*Root Mean Square* (RMS)), Curtose, Assimetria (*Skewness*), Entropia de Rényi, Fator de Crista e Fator de Forma. Essas métricas representam diferentes aspectos do comportamento do sinal e são amplamente utilizadas em problemas de classificação. A seleção dessas variáveis baseou-se na sua capacidade de capturar informações essenciais do sinal, garantindo a preservação de padrões

relevantes e a redução da dimensionalidade, o que contribui para um modelo mais eficiente.

Estudos anteriores destacam a importância dessas características na análise de sinais. [Borges \(2013\)](#) investigou a detecção e classificação de distúrbios na qualidade da energia elétrica utilizando árvores de decisão. [Santos \(2019\)](#) aplicou SVM para identificar anomalias em sinais cerebrais, enquanto [Souza \(2019\)](#) utilizou a mesma técnica para detectar falhas em sinais de vibração de máquinas rotativas. O uso recorrente dessas métricas em diferentes domínios, aliado aos bons resultados obtidos, motivou sua aplicação neste estudo, visando garantir uma representação robusta dos sinais.

4.3.1 Características extraídas

O valor eficaz (RMS) quantifica a magnitude do sinal e é amplamente utilizado para medir a intensidade de grandezas elétricas. Ele representa uma medida estatística da amplitude do sinal, fornecendo uma estimativa do valor eficaz da tensão ou corrente ao longo do tempo:

$$F_1 = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (4.1)$$

na qual N é o número total de amostras e x_i representa cada valor do sinal.

A curtose avalia a presença de picos extremos no sinal, podendo indicar variações abruptas ou anomalias:

$$F_2 = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{\left[\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \right]^2} \quad (4.2)$$

na qual μ é a média do sinal e x_i representa os valores individuais do sinal.

A assimetria mede a distribuição dos valores do sinal em torno da sua média, ajudando a identificar distorções na forma da onda:

$$F_3 = \frac{\sum_{i=1}^N (x_i - \mu)^3}{(N-1)\sigma^3} \quad (4.3)$$

sendo σ é o desvio padrão do sinal.

A entropia de Rényi captura a complexidade do sinal, sendo utilizada para quantificar a diversidade das componentes do sinal:

$$F_4 = \frac{1}{1-\alpha} \log \sum_{i=1}^N \log(x_i^\alpha) \quad (4.4)$$

na qual α foi definido como 0,4 com base em estudos anteriores.

O fator de crista mede a relação entre o pico máximo do sinal e seu valor eficaz, sendo útil para detectar anomalias:

$$F_5 = \frac{\max(x_i)}{F_1} \quad (4.5)$$

O fator de forma avalia a regularidade do sinal, comparando o valor eficaz com a média aritmética:

$$F_6 = \frac{F_1}{\frac{\sum_{i=1}^N x_i}{N}} \quad (4.6)$$

4.3.2 Características relacionadas à distorção harmônica

Dado que este estudo buscou identificar a localização da principal fonte de distorção harmônica no PAC, foram incluídas também variáveis específicas relacionadas a harmônicos: a distorção harmônica total (THD) e as magnitudes das harmônicas ímpares da 3ª à 13ª ordem.

A THD quantifica a contribuição das componentes harmônicas em relação à fundamental:

$$F_7 = \sqrt{\frac{\sum_{j=3}^{13} h_j^2}{h_1}} \quad (4.7)$$

As magnitudes das harmônicas ímpares da 3ª à 13ª ordem capturam distorções específicas em sistemas sujeitos a cargas não lineares. A Transformada Discreta de Fourier (DFT) é utilizada para sua obtenção:

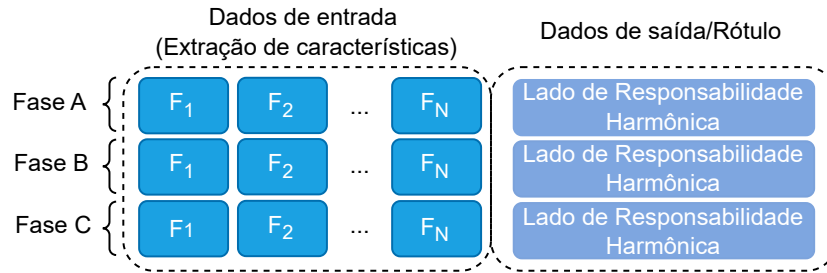
$$H_k = \sum_{i=1}^N x_i \cdot \exp\left(-\frac{i2\pi}{N} ki\right) \quad (4.8)$$

onde cada harmônica H_k na ordem k é obtida com sua magnitude e ângulo de fase.

Devido à configuração desbalanceada do sistema de distribuição, a extração de características foi realizada nos sinais de tensão e corrente de cada fase, gerando três vetores de características por componente, identificados como F_1 a F_N para cada fase. Esses vetores compõem as variáveis de entrada, enquanto a variável de saída, que indica o lado em que a fonte harmônica está localizada, completa o conjunto de dados.

A Figura 25 apresenta a estrutura do conjunto de dados resultante, que abrange tanto as variáveis de entrada quanto a variável de saída, organizadas por fase. Essa estrutura é utilizada no algoritmo de aprendizado de máquina para o treinamento e validação do modelo.

Figura 25 – Estrutura completa do conjunto de dados para cada fase dos sinais simulados.

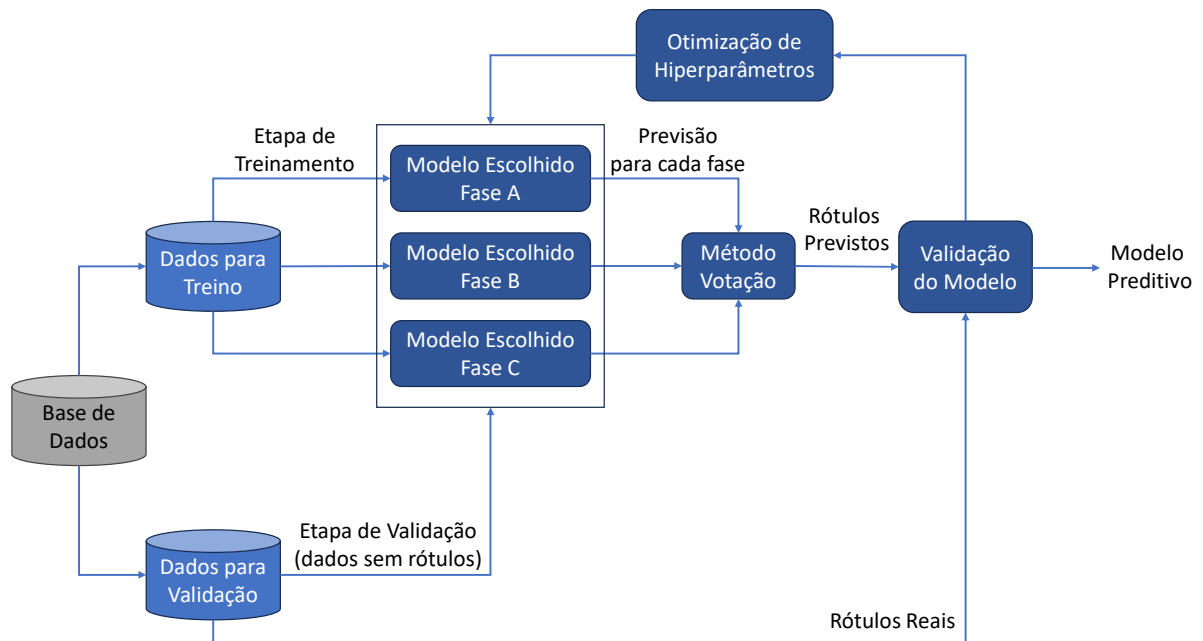


Fonte: Autoria própria.

4.4 Modelos Preditivos

O desenvolvimento dos modelos de aprendizado de máquina neste estudo envolveu diversas etapas fundamentais para garantir o desempenho adequado, iniciando com a divisão dos dados e passando pelo treinamento e validação dos modelos. O fluxo que permeia o treinamento e validação dos modelos preditivos, bem como a otimização de seus hiperparâmetros pode ser visualizado na Figura 26.

Figura 26 – Fluxo de treinamento e validação dos modelos preditivos.



