

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

Anderson Luis de Moraes

**Gerenciamento da Qualidade da Energia Elétrica em
Smart Grids Baseado em Técnicas de *Soft Computing***

São Carlos – SP
2021

Anderson Luis de Moraes

**Gerenciamento da Qualidade da Energia Elétrica em
Smart Grids Baseado em Técnicas de *Soft Computing***

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

Área de Concentração: Sistemas Elétricos e Eletrônicos

Orientador: Prof. Dr. Ricardo Augusto Souza Fernandes

São Carlos – SP

2021

Moraes, Anderson Luis de

Gerenciamento da qualidade da energia elétrica em smart grids baseado em técnicas de soft computing / Anderson Luis de Moraes -- 2021. 129f.

Dissertação (Mestrado) - Universidade Federal de São Carlos, campus São Carlos, São Carlos

Orientador (a): Ricardo Augusto Souza Fernandes

Banca Examinadora: Daniel Barbosa, Murilo da Silva

Bibliografia

1. Qualidade da energia elétrica. 2. Smart grids. 3. Detecção, compressão e classificação. I. Moraes, Anderson Luis de. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Ronildo Santos Prado - CRB/8 7325



UNIVERSIDADE FEDERAL DE SÃO CARLOS

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

Folha de Aprovação

Defesa de Dissertação de Mestrado do candidato Anderson Luis de Moraes, realizada em 13/05/2021.

Comissão Julgadora:

Prof. Dr. Ricardo Augusto Souza Fernandes (UFSCar)

Prof. Dr. Daniel Barbosa (UFBA)

Prof. Dr. Murilo da Silva (UTFPR)

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

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

À minha mãe Jane.

AGRADECIMENTOS

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

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

Ao meu amigo Renan e toda sua família por me acolherem em São Carlos como um membro da família, com muito amor e carinho.

As minhas amigas Admara e Carol por sempre me apoiarem e não deixarem que a distância prejudicasse a nossa amizade.

A minha amiga Regina por todo carinho, atenção, amizade e suporte.

Aos amigos Fábio e Guilherme pelos jantares, risadas, aventuras e, principalmente, pelo apoio durante o período de isolamento social.

Aos Profs. Rogério Andrade Flauzino e Ivan Nunes da Silva pela oportunidade de conhecer a área de *Machine Learning*, em que me identifiquei à primeira vista e decidi seguir meus estudos.

Ao Prof. Ricardo Augusto Souza Fernandes pela orientação acadêmica, aprendizagem, assistência e apoio ao longo do mestrado, cuja dedicação e competência permitiram meu amadurecimento na vida acadêmica.

Ao Diego Cavalca pela disponibilidade de assistência nos momentos em que surgiram algumas dúvidas técnicas do projeto de mestrado.

À UFSCar por permitir o desenvolvimento da minha pesquisa de mestrado concomitantemente às atividades da minha função de técnico no Departamento de Ciências Ambientais (DCAm).

Aos amigos da pós-graduação que fiz durante o mestrado. À Wanessa e Frederico pelo acolhimento no laboratório, pelo café, pelas risadas e compartilhamento de experiências. À Andrea pela amizade, pelos momentos de loucura, pelas risadas e pelo carinho. À Amandia pelo companheirismo, apoio, suporte emocional, almoços no RU e auxílios na pesquisa. Ao Leonardo e Gabriel pelas conversas, pelos trabalhos em grupos e pelo amadurecimento acadêmico.

À Valéria e aos professores do Programa de Pós-Graduação em Engenharia Elétrica da

UFSCar, cujo compromisso com a pesquisa possibilitou o desenvolvimento do mestrado.

Finalmente, agradeço a todos que, de alguma forma, contribuíram para a minha formação de pesquisador e cidadão.

“Explicar toda a natureza é uma tarefa difícil demais para qualquer homem ou para qualquer época. É muito melhor fazer um pouco e com certeza e deixar o resto para outros que vêm depois de você.”
(Isaac Newton)

RESUMO

MORAES, A. L.. **Gerenciamento da Qualidade da Energia Elétrica em *Smart Grids* Baseado em Técnicas de *Soft Computing***. 129 p. Dissertação de Mestrado – Centro de Ciências Exatas e de Tecnologia, Universidade Federal de São Carlos, São Carlos, 2021.

