



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CAMPUS SOBRAL**  
**CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**MARCELO ESTEVÃO DA SILVA**

**MODELAGEM E CLASSIFICAÇÃO DE DISTÚRBIOS DE QUALIDADE DE ENERGIA  
EM SISTEMA DE DISTRIBUIÇÃO COM GERAÇÃO DISTRIBUÍDA**

**SOBRAL**

**2023**

MARCELO ESTEVÃO DA SILVA

MODELAGEM E CLASSIFICAÇÃO DE DISTÚRBIOS DE QUALIDADE DE ENERGIA EM  
SISTEMA DE DISTRIBUIÇÃO COM GERAÇÃO DISTRIBUÍDA

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

Orientador: Prof. Dr. Márcio André Baima Amora

Coorientador: Me. Joaquim Osterwald Frota Moura Filho

SOBRAL

2023

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

D11m da Silva, Marcelo Estevão.  
Modelagem e Classificação de Distúrbios de Qualidade de Energia em Sistema de Distribuição com Geração Distribuída / Marcelo Estevão da Silva. – 2023.  
92 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Sobral, Curso de Engenharia Elétrica, Sobral, 2023.  
Orientação: Prof. Dr. Márcio André Baima Amora.  
Coorientação: Prof. Me. Joaquim Osterwald Frota Moura Filho.

1. Aprendizado de máquina. 2. Extração de características. 3. Distribuição de energia. 4. Geração distribuída. 5. Qualidade de energia. I. Título.

CDD 621.3

---

MARCELO ESTEVÃO DA SILVA

MODELAGEM E CLASSIFICAÇÃO DE DISTÚRBIOS DE QUALIDADE DE ENERGIA EM  
SISTEMA DE DISTRIBUIÇÃO COM GERAÇÃO DISTRIBUÍDA

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

Aprovada em: 13/07/2023

BANCA EXAMINADORA

---

Prof. Dr. Márcio André Baima Amora (Orientador)  
Universidade Federal do Ceará (UFC)

---

Me. Joaquim Osterwald Frota Moura  
Filho (Coorientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Adson Bezerra Moreira  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Iális Cavalcante de Paula Júnior  
Universidade Federal do Ceará (UFC)

Dedico este trabalho aos meus pais e minhas irmãs.

## AGRADECIMENTOS

A Deus, pela vida e pela minha família.

À minha mãe, Creuza Maria Estevão, pelo cuidado, carinho e pela exemplar educação, responsável pelo carácter e pelos valores que tenho.

Ao meu pai, Amadeu Sales da Silva, pelo cuidado e proteção nas ocasiões em que lhe foi possível.

À minha irmã, Maria de Lourdes Estevão da Silva, pelo cuidado e educação ao longo da minha vida e pela inspiração em seguir carreira na área de exatas.

À minha irmã, Simone Estevão da Silva, pelo incondicional apoio e incentivo desde sempre.

À minha família, por ser meu alicerce e por dar a mim todos os recursos necessários ao meu desenvolvimento pessoal e profissional.

Ao coorientador Joaquim Moura pelo apoio, incentivo e motivação durante a construção deste trabalho.

Ao professor Dr. Márcio Amora pela excepcional orientação durante a elaboração deste trabalho e pela condução dos projetos de pesquisa em que fiz parte.

Aos meus amigos de graduação, Joan Kennedy, Edenio Galvão, Pedro Ximenes, Wellington Filho, Roniel Mesquita, Carlos Daniel, Eli Marques, Tiago Melo, Ruthiany Souza, Bruna Letícia, Alexandre Holanda, Vitor Manoel, William Migge, Emerson Nunes, Felipe Sales, Paulo Louzada, Lucas Eduardo e Matheus Renan, pelos momentos de dificuldade e alegria que passamos juntos. Agradecer também pela amizade de Matheus de Souza García, que hoje descansa na vida eterna.

Às companhias Votorantim Cimentos e B&Q Energia pelo valioso aprendizado e investimento na minha formação profissional.

À Universidade Federal do Ceará com seus professores e servidores, que forneceram a mim o ensino da engenharia em alto nível, do qual tenho muito orgulho.

“Na adversidade, uns desistem, enquanto outros batem recordes. Com sua força de vontade, sua determinação, seu instinto e a sua experiência também, você pode voar muito alto.”

**(Ayrton Senna da Silva (1960-1994))**

*Tricampeão Mundial de Fórmula 1*

*(1988, 1990, 1991)*

## RESUMO

A crescente demanda energética associada ao aumento de cargas não lineares no Sistema Elétrico de Potência e a geração distribuída têm aumentado a incidência de distúrbios de Qualidade de Energia nos últimos anos. Esses problemas comprometem o funcionamento dos equipamentos e até mesmo da segurança dos consumidores. Isto posto, identificar tais eventos na rede para isolar sua origem é uma importante e necessária tarefa para a operação correta do sistema elétrico. Desta forma, diversas técnicas de classificação foram propostas na literatura, com destaque às técnicas baseadas em Aprendizado de Máquina, que oferecem grande capacidade de generalização e acurácia. Portanto, o presente trabalho propõe a classificação de quatro principais distúrbios de qualidade de energia, sendo eles, queda de tensão, distorção harmônica, transiente impulsivo e transiente oscilatório. Para tal, compara-se o desempenho dos algoritmos de Árvore de Decisão e *Light Gradient Boosting*, associados à extração de característica pelo método da Análise Multiresolução de *Wavelet*, que possui a vantagem de extrair características tanto no domínio do tempo como da frequência. Os sinais coletados foram extraídos via simulação do Alimentador IEEE de 13 Barras com adição de um sistema de geração solar fotovoltaico para acrescentar a característica de geração distribuída à rede. Os sinais são coletados em duas barras estrategicamente escolhidas a fim de se observar a propagação do distúrbio ao longo da rede. Os resultados obtidos foram satisfatórios, com superior desempenho do algoritmo de *Light Gradient Boosting* em todas as barras, com acurácia superior a 98% para a barra mais próxima, provando a grande aplicabilidade desta técnica na classificação destes distúrbios.

**Palavras-chave:** Aprendizado de máquina. Extração de características. Distribuição de energia. Geração distribuída. Qualidade de energia.



## ABSTRACT

The growing energy demand associated with the increase of non-linear loads in the Electric Power System and distributed generation have increased the incidence of Power Quality disturbances in recent years. These problems compromise the functioning of the equipment and even the safety of consumers. That said, identifying such events in the network to isolate their origin is an important and necessary task for the correct operation of the electrical system. In this way, several classification techniques have been proposed in the literature, with emphasis on techniques based on Machine Learning, which offer great generalization capacity and accuracy. Therefore, this work proposes the classification of four main power quality disturbances, namely, voltage drop, harmonic distortion, impulsive transient and oscillatory transient. To this end, the performance of the Decision Tree and Light Gradient Boosting algorithms, associated with feature extraction by the Multiresolution Analysis method of Wavelet, is compared, which has the advantage of extracting features both in the domain of time and frequency. The collected signals were extracted via simulation of the IEEE 13 Bus Feeder with addition of a photovoltaic solar generation system to add the characteristic of distributed generation to the grid. The signals are collected in two strategically chosen buses in order to observe the propagation of the disturbance along the network. The results obtained were satisfactory, with superior performance of the Light Gradient Boosting algorithm in all bars, with an accuracy greater than 98% for the closest bar, proving the great applicability of this technique in the classification of these disturbances.

**Keywords:** Machine learning. Feature extraction. Energy distribution. Distributed generation. Power quality.

## LISTA DE FIGURAS

Figura 1 – Alimentador IEEE de 13 Barras (Original) . . . . .	29
Figura 2 – Alimentador IEEE de 13 Barras (Modificado) . . . . .	30
Figura 3 – Alimentador IEEE de 13 barras com geração distribuída . . . . .	31
Figura 4 – Modelo de linha $\pi$ -equivalente. . . . .	31
Figura 5 – Espaçamentos em linhas aéreas (em metros) . . . . .	33
Figura 6 – Condutor CAA . . . . .	33
Figura 7 – Espaçamentos em linhas subterrâneas (cm) . . . . .	35
Figura 8 – Condutor CA CN . . . . .	35
Figura 9 – Condutor CA TS . . . . .	35
Figura 10 – Transformador de distribuição de 500kVA . . . . .	36
Figura 11 – Capacitores de distribuição . . . . .	37
Figura 12 – Barramento CC . . . . .	41
Figura 13 – Inversor centralizado . . . . .	42
Figura 14 – Inversor centralizado simulado . . . . .	42
Figura 15 – Cuva I-V (25 °C) . . . . .	45
Figura 16 – Cuva P-V (25 °C) . . . . .	46
Figura 17 – Diagrama de blocos do controle do inversor . . . . .	46
Figura 18 – Algoritmo <i>Maximum Power Point Tracking</i> (MPPT) com P&O . . . . .	47
Figura 19 – Modelagem da Falta . . . . .	49
Figura 20 – Queda de Tensão . . . . .	50
Figura 21 – Modelagem da Distorção Harmônica . . . . .	51
Figura 22 – Distorção Harmônica . . . . .	52
Figura 23 – Transiente Impulsivo . . . . .	53
Figura 24 – Modelagem do Transiente Impulsivo . . . . .	53
Figura 25 – Transiente Oscilatório . . . . .	54
Figura 26 – Etapas da metodologia . . . . .	56
Figura 27 – Etapa 1: Geração dos distúrbios via simulação . . . . .	57
Figura 28 – Etapa 2: Extração de características . . . . .	57
Figura 29 – Etapa 3: Classificação dos distúrbios . . . . .	58
Figura 30 – Validação com <i>Random Search</i> . . . . .	59
Figura 31 – Processo de Janelamento . . . . .	59

Figura 32 – Conjunto de dados . . . . .	61
Figura 33 – Decomposição de Wavelet . . . . .	64
Figura 34 – Análise Multiresolução de Wavelet para uma senoide . . . . .	64
Figura 35 – Modelo de Árvore de Decisão . . . . .	67
Figura 36 – Modelo de LightLGBM . . . . .	68
Figura 37 – Exemplo de Matriz de Confusão . . . . .	69
Figura 38 – Queda de Tensão (Barra 634) . . . . .	72
Figura 39 – Queda de Tensão RMS (Barra 634) . . . . .	73
Figura 40 – Queda de Tensão (Barra 671) . . . . .	73
Figura 41 – Queda de Tensão RMS (Barra 671) . . . . .	74
Figura 42 – Distorção Harmônica (634) . . . . .	74
Figura 43 – Distorção Harmônica FFT (634) . . . . .	75
Figura 44 – Distorção Harmônica (671) . . . . .	75
Figura 45 – Distorção Harmônica FFT (Barra 671) . . . . .	76
Figura 46 – Transiente Impulsivo (Barra 634) . . . . .	76
Figura 47 – Transiente Impulsivo (Barra 671) . . . . .	77
Figura 48 – Impulso de tensão . . . . .	77
Figura 49 – Transiente Oscilatório (Barra 634) . . . . .	78
Figura 50 – Transiente Oscilatório FFT (Barra 634) . . . . .	78
Figura 51 – Transiente Oscilatório (Barra 671) . . . . .	79
Figura 52 – Transiente Oscilatório FFT (Barra 671) . . . . .	79
Figura 53 – Acurácia por fold da validação cruzada (Árvore de Decisão (AD)) . . . . .	80
Figura 54 – Acurácia por fold da validação cruzada ( <i>Light Gradient Boosting</i> (LGBM)) . . . . .	82

## LISTA DE TABELAS

Tabela 1 – Principais normas de QEE . . . . .	20
Tabela 2 – Configuração de linhas aéreas . . . . .	32
Tabela 3 – Espaçamentos de linhas aéreas . . . . .	33
Tabela 4 – Segmentos de linhas aéreas . . . . .	34
Tabela 5 – Configuração de linhas subterrâneas . . . . .	34
Tabela 6 – Espaçamentos de linhas subterrâneas . . . . .	34
Tabela 7 – Segmentos de linhas subterrâneas . . . . .	35
Tabela 8 – Configuração dos transformadores . . . . .	36
Tabela 9 – Configuração dos capacitores . . . . .	37
Tabela 10 – Cargas concentradas . . . . .	37
Tabela 11 – Cargas concentradas por barra . . . . .	38
Tabela 12 – Cargas distribuídas . . . . .	38
Tabela 13 – Distúrbios simulados . . . . .	48
Tabela 14 – Categoria dos distúrbios segundo o <i>Institute of Electrical and Electronics Engineers (IEEE)</i> . . . . .	48
Tabela 15 – Parâmetros da falta de linha . . . . .	50
Tabela 16 – Parâmetros para Distorção Harmônica . . . . .	51
Tabela 17 – Parâmetros para Transiente Impulsivo . . . . .	53
Tabela 18 – Parâmetros para Transiente Oscilatório . . . . .	55
Tabela 19 – Sinais temporais . . . . .	60
Tabela 20 – Sinais após janelamento . . . . .	60
Tabela 21 – Conjunto de dados após balanceamento . . . . .	61
Tabela 22 – Principais hiperparâmetros para AD . . . . .	66
Tabela 23 – Principais Hiperparâmetros para LGBM . . . . .	68
Tabela 24 – Hiperparâmetros para AD . . . . .	79
Tabela 25 – Desempenho da AD . . . . .	81
Tabela 26 – Matriz de confusão para AD . . . . .	81
Tabela 27 – Hiperparâmetros para LGBM . . . . .	82
Tabela 28 – Desempenho da LGBM . . . . .	83
Tabela 29 – Matriz de confusão para LGBM . . . . .	84
Tabela 30 – Comparação de resultados . . . . .	84

## LISTA DE ABREVIATURAS E SIGLAS

AD	Árvore de Decisão
AMI	<i>Automatic Metering Infrastructure</i>
AMR	Análise Multiresolução
CA	Condutor de Alumínio
CAA	Condutor de Alumínio com Alma de Aço
CACFE	Classificação Automática da Causa Fundamental de Eventos
CC	Corrente Contínua
EPR	Borracha Etileno-Propileno
FFML	<i>Feed Forward Multilayer Network</i>
FP	Fator de Potência
GD	Geração Distribuída
GRNN	<i>Generalized Regressive Neural Network</i>
HSP	Horas de Sol Pleno
ICA	Inteligência Computacional Aplicada
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
LGBM	<i>Light Gradient Boosting</i>
LROE	Localização Relativa da Origem do Evento
LVQ	<i>Learning Vector Quantization</i>
MIT	Motor de Indução Trifásico
ML	<i>Machine Learning</i>
MPP	<i>Maximum Power Point</i>
MPPT	<i>Maximum Power Point Tracking</i>
OIE	Oferta Interna de Energia
PAC	Ponto de Acoplamento Comum
PNN	<i>Probabilistic Neural Network</i>
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
PVC	Policloreto de Vinila
PWM	<i>Pulse Width Modulation</i>
QEE	Qualidade de Energia Elétrica
RBFNN	<i>Radial Basis Function Neural Network</i>
RMS	<i>Root Mean Square</i>

SEP	Sistema Elétrico de Potência
SFCR	Sistema Fotovoltaico Conectado à Rede
SG	<i>Smart Grid</i>
SGWT	<i>Second-Generation Wavelet Transform</i>
SM	<i>Smart Meter</i>
STFT	<i>Short-Time Fourier Transform</i>
TF	Transformada de Fourier
TW	Transformada de <i>Wavelet</i>
TWC	Transformada de <i>Wavelet</i> Contínua
TWD	Transformada de <i>Wavelet</i> Discreta
VTCD	Variação de Tensão de Curta Duração

## LISTA DE SÍMBOLOS

$I$	Corrente elétrica
$N$	Condutor de neutro
$P$	Potência
$R$	Resistência
$V$	Tensão
$Z$	Impedância
$X$	Reatância
$Y$	Admitância
$B$	Susceptância
$S$	Siemens
$\Omega$	Ohm
$W$	Watt
$W_p$	Watt-pico
$C$	Capacitância
$\eta$	Rendimento
$F$	Fahrenheit
$C$	Grau Celsius
$\alpha$	Fator de amortecimento
$t$	Tempo
$p$	Fator de normalização
$\psi$	Família de funções <i>Wavelets</i>
$R^n$	Espaço euclidiano
$a$	Fator de escala para Transformada de <i>Wavelet</i> contínua
$b$	Fator de translação para Transformada de <i>Wavelet</i> contínua
$cA$	Componente de aproximação da Transformada de <i>Wavelet</i>
$cD$	Componente de detalhe da Transformada de <i>Wavelet</i>

$x$	Variável de tempo ou espaço
$\ $	Módulo de função
$m$	Parâmetro de escala para Transformada de <i>Wavelet</i> discreta
$n$	Parâmetro de translação para Transformada de <i>Wavelet</i> discreta
$L1$	Parâmetro de normalização no hiperparâmetro <i>reg_alpha</i> de <i>Light Gradient Boosting</i>
$L2$	Parâmetro de normalização no hiperparâmetro <i>reg_lambda</i> de <i>Light Gradient Boosting</i>
$Q_m$	Conjunto de dados em divisão de nó de Árvore de Decisão
$d$	Coefficientes de expansão em funções <i>Wavelets</i>
$j$	Fator de escala relacionado a Análise Multiresolução
$k$	Fator de translação relacionado a Análise Multiresolução
$A$	Amplitude do transiente impulsivo
$e$	Constante de Euler
$u$	Função degrau
$\phi$	Fase elétrica
$Q_C$	Potência reativa
$P_C$	Potência ativa
$R_{choke}$	Resistência de impacto do filtro harmônico
$L_{choke}$	Indutância de impacto do filtro harmônico
$pu$	Por unidade
$V_{CC}$	Tensão em corrente contínua
$P_{nom}$	Potência nominal
$F_{nom}$	Frequência nominal
$P_{Wp}$	Potência em Watt-pico
$\Delta$	Intervalo entre valores



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>19</b>
<b>1.1</b>	<b>Considerações gerais</b>	<b>19</b>
<b>1.2</b>	<b>Motivação e justificativa</b>	<b>20</b>
<b>1.3</b>	<b>Objetivos</b>	<b>20</b>
<b>1.3.1</b>	<i>Objetivos específicos</i>	<b>21</b>
<b>1.4</b>	<b>Lista de publicações</b>	<b>21</b>
<b>1.5</b>	<b>Estrutura do trabalho</b>	<b>22</b>
<b>2</b>	<b>ESTADO DA ARTE</b>	<b>23</b>
<b>2.1</b>	<b>Classificação de distúrbios de QEE usando técnicas de <i>Machine Learning</i> com equações paramétricas</b>	<b>23</b>
<b>2.2</b>	<b>Aquisição de dados via simulação de rede</b>	<b>25</b>
<b>2.3</b>	<b>Smart Grid e Smart Meter</b>	<b>27</b>
<b>2.4</b>	<b>Considerações do capítulo</b>	<b>28</b>
<b>3</b>	<b>MODELAGEM DO ALIMENTADOR IEEE DE 13 BARRAS</b>	<b>29</b>
<b>3.1</b>	<b>Alimentador IEEE de 13 barras</b>	<b>29</b>
<b>3.1.1</b>	<i>Segmentos de linhas</i>	<b>30</b>
<b>3.1.1.1</b>	<i>Linhas aéreas</i>	<b>32</b>
<b>3.1.1.2</b>	<i>Linhas subterrâneas</i>	<b>34</b>
<b>3.1.2</b>	<i>Transformadores</i>	<b>36</b>
<b>3.1.3</b>	<i>Capacitores</i>	<b>36</b>
<b>3.1.4</b>	<i>Cargas</i>	<b>37</b>
<b>3.2</b>	<b>Considerações do capítulo</b>	<b>38</b>
<b>4</b>	<b>MODELAGEM DO SISTEMA DE GERAÇÃO FOTOVOLTAICO</b>	<b>39</b>
<b>4.1</b>	<b>Painéis fotovoltaicos</b>	<b>39</b>
<b>4.2</b>	<b>Barramento CC</b>	<b>40</b>
<b>4.3</b>	<b>Inversor fotovoltaico</b>	<b>41</b>
<b>4.3.1</b>	<i>Conversor NPC</i>	<b>43</b>
<b>4.3.2</b>	<i>Filtro harmônico</i>	<b>43</b>
<b>4.3.3</b>	<i>Transformador</i>	<b>44</b>
<b>4.4</b>	<b>Controlador do inversor</b>	<b>45</b>

4.5	Considerações do capítulo . . . . .	47
5	<b>MODELAGEM DOS DISTÚRBIOS DE QEE . . . . .</b>	48
5.1	Queda de Tensão . . . . .	49
5.1.1	<i>Falta de linha . . . . .</i>	49
5.2	Distorção Harmônica . . . . .	50
5.2.1	<i>Ponte retificadora monofásica com capacitor de filtro . . . . .</i>	50
5.3	Transiente Impulsivo . . . . .	51
5.3.1	<i>Descarga atmosférica . . . . .</i>	51
5.4	Transiente Oscilatório . . . . .	54
5.4.1	<i>Energização de banco de capacitores . . . . .</i>	54
5.5	Considerações do capítulo . . . . .	55
6	<b>CLASSIFICAÇÃO DOS DISTÚRBIOS DE QEE . . . . .</b>	56
6.1	Metodologia proposta . . . . .	56
6.1.1	<i>Janelamento . . . . .</i>	58
6.2	Conjunto de dados . . . . .	60
6.3	Extração de características . . . . .	61
6.3.1	<i>Transformada de Wavelet . . . . .</i>	61
6.3.2	<i>Análise Multiresolução de Wavelet . . . . .</i>	63
6.4	Técnicas de Machine Learning . . . . .	64
6.4.1	<i>Árvore de Decisão . . . . .</i>	65
6.4.2	<i>Light Gradient Boosting . . . . .</i>	67
6.5	Métricas de avaliação . . . . .	68
6.5.1	<i>Matriz de Confusão . . . . .</i>	69
6.5.2	<i>Acurácia . . . . .</i>	69
6.5.3	<i>Precisão . . . . .</i>	70
6.5.4	<i>Sensibilidade . . . . .</i>	70
6.5.5	<i>Medida-F . . . . .</i>	70
6.6	Considerações do capítulo . . . . .	71
7	<b>RESULTADOS . . . . .</b>	72
7.1	Resultados para Simulação dos Distúrbios . . . . .	72
7.1.1	<i>Queda de Tensão . . . . .</i>	72
7.1.2	<i>Distorção Harmônica . . . . .</i>	74

7.1.3	<i>Transiente Impulsivo</i> . . . . .	76
7.1.4	<i>Transiente Oscilatório</i> . . . . .	77
7.2	<b>Resultados para AD</b> . . . . .	79
7.2.1	<i>Treinamento e validação</i> . . . . .	79
7.2.2	<i>Teste</i> . . . . .	80
7.3	<b>Resultados para LGBM</b> . . . . .	82
7.3.1	<i>Treinamento e validação</i> . . . . .	82
7.3.2	<i>Teste</i> . . . . .	83
7.4	<b>Comparação de resultados</b> . . . . .	83
7.5	<b>Considerações do capítulo</b> . . . . .	85
8	<b>CONCLUSÕES E TRABALHOS FUTUROS</b> . . . . .	86
	<b>REFERÊNCIAS</b> . . . . .	87

# 1 INTRODUÇÃO

## 1.1 Considerações gerais

Os distúrbios de Qualidade de Energia Elétrica (QEE) são definidos como os desvios da tensão, corrente ou frequência dos seus respectivos valores nominais (MEENA *et al.*, 2018). Esses distúrbios constituem eventos eletromagnéticos no sistema elétrico que comprometem a operação normal das cargas que estão a ele conectados.