Fonte: Autoria própria.

4.4.1 Divisão dos Dados

O conjunto de dados foi dividido em dois subconjuntos: 70% para o conjunto de treinamento e 30% para o conjunto de validação. O conjunto de treinamento é essencial para o processo de aprendizado, permitindo que o modelo identifique padrões e relações entre as variáveis de en-

trada e o resultado desejado. Um treinamento adequado possibilita que o modelo generalize esses padrões para dados não conhecidos, assegurando robustez e validade em diferentes cenários.

4.4.2 Treinamento dos Modelos

A partir dos subconjuntos de dados, foi conduzido o treinamento dos modelos *Random Forest* e *XGBoost*. Neste estudo, as características resultantes dos sinais de tensão e corrente de cada fase foram modeladas separadamente devido à configuração desequilibrada do alimentador. Assim, os modelos geraram três predições — uma para cada fase — que foram combinadas por meio de um método de votação para produzir a predição final da classe.

4.4.3 Validação dos Modelos

A validação foi realizada comparando as classes preditas com os rótulos verdadeiros do conjunto de validação, confirmando o desempenho dos modelos e sua capacidade de generalização.

Para tanto, empregou-se uma combinação de métricas amplamente reconhecidas na literatura, as quais são fundamentais para avaliar a qualidade e a eficácia de modelos de aprendizado de máquina. As métricas utilizadas incluem a acurácia, precisão, *recall*, F_1 -score e a matriz de confusão. Estas métricas não apenas ajudam a caracterizar o comportamento do modelo, mas também fornecem uma visão detalhada de seu desempenho, possibilitando a identificação de potenciais pontos de melhoria.

Essas métricas são calculadas com base em quatro valores fundamentais que resultam da comparação entre as previsões do modelo e os rótulos reais dos dados. Esses valores indicam como o modelo está se comportando em relação às fontes harmônicas localizadas na MR e na rede principal:

- **Verdadeiros Positivos (TP)** – ocorrem quando o modelo identifica corretamente que a fonte harmônica está localizada na MR;
- **Verdadeiros Negativos (TN)** – ocorrem quando o modelo acerta ao identificar que a rede principal é a responsável pela localização da fonte harmônica;
- **Falsos Positivos (FP)** – ocorrem quando o modelo classifica incorretamente que a fonte harmônica está localizada na MR, quando na realidade ela está na rede principal;
- **Falsos Negativos (FN)** – ocorrem quando o modelo falha ao identificar que a rede principal é responsável pela localização da fonte harmônica, quando, na verdade, ela está na MR.

Esses quatro valores são usados para calcular as métricas, fornecendo uma análise mais completa da capacidade de classificação do modelo. A seguir, detalha-se como cada uma das métricas é definida e interpretada.

4.4.3.1 Acurácia

A acurácia é uma das métricas mais simples e amplamente usadas para avaliar o desempenho de modelos de classificação. Ela mede a proporção de predições corretas em relação ao total de predições feitas. Em outras palavras, a acurácia representa a fração de todas as instâncias que foram corretamente classificadas pelo modelo, considerando tanto os TP quanto os TN. Ela pode ser calculada da seguinte forma:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN}$$

Embora a acurácia seja uma métrica útil para fornecer uma visão geral do desempenho do modelo, ela pode ser enganosa em problemas de classificação em que o conjunto de dados é desbalanceado, ou seja, quando a classe majoritária tende a dominar o resultado (OLSON; DELEN, 2008). No contexto dessa dissertação, por exemplo, se o modelo predizer consistentemente que a fonte harmônica está na rede principal (classe majoritária), a acurácia pode ser alta. No entanto, isso indicaria uma falha do modelo, já que ele não seria capaz de identificar corretamente quando a fonte harmônica está localizada na MR.

4.4.3.2 Precisão

A precisão, também conhecida como valor preditivo positivo, mede a proporção de TP em relação ao total de instâncias classificadas como positivas pelo modelo. Em outras palavras, ela reflete a capacidade do modelo de evitar FP (OLSON; DELEN, 2008). No contexto dessa dissertação, a precisão é uma métrica crucial para assegurar que as predições sobre as fontes harmônicas localizadas na MR sejam confiáveis. Seu cálculo se dá por:

$$\text{Precisão} = \frac{TP}{TP + FP}$$

Uma alta precisão indica que, sempre que o modelo prevê que a MR é o local da fonte harmônica, ele está, na maioria das vezes, correto. Contudo, a precisão por si só não leva em consideração as instâncias em que a MR foi incorretamente descartada (FN), o que pode resultar em uma visão incompleta do desempenho do modelo.

4.4.3.3 Recall

O *recall*, também conhecido como sensibilidade, mede a proporção de TP em relação ao total de instâncias que realmente pertencem à classe positiva (neste caso, à classe da MR)

(OLSON; DELEN, 2008). Em outras palavras, o *recall* avalia a capacidade do modelo de identificar corretamente todas as instâncias associadas à MR, independentemente dos erros de classificação. Ela pode ser obtida por:

$$Recall = \frac{TP}{TP + FN}.$$

Um alto *recall* indica que o modelo é eficaz em identificar a grande maioria das instâncias em que a fonte harmônica está localizada na MR. No entanto, isso pode resultar em um aumento na quantidade de FP, ou seja, instâncias incorretamente classificadas como MR quando, na realidade, pertencem à rede principal.

4.4.3.4 *F1-Score*

O F_1 -score é uma métrica combinada que busca equilibrar a precisão e o *recall*, fornecendo uma medida única para avaliar o desempenho do modelo em relação a ambas as métricas. Essa métrica é particularmente útil em cenários de classes desbalanceadas, pois penaliza tanto os FP quanto os FN de maneira equilibrada (OLSON; DELEN, 2008). O F_1 -score é a média harmônica entre a precisão e o *recall*, e seu valor varia de 0 (desempenho ruim) a 1 (desempenho excelente), sendo obtida por:

$$F1-Score = \frac{2 \times (Precisão \times Recall)}{Precisão + Recall}.$$

Um F_1 -score elevado indica que o modelo está equilibrando de forma eficaz a identificação correta das instâncias das fontes harmônicas localizadas na MR (*recall*), ao mesmo tempo em que mantém uma boa precisão nessa identificação. Em cenários com classes desbalanceadas, o F_1 -score oferece uma visão mais precisa do desempenho do modelo do que a acurácia, pois considera o desempenho sobre a classe minoritária.

4.4.3.5 *Matriz de Confusão*

A matriz de confusão é uma ferramenta útil para avaliar o desempenho do modelo, mostrando a distribuição de TP, TN, FP e FN. Ela permite identificar tipos específicos de erros, como dificuldades na identificação da MR (FN) ou na classificação incorreta da rede principal (FP). No contexto dessa dissertação, ela pode ajudar a ajustar a classificação das contribuições harmônicas da MR e da rede principal.

4.4.4 *Otimização de Hiperparâmetros*

A otimização de hiperparâmetros é crucial para melhorar o desempenho dos modelos de aprendizado de máquina. Esses parâmetros, definidos antes do treinamento, impactam diretamente como o modelo aprende e generaliza. A escolha adequada é essencial para evitar

problemas como *overfitting*, onde o modelo se ajusta excessivamente aos dados de treinamento, ou *underfitting*, quando o modelo é incapaz de capturar padrões complexos (GOODFELLOW; BENGIO; COURVILLE, 2016).

Nessa dissertação, foi utilizada a biblioteca *Optuna*, uma ferramenta de otimização automatizada em Python, com o objetivo de buscar os melhores hiperparâmetros para os modelos preditivos. O *Optuna* adota uma otimização bayesiana, ajustando os hiperparâmetros dentro de intervalos pré-definidos com o intuito de maximizar a métrica de avaliação desejada, que, neste caso, foi o F_1 -score. A técnica de otimização bayesiana é baseada em um modelo probabilístico que prevê as combinações de hiperparâmetros mais promissoras. Em vez de testar exaustivamente todas as opções possíveis, o *Optuna* ajusta iterativamente as combinações de parâmetros com base nos resultados anteriores, reduzindo significativamente o tempo de computação necessário (AKIBA *et al.*, 2020).