O crescente uso de cargas não lineares (principalmente as baseadas em dispositivos de eletrônica de potência), a inserção de fontes renováveis (como eólica e fotovoltaica), descargas atmosféricas, partida de motores e energização de grandes blocos de carga geram distúrbios que afetam a Qualidade da Energia Elétrica que é entregue aos consumidores. No âmbito de *Smart Grids*, as concessionárias de distribuição de energia elétrica buscam meios de monitorar a Qualidade da Energia Elétrica, de forma que os distúrbios possam ser detectados por *smart meters* e as informações possam ser compactadas e transmitidas de forma eficiente. Ainda, espera-se que, após a descompactação, os sinais sejam recuperados com poucas perdas e possam ser classificados para auxiliar nas tomadas de decisão da concessionária. Portanto, este trabalho propõe um *framework* baseado em *edge computing* e *cloud computing*, onde os processos de detecção/segmentação, compressão e classificação dos distúrbios serão devidamente realizados. Para analisar o desempenho desse *framework*, foi gerada uma base de dados sintéticos com 15 classes de distúrbios (simples e combinados). Neste sentido, a detecção dos distúrbios foi realizada por uma Árvore de Decisão capaz de identificar 94,71% das janelas de distúrbios. Na sequência, os distúrbios detectados foram submetidos a uma etapa de tratamento, a fim de garantir uma segmentação mais eficiente dos sinais. As janelas de distúrbio resultantes foram então comprimidas por meio de uma Transformada *Wavelet*, considerando filtros da família *Daubechies*, em que foi possível reduzir os pacotes de dados a uma taxa de compressão superior a 3,6. Por meio da descompactação, notou-se uma baixa perda de informação. Por fim, realizou-se a transformação dos sinais temporais em Gráficos de Recorrência, *Gramian Angular Summation Field* e *Gramian Angular Difference Field* com o intuito de contribuir de forma efetiva ao processo de classificação dos distúrbios, feito por meio de um conjunto de Redes Neurais Convolucionais. Neste contexto, a abordagem proposta possibilitou uma acurácia média acima de 94%. Assim, os resultados desta pesquisa contribuirão no avanço do estado da arte em mecanismos de processamento automático de sinais em prol da Qualidade da Energia Elétrica.

Palavras-chave: Aprendizado de Máquina, Classificação de Distúrbios, Compressão de Dados, Detecção de Distúrbios, Processamento de Sinais, Qualidade da Energia Elétrica.

ABSTRACT

MORAES, A. L.. **Power Quality Management in Smart Grids Based on Soft Computing Techniques**. 129 p. Master Dissertation – São Carlos School of Engineering, University of São Paulo, São Carlos, 2021.

The increasing use of nonlinear loads (mainly those based on power electronics), the integration of renewable sources (such as wind and photovoltaic), atmospheric discharges, starting of motors and driving large load blocks generate disturbances that affect the Power Quality, i.e., the energy delivered to consumers. In the Smart Grids context, the distribution utilities seek ways to monitor the Power Quality, so that disturbances can be detected by smart meters and the resulting data should be compressed to ensure an efficient exchange of data packets. In this sense, it is expected that, after unpacking the data, the signals will be recovered with few information losses and can be classified to assist in the utilities' decision making. Therefore, this work proposes a framework based on the edge and cloud computing technologies, where the processes of detection/segmentation, compression and classification of power quality disturbances will be properly performed. To analyze the performance of this framework, a synthetic database with 15 disturbance classes (simple and combined) was generated. Thus, detection of disturbances was performed by a Decision Tree capable of identifying 94.71% of the disturbance windows. Next, the disturbances detected were submitted to a treatment stage in order to guarantee a more efficient segmentation of the signals. The resulting windows of disturbances were then compressed using a Wavelet Transform, considering filters from the Daubechies family, in which it was possible to reduce the data packets to a compression rate greater than 3.6. Through data unpacking, a low information loss was observed. Finally, there was a transformation of the temporal signals in Recurrence Plots, Gramian Angular Summation Field and Gramian Angular Difference Field in order to identify the voltage signal patterns through a set of Convolutional Neural Networks. In this context, the proposed approach allows to obtain an average accuracy above 94%. Thus, the results of this research will contribute to advance the state-of-the-art in Power Quality automatic signal processing.

