

**Maísa Lauriane Ferreira dos Santos**

# **Análise de Distúrbios na Qualidade da Energia Elétrica Empregando a Decomposição Variacional de Modos**

**João Pessoa – PB**  
**Março de 2023**

**Maísa Lauriane Ferreira dos Santos**

## **Análise de Distúrbios na Qualidade da Energia Elétrica Empregando a Decomposição Variacional de Modos**

Dissertação de Mestrado submetida ao Programa de Pós-Graduação em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, como requisito necessário à obtenção do grau de Mestre em Ciências no Domínio da Engenharia Elétrica.

Área de Concentração: Telecomunicações  
Linha de Pesquisa: Processamento de Sinais

Suzete Élide Nóbrega Correia, Dra.  
Orientação

Álvaro de Medeiros Maciel, Dr.  
Cleumar da Silva Moreira, Dr.  
Coorientação

João Pessoa – PB, Março de 2023

© Maísa Lauriane Ferreira dos Santos — maisalfsantos@gmail.com

Dados Internacionais de Catalogação na Publicação – CIP  
Biblioteca Nilo Peçanha – IFPB, *campus* João Pessoa

S237a	<p>Santos, Maísa Lauriane Ferreira dos. Análise de distúrbios na qualidade da energia elétrica empregando a decomposição variacional de modos / Maísa Lauriane Ferreira dos Santos. – 2023. 72 f. : il. Dissertação (Mestrado em Engenharia Elétrica) – Instituto Federal de Educação da Paraíba – IFPB / Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), 2023. Orientação : Profa. D.ra Suzete Élide Nóbrega Correia. Coorientação : Prof. D.r Álvaro de Medeiros Maciel e Prof. D.r Cleumar da Silva Moreira. 1. Distúrbios da qualidade da energia elétrica – análise. 2. Decomposição variacional de modos. 3. Processamentos de sinais. 4. Randon Forest. I. Título. CDU 621.3.05:519.873(043)</p>
-------	---



MINISTÉRIO DA EDUCAÇÃO  
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA  
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA

**PROGRAMA DE PÓS-GRADUAÇÃO *STRICTO SENSU***

**MESTRADO EM ENGENHARIA ELÉTRICA**

**MAÍSA LAURIANE FERREIRA DOS SANTOS**

**ANÁLISE DE DISTÚRBIOS NA QUALIDADE DA ENERGIA ELÉTRICA EMPREGANDO A DECOMPOSIÇÃO  
VARIACIONAL DE MODOS**

Dissertação apresentada como requisito para obtenção do título de Mestre em Engenharia Elétrica, pelo Programa de Pós- Graduação em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba – IFPB - Campus João Pessoa.

Aprovado em 30 de março de 2023.

**Membros da Banca Examinadora:**

**Dr<sup>a</sup>. Suzete Élide Nóbrega Correia**

IFPB

**Dr. Cleumar da Silva Moreira**

IFPB

**Dr. Alvaro de Medeiros Maciel**

IFPB

**Dr. Edgard Luiz Lopes Fabricio**

IFPB

**Dr. José Maurício Ramos de Souza Neto**

UFPB

João Pessoa/2023

Documento assinado eletronicamente por:

- **Suzete Elida Nobrega Correia**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 11/04/2023 14:49:43.
- **Alvaro de Medeiros Maciel**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 11/04/2023 14:53:40.
- **Cleumar da Silva Moreira**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 11/04/2023 16:24:20.
- **Edgard Luiz Lopes Fabricio**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 13/04/2023 10:31:40.
- **José Maurício Ramos de Souza Neto**, PROFESSOR DE ENSINO SUPERIOR NA ÁREA DE ORIENTAÇÃO EDUCACIONAL, em 13/04/2023 11:36:25.

Este documento foi emitido pelo SUAP em 31/03/2023. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código 411951  
Verificador: 2ceb7f4962  
Código de Autenticação:



Av. Primeiro de Maio, 720, Jaguaribe, JOÃO PESSOA / PB, CEP 58015-435  
<http://ifpb.edu.br> - (83) 3612-1200

## AGRADECIMENTOS

Agradeço primeiramente a Deus, pela minha vida e por me permitir ultrapassar os obstáculos, que foram muitos em meio a uma pandemia, por vezes pensei que não iria conseguir, mas Ele segurou minha mão.

Agradecimento especial à minha amada mãe Maria, meu amado pai Laurentino e meu querido irmão Haniel, que me incentivaram e estiveram ao meu lado em todos os momentos e a todos os familiares que tanto amo, muito obrigada pelo apoio e por sempre acreditarem em mim.

Agradeço a Lucas Cardoso seu carinho, companheirismo e incentivo foram fundamentais.

Agradeço à minha orientadora professora Suzete Élide Nóbrega Correia por toda compreensão e paciência comigo, pelas contribuições prestadas para o desenvolvimento da dissertação, assim como aos conselhos pessoais e profissionais que estarão sempre em meu coração.

Agradeço aos coorientadores Cleumar da Silva Moreira e Álvaro de Medeiros Maciel pelas contribuições e conselhos prestados ao longo do desenvolvimento desta pesquisa. Aos professores da pós-graduação por todo o conhecimento compartilhado.

Aos amigos da Pós-Graduação em Engenharia Elétrica do IFPB em especial: Luana, Leonardo, Yago, pela amizade construída desde a graduação que se estendeu para a pós, meus sinceros agradecimentos por todo o conhecimento e experiências compartilhadas.

Agradeço às minhas amigas e companheiras de vida: Yasmin, Lívia, Sammara, Clara, Amora, Laryssa, Marília, Marina, pelo amor, o carinho, compreensão quando estive ausente, e pela força nos momentos de luta.

Agradeço ao Instituto Federal da Paraíba (IFPB) Campus João Pessoa, que sempre foi minha segunda casa desde a graduação, pela disponibilização de materiais e auxílios necessários para a conclusão desta pesquisa.

Ao CNPq pelo apoio financeiro.

A todos que contribuíram, direta ou indiretamente, no desenvolvimento desta dissertação, enriquecendo o meu processo de aprendizado.

*"A maior glória de viver não está em nunca cair, mas em nos levantar toda vez que caímos."*

*Nelson Mandela*

## RESUMO

Este trabalho aborda a classificação de Distúrbios que afetam a Qualidade da Energia Elétrica (QEE), utilizando a Decomposição Variacional de Modos (*Variational Mode Decomposition* - VMD) e o algoritmo de classificação *Random Forest* (RF). Nove classes de distúrbios elétricos foram gerados baseados em equações paramétricas, aos quais foram acrescentados ruídos gaussianos com relação sinal-ruído de 30, 40 e 50 dB, para avaliar a robustez do método. A VMD foi utilizada para decompor os sinais em Funções de Modo Intrínseco (*Intrinsic Mode Function*, IMF), das quais foram obtidas seis características, que foram empregadas na classificação dos Distúrbios da Qualidade da Energia Elétrica (DQEE). O método implementado atingiu acurácia de classificação de 99,71% para sinais sem ruídos e 99,49% para sinais sob ruído de 50 db. Os resultados obtidos comprovam o desempenho satisfatório do método proposto em termos de precisão, mesmo sob condições ruidosas.

**Palavras-chave:** Distúrbios da Qualidade da Energia Elétrica, Decomposição Variacional de Modos, Processamento de Sinais, *Randon Forest*.



## ABSTRACT

This work deals with the classification of Disturbances that affect the Electricity Quality (QEE) using the (*Variational Mode Decomposition - VMD*) and the *Random Forest* (RF) classification algorithm. Nine classes of electrical disturbances were generated based on parametric equations to evaluate the robustness of the method were also added Gaussian noises with signal to noise ratios of 30 40 and 50db. VMD was used to decompose the signals into Intrinsic Mode Functions (IMFs) from which six characteristics were obtained, which were used in the classification of Power Quality Disturbances (PQD). The implemented method achieved classification accuracy of 99.71% for noiseless signals and 99.49% for signals with 50 db noise, the obtained results prove the satisfactory performance of the proposed method in terms of accuracy even under noisy conditions.

**Keywords:** Power Quality Disturbances, Variational Mode Decomposition, Signal Processing, *Machine Learning*.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Afundamento de Tensão (SAG). . . . .	27
Figura 2 – Elevação de Tensão (SWELL). . . . .	28
Figura 3 – Interrupção. . . . .	29
Figura 4 – Transitório Impulsivo. . . . .	30
Figura 5 – Transitório Oscilatório. . . . .	30
Figura 6 – Sinal senoidal com Harmônicos. . . . .	31
Figura 7 – <i>Notching</i> . . . . .	32
Figura 8 – Flicker. . . . .	32
Figura 9 – Envoltórias EMD. . . . .	37
Figura 10 – Sinal multicomponente. . . . .	41
Figura 11 – Decomposição EMD e análise tempo frequência do sinal multicomponente. . . . .	42
Figura 12 – Decomposição VMD e análise tempo frequência do sinal multicomponente. . . . .	42
Figura 13 – Sinal multicomponente de banda estreita. . . . .	43
Figura 14 – Decomposição EMD e análise tempo frequência do sinal multicomponente de banda estreita. . . . .	43
Figura 15 – Decomposição VMD e análise tempo frequência do sinal multicomponente de banda estreita. . . . .	44
Figura 16 – Sinal multicomponente de banda estreita. . . . .	45
Figura 17 – Decomposição EMD e análise tempo frequência do sinal multicomponente de banda estreita. . . . .	45
Figura 18 – Decomposição VMD e análise tempo frequência do sinal multicomponente de banda estreita. . . . .	46
Figura 19 – Sinal com ruído com SNR 10 dB. . . . .	46
Figura 20 – EMD do sinal com ruído com SNR 10 dB. . . . .	47
Figura 21 – VMD do sinal com ruído com SNR 10 dB. . . . .	48
Figura 22 – Diagrama do <i>Random Forest</i> . . . . .	50
Figura 23 – Fluxograma metodologia proposta. . . . .	53
Figura 24 – Sinais de tensão em estudo. . . . .	54
Figura 25 – VMD do sinal senoidal puro. . . . .	55
Figura 26 – VMD do sinal Afundamento. . . . .	56
Figura 27 – VMD do sinal Elevação. . . . .	56
Figura 28 – VMD do sinal Interrupção. . . . .	57
Figura 29 – VMD do sinal Transitório impulsivo. . . . .	57
Figura 30 – VMD do sinal Transitório Oscilatório. . . . .	58
Figura 31 – VMD do sinal com harmônicos. . . . .	58

Figura 32 – VMD do sinal com <i>Fliker</i> . . . . .	59
Figura 33 – VMD do sinal <i>notching</i> . . . . .	59
Figura 34 – Distribuição dos valores máximo para IMF1. . . . .	60
Figura 35 – Distribuição dos valores mínimos para IMF1. . . . .	61
Figura 36 – Distribuição dos valores da energia para IMF1. . . . .	61
Figura 37 – Distribuição dos valores TCZ para IMF3. . . . .	61
Figura 38 – Distribuição dos valores Skewness para IMF4. . . . .	62
Figura 39 – Distribuição dos valores máximo para IMF4. . . . .	62

## LISTA DE TABELAS

Tabela 1 – Matriz de confusão base BD01 sem ruído. . . . .	64
Tabela 2 – Matriz de confusão base BD02 ruído SNR de 30 dB. . . . .	64
Tabela 3 – Matriz de confusão BD03 ruído SNR de 40 dB. . . . .	65
Tabela 4 – Matriz de confusão BD04 ruído SNR de 50 dB. . . . .	65
Tabela 5 – Acurácia da classificação . . . . .	66

## LISTA DE SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
DQEE	Distúrbios da Qualidade da Energia Elétrica
DFT	Transformada Discreta de Fourier
DSCN	<i>Deep Stochastic Configuration Network</i>
EMD	<i>Empirical Mode Decomposition</i>
EVs	<i>Electric Vehicle</i>
EPE	Empresa de Pesquisa Energética
HHT	<i>Hilbert-Huang Transform</i>
IEC	<i>International Electrotechnical Commission</i>
IMF	<i>Intrinsic Mode Function</i>
MLP	<i>Multilayer Perceptron</i>
RF	<i>Random Forest</i>
RKELM	<i>Reduce Kernel Extreme learning machine</i>
SDEE	Sistema de Distribuição de Energia Elétrica
SIN	Sistema Interligado Nacional
SEP	Sistemas Elétricos de Potência
SVM	<i>Support Vector Machine</i>
STFT	<i>Short-time Fourier transform</i>
VMD	<i>Variational Mode Decomposition</i>
VTCD	Variação de tensão de curta duração

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
1.1	Justificativa	16
1.2	Objetivos	17
1.3	Organização do trabalho	17
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>19</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>23</b>
3.1	Qualidade da energia elétrica	23
3.1.1	Variações de Tensão de Curta Duração	26
3.1.1.1	Afundamento de Tensão (SAG)	26
3.1.1.2	Elevação de Tensão (SWELL)	27
3.1.2	Interrupção	28
3.1.3	Transitório	29
3.1.4	Transitório impulsivo	29
3.1.5	Transitório Oscilatório	30
3.1.6	Harmônicos	31
3.1.7	<i>Notching</i>	31
3.1.8	Flutuação de Tensão ( <i>Flicker</i> )	32
3.1.9	Modelagem matemática	33
3.2	Análise de sinais	34
3.2.1	Decomposição Empírica de modos (EMD)	35
3.2.2	Decomposição Variacional de modos (VMD)	38
3.2.3	Análise de desempenho da VMD em comparação com a EMD	41
3.2.3.1	Decomposição de sinal multicomponente	41
3.2.3.2	Detecção de recursos de banda lateral	43
3.2.3.3	Decomposição de sinal multicomponente com frequência variável	44
3.2.3.4	Robustez ao ruído	46
3.3	Inteligência artificial (IA)	48
3.3.1	<i>Random forest</i>	49
3.3.2	Extração de características	50
3.3.2.1	Validação e desempenho	52
<b>4</b>	<b>METODOLOGIA</b>	<b>53</b>
4.1	Base de Dados	53
4.2	VMD aplicada aos sinais com DQEE	54
4.3	Extração e seleção de Características	60

<b>4.4</b>	<b>Classificadores . . . . .</b>	<b>63</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÃO . . . . .</b>	<b>64</b>
<b>6</b>	<b>CONSIDERAÇÕES FINAIS . . . . .</b>	<b>67</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>68</b>

## 1. INTRODUÇÃO

Nos últimos anos, o setor elétrico brasileiro tem apresentado um crescimento e desenvolvimento notável. Segundo a Empresa de Pesquisa Energética (EPE), em seu Anuário Estatístico de Energia Elétrica de 2022, entre os anos de 2012 e 2021, houve um aumento de 20,1% na quantidade de consumidores presentes no sistema de distribuição de energia elétrica brasileiro. O consumo em GWh foi de 448.126 para 497.503 representando um aumento de 11%, acompanhando a capacidade de geração instalada brasileira, a qual teve um crescimento de 50%, nesse mesmo período. Nesse cenário, a perspectiva para o futuro será de que a carga de energia no Sistema Interligado Nacional (SIN) cresça à taxa média de 3,4% ao ano, entre 2021 e 2031 (EMPRESA DE PESQUISA ENERGÉTICA, 2022).

A expansão do setor elétrico é acompanhada pelas preocupações referentes aos temas relacionados à Qualidade da Energia Elétrica (QEE), por parte das concessionárias de energia elétrica e consumidores em geral, principalmente no segmento industrial. Da perspectiva da concessionária, tal preocupação decorre pela obrigatoriedade da adequação às normas e legislações que regem o mercado de energia elétrica. Já para os consumidores e indústrias, essa preocupação tem se tornado mais evidente devido à diversos fatores, entre os quais pode-se citar os prejuízos financeiros acarretados pelos Distúrbios da Qualidade da Energia Elétrica (DQEE) (DUGAN; MCGRANAGHAN; BEATY, 1996).

O fornecimento de energia elétrica fora dos padrões mínimos de qualidade acarreta em diversos impactos como: perda de eficiência, ocorrência de desligamento, diminuição da vida útil das instalações elétricas (fios, cabos, conexões, e equipamentos), diminuição de competitividade, aumento de custos tanto ao prestador do serviço, quanto aos consumidores, custos de reinicialização de sistemas, perda de processo produtivo ou inatividade. Assim, torna-se essencial identificar e classificar os DQEE (DUGAN; MCGRANAGHAN; BEATY, 1996).

Nesse sentido, redes inteligentes (*smart grids*) apresentam implementações de dispositivos inovadores para se obter informações dos Sistemas Elétricos de Potência (SEP). Esses dispositivos inteligentes devem ser capazes de extrair características relevantes acerca das informações obtidas dos sinais elétricos, de forma a mensurar e detectar os distúrbios e criar formas eficazes de prever soluções (GUNGOR et al., 2013). Diversos estudos abordam técnicas de processamento de sinais combinadas com algoritmos de aprendizagem de máquina que podem ser aplicadas aos sinais obtidos do SEP, com o objetivo de detectar e classificar os eventos de DQEE e com isso traçar estratégias eficazes de mitigação para melhoria da qualidade dos sistemas de



energia elétrica.

## 1.1 JUSTIFICATIVA

Diversos pesquisadores têm dedicado esforços no desenvolvimento de técnicas eficientes para discriminar os DQEEs. O trabalho de Rodriguez et al. (2019a), aborda a aplicação da Transformada de Hilbert-Huang e o modelo de rede neural *Multilayer Perceptron* (MLP) destinado a detectar e classificar sinais afetados por distúrbios na qualidade de energia. Por sua vez, Meena et al. (2018), utilizaram a Transformada de *Stockwell* em sinais afetados por DQEE, em que foi extraído uma série de atributos, nos quais foram utilizados por um sistema de classificação composto por uma árvore de decisão baseada em regras pré-definidas pelo autor a fim de realizar a detecção e classificação de distúrbios complexos de qualidade de energia.

No trabalho desenvolvido em Sahani (2020), foi realizado a aplicação da Decomposição de Modo Empírico (*Empirical Mode Decomposition* - EMD) juntamente com a transformada de Hilbert-Huang em sinais afetados por DQEE, associada à uma classificação baseada no algoritmo *Random Florest*, para detectar e classificar os eventos de qualidade de energia em tempo real. A EMD, segundo (ACHLERKAR; SAMANTARAY; MANIKANDAN, 2018), tem sido amplamente utilizada em sinais que apresentam perturbações na QEE, devido ao seu bom desempenho adaptativo, de não necessitar, a priori, de uma função base para a decomposição do sinal como utilizado em algumas transformadas e sua aplicação a sinais lineares e não lineares. A EMD, entretanto, é sensível ao ruído, e tem limitações no que se refere à detecção de dois ou mais componentes de frequência que estejam próximos.

Outra técnica de decomposição de sinais foi proposta por Dragomiretskiy e Zosso, sendo esta denominada Decomposição Variacional de Modos (*Variational Mode Decomposition* - VMD), na qual trata-se de uma técnica mais robusta desenvolvida para superar as desvantagens da EMD (KONSTANTIN; DOMINIQUE, 2014). Ao destacar a VMD, estudos têm tentado aprimorar sua aplicação na extração de características de diversos tipos de sinais, na área de Qualidade de Energia. Abdoos, Mianaei e Ghadikolaei, (2016), utilizam metodologia híbrida para classificação de DQEE utilizando a VMD com a transformada de *Stockwell* (ST) e o classificador *Support Vector Machine* (SVM).