Esforços recentes dedicaram-se aos distúrbios de QEE devido ao crescente uso de equipamentos eletrônicos sensíveis aos fenômenos eletromagnéticos decorrentes desses eventos, aumento de cargas não lineares, rigidez na regulamentação do setor elétrico e maior diversificação das fontes de energia renováveis, no contexto da Geração Distribuída (GD), com destaque às fontes eólica e solar (SHEN *et al.*, 2019).

A GD baseada em fontes de energias renováveis em redes de distribuição tradicionais têm se tornado uma preocupação, pois usam dispositivos de eletrônica de potência para controle, cargas não lineares significativas, além de ferramentas que empregam microprocessadores e computadores (SHEN *et al.*, 2019). A combinação desses elementos representa não só maior sensibilidade aos distúrbios de QEE como também provocam tais fenômenos na rede.

A ênfase das fontes eólica e solar no contexto da GD se justifica pela sua relevância no panorama da composição da oferta de energia. No contexto da Oferta Interna de Energia (OIE) do Brasil, por exemplo, a energia solar representou aumentos de 71,1% no período de 2019 a 2020 e 32,4% no período de 2020 a 2021. Já a energia solar obteve crescimentos de 29,1% e 26,7% para os mesmos períodos (EPE, 2021). Existe uma relação direta entre o incremento de tais fontes nos sistemas de distribuição e o aumento dos distúrbios de QEE. Isto posto, o presente trabalho se dedica a abordagem da geração solar distribuída, onde tal escolha se justifica pela sua grande capilaridade, modularidade e crescimento nos últimos anos.

Visando o monitoramento, medição e análise destes eventos, existem duas principais normas aplicáveis, a saber: a norma IEEE Std 1159-2019 (IEEE 1159, 2019) de abrangência internacional e o PRODIST Módulo 8 (ANEEL, 2021) de abrangência nacional. Além destas, aplicam-se a este contexto as normas listadas na Tabela 1, que contém as principais normas de QEE no contexto da caracterização, medição, análise e mitigação dos eventos causadores de distúrbios de QEE e seus efeitos, que são aplicáveis às concessionárias de energia, às indústrias e instalações elétricas em geral.

Tabela 1 – Principais normas de QEE

Organizador	Norma	Descrição
IEEE	519-2014	Controle de harmônicos de QEE
IEEE	1159-1995	Monitoramento de distúrbios de QEE
IEEE	1100-1999	Alimentação e aterramento de equipamentos sensíveis
IEEE	1250-1995	Manutenção de equipamentos sensíveis a distúrbios transitórios de tensão
IEEE	1366-2012	Índices para concessionárias de energia elétrica
IEC	P1547	Interconexão de GD/ER em redes de distribuição
IEC	61000-2-2	Distúrbios de baixa frequência em redes de distribuição
IEC	61000-2-4	Distúrbios de baixa frequência em indústrias
IEC	61000-4-7	Distorções não lineares em redes de distribuição
IEC	61000-4-15	Medição de oscilações de tensão
IEC	61000-4-30	Precisão mínima em medições de diferentes parâmetros elétricos
EN	50160-1999	Características de tensão em redes de distribuição

Fonte: Schneider *et al.* (2017), Watitwa (2022).

## 1.2 Motivação e justificativa

A transição energética das fontes de geração tradicionais para as fontes renováveis tem agravado os problemas associados à qualidade de energia. Desta forma, torna-se ainda mais necessária a análise de metodologias que acompanhem a dinâmica das redes e considerem as mudanças nela aplicadas. Entre essas mudanças temos a inserção da geração distribuída, que representa a maior mudança no cenário da qualidade de energia, por necessitar em sua maioria de grandes conversores de potência, que por sua vez podem comprometer a qualidade da energia fornecida (KAISER, 2004).

Portanto, o presente trabalho se justifica na necessidade de novas metodologias que considerem as fontes de geração distribuída, principalmente a solar fotovoltaica, devido a sua grande capilaridade e rápido crescimento (MOHAMED S.R.; JEYANTHY, 2019), no contexto das redes de distribuição.

## 1.3 Objetivos

Considerando as diversas metodologias existentes no campo de qualidade de energia para classificação de distúrbios, este trabalho tem por objetivo apresentar uma metodologia baseada na simulação de uma rede de distribuição real para aquisição de dados, ao mesmo tempo que acrescenta características da geração distribuída, empregando na classificação dois modelos de Aprendizado de Máquina.

### 1.3.1 *Objetivos específicos*

- Modelar um sistema de distribuição de energia com geração fotovoltaica a fim de simular e adquirir sinais de distúrbios de qualidade de energia;
- Testar o desempenho da técnica de Análise Multiresolução de *Wavelet* na extração de características desses distúrbios;
- Comparar o desempenho dos algoritmos *Árvore de Decisão* e *Light Gradient Boosting* na classificação destes distúrbios.

## 1.4 Lista de publicações

Durante a graduação foram elaborados diversos trabalhos de aplicações de Inteligência Computacional Aplicada (ICA) à Engenharia Elétrica que, assim como o presente trabalho, comprovam a promissora aplicabilidade das técnicas de Aprendizado de Máquinas nas mais diversas áreas da engenharia. A seguir estão listados os quatro trabalhos desenvolvidos, em ordem cronológica decrescente, que resultaram em artigos completos publicados em anais de congressos nacionais:

- **SILVA, M.E. da.; MOURA FILHO, J.O.F.; SUNI, J.C.P.; AMORA, M.A.B. Classificação Inteligente de Falhas Multiestágio em Alimentadores Primários de Distribuição de Energia Elétrica.** *In:* Anais do XXIV Congresso Brasileiro de Automática, Fortaleza, 2022.
- MOURA FILHO, J.O.F.; **SILVA, M.E. da.;** PINTO, V.P.; AMORA, M.A. **Modelagem da Degradação em Turbinas de Aeronave sob Condições Reais de Voo.** *In:* Anais do XXIV Congresso Brasileiro de Automática, Fortaleza, 2022.
- **SILVA, M.E. da. et al. Classification of the Supply Voltage conditions of a Three-Phase Induction Motor with Machine Learning Techniques.** *In:* Anais do XV Simpósio Brasileiro de Automação Inteligente, Rio Grande, 2021.
- MOURA FILHO, J.O.F.; **SILVA, M.E. da.;** PARENTE, J.K.C.; AMORA, M.A.B.; PINTO, V.P. **Diagnóstico de Falhas em Máquinas Elétricas Rotativas utilizando Técnicas de Ensemble Learning.** *In:* Anais do XV Simpósio Brasileiro de Automação Inteligente, Rio Grande, 2021.

## 1.5 Estrutura do trabalho

Este trabalho está estruturado da seguinte forma, no capítulo 1 são feitas considerações iniciais sobre a problemática de qualidade de energia e as ferramentas empregadas para sua detecção e classificação, bem como apresentadas os objetivos, justificativa e publicações do autor.

No capítulo 2 está o estado da arte sobre os principais trabalhos da área e suas respectivas metodologias para modelagem e classificação de distúrbios de qualidades de energia. Já no capítulo 3 está a modelagem do alimentador IEEE de 13 barras e seus componentes. No capítulo 4 será abordada a modelagem do sistema de geração fotovoltaico conectado à rede. No capítulo 5 está a modelagem dos distúrbios, através da simulação dos eventos que o causam.

No capítulo 6 estão a metodologia proposta para a classificação e os algoritmos de classificação baseados em árvore. No capítulo 7 são expostos os resultados obtidos, onde é realizada a discussão das métricas de avaliação obtidas. Finalmente, no capítulo 8, estão as conclusões e trabalhos futuros.

## 2 ESTADO DA ARTE

Os trabalhos de pesquisas sobre os distúrbios de qualidade de energia se concentram em duas principais áreas: i) a Localização Relativa da Origem do Evento (LROE); e ii) Classificação Automática da Causa Fundamental de Eventos (CACFE). O presente trabalho está contido na área de CACFE, considerando medidores no Ponto de Acoplamento Comum (PAC) (GARCIA, 2013).

Diversas metodologias foram desenvolvidas a fim de classificar de forma acurada o problema da qualidade de energia. Porém, com o advento das *Smart Grid* (SG) e o incremento de elementos semicondutores, que são mais sensíveis à QEE, torna-se necessário a adequação e o desenvolvimento de novas metodologias para atender a nova dinâmica das redes. Desta forma, este capítulo apresenta as mais recentes e relevantes publicações sobre a classificação de distúrbios de QEE, utilizando técnicas de *Machine Learning* (ML), de extração de características como a Transformada de *Wavelet* (TW) e a obtenção dos sinais de distúrbios via simulação.

Portanto, na seção 2.1 serão abordadas os trabalhos que empregaram técnicas de ML e a TW para classificar distúrbios de QEE. Por conseguinte, na seção 2.2, serão apresentados os trabalhos que coletaram os sinais de distúrbios via simulação. Finalmente, na seção 2.3 serão expostos os conceitos de SG e *Smart Meter*.

### 2.1 Classificação de distúrbios de QEE usando técnicas de *Machine Learning* com equações paramétricas

A técnica da TW tem sido largamente empregada na detecção e classificação de distúrbios de QEE devido a sua capacidade de fornecer características de tempo-frequência e por analisar discontinuidades locais de sinais (ALIMI *et al.*, 2020).

Um dos trabalhos pioneiros nesta tarefa é o de Santoso *et al.* (1996), onde os autores apresentaram uma nova abordagem para detectar e localizar múltiplos distúrbios de QEE. A abordagem adotada foi da Análise Multiresolução (AMR), uma das primeiras aplicações desta técnica, com a função *Wavelet*-mãe Daubechies de ordem quatro (db4). Esta abordagem consiste na decomposição de um dado sinal em dois outros, chamados de aproximação (que decompõe o sinal em baixas frequências) e detalhe (que decompõe o sinal em altas frequências). A decomposição pode ocorrer em vários níveis e a sobreposição dos sinais decompostos resulta no sinal original.



Já no trabalho de Manimala *et al.* (2012), o problema da escolha da *Wavelet*-mãe foi abordado de forma mais abrangente. Esta escolha é de suma importância na análise pela sua influência direta nos resultados. É verdade que na literatura a função *Wavelet*-mãe mais empregada é a db4 devido a sua semelhança com o sinal do distúrbio. Os autores empregaram a Transformada de Pacote *Wavelet* (WPT, do inglês *Wavelet Packet Transform*) para a extração de características e o algoritmo de Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machines*) para a classificação dos distúrbios.

Por outro lado, visando um desempenho superior, muitos autores exploram o uso combinado da Transformada de *Wavelet* Discreta (TWD) com a AMR e ML, como é caso do trabalho dos autores Kanirajan e Kumar (2015). Neste trabalho, os autores defendem que a TW combinada com a AMR oferece uma ótima resolução no espectro tempo-frequência, pois esta combinação tem a característica de janela curta para componentes de altas frequências e janela longa para baixas frequências. Os autores empregaram o algoritmo de *Radial Basis Function Neural Network* (RBFNN) para a classificação de 20 tipos de distúrbios de QEE e os resultados obtidos foram comparados com outros algoritmos tais como *Probabilistic Neural Network* (PNN), *Feed Forward Multilayer Network* (FFML), *Learning Vector Quantization* (LVQ) e *Generalized Regressive Neural Network* (GRNN). Este trabalho possui o diferencial de apresentar um emprego de funções *Wavelets* em níveis de decomposição diferentes, além de utilizar uma técnica de redução de ruído baseada em *Wavelets*, utilizando-a como filtro.

Em Mishra *et al.* (2008), uma abordagem diferente baseada na Transformada de *Stockwell* foi adotada para a redução de características. O classificador adotado foi o PNN, com acurácia geral de 95,91% para três características e 97,4% para quatro características. Os autores classificaram onze distúrbios, com redução de memória e tempo durante o aprendizado do classificador.

Similar a Kanirajan e Kumar (2015), o trabalho de Khokhar *et al.* (2017) também emprega a combinação da TWD com a AMR, porém com o diferencial de utilizar a Entropia Normalizada de *Wavelet* para extração de características. Neste trabalho, os autores propõem uma nova técnica de classificação automática de distúrbios simples e combinados baseados na TWD e na PNN associada com Colônia de Abelhas Artificiais. Além da aquisição dos sinais via equações paramétricas, os autores testam o classificador em um sistema de distribuição subterrâneo de 11kV existente na Malásia.

De maneira mais abrangente, o trabalho de Garcia (2013) realiza não só o diagnóstico

dos eventos como também a localização da sua origem. Desta forma, o autor aborda dois temas relevantes quando se trata de QEE: LROE e CACFE. A caracterização dos eventos transitórios é realizada mediante o desenvolvimento de algoritmos de segmentação, extração de características e classificação, utilizando-se da ferramenta MATLAB (MATLAB, 2022). O banco de dados empregado foi obtido a partir da operação real de uma concessionária do Estado de São Paulo. O diferencial deste trabalho está no uso da extração de características baseados na energia dos coeficientes de decomposição da AMR da TWD.

Em suma, existem diversas variações e metodologias de extração de características baseadas na TW, sendo que, cada uma delas possui vantagens e desvantagens próprias que melhor se enquadram em casos específicos, como é o caso do trabalho de Upadhyaya *et al.* (2022). Nesta variação da TW, chamada de *Second-Generation Wavelet Transform* (SGWT), o autor usufrui da vantagem desta técnica ser uma extração no domínio do tempo que requer menos tempo de processamento e, conseqüentemente, menos memória. Portanto, as diferenças entre as variações da TW devem ser analisadas dentro do contexto de implementação, pois esta escolha reflete diretamente na qualidade da classificação.

## 2.2 Aquisição de dados via simulação de rede

A aquisição dos dados nos trabalhos concernentes à classificação de distúrbios de QEE acontece normalmente a partir de três metodologias (GARCIA, 2013): i) simulação dos distúrbios a partir de um modelo de uma rede; ii) aquisição de dados reais a partir da operação de uma rede elétrica existente; ou iii) via simulação de equações paramétricas sintéticas.

No trabalho de Garcia (2013) é realizada uma discussão sobre as vantagens e desvantagens das metodologias baseadas em equação paramétrica e redes simuladas. Cada uma dessas metodologias possuem vantagens e desvantagens próprias, que devem ser ponderadas caso a caso. As simulações dos distúrbios a partir de modelos de redes reais possuem a grande vantagem de possibilitar configurações e parâmetros específicos tanto da rede quanto dos distúrbios, que se traduz em sinais de distúrbios mais abrangentes no que se refere as possibilidades de surgimento de tais eventos em redes reais. Por outro lado, as equações paramétricas sintéticas também oferecem a liberdade de configurações de parâmetros, mas não reproduzem de forma fidedigna a dinâmica dos distúrbios em redes reais. Finalmente, os dados reais apresentam os sinais exatos dos distúrbios, mas a característica aleatória e estocástica de tais eventos torna a coleta desses sinais uma tarefa difícil e imprevisível.

Em Shen *et al.* (2019) o autor adotou uma metodologia que inclui a simulação de 12 tipos de distúrbios simples e múltiplos de QEE a partir de equações paramétricas sintéticas e simulações de um modelo de rede de distribuição real, testadas em três níveis diferentes de ruído branco. A rede simulada é uma adaptação do Alimentador IEEE de 13 Barras (SCHNEIDER *et al.*, 2017) que, entre as modificações, estão a adição de energia eólica por meio de duas turbinas eólicas de 1,5 MW no barramento 380, o balanceamento da rede, entre outras. O autor obtém os sinais de queda e elevação de tensão a partir da simulação de faltas entre linhas e faltas multiestágio, *notch* (corte de tensão) e harmônicos são gerados a partir da conexão de cargas não lineares à rede, transiente oscilatório é gerado a partir da adição de banco de capacitores, forno elétrico a arco é usado para gerar flutuações de tensão, e descarga atmosférica para gerar transiente impulsivo.

Por outro lado, no trabalho de Upadhyaya *et al.* (2022), o autor obteve os sinais de distúrbios a partir do Sistema IEEE de 14 Barras com GD, neste caso, um sistema de geração solar fotovoltaico. Neste trabalho, são analisados os efeitos de conexão e desconexão do sistema fotovoltaico a rede, realizando as medições no PAC. No total são geradas 7 classes de sinais com a conexão do sistema fotovoltaico e 7 classes sem a conexão.

De forma a combinar as duas principais formas de geração no contexto da geração distribuída, o trabalho de Xu *et al.* (2020) empregou o Alimentador IEEE de 13 Barras (SCHNEIDER *et al.*, 2017) para obter nove tipos de distúrbios. As cargas são mantidas entre as barras 632 e 671 e os geradores eólico e fotovoltaico incluídos no barramento 680. Neste trabalho são investigados os fenômenos de ilha entre a barra 650 e o restante da rede. O gerador eólico tem capacidade de 1,5 MW em 60 Hz e tensão de saída de 575 V. Analogamente para o gerador fotovoltaico tem-se 1 MW de capacidade e 273,05 V para a tensão de saída que é elevada a 500 V em Corrente Contínua (CC) pela conexão de um conversor do tipo *boost* e, em seguida, conectado a um inversor que injeta na rede 260 V em Corrente Alternada.

É verdade que o surgimento de harmônicos é um dos mais indesejados e nocivo às cargas, desta forma, este distúrbio específico e sua dinâmica de propagação ao longo da rede é objetivo de estudo de diversos autores, como é o caso do trabalho de Skorupa (2021). Neste trabalho, a autora analisa os efeitos de propagação de harmônico ao longo da rede utilizando três sistemas para simular os eventos de harmônicos. No primeiro sistema, tem-se um sistema de cinco barras com os distúrbios harmônicos gerados por um Motor de Indução Trifásico (MIT) e inversores de frequência. No segundo sistema, o Alimentador IEEE de 13 Barras (SCHNEIDER

*et al.*, 2017) é empregado com um MIT acoplado na barra 680 para a geração dos harmônicos. Finalmente, no terceiro sistema, o mesmo alimentador supracitado é utilizado, porém, com a presença de múltiplas fontes de harmônicos, desta vez gerados por sete cargas não lineares acopladas em diferentes barras do sistema.

Por fim, o trabalho de Borges (2017) que faz um estudo abrangente do comportamento das fontes causadoras de Variação de Tensão de Curta Duração (VTCD) para localizar a origem de tais fontes. O autor utilizou o Alimentador IEEE de 34 Barras (SCHNEIDER *et al.*, 2017) para obter os sinais de relacionados aos eventos de VTCD. Os eventos simulados são causados por curto-circuitos para afundamento e interrupção de tensão, partidas e desligamento de grandes cargas e adição de banco de capacitores para elevação de tensão. A metodologia de classificação da origem da fonte de VTCD é baseada em algoritmos inteligentes de clusterização, cujos sinais obtidos são coletados considerando dispositivos de *Smart Meter* (SM) instalados ao longo de várias barras da rede.

### 2.3 Smart Grid e Smart Meter

O conceito de SG se refere à rede elétrica onde a distribuição de energia e o seu gerenciamento são realizados por meio de comunicações avançadas e bidirecionais, além de recursos sofisticados de controle, eficiência, confiabilidade e segurança. Uma SG possui a característica de fornecer energia a partir de tecnologias digitais e bidirecionais entre fornecedor e consumidor. Para tal, considera-se, nesse contexto, o controle automático das cargas em residências e prédios consumidores a fim de otimizar o consumo de energia, reduzir custos, aumentar a confiabilidade e a eficiência da rede (YAN *et al.*, 2013).

Existem três principais componentes de uma SG (FANG *et al.*, 2012): i) o sistema de infraestrutura inteligente; ii) o sistema de gerenciamento inteligente; e iii) o sistema de proteção inteligente. O sistema de infraestrutura inteligente abrange a infraestrutura de energia, informações e comunicações relacionados à geração, entrega e consumo de energia, medição, monitoramento e tecnologias avançadas de comunicação. Por outro lado, o sistema de gerenciamento inteligente compreende o fornecimento de serviços avançados de gerenciamento e controle da SG. Finalmente, o sistema de proteção inteligente é o subsistema que provê análises avançadas de confiabilidade da rede, proteção contra falhas, além de serviços de proteção de segurança e privacidade (FANG *et al.*, 2012).

Para tornar viável as funções supracitadas, os principais componentes como SM,

sensores, atuadores, sistemas de gerenciamento de dados e *microgrids* precisam estar conectados entre si. A esta infraestrutura dá-se o nome de *Automatic Metering Infrastructure* (AMI) (BORGES, 2017). Existem dois tipos principais de infraestruturas de comunicações empregadas na AMI: i) entre os dispositivos das residências e os SMs; e ii) entre os SMs e os centros de dados (BORGES, 2017).