Keywords: Machine Learning, Disturbances Classification, Data Compression, Disturbances Detection, Signal Processing, Power Quality.

LISTA DE ILUSTRAÇÕES

Figura 1 – Contexto da pesquisa. BD representa a Base de Dados, RP <i>Recurrence Plot</i> , GASF <i>Gramian Angular Summation Field</i> , GADF <i>Gramian Angular Difference Field</i> e ML <i>Machine Learning</i>	4
Figura 2 – Interrupção de Tensão.	8
Figura 3 – Afundamento de Tensão.	9
Figura 4 – Elevação de Tensão.	9
Figura 5 – Interrupção Sustentada de Tensão.	10
Figura 6 – Subtensão.	10
Figura 7 – Sobretensão.	11
Figura 8 – Transitório Impulsivo.	11
Figura 9 – Transitório Oscilatório.	12
Figura 10 – Flutuação de Tensão.	13
Figura 11 – Distorção harmônica.	14
Figura 12 – Inter-harmônicos.	15
Figura 13 – <i>Notching</i>	15
Figura 14 – <i>Spike</i>	16
Figura 15 – Visão geral da metodologia proposta.	44
Figura 16 – Processo de janelamento.	45
Figura 17 – Processo de detecção/segmentação adotado.	48
Figura 18 – Processo de compactação adotado.	49
Figura 19 – Esquema genérico de um classificador baseado em <i>Decision Tree</i> (DT).	51
Figura 20 – Exemplificação da ocorrência de falsos negativos na detecção de distúrbios.	52
Figura 21 – Exemplificação da mitigação de falsos negativos na detecção do distúrbios.	53
Figura 22 – Esquema de decomposição de um sinal por meio da <i>Discrete Wavelet Transform</i> (DWT) até o terceiro nível de resolução.	54
Figura 23 – Esquema de descompactação do sinal.	57
Figura 24 – Esquema de classificação de distúrbio de QEE.	57
Figura 25 – Exemplo genérico do processo de classificação.	58
Figura 26 – (a) RP de um sinal senoidal ideal; (b) RP de um afundamento de tensão; e (c) RP de uma elevação de tensão.	60
Figura 27 – (a) GASF de um sinal senoidal ideal; (b) GASF de um afundamento de tensão; e (c) GASF de uma elevação de tensão.	61

Figura 28 – (a) GADF de um sinal senoidal ideal; (b) GADF de um afundamento de tensão; e (c) GADF de uma elevação de tensão.	62
Figura 29 – Ilustração de um classificador baseado em CNN.	62
Figura 30 – Exemplo de classificação <i>One vs. All</i>	65
Figura 31 – Desempenho da Regressão Logística para a base de Teste.	70
Figura 32 – Desempenho da Árvore de Decisão para a base de Teste.	71
Figura 33 – Regressão Logística: <i>Boxplot</i> do comprimento/extensão das regiões com falsos negativos para a base de Teste.	73
Figura 34 – Árvore de Decisão: <i>Boxplot</i> do comprimento/extensão das regiões com falsos negativos para a base de Teste.	73
Figura 35 – Estrutura da Árvore de Decisão obtida pelo algoritmo.	75
Figura 36 – Distribuição do erro para a detecção do início do distúrbio para a base de Teste.	76
Figura 37 – Distribuição do erro para a detecção do fim do distúrbio para a base de Teste.	76
Figura 38 – Resultado do Filtro <i>db4</i> com 2 níveis de decomposição.	79
Figura 39 – Resultado do Filtro <i>db4</i> com 4 níveis de decomposição.	79
Figura 40 – Resultado do Filtro <i>bior3.1</i> com 2 níveis de decomposição.	80
Figura 41 – Resultado do Filtro <i>bior3.1</i> com 4 níveis de decomposição.	80
Figura 42 – Resultado do Filtro <i>db4</i> com 2 níveis de decomposição em uma perspectiva 3D.	81
Figura 43 – Resultado do Filtro <i>db4</i> com 4 níveis de decomposição em uma perspectiva 3D.	81
Figura 44 – Resultado do Filtro <i>bior3.1</i> com 2 níveis de decomposição em uma perspectiva 3D.	82
Figura 45 – Resultado do Filtro <i>bior3.1</i> com 4 níveis de decomposição em uma perspectiva 3D.	82
Figura 46 – Comparação entre um afundamento de tensão antes (a) e após (b) a compressão/descompactação.	83
Figura 47 – Comparação entre uma elevação de tensão antes (a) e após (b) a compressão/descompactação.	83
Figura 48 – Comparação entre uma interrupção de tensão antes (a) e após (b) a compressão/descompactação.	84
Figura 49 – Comparação entre um transitório oscilatório antes (a) e após (b) a compressão/descompactação.	84
Figura 50 – Comparação entre um transitório impulsivo antes (a) e após (b) a compressão/descompactação.	85
Figura 51 – Comparação entre uma flutuação de tensão antes (a) e após (b) a compressão/descompactação.	85
Figura 52 – Comparação entre uma distorção harmônica antes (a) e após (b) a compressão/descompactação.	86
Figura 53 – Comparação entre um <i>notching</i> antes (a) e após (b) a compressão/descompactação.	86