ChakravorTi e Dash (2018), utilizam a VMD associada a um seletor de características, na classificação dos principais DQEE utilizando o classificador *Reduce Kernel Extreme learning machine* (RKELM). Cai, et al. (2018), utilizaram a decomposição VMD associada com a *Deep Stochastic Configuration Network* (DSCN) para classificar DQEE. Os resultados dos trabalhos destacados apresentam elevada acurácia, isso

se deve a algumas vantagens da VMD, entre elas, a largura de banda dos modos intrínsecos da VMD é estreita, isso possibilita a extração com precisão os componentes de frequência próximos, presentes no sinal, sem perder a informação no tempo. Outro fator, o filtro de Wiener presente na VMD possibilita uma menor interferência em relação ao ruído associado ao sinal.

Baseada no trabalho de Abdoos, Mianaei e Ghadikolaei, (2016) esta pesquisa propõe-se analisar a VMD aplicada a classificação dos sinais afetados por oito tipos DQEE, adicionando um detalhamento a respeito das informações obtidas da série de IMFs (*Intrinsic Mode Function*, IMF). Além disso, analisou-se outros tipos de atributos que representem a dinâmica do sinal. Tais atributos foram utilizados em sistema de classificação baseado em algoritmo RF. Deste modo, buscou-se obter a identificação e classificação de sinais com a presença de DQEE sob efeitos de ruídos gaussianos em diferentes faixas de valores de relação sinal/ruído (SNR), sendo estas de 30 dB, 40 dB e 50 dB.

## 1.2 OBJETIVOS

O trabalho tem como objetivo geral realizar a classificação de distúrbios que interferem na qualidade de energia elétrica com base na Decomposição Variacional de Modos.

Como objetivos específicos:

- Analisar a VMD aplicada a sinais com a presença de DQEE;
- Caracterizar os sinais em estudo, por meio das métricas extraídas da VMD;
- Aplicar técnica de classificação de padrões *Random Florest*;

## 1.3 ORGANIZAÇÃO DO TRABALHO

Esta dissertação está dividida em 6 capítulos, incluindo este capítulo introdutório, da seguinte maneira: O presente Capítulo aborda uma visão geral e a relevância dos estudos relacionados à qualidade de energia elétrica e também apresentou as justificativas e objetivos deste trabalho. Ao segundo capítulo deste trabalho refere-se a fundamentação teórica. Nele são abordados os tópicos: qualidade de energia, técnicas de análise de sinais e machine learning. Esse capítulo apresenta a caracterização dos distúrbios de tensão e seus modelos matemáticos, bem como, as técnicas matemáticas utilizadas para processamento dos dados.

No Capítulo 3, é encontrada a revisão bibliográfica, resultado de diferentes estudos baseados na VMD para classificação de DQEE. No Capítulo 4, expõe-se de forma

detalhada a metodologia proposta. O Capítulo 5, intitulado Resultados e Discussão são apresentadas as análises dos resultados obtidos. O Capítulo 6, apresenta as considerações finais, também são apresentadas propostas para trabalhos futuros e continuidade da pesquisa.

## 2. REVISÃO BIBLIOGRÁFICA

Com o intuito de conhecer os trabalhos concernentes à aplicação da Decomposição Variacional de Modos (VMD) para análise de distúrbios relacionados com a QEE, alguns dos principais estudos foram levantados. Este Capítulo destina-se a abordar o estado da arte no que se refere às aplicações da VMD, técnicas e ferramentas utilizadas.

Inicialmente o trabalho de Aneesh et al. (2015) se destaca por ser um dos primeiros a utilizar a VMD aplicado a classificação de DQEEs. Este trabalho utilizou dados sintéticos obtidos via MATLAB, para seis classes de DQEE sendo: sinal senoidal normal, sag, swell, harmônicos, sag com harmônicos, swell com harmônicos. Cada classe continha 120 sinais. A ideia central é apresentar uma comparação de desempenho da classificação de DQEEs entre a VMD e a EWT (Empirical Wavelet Transform). Estes dois métodos de processamento de sinal são utilizados para produzir três componentes de função de modo intrínseco (IMF). São extraídas 3 características de cada IMF curtose, média e variação. Os vetores de características são usados para treinar a SVM. Os resultados da classificação usando SVM mostram que a VMD apresentou desempenho superior ao EWT obtendo acurácia de 82,5%, em comparação, a EWT obteve acurácia de 78,2%.

O estudo de Abdoos, Mianaei e Ghadikolaei, (2016), aborda uma metodologia híbrida para classificação de DQEE utilizando a VMD com a transformada de stockwell (ST) e o classificador SVM. O VMD decompõe os sinais em diferentes modos e o ST também analisa os sinais nos domínios do tempo e da frequência, são usados a seleção sequencial para frente (SFS) e a seleção sequencial para trás (SBS) como métodos baseados em *wrapper* e o método de seleção de características baseado em *Gram-Schmidtorthogonalization* (GSO) para eliminação de recursos redundantes. Na próxima etapa, os DQEE são discriminados por máquinas de vetor de suporte (SVMs). Os resultados obtidos dos testes comprovam o desempenho satisfatório do método proposto em termos de velocidade e precisão mesmo em condições ruidosas. Além disso, os pontos inicial e final dos DQEE podem ser detectados com alta precisão.

ChakravorTi e Dash (2018), apresentam um estudo em que analisam a influência da VMD associada a um seletor de características FDA, na classificação dos principais DQEE via Reduce Kernel Extreme learning machine (RKELM). Para o estudo foram utiliza dados sintéticos, para quinze classes de DQEE, com 250 sinais em cada classe, sendo estas: sinal senoidal normal, sag, swell, harmônicos, notch, flicker, sag com transitório Osc., sag com harmônicos, swell com harmônicos, swell com flickr, transitório com notch, transitório com harmônicos, flicker com transitório, harmônicos com notch e

flicker com harmônicos. Todos os sinais são decompostos pela VMD obtendo 4 IMFs de cada sinal, dessas IMFs são extraídas 45 características, sendo: energia, razão entre média e mediana, diferença da média e mediana, razão de energia do modo (MER), correlação, entropia, desvio padrão, curtose, skewness e a variação para cada IMF. O cerne do trabalho concentra-se na escolha da melhor combinação das características, para tal os autores aplicaram a Análise de Discriminante Linear de Fischer (FDA) e em seguida o classificador RKELM. Segundo os resultados obtidos a acurácia do método proposto foi de 98,8% para um kernel polinomial. Computacionalmente RKELM é muito eficiente, e tem uma resposta rápida, com menor tempo de treinamento, para quase todos os distúrbios multiclasse.

Cai, et al. (2018), propuseram em seu trabalho uma metodologia baseada na decomposição VMD associada com um rede neural profunda de configuração estocástica (DSCN), para detecção de DQEE. Este estudo utiliza dados sintéticos obtidos via MATLAB, e sinais reais IEEE 1159.2 WorkingGroup datasheet para DQEE sendo: sinal senoidal normal, sag, swell, interrupção, interrupção com transitório, sag com harmônicos, swell com notch e swell com spike, cada classe contendo 200 sinais. A abordagem se baseia em dois estágios de classificação. O primeiro estágio é destinado a verificação da presença de Flicker ou ruído no sinal. Para tal, é realizada a VMD para obtenção de três IMFs, em seguida é analisado se a frequência instantânea está contida na faixa de frequência pertencente ao distúrbio segundo a IEEE 1519. O segundo estágio a VMD é novamente parametrizada e são obtidas outras duas IMF. De cada IMF, são extraídas características de média, variância e curtose da amplitude instantânea, logo após são enviadas para o classificador DSCN. Os autores afirmam que a metodologia proposta é robusta, obtendo acurácia de 99,4% o suficiente para classificar corretamente os sinais em estudo, inclusive com múltiplos distúrbios.

O artigo desenvolvido por Xu, et al. (2019), aborda um novo algoritmo para detecção e classificação dos DQEEs presentes em redes de distribuição com geração distribuída. Os dados utilizados foram provenientes de uma plataforma de teste contendo fontes de geração fotovoltaica e eólica, as perturbações foram obtidas alterando os eventos operacionais. Nove tipos de DQEE foram analisados sendo: sag, swell, interrupção, harmônico, flicker, flicker com harmônicos, transitório oscilatório, transitório impulsivo e notch. O algoritmo utilizou a VMD para obtenção das funções de modo intrínseco, estas funções servem como entrada para o Detrended Fluctuation Analysis (DFA). No DFA foram configurados três tipos de janelas para processar os sinais. Tamanhos de janela pequenos podem rastrear componentes de frequência mais alta, como harmônico, flicker, oscilação e outros componentes de alta frequência. Tamanhos de janela grandes podem rastrear componentes de frequência de ordem inferior, como swell, sag e interrupção de tensão. Tamanhos de janela médios são

selecionados quando a frequência de perturbação está em 50–100 Hz. Os resultados mostram acurácia de 99,38% para classificação, outro aspecto avaliado foi o tempo computacional relativo. Os autores baseados nos resultados, afirmam que o algoritmo é simples, preciso e com menor complexidade computacional, a metodologia fornece uma abordagem para detecção online em tempo real utilizando sistemas embarcados.

Deng, et al. (2021), discutem um método combinado, para detecção de DQEE baseado na VMD e redes neurais convolucionais (CNN). Segundo os autores, o objetivo é combinar as vantagens do VMD para decomposição dos sinais em diferentes modos e a vantagem da CNN para extrair mais facilmente as características discriminatórias ocultas nos sinais originais, com isso, obter uma classificação precisa. O trabalho utilizou dados sintéticos obtidos via MATLAB, para oito classes de DQEE sendo: sinal senoidal normal, sag, swell, harmônicos, interrupção, transitório oscilatório, flicker e notch. Os sinais são decompostos em 4 IMFs e então, combinados em vetores de entrada para a CNN. A análise do desempenho é feita pelas métricas de precisão, F1 e recall, obtendo em todas aproximadamente 98% para VMD com CNN. Os resultados mostram que a abordagem VMD com CNN tem um desempenho melhor em relação a CNN sem VMD, que obteve aproximadamente 96% de precisão, F1 e recall, ambas com a mesma arquitetura de CNN.

A análise do estado da arte dos últimos anos corrobora que a avaliação dos distúrbios de qualidade de energia tem sido amplamente estudada. No Quadro 01 é possível observar um resumo das principais pesquisas. Baseado no trabalho de Abdoos, Mianaei e Ghadikolaei, (2016) este estudo propõe extrair diferentes atributos das IMFs resultantes da VMD, tais atributos tem como objetivo serem utilizados em algoritmo de aprendizado de máquina a fim de realizar a classificação dos sinais afetados por oito tipos DQEE. Além disso, o trabalho aborda uma análise das IMFs a fim de entender o comportamento do sinal afetado por DQEE. Para a seleção de atributos foi utilizado um algoritmo para reduzir a dimensionalidade do classificador, ou seja, selecionar a menor quantidade de características que possam apresentar desempenho satisfatório no processo de classificação. O algoritmo de aprendizado utiliza o RF e a métrica de desempenho acurácia.

Quadro 01 - Resumo estado da arte.

Autoria	Características	Metodologia	Resultados
Aneesh et al. (2015)	Foram utilizadas Curtose, média e variação.	Aplicou a VMD e a EWT. <b>Base de dados:</b> Dados sintéticos 6 classes contendo 120 sinais cada classe foram extraídas 3 IMF. As classes foram: sinal senoidal, Sag, Swell, Harmônicos, Sag e Sewll com harmônicos. <b>Classificador:</b> SVM	Foi obtida acc de 82% para a VM e 78% para a EWT.
Abdoos, Mianaei e Ghadikolaeei, (2016).	Foram utilizadas a Energia, desvio padrão, magnitude, fase, frequência e outras	Utilizou a VMD e transform. de Stockwell <b>Base de dados:</b> Dados sintéticos com 5 IMF de cada sinal. Sinal senoidal, Sag, Swell, Harmônicos, Sag e Swell com harmônicos e Flicker. Sinais sem ruído e com SNR 30 dB, 40dB e 50dB. Seletor de características: Gram Schmidorth Ogonalization (GSO) <b>Classificador:</b> SVM	Foi obtida acc de 99% para base sem ruído e acc de 98,6% para ruído com SNR de 30dB
ChakravorTi e Dash (2018).	Energia, razão entre media e mediana, desvio padrão, curtose, skewness entropia, variação correlação,	<b>Base de dados:</b> Dados sinteticos, com 250 sinais em cada classe, sendo estas: Sag, Swell, Harmônicos, Notching, Flicker, Sag com Transitório Osc., Sag e Swell com harmonicos, Swell com flicker. Seletor de características: Analise de Discriminante Linear Fischer (FDA) <b>Classificador:</b> Reduce Kernel Extreme learning machine (RKELM).	Foi obtida acc de de 98,8% para o kernel polinomial
Cai, et al. (2018)	Frequência, media, variância e curtose	Utilizou a VMD e lógica Fuzzy. <b>Base de dados:</b> Dados sintéticos, Sag, Swell, Interrupção, Interrupção com transitório, Sag com harmônicos, Swell com notching cada classe contendo 200 sinais e 5 IMFs. <b>Classificador:</b> Rede Neural Profunda de Configuração Estocástica.	Foi obtida acc de 99%
Xu, et al. (2019).	-	Utilizou a VMD <b>Base de dados:</b> Sag, Swell, Interrupcao, Harmonico, Flicker, Flicker com harmônicos, Transitorio Osc. e imp, Notching. <b>Classificador:</b> Detrended Fluctuation Analysi	Foi obtido acc de 99,38% o DFA reduz complexidade.
Deng, et al. (2021).	-	Utilizou a VMD com 4 IMFs. <b>Base de dados:</b> Sinais sintéticos, Sinal senoidal, Sag, Swell, Harmonicos Transitorio Oscil. Flicker <b>Classificador:</b> Convolutional Neural Network	Foi obtida acc de 98% com VMD e sem VMD acc de 96%.

### 3. FUNDAMENTAÇÃO TEÓRICA

Este Capítulo destina-se a apresentar os conceitos dos fenômenos elétricos relacionados com a Qualidade da Energia Elétrica, bem como apresentar conceitos das técnicas de processamento de sinais relevantes para o desenvolvimento da metodologia proposta, os quais são resumidos a seguir.

- Principais conceitos da QEE, suas causas e consequências. Os diferentes fenômenos foram subdivididos em categorias de acordo com tempo de duração, conteúdo espectral e amplitude típica no sistema.
- Breve descrição sobre as técnicas de processamento de sinais mais utilizadas em QEE, fundamentos e análise comparativa da EMD e da VMD.
- Principais conceitos da aprendizagem de máquinas *Random Forest*, técnica adotada para validação, matriz de confusão e métrica de desempenho acurácia.

#### 3.1 QUALIDADE DA ENERGIA ELÉTRICA

Qualidade de Energia Elétrica, segundo Dugan et al. (1996), pode ser definida como qualquer problema manifestado na tensão, corrente ou desvio de frequência, que resulte em falha ou má operação dos equipamentos dos consumidores.

Verifica-se que os consumidores e seus aparelhos estão sucessivamente mais dependentes das condições de operação do sistema de energia elétrica e sensíveis às variações, tanto no nível de cargas comerciais e domésticas como em aplicações industriais. Isso é fruto do aumento da complexidade das funcionalidades que as cargas elétricas precisam executar através de controle de processos, até mesmo presentes em equipamentos domésticos (DECKMANN; POMILIO, 2017).

A geração distribuída e os veículos elétricos, são tecnologias emergentes que tendem a crescer e a se sobrepor geograficamente. Essas duas tecnologias representam mudanças na sociedade e têm repercussão nos sistemas elétricos de potência. Ambos acessam a rede por meio de conversores presentes em carregadores (conversores CA/CC) e inversores (conversores CA/CC/CA), e essa conexão acentuada de cargas não lineares são fontes de distúrbios de QEE (OLIVEIRA, 2019).

Outro aspecto relevante, refere-se aos impactos dos distúrbios de QEE no que concerne a Indústria 4.0, conhecida como Quarta Revolução Industrial, em que é o atual estágio vivenciado globalmente, resultante do avanço da Inteligência Artificial, da Computação Cognitiva e de outras inovações tecnológicas, na qual a robotização é utilizada em grande escala e, para isso, é fundamental o fornecimento de ener-



gia de qualidade, para que os robôs e sistemas de automação possam trabalhar adequadamente.

Alguns fatores que geram uma parte considerável dos problemas de qualidade de energia nos sistemas elétricos são ocasionados por cargas não lineares, como: dispositivos e equipamentos que utilizam eletrônica de potência tais como *drivers* de velocidade ajustável, impressoras a laser, computadores, lâmpadas fluorescentes, retificadores, cargas altamente indutivas, como motores de indução e unidades de ar condicionado. Outros fatores também surgem devido a eventos naturais e imprevisíveis (ZHANG; YAN, 2020).

São amplos e diversos os impactos econômicos em virtude de distúrbios QEE. Em alguns casos, o impacto da perturbação QEE é óbvio e imediatamente perceptível devido a danos ao equipamento, custos de reinicialização de sistemas, perda de processo produtivo ou inatividade. Este é particularmente o caso de quedas, interrupções e transientes. Em outros casos, o impacto só é observado com o tempo, podendo citar desta forma, o envelhecimento de equipamentos, pois a deterioração do equipamento se evidencia com o passar dos anos e a necessidade de substituições (ELPHICK et al., 2015).

Os impactos econômicos da qualidade da energia são geralmente divididos em três categorias amplas (FUCHS; MASOUM, 2015):

- Impactos econômicos diretos:
  - Perda de produção; Danos a equipamentos; tempo de inatividade e recursos irre recuperáveis; custos de reinicialização do processo; deterioração da produção semi - acabada; penalidades financeiras.
- Impactos econômicos indiretos:
  - Os custos para uma organização de receitas sendo adiados; o custo financeiro da perda de participação no mercado; o custo de restaurar o valor.
- Impactos econômicos de segurança:
  - Danos pessoais, também relacionados à redução da eficiência, saúde e segurança; evacuação edifícios residenciais vizinhos como um impacto social indireto no evento de falha de segurança industrial.

De acordo com a Norma IEEE 1159 - 2019, os problemas da qualidade de energia são classificados em sete categorias principais, mostradas no Quadro 02.

**Quadro 02** - Classificação dos distúrbios de QEE segundo a Norma IEEE 1159.

<b>Classificação</b>	<b>Conteúdo Espectral</b>	<b>Duração</b>	<b>Magnitude</b>
<b>1.0 Transitórios</b>			
1.1 Impulsivos			
Nanossegundo	5 ns	< 50 ns	
Microsssegundo	1 $\mu$	50 ns – 1 ms	
Milissegundo	0,1 ms	> 1 ms	
1.2 Oscilatórios			
Baixa Frequência	< 5 kHz	0,3 – 50 ms	0 – 4 pu
Média Frequência	5 - 500 kHz	20 $\mu$ s	0 – 8 pu
Alta Frequência	0,5 - 5 MHz	5 $\mu$ s	0 – 4 pu
<b>2. Variação de Tensão de Curta duração</b>			
2.1 Instantânea			
Afundamento		0,5 - 30 ciclos	0,1 – 0,9 pu
Elevação de tensão		0,5 - 30 ciclos	1,1 – 1,8 pu
2.2 Momentânea			
Interrupção		0,5 – 30 ciclos	< 0,1 pu
Afundamento		30 ciclos – 3 s	0,1 – 0,9 pu
Elevação		30 ciclos – 3 s	1,1 – 1,4 pu
2.3 Temporária			
Interrupção		> 3 s – 1 min	< 0,1 pu
Afundamento		> 3 s – 1 min	0,1 – 0,9 pu
Elevação		> 3 s – 1 min	1,1 – 1,2 pu
<b>3.0 Variação de tensão de longa duração</b>			
3.1 Interrupção sustentada		> 1 min	0,0 pu
3.2 Subtensão		> 1 min	0,8 – 0,9 pu
3.3 Sobretensão		> 1 min	1,1 – 1,2 pu
3.4 Sobrecarga de corrente		> 1 min	
<b>4.0 Desequilíbrio</b>			
4.1 Tensão		regime permanente	0,5 – 2%
4.2 Corrente		regime permanente	1,0 – 30%
<b>5.0 Distorção da forma de onda</b>			
5.1 Nível CC		regime permanente	0 – 0,1%
5.2 Harmônicos	0 – 9 kHz	regime permanente	0 – 20%
5.3 Interharmônico	0 – 9 kHz	regime permanente	0 – 2%
5.4 Notching		regime permanente	
5.5 Ruído	faixa ampla	regime permanente	0 – 1%
<b>6.0 Flutuações de tensão</b>			
	< 25 Hz	intermitente	0,1 – 7%
<b>7.0 Variações de frequência</b>			
		< 10 s	$\geq 0,10H_z$

### 3.1.1 Variações de Tensão de Curta Duração

Variações de tensão de curta duração (VTCD) são desvios significativos no valor eficaz da tensão em curtos intervalos de tempo (IEEE, 2019). O IEEE Std. 1159 normatiza esses eventos de acordo com o Quadro 02.