Considerando o monitoramento permanente da SG, os SMs podem ser empregados para a inspeção da QEE. Desta forma, os dados oriundos dos SMs podem ser usados para suporte à tomada de decisão (BORGES, 2017). Por outro lado, monitorar distúrbios de QEE é uma tarefa complexa em virtude do alto custo associado aos dispositivos de medição. Desta forma, à medida que a rede cresce, torna-se inviável o monitoramento de todos os segmentos da rede, de onde se justifica a necessidade de estabelecer metodologias para determinar o ponto ótimo de alocação, sendo, portanto, um ponto crítico no gerenciamento da rede (ALI *et al.*, 2016). O posicionamento de medidores é também indicado em normas aplicáveis da área de QEE, como é o caso da norma IEEE 1159 (2019), que sugere a medição no PAC.

## 2.4 Considerações do capítulo

O presente capítulo apresentou o embasamento teórico sobre as principais metodologias de classificação de distúrbios de qualidade de energia via aplicação da Transformada de *Wavelet*, técnicas de *Machine Learning* no contexto das *Smart Grids*.

Os métodos de obtenção de sinais dos distúrbios via simulação de redes de distribuição se estabelecem como uma metodologia satisfatória, haja vista a grande similaridade dos modelos de alimentadores com as redes reais. Além disso, possui a grande vantagem de reproduzir as características dinâmicas de uma rede real, embora para isso, a complexidade deste método seja maior que as tradicionais equações paramétricas.

A implementação do monitoramento de QEE também são dependentes de abrangentes sistemas de medição, no contexto das SG, para coletar e processar os distúrbios da rede. A localização dos medidores é outro fator de relevância, normalmente escolhida nos pontos de acoplamento comum das cargas.

O próximo capítulo se dedica a apresentar a modelagem do alimentador IEEE de 13 Barras com as respectivas modificações propostas neste trabalho para a simulação dos distúrbios de QEE.


### 3 MODELAGEM DO ALIMENTADOR IEEE DE 13 BARRAS

#### 3.1 Alimentador IEEE de 13 barras

O alimentador IEEE de 13 barras, representado na Figura 1, é uma das diversas redes de distribuição desenvolvidas pelo Grupo de Trabalho de Alimentadores de Teste do Subcomitê de Análises de Sistemas de Distribuição do IEEE (*IEEE Test Feeder Working Group of the Distribution System Analysis Subcommittee*). Estes alimentadores objetivam estabelecer modelos de sistemas de distribuição com características amplas e diversas de projeto para refletir problemas e dificuldades frequentemente encontradas em alimentadores reais (SCHNEIDER *et al.*, 2017).

As características do alimentador IEEE de 13 barras incluem seu tamanho reduzido e curto, relativamente carregado, um regulador de tensão na subestação, linhas aéreas e subterrâneas, capacitores *shunt*, um transformador em linha, carregamento desbalanceado e operação em 4,16kV. Esta topologia de alimentador é normalmente empregada em testes de recursos de *software* de análise de sistemas de distribuição radiais trifásicos desbalanceados (PES, 2023).


Figura 1 – Alimentador IEEE de 13 Barras (Original)



Fonte: Schneider *et al.* (2017).

De modo a agregar as características associadas às *Smart Grids* no contexto da Geração Distribuída (GD), decidiu-se modificar o alimentador original, acrescentando-se uma usina fotovoltaica acoplada ao barramento 680, ao passo que decidiu-se remover o regulador de tensão no barramento 650 para simplificar as simulações, conforme a Figura 2.

Figura 2 – Alimentador IEEE de 13 Barras (Modificado)



Fonte: Adaptado de Schneider *et al.* (2017), PES (2023).

O alimentador simulado no ambiente MATLAB Simulink (MATLAB, 2022) está representado, a seguir, na Figura 3.

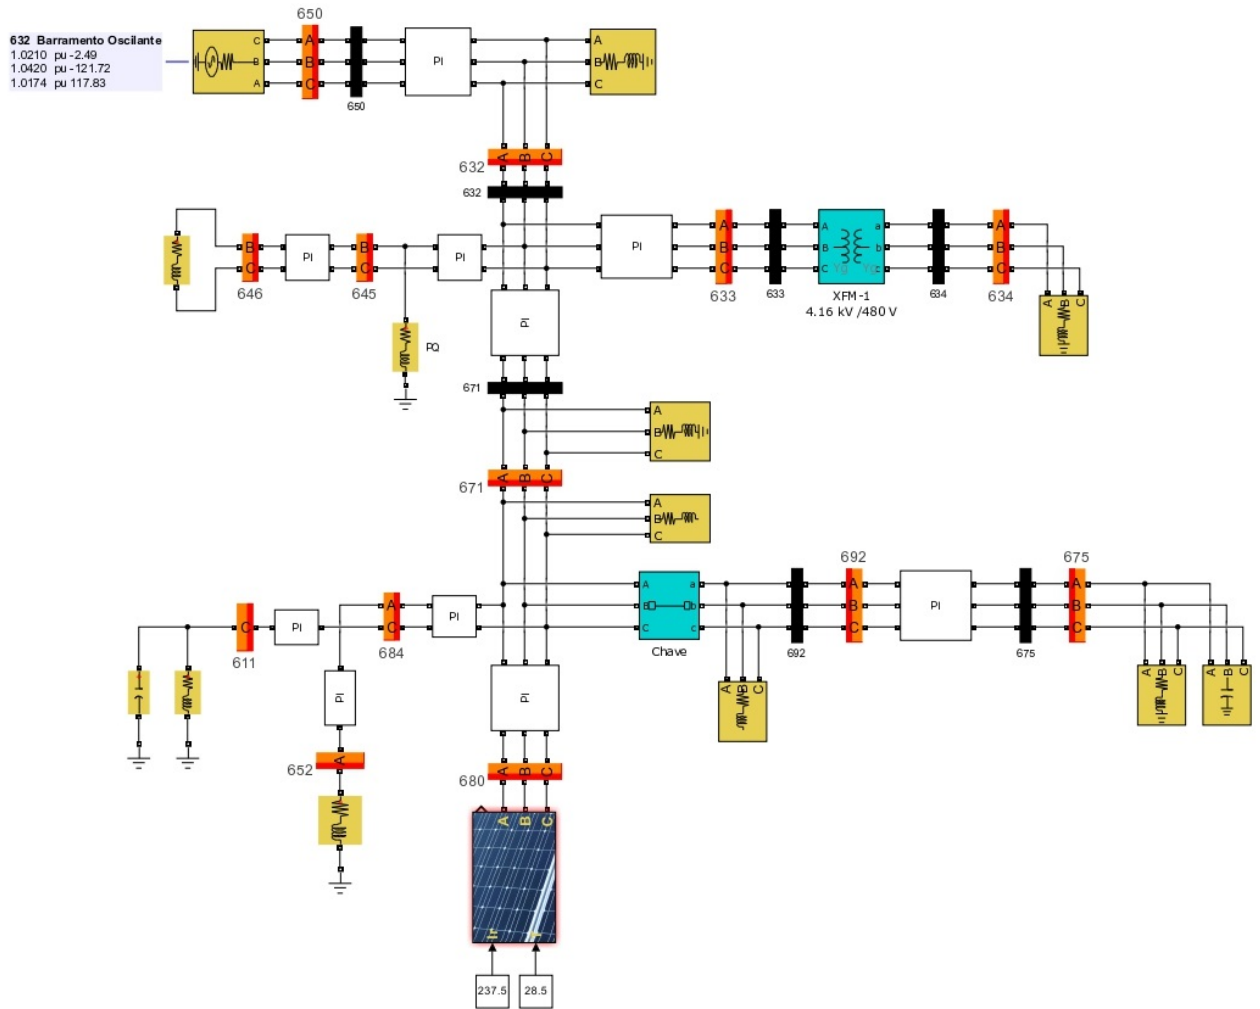
### 3.1.1 Segmentos de linhas

A rede possui segmentos de linha tanto aéreos como subterrâneos, de modo que as características distintas de condutores nus e isoladas de ambas as redes podem ser analisadas para diferentes condições de distúrbios.

O modelo aqui utilizado é o chamado  $\pi$ -equivalente, que combina elementos passivos de resistência ( $R$ ), indutância ( $L$ ) e capacitância ( $C$ ) (GLOVER *et al.*, 2012). Este modelo de linha, representado na Figura 4, é amplamente empregado em sistemas de transmissão e distribuição de energia pela sua ampla usabilidade, sendo ideal para análises de sistemas sem perda de precisão significativa, quando os níveis de tensão não são superiores à média tensão.

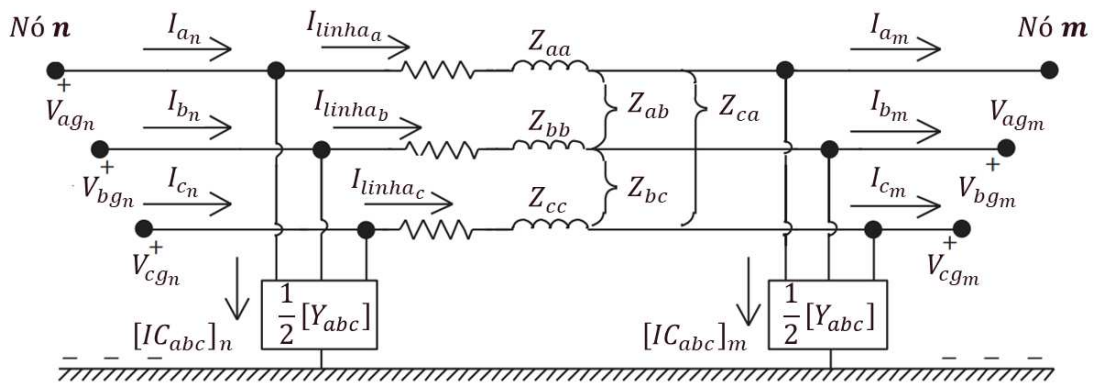
Desta forma, a aplicação da Lei das Tensões de Kirchhoff (KERSTING, 2012), as tensões entre fase e terra resultam na Equação (1), onde os valores de  $Z$  são as impedâncias entre os nós  $a$ ,  $b$  e  $c$ , e  $I$  são as correntes de linha, indicados na Figura 4.

Figura 3 – Alimentador IEEE de 13 barras com geração distribuída



Fonte: Adaptado de LeSage (2023).

Figura 4 – Modelo de linha  $\pi$ -equivalente.



Fonte: Adaptado de Kersting (2012).

$$\begin{bmatrix} V_{ag} \\ V_{bg} \\ V_{cg} \end{bmatrix}_n = \begin{bmatrix} V_{ag} \\ V_{bg} \\ V_{cg} \end{bmatrix}_m + \begin{bmatrix} Z_{aa} & Z_{ab} & Z_{ac} \\ Z_{ba} & Z_{bb} & Z_{bc} \\ Z_{ca} & Z_{cb} & Z_{cc} \end{bmatrix} \cdot \begin{bmatrix} I_{linha_a} \\ I_{linha_b} \\ I_{linha_c} \end{bmatrix}_m \quad (1)$$



E, para as correntes de linha resulta (KERSTING, 2012):

$$\begin{bmatrix} I_a \\ I_b \\ I_c \end{bmatrix}_n = \begin{bmatrix} I_{linha_a} \\ I_{linha_b} \\ I_{linha_c} \end{bmatrix}_m + \frac{1}{2} \cdot \begin{bmatrix} Y_{aa} & Y_{ab} & Y_{ac} \\ Y_{ba} & Y_{bb} & Y_{bc} \\ Y_{ca} & Y_{cb} & Y_{cc} \end{bmatrix} \cdot \begin{bmatrix} V_{ag} \\ V_{bg} \\ V_{cg} \end{bmatrix}_n \quad (2)$$

Finalmente, as tensões de linha são obtidas da seguinte forma (KERSTING, 2012):

$$\begin{bmatrix} V_{ab} \\ V_{bc} \\ V_{ca} \end{bmatrix}_m = \begin{bmatrix} 1 & -1 & 0 \\ 0 & 1 & -1 \\ -1 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} V_{ag} \\ V_{bg} \\ V_{cg} \end{bmatrix}_m \quad (3)$$

Portanto, cada segmento de linha possui uma modelagem própria de acordo com a Figura 4, cujos parâmetros variam com o tipo de rede (aérea ou subterrânea) e o respectivo tipo de condutor.

### 3.1.1.1 Linhas aéreas

Os segmentos aéreos do alimentador possuem diferentes configurações de faseamento, de seção de condutores e espaçamentos. Estas configurações estão resumidas a seguir, na Tabela 2.

Tabela 2 – Configuração de linhas aéreas

Configuração	Faseamento	Fase (CAA)	Neutro (CAA)	Espaçamento (ID)
601	B A C N	556,500 26/7	4/0 6/1	500
602	C A B N	4/0 6/1	4/0 6/1	500
603	C B N	1/0	1/0	505
604	A C N	1/0	1/0	505
605	C N	1/0	1/0	510

Fonte: Kersting (2001), PES (2023).

Visando padronizar as diferentes configurações de espaçamento, na Tabela 2 são referenciadas três tipos, que estão detalhadas na Tabela 3. As dimensões e o posicionamento espacial dos condutores são exibidos na Figura 5, cujos valores estão em metros.

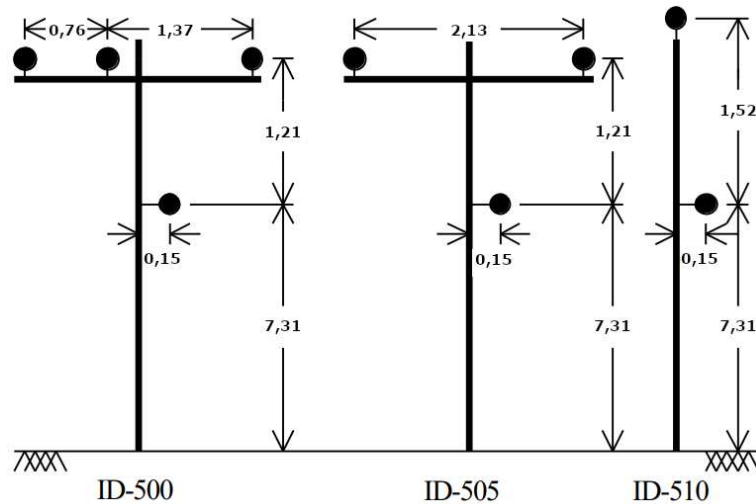
Os condutores do tipo Condutor de Alumínio com Alma de Aço (CAA) utilizados neste tipo de rede são construídos em alumínio, revestidos com zinco contra corrosão e encordoados sobre o núcleo de aço, que garantem maior resistência mecânica.

Tabela 3 – Espaçamentos de linhas aéreas

Espaçamento (ID)	Tipo	Condutores
500	Trifásico	4
505	Bifásico	3
510	Monofásico	2

Fonte: Kersting (2001), PES (2023).

Figura 5 – Espaçamentos em linhas aéreas (em metros)



Fonte: Adaptado de Kersting (2001), PES (2023).

Este tipo de condutor é econômico e possui boa relação de resistência e peso, além disso, o peso leve associado à alta condutividade do alumínio e a resistência do núcleo permite conduzir em tensões mais elevadas com menos arqueamento e vãos mais longos (HOUSTON WIRE CABLE, 2023). A Figura 6 ilustra um condutor do tipo CAA.

Figura 6 – Condutor CAA



Fonte: Houston Wire Cable (2023).

Portanto, considerando o Nó A como de início e o Nó B como de término na Figura 2, estabelece-se dez segmentos aéreos, cujos valores de comprimento (em metros) e a respectiva configuração são dadas na Tabela 4.

Tabela 4 – Segmentos de linhas aéreas

Nó A	Nó B	Comprimento (m)	Configuração
632	645	152,4	603
632	633	152,4	602
633	634	0	XFM-1
645	646	91,44	603
650	632	609,6	601
632	671	609,6	601
671	684	91,44	604
671	680	304,8	601
671	692	0	Chave
684	611	91,44	605

Fonte: Adaptado de Kersting (2001), PES (2023).

### 3.1.1.2 Linhas subterrâneas

Analogamente aos segmentos aéreos, na Tabela 5 estão representadas as configurações adotadas para os segmentos subterrâneos. Ressalta-se aqui, diferente dos segmentos aéreos com condutores nus, os condutores CA empregados nos segmentos subterrâneos de isolamento do tipo Borracha Etileno-Propileno (EPR) designado por TS (do inglês, *Tape Shielded*) e do tipo Neutro Concêntrico designado por CN (do inglês, *Concentric Neutral*).

Tabela 5 – Configuração de linhas subterrâneas

Configuração	Faseamento	Condutor	Neutro	Espaçamento (ID)
606	A B C N	250 CA, CN		515
607	A N	1/0 CA, TS	1/0 Cu	520

Fonte: Schneider *et al.* (2017), Watitwa (2022).

Os espaçamentos estão detalhados na Tabela 6 e Figura 7, com suas respectivas quantidades de condutores e unidade em centímetros.


Tabela 6 – Espaçamentos de linhas subterrâneas

Espaçamento (ID)	Tipo	Condutores
515	Trifásico	3
520	Monofásico	2

Fonte: Kersting (2001), PES (2023).


Os condutores do tipo Condutor de Alumínio (CA) CN (Figura 8) são amplamente empregados em sistemas primários de distribuição. Possuem isolamento do tipo EPR e são construídos com alumínio, com neutros concêntricos de cobre nu e capa de Polietileno de baixa densidade.

Figura 7 – Espaçamentos em linhas subterrâneas (cm)



Fonte: Adaptado de Kersting (2001), PES (2023).


Figura 8 – Condutor CA CN



Fonte: Henan Qingzhou Cable (2023).

Por outro lado, os condutores do tipo CA TS (Figura 9) são construídos com alumínio e isolamento em EPR. A blindagem de cobre mantém os condutores na posição adequada e os protege contra o estresse mecânico. A capa é de Policloreto de Vinila (PVC) e oferece proteção contra umidade, chamas, produtos químicos corrosivos e abrasão (NASSAU NATIONAL CABLE, 2023).

Figura 9 – Condutor CA TS



Fonte: Nassau National Cable (2023).

Portanto, considerando o Nó A como de início e o Nó B como de término na Figura 2, estabelecem-se dois segmentos subterrâneos, cujos valores de comprimento (m) e a respectiva configuração são dados na Tabela 7.

Tabela 7 – Segmentos de linhas subterrâneas

Nó A	Nó B	Comprimento (m)	Configuração
684	652	243,84	607
692	675	152,4	606

Fonte: Adaptado de Kersting (2001), PES (2023).

### 3.1.2 Transformadores

As unidades de transformações do alimentador são duas: i) a subestação, representada pelo barramento oscilante; e ii) um transformador de 500kVA, que alimenta a carga em baixa tensão. A potência, tensões do primário e secundário, e os valores de resistência e indutância (em pu) dos enrolamentos seguem conforme a Tabela 8.

Tabela 8 – Configuração dos transformadores

	kVA	kV (lado de alta)	kV (lado de baixa)	R (%)	X (%)
Subestação	5.000	115 ( $\Delta$ )	4,16 ( $YN$ )	1	8
XFM-1	500	4,16 ( $YN$ )	0,48 ( $YN$ )	1,1	2

Fonte: Kersting (2001), PES (2023).

As simulações consideram os valores de resistência do núcleo ( $R_c$ ) e indutância de magnetização ( $X_m$ ) como sendo 500 (pu) para ambos. Um exemplo de transformador com potência de 500kVA é dado na Figura 10. Em redes aéreas como esta, utilizam-se transformadores com isolamento a óleo por estarem abrigadas ao tempo.

Figura 10 – Transformador de distribuição de 500kVA



Fonte: Scottech (2023).

### 3.1.3 Capacitores

Os capacitores de redes de distribuição (Figura 11) são equipamentos que desempenham as funções de correção do Fator de Potência (FP), estabilidade da tensão e economia de custos com FP próximo do seu valor unitário, por exemplo (EATON, 2023).

Figura 11 – Capacitores de distribuição



Fonte: Eaton (2023).

A Tabela 9 resume os capacitores empregados no alimentador, onde se utilizou dois bancos de capacitores, um trifásico no nó 675 e um monofásico no nó 611.

Tabela 9 – Configuração dos capacitores

Nó	Fase A (kvar)	Fase B (kvar)	Fase C (kvar)
675	200	200	200
611	0	0	100
<b>Total</b>	<b>200</b>	<b>200</b>	<b>300</b>

Fonte: Kersting (2001), PES (2023).

### 3.1.4 Cargas

As cargas acopladas ao alimentador possuem diferentes características de distribuição, podendo ser cargas concentradas que estão conectadas em apenas um PAC ou cargas distribuídas que estão distribuídas uniformemente ao longo de um trecho do alimentador (KERSTING, 2012). As várias configurações de conexão estão detalhadas na Tabela 10.

Tabela 10 – Cargas concentradas

Configuração	Conexão	Descrição
Y-PQ	Estrela	kW e kvar constantes
Y-I	Estrela	Corrente constante
Y-Z	Estrela	Impedância constante
D-PQ	Delta	kW e kvar constantes
D-I	Delta	Corrente constante
D-Z	Delta	Impedância constante

Fonte: Kersting (2001), PES (2023).

Os valores de potência ativa e reativa das cargas concentradas, bem como sua

configuração e respectivo nó de conexão ao sistema estão resumidos na Tabela 11. E de maneira análoga com as cargas concentradas, a Tabela 12 resume os valores de carga para as cargas distribuídas.

Tabela 11 – Cargas concentradas por barra

Nó	Carga Conexão	Fase 1 kW	Fase 1 kvar	Fase 2 kW	Fase 2 kvar	Fase 3 kW	Fase 3 kvar
634	Y-PQ	160	110	120	90	120	90
645	Y-PQ	0	0	170	125	0	0
646	D-Z	0	0	230	132	0	0
652	Y-Z	128	86	0	0	0	0
671	D-PQ	385	220	385	220	385	220
675	Y-PQ	485	190	68	60	290	212
692	D-I	0	0	0	0	170	151
611	Y-I	0	0	0	0	170	80
	<b>Total</b>	<b>1158</b>	<b>606</b>	<b>973</b>	<b>627</b>	<b>1135</b>	<b>753</b>

Fonte: Kersting (2001), PES (2023).

Tabela 12 – Cargas distribuídas

Nó A	Nó B	Carga Conexão	Fase 1 kW	Fase 1 kvar	Fase 2 kW	Fase 2 kvar	Fase 3 kW	Fase 3 kvar
632	671	Y-PQ	17	10	66	38	117	68

Fonte: Kersting (2001), PES (2023).