Figura 54 – Comparação entre um <i>spike</i> antes (a) e após (b) a compressão/descompactação.	87
Figura 55 – Representação de sinal puro de tensão em (a) RP e (b) domínio do tempo. . .	87
Figura 56 – Representação de afundamento de tensão em (a) RP e (b) domínio do tempo.	88
Figura 57 – Representação de elevação de tensão em (a) RP e (b) domínio do tempo. . .	88
Figura 58 – Representação de interrupção de tensão em (a) RP e (b) domínio do tempo. .	89
Figura 59 – Representação de transitório oscilatório em (a) RP e (b) domínio do tempo. .	89
Figura 60 – Representação de transitório impulsivo em (a) RP e (b) domínio do tempo. . .	90
Figura 61 – Representação de flutuação de tensão em (a) RP e (b) domínio do tempo. . .	90
Figura 62 – Representação de distorção harmônica em (a) RP e (b) domínio do tempo. . .	91
Figura 63 – Representação de <i>notching</i> em (a) RP e (b) domínio do tempo.	91
Figura 64 – Representação de <i>spike</i> em (a) RP e (b) domínio do tempo.	92
Figura 65 – Representação de afundamento de tensão com distorção harmônica em (a) RP e (b) domínio do tempo.	92
Figura 66 – Representação de elevação de tensão com distorção harmônica em (a) RP e (b) domínio do tempo.	93
Figura 67 – Representação de flutuação de tensão com afundamento em (a) RP e (b) domínio do tempo.	93
Figura 68 – Representação de flutuação de tensão com elevação em (a) RP e (b) domínio do tempo.	94
Figura 69 – Representação de afundamento de tensão com transitório oscilatório em (a) RP e (b) domínio do tempo.	94
Figura 70 – Representação de elevação de tensão com transitório oscilatório em (a) RP e (b) domínio do tempo.	95
Figura 71 – Representação de sinal senoidal puro em (a) GASF e (b) GADF.	95
Figura 72 – Representação de afundamento de tensão em (a) GASF e (b) GADF.	96
Figura 73 – Representação de elevação de tensão em (a) GASF e (b) GADF.	96
Figura 74 – Representação de interrupção de tensão em (a) GASF e (b) GADF.	97
Figura 75 – Representação de transitório oscilatório em (a) GASF e (b) GADF.	97
Figura 76 – Representação de transitório impulsivo em (a) GASF e (b) GADF.	98
Figura 77 – Representação de flutuação de tensão em (a) GASF e (b) GADF.	98
Figura 78 – Representação de distorção harmônica em (a) GASF e (b) GADF.	99
Figura 79 – Representação de <i>notching</i> em (a) GASF e (b) GADF.	99
Figura 80 – Representação de <i>spike</i> em (a) GASF e (b) GADF.	100
Figura 81 – Representação de afundamento de tensão com distorção harmônica em (a) GASF e (b) GADF.	100
Figura 82 – Representação de elevação de tensão com distorção harmônica em (a) GASF e (b) GADF.	101
Figura 83 – Representação de flutuação de tensão com afundamento em (a) GASF e (b) GADF.	101