Para definir um critério de parada adequado, o *Optuna* adota duas abordagens principais. Primeiro, um número máximo de iterações é estabelecido, garantindo que a busca não continue indefinidamente. Além disso, a técnica de *early stopping* é empregada para interromper automaticamente a otimização quando não há melhorias significativas na métrica de avaliação após um determinado número de iterações consecutivas. Esse mecanismo evita o consumo desnecessário de recursos computacionais e assegura que a busca seja finalizada quando um conjunto de hiperparâmetros suficientemente bom for encontrado (AKIBA *et al.*, 2020).

Antes de iniciar a busca pelos melhores parâmetros, foram definidos intervalos específicos para os hiperparâmetros de cada modelo, garantindo um ponto de partida adequado para a otimização.

A Tabela 10 apresenta os intervalos definidos para os hiperparâmetros do modelo *Random Forest*.

Tabela 10 – Intervalos de otimização para o modelo Random Forest

Hiperparâmetro	Intervalo/Opções
Número de árvores (<i>n_estimators</i>)	100 a 150
Profundidade máxima (<i>max_depth</i>)	5 a 15
Mínimo de amostras para divisão (<i>min_samples_split</i>)	4 a 20
Mínimo de amostras por folha (<i>min_samples_leaf</i>)	4 a 20
Número de variáveis consideradas (<i>max_features</i>)	'sqrt', 'log2'
Amostragem com reposição (<i>bootstrap</i>)	True, False

Já para o modelo *XGBoost*, os intervalos definidos para a otimização dos hiperparâmetros estão apresentados na Tabela 11.

Tabela 11 – Intervalos de otimização para o modelo XGBoost

Hiperparâmetro	Intervalo/Opções
Número de rodadas de boosting (<i>n_estimators</i>)	100 a 150
Profundidade máxima (<i>max_depth</i>)	3 a 15
Taxa de aprendizado (<i>learning_rate</i>)	10^{-3} a 0.1
Fração de amostras por árvore (<i>subsample</i>)	0.5 a 0.7
Fração de variáveis por árvore (<i>colsample_bytree</i>)	0.05 a 0.5
Redução mínima de perda (<i>gamma</i>)	0 a 5
Regularização L1 (<i>reg_alpha</i>)	0 a 10
Regularização L2 (<i>reg_lambda</i>)	0 a 10

Os intervalos dos hiperparâmetros foram definidos com base nas melhores práticas da literatura de aprendizado de máquina, levando em consideração a natureza de cada algoritmo. Para o *Random Forest*, os valores foram ajustados para equilibrar a complexidade do modelo e sua capacidade de generalização, garantindo diversidade entre as árvores e evitando *overfitting*. Já no *XGBoost*, os intervalos foram escolhidos para otimizar a eficiência do boosting, garantindo que cada iteração contribua de forma significativa sem comprometer a estabilidade do modelo.

O uso do Optuna dentro desses limites permitiu explorar combinações promissoras, ajustando os hiperparâmetros de maneira eficiente para obter o melhor desempenho possível em cada modelo.

4.5 Implementação da Metodologia

Toda a metodologia foi implementada em *Python*, escolhido por sua flexibilidade, ampla biblioteca de aprendizado de máquina e facilidade de integração com outras ferramentas. O desenvolvimento foi realizado no ambiente *Spyder*, uma IDE voltada para ciência de dados e engenharia, que oferece suporte à depuração, visualização de variáveis e organização eficiente do código.

O código foi integrado ao *ATP/ATPDraw*, permitindo a execução automatizada das simulações. No *Python*, foram definidos os parâmetros das fontes harmônicas e os barramentos onde seriam inseridas, possibilitando a execução sequencial das simulações para todos os cenários planejados.

Após a aquisição dos dados, o processamento continuou no *Python*, incluindo a estruturação da base de dados, extração de características e implementação do pipeline de aprendizado de máquina. Esse pipeline envolveu a divisão dos dados, seleção dos classificadores *Random Forest* e *XGBoost*, e otimização dos hiperparâmetros com *Optuna*, garantindo a melhor configuração para maximizar a acurácia.

Por fim, o modelo final foi gerado e validado com base nas métricas definidas, assegurando um desempenho robusto na classificação dos sinais.

RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados e discutidos os resultados obtidos pelos modelos preditivos baseados em *Random Forest* e *XGBoost*, os quais foram empregados para prever em qual dos lados – MR ou rede principal (concessionária) – está localizada a fonte harmônica dominante.

5.1 Análise Geral dos Resultados

A princípio, é válido informar que ambos os algoritmos de aprendizado de máquina foram utilizados como classificadores binários, em que o rótulo “0” indica que a fonte harmônica está localizada no lado da concessionária, enquanto o rótulo “1” indica que está no lado da MR.

O processo de ajuste dos hiperparâmetros foi realizado utilizando o *framework Optuna*, que permitiu uma busca eficiente pelos valores ideais para maximizar o desempenho dos modelos. Durante o ajuste fino, foram explorados múltiplos valores para parâmetros como o número de estimadores, a profundidade máxima das árvores, a taxa de aprendizado, entre outros parâmetros específicos de cada classificador. Os valores finais dos hiperparâmetros ajustados estão resumidos na Tabela 12.

A partir dos modelos com os melhores hiperparâmetros, foi possível então obter e analisar as métricas usadas para avaliar seus desempenhos, que são: acurácia, precisão, *recall* e *F1-score*. Assim, para proporcionar uma melhor análise das taxas de acertos, optou-se por separar os resultados em função de cada tipo de fonte harmônica considerada nessa dissertação, conforme mostrado nas Tabelas 13 e 14. Entretanto, com o intuito de trazer uma visão geral do comportamento de cada classificador, a última linha de cada tabela apresenta o valor médio de cada uma das métricas.

Os resultados demonstraram um desempenho adequado dos classificadores *Random Forest* e *XGBoost* na predição do lado de maior contribuição harmônica. Ambos os classificadores

Tabela 12 – Melhores Hiperparâmetros para *Random Forest* e *XGBoost*

Classificador	Hiperparâmetro	Valor
Random Forest	<i>bootstrap</i>	True
	<i>max_depth</i>	15
	<i>max_features</i>	'sqrt'
	<i>min_samples_leaf</i>	4
	<i>min_samples_split</i>	7
	<i>n_estimators</i>	127
XGBoost	<i>colsample_bytree</i>	0.3815
	<i>gamma</i>	0.1967
	<i>learning_rate</i>	0.1000
	<i>max_depth</i>	9
	<i>n_estimators</i>	150
	<i>reg_alpha</i>	0.1909
	<i>reg_lambda</i>	0.1331
	<i>subsample</i>	0.6967

Tabela 13 – Métricas de Desempenho para *Random Forest*

Fonte Harmônica	Acurácia	Precisão	Recall	F1-Score
6-pulsos	99,38%	98,78%	99,51%	99,15%
12-pulsos	99,20%	98,54%	99,26%	98,90%
SFC	99,11%	99,01%	98,53%	98,77%
Motor CC	99,56%	99,51%	99,26%	99,39%
TCR	99,29%	98,54%	99,51%	99,02%
Total	99,31%	98,88%	99,22%	99,05%

Tabela 14 – Métricas de Desempenho para *XGBoost*

Fonte Harmônica	Acurácia	Precisão	Recall	F1-Score
6-pulsos	99,73%	99,51%	99,75%	99,63%
12-pulsos	99,47%	98,79%	99,75%	99,27%
SFC	99,47%	99,02%	99,51%	99,27%
Motor CC	99,64%	99,75%	99,26%	99,51%
TCR	99,47%	99,02%	99,51%	99,27%
Total	99,57%	99,27%	99,56%	99,41%

apresentaram *F1-Scores* elevados para todas as fontes harmônicas, com o *XGBoost* mostrando um desempenho ligeiramente superior.


A *Random Forest* obteve uma média de *F1-Score* de 99,05%, enquanto o *XGBoost* alcançou 99,41%. Essa diferença pode ser atribuída à abordagem de *boosting* do *XGBoost*, que ajusta os erros das iterações anteriores e consegue capturar padrões mais complexos.