As VTCD são usualmente decorrentes de curtos-circuitos, energização de transformadores, partida de motores e energização/desenergização de sistemas. Dependendo da localização da falta e das condições do sistema, a falta pode causar temporariamente tanto redução na tensão, que é denominada como afundamento de tensão, a elevação da tensão, ou até a perda completa de tensão; a ausência de tensão é denominada interrupção (MEDEIROS, 2016).

Com base na duração do evento, as VTCD podem ser classificadas segundo a Norma IEEE Std 1159 em três categorias, instantânea, momentânea e temporária. As diferentes classificações estão listadas no Quadro 01. As classificações das VTCD no Brasil são regulamentadas pela ANEEL, estabelecida no Módulo 8, Qualidade da Energia Elétrica, do PRODIST, conforme apresentado no Quadro 03.

**Quadro 03** - Classificação das VTCD segundo o PRODIST.


Classificação	Denominação	Duração do evento	Amplitude da tensão
Variação Momentânea	Interrupção	$\leq 3s$	$< 0,1 \text{ pu}$
	Afundamento	$\geq 1\text{ciclo}$ $\leq 3s$	$\geq 0,1\text{pu}$ $< 0,9 \text{ pu}$
	Elevação	$\geq 1\text{ciclo}$ $\leq 3s$	$> 1,1 \text{ pu}$
Variação Temporária	Interrupção	$> 3s$ $\leq 1\text{mim}$	$< 0,1 \text{ pu}$
	Afundamento	$> 3 \text{ s}$ $\leq 1\text{mim}$	$\geq 0,1\text{pu}$ $< 0,9 \text{ pu}$
	Elevação	$> 3s$ $\leq 1\text{mim}$	$> 1,1 \text{ pu}$

#### 3.1.1.1 Afundamento de Tensão (SAG)

A definição de acordo com a Norma IEEE 1159-2019 de afundamento de tensão (SAG) é a queda brusca do valor eficaz da tensão para um valor entre 0,1 p.u. e 0,9 p.u. na frequência fundamental, com duração entre 0,5 ciclo a um minuto. A Figura 1 exemplifica um afundamento instantâneo de tensão.

O afundamento é provocado tipicamente por faltas no Sistema de Distribuição de Energia Elétrica (SDEE), faltas na instalação consumidora ou, em sua maioria devido a energização de um equipamento que necessite alta potência num pequeno período de tempo, como por exemplo a partida direta de motores com potência superior a 5 cv (DIAS, 2019). Em geral, o efeito desaparece após a causa ser removida.

**Figura 1 – Afundamento de Tensão (SAG).**



**Fonte: Autoria própria**

O problema de qualidade de energia que mais frequentemente afeta os usuários finais, tanto industriais como comerciais são os afundamentos de tensão. A queda de tensão afeta o equipamento do usuário em termos de mau funcionamento de computadores, controladores de processo, controladores lógicos programáveis, drives de velocidade ajustável, a robótica nas indústrias modernas, a redução no desempenho de motores, oscilação nos dispositivos de iluminação, queima de máquinas elétricas, entre outros (FUCHS; MASOUM, 2015).

Alguns dos equipamentos que fornecem soluções para problemas de afundamento de tensão são: utilização de transformadores ferroressonantes, também conhecidos como transformadores de tensão constante (CVT, do inglês *Constant Voltage Transformer*), restauradores de tensão dinâmica (DVR, do inglês *Dynamic Voltage Restorers*), dispositivos de armazenamento de energia supercondutores, conjuntos de motor-gerador e fontes de alimentação ininterrupta de energia (UPS, do inglês *Uninterruptible Power Supply*) (KUMAR; ALEXANDER, 2018).


### **3.1.1.2 Elevação de Tensão (SWELL)**

A definição de acordo com a Norma IEEE 1159 de uma elevação de tensão de curta duração é um aumento na tensão RMS entre 1,1 e 1,8 pu e uma duração de tempo de 0,5 ciclo a 1 minuto. A magnitude típica da tensão está entre 1,1 e 1,2 pu (IEEE, 2019). A Figura 2 ilustra a forma de onda da elevação de tensão.

As principais causas deste tipo de distúrbio segundo Durgan et al geralmente estão associadas a condições de falta no SDEE, podendo citar o curto-circuito fase-

terra, em que as fases não defeituosas apresentam um aumento temporário da tensão. Este fenômeno também está relacionado com as saídas de grandes blocos de cargas (ocasionando a diminuição na corrente do alimentador), ou à energização de grandes bancos de capacitores.

**Figura 2 – Elevação de Tensão (SWELL).**



Fonte: Autoria própria


A elevação de tensão provocar vários efeitos adversos, como: sobreaquecimento em lâmpadas e motores, oscilações do nível de luminosidade em sistemas de iluminação, perda de dados e erros de processamento em dispositivos microprocessados, danos e desligamento de equipamentos, redução do tempo de operação ou de eficiência de equipamentos. Algumas sugestões para eliminar ou reduzir as consequências desse fenômeno são: verificação de fiações e ligações elétricas, transferência de equipamentos para outros circuitos, utilização de reguladores de tensão, instalação de compensadores estáticos de reativos (LIMA, 2013).

### 3.1.2 Interrupção

As interrupções momentâneas segundo a Norma IEEE std 1159 são reduções de curta duração na magnitude da tensão de menos de 0,1 pu por menos de 1 minuto de duração. A duração da interrupção é determinada pelo tempo de eliminação da falta e pelo tempo de fechamento do disjuntor (FUCHS; MASOUM, 2015). A Figura 3 ilustra a interrupção momentânea na tensão.

A interrupção pode ser causada por várias condições, algumas das quais são: curtos-circuitos, falhas em equipamentos, atuação de dispositivos de proteção, descargas atmosféricas ou problemas de isolamento. A duração de uma interrupção devido a uma falha no sistema da concessionária é determinada pelo tempo de operação dos dispositivos de proteção da concessionária. O religamento instantâneo geralmente limitará a interrupção causada por uma falta não permanente a menos de 30 ciclos. O fechamento retardado do dispositivo de proteção pode causar uma

Figura 3 – Interrupção.



Fonte: Autoria própria

interrupção momentânea ou temporária.

Nas indústrias, as interrupções momentâneas podem afetar os contadores eletromecânicos, prejudicando, deste modo, os processos que dependem das máquinas acionadas por esses contadores. Podem ocasionar também, perdas nos sistemas de informação, como em dispositivos microprocessadores conectados à rede ou computadores (DIAS, 2019).

A solução para as interrupções incluem fontes alternativas de fornecimento de energia elétrica. Um usuário final pode instalar fontes no local, como UPSs com bateria ou grupos geradores a motor, enquanto um utilitário pode oferecer uma fonte externa que compreende dois alimentadores com um interruptor de alta velocidade que muda para o alternativo quando ocorrer uma falha (KUMAR; ALEXANDER, 2018).

### 3.1.3 Transitório

Transitórios eletromagnéticos segundo Dugan et al. (1996), são respostas elétricas ou manifestações locais ou nas adjacências, provenientes de alterações súbitas nas condições operacionais de um SDEE. As classificações de transitórios listadas na IEEE 1159-2019 são exibidas no Quadro 01.


O transitório apresenta uma curta duração, mas de extrema relevância, uma vez que os equipamentos presentes nos sistemas elétricos estarão sujeitos a grandes solicitações de tensão ou corrente. De um modo geral, os fenômenos transitórios podem ser classificados em dois grupos, impulsivos e oscilatórios.

### 3.1.4 Transitório impulsivo

Transitório impulsivo segundo Dugan et al. (1996), pode ser definido por uma alteração súbita, indesejável no SDEE, que se encontra em condição de regime

permanente, refletida nas formas de ondas da tensão, corrente ou ambas, tendo como característica impulsos unidirecional em polaridade (positiva ou negativa). A Figura 4 ilustra o transitório Impulsivo de polaridade negativa aparecendo no ciclo negativo.

**Figura 4 – Transitório Impulsivo.**




**Fonte: Autoria própria**

Os transitórios impulsivos são geralmente causados por descargas atmosféricas e apresentam nível de frequência distinto da frequência nominal da rede elétrica, em razão disso, são amortecidos rapidamente devido à resistência dos componentes do sistema.

### 3.1.5 Transitório Oscilatório

Transitório Oscilatório segundo Dugan et al. (1996), pode ser definido por uma mudança repentina nas condições de regime permanente da tensão ou corrente ou ambas na polaridade bidirecional (positiva e negativa), a Figura 5 ilustra este distúrbio.

**Figura 5 – Transitório Oscilatório.**



**Fonte: Autoria própria**


Os transitórios oscilatórios podem de provocar diversos efeitos negativos como: diminuir a vida útil de motores, causar o mau funcionamento de dispositivos controlados eletronicamente, bem como de geradores e transformadores, entre outros equipamentos. Visando a eliminação dos transitórios oscilatórios do SDEE, podem-se utilizar

como solução: supressores de surto, transformadores isoladores e filtros (DUGAN; MCGRANAGHAN; BEATY, 1996)

### 3.1.6 Harmônicos

A definição de acordo com Dugan et al. (1996), harmônicos são componentes dos sinais de tensão e /ou corrente senoidais com frequências que são múltiplos inteiros da frequência na qual o sistema de alimentação foi projetado para operar (50Hz ou 60 Hz dependendo da região). A Figura 6 ilustra um sinal de tensão com a presença de harmônicos. Os harmônicos são responsáveis por distorcer as formas de onda de tensão e corrente, são proveniente de cargas com características não-lineares interligadas ao SEP.

**Figura 6 – Sinal senoidal com Harmônicos.**



**Fonte: Autoria própria**

A utilização de filtros pode atenuar os harmônicos e reduzir sua interferência nos sistemas elétricos e eletrônicos. O uso de transformadores com núcleo de material ferromagnético com baixa permeabilidade também pode reduzir a corrente harmônica que flui para a carga (GAO; CHEN; LI, 2018).


### 3.1.7 Notching

Denominação que se dá aos distúrbios periódicos na tensão decorrentes operação normal de dispositivos da eletrônica de potência. Os conversores trifásicos que produzem saída CC contínua são as principais causas do distúrbio *notching*. Isto se deve ao fato de que quando a corrente é comutada de uma fase para outra, durante este período, existe um curto-circuito momentâneo entre duas fases (FUCHS; MASOUM, 2015).

Na Figura 7 são exibidos *notching* de tensão causados pela operação de um conversor. A intensidade resultante do *notching* é função das impedâncias envolvidas. Este fenômeno pode ser detectado por meio da informação do conteúdo harmônico



Figura 7 – Notching.



Fonte: Autoria própria


da tensão afetada. Eles são caracterizados como fontes de ruídos e interferências indesejáveis.

Algumas possíveis soluções para mitigar o problema do notching são: Uso de equalização, aplicação de técnicas de cancelamento de interferência e o uso de equalizador adaptativo. Ajudam a compensar as perdas de amplitude em determinadas frequências e, assim, reduzir a presença do distúrbio (SONG et al., 2019).

### 3.1.8 Flutuação de Tensão (*Flicker*)

A flutuação de tensão segundo o modulo 8 do PRODIST é uma variação aleatória, repetitiva ou esporádica no valor eficaz da tensão (ANEEL, 2021). As normas como IEC 61000-3-3 (IEC, 2022) e IEC 61000-3-5 (IEC, 2009) apresentam limites e procedimentos de medição, que também abordam as características do distúrbio. A Figura 8 ilustra o sinal de tensão com a presença do distúrbio *Flicker*.

Figura 8 – Flicker.



Fonte: Autoria própria

Visto que os alimentadores possuem uma impedância série, equivalente a uma carga que se altera periodicamente, sua corrente provoca uma variação correspondente da tensão no ponto de conexão. O comportamento de outras cargas podem

ser afetadas devido a esta alteração de tensão, principalmente as mais suscetíveis ao valor eficaz da tensão de alimentação. São exemplos de cargas variáveis que frequentemente provocam tal efeito: prensas e estamparias, aparelhos de solda elétrica, aquecedores e fornos elétricos com controle automático de temperatura, elevadores, fornos a arco, laminadores siderúrgicos e bombas (DECKMANN; POMILIO, 2017).

### 3.1.9 Modelagem matemática

Diversos modelos matemáticos foram propostos em estudos existentes. Para as simulações de distúrbios de tensão foram utilizados os modelos matemáticos disponíveis no trabalho do Igual et al. (2018), que é apresentado no Quadro 04, na qual se tem as equações bem como os parâmetros utilizados para simulação de cada distúrbio. Os sinais foram gerados com base em números pseudo-aleatórios.

**Quadro 04** - Equações e parâmetros utilizados nas simulações.

Distúrbios	Equações	Parâmetros
Sinal Puro	$x(t) = A \sin(\omega t - \varphi)$	$\omega = 2\pi f$ $-\pi \leq \varphi \leq \pi$
Sag	$x(t) = A(1 - \alpha(u(t - t_1) - u(t - t_2))) \sin(\omega t - \varphi)$	$T \leq t_2 - t_1 \leq (N - 1)T$ $0 \leq \alpha \leq 0,9$
Swel	$x(t) = A(1 + \beta(u(t - t_1) - u(t - t_2))) \sin(\omega t - \varphi)$	$T \leq t_2 - t_1 \leq (N - 1)T$ $0,1 \leq \beta \leq 0,8$
Interrupção	$x(t) = A(1 - \rho(u(t - t_1) - u(t - t_2))) \sin(\omega t - \varphi)$	$T \leq t_2 - t_1 \leq (N - 1)T$ $0,9 \leq \rho \leq 1,0$
Flutuação	$x(t) = A[1 + \lambda \sin(\omega_f t)] \sin(\omega t - \varphi)$	$0,05 \leq \lambda \leq 0,1$ $8 \leq f \leq 25 \text{Hz}$
Trans Imp.	$x(t) = A[\sin(\omega t - \varphi) - \psi(e^{-750(t-t_a)} - e^{-344(t-t_a)})((u(t - t_a) - u(t - t_b)))]$	$0,22 \leq \psi \leq 1,11$ $T \leq t_a \leq (N - 1)T$ $t_b = t_a + 1 \text{ms}$
Trans Osc	$x(t) = A[\sin(\omega t - \varphi) + \beta e^{\frac{-(t-t_I)}{\tau}} \sin(\omega_n(t - t_I) - \vartheta)((u(t - t_{II}) - u(t - t_I)))]$	$300 \leq f_n \leq 900 \text{Hz}$ $8 \text{ms} \leq \tau \leq 40 \text{ms}$ $0,5T \leq t_{II} - t_I \leq \frac{N}{3,33}T$
Harmônico	$x(t) = A[\sin(\omega t - \varphi) + \sum_{n=3}^7 \alpha_n \sin(n\omega t - \vartheta_n)]$	$0,005 \leq \alpha_n \leq 0,15$ $-\pi \leq \vartheta_n \leq$
Notching	$x(t) = A[\sin(\omega t - \varphi) - \text{sign}(\sin(\omega t - \varphi)) \sum_{n=0}^{N-1} k(u(t - (t_c + sn)) - u(t - (t_d + sn)))]$	$0,01 \leq k \leq 0,4$ $0,01T \leq t_d - t_c \leq 0,05T$

### 3.2 ANÁLISE DE SINAIS

Atualmente, existem muitas técnicas que permitem a detecção e classificação dos distúrbios QEE, com base em diferentes formulações matemáticas e estatísticas e considerando que qualquer sinal distorcido é concebido como a soma de diferentes modos de oscilação. No entanto, existem muitas dificuldades em detectar esses distúrbios nos métodos tradicionais de decomposição de sinais. Esses métodos não têm conseguido realizar o processo de detecção com a eficiência, velocidade e precisão exigidas para este tipo de trabalho, devido ao comportamento não estacionário e não linear desses distúrbios (RODRIGUEZ et al., 2019b).

A Transformada Rápida de Fourier (FFT) e a Transformada Discreta de Fourier (DFT) são amplamente usados para a decomposição de sinais em seus componentes de frequência (BOLLEN, 1999). São ferramentas de fácil utilização e rápida implementação. Ainda que a FFT funcione muito bem ao lidar com sinais periódicos estacionários, não é adequado para sinais não estacionários cuja frequência, amplitude ou fase variam ao longo do tempo. Nessa transformada a representação se dá no domínio da frequência e a informação temporal fica indisponível, impossibilitando afirmar quando, a partir do sinal transformado no domínio da frequência, um determinado evento ocorreu, o que dificulta a análise de sinais com características transitórias ou não estacionárias. (AFRONI; SUTANTO, 2014).

A transformada de Fourier de curta duração (SFT) foi desenvolvida para superar a limitação da transformada de Fourier. A STFT usa técnicas de janelamento móvel ao longo do eixo do tempo para avaliar o FFT de uma área menor de todo o sinal. A largura da função de janela determina se há uma boa resolução de frequência ou uma boa resolução de tempo. Uma vez que um determinado tamanho de janela é escolhido, essa janela deve ser usada para todas as frequências contidas em todo o sinal restringindo assim os resultados a serem obtidos. Os sinais com distúrbios de QEE não estacionários podem exigir alguma flexibilidade na escolha desta janela (HARRIS, 1978).

A transformada wavelet através da sua formulação matemática, ajudou a superar a restrição que a janela fixa da STFT impunha, empregando a técnica de janelamento variável, ou seja, emprega uma janela de tamanho maior para a extração de informação de baixa frequência e uma janela de tamanho menor para a extração de informação de alta frequência (MALLAT, 1999). A transformada wavelet decompõe o sinal em suas "wavelets filhas" que são versões escalonadas e deslocadas da wavelet mãe. (FLORES, 2003). A transformada wavelet é limitada, devido à dificuldade de ajuste entre a precisão no domínio do tempo e boa resolução na frequência. (PENG et al., 2005).

Outro fator determinante para o sucesso da identificação de eventos QEE depende, até certo ponto, da escolha da wavelet mãe. Uma vez que uma função wavelet mãe é escolhida, ela terá que ser usada para analisar todos os dados, mas devido à natureza não estacionária da maioria dos sinais QEE, uma escolha diferente de wavelet mãe pode ser necessária e levar a resultados diferentes (FLORES, 2003). Para caracterização dos sinais é interessante que os métodos não necessitem de uma função base a priori.