Figura 84 – Representação de flutuação de tensão com elevação em (a) GASF e (b) GADF.	102
Figura 85 – Representação de afundamento de tensão com transitório oscilatório em (a) GASF e (b) GADF.	102
Figura 86 – Representação de elevação de tensão com transitório oscilatório em (a) GASF e (b) GADF.	103

LISTA DE TABELAS

Tabela 1 – Análise do estado da arte em termos de detecção/segmentação, compressão e classificação de distúrbios de Qualidade da Energia Elétrica (QEE).	40
Tabela 2 – Distúrbios de QEE modelados matematicamente para geração de sinais sintéticos.	44
Tabela 3 – Modelos matemáticos dos distúrbios de QEE.	46
Tabela 4 – Resultados de Detecção por meio das métricas $F1_{score}$ e Acurácia para a base de Teste.	70
Tabela 5 – Matriz de Confusão da Detecção utilizando Regressão Logística para a base de Teste.	70
Tabela 6 – Matriz de Confusão da Detecção utilizando Árvore de Decisão para a base de Teste.	70
Tabela 7 – Extrato dos Resultados de Classificação da Regressão Logística para a base de Teste.	71
Tabela 8 – Extrato dos Resultados de Classificação da Árvore de Decisão para a base de Teste.	72
Tabela 9 – Extrato da Classificação após o Tratamento dos Dados para a base de Teste.	74
Tabela 10 – Parâmetros das distribuições dos erros de estimação para a base de Execução.	77
Tabela 11 – Resultados de Detecção por meio das métricas $F1_{score}$ e Acurácia para a base de Execução.	77
Tabela 12 – Matriz de Confusão da Detecção utilizando Regressão Logística para a base de Teste.	77
Tabela 13 – Extrato dos Resultados de Classificação da Árvore de Decisão para a base de Execução.	77
Tabela 14 – Resumo dos resultados de teste.	103
Tabela 15 – Resumo dos resultados para compor o <i>ensemble</i> de classificação final referente aos dados de teste.	104
Tabela 16 – Matriz de confusão para o <i>ensemble</i> de classificação final referente aos dados de teste.	105
Tabela 17 – Resumo dos resultados de teste para o <i>ensemble</i> final de classificação levando em consideração os níveis de ruído.	106
Tabela 18 – Matriz de confusão para o <i>ensemble</i> de classificação final referente aos dados de execução.	107

Tabela 19 – Resumo dos resultados de execução para o <i>ensemble</i> final de classificação levando em consideração os níveis de ruído.	108
Tabela 20 – Resultados de classificação de alguns dos trabalhos da literatura revisados. .	110
Tabela 21 – Matriz de confusão para os resultados de classificação utilizando CNN e imagens de RP.	123
Tabela 22 – Matriz de confusão para os resultados de classificação utilizando CNN e imagens de GASF.	124
Tabela 23 – Matriz de confusão para os resultados de classificação utilizando CNN e imagens de GADF.	124
Tabela 24 – Matriz de confusão para os resultados de classificação utilizando VGG16 e imagens de RP.	125
Tabela 25 – Matriz de confusão para os resultados de classificação utilizando VGG16 e imagens de GASF.	125
Tabela 26 – Matriz de confusão para os resultados de classificação utilizando VGG16 e imagens de GADF.	126
Tabela 27 – Matriz de confusão para o <i>ensemble</i> de classificação final referente aos dados de teste com SNR = 20dB.	126
Tabela 28 – Matriz de confusão para o <i>ensemble</i> de classificação final referente aos dados de teste com SNR = 35dB.	127
Tabela 29 – Matriz de confusão para o <i>ensemble</i> de classificação final referente aos dados de teste com SNR = 45dB.	127
Tabela 30 – Matriz de confusão para o <i>ensemble</i> de classificação final referente aos dados de teste sem ruído.	128
Tabela 31 – Matriz de confusão para o <i>ensemble</i> de classificação final referente aos dados de execução com SNR = 25dB.	128
Tabela 32 – Matriz de confusão para o <i>ensemble</i> de classificação final referente aos dados de execução com SNR = 30dB.	129
Tabela 33 – Matriz de confusão para o <i>ensemble</i> de classificação final referente aos dados de execução com SNR = 40dB.	129