Ambos os modelos se destacaram em termos de consistência e robustez, com a *Random Forest* atingindo *F1-Scores* acima de 98,7% para todas as fontes harmônicas. O *XGBoost*, por sua vez, obteve *F1-Scores* ainda mais altos, com destaque para o retificador de 6-pulsos (99,63%) e para o drive de acionamento de motor CC (99,51%).

Em resumo, tanto a *Random Forest* quanto o *XGBoost* são eficazes para a tarefa de classificação das fontes harmônicas. A vantagem do *XGBoost* deve-se principalmente à sua capacidade de modelar interações mais complexas e sua maior precisão na captura de variações sutis nos dados.

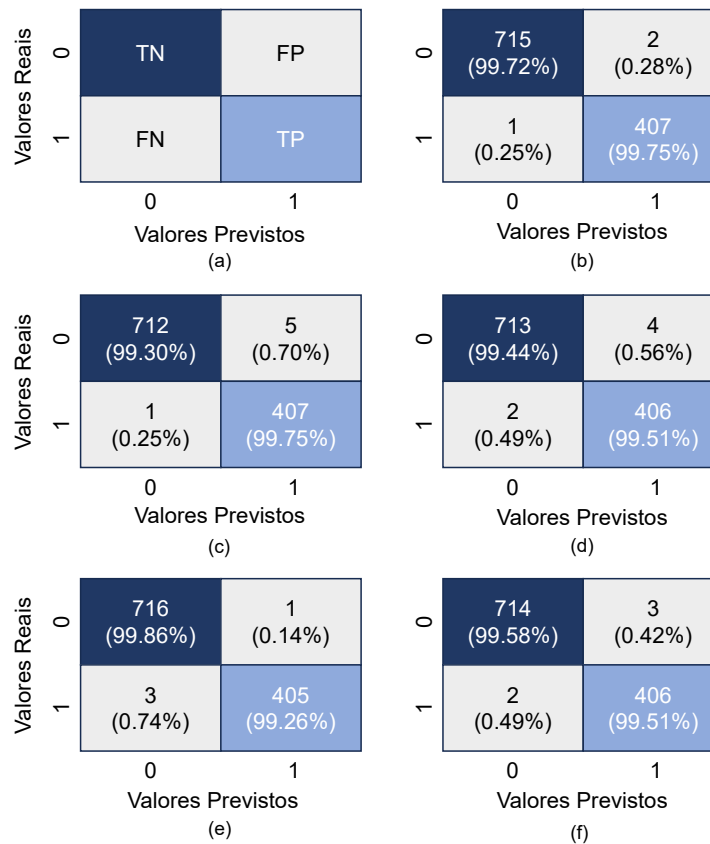
Além das métricas de desempenho previamente apresentadas, matrizes de confusão foram geradas para cada fonte harmônica e para cada classificador, conforme ilustrado nas Figuras 27 e 28, que apresentam os resultados para a *Random Forest* e o *XGBoost*, respectivamente. A matriz de confusão é uma ferramenta essencial para avaliar o desempenho do classificador, exibindo os valores de *TP*, *TN*, *FP* e *FN*. A análise de ambas as figuras revela uma alta taxa de *TP* e *TN*, indicando a capacidade dos modelos de identificar corretamente quando a fonte harmônica está localizada no lado da MR e no lado da concessionária, respectivamente. Esse comportamento demonstra que o modelo possui alta precisão na identificação do lado de origem da fonte harmônica.

Figura 27 – Matrizes de confusão - Resultados *Random Forest*: (a) interpretação de uma matriz de confusão genérica; (b) retificador de 6 pulsos; (c) retificador de 12 pulsos; (d) SFC; (e) acionamento de motor CC; e (f) TCR.



Fonte: Autoria própria.

Figura 28 – Matrizes de confusão - Resultados *XGBoost*: (a) interpretação de uma matriz de confusão genérica; (b) retificador de 6 pulsos; (c) retificador de 12 pulsos; (d) SFC; (e) acionamento de motor CC; e (f) TCR.




Fonte: Autoria própria.

5.2 Análise dos Resultados Considerando as Distâncias das Fontes Harmônicas em Relação ao PAC da MR

Nas simulações realizadas, cada fonte harmônica foi posicionada em uma barra específica do alimentador de teste IEEE 34 barras, sendo que cada barra está localizada a uma distância determinada do PAC. A posição da fonte harmônica exerce influência direta nas medições, principalmente de corrente, realizadas no PAC da MR. A Figura 29 ilustra um exemplo do sinal de corrente da fase A medido no PAC, evidenciando a diferença no formato da onda e na THD, dependendo da localização do retificador de 6 pulsos, seja na barra 802 ($\approx 53,4$ km do PAC), ou na barra 832 ($\approx 1,5$ km do PAC).

Como pode ser observado, o formato da onda do sinal de corrente medido no PAC com a fonte harmônica alocada na barra 832 apresenta uma distorção mais acentuada, com uma THD de 7,72%. Em contraste, quando a fonte harmônica está na barra 802, nota-se uma THD significativamente menor, de 4,83%. Este exemplo ilustra claramente que, à medida que a distância entre a fonte harmônica e o PAC da MR aumenta, o impacto na distorção harmônica diminui.

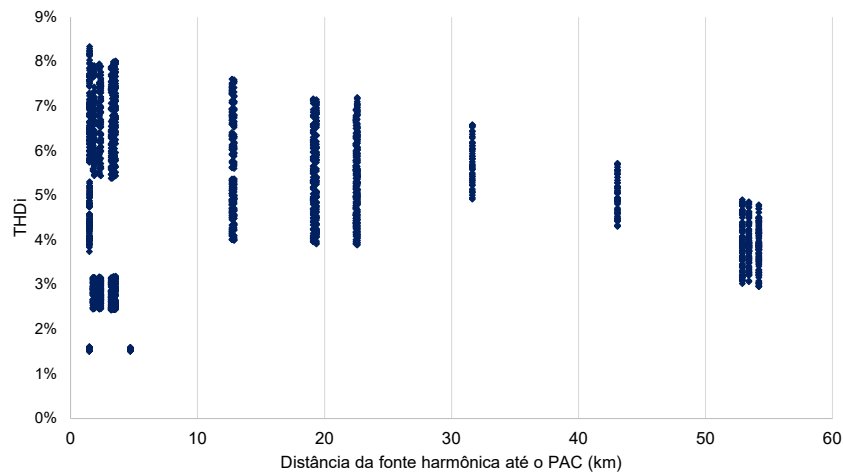
Figura 29 – Diferença no sinal de corrente e na THD em função da posição da carga harmônica no sistema: (a) Retificador de 6 pulsos alocado na barra 802 e (b) Retificador de 6 pulsos alocado na barra 832.



Fonte: Autoria própria.

A Figura 30 mostra um gráfico de dispersão da THD da corrente da fase A no PAC, considerando todas as simulações realizadas, com diferentes fontes harmônicas e condições operacionais da MR, em relação à distância (dada em quilômetros) da barra onde a fonte harmônica foi alocada até o PAC. É possível observar que, de maneira geral, nas simulações, há uma tendência de redução da distorção harmônica no PAC à medida que a fonte harmônica se afasta dele.

Figura 30 – Relação entre a THD e a distância da fonte harmônica até o PAC.



Fonte: Autoria própria.

Com base nessas informações, foi realizada a análise de desempenho dos modelos

Random Forest e *XGBoost* de acordo com a distância entre a fonte harmônica e o PAC. Para essa análise, foram definidos agrupamentos de distância, considerando que, como mostrado na Figura 30, há concentrações de barras em algumas distâncias específicas. Caso o desempenho dos modelos fosse avaliado individualmente por barra ou distância, o tamanho reduzido das amostras tornaria os resultados estatisticamente insignificantes.