A Transformada de Hilbert-Huang (HTT), desenvolvida por HUANG et al. (1998), é um método adaptativo concebido para análise de dados de fenômenos não estacionários e não lineares. Como é um método adaptativo, ou seja, não requerem nenhuma suposição inicial do sinal são mais adequadas para decompor sinais não estacionários frequentemente encontrados em formas de onda QEE (AFRONI; SUTANTO, 2014). A HTT do sinal em análise é decomposto em Funções de Modo Intrínseco (IMF), isto pode ser feito através da decomposição empírica de modos (EMD). A HHT aplica nas IMFs a Análise do Espectro de Hilbert ( *Hilbert Spectral Analysis* - HSA) de modo a obter a frequência instantânea para cada IMF em questão (HUANG et al., 1998). Para um maior detalhamento as técnicas de decomposição EMD e VMD serão explanadas nas seções seguintes do capítulo.

### 3.2.1 Decomposição Empírica de modos (EMD)

A técnica EMD proposta por Huang et al (1998) é estudada e usada em diversos campos científicos, podendo ser aplicada a sinais não estacionários e não lineares. Possui como característica principal a decomposição de séries temporais tendo como base apenas os pontos extremos locais (HUANG et al., 1998).

Em contraste com os métodos convencionais de análise de tempo-frequência (*Time Frequency Analysis*, TFA), a EMD fornece representações de sinal mais realistas sem artefatos impostos pelas limitações não adaptativas dos métodos TFA baseados em transformada de Fourier e wavelet. Estes sinais são completamente adaptáveis à mudança das formas de onda do sinal e decompõe o sinal em um número limitado de funções de modo intrínseco (IMFs) através da execução automática de uma série de cálculos recursivos (PENG et al., 2016).

Essas funções decompostas representam os modos oscilatórios fundamentais do sinal, a partir dos quais as características de tempo-frequência instantâneas de interesse são consideradas observadas. A IMF é definida como uma função que satisfaz as seguintes condições (HUANG et al., 1998):

1. Em um conjunto de dados, o número de máximos e de mínimos locais e o número de cruzamentos por zero devem ser iguais ou diferentes em pelo menos 1.

2. Em qualquer ponto, a média do envelope definido pelos máximos locais e do envelope definido pelos mínimos locais deve ser zero.

Cada IMF representa um modo de oscilação presente na série temporal original. Um sinal que possui mais de uma frequência de oscilação, possui também mais de uma IMF. O método sistemático para extrair as funções intrínsecas é chamado de processo de *sifting*, e é descrito da seguinte forma:

Dado um sinal de entrada  $x(t)$  inicialmente são calculados os pontos de máximos e mínimos locais deste sinal. Após delimitação e indicação dos picos, é formado o envelope superior, que consiste na ligação de todos os máximos locais por meio de uma interpolação cúbica. Esse processo é o mesmo para os mínimos locais, desta forma é obtido o envelope inferior. O passo seguinte consiste em calcular a média entre os dois envelopes, definida como  $m_1$ .

$$m_1 = \frac{E_{sup} + E_{inf}}{2}. \quad (1)$$

A primeira componente,  $h_1$ , é a diferença entre  $x(t)$  e  $m_1$  ou seja.

$$h_1 = x(t) - m_1. \quad (2)$$

Com base na definição, para um componente  $h_1$  ser uma IMF, o sinal não deve conter nenhum máximo local abaixo de zero ou um mínimo local acima de zero (HUANG et al., 1998). Caso  $h_1$  apresente tais condições, o procedimento de cálculo da IMF é repetido varias vezes até que o componente alcance as condições necessárias para ser uma IMF, assumindo  $h_1$  como o novo sinal  $x(t)$ . Assim:

$$h_{11} = h_1 - m_{11}. \quad (3)$$

em que  $m_{11}$  é a nova média entre os envelopes inferior e superior de  $h_1$  e  $h_{11}$  é o novo sinal aspirante a IMF. O processo de *sifting* é repetido  $k$  vezes até que  $h_1$  seja uma IMF:

$$h_{1k} = h_{1(k-1)} - m_{1k}. \quad (4)$$

no qual  $c_1$  representa a primeira IMF dos dados em estudo. Podendo ser definido como:

$$c_1 = h_{1k}. \quad (5)$$

Assim  $c_1$  pode ser separado a partir dos dados originais:


$$r_1 = x(t) - c_1. \quad (6)$$

Caso o resíduo  $r_1$  contenha informações a respeito o sinal, assume-se que este é o novo dado, e então o processo de *sifting* é aplicado novamente sobre o novo dado. Esse procedimento será repetido para todos os  $r_s$  seguintes. As etapas mencionadas anteriormente são realizadas  $n$  vezes para encontrar todas as IMFs e para que o resíduo  $r_n$  se torne uma constante, uma função monótona ou ainda, uma função com um único máximo e mínimo do qual nenhum outro IMF pode ser extraído (HUANG et al., 1998).

$$r_n = r_{n-1}c_n. \quad (7)$$

Na Figura 9 é ilustrada o procedimento de decomposição. As envoltórias superiores e inferiores estão destacadas com as linhas verde. A linha azul é o sinal analisado, os pontos de mínimos estão marcado em azul e os pontos de máximos em vermelhas. A linha tracejada mostra a média que é calculada com base nas duas envoltórias.

**Figura 9 – Envoltórias EMD.**



Fonte: (SANTOS, 2020)

No entanto, a prática revelou que a EMD e suas formas de extensão também apresentam os seguintes defeitos no processamento de sinal e na extração de recursos:

- As técnicas baseadas em EMD são sensíveis ao ruído contido no sinal. Uma pequena mudança na relação sinal-ruído (SNR) do sinal pode levar a resultados de decomposição de sinal significativamente diferentes.

- Apresenta limitações em distinguir diferentes componentes em sinais de banda estreita. A EMD geralmente alocam esses componentes de frequência nas imediações na mesma função de decomposição. Como consequência, as características de tempo-frequência instantânea não podem ser extraídas com sucesso do sinal.
- Algumas 'ondulações' não identificadas estão frequentemente presentes nos resultados obtidos a partir de técnicas baseadas em EMD. Eles estragam as características de tempo-frequência do sinal e, assim, aumentam a dificuldade de interpretação do sinal.

### 3.2.2 Decomposição Variacional de modos (VMD)

A Decomposição Variacional de Modos foi proposta por Dragomiretskiy e Zosso em 2014. Inspirado na EMD, é uma técnica adaptativa e não-recursiva, o método assume que o sinal original é composto por uma quantidade das chamadas Funções de Modo Intrínseco (IMFs)  $u_k$  que são definidas como componentes AM-FM (KONSTANTIN; DOMINIQUE, 2014).

$$u_k(t) = A(t)\cos[\phi(t)]. \quad (8)$$

em que  $A(t)$  e  $\phi(t)$  correspondem respectivamente a amplitude instantânea e a fase instantânea de  $u_k(t)$ . A frequência central da IMF é considerada a frequência instantânea correspondente  $w(t) = \phi(t)$ . A largura de banda para cada modo  $u_k$  pode ser estimada através do seguinte procedimento:

i) O sinal analítico de cada modo é obtido por uma transformada de Hilbert para adquirir o espectro unilateral. ii) Um termo exponencial é adicionado ao sinal de análise de cada modo para ajustar sua frequência central estimada, com o espectro de cada modo modulado para a banda base de frequência correspondente. iii) A largura de banda do sinal de cada modo é estimada por meioquadrado da norma L2 do gradiente do sinal de demodulação (MORENO, ).

O objetivo da VMD é decompor um sinal multicomponente em um número finito de sub-sinais de banda limitada (modos),  $u_k(t)$ , que se compactam em torno de uma frequência central  $w_k(t)$ . A técnica VMD primeiro utiliza a transformada de Hilbert para converter cada modo  $u_k(t)$  em uma expressão analítica  $u_k^+(t)$  em um domínio espectral unilateral para obter a largura de banda de cada função de modo:

$$u_k^+(t) = \left( \delta(t) + \frac{j}{\pi t} \right) .u_k(t), \quad (9)$$

Após a transformação de Hilbert, o espectro de frequência de cada modo é deslocado para a banda base e a frequência central estimada  $w_k(t)$  correspondente ajustada usando um termo exponencial. Posteriormente, a largura de banda é estimada de acordo com a suavidade gaussiana do sinal demodulado, utilizando a norma L2 quadrada do gradiente. Assim, o processo VMD é realizado resolvendo um problema variacional restrito (KONSTANTIN; DOMINIQUE, 2014):

$$\begin{aligned} \min_{\{u_k\}, \{w_k\}} & \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \\ \text{sujeito a} & \sum_k u_k = f \end{aligned} \quad (10)$$

em que,  $\{u_k\} = \{u_1 \dots u_k\}$  representam os conjuntos de sinais analisados dos IMFs,  $\{w_k\} = \{w_1 \dots w_k\}$  representam as frequências centrais a definir. Para resolver o problema de otimização restrito apresentado na Equação 10 são introduzidos a penalidade quadrática  $\alpha$  e os multiplicadores Lagrangianos  $\lambda$  com a finalidade de tornar a otimização irrestrita (WANG et al., 2017).

$$\begin{aligned} L(\{u_k\}, \{w_k\}, \lambda) &= \alpha \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 \\ &+ \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle. \end{aligned} \quad (11)$$

A solução é alcançada atualizando a frequência central e a largura de banda de cada IMF em uma sequência de otimização chamada de método de direção alternativa de multiplicadores (ADMM). Os procedimentos de atualização de  $u_k$  podem ser expressos como:

$$\widehat{u}_k^{n+1}(w) = \frac{\widehat{f}(w) - \sum_{i \neq k} \widehat{u}_i(w) + \frac{\widehat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_k)^2}, \quad (12)$$

em que,  $\widehat{u}_k^{n+1}$ ,  $\widehat{f}(w)$ ,  $\widehat{\lambda}(w)$  representam as transformações de Fourier de  $u_k^{n+1}$ . A equação 12 pode ser identificada como um filtro passa-baixa de Wiener centrado em torno da frequência  $u_k$ , com largura de banda definida por  $\alpha$ . Nos procedimentos iterativos, a frequência central de cada modo é re-estimada pelo espectro de potência. A equação de atualização de  $w_k^{n+1}$  é (KONSTANTIN; DOMINIQUE, 2014):

$$w_k^{n+1} = \frac{\int_0^\infty w |\widehat{u}_k(w)|^2 dw}{\int_0^\infty |\widehat{u}_k(w)|^2 dw}. \quad (13)$$



O processo VMD continua até que o erro relativo seja menor que uma tolerância de convergência  $\varepsilon$ :

$$e = \frac{\sum_k \|\widehat{u}_k^{n+1} - \widehat{u}_k^n\|_2^2}{\|\widehat{u}_k^n\|_2^2} < \varepsilon. \quad (14)$$

De acordo com os conceitos apresentados, as etapas do algoritmo da VMD na forma irrestrita utilizando as Equações 12 e 13 para um erro de convergência  $e$  são descritas pelo algoritmo da VMD:

---

### Algoritmo da VMD

---

1: Inicializar:  $\widehat{u}_k^1, \widehat{\lambda}, w_k^1, n \leftarrow 0$

2: Repetir

3:  $n \leftarrow n + 1$

4: para  $k = 1$  até  $K$  faça:

5: Atualize  $\widehat{u}_k$  para todo  $w \geq 0$

$$6: \widehat{u}_k^{n+1}(w) = \frac{\widehat{f}(w) - \sum_{i \neq k} \widehat{u}_i(w) + \frac{\widehat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_k)^2}$$

7: Atualize  $w_k$

$$8: w_k^{n+1} = \frac{\int_0^\infty w |\widehat{u}_k(w)|^2 dw}{\int_0^\infty |\widehat{u}_k(w)|^2 dw}$$

9: fim

10: Aplicar *Dual Ascent* para todo  $w \geq 0$

$$11: \widehat{w}_{n+1} \leftarrow \widehat{w}^n + \tau(\widehat{f} - \sum_k \widehat{u}_k^{n+1})$$

$$12: \text{até atender a convergência : } e = \frac{\sum_k \|\widehat{u}_k^{n+1} - \widehat{u}_k^n\|_2^2}{\|\widehat{u}_k^n\|_2^2} < \varepsilon$$


---

### 3.2.3 Análise de desempenho da VMD em comparação com a EMD

Nesta seção, serão abordadas as vantagens da VMD em relação o EMD no quesito, decomposição de sinal multicomponente, detecção de características de banda estreita e robustez ao ruído. Para facilitar a comparação do VMD e do EMD, o número de FMIs resultantes do EMD no cenário correspondente será tomado como valor padrão de IMF para a VMD.


#### 3.2.3.1 Decomposição de sinal multicomponente

Analisando um sinal multicomponente definido como  $x(t)$ :

$$x(t) = \sin(2\pi f_1 t) + \sin(2\pi f_2 t) + \sin(2\pi f_3 t). \quad (15)$$

em que  $x(t)$  é composto por três componentes harmônicos  $f_1 = 35\text{Hz}$ ,  $f_2 = 50\text{Hz}$  e  $f_3 = 75\text{Hz}$  a forma de onda no tempo do sinal é mostrada na Fig 10.

**Figura 10 – Sinal multicomponente.**




**Fonte: Elaborado pela autora.**

Aplicando a VMD e EMD para decompor o sinal e analisando cada IMF na frequência por meio da FFT, os resultados correspondentes são mostrados nas Figura 11 Figura 12. Analisando os resultados das decomposições VMD e EMD para o sinal multicomponente, verifica-se que o VMD separou os três componentes harmônicos 35, 50 e 75 Hz presentes no sinal e, além disso, os alocou corretamente nas IMF 1, IMF 2 e IMF 3.

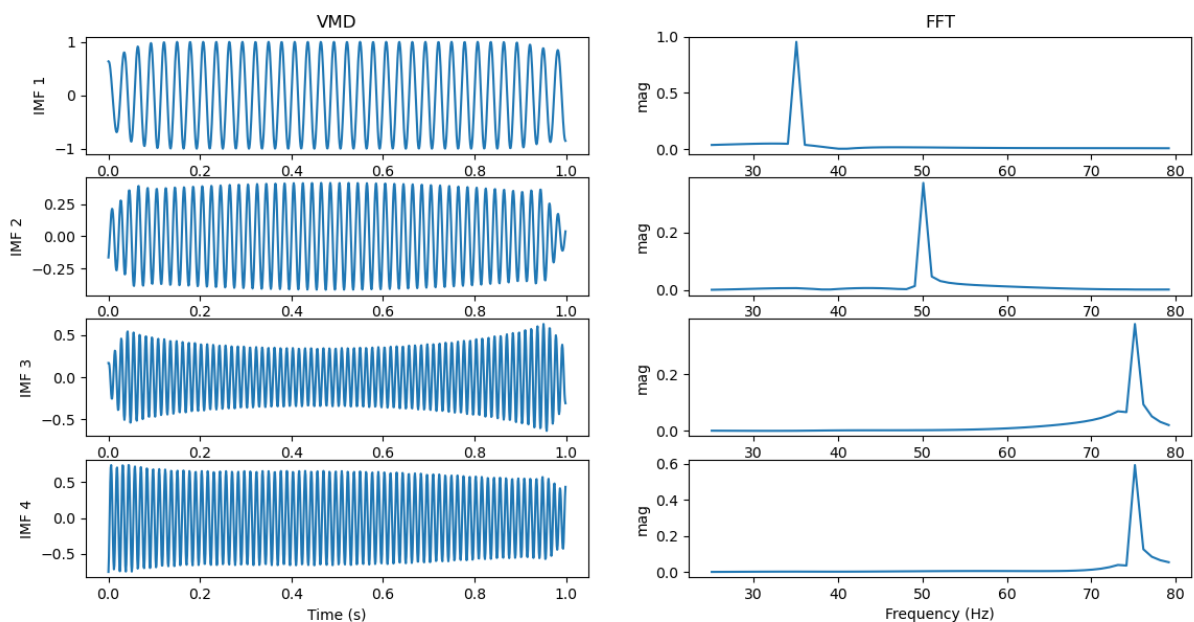
Por outro lado, a EMD não consegue desacoplar corretamente esses três componentes de frequência. Os componentes de 50 e 75 Hz estão alocados na mesma IMF 1. O componente de 35 Hz está alocado no IMF2, mas um pequeno vazamento dele ainda pode ser observado no IMF1. Assim, pode-se dizer que o VMD separa melhor os componentes que a EMD na decomposição do sinal multicomponente.

**Figura 11 – Decomposição EMD e análise tempo frequência do sinal multicomponente.**



Fonte: Elaborado pela autora.

**Figura 12 – Decomposição VMD e análise tempo frequência do sinal multicomponente.**



Fonte: Elaborado pela autora.


### 3.2.3.2 Detecção de recursos de banda lateral

Analisando um sinal multicomponente com frequência a direita e a esquerda da frequência central (banda lateral) definido como  $x(t)$ :

$$x(t) = 0,5\sin(2\pi f_1t) + \sin(2\pi f_2t) + 0,5\sin(2\pi f_3t), \tag{16}$$

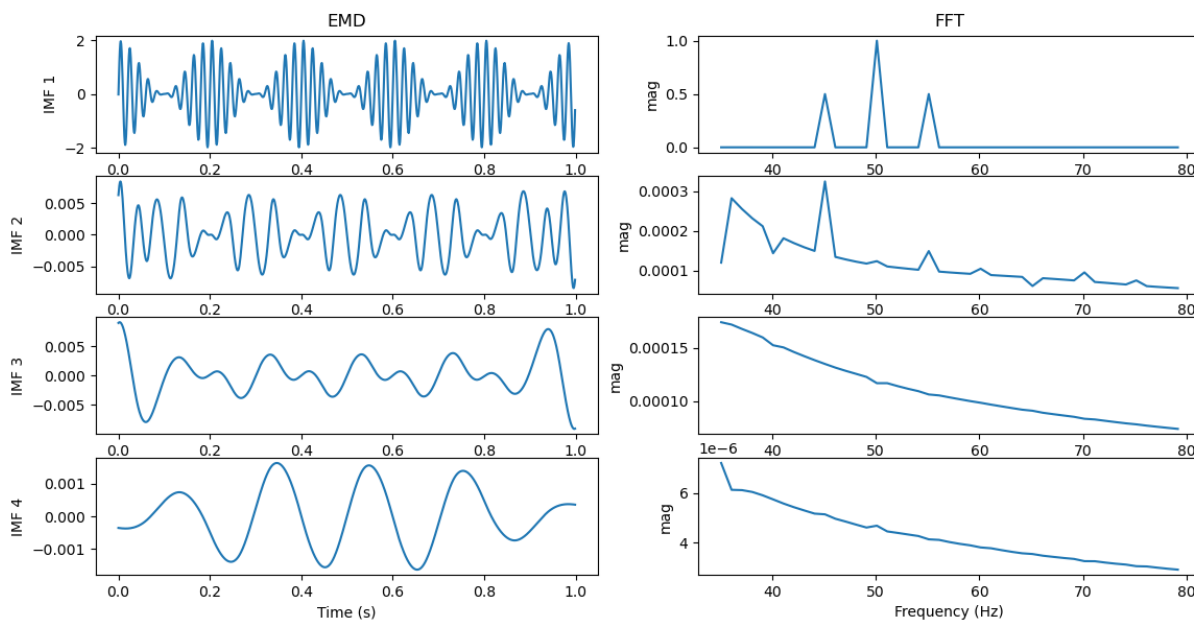
em que  $x(t)$  é composto por três componentes harmônicos  $f_1 = 45Hz$ ,  $f_2 = 50Hz$  e  $f_3 = 55Hz$  a forma de onda no tempo do sinal é mostrada na Figura 13.

Figura 13 – Sinal multicomponente de banda estreita.