### 3.2 Considerações do capítulo

Neste capítulo foram abordadas as principais características do Alimentador IEEE de 13 Barras, incluindo a modelagem dos condutores, cargas e elementos de transformação.

Por se tratar de uma rede radial com trechos aéreos e subterrâneos, este alimentador representa a característica da maioria dos sistemas de distribuição no Brasil e no mundo, sendo, por este motivo, ideal para a simulação dos distúrbios de qualidade de energia.

A fim de inserir a característica da geração distribuída neste alimentador, no próximo capítulo será abordada a modelagem do sistema de geração fotovoltaico e seus elementos, que consideram, sempre que possível, as características típicas de geração da região da cidade de Sobral.

## 4 MODELAGEM DO SISTEMA DE GERAÇÃO FOTOVOLTAICO

O Sistema Fotovoltaico Conectado à Rede (SFCR) simulado no alimentador da Figura 2 é projetado para suprir 8% de suas cargas. Os dados meteorológicos necessários ao projeto do sistema foram obtidos considerando a localização da cidade de Sobral no Ceará. Este sistema é acoplado à barra 680 do sistema da Figura 2, a exemplo do trabalho de Xu *et al.* (2020).

### 4.1 Painéis fotovoltaicos

De acordo com as Tabelas 11 e 12, as cargas totalizam 3.466 kW de potência ativa ( $P$ ). Além disso, considerando tempo de uso ( $\Delta t$ ) de 24 horas por dia, temos que o consumo será:

$$Consumo_{dia} = P \cdot \Delta t = (3.466 \cdot 10^3) \cdot 24 = 83,184 \cdot 10^6 \cong 83 \text{ MWh/dia} \quad (4)$$

De acordo com o Atlas Solarimétrico do Brasil (TIBA *et al.*, 2000), Sobral possui média de 7 horas de Horas de Sol Pleno (HSP) por dia. Daí, considerando o percentual das perdas ( $\eta$ ) como 10% temos que a potência desejada para o sistema é, portanto (PINFILDI, 2022):

$$P_{Wp} = \frac{P \cdot 8\%}{HSP \cdot (100\% - \eta)} = \frac{(83,184 \cdot 10^6) \cdot 8\%}{7 \cdot (100\% - 10\%)} = 1,06 \text{ MW}_p \quad (5)$$

Considerando painéis solares do modelo SunPower SPR-X22-480-COM (SUNPOWER, 2023), de alta eficiência (22,2%), cuja potência nominal ( $P_{nom}$ ) é  $480W_p$ , temos que a quantidade de painéis será (PINFILDI, 2022):

$$Quantidade_{paineis} = \frac{P_{Wp}}{P_{nom}} = \frac{1,06 \cdot 10^6}{480} = 2208,3 \quad (6)$$

Para este nível de potência utiliza-se um inversor do tipo centralizado, empregado em centrais geradoras fotovoltaicas de grande porte. Se a tensão de circuito aberto ( $V_{oc}$ ) das placas é 92,7V e tomando como base o inversor centralizado modelo ULTRA-1100-TL-OUTD-X-US-690 (ABB, 2023) com potência nominal de saída de 1170kW e tensão máxima CC ( $V_{max_{cc}}$ ) de 1000V, temos que a quantidade de painéis em série (*string*) é (PINFILDI, 2022):

$$Quantidade_{paineis_{serie}} = \frac{V_{max_{cc}}}{V_{oc}} = \frac{1000}{92,7} = 10,79 \cong 11 \quad (7)$$



Finalmente, calculando a quantidade de *strings*, temos (PINFILDI, 2022):

$$Quantidade_{strings} = \frac{Quantidade_{painéis}}{Quantidade_{painéis_{serie}}} = \frac{2208,3}{11} = 200,75 \cong 201 \quad (8)$$

Para fins de simulação, considera-se uma irradiação constante de  $237,5W/m^2$ , que é o valor média diário de Sobral segundo o *National Renewable Energy Laboratory* (NREL, 2023). Além disso, sabendo que serão necessários 11 painéis em série e 201 *strings*, o resultado da Equação (6) deve ser arredondado para  $11 \times 201 = 2211$  para padronizar todas as *strings* com a mesma quantidade de painéis.

## 4.2 Barramento CC

O barramento CC é constituído de um capacitor, cuja função principal é de regular, filtrar e estabilizar a corrente CC à montante do inversor. Este capacitor é importante para atenuar as flutuações de tensão e corrente que os painéis solares geram e que variam com fatores externos como irradiação solar e sombreamento. Desta forma, o barramento CC, que também é conhecido como *DC Link*, reduz o ruído elétrico e as interferências eletromagnéticas geradas pelo inversor, aumentando a qualidade da energia gerada. Outra função do *DC Link* é servir de *buffer* para armazenar energia por um curto período, de modo a garantir a estabilidade e a capacidade de resposta às variações na demanda de energia (MOHAMED S.R.; JEYANTHY, 2019). A capacitância do *DC Link* é calculada como segue (MOHAMED S.R.; JEYANTHY, 2019):


$$C_{Link} = 2 \cdot \frac{3}{4} \cdot \frac{P_{nom}}{F_{nom}} \cdot \frac{2}{V_{nomCC}^2} \quad (9)$$

$$C_{Link} = 2 \cdot \frac{3}{4} \cdot \frac{83,184 \cdot 10^6}{60} \cdot \frac{2}{1000^2} = 0,0530 F \quad (10)$$

onde  $P_{nom}$  é a potência nominal do sistema,  $F_{nom}$  é a frequência nominal do sistema, e  $V_{nomCC}$  é a tensão nominal no barramento CC.

Em um ciclo de energia, a corrente atinge seu pico em 3/4 de ciclo, por este motivo, a capacitância do barramento CC deve ser dimensionada utilizando esse período para suportar esta corrente. Esquematicamente, o barramento CC dimensionado segue conforme a Figura 12, que utiliza dois capacitores idênticos e com neutro central, topologia normalmente empregada.

Figura 12 – Barramento CC



Fonte: Adaptado de LeSage (2023).

Na Figura 12, os polos FV+ e FV– representam os terminais conectados aos painéis fotovoltaicos, os polos Inv+ e Inv– e o terminal  $N$  representam os polos e terminal conectados ao inversor, enquanto o terminal  $V_{CC}$  alimenta o controlador do inversor.

### 4.3 Inversor fotovoltaico

Como citado anteriormente, os inversores empregados em sistema de geração com o nível de potência compatível com o simulado neste trabalho são chamados “Inversores Centralizados”, que são centrais conversoras de energia CC-CA em larga escala, em sistemas de minigeração distribuída.

No Brasil, a minigeração distribuída é classificada pelas centrais geradoras de energia elétrica renovável ou de cogeração qualificada que possuem potência instalada em corrente alternada maior que 75kW e menor de 5MW para as fontes despacháveis e maior que 75kW e menor que 3MW para as fontes não despacháveis de acordo com a Lei Nº 14.300 de 6 de janeiro de 2022 (CONGRESSO NACIONAL, 2022).

A Figura 13 representa o modelo ULTRA-1100-TL-OUTD-X-US-690 do fabricante ABB (ABB, 2023), cujos valores de potência e níveis de tensão nominais serviram de base para as simulações do presente trabalho.

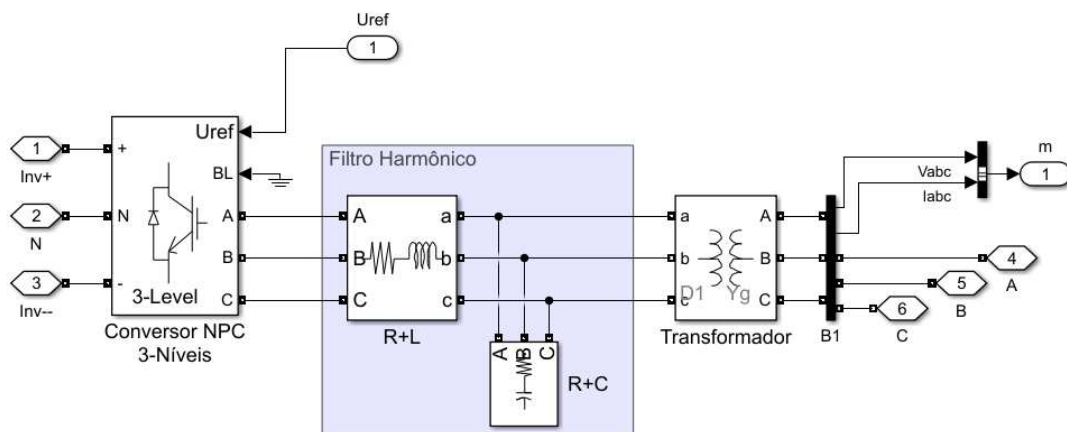
O modelo de inversor implementado no ambiente de simulação Simulink (MATLAB, 2022), reproduzido na Figura 14, é uma simplificação de um modelo real, consistindo de três elementos principais, a saber: i) Conversor NPC de 3 níveis, ii) Filtro Harmônico, e iii) transformador.

Figura 13 – Inversor centralizado



Fonte: ABB (2023).

Figura 14 – Inversor centralizado simulado



Fonte: Adaptado de LeSage (2023)

Ressalta-se que, na prática, os inversores centralizados podem ou não ter transformador elevador próprio, sendo mais frequente inversores desprovido destes. Neste caso, há de se construir uma subestação para acoplar o inversor à rede, visto que sistemas fotovoltaicos de grande porte são conectados em redes de média tensão e necessitam elevar sua tensão de geração aos níveis compatíveis à rede. Para fins de simplificação, considera-se neste trabalho o transformador elevador já acoplado ao inversor.

Definem-se os valores de entrada ( $V_{nom_{prim}}$ ) e saída ( $V_{nom_{sec}}$ ) do inversor como segue, onde  $V_{CC}$  é a tensão de saída no barramento CC, cujo valor é 1000V. Convenciona-se aqui que os terminais do primário estão conectados ao filtro CC e os terminais do secundário conectados à rede (MESSENGER; ABTAHI, 2017):

$$V_{nom_{prim}} = 0,85 \cdot \frac{V_{CC} \cdot \sqrt{3}}{2 \cdot \sqrt{2}} = 520,5166 \text{ V} \quad (11)$$

$$V_{nom_{sec}} = 4,16 \text{ kV} \quad (12)$$

#### 4.3.1 Conversor NPC

O conversor NPC, que significa “Ponto Neutro Grampeado” (do inglês, *Neutral-Point Clamped*), é o elemento responsável pela conversão da corrente e tensão CC em CA. O ponto neutro, neste caso, é o indicado na Figura 12, cuja função é fornecer energia com maior qualidade à rede elétrica, pois reduz as distorções harmônicas geradas por comutação dos dispositivos semicondutores, melhora o fator de potência, além de reduzir ruídos e interferências (CARUANA, 2023).

O modelo de Conversor NPC simulado é do tipo “Modelo Médio” que é uma função de comutação diretamente controlada por um sinal vetorizado de referência ( $U_{ref}$ ), constituído por três tensões de referência, uma para cada fase. Neste tipo de conversor um gerador *Pulse Width Modulation* (PWM) não é necessário, pois a saída já possui três níveis de tensão fixos, tornando desnecessário o uso de PWM para modular a saída.

#### 4.3.2 Filtro harmônico

O filtro harmônico simulado é do tipo passivo “Passa-Baixa”, empregado para filtrar componentes de altas frequências, permitindo a passagem de frequências abaixo de uma frequência de corte e rejeitando as de frequência superior (RASHID, 2015).

Calculando as componentes  $R$  e  $L$  do filtro, onde  $R_{choke}$  e  $L_{choke}$  são as resistência e a indutância de impacto em pu do filtro, obtidas de forma empírica através dos trabalhos de Tan e Ramachandaramurthy (2015), de onde resulta:

$$R_{choke} = \frac{0,15}{100} = 0,0015 \text{ pu} \quad (13)$$

$$L_{choke} = 0,15 \text{ pu} \quad (14)$$

$$Z_{base} = \frac{V_{nom_{sec}}^2}{P_{nom}} = 0,2556 pu \quad (15)$$

onde  $P_{nom}$  é a potência nominal do inversor com sua respectiva frequência nominal de 60Hz ( $F_{nom}$ ). Então, a resistência e a indutância serão:

$$R = R_{choke} \cdot Z_{base} = 383,4 \mu\Omega \quad (16)$$

$$L = \frac{L_{choke} \cdot Z_{base}}{2 \cdot \pi \cdot F_{nom}} = 101,7 \mu F \quad (17)$$

A componente  $RC$  é ligada em delta e possui os seguintes valores de potência reativa ( $Q_C$ ) e ativa ( $P_C$ ):

$$Q_C = 0,1 \cdot P_{nom} = 106 kvar \quad (18)$$

$$P_C = \frac{Q_C}{50} = 2,12 kW \quad (19)$$

A Equação (18) define que a potência reativa do filtro deve ser 10% da potência nominal do inversor, enquanto a Equação (19) representa a potência ativa dissipada no resistor de descarga, onde 50 é a impedância característica do filtro usada para converter a reatância capacitiva em uma impedância equivalente, segundo a recomendação do trabalho de (TAN; RAMACHANDARAMURTHY, 2015).

### 4.3.3 Transformador

O transformador acoplado ao inversor é do tipo elevador, com dois enrolamentos por fase, com ligação Delta do lado do inversor e Estrela-Aterrado do lado da rede. A potência do transformador é a mesma do inversor ( $P_{nom}$ ) e as tensões nominais do lado de alta ( $V_{nom_{sec}}$ ) e baixa ( $V_{nom_{prim}}$ ) são as mesmas definidas nas Equações (11) e (12). Define-se também as resistências ( $R_1$  e  $R_2$ ) e indutâncias de dispersão ( $L_1$  e  $L_2$ ) em pu, como segue (KINGSLEY; UMANS, 2013):

$$R_1 = R_2 = \frac{R_{dispersao}}{2} \quad (20)$$

$$L_1 = L_2 = \frac{L_{dispersao}}{2} \quad (21)$$

onde  $L_{dispersao}$  é definida em 6% e  $R_{dispersao}$  como sendo a 1/25 parcela de  $L_{disp}$ . Finalmente, a resistência ( $R_c$ ) de perdas no núcleo e a indutância de magnetização ( $L_m$ ) são definidas em 200 pu, de acordo com os resultados empíricos obtidos do trabalho de Tan e Ramachandaramurthy (2015)


#### 4.4 Controlador do inversor

O controlador do inversor é modelado com base no algoritmo de MPPT com a técnica “Perturbe e Observe” que, para sua implementação, necessita de outros elementos denominados por: i) Loops de bloqueio de fase (PPL, do inglês *Phase-locked loop*) e Medições, ii) Regulador CC, iii) Regulador de Corrente, e iv) Gerador do Sinal de Referência.

Pela natureza estocástica da irradiação solar na geração fotovoltaica, existe a necessidade de estabelecer um controle que otimize a geração. Neste sentido, duas curvas são particularmente importantes no projeto e controle de sistemas fotovoltaicos: a Curva I-V e a Curva P-V. Enquanto a primeira estabelece uma relação de corrente e tensão para um valor fixo de irradiação e temperatura, o segundo estabelece uma relação entre potência e tensão para sob as mesmas condições.


As Figuras 15 e 16 reproduzem essas curvas para o modelo SunPower SPR-X22-480-COM, utilizado nas simulações deste trabalho.

Figura 15 – Cuva I-V (25 °C)



Fonte: Adaptado de SunPower (2023).

Figura 16 – Cuva P-V (25 °C)

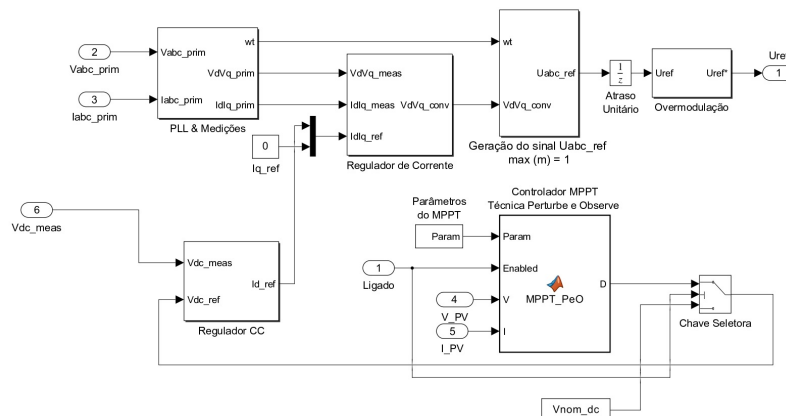


Fonte: Adaptado de SunPower (2023).

Estas curvas representam os diferentes valores de corrente e potência para diferentes valores de irradiação, de onde resulta a necessidade de operar nos pontos da curva com a maior potência, de acordo com a irradiação incidente. Portanto, o sistema deve se manter no ponto ótimo de operação, chamado de *Maximum Power Point* (MPP), onde a corrente e a tensão fornecem o maior valor de potência de saída. Diversas técnicas de otimização podem ser empregadas na tarefa de manter o sistema em seu ponto ótimo, sendo a técnica de MPPT com o algoritmo “Perturbe e Observe” (P&O) uma das mais empregadas em sistemas fotovoltaicos, pela sua simplicidade.

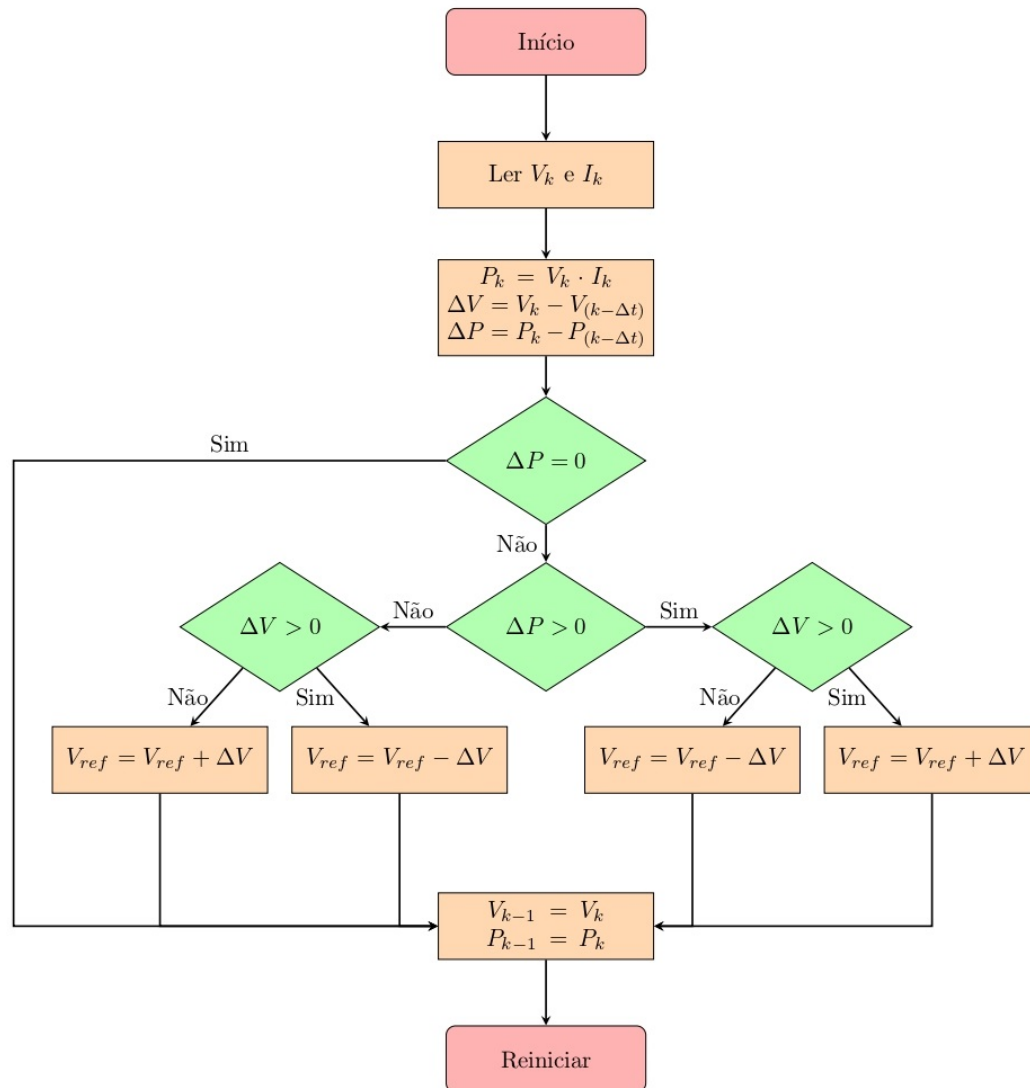
O funcionamento do algoritmo consiste em verificar os valores de tensão e corrente gerados nos painéis e a partir daí calcular a potência de saída, ao realizar um incremento de tensão (perturbação do sistema), verifica-se a potência aumenta ou diminui. Se a potência aumenta com a tensão de perturbação, o valor da tensão é atualizado para a tensão atual somada à perturbação, em caso contrário o valor atual de tensão é subtraído da tensão de perturbação e o ponto de operação é atualizado. Ao finalizar a atualização, o ciclo é reiniciado (VIVERT *et al.*, 2021). A Figura 17 reproduz o diagrama do controle simulado no ambiente Simulink, com os respectivos elementos e suas conexões, e na Figura 18 está o fluxograma do algoritmo.

Figura 17 – Diagrama de blocos do controle do inversor



Fonte: Adaptado de LeSage (2023).

Figura 18 – Algoritmo MPPT com P&amp;O



Fonte: Adaptado de Vivert *et al.* (2021).

#### 4.5 Considerações do capítulo

Neste capítulo realizou-se a modelagem do sistema de geração fotovoltaico, que consiste em um sistema de minigeração com a insolação correspondente à cidade de Sobral. O inversor utilizado é do tipo centralizado, empregado em sistemas de geração fotovoltaica com potências significativas. Algumas considerações para fins de simplificação são realizadas, seguindo as recomendações da literatura. O controle MPPT adotado é o Perturbe e Observe, que corresponde ao mais utilizado nas aplicações deste tipo. No capítulo seguinte será detalhada a modelagem dos distúrbios de QEE, segundo a norma IEEE 1159 (2019), onde serão simulados quatro eventos na rede, a fim de se obter tais distúrbios.