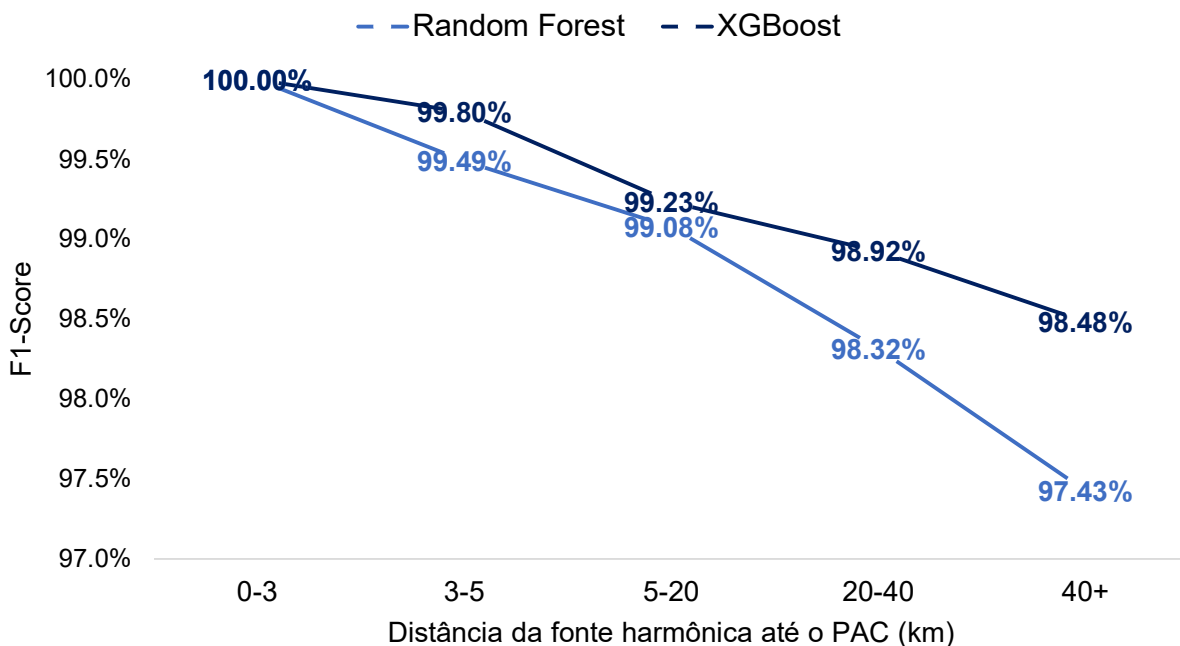
Assim, as distâncias foram segmentadas nas seguintes categorias:

- 0-3 km: cargas localizadas a até 3 km do PAC;
- 3-5 km: cargas localizadas a mais de 3 km e até 5 km do PAC;
- 5-20 km: cargas localizadas a mais de 5 km e até 20 km do PAC;
- 20-40 km: cargas localizadas a mais de 20 km e até 40 km do PAC;
- 40+ km: cargas localizadas a mais de 40 km do PAC.

Essas categorias foram definidas de modo que cada grupo tivesse quantidades similares de amostras, garantindo maior representatividade estatística para a análise.

Com isso, as Tabelas 15 e 16 apresentam os resultados de desempenho dos modelos *Random Forest* e *XGBoost*, respectivamente, para cada fonte harmônica e para as diferentes segmentações de distância entre a fonte harmônica e o PAC. A Figura 31 ilustra o *F1-Score* de cada modelo ao longo das diversas distâncias entre as fontes harmônicas e o PAC.

Figura 31 – *F1-Score* por segmentação de distância da fonte harmônica até o PAC para cada classificador.



Fonte: Autoria própria.

A análise dos dados revelou que tanto os modelos *Random Forest* quanto *XGBoost* apresentaram uma tendência de diminuição no *F1-Score* à medida que a distância entre a fonte

Tabela 15 – Desempenho da *Random Forest* por fonte harmônica e faixa de distância até o PAC

Fonte Harmônica	Distância até o PAC	Acurácia	Precisão	Recall	F1-Score
6-pulsos	0-3 km	100.00%	100.00%	100.00%	100.00%
	3-5 km	99.63%	98.99%	100.00%	99.49%
	5-20 km	98.89%	98.46%	98.46%	98.46%
	20-40 km	99.44%	98.48%	100.00%	99.24%
	40+ km	98.33%	97.01%	98.48%	97.74%
12-pulsos	0-3 km	100.00%	100.00%	100.00%	100.00%
	3-5 km	99.63%	98.99%	100.00%	99.49%
	5-20 km	98.89%	98.46%	98.46%	98.46%
	20-40 km	98.33%	96.97%	98.46%	97.71%
	40+ km	98.33%	97.01%	98.48%	97.74%
SFC	0-3 km	100.00%	100.00%	100.00%	100.00%
	3-5 km	99.26%	98.98%	98.98%	98.98%
	5-20 km	98.89%	98.46%	98.46%	98.46%
	20-40 km	98.89%	98.46%	98.46%	98.46%
	40+ km	97.78%	98.44%	95.45%	96.92%
Motor CC	0-3 km	100.00%	100.00%	100.00%	100.00%
	3-5 km	100.00%	100.00%	100.00%	100.00%
	5-20 km	100.00%	100.00%	100.00%	100.00%
	20-40 km	98.89%	98.46%	98.46%	98.46%
	40+ km	98.33%	98.46%	96.97%	97.71%
TCR	0-3 km	100.00%	100.00%	100.00%	100.00%
	3-5 km	99.63%	98.99%	100.00%	99.49%
	5-20 km	100.00%	100.00%	100.00%	100.00%
	20-40 km	98.33%	96.97%	98.46%	97.71%
	40+ km	97.78%	95.59%	98.48%	97.01%

harmônica e o PAC aumentava. Essa redução pode ser explicada pelo efeito atenuado das distorções harmônicas sobre o PAC conforme a distância aumenta. Com distâncias maiores, as fontes harmônicas exercem um impacto menor no PAC, o que torna mais difícil para os modelos identificar com precisão a localização da fonte harmônica, afetando, assim, o desempenho.

Apesar dessa tendência de queda, ambos os modelos demonstraram *F1-Scores* acima de 97% mesmo nas maiores distâncias (40+ km), o que evidencia a robustez e a capacidade de generalização dos classificadores. Isso sugere que, embora a capacidade de predição se reduza com o aumento da distância, os modelos continuam a apresentar um desempenho consistente, mantendo altos índices de precisão, *recall* e *F1-Score*, mesmo diante das variações na localização das fontes harmônicas. Dessa forma, ambos os modelos se mostram eficazes para lidar com a tarefa, demonstrando estabilidade e boa capacidade de adaptação em diferentes cenários de distância.

Tabela 16 – Desempenho do *XGBoost* por fonte harmônica e faixa de distância até o PAC

Fonte Harmônica	Distância até o PAC	Acurácia	Precisão	Recall	F1-Score
6-pulsos	0-3 km	100.00%	100.00%	100.00%	100.00%
	3-5 km	100.00%	100.00%	100.00%	100.00%
	5-20 km	99.44%	98.48%	100.00%	99.24%
	20-40 km	100.00%	100.00%	100.00%	100.00%
	40+ km	98.89%	98.48%	98.48%	98.48%
12-pulsos	0-3 km	100.00%	100.00%	100.00%	100.00%
	3-5 km	99.63%	98.99%	100.00%	99.49%
	5-20 km	99.44%	98.48%	100.00%	99.24%
	20-40 km	98.89%	98.46%	98.46%	98.46%
	40+ km	98.89%	97.06%	100.00%	98.51%
SFC	0-3 km	100.00%	100.00%	100.00%	100.00%
	3-5 km	99.63%	98.99%	100.00%	99.49%
	5-20 km	98.89%	98.46%	98.46%	98.46%
	20-40 km	99.44%	98.48%	100.00%	99.24%
	40+ km	98.89%	98.48%	98.48%	98.48%
Motor CC	0-3 km	100.00%	100.00%	100.00%	100.00%
	3-5 km	100.00%	100.00%	100.00%	100.00%
	5-20 km	100.00%	100.00%	100.00%	100.00%
	20-40 km	98.89%	98.46%	98.46%	98.46%
	40+ km	98.89%	100.00%	96.97%	98.46%
TCR	0-3 km	100.00%	100.00%	100.00%	100.00%
	3-5 km	100.00%	100.00%	100.00%	100.00%
	5-20 km	99.44%	98.48%	100.00%	99.24%
	20-40 km	98.89%	98.46%	98.46%	98.46%
	40+ km	98.89%	98.48%	98.48%	98.48%

CONCLUSÕES

Este projeto propôs uma abordagem baseada em aprendizado de máquina para identificar o lado responsável pela localização das fontes harmônicas em sistemas de distribuição, determinando se a principal contribuição para a distorção ocorre no lado da concessionária ou da microrrede (MR). Para isso, foram utilizados os classificadores *Random Forest* e *XGBoost*, que combinam fundamentos matemáticos consolidados com técnicas avançadas de aprendizado de máquina para otimizar a análise dos sinais de tensão e corrente.