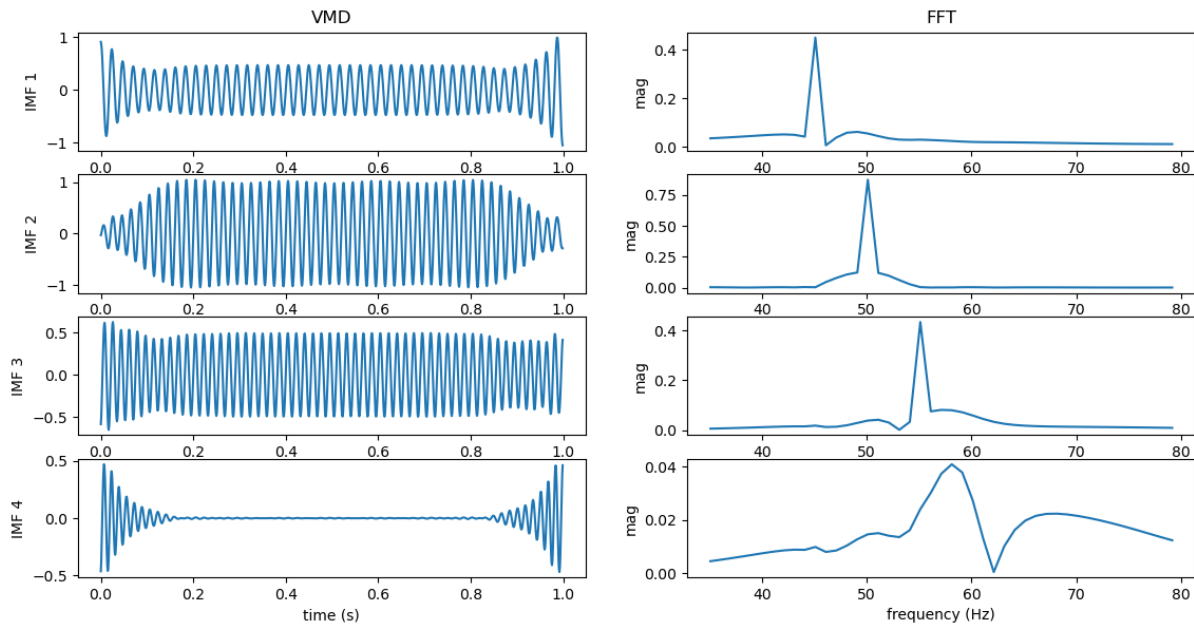
Fonte: Elaborado pela autora.

Figura 14 – Decomposição EMD e análise tempo frequência do sinal multicomponente de banda estreita.



Fonte: Elaborado pela autora.

**Figura 15 – Decomposição VMD e análise tempo frequência do sinal multicomponente de banda estreita.**



Fonte: Elaborado pela autora.

O primeiro e o terceiro componentes da equação são projetados com menor amplitude para simular componentes de frequência de banda lateral. Aplicando a VMD e EMD para decompor o sinal e analisando cada IMF na frequência por meio da FFT, os resultados correspondentes são mostrados nas Figura 14 e na Figura 15.

Verifica-se que, embora as três frequências estejam muito próximas umas das outras e os componentes da banda lateral apresentem baixa amplitude, ambos os componentes da banda lateral foram detectados com sucesso pela VMD e perfeitamente desacoplados da frequência central 50 Hz.

A EMD não consegue realizar a detecção bem-sucedida dos recursos de banda lateral. Todos os três componentes de frequência estão alocados erroneamente no mesmo IMF. Através deste experimento, pode-se dizer que o EMD é ineficiente na detecção de características de banda lateral, enquanto o VMD apresenta uma poderosa capacidade neste aspecto.


### 3.2.3.3 Decomposição de sinal multicomponente com frequência variável

Analisando um sinal definido como  $x(t)$ :

$$x(t) = \begin{cases} \sin(2\pi f_1 t), & 1 < t < 0,5s \\ \sin(2\pi f_c t), & 0,5 < t < 1s \\ \sin(2\pi f_2 t)\sin(2\pi f_3 t), & 1 < t < 1,5s \end{cases} \quad (17)$$

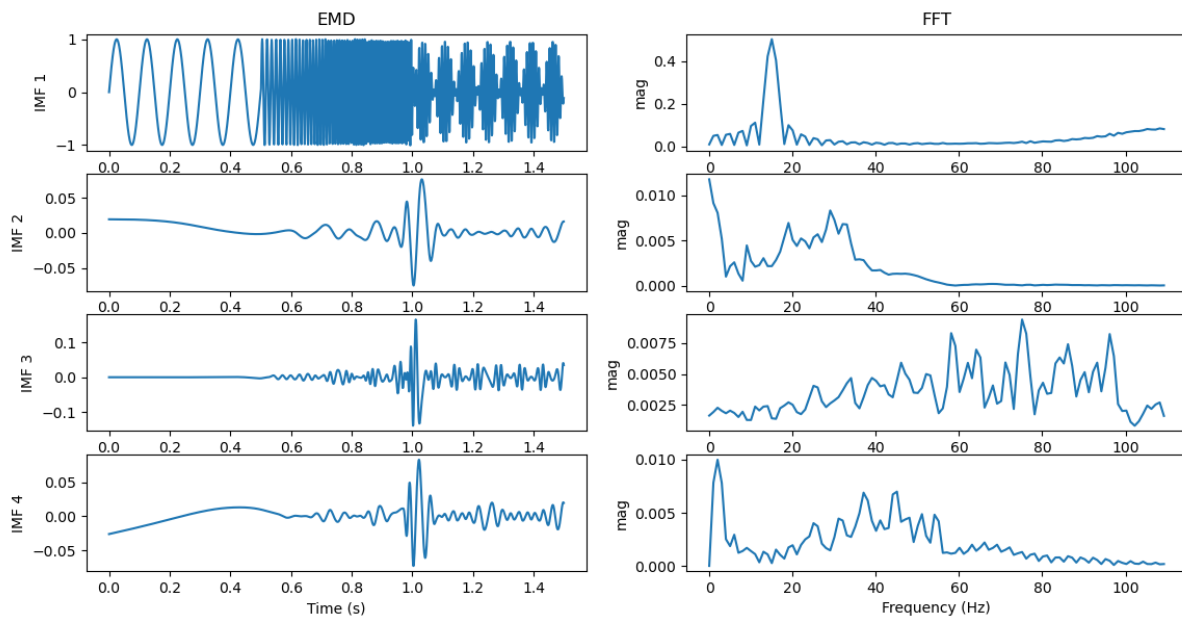
Em que  $x(t)$  é composto por  $f_1 = 10Hz$ ,  $f_2 = 110Hz$  e  $f_3 = 5Hz$  e  $f_c$  é *Chirp linear* incrementa linearmente de  $f_1$  à  $f_2$  no intervalo de 0,5 à 1s a forma de onda do sinal é mostrada na Figura 16.

**Figura 16 – Sinal multicomponente de banda estreita.**



**Fonte: Elaborado pela autora.**

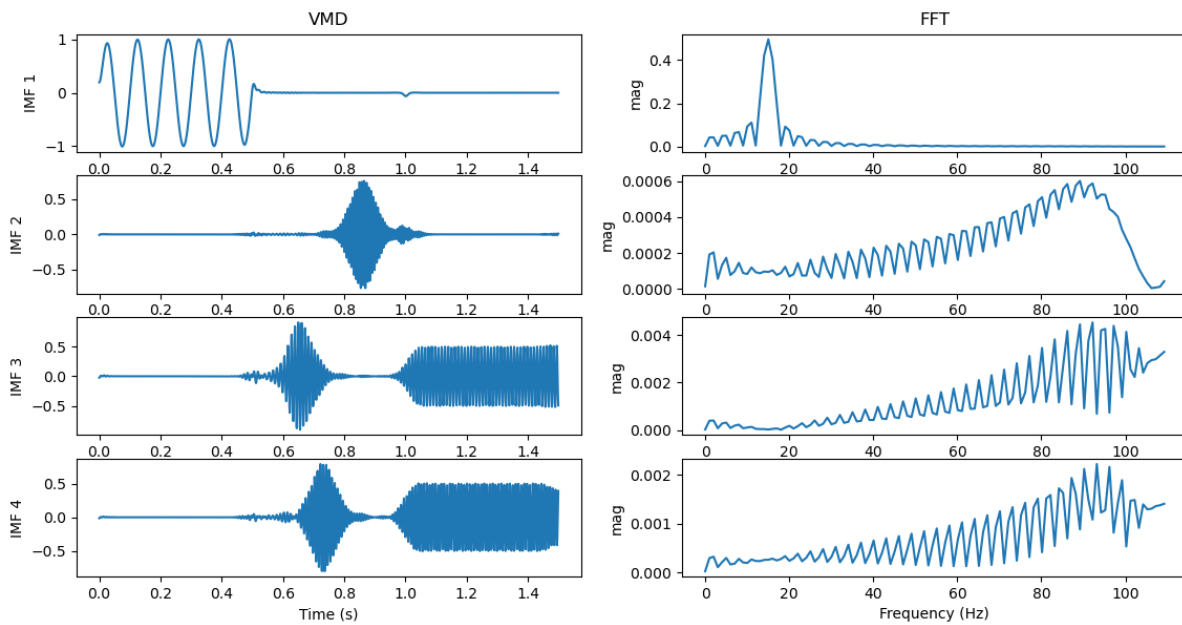
**Figura 17 – Decomposição EMD e análise tempo frequência do sinal multicomponente de banda estreita.**



**Fonte: Elaborado pela autora.**

Da mesma forma, tanto o VMD como o EMD são aplicados ao sinal e os resultados correspondentes são mostrados nas Figura 17 e Figura 18. A partir dos resultados obtidos, é verificado que a característica intra-onda foi extraída com sucesso tanto pela VMD como pela EMD. Na Figura 18, é possível observar que o recurso de modulação de amplitude  $f_1$  até  $f_2$  foram detectados com sucesso pela VMD, a partir do qual as frequências  $f_1$  e  $f_2$  podem ser facilmente derivada. Entretanto, o recurso de modulação não pode ser observado a partir dos resultados da EMD. A comparação mostra que a VMD ainda é superior a EMD porque a EMD gera componentes não

**Figura 18 – Decomposição VMD e análise tempo frequência do sinal multicomponente de banda estreita.**



Fonte: Elaborado pela autora.

identificados enquanto a VMD não. Esses componentes de frequência não identificados dificultam a interpretação do sinal.


### 3.2.3.4 Robustez ao ruído

Para investigar o desempenho da VMD em relação a presença de ruído no sinal, foi definido como  $x(t)$ :

$$x(t) = \sin(2\pi f_1 t) + \sigma(t). \tag{18}$$

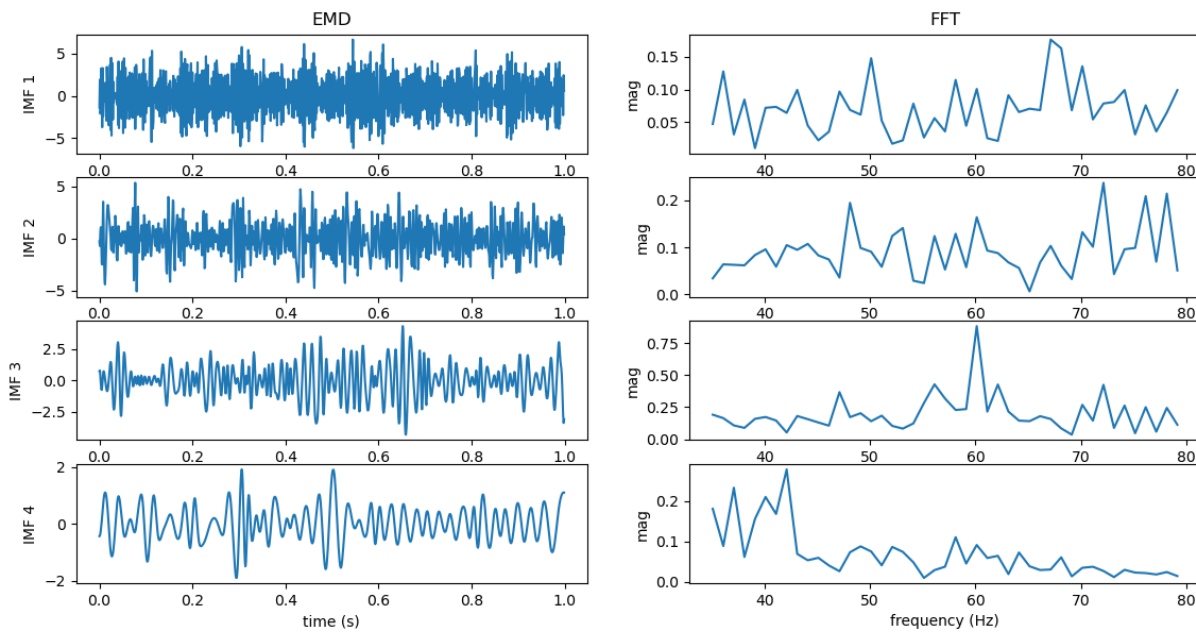
O sinal  $x(t)$  harmônico de frequência  $f_1 = 60\text{Hz}$  é somado a um ruído branco Gaussiano  $\sigma(t)$ , com relação sinal ruído (SNR) de 10 dB.

**Figura 19 – Sinal com ruído com SNR 10 dB.**



Fonte: Elaborado pela autora.

**Figura 20 – EMD do sinal com ruído com SNR 10 dB.**



**Fonte: Elaborado pela autora.**

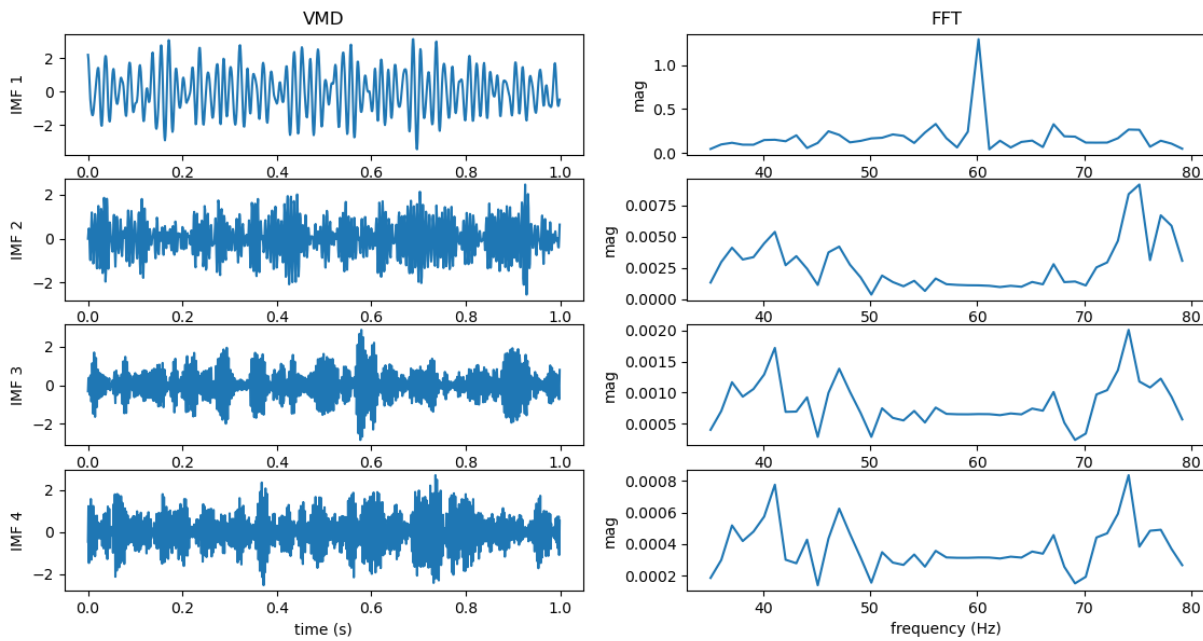
A forma de onda no tempo do sinal é mostrada na Figura 19. Observando a Figura 19 é percebido que o sinal harmônico foi seriamente distorcido pelo ruído. Então, tanto a VMD quanto a EMD são aplicadas ao processamento do sinal e os resultados correspondentes são mostrados nas Figura 21 e Figura 20 respectivamente.

Na Figura 20 é observado que o ruído, particularmente aqueles em bandas de alta frequência, não são extraídos com sucesso pelo EMD, como observado, Isso implica que ainda existe ruído nos FMIs resultantes pelo EMD. Em comparação com a Figura 21 é notório que o VMD mostra uma capacidade mais poderosa do que o EMD na filtragem de ruído branco, ou seja, o ruído branco distribuído em diferentes bandas de frequência foi extraído com sucesso pelo VMD, como pode ser observado na IMF 1.

A partir dos experimentos acima, pode-se concluir a VMD apresenta desempenho superior a EMD no que diz respeito a separação de frequências e robustez ao ruído. O algoritmo da VMD é mais robusto ao ruído, porque o filtro wiener está embutido para atualização de modos. Além disso, pode distinguir com precisão os componentes harmônicos de sinais não estacionários, independentemente de quão próximos estão seus componentes de frequência (KONSTANTIN; DOMINIQUE, 2014). Diante do exposto todas essas superioridades permitem que a VMD tenha potencial como uma ferramenta promissora para a decomposição de sinais com distúrbios elétricos.



Figura 21 – VMD do sinal com ruído com SNR 10 dB.



Fonte: Elaborado pela autora.

### 3.3 INTELIGÊNCIA ARTIFICIAL (IA)

Inteligência artificial é um ramo da ciência da computação que se concentra no desenvolvimento de sistemas inteligentes que podem realizar tarefas que normalmente exigiriam inteligência humana (MURPHY, 2012). A história da IA remonta à década de 1950, quando pesquisadores como John McCarthy, Marvin Minsky e Claude Shannon iniciaram estudos sobre como as máquinas poderiam ser programadas para pensar como seres humanos. Ao longo dos anos, a IA tem evoluído e se diversificado em várias subáreas, como aprendizado de máquina, processamento de linguagem natural, robótica e visão computacional (RUSSELL; NORVIG, 2015).

O aprendizado de máquina é uma subárea da IA que se concentra no desenvolvimento de algoritmos que podem aprender a partir de dados. O termo foi cunhado por Arthur Samuel pode ser definido, como “um campo de estudo que dá aos computadores a capacidade de aprender sem serem explicitamente programados” (SAMUEL, 2000).

A “aprendizagem” do aprendizado de máquina possui uma etapa de treinamento, no qual amostras de dados de entrada são fornecidas juntamente com os resultados esperados na saída. O algoritmo então se configura de forma otimizada para que possa não apenas produzir o resultado desejado quando apresentado às entradas de treinamento, mas também generalizar para produzir o resultado desejado a partir de dados novos e inéditos. Assim como acontece com os humanos, um bom algoritmo

pode praticar o aprendizado “ao longo da vida” à medida que processa novos dados e aprende com seus erros (NAQA; MURPHY, 2015).

É possível dividir o aprendizado de máquina em supervisionado, não supervisionado e semi-supervisionado. O aprendizado supervisionado é usado para estimar um conjunto de dados desconhecido (entrada, saída) a partir de amostras conhecidas (entrada, saída), onde a saída é rotulada (por exemplo, classificação e regressão). Para o aprendizado não supervisionado, apenas amostras de entrada são fornecidas ao algoritmo de aprendizado (por exemplo, agrupamento e estimativa da função de densidade de probabilidade) (NAQA; MURPHY, 2015).