## 5 MODELAGEM DOS DISTÚRBIOS DE QEE

Os distúrbios de QEE simulados neste trabalho consideram eventos reais, frequentemente encontrados em redes de distribuição de energia públicas e industriais. No total, quatro distúrbios foram simulados, de acordo com a Tabela 13:

Tabela 13 – Distúrbios simulados

Nº	Distúrbio	Evento
1	Queda de Tensão	Falta de linha (curto-circuito)
2	Distorção Harmônica	Carga não linear
3	Transiente Impulsivo	Descarga atmosférica
4	Transiente Oscilatório	Banco de capacitores

Fonte: Elaborado pelo autor.

Todas as simulações realizadas possuem duração de 0,1667 segundos, que corresponde a 10 ciclos do sinal, conforme orientações da literatura (BORGES, 2013). A taxa de amostragem adotada é de 10kHz para atender as recomendações do Módulo 8 dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) (ANEEL, 2021).

A análise destes eventos são padronizados pela norma IEEE 1159 (2019), que os caracterizam de acordo com a Tabela 14.

Tabela 14 – Categoria dos distúrbios segundo o IEEE

Categorias	Conteúdo espectral	Duração típica	Magnitude de Tensão
Variação de Tensão de Curta Duração			
Instantâneo			
Queda de Tensão		0,5 - 30 ciclos	0,1 - 0,9 pu
Distorções na Forma de Onda			
Distorções Harmônicas	0 - 9 kHz	Regime Permanente	0 - 20%
Transitórios			
Impulsivos			
Nanosegundo	5 ns pico	< 50 ns	
Microsegundo	1 $\mu$ s pico	50 ns - 1 ms	
Milisegundo	0,1 ms pico	> 1 ms	
Oscilatórios			
Baixa Frequência	< 5kHz	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

Fonte: Elaborado pelo autor.

Todos os distúrbios são simulados na barra 632 da Figura 2, cuja escolha se justifica na sua localização central, que permite uma abrangente propagação de seus efeitos pelo alimentador, prova disso são os trabalhos de Sharma *et al.* (2018) e Khoa *et al.* (2020), que também simulam distúrbios nesta mesma barra.

A escolha das barras de medição se justifica pelo fato de que essas barras correspondem à alimentação de trechos com características distintas à análise. A barra 634 corresponde ao trecho das cargas em baixa tensão, a barra 671 corresponde ao trecho central da rede, de média tensão. Portanto, ao medir tais distúrbios nas barras supracitadas, é possível estabelecer um comparativo dos efeitos e consequências desses distúrbios nos diferentes trechos da rede.


## 5.1 Queda de Tensão

### 5.1.1 Falta de linha

As faltas de linha são os principais causadores de queda de tensão no sistema elétrico. É verdade que outros eventos podem também contribuir com o surgimento desse distúrbio, tais como partida de grandes motores e magnetização de transformador, mas a falta de linha é a mais frequente. Os principais efeitos deste distúrbio são o desligamento de equipamento, redução de vida útil e falha de operação (BORGES, 2013).

Estima-se que 63% das ocorrências de faltas no Sistema Elétrico de Potência (SEP) sejam do tipo fase-terra ( $1\phi$ -terra), 16% entre duas fases e terra ( $2\phi$  – terra), 15% entre duas fases ( $2\phi$ ) e 6% entre três fases ( $3\phi$ ) segundo Kindermann (1997). O modelo de falta simulada está representado na Figura 19, onde  $R_{on}$  é a resistência de falta e  $R_g$  é a resistência à terra.

Figura 19 – Modelagem da Falta



Fonte: Elaborado pelo autor.

A Tabela 15 resume os parâmetros adotados nas 120 simulações realizadas, onde  $R_{on}$  é a resistência de falta e  $R_g$  é a resistência à terra. Já na Figura 20 está representado um sinal padrão de Queda de Tensão, obtido via simulação da equação paramétrica (22), cujos parâmetros estão detalhados em Shen *et al.* (2019):


$$v(t) = [1 - \alpha_{sa}(u(t - t_1) - u(t - t_2))] \sin(\omega t) \quad (22)$$

Tabela 15 – Parâmetros da falta de linha

Parâmetros	Valor
$R_{on}$ ( $\Omega$ )	0,05; 0,1; 0,15; 0,2; 0,25; 0,3; 0,35; 0,4; 0,45; 0,5
$R_g$ ( $\Omega$ )	0,001; 0,01; 0,1; 1
Ângulo de inserção da falta ( $^\circ$ )	0; 45; 90
Tipo de falta	ABCG

Fonte: Elaborado pelo autor.

Figura 20 – Queda de Tensão



Fonte: Elaborado pelo autor.

## 5.2 Distorção Harmônica

### 5.2.1 Ponte retificadora monofásica com capacitor de filtro

As distorções harmônicas foram simuladas considerando o acoplamento de cargas não lineares na rede, que injetam tais distúrbios. A carga não linear é composta basicamente por pontes retificadoras monofásicas em cada fase com capacitores de filtro, que são frequentemente encontradas em equipamentos eletrônicos em residências.

Os parâmetros utilizados para as 216 simulações estão resumidos a seguir, na Tabela 16, onde  $R$  e  $C_{cap}$  são as resistências e as capacitâncias dos filtros capacitivos por fase, indicadas pelo índices  $A$ ,  $B$  e  $C$ .

A Figura 21 representa o modelo simulado no ambiente Simulink, cuja característica pode ser observado pela Figura 22, obtida via simulação da equação paramétrica (23), cujos parâmetros estão detalhados em Shen *et al.* (2019):

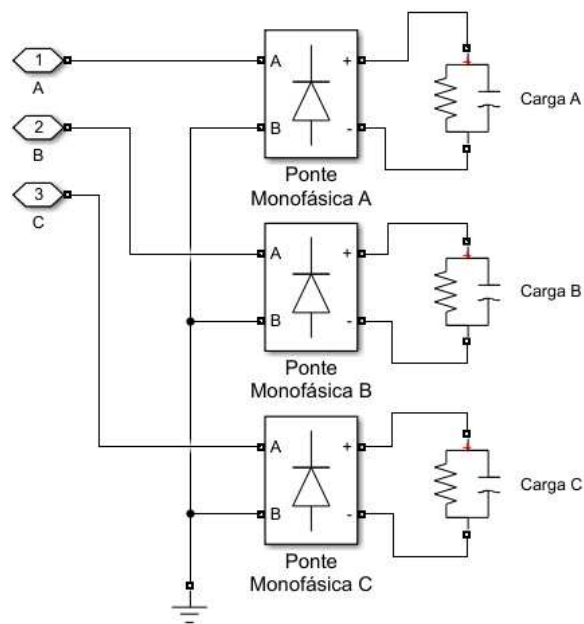
$$v(t) = \alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t) \quad (23)$$

Tabela 16 – Parâmetros para Distorção Harmônica

Parâmetros	Valor
$R_A$ ( $\Omega$ )	10; 10; 30
$R_B$ ( $\Omega$ )	10; 10; 30
$R_C$ ( $\Omega$ )	10; 10; 30
$Cap_A$	$200 \times 10^{-6}$ ; $400 \times 10^{-6}$
$Cap_B$	$200 \times 10^{-6}$ ; $400 \times 10^{-6}$
$Cap_C$	$200 \times 10^{-6}$ ; $400 \times 10^{-6}$

Fonte: Elaborado pelo autor.

Figura 21 – Modelagem da Distorção Harmônica



Fonte: Adaptado de LeSage (2023).


## 5.3 Transiente Impulsivo

### 5.3.1 Descarga atmosférica

Para simulação dos eventos de Transiente Impulsivo, utilizou-se a modelagem de descargas atmosféricas, que são eventos naturais e dos quais estão expostas todas as redes de

distribuição. Para tal, empregou-se uma fonte de tensão controlada em série com um resistor e um indutor para o acoplamento do impulso à rede.

Figura 22 – Distorção Harmônica



Fonte: Elaborado pelo autor.

Este impulso ( $v$ ) é modelado de acordo com a Equação (24), onde  $A$  é a magnitude do impulso,  $\alpha$  é o fator de amortecimento,  $t_1$  é o instante de início do impulso,  $t$  é a variável tempo e  $u$  é a função degrau (TAN; RAMACHANDARAMURTHY, 2015):


$$v = Ae^{-\alpha \cdot |t-t_1|} \cdot u(t-t_1) \quad (24)$$

A característica padrão do impulso é  $1,2/50\mu s$ , ou seja, o impulso sobe em um pico de  $1,2\mu s$  e decai para 50% no tempo de  $50\mu s$ , de acordo com as normas IEEE 1159 (2019) e IEEE C62.41.2 (2002). Na Figura 23 está representado um distúrbio de transiente impulsivo padrão, obtido via simulação da equação paramétrica (25), cujos parâmetros estão detalhados em Shen *et al.* (2019):

$$v(t) = [1 - \alpha_t(u(t-t_1) - u(t-t_2))] \sin(\omega t) \quad (25)$$

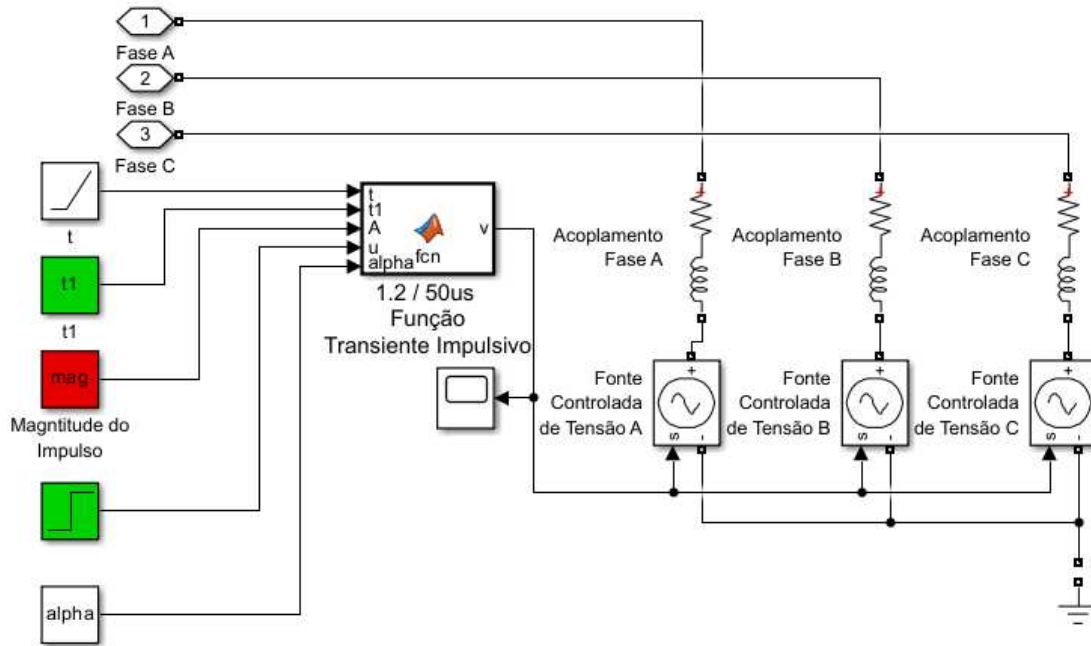
Já na Figura 24, a seguir, está representada a implementação do impulso de tensão para simulação de transiente impulsivo. Os parâmetros adotados nas 320 simulações são os da Tabela 17, que correspondem às variáveis da Equação (24).

Figura 23 – Transiente Impulsivo



Fonte: Elaborado pelo autor.

Figura 24 – Modelagem do Transiente Impulsivo



Fonte: Adaptado de LeSage (2023).

Tabela 17 – Parâmetros para Transiente Impulsivo

Parâmetros	Valor
$A$ (V)	4160; 5200; 6240; 7280; 8320
$\alpha$	$5 \times 10^3$ ; $10 \times 10^3$ ; $15 \times 10^3$
$t_1$ (s)	0,0833 0,0854 0,0875 0,0896 0,0917 0,0938 0,0958 0,0979

Fonte: Elaborado pelo autor.

## 5.4 Transiente Oscilatório


### 5.4.1 Energização de banco de capacitores

Para a simulação dos distúrbios de transiente oscilatório utilizou-se um modelo de banco de capacitores, cuja energização induz tais distúrbios na rede. Estes elementos capacitivos ao longo de redes de distribuição são comuns e frequentes, pois desempenham o papel de compensação do fator de potência da rede. A Figura 25 mostra um exemplo de transiente oscilatório, obtido via simulação da equação paramétrica (26), cujos parâmetros estão detalhados em Shen *et al.* (2019).

$$v(t) = \alpha_t(wt) - e^{-\frac{t-t_1}{\tau}} (u(t-t_2) - u(t-t_1)) \sin(2\pi f_t) \quad (26)$$

O comportamento do Transiente Oscilatório em uma rede de distribuição real é de diminuir sua magnitude de tensão à medida que se propaga a jusante do alimentador. Além disso, a frequência transitória da tensão oscilatória depende diretamente do tamanho do banco de capacitores, desta forma, quanto maior o tamanho, menor será a frequência do transiente de tensão. Finalmente, a velocidade do transiente estabelece sua oscilação dependendo da ordem de grandeza da carga, que quanto mais resistiva, maior será o amortecimento e mais rápida a oscilação transitória.

Figura 25 – Transiente Oscilatório



Fonte: Elaborado pelo autor.

A Tabela 18 resume os parâmetros adotados nas 192 simulações, onde  $C_{ap}$  é a capacitância de cada fase, indicadas pelos índices  $A$ ,  $B$ ,  $C$  e  $t_1$  é o instante de energização do

banco de capacitores.

Tabela 18 – Parâmetros para Transiente Oscilatório

Parâmetros	Valor
$Cap_A$ (kvar)	$50 \times 10^3; 75 \times 100^3; 125 \times 10^3$
$Cap_B$ (kvar)	$50 \times 10^3; 75 \times 100^3; 125 \times 10^3$
$Cap_C$ (kvar)	$50 \times 10^3; 75 \times 100^3; 125 \times 10^3$
$t_1$ (s)	0,0833; 0,0938; 0,1042

Fonte: Elaborado pelo autor.

## 5.5 Considerações do capítulo

Neste capítulo realizou-se a modelagem dos distúrbios de QEE, onde se escolheu quatro principais distúrbios com base na sua frequência de ocorrência na rede. A característica dos sinais respeitam as recomendações da norma (IEEE 1159, 2019), com a taxa de amostragem definida em 10kHz para adequar as especificações dos medidores comerciais disponíveis. No capítulo seguinte será abordado o processo de processamento dos dados e classificação dos sinais a partir dos algoritmos baseados em árvore e da extração de características baseada na Análise Multiresolução de *Wavelet*.



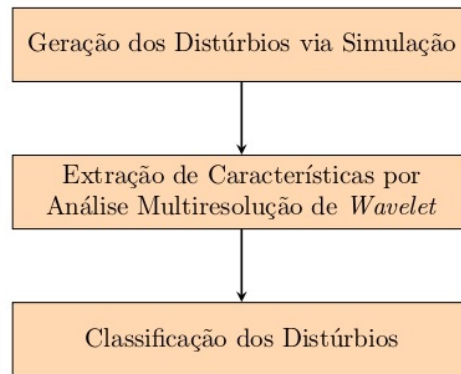
## 6 CLASSIFICAÇÃO DOS DISTÚRBIOS DE QEE

Neste capítulo serão discutidos a metodologia proposta para a obtenção e tratamento dos dados, extração de características via Análise Multiresolução (AMR) de *Wavelet* e os algoritmos de *Machine Learning* (ML) empregados na tarefa de classificar tais distúrbios.

### 6.1 Metodologia proposta

A metodologia proposta consiste em três etapas principais, que estão detalhadas e sequenciadas segundo a Figura 26.

Figura 26 – Etapas da metodologia



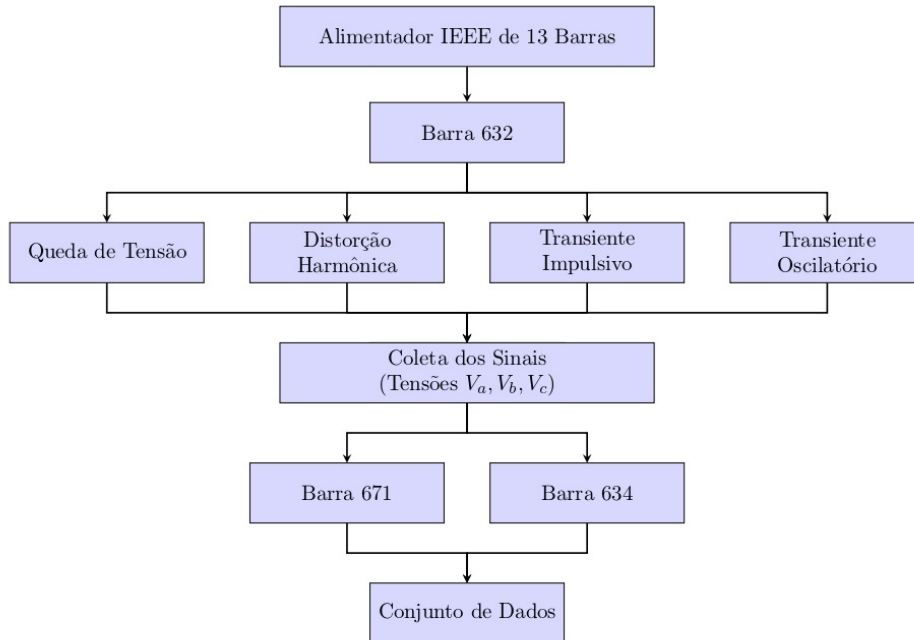
Fonte: Elaborado pelo autor.

Na Etapa 1, de “Geração dos Distúrbios via Simulação”, tem-se a simulação da rede de distribuição denominada Alimentador IEEE de 13 Barras (KERSTING, 2001), que foi modificada neste trabalho a fim de incrementar características de interesse neste estudo que são os efeitos da Geração Distribuída (GD). Desta forma, quatro distúrbios foram simulados, que, somada à classe normal, totalizam cinco classes de sinais simuladas. Além disso, a coleta dos sinais de tensão nas três fases são realizadas em barras estratégicas do sistema, que possuem características distintas entre si, que são a barra 634 localizada em um trecho de baixa tensão e a barra 671 localizada no trecho central, em um trecho de média tensão. A Figura 27, a seguir, representa o fluxo para geração dos distúrbios.

Já na Etapa 2 (Figura 28), a extração de características ocorre por meio da AMR de *Wavelet*, que decompõe cada sinal de tensão em um nível de aproximação e três níveis de detalhe. Um ponto de destaque nesta etapa é o janelamento do sinal, que extrai características em partes diferentes do sinal temporal. Após o janelamento ocorre a decomposição, que extrai a energia

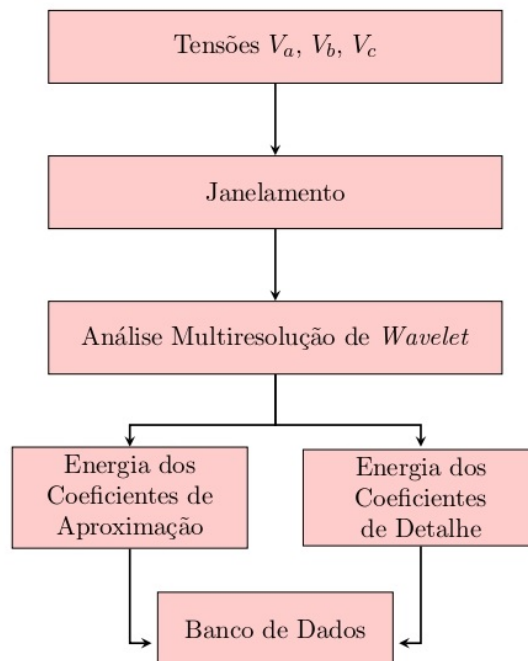
dos coeficientes de aproximação e detalhe da decomposição de *Wavelet*. Após a decomposição, os dados são armazenados e rotulados para formar o banco de dados.

Figura 27 – Etapa 1: Geração dos distúrbios via simulação



Fonte: Elaborado pelo autor.

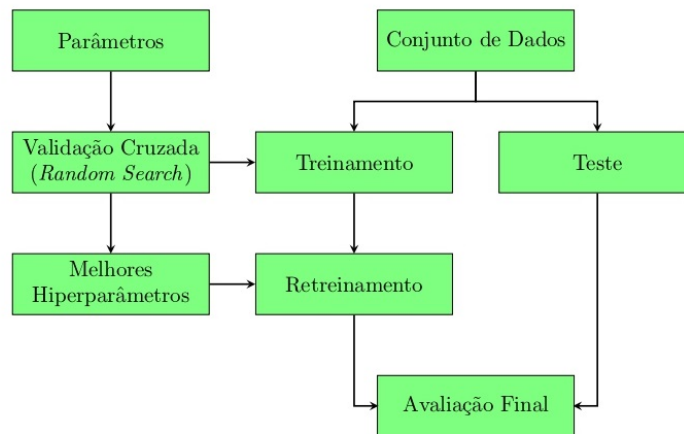
Figura 28 – Etapa 2: Extração de características



Fonte: Elaborado pelo autor.

Finalmente, na Etapa 3 ocorre o treinamento e classificação dos distúrbios com uma otimização aleatória dos hiperparâmetros dos algoritmos empregados. A técnica de validação utilizada é a de Validação Cruzada (do inglês, *Cross Validation*) que ocorre dentro do algoritmo *Random Search*, para otimização de hiperparâmetros. Após o treinamento sucede-se o teste e por fim a avaliação final do algoritmo, onde se pode analisar seu desempenho e aplicabilidade na classificação dos distúrbios. A Figura 29 mostra a sequência de treinamento e classificação dos sinais pelos algoritmos de *Machine Learning*. Para a divisão dos dados, que ocorre de forma aleatória, consideram-se 80% do conjunto de dados para treinamento e validação, e 20% para teste.

Figura 29 – Etapa 3: Classificação dos distúrbios



Fonte: Elaborado pelo autor.