A metodologia foi validada por meio de simulações no alimentador IEEE 34 barras utilizando o software ATP. Nessas simulações, sinais trifásicos de tensão e corrente foram adquiridos para a extração de características relevantes. Cada cenário considerou a presença de apenas uma fonte harmônica por vez, podendo ser um retificador de 6 ou 12 pulsos, um SFC, um *drive* de motor CC ou um TCR, localizada exclusivamente no lado da concessionária ou da microrrede. Essa configuração garantiu que não houvesse simultaneidade de fontes harmônicas em ambos os lados. A base de dados gerada foi utilizada para treinar e validar os modelos, que alcançaram um *F1-score* superior a 99%, demonstrando a robustez da abordagem na identificação do lado predominante na contribuição harmônica.

Todo o processo foi automatizado via *Python*, que permitiu a definição dos cenários, execução das simulações, estruturação da base de dados e implementação do pipeline de aprendizado de máquina, incluindo a otimização dos modelos com *Optuna*.

Apesar do alto desempenho dos modelos, é fundamental destacar que a abordagem proposta se limitou à identificação do lado dominante na contribuição harmônica, ou seja, do lado em que as fontes foram implementadas, sem considerar cenários nos quais múltiplas fontes operam simultaneamente em diferentes pontos da rede. Na prática, essa condição é frequente, tornando essencial o desenvolvimento de um modelo capaz de quantificar a participação relativa de cada lado, proporcionando uma análise mais realista da distorção harmônica total no PAC.

Diante dessas considerações, uma linha de investigação futura relevante envolve a am-

pliação das simulações para contemplar cenários mais realistas, nos quais múltiplas fontes harmônicas estejam simultaneamente presentes em diferentes barramentos. Esse aprimoramento possibilitaria uma modelagem mais próxima da realidade dos sistemas de distribuição, aumentando a aplicabilidade prática da metodologia proposta. Além disso, é essencial considerar a influência dos Recursos Energéticos Distribuídos (*Distributed Energy Resources* (DERs)), como painéis fotovoltaicos, turbinas eólicas, sistemas de armazenamento de energia por baterias (*Battery Energy Storage Systems* (BESS)), geradores a gás/diesel e veículos elétricos. Estudos indicam que esses sistemas podem injetar harmônicos na rede elétrica, exigindo uma análise detalhada de seus impactos tanto no lado da microrrede quanto no da concessionária. Destaca-se que os DERs, especialmente os BESS, podem estar distribuídos ao longo do alimentador e não apenas na MR, tornando essencial uma abordagem mais abrangente para a análise harmônica.

Por fim, o desenvolvimento de um modelo que quantifique a contribuição harmônica de cada lado da rede representaria um avanço significativo no monitoramento da qualidade da energia elétrica. Uma abordagem que forneça não apenas a localização da principal fonte harmônica, mas também uma análise percentual da responsabilidade de cada lado da rede, permitiria um controle mais eficiente da distorção harmônica e uma melhor fundamentação para ações regulatórias e técnicas. Dessa forma, os aprimoramentos sugeridos podem tornar a metodologia proposta ainda mais robusta e aplicável a diferentes cenários elétricos, consolidando sua utilidade para concessionárias e operadores de sistemas elétricos na busca pela melhoria da qualidade da energia elétrica.

REFERÊNCIAS

AKIBA, T.; SANO, S.; YAMAMOTO, T.; KOYAMA, M. Optuna: A next-generation hyperparameter optimization framework. **Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery Data Mining**, ACM, p. 2623–2631, 2020. Citado na página 61.

ALI, Z.; ABDULJABBAR, Z.; TAHIR, H.; SALLOW, A.; ALMUFTI, S. Exploring the power of extreme gradient boosting algorithm in machine learning: A review. **Academic Journal of Nawroz University**, v. 12, p. 320–334, 05 2023. Citado 2 vezes nas páginas 31 e 32.

ANEEL. **Resolução Normativa ANEEL nº 1000/21**. Brasília, DF, Brazil: Agência Nacional de Energia Elétrica (ANEEL), 2021. Citado na página 2.

ARRILLAGA, J.; WATSON, N. **Power System Harmonics**. Chichester, UK: John Wiley & Sons, 2003. 499 p. ISBN 978-0-471-89280-2. Citado na página 19.

BAGGINI, A. **Handbook of Power Quality**. Chichester, UK: Wiley, 2008. 768 p. ISBN 9780470065617. Citado 10 vezes nas páginas 8, 10, 11, 12, 13, 14, 15, 16, 20 e 21.

BOLLEN, M. H. J. **Understanding Power Quality Problems: Voltage Sags and Interruptions**. Hoboken, NJ, USA: Wiley-IEEE Press, 2006. 672 p. ISBN 978-0-471-67532-1. Citado na página 1.

BORGES, F. A. S. **Extração de características combinadas com árvore de decisão para detecção e classificação dos distúrbios de qualidade da energia elétrica**. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, Brasil, 2013. Citado na página 55.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. ISSN 1573-0565. Citado 2 vezes nas páginas 29 e 30.

CHEN, C.; LIU, X.; KOVAL, D.; XU, W.; TAYJASANANT, T. Critical impedance method: A new detecting harmonic sources method in distribution systems. **IEEE Transactions on Power Delivery**, v. 19, n. 1, p. 288–297, 2004. Citado na página 41.

CHEN, H.; LI, F.; WANG, Y. Wind power forecasting based on outlier smooth transition autoregressive garch model. **Journal of Modern Power Systems and Clean Energy**, v. 6, 2018. Citado na página 43.

CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: **Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. New York, NY, USA: Association for Computing Machinery, 2016. p. 785–794. ISBN 9781450342322. Citado na página 31.

CRISTALDI, L.; FERRERO, A. A digital method for the identification of the source of distortion in electric power systems. **IEEE Transactions on Instrumentation and Measurement**, v. 44, n. 1, p. 14–18, 1995. Citado 2 vezes nas páginas 33 e 34.

DAS, J. C. **Harmonic Distortion Limits According to Standards**. Hoboken, NJ, USA: John Wiley & Sons, Inc, 2015. 427–451 p. ISBN 9781119035725. Citado 2 vezes nas páginas 20 e 21.

DUGAN, R. C.; MCGRANAGHAN, M. F.; SANTOSO, S.; BEATY, H. W. **Electrical Power Systems Quality**. 3rd. ed. New York, NY, USA: McGraw Hill, 2012. 577 p. ISBN 9780071761550. Citado 3 vezes nas páginas 7, 8 e 14.

EFRON, B.; TIBSHIRANI, R. J. **An Introduction to the Bootstrap**. 1st. ed. New York: Chapman and Hall/CRC, 1994. 456 p. ISBN 9780429246593. Citado na página 29.

FERNANDES, R. A. S.; BARBOSA, D.; MONTAGNOLI, A. N.; SUETAKE, M. Determining the responsibility sharing of harmonic distortion: An approach based on decision trees and neural-fuzzy systems. **2023 IEEE PES Innovative Smart Grid Technologies Latin America (ISGT-LA)**, p. 225–229, 2023. Citado 4 vezes nas páginas 4, 44, 46 e 47.

GOMEZ-EXPOSITO ANTONIO CONEJO, A. J. C. C. **Electric Energy Systems: Analysis and Operation**. 2nd. ed. Boca Raton, FL, USA: CRC Press, 2018. 664 p. ISBN 9780367734275. Citado na página 17.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge, MA: MIT Press, 2016. 800 p. ISBN 9780262035613. Citado na página 61.

GUO, M.; CHEN, W.; JIN, Q. Research on identification and calculation method of harmonic active power responsibility. **2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia)**, p. 2302–2307, 2019. Citado na página 42.