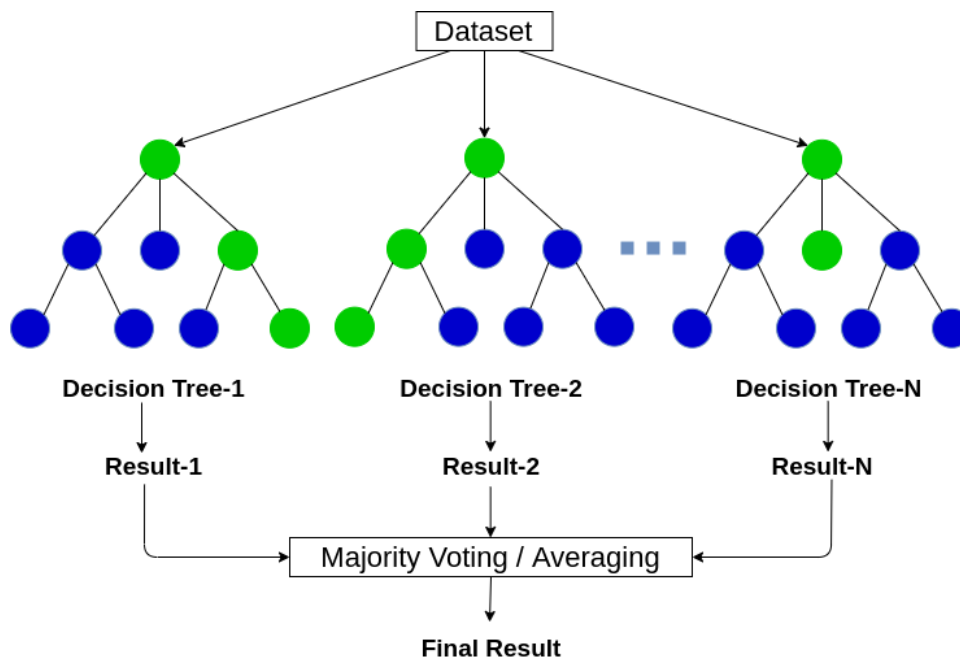
O aprendizado semi-supervisionado é uma combinação de supervisionado e não supervisionado, onde parte dos dados é parcialmente rotulada e a parte rotulada é usada para inferir a parte não rotulada (por exemplo, sistemas de recuperação de texto/imagem). O aprendizado de máquina tem aspectos da ciência da engenharia, como estruturas de dados, algoritmos, probabilidade e estatística, e teoria da informação e controle e aspectos das ciências sociais, desenhando ideias da psicologia e da filosofia (NAQA; MURPHY, 2015).

### 3.3.1 *Random forest*

A expressão florestas de decisão aleatórias foi introduzido por Tin Kam Ho em seu trabalho intitulado *Random decision forests* em 1995, que propunha a inserção da aleatoriedade a árvores de decisão (*Decision Trees - DT*) com o objetivo de melhorar o desempenho das previsões. (HO, 1995). Leo Breiman, desenvolveu o algoritmo de aprendizado de máquina que combina a saída de um conjunto de árvores de decisão, em que cada árvore é construída usando um processo aleatório para alcançar um resultado único, o *Random forest* (BREIMAN, 2001).

As DTs são algoritmos de aprendizado supervisionado amplamente utilizados devido à sua alta velocidade de execução, entretanto elas podem estar sujeitas a problemas, como viés e perda de precisão de generalização em dados não vistos (HO, 1995). O algoritmo do RF utiliza *bagging*, também conhecido como agregação por *bootstrap*, (BREIMAN, 1996) e subespaço aleatório para criar uma floresta não correlacionada de árvores de decisão.

O subespaço aleatório, gera um subconjunto aleatório de recursos, que garante uma correlação reduzida entre as DT e isto é o que distingue árvores de decisão e florestas aleatórias. Enquanto as árvores de decisão levam em conta todas as possíveis divisões de recursos, as florestas aleatórias selecionam somente um subconjunto desses recursos possibilitando previsões e resultados mais precisos (BREIMAN, 2001).

Figura 22 – Diagrama do *Random Forest*.

Fonte: (VIDHYA, 2021).

A Figura 22 exemplifica o algoritmo de floresta aleatória em que o algoritmo é composto por um conjunto de árvores de decisão. Instância de aleatoriedade é injetada por meio do empacotamento de recursos, adicionando mais diversidade ao conjunto de dados e reduzindo a correlação entre as árvores de decisão. Dependendo do tipo de problema, a determinação da previsão irá variar. Para uma tarefa de regressão, será calculada a média das árvores de decisão individuais e, para uma tarefa de classificação, um voto majoritário produzirá a classe prevista.

O algoritmo RF sob presença de *outliers* demonstra ser um algoritmo robusto para modelagem de dados, também é utilizado em espaços de parâmetros dimensionais elevados. Embasado na metodologia do subespaço aleatório, o algoritmo RF emprega o critério da impureza de Gini para analisar o poder de predição na etapa de treinamento, em que a convergência tem como princípio a redução da impureza (SARICA; CERASA; QUATTRONE, 2017).

### 3.3.2 Extração de características

As principais vantagens de representar um sinal usando atributos para análise são robustez e simplicidade (JENA; RAY; BABU, 2018). Valores de pontos máximos e mínimos do sinal apresentam-se como boas métricas para DQEE, indicando os valores de picos superiores e inferiores.

Uma métrica bastante conhecida é a energia do sinal, que representa sua

intensidade e pode ser obtida através da soma dos quadrados das amplitudes das amostras, como mostra a equação 19.

$$E = \sum_{k=0}^{K-1} [u(k)]^2 \quad (19)$$

em que  $E$  é a energia  $u(k)$  é a amplitude da IMF,  $K$  é o número de amostras total. A energia aparenta ser uma boa característica, pois a amplitude do sinal de tensão ideal não apresenta as variações do que em sinais com perturbações apresentam.

Outra métrica a ser avaliada é a Taxa de Cruzamento por Zeros (TCZ), que indica quantas vezes houve variação entre os eixos positivos e negativos do sinal de cada segmento, ou seja, informa quantas vezes o sinal cruza o eixo zero (KIM; KUO, 2003).

$$TCZ = \frac{1}{2} \sum_{k=1}^{K-1} | \operatorname{sgn}[u(k)] - \operatorname{sgn}[u(k-1)] | \quad (20)$$

em que:

$$\operatorname{sgn}[u(k)] = \begin{cases} 1, & u(k) \geq 0 \\ -1, & u(k) < 0 \end{cases} \quad (21)$$

A curtose é definida conforme a equação 22, onde  $T_1$  é o valor RMS do sinal e  $T_2$  é o valor do desvio padrão. A curtose calcula os picos ou vales relativos da distribuição comparada com uma distribuição normal. A curtose representa um momento estatístico que informa quão longe o sinal está de uma distribuição normal com o mesmo desvio padrão (PEARSON, 1905).

$$\gamma = \frac{\sum_1^K (u(k) - T_1)^2}{(K-1)T_2^2} \quad (22)$$

Skewness é uma medida de falta de simetria. É dado na Equação 23. É um parâmetro de forma que caracteriza o grau de assimetria de uma distribuição. Uma distribuição é dita positivamente assimétrica com grau de assimetria maior que 0, indicando um excesso de valores baixos. Por outro lado, é assimétrico negativo com grau de assimetria menor que 0, indicando um excesso de valores altos (GOLUBEV, 1961).

$$S = \left[ \frac{1}{(k-1)} \right] \sum_{k=1}^K \frac{(X_k - \widehat{X})^3}{S^3} \quad (23)$$

### 3.3.2.1 Validação e desempenho

A validação cruzada K-fold é uma técnica computacional intensa, que utiliza todas as amostras disponíveis tanto como amostras de treinamento quanto para teste. Com isso, em relação a outros métodos de validação como *Hold-out* e *Leave-One-Out* a cruzada consegue chegar a resultados mais precisos (SCHREIBER JACQUES NELSON CORLETA; BESKOW, 2017).

A avaliação de desempenho de um classificador consiste em verificar se a classe prevista corresponde, de fato, à classe da amostra de entrada. A acurácia, pode ser obtida a partir dos parâmetros de saída contribuindo para a avaliação do desempenho do classificador. A Acurácia indica a capacidade da rede de classificar as amostras corretamente (SOKOLOVA; LAPALME, 2009). É matematicamente expresso pela Equação 24.

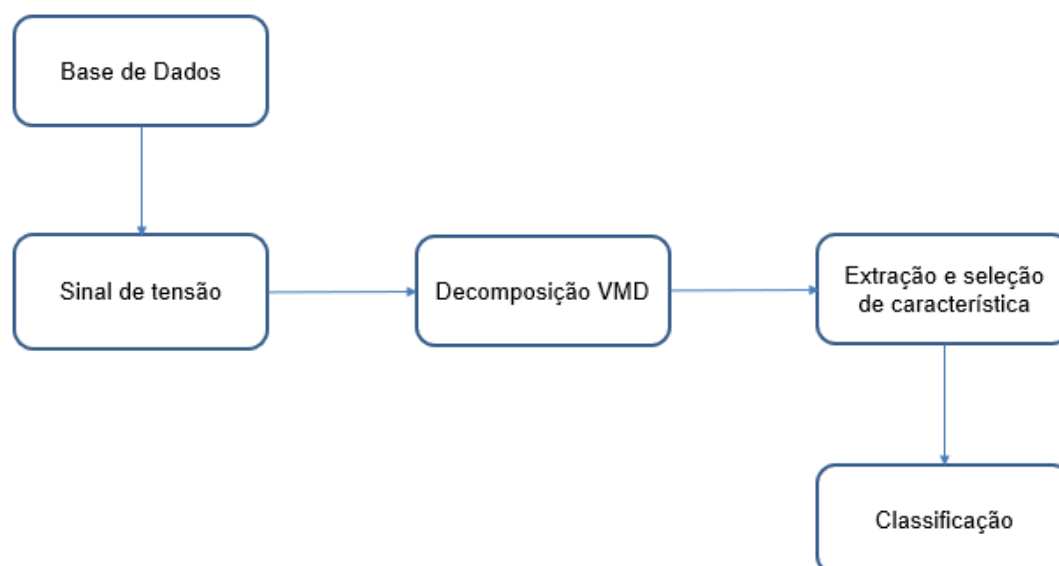
$$\text{Acurácia} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (24)$$

Conforme mostrado na Equação 24, tem-se que TP (*True Positive*) representa o número de sinais verdadeiramente positivos, o que significa que o tipo de DQEE estimado está classificado corretamente. FP (*False Positive*) representa o número de sinais classificados como falso positivo, o que significa que o DQEE não pertencia a classe a qual foi estimado, ou seja, foi classificado incorretamente. FN (*False Negative*) representa o número de sinais de falso negativo, o que significa que o classificador indicou a não ocorrência do DQEE no sinal estimado, porém de forma incorreta. TN (*True Negative*) representa o número de sinais negativos verdadeiros, o que significa a não ocorrência do DQEE no sinal foi identificado corretamente.

## 4. METODOLOGIA

Nesta pesquisa, a metodologia proposta segue, em linhas gerais, o fluxograma em blocos apresentado na Figura 23. Inicialmente são adquiridos por meio das equações paramétricas os sinais de tensão com e sem distúrbios. Tais equações foram obtidas com base no modelo público disponibilizado por Igual, (2018). A segunda etapa consiste em aplicar pré-processamento nos sinais da base, nos quais são decompostos por meio do algoritmo da VMD em funções de modo intrínseco IMFs. Na terceira etapa, realiza-se a extração de atributos obtidos por meio de métricas aplicadas a cada sinal. Na quarta etapa as métricas de cada uma das classes são submetidas a um sistema seletor de características para escolha da melhor combinação. Na quinta etapa o classificador multiclasse baseado em algoritmo *Random Forest* realiza a detecção e discriminação entre os distúrbios em estudo

**Figura 23 – Fluxograma metodologia proposta.**



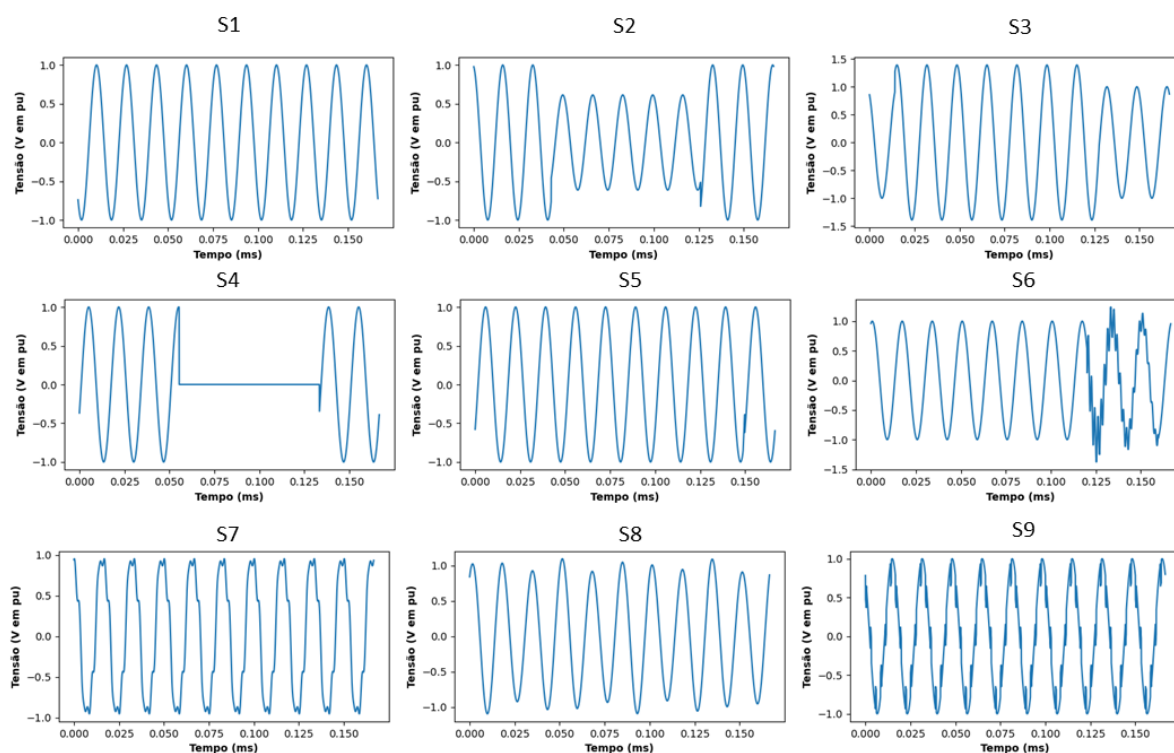
Fonte: Autoria própria

### 4.1 BASE DE DADOS

Com base nas equações paramétricas disponibilizado por Igual et al. (2018), gerou-se a base de dados denominada de BD01. Tal base contém nove classes de sinais, sendo uma classe composta por sinais ideais (S1) e demais por: (S2) Afundamento de Tensão, (S3) Elevação de Tensão, (S4) Interrupção, (S5) Transitório Impulsivo, (S6) Transitório Oscilatório, (S7) Harmônico, (S8) Flicker, (S9) Notching.

A Figura 24 ilustra os distúrbios presentes na BD01. Para a BD01 foram gerados 9000 sinais distintos, sendo 1000 de sinais ideais sem perturbações e 1000 sinais

Figura 24 – Sinais de tensão em estudo.



Fonte: Autoria própria

para cada uma das oito classe de distúrbio. Cada sinal representa uma forma de onda de tensão com duração de 10 ciclos. A frequência de amostragem foi definida em 15,6 kHz, em consonância com a frequência usual dos Registradores Digitais de Perturbação e a frequência fundamental foi definida em 60 Hz. As amplitudes dos sinais sintéticos foram normalizadas para 1 p.u, contendo 2560 amostras cada sinal.

Com o intuito de avaliar a robustez do método proposto, criou-se as bases de dados BD02, BD03 e BD04 compostas pelos mesmos sinais da BD01, acrescidos de ruídos com valores de SNR iguais a, respectivamente, 30 dB, 40 dB e 50 dB.


## 4.2 VMD APLICADA AOS SINAIS COM DQEE

Os sinais presentes na base de dados são decompostos pela VMD em IMFs. É esperado que a decomposição consiga separar o conteúdo do sinal presente na frequência fundamental de 60Hz isoladamente em uma IMF, proporcionando assim que as outras IMFs possam indicar, diretamente a existência de distúrbios bem como sua localização no tempo, associados a outros níveis de frequências.

Para o trabalho em questão o algoritmo da VMD foi parametrizado com  $K=5$  (número de IMFs) e  $\alpha = 200$ . Cada IMF apresenta características na amplitude, tempo e frequência que mostram-se relevantes para classificação das DQEEs.

Para tornar possível a análise e diferenciação entre os diversos distúrbios, inicialmente será observada a decomposição um sinal senoidal com frequência de 60Hz. A Figura 25 ilustra a VMD com suas 5 IMFs respectivamente.

**Figura 25 – VMD do sinal senoidal puro.**



**Fonte: Elaborado pela autora.**

Analisando as decomposições do sinal em regime permanente observa-se que a primeira IMF está centralizada na frequência de 60Hz e contém o sinal senoidal praticamente sem alterações na amplitude. As IMFs 2, 3, 4 e 5 apresentam apenas a variação no início e fim do sinal característica do algoritmo da VMD, porém em sua maioria apresenta valor zero, visto que é um sinal senoidal puro. A Figura 26 ilustra as cinco primeiras IMFs para o o distúrbio de afundamento.

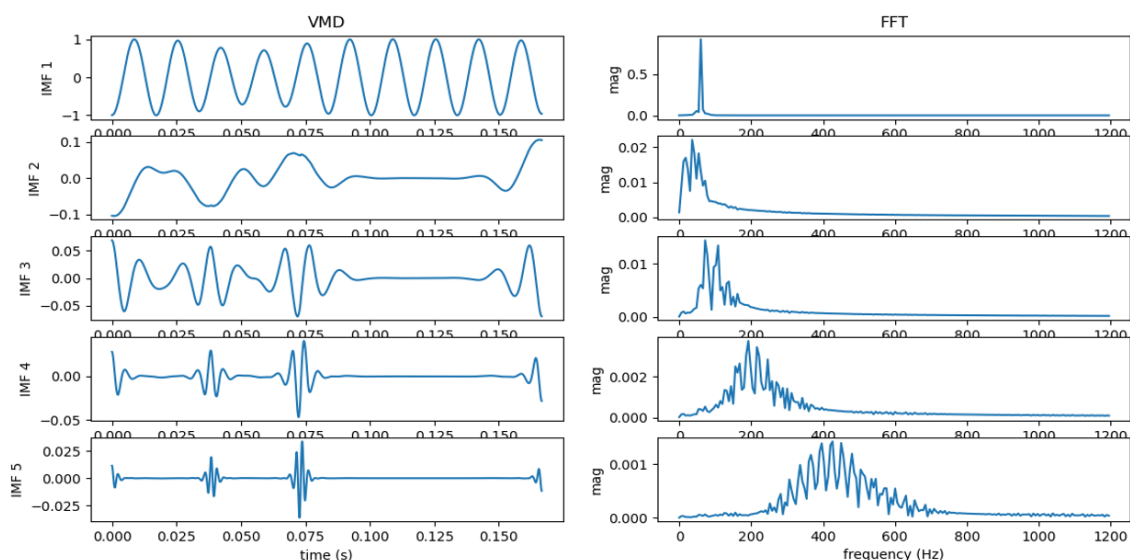
O afundamento tem como característica uma redução no valor eficaz do sinal, isto é refletido na primeira IMF que apresenta amplitude com valor reduzido e com frequência central de 60Hz. Pode-se observar que as IMFs 3, 4 e 5 apresentam oscilações nos instantes de início e término do distúrbio (tendo sido menos distinto na IMF 3). Estas oscilações, não aparecem na decomposição do sinal de tensão em regime permanente. Este comportamento se repete para elevação e interrupção de tensão. A Figura 27 ilustra as cinco primeiras IMFs para a elevação de tensão. A Figura 28 ilustra as cinco primeiras IMFs para a interrupção de tensão.