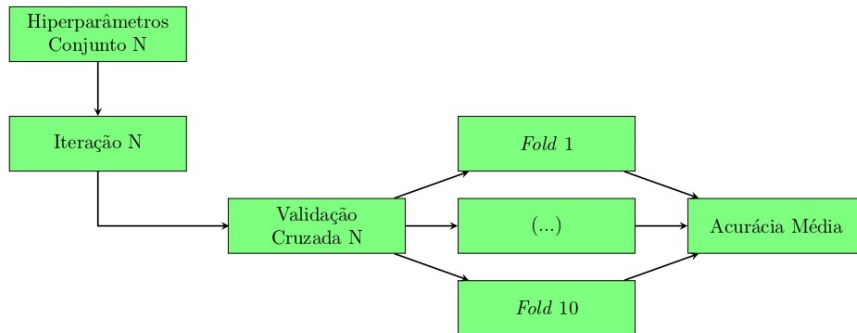
O algoritmo *Random Search* (BERGSTRA; BENGIO, 2012), exibido na Figura (30), implementa testes aleatórios no espaço de hiperparâmetros para obter a combinação com o melhor desempenho. Trata-se de um algoritmo iterável que testa uma combinação de hiperparâmetros de forma aleatória a cada iteração, cuja métrica de desempenho adotada é a acurácia de uma Validação Cruzada do tipo *K-fold*, de acordo a Figura 30. Neste trabalho, são realizadas 10 iterações do algoritmo *Random Search* e em cada iteração ocorre uma validação cruzada com 10 *folds*.

### 6.1.1 Janelamento

Os sinais temporais, após a coleta, são submetidos ao processo de janelamento. Encontra-se na literatura o termo “Janelas Deslizantes” (do inglês, *Sliding Window*) para o método aqui aplicado devido ao fato do sinal ser seccionado em tamanhos (janelas) e deslocamento

(passo) fixo, podendo estas janelas estarem sobrepostas ou não.

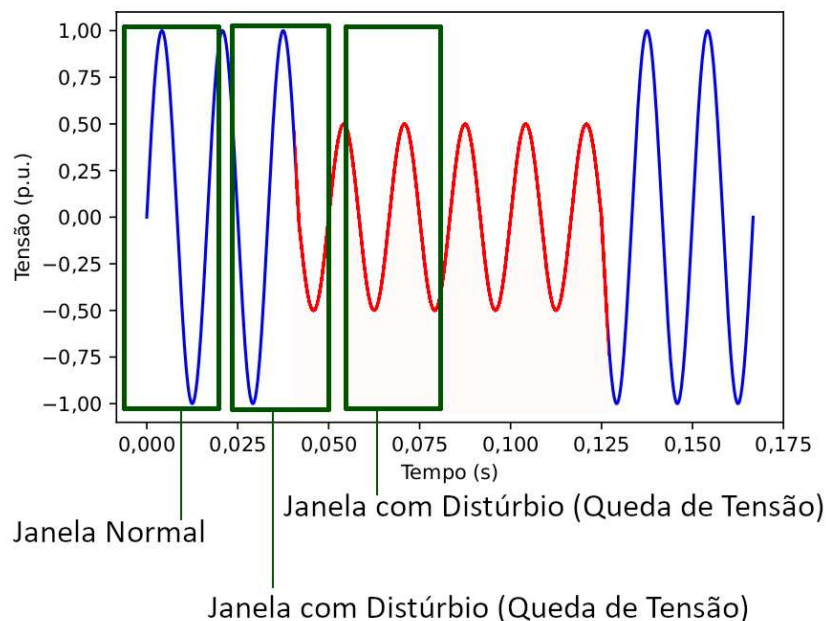
Figura 30 – Validação com *Random Search*



Fonte: Elaborado pelo autor.

A janela é movida ao longo do sinal de entrada com o passo definido, posteriormente a janela é rotulada com a característica que se deseja mapear. O objetivo do janelamento é capturar informações locais e dinâmicas em diferentes segmentos do sinal. Desta forma, o tamanho da janela e o passo são elementos de grande importância na análise, sendo o tamanho do elemento de controle do tamanho do sinal analisado e o passo o elemento de controle de sobreposição, ou seja, quanto menor a sobreposição mais densa será a amostragem do sinal (MUNDANI *et al.*, 2015). A Figura 31, a seguir, ilustra como ocorre este processo, representando três janelas como exemplo.

Figura 31 – Processo de Janelamento



Fonte: Elaborado pelo autor.

Na Figura 31, que é um exemplo de distúrbio de queda de tensão, observa-se que as janelas que contém qualquer segmento do distúrbio é rotulada com o respectivo distúrbio, independente da janela ser composta completamente de um distúrbio ou não, ou seja, se a janela é composta apenas por uma parcela do distúrbio e o restante por um segmento normal, esta janela será rotulada com o distúrbio correspondente, como a segunda e terceira janela (da esquerda para a direita) do exemplo da Figura 31.

## 6.2 Conjunto de dados

Os sinais temporais das ondas de tensão coletados das simulações possuem as quantidades da Tabela 19, cujos valores estão representados por fase.

Tabela 19 – Sinais temporais

Designação	Classe do Sinal	Barra 634	Barra 671
D1	Queda de Tensão	120	120
D2	Distorção Harmônica	216	216
D3	Transiente Impulsivo	320	320
D4	Transite Oscilatório	192	192

Fonte: Elaborado pelo autor.

Os sinais são então submetidos ao processo de janelamento e com seus respectivos rótulos. Após o janelamento, as quantidades de cada sinal (por barra) resultam na Tabela 20.

Tabela 20 – Sinais após janelamento

Classe do Sinal	Barra 634	Barra 671
Normal	41952	41952
Queda de Tensão	9000	9000
Distorção Harmônica	23976	23976
Transiente Impulsivo	7680	7680
Transite Oscilatório	11520	11520

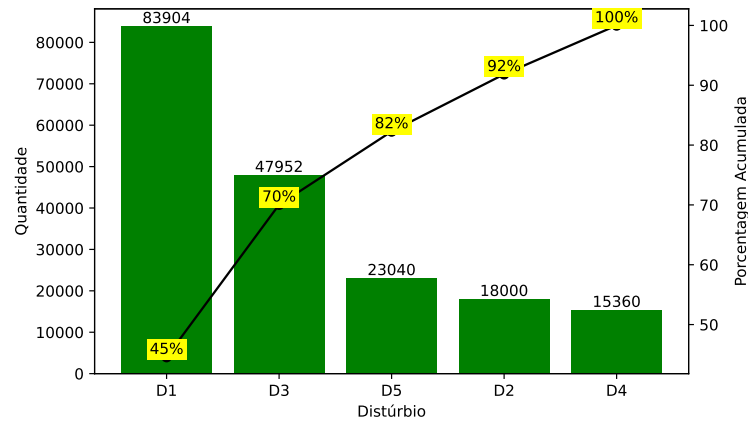
Fonte: Elaborado pelo autor.

Graficamente, a Figura 32 representa a distribuição dos distúrbios no conjunto de dados. Nesta Figura, observa-se que o conjunto de dados está desbalanceado, com predominância da classe “Normal”. Este é um resultado esperado já que os distúrbios surgem em ciclos específicos do sinal e não na sua totalidade, com exceção da classe de distorção harmônica. As denominações das classes, presentes na Figura 32, são descritas segundo a Tabela 19.

A fim de solucionar o problema de desbalanceamento dos dados, aplicou-se o método de balanceamento denominado por *undersamplig*. Nesta técnica as amostras da classe

majoritária são reduzidas, de forma aleatória, à quantidade da classe minoritária para igualar a quantidade de amostras do conjunto de dados. Ao realizar o balanceamento, reduz-se o viés resultante de desproporções significativas no conjunto de dado (XIE *et al.*, 2021). Portanto, após o balanceamento, as quantidades de janelas resultam na Tabela 21.

Figura 32 – Conjunto de dados



Fonte: Elaborado pelo autor.

Tabela 21 – Conjunto de dados após balanceamento

Classe do Sinal	Barra 634	Barra 671
Queda de Tensão	7680	7680
Distorção Harmônica	7680	7680
Transiente Impulsivo	7680	7680
Transite Oscilatório	7680	7680

Fonte: Elaborado pelo autor.

## 6.3 Extração de características

### 6.3.1 Transformada de Wavelet

A extração de características adotada é a técnica da Análise Multiresolução de *Wavelet* com a função *Wavelet*-mãe Daubechies de ordem quatro (db4), que permite analisar e representar sinais temporais em diferentes escalas e frequência.

Definem-se *Wavelets* a família de funções definidas pela Equação (27) (ARRUDA, 2003):

$$\psi_{a,b}(x) = |a|^{-p} \psi\left(\frac{x-b}{a}\right) \quad a, b \in \mathfrak{R} \quad a \neq 0 \quad (27)$$

onde  $x$  pode corresponder ao tempo ou ao espaço e  $p$  o fator de normalização ( $p \geq 0$ ). Estas famílias de funções são geradas a partir de operações de dilatação pelo fator de escala  $a$  e por operações de translação pelo fator  $b$  de uma mesma função  $\psi$  que é dita *Wavelet Mãe* (ARRUDA, 2003).

Existem duas versões da Transformada de *Wavelet* que é a Transformada de *Wavelet* Contínua e a Transformada de *Wavelet* Discreta, sendo esta última a de interesse para o presente trabalho por tratar de dados no domínio discreto e não contínuo.

Em termos de comparação a TW possui diversas vantagens em relação à Transformada de Fourier (TF), que é a técnica mais popular quando se trata em análise de sinais. A TF, em linhas gerais, implementa a transformação do sinal do domínio do tempo para o domínio da frequência, que possui a desvantagem de perder as características do domínio do tempo na análise. Além disso, a TF é limitada a sinais ditos estacionários ou semi-estacionários, que do contrário, apresentará considerável perda de informações. Para corrigir esta limitação desenvolveu-se a *Short-Time Fourier Transform* (STFT), que mapeia o sinal no domínio do tempo e da frequência através de janelas fixas amostradas sequencialmente, mas possuem limitações de precisão devido o tamanho fixo de suas janelas (KAISER, 1994).

Neste sentido, a TW é, na verdade uma evolução da STFT que resolve a limitação da janela fixa substituindo-a por uma janela variável, aplicando uma janela maior para analisar as informações de baixa frequência e uma janela menor para as de alta frequência. As condições para que uma função  $\psi$  seja considerada uma *wavelet* mãe são as seguintes:

- Possui média zero;
- Decair a zero de forma rápida;
- Pertencer ao espaço das funções infinitas.

A Transformada de *Wavelet* Contínua (TWC) é definida segundo a Equação (28) (ARRUDA, 2003):

$$(TWC)(a, b) := |a|^{-\frac{1}{2}} \int_{-\infty}^{\infty} f(x) \psi \left( \frac{x-b}{a} \right) \cdot dx \quad (28)$$

que consiste no mapeamento de um sinal unidimensional  $f(x)$  em uma nova função em um espaço bidimensional em escala  $a$  e translação  $b$ . Em suma, os coeficientes  $(a, b)$  são a representação *Wavelet* do sinal  $f(x)$  em relação à *wavelet* mãe  $\psi(x)$ .

Analogamente, para a TWD, resulta (ARRUDA, 2003):

$$(TWD)(m, n) := |a_0^m|^{-\frac{1}{2}} \sum_n f(n) \psi\left(\frac{x - nb_0^m}{a_0^m}\right) \quad (29)$$

onde  $m$  e  $n$  são parâmetros inteiros tais que  $a = a_0^m$  e  $b = b_0^m$ , que são empregados na geração da família de funções *Waveletss*.

### 6.3.2 Análise Multiresolução de Wavelet

A AMR de *Wavelet* permite analisar sinais e dados em diferentes escalas de detalhe utilizando a transformada de *Wavelet* para decompor um sinal em diferentes componentes, extraindo informações em várias resoluções. Desta forma, ela ocorre pela convolução do sinal com uma função *Wavelet*, que atua como base para esta composição.

A AMR fornece uma representação detalhada das características presentes no sinal, ou seja, as componentes de alta frequência (coeficientes de detalhe) representam os detalhes peculiares, já as componentes de baixa frequência (coeficientes de aproximação) representam as características gerais.

Uma das vantagens da AMR é a possibilidade de reconstruir o sinal original a partir das componentes decompostas, desta forma, é possível reconstruir o sinal com diferentes níveis de detalhe, selecionando as componentes de interesse. Essa propriedade permite adaptar a análise às necessidades específicas do problema em questão. A Figura 33 demonstra como ocorre a decomposição do sinal em diferentes níveis de aproximação e detalhe. Já a Figura 34 mostra um exemplo de decomposição para um sinal de senoide pura, com um nível de aproximação e três níveis de detalhe.

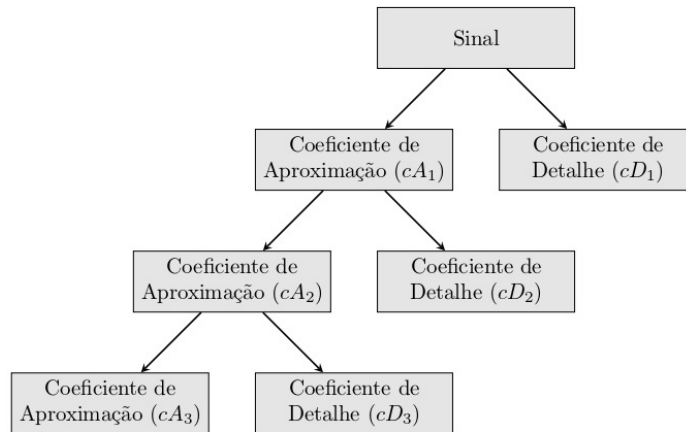
As características obtidas no presente trabalho são as energias dos coeficientes de aproximação e detalhe da decomposição multiresolução de *Wavelet*, que é uma consequência do Teorema da Energia de Parseval (GU; LO, 2010). Que afirma que a energia de um sinal é igual ao somatório das energias concentradas nos diferentes níveis de resolução de sua TW, ou seja, a energia do sinal pode ser decomposta em função dos seus coeficientes da TW, donde resulta:

$$\sum_{n=1}^N |f(n)|^2 = \sum_{n=1}^N |a_j(n)|^2 + \sum_{j=1}^J \sum_{n=1}^N |d_j(n)|^2 \quad (30)$$

onde  $\sum_{n=1}^N |f(n)|^2$  é o sinal amostrado no tempo,  $\sum_{n=1}^N |a_j(n)|^2$  é a energia de aproximação de nível “j” do sinal e  $\sum_{j=1}^J \sum_{n=1}^N |d_j(n)|^2$  são as energias de detalhe dos níveis de 1 a “j” do sinal



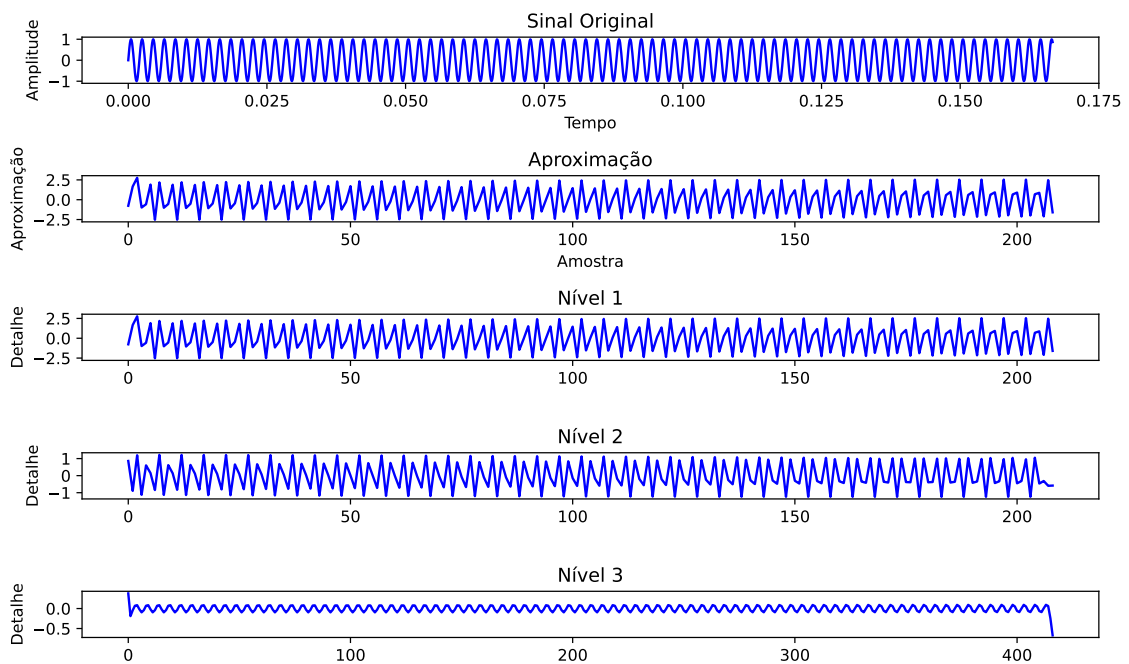
Figura 33 – Decomposição de Wavelet



Fonte: Elaborado pelo autor.

(Medeiros Jr *et al.*, 2006).

Figura 34 – Análise Multiresolução de Wavelet para uma senoide



Fonte: Elaborado pelo autor.

## 6.4 Técnicas de Machine Learning

As técnicas baseadas em árvores de AD e LGBM, utilizadas neste trabalho, se justificam pela popularidade e robustez dos seus resultados, sendo amplamente empregados em problemas de classificação.

### 6.4.1 Árvore de Decisão

O algoritmo denominado Árvore de Decisão é um modelo de ML supervisionado que pode ser implementado em problemas de classificação e regressão, sendo sua versão mais empregada chamada de CART (do inglês, *Classification and Regression Trees*). O objetivo central é obter um modelo capaz de aprender regras de decisão simples inferidas de um banco de dados (BREIMAN *et al.*, 1984).

Então, considerando os vetores  $x_i \in R^n$ , com  $i = 1, \dots, l$  para treinamento e o vetor  $y \in R^l$  para as classes, uma AD é o algoritmo que divide recursivamente o espaço de atributos para que as amostras de mesma classe sejam agrupadas. Por exemplo, seja um nó  $m$  representado por  $Q_m$  com  $N_m$  amostras, para cada divisão possível  $\theta = (j, t_m)$  consistindo de uma característica  $j$  e um limiar  $t_m$ , particiona-se os dados nos subconjuntos  $Q_m^{esquerda}$  e  $Q_m^{direita}$  da seguinte forma (PEDREGOSA *et al.*, 2011):

$$Q_m^{esquerda}(\theta) = (x, y) | x_j \leq t_m \quad (31)$$

$$Q_m^{direita}(\theta) = Q_m / Q_m^{esquerda}(\theta) \quad (32)$$

A qualidade de cada divisão no nó  $m$  é obtida pela função de impureza dada por (PEDREGOSA *et al.*, 2011), onde  $H$  é a função do cálculo de impureza:

$$G(Q_m, \theta) = \frac{N_m^{esquerda}}{N_m} H(Q_m^{esquerda}(\theta)) + \frac{N_m^{direita}}{N_m} H(Q_m^{direita}(\theta)) \quad (33)$$

Na sequência, otimizam-se os parâmetros que minimizam a Equação (33) (PEDREGOSA *et al.*, 2011):

$$\theta^* = \operatorname{argmin}_{\theta} G(Q_m, \theta) \quad (34)$$

Posteriormente, dividem-se novamente os subconjuntos das Equações (31) e (32) até atingir a máxima profundidade permitida (PEDREGOSA *et al.*, 2011):

$$N_m < \min_{amostras} \quad (35)$$

As medidas de impureza mais comuns são o Índice Gini e Entropia. Para o Índice Gini resulta (PEDREGOSA *et al.*, 2011):

$$H(Q_m) = \sum_k p_{mk}(1 - p_{mk}) \quad (36)$$

Analogamente para a Entropia (PEDREGOSA *et al.*, 2011):

$$H(Q_m) = - \sum_k p_{mk} \log(p_{mk}) \quad (37)$$

onde  $p_{mk}$  é a proporção de observações da classe  $k$  no nó  $m$  (PEDREGOSA *et al.*, 2011):

$$p_{mk} = \frac{1}{N_m} \sum_{y \in Q_m} I(y = k) \quad (38)$$

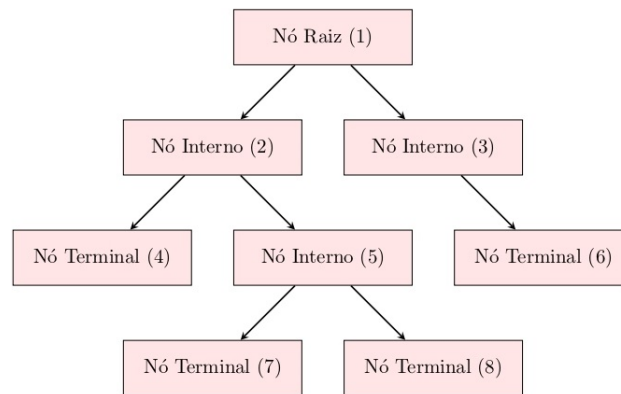
Os principais hiperparâmetros para Árvore de Decisão, e sua respectiva descrição estão descritos na Tabela 22. Entre as vantagens das ADs destacam-se a interpretabilidade das regras de decisão e a possibilidade de visualização, ou seja, é baseada em um modelo “caixa branca”; requer mínimo pré-processamento dos dados; e é capaz de classificar múltiplas classes. Como desvantagens, destaca-se a tendência à sobreajuste (*overfitting*), que pode ser minimizada através do procedimento de poda; é propensa a ser enviesada caso o banco de dados não seja balanceado; e podem ser instáveis à variações nos dados resultando em árvores diferentes da obtida antes da variação (PEDREGOSA *et al.*, 2011). A Figura 35 representa uma árvore de decisão genérica, com as indicações de nó raiz, nós internos e terminais (classes).