GUPTA, M.; GAO, J.; AGGARWAL, C. C.; HAN, J. Outlier detection for temporal data: A survey. **IEEE Transactions on Knowledge and Data Engineering**, v. 26, n. 9, p. 2250–2267, 2014. Citado na página 43.

HAN, J.-H.; LEE, K.; SONG, C. S.; JANG, G.-S.; BYEON, G.; PARK, C.-H. A new assessment for the total harmonic contributions at the point of common coupling. **Journal of Electrical Engineering and Technology**, v. 9, n. 1, p. 6–14, 2014. Citado na página 43.

HOU, S.; FEI, J.; CHEN, C.; CHU, Y. Finite-time adaptive fuzzy-neural-network control of active power filter. **IEEE Transactions on Power Electronics**, v. 34, p. 10298–10313, 2019. Citado na página 42.

HUANG, C.-H.; LIN, C.-H. Multiple harmonic-source classification using a self-organization feature map network with voltage–current wavelet transformation patterns. **Applied Mathematical Modelling**, v. 39, n. 19, p. 5849–5861, 2015. Citado 3 vezes nas páginas 43, 44 e 47.

IEC. **Electromagnetic Compatibility (EMC) - Part 3-4: Limits - Limitation of Emission of Harmonic Currents in Low-Voltage Power Supply Systems for Equipment with Rated Current Greater than 16 A**. 1st. ed. Geneva, Switzerland: International Electrotechnical Commission (IEC), 1998. 29 p. ISBN 2831845696. Citado na página 24.

_____. **Electromagnetic Compatibility (EMC) - Part 3-2: Limits - Limits for Harmonic Current Emissions (Equipment Input Current 16 A per Phase)**. Geneva, Switzerland: International Electrotechnical Commission (IEC), 2014. 29 p. ISBN 9780580772344. Citado 2 vezes nas páginas 4 e 24.

IEEE. **IEEE Recommended Practices and Requirements for Harmonic Control in Electric Power Systems**. 2014. Citado 4 vezes nas páginas 2, 4, 24 e 25.

JHAVERI, R. H.; REVATHI, A.; RAMANA, K.; RAUT, R.; DHANARAJ, R. K. A review on machine learning strategies for real-world engineering applications. **Mobile Information Systems**, p. 1–26, 2022. Citado na página 27.

JIA, X.; HUA, H.; CAO, D.; ZHAO, C. Determining harmonic contributions based on complex least squares method. **Zhongguo Dianji Gongcheng Xuebao/Proceedings of the Chinese Society of Electrical Engineering**, v. 33, p. 149–155, 02 2013. Citado na página 43.

JOHNSON, D.; HASSAN, K. Issues of power quality in electrical systems. **International Journal of Energy and Power Engineering**, v. 5, n. 4, p. 148, 2016. Citado na página 1.

JR., G. V. de A.; NAIDU, S. R.; NERI, M. G. G.; COSTA, E. G. da. Estimation of the utility's and consumer's contribution to harmonic distortion. **IEEE Transactions on Instrumentation and Measurement**, v. 58, n. 11, p. 3817–3823, 2009. Citado na página 43.

KHAN, I.; VIJAY, A. S.; DOOLLA, S. Nonlinear load harmonic mitigation strategies in microgrids: State of the art. **IEEE Systems Journal**, v. 16, n. 3, p. 4243–4255, 2022. Citado na página 22.

KHAN, S.; SINGH, B.; MAKHIJA, P. A review on power quality problems and its improvement techniques. **Proceedings of the 2017 Innovations in Power and Advanced Computing Technologies (i-PACT)**, p. 1–7, 2017. Citado 2 vezes nas páginas 1 e 2.

LASSETER, R. Microgrids. **2002 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No.02CH37309)**, v. 1, p. 305–308, 2002. Citado na página 21.

LI, C.; XU, W.; TAYJASANANT, T. A "critical impedance-based method for identifying harmonic sources. **IEEE Transactions on Power Delivery**, v. 19, p. 671–678, 2002. Citado 4 vezes nas páginas 3, 35, 41 e 42.

LIAW, A.; WIENER, M. Classification and regression by randomforest. **R News**, The R Foundation, v. 2, n. 3, p. 18–22, 2002. Citado na página 30.

LIN, C.-H.; WANG, C.-H. Adaptive wavelet networks for power-quality detection and discrimination in a power system. **IEEE Transactions on Power Delivery**, v. 21, n. 3, p. 1106–1113, 2006. Citado na página 52.

LIN, W.-M.; LIN, C.-H.; TU, K.-P.; WU, C.-H. Multiple harmonic source detection and equipment identification with cascade correlation network. **IEEE Transactions on Power Delivery**, v. 20, n. 3, p. 2166–2173, 2005. Citado na página 52.

LIU, Y.; XU, W. A method for determining customer and utility harmonic contributions at the point of common coupling. **IEEE Transactions on Power Delivery**, v. 15, n. 2, p. 804–811, 2000. Citado 6 vezes nas páginas 2, 3, 4, 22, 38 e 41.

MATHUR, R.; VARMA, R. **Thyristor-Based FACTS Controllers for Electrical Transmission Systems**. Hoboken, New Jersey, USA: Wiley-IEEE Press, 2002. 495 p. ISBN 9780470546680. Citado 3 vezes nas páginas 16, 17 e 18.

- MATOS, E. O. de; SOARES, T. M.; BEZERRA, U. H.; TOSTES, M. E. de L.; MANITO, A. R. A.; COSTA, B. C. Using linear and non-parametric regression models to describe the contribution of non-linear loads on the voltage harmonic distortions in the electrical grid. **IET Generation, Transmission Distribution**, v. 10, 03 2016. Citado na página 43.
- MAZUMDAR, J.; HARLEY, R. G.; LAMBERT, F. C.; VENAYAGAMOORTHY, G. K.; PAGE, M. L. Intelligent tool for determining the true harmonic current contribution of a customer in a power distribution network. **IEEE Transactions on Industry Applications**, v. 44, n. 5, p. 1477–1485, 2008. Citado 3 vezes nas páginas 43, 44 e 47.
- MCEACHERN, A.; GRADY, W.; MONCRIEF, W.; HEYDT, G.; MCGRANAGHAN, M. Revenue and harmonics: an evaluation of some proposed rate structures. **IEEE Transactions on Power Delivery**, v. 10, n. 1, p. 474–482, 1995. Citado na página 23.
- MURUGAN, A.; KUMAR, V. S. Determining true harmonic contributions of sources using neural network. **Neurocomputing**, v. 173, p. 72 – 80, 2016. Citado 6 vezes nas páginas 3, 4, 43, 44, 45 e 47.
- OLIVARES, D. E.; MEHRIZI-SANI, A.; ETEMADI, A. H.; CAÑIZARES, C. A.; IRAVANI, R.; KAZERANI, M.; HAJIMIRAGHA, A. H.; GOMIS-BELLMUNT, O.; SAEEDIFARD, M.; PALMA-BEHNKE, R.; JIMÉNEZ-ESTÉVEZ, G. A.; HATZIARGYRIOU, N. D. Trends in microgrid control. **IEEE Transactions on Smart Grid**, v. 5, n. 4, p. 1905–1919, 2014. Citado na página 22.
- OLSON, D. L.; DELEN, D. **Performance Evaluation for Predictive Modeling**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. 137–147 p. ISBN 978-3-540-76917-0. Citado 2 vezes nas páginas 59 e 60.
- PARK, J.-I.; LEE, H.; YOON, M.; PARK, C.-H. A novel method for assessing the contribution of harmonic sources to voltage distortion in power systems. **IEEE Access**, v. 8, p. 76568–76579, 2020. Citado na página 43.
- PFAJFAR, T.; BLAZIC, B.; PAPIC, I. Harmonic contributions evaluation with the harmonic current vector method. **IEEE Transactions on Power Delivery**, v. 23, n. 1, p. 425–433, 2008. Citado na página 23.
- PRIKLER, L.; HOIDALEN, H. K. **ATPDraw Version 5.6 for Windows 9x/NT/2000/XP/Vista Users' Manual**. Trondheim, Norway, 2009. 270 p. Citado na página 50.
- PROAKIS, J. G.; MANOLAKIS, D. G. **Digital Signal Processing: Principles, Algorithms, and Applications**. 4th. ed. Upper Saddle River, NJ: Pearson Prentice Hall, 2006. ISBN 978-0131873742. Citado na página 10.
- PRODIST. Módulo 8 procedimento de distribuição - qualidade do fornecimento de energia elétrica. **Agência Nacional de Energia Elétrica - ANEEL**, 2021. Citado 2 vezes nas páginas 25 e 26.
- ROBERT, A.; DEFLANDRE, T.; GUNTHER, E.; BERGERON, R.; EMANUEL, A.; FERRANTE, A.; FINLAY, G.; GRETSCH, R.; GUARINI, A.; IGLESIAS, J. G.; HARTMANN, D.; LAHTINEN, M.; MARSHALL, R.; OONISHI, K.; PINCELLA, C.; POULSEN, S.; RIBEIRO, P.; SAMOTYJ, M.; SAND, K.; SMID, J.; WRIGHT, P.; ZHELESKO, Y. Guide for assessing the

network harmonic impedance. In: **14th International Conference and Exhibition on Electricity Distribution. Part 1. Contributions (IEE Conf. Publ. No. 438)**. [S.l.: s.n.], 1997. v. 2, p. 3/1–310 vol.2. Citado na página 3.