LISTA DE SIGLAS

<i>AdaKNEO</i>	<i>Adaptive K-Nearest Neighbor with Excluding Outliers</i>
<i>ADALINE</i>	<i>Adaptive Linear</i>
<i>ANEEL</i>	<i>Agência Nacional de Energia Elétrica</i>
<i>BiLSTM</i>	<i>Bidirectional Long Short-Term Memory</i>
<i>CAM</i>	<i>Class Activation Map</i>
<i>CFS</i>	<i>Correlation-Based Feature Selection</i>
<i>CNN</i>	<i>Convolutional Neural Network</i>
<i>CS</i>	<i>Compressed Sensing</i>
<i>CT</i>	<i>Curvelet Transform</i>
<i>DCNN</i>	<i>Deep Convolutional Neural Network</i>
<i>DCT</i>	<i>Discrete Cosine Transform</i>
<i>DFT</i>	<i>Discrete Fourier Transform</i>
<i>DHT</i>	<i>Distorção Harmônica Total</i>
<i>DT</i>	<i>Decision Tree</i>
<i>DWT</i>	<i>Discrete Wavelet Transform</i>
<i>ELM</i>	<i>Extreme Learning Machines</i>
<i>EMD</i>	<i>Empirical Mode Decomposition</i>
<i>ICEEMDAN</i>	<i>Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise</i>
<i>FAM</i>	<i>Fuzzy Associative Memory</i>
<i>FD</i>	<i>Fator de Desequilíbrio</i>
<i>FFT</i>	<i>Fast Fourier Transform</i>
<i>FPGA</i>	<i>Field-Programmable Gate Array</i>
<i>FrFT</i>	<i>Fractional Fourier Transform</i>
<i>GRU</i>	<i>Gated Recurrent Units</i>