Tabela 22 – Principais hiperparâmetros para AD

Hiperparâmetro	Descrição
<i>max_depth</i>	Profundidade máxima da árvore
<i>criterion</i>	Medida de qualidade da divisão em um nó da árvore
<i>min_samples_split</i>	Quantidade mínima de amostras em um nó
<i>min_samples_leaf</i>	Quantidade mínima de amostras em uma folha
<i>max_features</i>	Quantidade máxima de características a serem consideradas em cada divisão de nó

Fonte: Elaborado pelo autor.

Figura 35 – Modelo de Árvore de Decisão



Fonte: Elaborado pelo autor.

#### 6.4.2 *Light Gradient Boosting*

Algoritmo de LGBM é uma técnica baseada em *Gradient Boosting* que emprega AD como estimadores base. O algoritmo inicia pela definição de seus hiperparâmetros e inicializa o modelo com um valor inicial para a predição, que pode ser a probabilidade média de cada classe no conjunto de treinamento. Em seguida, calculam-se as probabilidades iniciais para cada classe usando uma função de transformação como a *sigmoid* ou *softmax* (KE *et al.*, 2017).

Na sequência constroem-se as árvores pela divisão dos dados de treinamento em conjuntos com base nas características e valores preditivos empregando o cálculo do ganho de informação pela Entropia ou Índice Gini, por exemplo. Assim, calcula-se o ganho de informação para todas as possíveis divisões e escolhe-se a divisão que otimiza a homogeneidade dos grupos resultantes. Esta sequência se repete até atingir uma profundidade limite ou quando a divisão não melhora.


O próximo passo é a atualização das probabilidades onde a probabilidade atual da árvore para cada amostra de treinamento é recalculada. Atualizam-se as probabilidades gerais do modelo realizando a soma das probabilidades atuais ponderadas pelo valor de *Learning Rate*, que é taxa de aprendizado que controla a contribuição de cada uma das árvores para a probabilidade final do modelo para não ocorrer o caso de uma árvore ter um impacto excessivo.

Em seguida calcula-se a função perda do modelo baseado nas probabilidades atualizadas e nos rótulos verdadeiros, com uma função como a “*log loss*” por exemplo. A próxima etapa é a atualização das probabilidades com “*gradient boosting*” onde o gradiente da função de perda é calculada em relação às probabilidades atuais (KE *et al.*, 2017).

Finalmente, ocorre a combinação das árvores após a construção de várias árvores,

onde as probabilidades de cada árvore são somadas e normalizadas para obter as probabilidades finais do modelo. É importante destacar que este modelo cresce verticalmente, ou seja, o algoritmo seleciona a folha que tenha a máxima determinação do delta de perda para crescer (“*delta loss to grow*”). A criação das árvores ocorre de maneira paralela empregando uma estratégia conhecida como “leaf-wise” como mostra a Figura 36.

Figura 36 – Modelo de LightLGBM



Fonte: Microsoft Corporation (2023)

Este algoritmo é referenciado na literatura pela rapidez de processamento, capacidade de trabalhar com grandes conjuntos de dados com menos memória e suporte a GPU *learning* por exemplo. Os principais hiperparâmetros para *LightGBM*, com sua respectiva descrição, estão descritos segundo a Tabela 23.

Tabela 23 – Principais Hiperparâmetros para LGBM

Hiperparâmetro	Descrição
<i>boosting_type</i>	Tipo de <i>boosting</i> empregado
<i>num_leaves</i>	Quantidade máxima de folhas em uma árvore
<i>learning_rate</i>	Taxa de aprendizado
<i>n_estimators</i>	Número de estimadores (árvores)
<i>min_child_samples</i>	Quantidade mínima de amostras em um nó
<i>reg_alpha</i>	Parâmetro de regularização <i>L1</i>
<i>reg_lambda</i>	Parâmetro de regularização <i>L2</i>

Fonte: Elaborado pelo autor.

## 6.5 Métricas de avaliação

As medidas de avaliação de modelos empregadas neste trabalho serão a Matriz de Confusão, Acurácia, Precisão, Sensibilidade e Medida-F.

### 6.5.1 Matriz de Confusão

Entende-se por Matriz de Confusão a tabela que exhibe o desempenho de um algoritmo de classificação, onde as colunas são as instâncias previstas e as linhas as instâncias reais. Através dele é possível analisar a quantidade de verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN). A Figura 37 mostra um exemplo desta matriz para duas classes.

Figura 37 – Exemplo de Matriz de Confusão

		Classificação Prevista	
		Positivo	Negativo
Classificação Real	Positivo	<b>VP</b>	FN
	Negativo	FP	<b>VN</b>

Fonte: Elaborado pelo autor.

As definições para os termos VP, VN, FP e FN são dadas como segue (DUDA; STORK, 2001):

- Verdadeiros Positivos: quando o modelo classifica como positiva uma instância que é realmente positiva;
- Verdadeiro Negativo: quando o modelo classifica como negativa uma instância que é realmente negativa;
- Falso Positivo: quando o modelo classifica como positiva uma instância que é realmente negativa;
- Falso Negativo: quando o modelo classifica como negativa uma instância que é realmente positiva.

### 6.5.2 Acurácia

A acurácia (ACC) é a métrica de avaliação em problemas de classificação que representa o percentual de instâncias classificadas corretamente em relação ao total de instâncias. É calculada de acordo com a Equação (39) (DUDA; STORK, 2001):

$$ACC = \frac{\sum VP + \sum VN}{\sum VP + \sum VN + \sum FP + \sum FN} \quad (39)$$

Pode não ser adequada para conjuntos de dados desbalanceados, sendo necessário neste caso a análise de métricas como precisão, sensibilidade e Medida-F.

### 6.5.3 *Precisão*

A precisão é a métrica que avalia o percentual de instâncias positivas classificadas corretamente em relação ao total de instâncias classificadas como positivas. É calculada de acordo com a Equação (40) (DUDA; STORK, 2001):

$$Precisao = \frac{\sum VP}{\sum VP + \sum FP} \quad (40)$$

Altos valores para precisão indicam baixas taxas de FP ao passo que baixos valores de precisão indicam altas de FP. É indispensável quando o objetivo é a minimização de FP.

### 6.5.4 *Sensibilidade*

A sensibilidade é a métrica que avalia o percentual de instâncias positivas classificadas corretamente em relação ao total de instâncias positivas. É calculada de acordo com a Equação (41) (DUDA; STORK, 2001):

$$Sensibilidade = \frac{\sum VP}{\sum VP + \sum FN} \quad (41)$$

Esta métrica avalia a capacidade do modelo de identificar corretamente as instâncias positivas. É indispensável quando o objetivo é minimizar FN.

### 6.5.5 *Medida-F*

A Medida-F é uma métrica que combina a precisão e a sensibilidade, ou seja, é uma medida balanceada do desempenho do modelo. É calculada de acordo com a Equação (42) (DUDA; STORK, 2001):

$$Medida F = \frac{2 \cdot Precisao \cdot Sensibilidade}{Precisao + Sensibilidade} \quad (42)$$

## 6.6 Considerações do capítulo

Neste capítulo foram abordados as etapas da metodologia proposta e sua respectiva fundamentação teórica. Abordou-se também o funcionamento dos processamentos de janelamento e de extração de características com a AMR de *Wavelet*. Além disso, estabeleceram-se os classificadores baseados em árvore e suas métricas de avaliação para análise de desempenho dos algoritmos de classificação. No capítulo seguinte será exibida os resultados de desempenho para os dois classificadores utilizados, bem como realizada a discussão sobre o desempenho dos sinais coletados nas diferentes barras do sistema.



## 7 RESULTADOS

Neste capítulo serão apresentados os resultados das simulações do Alimentador IEEE de 13 Barras, bem como os resultados de desempenho dos algoritmos Árvore de Decisão e *LightGBM* na classificação dos distúrbios de QEE, que são discutidos e comparados com trabalhos similares.


### 7.1 Resultados para Simulação dos Distúrbios

Os sinais coletados nas barras 634 e 671 são semelhantes com os da literatura, apresentando diferenças nas magnitudes de tensão entre as duas barras consideradas, que se apresenta de forma mais intensa para a barra mais próxima e menos intensa para a barra mais distante. Em cada figura exibida nesta seção, disponíveis nas barras 634 e 671, há um sinal com um distúrbio escolhido de forma aleatória entre todos os sinais disponíveis de sua respectiva classe.

#### 7.1.1 Queda de Tensão

Os sinais de Queda de Tensão são exibidos, a seguir, nas Figuras 38 e 40, respectivamente. Nota-se que a barra 634, que está no trecho de baixa tensão, possui menor interferência de transitórios oscilatórios em comparação com a barra 671. Isto se explica pelo fato da barra 634 estar próxima ao transformador abaixador da rede, que está aterrado tanto no lado da fonte como no lado da carga, que resulta em um elemento de estabilidade para a tensão. Além disso, o perfil das cargas nesta barra, sem componentes capacitivos, também contribui para esta característica.


Figura 38 – Queda de Tensão (Barra 634)



Fonte: Elaborado pelo autor.

Por outro lado, a Figura 39 ilustra a dinâmica do distúrbio em valores eficazes ou *Root Mean Square* (RMS), onde se nota maior agravamento na fase A, que é a mais carregada segundo a Tabela 10.


Figura 39 – Queda de Tensão RMS (Barra 634)



Fonte: Elaborado pelo autor.

Já para a barra 671 observa-se a presença de interferências oscilatórias nos instantes de início e término do distúrbio, cuja explicação está embasada na sua localização, próxima aos capacitores nas barras 611 e 675, que contribuem diretamente para o surgimento dessas oscilações e também pela ausência de elementos de estabilidade tais como o aterramento presente na barra 634.

Figura 40 – Queda de Tensão (Barra 671)




Fonte: Elaborado pelo autor.

A Figura 41 representa o distúrbio em valores RMS, onde a fase B é a mais agravada por ser a fase mais carregada nesta barra. Vale ressaltar que tais desequilíbrios são inerentes aos sistemas de distribuições devido à grande variedade de cargas a ela acopladas e pela presença de

cargas monofásicas, bifásicas e trifásicas cuja distribuição uniforme ao longo do alimentador nem sempre é possível.

Figura 41 – Queda de Tensão RMS (Barra 671)




Fonte: Elaborado pelo autor.

Comparando as Figuras 38 e 40 conclui-se que os sinais obtidos por simulações possuem a grande vantagem de absorver características mais realistas dos distúrbios em comparação com os sinais obtidos via equações paramétricas, como exibido na Figura 20.

### 7.1.2 Distorção Harmônica

O sinal para Distorção Harmônica na barra 634 é exibido na Figura 42 onde as fases são afetadas de maneira diferente em virtude da assimetria do sistema.

Figura 42 – Distorção Harmônica (634)




Fonte: Elaborado pelo autor.

Para a fase C da Figura 42, por exemplo, a Figura 43 exibe o espectro de frequências, onde há predominância da 3ª (180Hz) e 7ª harmônica (420Hz), que representam aproxima-

damente 6% e 3,2% da magnitude da onda na frequência fundamental, respectivamente. Em seguida, percebe-se a 5ª harmônica (300Hz) com quase 2%.


Figura 43 – Distorção Harmônica FFT (634)



Fonte: Elaborado pelo autor.

A Figura 44 exibe o mesmo distúrbio para a barra 671, que apresenta maior intensidade desta anomalia em comparação com a barra 634 não só pelo fato de possuir carga capacitiva acoplada, como também pelo fato de estar próxima ao sistema de geração fotovoltaico.


Figura 44 – Distorção Harmônica (671)



Fonte: Elaborado pelo autor.

O espectro de frequências para a Fase C é exibido na Figura 45, com maior destaque para 3ª e 7ª harmônicas, cada uma com aproximadamente 6% da magnitude da onda na frequência fundamental, e em menor intensidade para 5ª e 11ª harmônicas, com aproximadamente 2,1% e 0,9% da frequência fundamental.

Figura 45 – Distorção Harmônica FFT (Barra 671)




Fonte: Elaborado pelo autor.

### 7.1.3 Transiente Impulsivo

Para o distúrbio de Transiente Impulsivo, a Figura 46 representa um sinal com impulso em 0,0917s, com magnitude próxima 1kV, medida na barra 634.

Figura 46 – Transiente Impulsivo (Barra 634)




Fonte: Elaborado pelo autor.

A barra 671, exibida na Figura 47, possui grande diferença em comparação com a 634 em relação à magnitude do impulso. Enquanto na primeira barra a anomalia é medida de forma expressiva, na segunda ela se apresenta de maneira atenuada. A explicação para este fenômeno está nas distâncias das barras em relação ao ponto do impulso, com a barra 634 distando 152,4m e a barra 671 distando 609,6m. Por se tratar de um evento de curta duração, quanto mais distante do impulso a barra estiver, menor será sua intensidade, além dos diferentes perfis de carga em cada barra, que contribuem de maneira distinta para a dissipação do impulso. Outro elemento que possui influência direta na magnitude é o ângulo de inserção do impulso,

neste caso, um impulso em ângulos cuja tensão sejam próximas do pico irão resultar em impulsos mais severos.


Figura 47 – Transiente Impulsivo (Barra 671)



Fonte: Elaborado pelo autor.

A Figura 48 mostra o impulso inserido nas Figuras 46 e 47, onde a linha pontilhada representa o instante de decaimento em 50% do seu valor máximo, que ocorre aproximadamente  $50\mu s$  após o início do impulso, obedecendo às determinações das normas IEEE 1159 (2019) e IEEE C62.41.2 (2002).

Figura 48 – Impulso de tensão




Fonte: Elaborado pelo autor.

#### 7.1.4 Transiente Oscilatório

Os sinais para Transiente Oscilatório e seu espectro de frequência para a barra 634 estão representados nas Figuras 49 e 50, respectivamente. Neste caso, a distância também desempenha uma forte influência na expressividade do distúrbio em cada barra, com a mais

próxima observando a anomalia de forma mais intensa.


Figura 49 – Transiente Oscilatório (Barra 634)



Fonte: Elaborado pelo autor.

Na Figura 50 temos o espectro da fase B, onde se observa a presença de harmônicas não inteiras da frequência fundamental, também chamadas de inter-harmônicas, cujo surgimento é característico de cargas não-lineares, como a frequência de 100Hz, por exemplo, que representa aproximadamente 17% da magnitude da onda na frequência fundamental.


Figura 50 – Transiente Oscilatório FFT (Barra 634)



Fonte: Elaborado pelo autor.


Na Figura 51, que mostra o distúrbio na barra 671, a distância da anomalia à barra dissipa parte do transitório, que é mais atenuada em comparação com a barra 634. Além disso, na Figura 52 observam-se frequências mais significativas para a fase B, também com a presença de inter-harmônicas.

Figura 51 – Transiente Oscilatório (Barra 671)



Fonte: Elaborado pelo autor.

Figura 52 – Transiente Oscilatório FFT (Barra 671)



Fonte: Elaborado pelo autor.

## 7.2 Resultados para AD

### 7.2.1 Treinamento e validação

Durante o treinamento e validação, que utiliza 80% do conjunto de dados, escolheu-se os melhores hiperparâmetros para a AD a partir de 10 iterações do algoritmo de otimização *Random Search*. Estes hiperparâmetros estão detalhados na Tabela 24.

Tabela 24 – Hiperparâmetros para AD

Hiperparâmetro	Espaço de Busca	Melhor Hiperparâmetro
<i>max_depth</i>	[Nenhum, 50, 100, 150, 200, 300]	200
<i>criterion</i>	[ <i>entropy</i> , <i>gini</i> , <i>log_loss</i> ]	<i>entropy</i>
<i>min_samples_split</i>	[2, 3, 4, 5]	2
<i>min_samples_leaf</i>	[1, 2, 3, 4, 5]	1
<i>max_features</i>	[Nenhum, <i>sqrt</i> , <i>log2</i> ]	Nenhum


Fonte: Elaborado pelo autor.



Da Tabela 24, conclui-se que a melhor configuração de AD está limitada a uma profundidade (níveis) de 200 (*max\_depth*), com o critério *entropy* resultando nas maiores taxas de acerto. Além disso, a quantidade mínima para uma divisão de nó interno é igual a 2 (*min\_samples\_split*) e cada folha (nó terminal) deve ter no mínimo 1 amostra de dados (*min\_samples\_leaf*). Por fim, verificou-se que a AD obteve o melhor resultado para o caso em que não possui número máximo de características na divisão de cada nó (*max\_features*).

Vale lembrar que são realizadas 10 iterações do algoritmo *Random Search*, e em cada iteração os dados são divididos em 10 *folds* para a validação cruzada, onde uma combinação diferente de hiperparâmetros é testada. Isto posto, a Figura 53 mostra a acurácia para os *folds* da melhor das 10 iterações, ou seja, com a maior taxa de classificação correta.

Figura 53 – Acurácia por fold da validação cruzada (AD)



Fonte: Elaborado pelo autor.

Nota-se da figura que todos os *folds* possuem elevadas taxas de acerto, com a diferença entre a maior e a menor acurácia não ultrapassando 0,7%. Este resultado é um indicativo da não existência de *overfitting*, ou seja, sobreajuste da AD.

### 7.2.2 Teste

Para a etapa de teste, que utiliza 20% do conjunto de dados não utilizados no treinamento, a Tabela 25 resume as principais métricas de avaliação obtidos para a mais acurada AD obtida entre as 10 iterações no treinamento. Observa-se que os sinais provenientes da barra 634 possuem as maiores métricas, que se justifica no fato desta barra ser a mais próxima do ponto do distúrbio. A classe de Queda de Tensão obteve a maior taxa de acerto em virtude da grande variação de energia do sinal durante a sua ocorrência, que facilita sua aprendizagem pelo

modelo de AD. Este modelo obteve acurácia geral de **98,31%** durante o teste.

Tabela 25 – Desempenho da AD

Classe	Precisão	Sensibilidade	Medida-F
Queda de Tensão (Barra 634)	<b>0,994175</b>	<b>0,993532</b>	<b>0,993853</b>
Queda de Tensão (Barra 671)	0,989973	0,991962	0,990967
Distorção Harmônica (Barra 634)	0,986211	0,984918	0,985564
Distorção Harmônica (Barra 671)	0,978288	0,979503	0,978895
Normal (Barra 634)	0,977079	0,979003	0,978040
Normal (Barra 671)	0,976728	0,966148	0,971409
Transiente Impulsivo (Barra 634)	0,990789	0,988189	0,989488
Transiente Impulsivo (Barra 671)	0,982997	0,989854	0,986414
Transiente Oscilatório (Barra 634)	0,984046	0,986564	0,985304
Transiente Oscilatório (Barra 671)	0,970414	0,970414	0,970414
Valor médio	0,983070	0,983009	0,983035

Fonte: Elaborado pelo autor.

Além disso, Transiente Oscilatório e a classe Normal desempenharam os menores resultados. Uma explicação para este desempenho está na semelhança destas classes com outros eventos da rede, tais como chaveamentos ou efeitos de interferência das cargas. Ademais, as janelas de sinais que possuem uma parte normal e outra parte com distúrbio são mais difíceis de serem classificadas, pois não são totalmente anômalas nem totalmente normais, situação esta que ocorre normalmente na transição entre o estado normal para o estado de distúrbio do sinal. Finalmente, a Tabela 26 exibe a Matriz de Confusão para a AD.

Tabela 26 – Matriz de confusão para AD

Classes	a	b	c	d	e	f	g	h	i	j
a = Queda de Tensão (634)	<b>1536</b>	0	1	0	7	0	0	0	2	0
b = Queda de Tensão (671)	0	<b>1481</b>	0	2	0	1	0	2	0	7
c = Distorção Harmônica (634)	0	0	<b>1502</b>	0	6	0	0	0	17	0
d = Distorção Harmônica (671)	0	0	0	<b>1577</b>	0	9	0	0	0	24
e = Normal (634)	5	0	7	0	<b>1492</b>	0	14	0	6	0
f = Normal (671)	0	3	0	8	0	<b>1427</b>	0	25	0	14
g = Transiente Impulsivo (634)	1	0	0	0	17	0	<b>1506</b>	0	0	0
h = Transiente Impulsivo (671)	0	2	0	0	0	14	0	<b>1561</b>	0	0
i = Transiente Oscilatório (634)	3	0	13	0	5	0	0	0	<b>1542</b>	0
j = Transiente Oscilatório (671)	0	10	0	25	0	10	0	0	0	<b>1476</b>

Fonte: Elaborado pelo autor.

Na tabela, os erros da classe Normal são devido a classificações equivocadas entre as janelas que antecedem ou sucedem o evento anômalo, ou seja, na região de limiar do distúrbio. A classe de Queda de Tensão obteve o melhor desempenho, seguido de Transiente Impulsivo, Distorção Harmônica e Transiente Oscilatório, com resultados superiores para os sinais oriundos da barra 634.

## 7.3 Resultados para LGBM

### 7.3.1 Treinamento e validação

De forma análoga à AD, a Tabela 27 exhibe os melhores hiperparâmetros obtidos durante o treinamento e validação do classificador LGBM.


Tabela 27 – Hiperparâmetros para LGBM

Hiperparâmetro	Espaço de Busca	Melhor Hiperparâmetro
<i>boosting_type</i>	[ <i>gbdt, dart, goss</i> ]	<i>dart</i>
<i>num_leaves</i>	[300, 400, 500]	300
<i>learning_rate</i>	[0,4, 0,5, 0,6]	0,4
<i>n_estimators</i>	[100, 200, 300]	200
<i>min_child_samples</i>	[20, 30, 50]	30
<i>reg_alpha</i>	[0, 0,1, 0,2]	0,2
<i>reg_lambda</i>	[0, 0,2, 0,3]	0,2

Fonte: Elaborado pelo autor.

Da tabela, conclui-se que o melhor tipo de *boosting* (*boosting\_type*) é o ‘*dart*’ que significa *Dropouts meet Multiple Additive Regression Trees*. A quantidade de estimadores é configurado para 300 (*n\_estimators*) com taxa de aprendizado de 0,4 (*learning\_rate*). Além disso, é necessário 30 ou mais amostras para cada divisão de nó (*min\_child\_samples*) com 0,2 para os coeficientes de regularização L1 (*reg\_alpha*) e L2 (*reg\_lambda*). Ademais, a Figura 54 mostra as acurácias para cada *fold* durante a melhor iteração de *Random Search*.

Figura 54 – Acurácia por fold da validação cruzada (LGBM)



Fonte: Elaborado pelo autor.