RODRIGUES, J. E. **Interferência de harmônicas em equipamentos de medição de energia elétrica**. Dissertação (Mestrado) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2009. Citado na página 20.

RÖNNBERG, S.; BOLLEN, M. Power quality issues in the electric power system of the future. **The Electric Journal**, v. 29, p. 49–61, 2016. Citado na página 1.

ROSA, F. C. D. L. **Harmonics and Power Systems**. 1st. ed. Boca Raton: CRC Press, 2006. 208 p. ISBN 9780429126369. Citado na página 7.

SAFARGHOLI, F.; MALEKIAN, K.; SCHUFFT, W. On the dominant harmonic source identification— part i: Review of methods. **IEEE Transactions on Power Delivery**, v. 33, n. 3, p. 1268–1277, 2018. Citado na página 42.

SAFARGHOLI FARHAD, K.; SCHUFFT, W. On the dominant harmonic source identification—part ii: Application and interpretation of methods. **IEEE Transactions on Power Delivery**, v. 33, n. 3, p. 1278–1287, 2018. Citado na página 42.

SAHOO, H.; SHARMA, P.; RATH, N. Robust harmonic estimation using forgetting factor rls. **2011 Annual IEEE India Conference: Engineering Sustainable Solutions, INDICON-2011**, p. 1–5, 2011. Citado na página 43.

SANTOS, A. F. M. **Otimização multiobjetivo aplicada na identificação de parâmetros para análise eletroencefalográfica**. Dissertação (Doutorado) — Universidade Federal de Uberlândia, Uberlândia, Brasil, 2019. Citado na página 55.

SCHNEIDER, K. P.; MATHER, B. A.; PAL, B. C.; TEN, C.-W.; SHIREK, G. J.; ZHU, H.; FULLER, J. C.; PEREIRA, J. L. R.; OCHOA, L. F.; ARAUJO, L. R. de; DUGAN, R. C.; MATTHIAS, S.; PAUDYAL, S.; MCDERMOTT, T. E.; KERSTING, W. Analytic considerations and design basis for the iee distribution test feeders. **IEEE Transactions on Power Systems**, v. 33, n. 3, p. 3181–3188, 2018. Citado na página 50.

SHA, H.; MEI, F.; ZHANG, C.; PAN, Y.; ZHENG, J.; LI, T. Multi-harmonic sources harmonic contribution determination based on data filtering and cluster analysis. **IEEE Access**, v. 7, p. 85276–85285, 2019. Citado 2 vezes nas páginas 44 e 47.

SILVA, C. B.; SILVA, I. N.; ARAVECHIA, J. V.; FERNANDES, R. A. A fuzzy-based approach for harmonic contribution determination at points of common coupling. **IEEE Eindhoven PowerTech**, p. 1–6, 2015. Citado 4 vezes nas páginas 4, 44, 45 e 47.

SOUZA, J. d. S. **Análise de atributos de classificação para o diagnóstico de falhas em rolamentos baseado em SVM**. Dissertação (Mestrado) — Universidade Federal do Pará, Tucuruí, Brasil, 2019. Citado na página 55.

SRINIVASAN, K. On separating customer and supply side harmonic contributions. **IEEE Transactions on Power Delivery**, v. 11, n. 2, p. 1003–1012, 1996. Citado 2 vezes nas páginas 38 e 40.

STEIN, E. M.; SHAKARCHI, R. **Fourier Analysis: An Introduction**. Princeton, NJ: Princeton University Press, 2003. 328 p. ISBN 978-0691113845. Citado na página 9.

- SUN, Y.; LI, S.; XU, Q.; XIE, X.; JIN, Z.; SHI, F.; ZHANG, H. Harmonic contribution evaluation based on the distribution-level pmus. **IEEE Transactions on Power Delivery**, v. 36, p. 909–919, 2021. Citado na página 43.
- TANAKA, T.; AKAGI, H. A new method of harmonic power detection based on the instantaneous active power in three-phase circuits. **IEEE Transactions on Power Delivery**, v. 10, n. 4, 10 1995. Citado na página 35.
- UDDIN, M.; MO, H.; DONG, D.; ELSAWAH, S.; ZHU, J.; GUERRERO, J. M. Microgrids: A review, outstanding issues and future trends. **Energy Strategy Reviews**, v. 49, p. 101127, 2023. Citado na página 2.
- UGWUAGBO, E.; BALOGUN, A.; RAY, B.; ANWAR, A.; UGWUISHIWU, C. Total harmonics distortion prediction at the point of common coupling of industrial load with the grid using artificial neural network. **Energy and AI**, v. 14, p. 100281, 2023. ISSN 2666-5468. Citado 2 vezes nas páginas 3 e 4.
- WANG, F.; JIANG, J. A novel static frequency converter based on multilevel cascaded h-bridge used for the startup of synchronous motor in pumped-storage power station. **Energy Conversion and Management**, v. 52, n. 5, p. 2085–2091, 2011. Citado 3 vezes nas páginas 17, 18 e 19.
- WU, J.; QIU, H.; XU, J.; ZHOU, F.; DAI, K.; YANG, C.; LV, D. Quantifying harmonic responsibilities based on kurtosis detection principle of amplitude fluctuations. **IEEE Access**, v. 6, p. 64292–64300, 2018. Citado na página 43.
- XU, W.; AHMED, E.; ZHANG, X.; LIU, X. Measurement of network harmonic impedances: practical implementation issues and their solutions. **IEEE Transactions on Power Delivery**, v. 17, n. 1, p. 210–216, 2002. Citado 2 vezes nas páginas 3 e 4.
- XU, W.; LIU, X.; LIU, Y. An investigation on the validity of power-direction method for harmonic source determination. **IEEE Transactions on Power Delivery**, v. 18, n. 1, p. 214–219, 2003. Citado 7 vezes nas páginas 15, 3, 34, 35, 36, 37 e 41.
- XU, W.; LIU, Y. A method to determine customer harmonic contributions for incentive-based harmonic control applications. **IEEE Power Engineering Society Summer Meeting. Conference Proceedings (Cat. No.99CH36364)**, v. 1, p. 361–366, 1999. Citado na página 38.
- YANG, S.; LEI, Q.; PENG, F. Z.; QIAN, Z. A robust control scheme for grid-connected voltage-source inverters. **IEEE Transactions on Industrial Electronics**, v. 58, n. 1, p. 202–212, 2011. Citado na página 49.
- ZHANG, W.; YANG, H.-G. Method for assessing harmonic emission level based on binary linear regression. **Engineering, Environmental Science**, v. 24, p. 50–53, 06 2004. Citado na página 43.
- ZOU, M.; DJOKIC, S. Z. A review of approaches for the detection and treatment of outliers in processing wind turbine and wind farm measurements. **Energies**, v. 13, n. 16, 2020. Citado na página 43.
- ŠPELKO, A.; PAPIČ, I.; DJOKIC, S. Z. A voltage-only method for assessing harmonic contribution from a customer installation. **18th International Conference on Harmonics and Quality of Power (ICHQP)**, p. 1–7, 2018. Citado na página 42.