Com a VMD a IMF 1 para ambas refletem na amplitude a característica do distúrbio em questão sendo de elevação ou redução no valor e centralizadas na frequência de 60Hz. Da mesma forma, as IMFs 3, 4 e 5 apresentam oscilações nos instantes de início e término do distúrbio.

A decomposição para os distúrbios transitório impulsivo e oscilatório são experi-

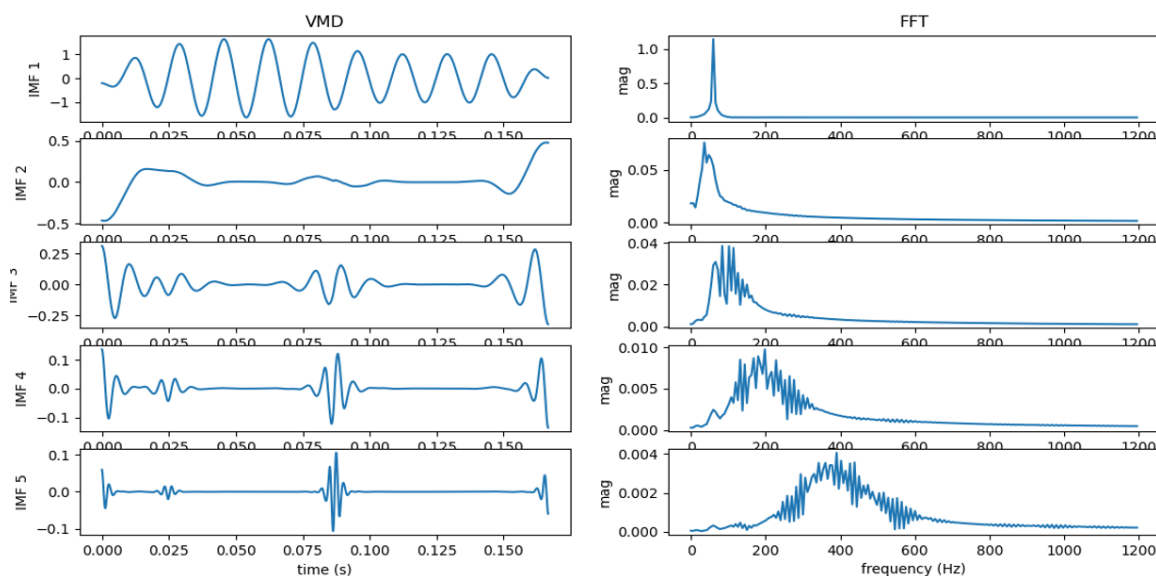


**Figura 26 – VMD do sinal Afundamento.**



Fonte: Elaborado pela autora.

**Figura 27 – VMD do sinal Elevação.**



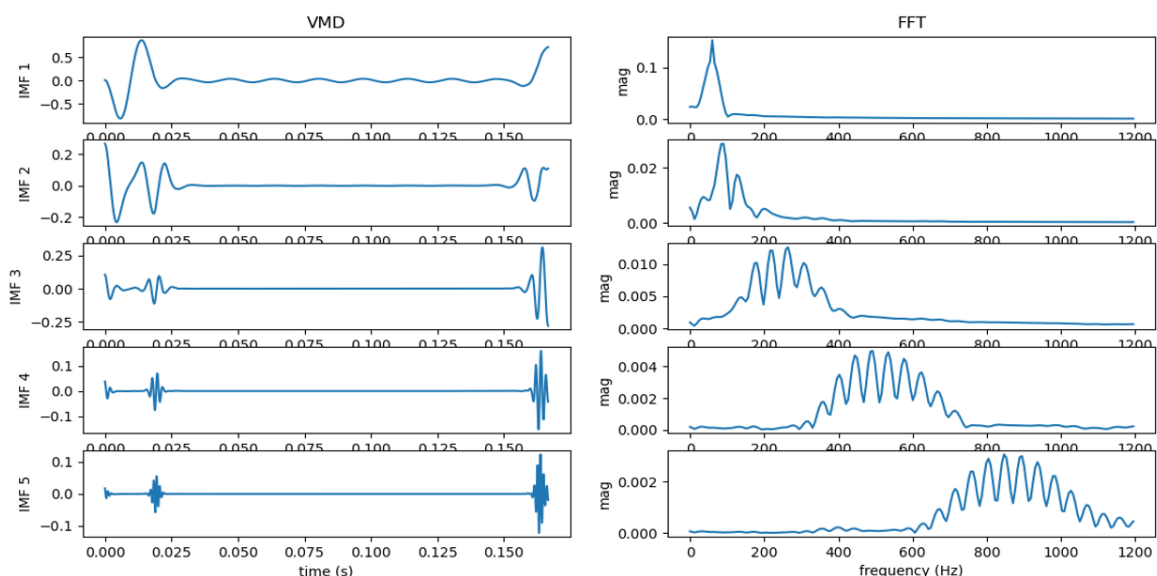
Fonte: Elaborado pela autora.

das nas Figuras 29 30 respectivamente.

É possível observar que para o transitório impulsivo a IMF 4 e IMF 5 (sendo mais significativa na 5) apresentam um pico indicando o instante que o evento ocorreu. Para o transitório oscilatório é possível observar que as oscilações transitórias estendem-se por todo sinal durante o evento nas IMFs 2, 4 e 5, assim como é possível observar as frequências presentes nessas oscilações no caso da ilustração 800Hz.


Para os harmônicos a Figura 31 ilustra a decomposição VMD. É possível obser-

Figura 28 – VMD do sinal Interrupção.



Fonte: Elaborado pela autora.

Figura 29 – VMD do sinal Transitório impulsivo.

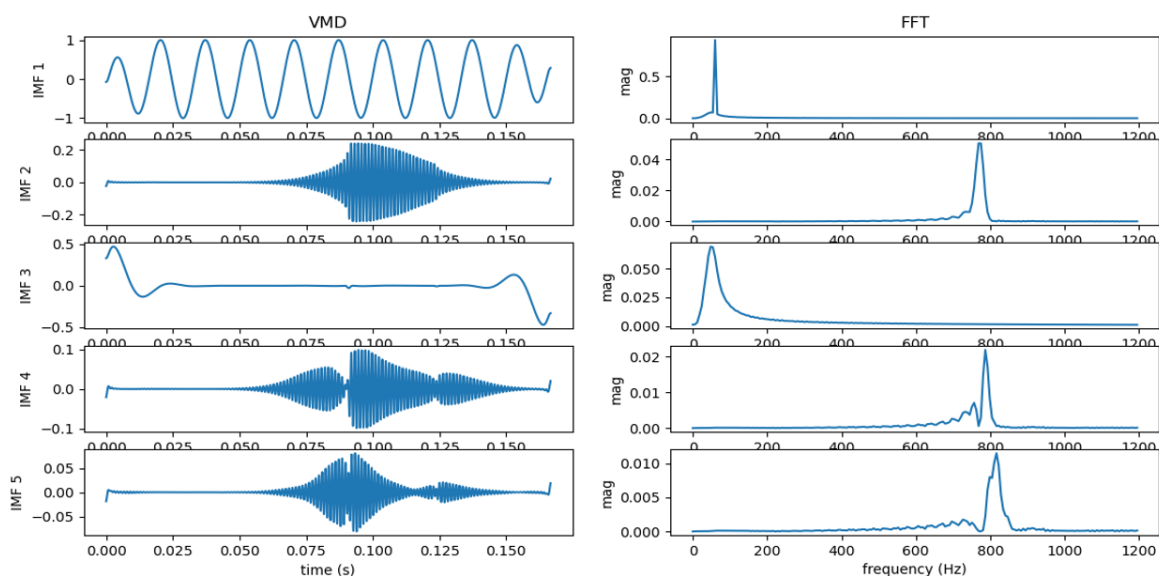


Fonte: Elaborado pela autora.

var que a IMF 1 apresenta o sinal senoidal puro com frequência de 60Hz. Nas IMF 2 e 4 é possível obter as amplitudes dos harmônicos com a frequência de 400Hz e as IMFs 3 e 5 os harmônicos com frequência de 300 Hz. Com isso, nota-se que as formas de onda analisadas nas decomposições VMD indicam as componentes de frequência presentes no distúrbio, permitindo a caracterização deste.

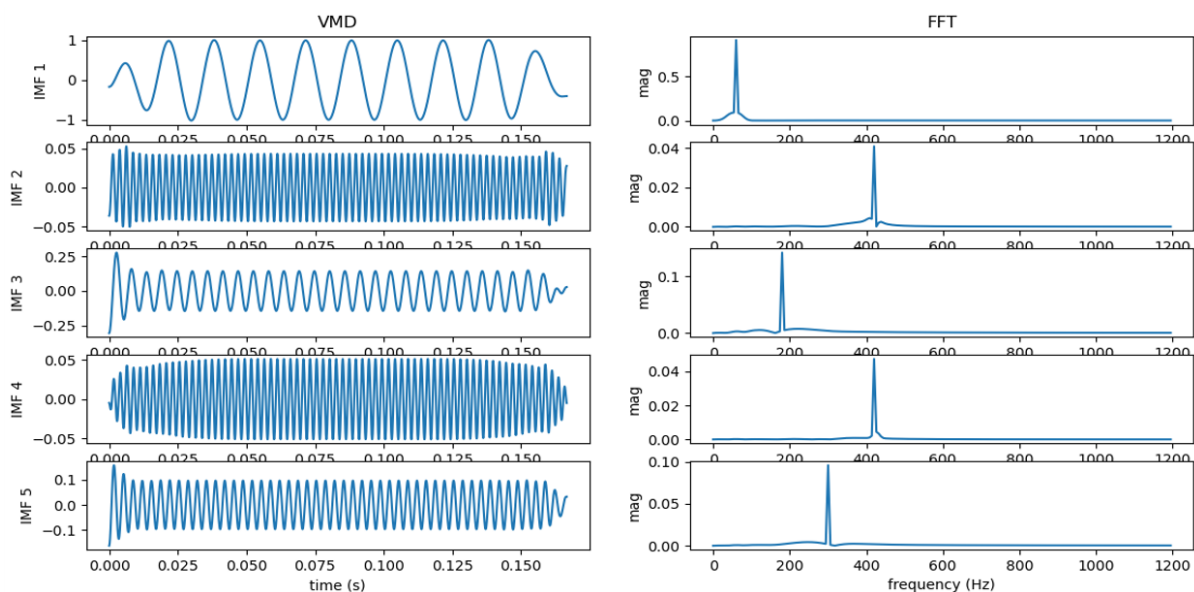
A decomposição VMD do distúrbio *Flicker* é ilustrado na Figura 32. Para o *Flicker*, na IMF 1 é possível obter a frequência de 60 Hz e as variações na amplitude do sinal apresentando valores ora inferiores ora superiores ao nominal. Na IMF 2 ainda

Figura 30 – VMD do sinal Transitório Oscilatório.



Fonte: Elaborado pela autora.

Figura 31 – VMD do sinal com harmônicos.

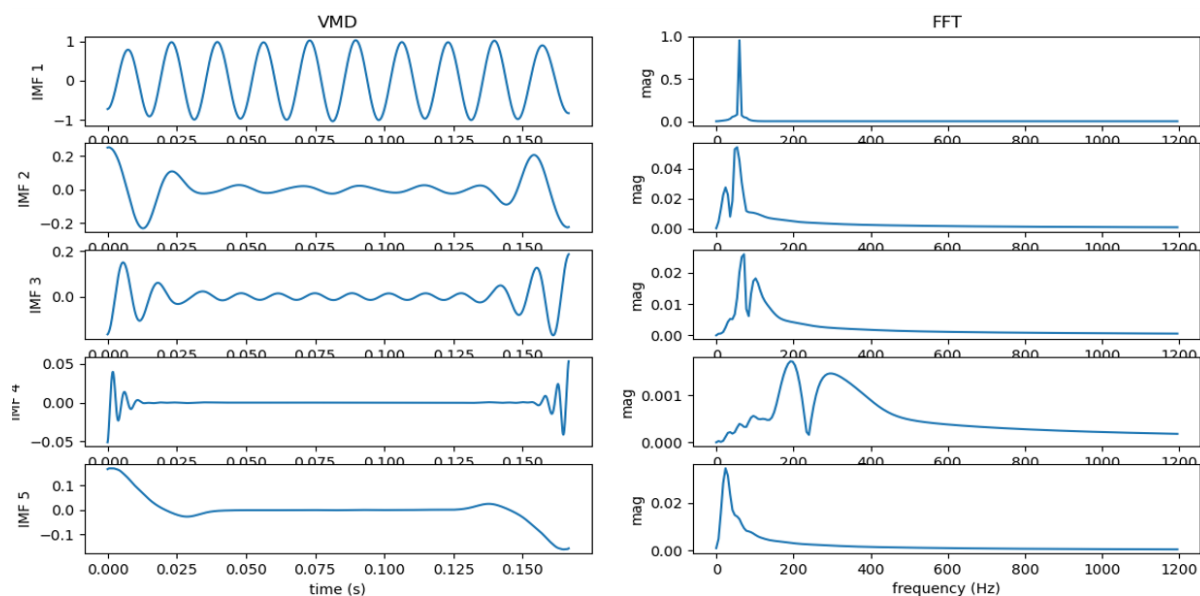


Fonte: Elaborado pela autora.

é possível observar vestígios dessa oscilação que se estende por todo sinal. A IMF 2 contém as frequências de 28 Hz e 60 Hz. As IMFs 4 e 5 apresentam comportamento similar ao sinal senoidal puro ilustrado na figura 25. Por apresentar características similares a outras classes de sinais é um distúrbio difícil de classificar corretamente.

O distúrbio *notching* denominado por alguns autores de corte de tensão, introduz frequências harmônicas e inter-harmônicas acima das habitualmente encontradas em sistemas de distribuição. Estas frequências podem ultrapassar 3,6k Hz. A Figura 33

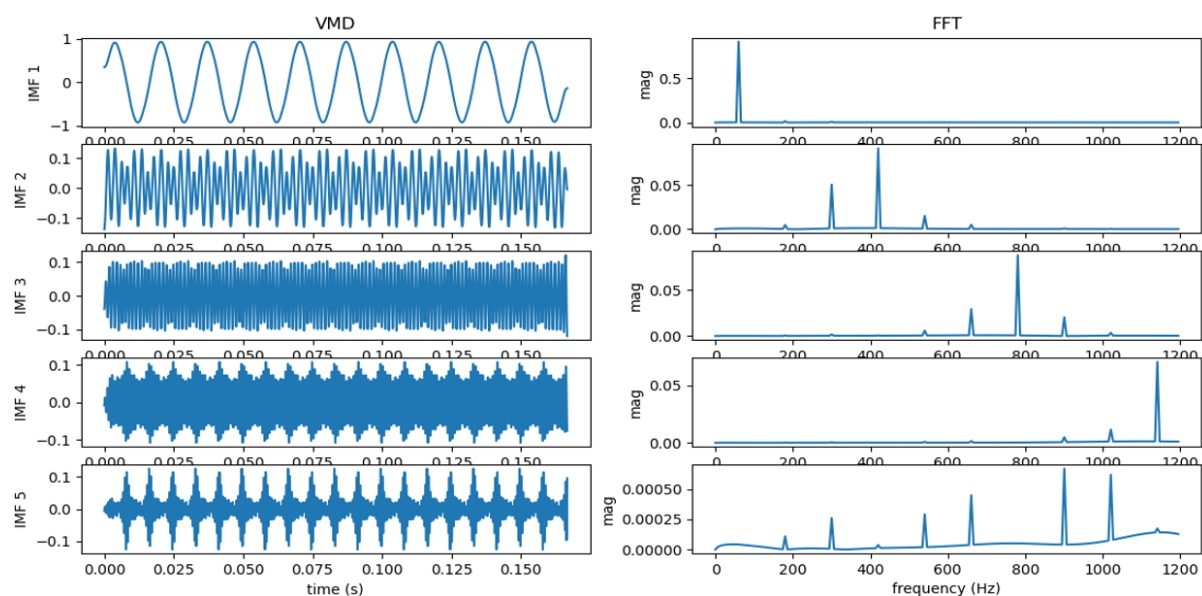
Figura 32 – VMD do sinal com *Fliker*.



Fonte: Elaborado pela autora.

ilustra a decomposição VMD do sinal com a presença do *notching*. Nota-se que a IMF 1 é possível observar o sinal puro na frequência de 60Hz totalmente separado de suas componentes harmônicas. Nas IMF 2 e 3 são encontradas frequências de 400 Hz a 800 Hz, bem como a amplitude correspondente dessas frequências. As IMF 4 e 5 estão as maiores frequências 1k Hz e 1,3k Hz.

Figura 33 – VMD do sinal *notching*.



Fonte: Elaborado pela autora.

### 4.3 EXTRAÇÃO E SELEÇÃO DE CARACTERÍSTICAS


Para a identificação de diferentes DQEE, a extração de atributos apresenta uma função importante no processo de reconhecimento de padrões. Para esta pesquisa, os atributos foram extraídos de cada IMF no tempo e frequência, sendo estes: valor máximo, valor mínimo, taxa de cruzamento por zeros (TCZ), energia, Curtose, Skewness, sendo estas matematicamente apresentadas na fundamentação teórica.

Os distúrbios de afundamento, elevação, interrupção como visto apresentaram comportamento semelhantes em suas IMFs o que dificulta a diferenciação entre eles, assim é importante analisar métricas que possam diferenciar tais distúrbios. Deste modo, algumas métricas podem ser extraídas da IMF que contém a frequência fundamental (IMF 1).

Para análise das métricas de uma maneira gráfica foi utilizado um diagrama de caixas (*boxplot*). O retângulo presente no *boxplot* contém 50% dos valores do conjunto de dados, a linha no interior do retângulo corresponde ao valor da mediana, os traços horizontais nas extremidades chamados de *whiskers* determinam os valores máximos e mínimos do conjunto de dados e os círculos são valores atípicos os *outliers*.

A Figura 34 ilustra o *boxplot* para o valor máximo obtido da primeira IMF de todos os sinais este evidencia a característica do distúrbio elevação de tensão com valores superiores aos demais, possibilitando serem linearmente separáveis.

**Figura 34 – Distribuição dos valores máximo para IMF1.**




Fonte: Elaborado pela autora.

A Figura 35 ilustra o *boxplot* para o valor mínimo obtido da primeira IMF de todos os sinais, esta métrica apresenta valores para afundamento e interrupção inferiores aos obtidos em outras classes, os distinguindo, da mesma forma é possível observar valores menores para a interrupção se comparado com o afundamento.

A Figura 36 ilustra o *boxplot* para a energia dos sinais obtido para a primeira IMF de todos os sinais. A Figura 37, ilustra o *boxplot* para a TCZ da IMF 3, A Figura


**Figura 35 – Distribuição dos valores mínimos para IMF1.**



Fonte: Elaborado pela autora.


38 ilustra o Skewness aplicado as frequência da IMF 4 e a Figura 39 ilustra o máximo para IMF4 de todos os sinais.

**Figura 36 – Distribuição dos valores da energia para IMF1.**



Fonte: Elaborado pela autora.


**Figura 37 – Distribuição dos valores TCZ para IMF3.**



Fonte: Elaborado pela autora.