Assim como o classificador AD, as altas acurácias por *fold* também indicam ausência

de *overfitting*, sendo 0,5% a diferença entre a maior e a menor acurácia entre os 10 *folds* do classificador LGBM.

### 7.3.2 Teste

Na etapa de teste, a acurácia geral obtida foi de **98,75%**, que representa ganho de 0,44% em relação ao teste da AD. A Tabela 28 resume o desempenho obtido para o classificador LGBM, onde a classe Queda de Tensão obteve o maior valor para Precisão e Medida-F, e Transiente Impulsivo para sensibilidade, com os melhores resultados obtidos na barra 634. As menores métricas foram obtidas pela classe Normal e Transiente Oscilatório na barra 671, pelo mesmo motivo discutido na seção passada, que consiste na dificuldade maior dos classificadores em distinguir as janelas de sinais no limiar dos distúrbios.

Tabela 28 – Desempenho da LGBM

Classe	Precisão	Sensibilidade	Medida-F
Queda de Tensão (Barra 634)	<b>0,996745</b>	0,990298	<b>0,993511</b>
Queda de Tensão (Barra 671)	0,993939	0,988614	0,991269
Distorção Harmônica (Barra 634)	0,988251	<b>0,992787</b>	0,990514
Distorção Harmônica (Barra 671)	0,983292	0,986957	0,985121
Normal (Barra 634)	0,986120	0,979003	0,982549
Normal (Barra 671)	0,982204	0,971564	0,976855
Transiente Impulsivo (Barra 634)	0,990202	0,994751	0,992471
Transiente Impulsivo (Barra 671)	0,985535	0,993659	0,989580
Transiente Oscilatório (Barra 634)	0,990446	0,994882	0,992659
Transiente Oscilatório (Barra 671)	0,978375	0,981591	0,979980
Valor médio	0,987511	0,987410	0,987451

Fonte: Elaborado pelo autor.

Finalmente, a Tabela 29 mostra a Matriz de Confusão, onde se destacam os 22 elementos da classe Distorção Harmônica classificadas como Transiente Oscilatório, 20 elementos da classe Normal classificadas como Transiente Impulsivo e 18 elementos de Transição Oscilatório classificadas como Distorção Harmônica, sendo estes os maiores erros do classificador.

## 7.4 Comparação de resultados

A fim de analisar o desempenho do método proposto neste trabalho com os da literatura, a Figura 30 mostra uma comparação com 3 trabalhos da área. Para os resultados do método proposto consideram-se os resultados do classificador que obteve maior acurácia geral no teste na barra com a maior taxa de acerto, ou seja, o classificador LGBM e a barra 634. Além

disso, os trabalhos comparados adotam metodologias baseadas em equações paramétricas com adição de ruído branco.

Tabela 29 – Matriz de confusão para LGBM

Classes	a	b	c	d	e	f	g	h	i	j
a = Queda de Tensão (634)	<b>1531</b>	0	1	0	11	0	0	0	3	0
b = Queda de Tensão (671)	0	<b>1476</b>	0	3	0	9	0	2	0	3
c = Distorção Harmônica (634)	0	0	<b>1514</b>	0	1	0	0	0	10	0
d = Distorção Harmônica (671)	0	0	0	<b>1589</b>	0	3	0	0	0	18
e = Normal (634)	5	0	10	0	<b>1492</b>	0	15	0	2	0
f = Normal (671)	0	3	0	6	0	<b>1435</b>	0	21	0	12
g = Transiente Impulsivo (634)	0	0	0	0	8	0	<b>1516</b>	0	0	0
h = Transiente Impulsivo (671)	0	1	0	0	0	9	0	<b>1567</b>	0	0
i = Transiente Oscilatório (634)	0	0	7	0	1	0	0	0	<b>1555</b>	0
j = Transiente Oscilatório (671)	0	5	0	18	0	5	0	0	0	<b>1493</b>

Fonte: Elaborado pelo autor.

Desta forma, a Tabela 30 resume a comparação de sensibilidade de alguns trabalhos da literatura onde se nota aumento de desempenho ao longo do tempo, de 2008 a 2023, onde o método proposto possui vantagem, por conter sinais mais realistas do que as metodologias baseadas em equações paramétricas dos métodos comparados.

Tabela 30 – Comparação de resultados

Distúrbio	Mishra <i>et al.</i> (2008)	Khokhar <i>et al.</i> (2015)	Proposto
Queda de Tensão	98%	92%	<b>99,96%</b>
Distorção Harmônica	95%	95%	<b>99,27%</b>
Transiente Impulsivo	86%	86%	<b>99,47%</b>
Transiente Oscilatório	86%	86%	<b>99,48%</b>
Classificador	PNN	PNN	LGBM
Extração de características	Transf. de <i>Stockwell</i>	Transf. de <i>Wavelet</i>	Transf. de <i>Wavelet</i>
Taxa de amostragem	3,2kHz	10kHz	10kHz

Fonte: Elaborado pelo autor.

Na Tabela 30, o trabalho de Mishra *et al.* (2008) está baseado no desvio padrão e na energia da Transformada de *Stockwell*, enquanto o de Khokhar *et al.* (2015) se baseia na entropia normalizada da Transformada de *Wavelet*. Finalmente, no método proposto utiliza-se a energia da Transformada de *Wavelet*, que se traduziu em resultados melhores que os demais, além disso, a frequência de 10kHz corresponde a um valor mais adequado de amostragem, prevendo a compatibilidade com os medidos de energia disponíveis no mercado.

## 7.5 Considerações do capítulo

Neste capítulo foram apresentados os sinais coletadas via simulação do Alimentador IEEE de 13 Barras e explanados os desempenhos da *Árvore de Decisão* e do *Light Gradient Boosting*. Os sinais coletados são coerentes com a literatura e representam as dinâmicas das cargas de maneira satisfatória, sendo, esta, uma vantagem em comparação aos sinais obtidos por equações paramétricas. Os sinais obtidos a partir da barra 634 resultaram em taxas de classificação corretas maiores que as demais, em virtude da diferença energética dos estados de distúrbios e não distúrbio deste evento ser mais acentuado. Além disso, a barra mais distantes observa os distúrbios de maneira mais atenuada, em virtude da dissipação do evento ao longo da rede. Finalmente, os erros das matrizes de confusão se justificam majoritariamente pela dificuldade na classificação de janelas de sinais referentes a transição do estado normal para o distúrbio, que naturalmente será mais difícil sua distinção pelo classificador. Ressalta-se também que diferentes configurações de transformadores podem contribuir de maneira diferente na propagação dos distúrbios.

## 8 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou uma abrangente metodologia para modelagem, processamento e classificação de sinais de distúrbios de qualidade de energia em um sistema de distribuição radial com geração distribuída, utilizando para isso o Alimentador IEEE de 13 Barras com adição de uma fonte de geração solar fotovoltaica.

Os sinais coletados em duas barras estratégicas do sistema seguiram as recomendações da literatura aplicável e os sinais coletados possuem as características esperadas, consistindo, portanto, em sinais mais realistas do que os obtidos pela abordagem tradicional baseada em equações paramétricas com adição de ruído branco. Além disso, a análise multiresolução de *Wavelet* se mostrou eficaz na extração das características, que extrai componentes de altas e baixas frequências dos sinais.

Os modelos de aprendizado de máquina empregados na classificação, a saber, Árvore de Decisão (AD) e *Light Gradient Boosting* (LGBM) resultaram em desempenhos altamente satisfatórios, com acurácias gerais maiores que 98% para ambos os classificadores. Em termos comparativos, o algoritmo de LGBM obteve resultados superiores ao algoritmo de AD, com acurácia geral de 98,75%. A robustez do algoritmo de LGBM, associado ao algoritmo de construção de seus estimadores justificam este resultado superior, e evidência o potencial deste algoritmo.

Portanto, os objetivos definidos no começo deste trabalho foram alcançados com sucesso. Como trabalhos futuros, espera-se aperfeiçoar a rede com a inserção de outras fontes de geração distribuída, tais como a geração eólica e as emergentes fontes baseadas em hidrogênio verde, além de expandir os distúrbios para outras classes que considerem não só distúrbios simples como também distúrbios combinados. Além disso, espera-se analisar de maneira mais detalhada a eventual influência que diferentes configurações de transformador podem ocasionar na propagação destes distúrbios, e testar outras técnicas de extração de características, como a Transformada de *Stockwell* ou a abordagem baseada em Redes Neurais Convolucionais, que realizam a extração ótima de características dos sinais.

## REFERÊNCIAS

- ABB. **Datasheet: ULTRA-1100-TL-OUTD-X-US-690**. 2023. Disponível em: <<https://global.abb/>>. Acesso em: 29 abr. 2023.
- AGENCIA NACIONAL DE ENERGIA ELETRICA. **PRODIST Módulo 8: Qualidade do fornecimento de energia elétrica**. Brasília, 2021.
- ALI, S.; WU, K.; WESTON, K.; MARINAKIS, D. A machine learning approach to meter placement for power quality estimation in smart grid. **IEEE Transactions on Smart Grid**, v. 7, n. 3, p. 1552–1561, 2016.
- ALIMI, O. A.; OUAHADA, K.; ABU-MAHFOUZ, A. M. A review of machine learning approaches to power system security and stability. **IEEE Access**, v. 8, p. 113512 – 113531, 2020.
- ARRUDA, E. F. de. **Análise de Distúrbios Relacionados com a Qualidade da Energia Elétrica utilizando a Transformada Wavelet**. 2003. 136 f. Dissertação (Mestrado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo, São Carlos, 2003.
- BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. **Journal of Machine Learning Research**, v. 13, p. 281–305, 2012.
- BORGES, F. A. S. **Extração de Características Combinadas com Árvores de Decisão para Detecção e Classificação dos Distúrbios de Qualidade de Energia Elétrica**. 2013. 118 f. Dissertação (Mestrado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo, São Carlos, 2013.
- BORGES, F. A. S. **Método Híbrido Baseado no Algoritmo K-Means e Regras de Decisão para Localização das Fontes de Variações de Tensões de Curta Duração no Contexto de Smart Grid**. 2017. 200 f. Tese (Doutorado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo, São Carlos, 2017.
- BREIMAN, L.; FRIEDMAN, J.; STONE, C. J.; OLSHEN, R. **Classification and Regression Trees**. Belmont: Taylor Francis, 1984.
- CARUANA, C. **Encyclopedia of Electrical and Electronic Power Engineering: Power Converters for Renewable Energy: Solar**. 1. ed. Netherlands: Elsevier, 2023.
- CONGRESSO NACIONAL. **Lei Nº 14.300, de 6 de janeiro de 2022**: Institui o marco legal da microgeração e minigeração distribuída. 2022. Disponível em: <[https://www.planalto.gov.br/ccivil\\_03/\\_ato2019-2022/2022/lei/L14300.htm](https://www.planalto.gov.br/ccivil_03/_ato2019-2022/2022/lei/L14300.htm)>. Acesso em: 01 mai. 2023.
- DUDA, R. O.; STORK, D. G. **Pattern classification**. 2. ed. New York: Wiley, 2001.
- EATON. **Power capacitors: fundamentals of power capacitors**. [S.l.], 2023. Disponível em: <<https://www.eaton.com/us/en-us/products/medium-voltage-power-distribution-control-systems/power-capacitors/fundamentals-of-power-capacitors.html>>. Acesso em: 11 abr. 2023.



EMPRESA DE PESQUISA ENERGÉTICA. **Balço Energético Nacional 2021**: Ano base 2020. Rio de Janeiro, 2021.

FANG, X.; MISRA, S.; MISRA, S.; YANG, D. Smart grid – the new and improved power grid: A survey. **IEEE Communications Surveys & Tutorials**, v. 14, n. 4, p. 944–980, 2012.

GARCIA, V. V. **Caracterização de Eventos Transitórios da Qualidade da Energia Elétrica utilizando Sistemas Inteligentes e Processamento de Sinais**. 2013. 172 f. Tese (Doutorado em Engenharia Elétrica) — Escola Politécnica, Departamento de Engenharia de Energia e Automação, Universidade de São Paulo, São Paulo, 2013.

GLOVER, J. D.; SARMA, M. S.; OVERBYE, T. J. **Power System: Modeling and analysis**. 5. ed. Stamford: Cengage Learning, 2012.

GU, X.; LO, K. L. Wavelet transform based fuzzy logic for power quality classification. In: **45th International Universities Power Engineering Conference UPEC2010**. [S.l.: s.n.], 2010. p. 1–6.

HENAN QINGZHOU CABLE. **Aluminum Conductor 15kV 25KV 28KV 35KV Primary URD EPR Concentric Cable**. [S.l.], 2023. Disponível em: <[https://www.qingzhou-cable.com/products/overhead\\_insulated\\_cable/mv\\_urd\\_cable.html/](https://www.qingzhou-cable.com/products/overhead_insulated_cable/mv_urd_cable.html/)>. Acesso em: 12 abr. 2023.

HOUSTON WIRE CABLE. **Aluminum Conductor Steel Reinforced (ACSR)**. [S.l.], 2023. Disponível em: <<https://www.houwire.com/acsr-aluminum-conductor-steel-reinforced/>>. Acesso em: 12 abr. 2023.

IEEE POWER ENERGY SOCIETY. **IEEE PES Test Feeder**. [S.l.], 2023. Disponível em: <<https://cmte.ieee.org/pes-testfeeders/resources/>>. Acesso em: 01 abr. 2023.

IEEE STANDARDS ASSOCIATION. **IEEE Std C62.41.2-2002**: Recommended practice on characterization of surges in low-voltage (1000v and less) ac power circuits. New York, 2002.

IEEE STANDARDS ASSOCIATION. **IEEE Std 1159-2019**: Recommended practice for monitoring electric power quality. New York, 2019.

KAISER, G. **A Friendly Guide to Wavelets**. Boston: Birkhäuser, 1994.

KAISER, G. **Electrical Power Systems Quality**. 2. ed. New York: McGraw-Hill, 2004.

KANIRAJAN, P.; KUMAR, V. S. Power quality disturbance detection and classification using wavelet and RBFNN. **Applied Soft Computing**, v. 35, p. 470–481, 2015.

KE, G. *et al.* Lightgbm: A highly efficient gradient boosting decision tree. In: **31st Conference on Neural Information Processing Systems (NIPS 2017)**. [S.l.: s.n.], 2017. p. 1–69.

KERSTING, W. Radial distribution test feeders. In: **2001 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No.01CH37194)**. [S.l.: s.n.], 2001. v. 2, p. 908–912.

KERSTING, W. H. **Distribution System: Modeling and analysis**. 3. ed. Las Cruces: CRC Press, 2012.

KHOA, N. M.; ; DAI, L. V. Detection and classification of power quality disturbances in power system using modified-combination between the stockwell transform and decision tree methods. **Energies**, v. 13, p. 1–30, 2020.

- KHOKHAR, S.; ZIN, A. A. M.; MEMONB, A. P.; MOKHTAR, A. S. New optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network. **Measurement**, v. 95, p. 246–259, 2017.
- KHOKHAR, S.; ZIN, A. M.; MOKHTAR, A.; ZAREEN, N. Automatic pattern recognition of single and multiple power quality disturbances. **Australian Journal of Electrical and Electronics Engineering**, v. 13, p. 43–53, 2015.
- KINDERMANN, G. **Curto-Circuito**. 2. ed. Porto Alegre: Sagra Luzzatto, 1997.
- KINGSLEY, C.; UMANS, S. D. **Fitzgerald Kingsley's Electric Machinery**. 7. ed. New York: McGraw Hill, 2013.
- LESAGE, J. **Systems-Level Microgrid Simulation from Simple One-Line Diagram**. 2023. Disponível em: <<https://www.mathworks.com/matlabcentral/fileexchange/67060-systems-level-microgrid-simulation-from-simple-one-line-diagram>>. Acesso em: 01 fev. 2023.
- MANIMALA, K.; SELVI, K.; AHILA, R. Optimization techniques for improving power quality data mining using wavelet packet based support vector machine. **Neurocomputing**, v. 77, n. 1, p. 36–47, 2012.
- MATLAB. **version 9.12.0.2039608 (R2022a)**. Natick, Massachusetts: The MathWorks Inc., 2022.
- Medeiros Jr, M. F. d. *et al.* Classificação automática de distúrbios através de redes neurais e da transformada wavelet combinando dados de simulações e registros de perturbações. **Universidade Federal do Rio Grande do Norte**, p. 1–11, 2006.
- MEENA, M.; MAHELA, O. P.; KUMAR, M.; KUMAR, N. Detection and classification of complex power quality disturbances using stockwell transform and rule based decision tree. 2018 International Conference on Smart Electric Drives Power System, p. 220–226, 2018.
- MESSENGER, R.; ABTAHI, H. **Photovoltaic Systems Engineering: Power Converters for Renewable Energy: Solar**. 4. ed. New York: CRC Press, 2017.
- Microsoft Corporation. **LightGBM**: Release 3.3.5.99. 2023. Disponível em: <<https://lightgbm.readthedocs.io/en/latest/index.html>>. Acesso em: 06 jun. 2023.
- MISHRA, S.; BHENDE, C. N.; PANIGRAHI, B. K. Detection and classification of power quality disturbances using s-transform and probabilistic neural network. **IEEE Transactions on Power Delivery**, v. 23, p. 280–287, 2008.
- MOHAMED S.R.; JEYANTHY, P. D. D. S. M. A. Dc-link voltage control of a grid-connected solar photovoltaic system for fault ride-through capability enhancement. **Applied Science**, v. 952, p. 1–27, 2019.
- MUNDANI, R.-P.; FRISCH, J.; VARDUHN, V.; RANK, E. A sliding window technique for interactive high-performance computing scenarios. **Advances in Engineering Software**, v. 84, n. 1, p. 21–30, 2015.
- NASSAU NATIONAL CABLE. **Aluminum Conductor 15KV MV-105 133% - EPR/PVC Copper Tape Shield**. [S.l.], 2023. Disponível em: <<https://nassaunationalcable.com/products/15kv-133>>. Acesso em: 12 abr. 2023.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

PINFILDI, G. V. **Estimativa Do Índice De Irradiação (Hsp) De Sistemas Fotovoltaicos Instalados Nos Municípios De Belém E Castanhal (Pa) - Análise Através Da Geração Mensal E Anual Comparados Com Dados Do Cresesb**. 2023. 68 f. Monografia em Engenharia Elétrica — Universidade Federal Rural Da Amazônia, Belém, 2022.

RASHID, M. **Eletrônica de Potência: Dispositivos, Circuitos e Aplicações**. São Paulo: Pearson Education do Brasil, 2015.

RENEWABLE ENERGY LABORATORY. **NSRDB: National Solar Radiation Database**. 2023. Disponível em: <<https://nsrdb.nrel.gov/data-sets/international-data>>. Acesso em: 29 abr. 2023.

SANTOSO, S.; POWERS, E.; GRADY, W.; HOFMANN, P. Power quality assessment via wavelet transform analysis. **IEEE Transactions on Power Delivery**, v. 11, n. 2, p. 24 – 930, 1996.

SCHNEIDER, K. P. *et al.* Analytic considerations and design basis for the ieeec distribution test feeders. **IEEE Transactions on Power Systems**, v. 33, n. 3, p. 3181 – 3188, 2017.

SCOTECH ELECTRICAL. **Scotech Electrical Transformer**. [S.l.], 2023. Disponível em: <<https://www.scotech-electrical.com/transformer/>>. Acesso em: 11 abr. 2023.

SHARMA, R.; MAHELA, O. P.; AGARWAL, S. Detection of power system faults in distribution system using stockwell transform. In: **2018 IEEE International Students Conference on Electrical, Eletronics and Computer Science**. [S.l.: s.n.], 2018. p. 19–22.

SHEN, Y.; ABUBAKAR, M.; LIU, H.; HUSSAI, F. Power quality disturbance monitoring and classification based on improved pca and convolution neural network for wind-grid distribution. **Energies**, MDPI, v. 12, n. 1280, p. 1–26, 2019.

SKORUPA, T. **Aplicação de Métodos Probabilísticos na Estimação de Distorção Harmônica em Sistemas de Distribuição de Energia Elétrica**. 2021. 165 f. Dissertação (Mestrado em Engenharia Elétrica) — Centro Tecnológico, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, 2021.

SUNPOWER CORPORATION. **Datasheet: SunPower SPR-X22-480-COM**. 2023. Disponível em: <<https://us.sunpower.com/>>. Acesso em: 29 abr. 2023.

TAN, R. H.; RAMACHANDARAMURTHY, V. K. A comprehensive modeling and simulation of power quality disturbances using matlab/simulink. **Power Quality Issues in Distributed Generation**, n. 1, p. 83–107, 2015.

TIBA, C. *et al.* (Ed.). **Atlas Solarimétrico do Brasil: Banco de dados terrestres**. Recife: Universidade Federal de Pernambuco, 2000.

UPADHYAYA, S.; BHENDE, C. N.; MOHANTY, S.; PATI, R. Evaluation of power quality disturbance in pv-connected ieeec-14 bus system using lifting-based wavelet transform and random forest. **Electrical Engineering**, v. 104, p. 2345–2354, 2022.

VIVERT, M.; COLLAGUAZO, G.; NARANJO, F.; QUINDE, I. Perturbe and observe mppt algorithm with integral actions. In: **IEEE 5th Colombian Conference on Automatic Control (CCAC)**. [S.l.: s.n.], 2021. p. 19–22.

WATITWA, J. **Active Distribution System with Distributed Generation**. 2022. Disponível em: <<https://www.mathworks.com/matlabcentral/fileexchange/71534-active-distribution-system-with-distributed-generation>>. Acesso em: 01 out. 2022.

XIE, X. *et al.* A novel progressively undersampling method based on the density peaks sequence for imbalanced data. **Knowledge-Based Systems**, v. 213, n. 1, p. 1–11, 2021.

XU, Y.; GAO, Y.; LI, Z.; LU, M. Detection and classification of power quality disturbances in distribution networks based on VMD and DFA. **CSEE Journal of Power and Energy Systems**, v. 6, n. 1, p. 122–130, 2020.

YAN, Y.; QIAN, Y.; SHARIF, H.; TIPPER, D. A survey on smart grid communication infrastructures: Motivations, requirements and challenges. **IEEE Communications Surveys & Tutorials**, v. 15, n. 1, p. 5–20, 2013.