Posteriormente foi realizada a etapa de seleção dos melhores atributos. Esta etapa consiste em selecionar recursos considerando recursivamente conjuntos de

**Figura 38 – Distribuição dos valores Skewness para IMF4.**



Fonte: Elaborado pela autora.

**Figura 39 – Distribuição dos valores máximo para IMF4.**



Fonte: Elaborado pela autora.

atributos cada vez menores. Primeiro, o estimador é treinado no conjunto total e a importância de cada atributo é obtida por meio de um coeficiente. Em seguida, os atributos menos importantes são removidos do conjunto atual. Esse procedimento é repetido recursivamente no conjunto até que o número desejado de recursos a serem selecionados seja alcançado. Com o auxílio a biblioteca sklearn.featureselection do Python foi utilizado o randomforest com número de árvores  $n=200$ . Os atributos utilizados no classificador seguem conforme o Quadro 05.

**Quadro 05 - Atributos selecionados.**

Nº IMF	ATRIBUTOS
IMF 1	Energia, Amplitude valores máximo e mínimo
IMF 2	Amplitude valor máximo, Curtose
IMF 3	TCZ, CurtoseF, SkewnessF
IMF 4	Amplitude valor Máximo, CurtoseF, SkewnessF

#### 4.4 CLASSIFICADORES

O algoritmo RF foi implementado, nesta pesquisa, empregando a biblioteca disponibilizada em linguagem *Python* chamada *Sklearn*. O classificador foi gerado por 200 árvores de decisão, sendo este valor escolhido após análise empírica. O treino e validação do modelo RF foi realizado por meio de validação cruzada do tipo *k-fold*. Nesta pesquisa, a quantidade de *folders* foi atribuído como  $k = 10$ . A validação cruzada consiste em dividir aleatoriamente os dados em  $k$  subconjuntos. Dessa forma,  $k - 1$  conjuntos são utilizados para o treinamento do classificador e o conjunto restante será empregado na etapa de validação. O processo acontece até que todos os conjuntos sejam utilizados na etapa de validação.



## 5. RESULTADOS E DISCUSSÃO

Para avaliação do método proposto, o desempenho do classificador pode ser analisado nas Tabelas 1, 2, 3 e 4 que exibem as matrizes de confusão resultante da classificação de DQEEs referente as bases de dados BD01, BD02, BD03 e BD04. É possível verificar na diagonal principal da matriz o total de sinais que foram classificados corretamente, os demais campos, apresentam a quantidade dos sinais que foram erroneamente classificados.

**Tabela 1 – Matriz de confusão base BD01 sem ruído.**

	S1	S2	S3	S4	S5	S6	S7	S8	S9
S1	1000	0	0	0	0	0	0	0	0
S2	1	990	0	8	0	1	0	0	0
S3	0	0	1000	0	0	0	0	0	0
S4	0	13	0	987	0	0	0	0	0
S5	0	0	0	0	999	1	0	0	0
S6	0	0	0	0	3	995	2	0	0
S7	0	0	0	0	0	7	993	0	0
S8	0	0	0	0	0	0	0	1000	0
S9	0	0	0	0	0	0	0	0	1000

**Tabela 2 – Matriz de confusão base BD02 ruído SNR de 30 dB.**

	S1	S2	S3	S4	S5	S6	S7	S8	S9
S1	772	0	0	0	226	0	0	0	0
S2	0	992	0	8	0	0	0	0	0
S3	0	0	999	0	0	0	0	1	0
S4	0	11	0	989	0	0	0	0	0
S5	302	0	0	0	696	0	0	0	2
S6	3	0	0	0	5	986	6	0	0
S7	0	0	0	0	0	3	997	0	0
S8	0	0	0	0	0	0	0	1000	0
S9	0	0	0	0	0	0	0	0	1000

Como visto na fundamentação, algumas classes de distúrbios apresentam uma semelhança no comportamento do sinal ao longo do tempo, com isso, é possível notar alguns erros de classificação ocasionados por essa similaridade, podendo citar a confusão presente entre sinais afetados pelo distúrbio do tipo Afundamento de Tensão (S2) e Interrupção (S4). Essa confusão ocorre devido ao fato de ambos os distúrbios ocasionarem uma atenuação na amplitude do sinal de tensão. De tal forma que, os atributos extraídos após a aplicação da decomposição VMD dos sinais que apresentam tais distúrbios podem ficar em uma faixa de valores similares entre si, o

Tabela 3 – Matriz de confusão BD03 ruído SNR de 40 dB.

	S1	S2	S3	S4	S5	S6	S7	S8	S9
S1	953	0	0	0	47	0	0	0	0
S2	0	989	0	10	1	0	0	0	0
S3	0	0	998	0	0	0	0	2	0
S4	0	12	0	988	0	0	0	0	0
S5	120	0	0	0	879	1	0	0	0
S6	0	0	0	0	2	992	3	0	0
S7	0	0	0	0	0	0	1000	0	0
S8	0	0	0	0	0	0	0	1000	0
S9	0	0	0	0	3	0	0	0	997

Tabela 4 – Matriz de confusão BD04 ruído SNR de 50 dB.

	S1	S2	S3	S4	S5	S6	S7	S8	S9
S1	997	0	0	0	3	0	0	0	0
S2	0	994	0	5	1	0	0	0	0
S3	0	0	999	0	0	0	0	1	0
S4	0	16	0	984	0	0	0	0	0
S5	17	0	0	0	983	1	0	0	0
S6	1	0	0	0	3	996	2	0	0
S7	0	0	0	0	0	4	996	0	0
S8	0	0	0	0	0	0	0	1000	0
S9	0	0	0	0	0	0	0	0	1000

que os tornam mais difíceis de serem linearmente separáveis. Para as classes sinal senoidal (S1) e transitório impulsivo (S5) quando submetido a ruído a característica impulsiva do distúrbio dificulta a detecção, uma vez que, em alguns casos, essa amplitude é pequena. Desta forma essas classes ficam semelhantes justificando o erro do classificador.

A Tabela 5 exibe os valores obtidos da acurácia de classificação do método proposto, para diferentes tipos de sinais simulados com a presença de DQEE. Os melhores resultados apresentaram acurácia de 99,7% para a base sem ruído, e 99,4% para ruído de 50dB. A acurácia na classificação reduziu conforme o nível de ruído aumentou, entretanto, ainda acima de 93% para SNR de 30 dB. Isso se deve à relação da equação de atualização da IMFs com o filtro de Wiener, em consequência afeta os atributos de tal forma que o comportamento aleatório do ruído, interfere na qualidade da representação destes sinais e dificulta a classificação.

Em comparação com o trabalho de Abdoos, Mianaei e Ghadikolaei, (2016) a pesquisa desenvolvida apresentou uma pequena melhoria em relação a acurácia da classificação das bases sem ruído e com relação sinal-ruído de 50 dB e um resultado

**Tabela 5 – Acurácia da classificação .**

Trabalho	BD01	BD02	BD03	BD04
Metodo proposto	<b>99,7% ± 0,3%</b>	<b>93,5% ± 0,6%</b>	<b>97,7% ± 0,5%</b>	<b>99,4% ± 0,3%</b>
Abdoos et all 2016	<b>99,6%</b>	<b>99%</b>	<b>99%</b>	<b>99,3%</b>

inferior para as bases com relação sinal-ruído de 30 db e 40db. Entretanto, a pesquisa desenvolvida utilizou um menor número de características e um número maior de distúrbios que os utilizados no trabalho de Abdoos.

## 6. CONSIDERAÇÕES FINAIS

A utilização de medidas que possam mitigar a ocorrência de distúrbios da qualidade da energia elétrica depende de um contínuo monitoramento da rede e de uma análise computacional, capaz de identificar e classificar tais distúrbios de forma automática. Este trabalho aborda esta temática e destaca a metodologia de decomposição variacional de modos.

Os resultados da pesquisa, revelaram que a metodologia proposta é eficaz para a detecção de vários sinais de DQGE e possui elevada acurácia de classificação. A robustez e precisão do método proposto é verificada com diferentes valores de relação sinal/ruído (SNR) apresentando acurácia de 99,7% para melhor caso e 93,5% para pior caso com relação sinal-ruído de 30db. Os resultados obtidos desta pesquisa deram subsídios para as duas publicações em congressos da área (SANTOS et al., 2022a) (SANTOS et al., 2022b).

Para trabalhos futuros e continuação da pesquisa, sugere-se a implementação de outro classificador em cascata voltado às classes que apresentam uma maior confusão na classificação a fim de melhorar a acurácia e reduzir o número de falsos positivos. A praticidade e eficiência propiciam a aplicação à tecnologia de monitoramento em tempo real. Recomenda-se implementação do algoritmo por meio de sistemas que possam executar aplicações, para detectar efetivamente distúrbios de qualidade de energia em aplicações de tempo real.

## REFERÊNCIAS

- ABDOOS, A. A.; MIANAIEI, P. K.; GHADIKOLAEI, M. R. Combined vmd-svm based feature selection method for classification of power quality events. **Applied Soft Computing**, Elsevier, v. 38, p. 637–646, 2016.
- ACHLERKAR, P. D.; SAMANTARAY, S. R.; MANIKANDAN, M. S. Variational mode decomposition and decision tree based detection and classification of power quality disturbances in grid-connected distributed generation system. **IEEE Transactions on Smart Grid**, v. 9, n. 4, p. 3122–3132, 2018.
- AFRONI, M. J.; SUTANTO, D. The hilbert huang transform for decomposition of power quality waveforms. In: IEEE. **2014 Australasian Universities Power Engineering Conference (AUPEC)**. [S.l.], 2014. p. 1–6.
- ANEEL. Módulo 8 – qualidade da energia elétrica. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST**, p. 1–69, 2021.
- ANEESH, C. et al. Performance comparison of variational mode decomposition over empirical wavelet transform for the classification of power quality disturbances using support vector machine. **Procedia Computer Science**, Elsevier, v. 46, p. 372–380, 2015.
- BOLLEN, M. Ieee industry applications society, ieee power electronics society, and ieee power engineering society. **Understanding power quality problems: voltage sags and interruptions**, 1999.
- BREIMAN, L. Bagging predictors. **Machine learning**, Springer, v. 24, p. 123–140, 1996.
- BREIMAN, L. Random forests. **Machine learning**, Springer, v. 45, n. 1, p. 5–32, 2001.
- CAI, K. et al. Hybrid approach for detecting and classifying power quality disturbances based on the variational mode decomposition and deep stochastic configuration network. **Energies**, MDPI, v. 11, n. 11, p. 3040, 2018.
- CHAKRAVORTI, T.; DASH, P. K. Multiclass power quality events classification using variational mode decomposition with fast reduced kernel extreme learning machine-based feature selection. **IET Science, Measurement & Technology**, Wiley Online Library, v. 12, n. 1, p. 106–117, 2018.
- DECKMANN, S. M.; POMILIO, J. A. Avaliação da qualidade da energia elétrica. **available in <http://www.dsce.fee.unicamp.br/antenor/pdf/qualidade/b5.pdf>**, 2017.
- DENG, W. et al. Detection and classification of power quality disturbances using variational mode decomposition and convolutional neural networks. In: IEEE. **2021 IEEE 11th Annual Computing and Communication Workshop and Conference (CCWC)**. [S.l.], 2021. p. 1514–1518.
- DIAS, d. M. M. J. A. A. Eletricidade básica para cursos técnicos. editora IFPB, 2019.

- DUGAN, R. C.; MCGRANAGHAN, M. F.; BEATY, H. W. Electrical power systems quality. **New York**, 1996.
- ELPHICK, S. et al. Summary of the economic impacts of power quality on consumers. In: IEEE. **2015 Australasian Universities Power Engineering Conference (AUPEC)**. [S.l.], 2015. p. 1–6.
- EMPRESA DE PESQUISA ENERGÉTICA. **Anuário Estatístico de Energia Elétrica 2022 – Base 2021**. 2022. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>>, Acesso em: 2022-11-19.
- FLORES, R. **Signal processing tools for power quality event classification**. Tese (Doutorado) — Chalmers tekniska högsk., 2003.
- FUCHS, E. F.; MASOUM, M. A. Power quality in power systems and electrical machines. Elsevier, 2015.
- GAO, Y.; CHEN, R.; LI, L. Review of harmonic problems and solutions for electrical distribution systems. **IET Generation, Transmission & Distribution**, IET, v. 12, n. 17, p. 3968–3979, 2018.
- GOLUBEV, G. K. Skewness in statistics. **Review of Economics and Statistics**, JSTOR, p. 384–385, 1961.
- GUNGOR, V. C. et al. Smart grid technologies: Communication technologies and standards. **IEEE Transactions on Industrial Informatics**, IEEE, v. 9, n. 1, p. 28–42, 2013.
- HARRIS, F. J. On the use of windows for harmonic analysis with the discrete fourier transform. **Proceedings of the IEEE**, IEEE, v. 66, n. 1, p. 51–83, 1978.
- HO, T. K. Random decision forests. In: **Proceedings of 3rd International Conference on Document Analysis and Recognition**. [S.l.: s.n.], 1995. v. 1, p. 278–282 vol.1.
- HUANG, N. E. et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. **Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences**, The Royal Society, v. 454, n. 1971, p. 903–995, 1998.
- IEC. Iec 61000 e 3 e 5.: **Limitation of Voltage Fluctuations and Flicker in Low Voltage PowerSupply Systems for Equipment with Rated Current Greater than 75A.**, 2009.
- IEC. Iec 61000 e 3 e 3. **Limitation of Voltage Changes, Voltage Fluctuations and Flicker in Public Low Voltage Power Supply Systems for Equipment with Rated Current 16 A PerPhase and Not Subject to Conditional Connection.**, 2022.
- IEEE. Recommended practice for monitoring electric power quality. **IEE Std 1159-2019 (Revision of IEEE Std 1159-2009)**, p. 1–98, 2019.

- IGUAL, R. et al. Integral mathematical model of power quality disturbances. In: **2018 18th International Conference on Harmonics and Quality of Power (ICHQP)**. [S.l.: s.n.], 2018. p. 1–6.
- JENA, S. K.; RAY, P.; BABU, M. K. Assessment of power quality events by emd based hilbert transform and s-transform using different classifiers. In: IEEE. **2018 International conference on recent innovations in electrical, electronics & communication engineering (ICRIEECE)**. [S.l.], 2018. p. 354–359.
- KIM, C.-A.; KUO, C.-C. J. Music genre classification using the zero-crossing rate of a signal. **Journal of the Audio Engineering Society**, v. 51, n. 1/2, p. 26–35, 2003.
- KONSTANTIN, D.; DOMINIQUE, Z. Variational mode decomposition. **IEEE Transactions on signal Processing**, v. 62, n. 3, p. 531–544, 2014.
- KUMAR, L. A.; ALEXANDER, S. A. **Computational paradigm techniques for enhancing electric power quality**. [S.l.]: CRC Press, 2018.
- LIMA, F. P. d. A. Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica baseada em sistemas imunológicos artificiais. Universidade Estadual Paulista (UNESP), 2013.
- MEDEIROS, E. L. **Sistema flexível de aquisição de sinais de grandezas elétricas aplicado a qualidade da energia elétrica**. 114 p. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal de Campina Grande, Paraíba, 2016.
- MEENA, M. et al. Detection and classification of complex power quality disturbances using stockwell transform and rule based decision tree. In: IEEE. **2018 International Conference on Smart Electric Drives and Power System (ICSEDPS)**. [S.l.], 2018. p. 220–226.
- MORENO, S. R. Modelo híbrido de decomposição multiestágio aplicado à previsão de séries temporais de velocidades de vento.
- MURPHY, K. P. **Machine learning: a probabilistic perspective**. [S.l.]: MIT press, 2012.
- NAQA, I. E.; MURPHY, M. J. **What is machine learning?** [S.l.]: Springer, 2015.
- OLIVEIRA, T. T. d. Estudo da distorção harmônica em redes de distribuição de baixa tensão com sistemas fotovoltaicos e veículos elétricos. 2019.
- PEARSON, K. On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can be reasonably supposed to have arisen from random sampling. **Philosophical Magazine Series 6**, Taylor & Francis, v. 50, n. 302, p. 157–175, 1905.
- PENG, Z. et al. Superiorities of variational mode decomposition over empirical mode decomposition particularly in time-frequency feature extraction and wind turbine condition monitoring. **IET Renewable Power Generation**, v. 11, 05 2016.

RODRIGUEZ, M. A. et al. Classification of power quality disturbances using hilbert huang transform and a multilayer perceptron neural network model. In: **2019 International Conference on Smart Energy Systems and Technologies (SEST)**. [S.l.: s.n.], 2019. p. 1–6.

RODRIGUEZ, M. A. et al. Classification of power quality disturbances using hilbert huang transform and a multilayer perceptron neural network model. In: **2019 International Conference on Smart Energy Systems and Technologies (SEST)**. [S.l.: s.n.], 2019. p. 1–6.

RUSSELL, S.; NORVIG, P. A brief history of artificial intelligence. **ACM SIGART Bulletin**, ACM, v. 22, n. 1, p. 6–12, 2015.

SAHANI, M. et al. Dsp based online power quality events detection and classification using hilbert huang transform and random forest method. In: IEEE. **2020 International Conference on Computational Intelligence for Smart Power System and Sustainable Energy (CISPSSE)**. [S.l.], 2020. p. 1–6.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of research and development**, IBM, v. 44, n. 1.2, p. 206–226, 2000.

SANTOS, M. **Classificação de complexo QRS em Sinais Cardíacos empregando abordagens baseadas na Decomposição Empírica de Modo**. Dissertação (Mestrado), 2020.

SANTOS, M. L. et al. Aplicação da decomposição variacional de modos na avaliação da presença de distúrbios da qualidade da energia elétrica. XL Simpósio Brasileiro de Telecomunicações e Processamento de Sinais., 2022.

SANTOS, M. L. F. et al. Análise de distúrbios da qualidade da energia elétrica empregando a decomposição variacional de modos. XXIV Congresso Brasileiro de Automática., 2022.

SARICA, A.; CERASA, A.; QUATTRONE, A. Random forest algorithm for the classification of neuroimaging data in alzheimer's disease: a systematic review. **Frontiers in aging neuroscience**, Frontiers Media SA, v. 9, p. 329, 2017.

SCHREIBER JACQUES NELSON CORLETA; BESKOW, A. L. M. J. C. T. N. E. O. B. S. J. I. D. R. J. W. Técnicas de validação de dados para sistemas inteligentes: Uma abordagem do software sdbayes. In: **XVII Colóquio Internacional de Gestão Universitária**. FLORIANÓPOLIS, SC: [s.n.], 2017.

SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. **Information Processing & Management**, Elsevier, v. 45, n. 4, p. 427–437, 2009.

SONG, Y. et al. Notch filtering method for gnss receivers in urban canyons. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 19, n. 7, p. 1589, 2019.

VIDHYA, A. **Bagging: 25 Questions to Test Your Skills on Random Forest Algorithm**. 2021. Disponível em: <<https://www.analyticsvidhya.com/blog/2021/05/bagging-25-questions-to-test-your-skills-on-random-forest-algorithm/>>.



WANG, Y. et al. Complex variational mode decomposition for signal processing applications. **Mechanical systems and signal processing**, Elsevier, v. 86, p. 75–85, 2017.

XU, Y. et al. Detection and classification of power quality disturbances in distribution networks based on vmd and dfa. **CSEE Journal of Power and Energy Systems**, CSEE, v. 6, n. 1, p. 122–130, 2019.

ZHANG, X.-P.; YAN, Z. Energy quality: A definition. **IEEE Open Access Journal of Power and Energy**, v. 7, p. 430–440, 01 2020.