GT *Gabor Transform*

GADF *Gramian Angular Difference Field*

GAF *Gramian Angular Field*

GASF *Gramian Angular Summation Field*

HT *Hilbert Transform*

IEEE *Institute of Electrical and Electronics Engineers*

KSVM *Kernel Support Vector Machine*

LDA *Linear Discriminant Analysis*

LSTM *Long Short-Term Memory*

LVQ *Learning Vector Quantization*

MDL *Minimum Description Length*

MLP *Multilayer Perceptron*

MP *Matching Pursuit*

MSSA *Multivariate Singular Spectrum Analysis*

NSGA-II *Non-dominated Sorting Genetic Algorithm II*

OEMD *Orthogonal Empirical Mode Decomposition*

OHDs *Overcomplete Hybrid Dictionaries*

OMP *Orthogonal Matching Pursuit*

PNN *Probabilistic Neural Network*

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

PSO *Particle Swarm Optimization*

PSR *Phase Space Reconstruction*

QEE *Qualidade da Energia Elétrica*

RBFFNN *Radial Basis Function Neural Network*

RF *Random Forest*

RL *Regressão Logística*

RLS *Recursive Least Square*

RMP *Regularized Matching Pursuit*

RMS *Root Mean Square*

RNA *Rede Neural Artificial*

ROMP *Regularized Orthogonal Matching Pursuit*

RP *Recurrence Plot*

RPS	<i>Reconstruction of Phase Space</i>
SAE	<i>Stacked Auto-Encoder</i>
SDD	<i>Sparse Signal Decomposition</i>
SEP	<i>Sistemas Eléctricos de Potência</i>
SFS	<i>Sequence Forward Search</i>
SG	<i>Smart Grids</i>
SM	<i>Smart Meter</i>
ST	<i>S-Transform</i>
StOMP	<i>Stagewise Orthogonal Matching Pursuit</i>
STFT	<i>Short-Time Fourier Transform</i>
SVM	<i>Support Vector Machine</i>
SWT	<i>Spline Wavelet Transform</i>
TDSF	<i>Time-Dependent Spectral Feature</i>
TIC	<i>Tecnologias da Informação e Comunicação</i>
URONN	<i>Univariate Randomly Optimized Neural Network</i>
VTCDs	<i>Variações de Tensão de Curta Duração</i>
VTLDs	<i>Variações de Tensão de Longa Duração</i>
WDFT	<i>Warped Discrete Fourier Transform</i>
WDF	<i>Wigner Distribution Function</i>
WPT	<i>Wavelet Packet Transform</i>
WT	<i>Wavelet Transform</i>
WVD	<i>Wigner-Ville Distribution</i>

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Motivação e Justificativa	3
1.2	Objetivos	4
1.3	Organização da Dissertação	5
2	ASPECTOS FUNDAMENTAIS DE QUALIDADE DA ENERGIA ELÉTRICA	7
2.1	Qualidade da Energia Elétrica	7
2.2	Distúrbios de QEE	8
2.2.1	Variações de Tensão de Curta Duração	8
2.2.2	Variações de Tensão de Longa Duração	9
2.2.3	Transitórios	11
2.2.4	Flutuações de Tensão	12
2.2.5	Distorções da Forma de Onda	13
2.2.6	Variações de Frequência	14
2.2.7	Desequilíbrio de Tensão	16
3	REFERENCIAL BIBLIOGRÁFICO	17
3.1	Deteccção e Segmentação de Distúrbios de QEE	17
3.2	Compactação de Distúrbios de QEE	23
3.3	Classificação de Distúrbios de QEE	29
3.4	Análise Geral	38
4	METODOLOGIA	43
4.1	Visão Geral	43
4.2	Modelagem e Geração da Base de Dados Sintéticos	44
4.3	Lado da Computação em Borda (<i>Edge Computing</i>)	48
4.3.1	Extração de características para deteccção/segmentação de distúrbios	49
4.3.2	Algoritmos utilizados na segmentação e deteccção de distúrbios	51
4.3.2.1	<i>Decision Tree</i>	51
4.3.2.2	Regressão Logística	52
4.3.3	Tratamento dos dados após a aplicação do algoritmo de deteccção e segmentação	52
4.3.4	Compressão de sinais	54
4.3.4.1	Transformada <i>Wavelet</i> Discreta	54

4.3.4.2	Quantização	55
4.3.4.3	Compressão sem perdas: <i>Huffman Code</i>	55
4.4	Lado da Computação em Nuvem (<i>Cloud Computing</i>)	56
4.4.1	Descompactação de sinais	57
4.4.2	Extração de características para classificação de distúrbios	58
4.4.2.1	Gráficos de Recorrência	58
4.4.2.2	Gramian Angular Fields (<i>Gramian Angular Fields</i> (GAFs))	60
4.4.3	Classificação de distúrbios por CNN	62
4.4.4	Método de Classificação	64
4.5	Métricas para Avaliação de Desempenho	66
4.5.1	Módulos de Detecção/Segmentação e Classificação	66
4.5.2	Módulos de Compactação e Descompactação	67
5	RESULTADOS	69
5.1	Módulo de Detecção e Segmentação	69
5.2	Módulo de Compactação	78
5.3	Módulo de Classificação	83
5.3.1	Resultados da transformação RP	83
5.3.2	Resultados das transformações GASFs e GADFs	92
5.3.3	Resultados da classificação dos distúrbios	101
6	CONCLUSÕES	111
6.1	Produção Científica	113
	REFERÊNCIAS	115
	APÊNDICE A RESULTADOS COMPLEMENTARES DO MÓDULO DE CLASSIFICAÇÃO	123

INTRODUÇÃO

A alteração da natureza e a diversificação dos tipos de cargas, bem como a inserção de gerações distribuídas em Sistemas Elétricos de Potências (SEPs) têm afetado a Qualidade da Energia Elétrica (QEE). Portanto, as agências reguladoras têm estabelecido procedimentos padronizados com o intuito de garantir o fornecimento de energia elétrica com qualidade, visto que este é um serviço essencial aos consumidores.

Segundo [Dugan et al. \(2012\)](#), qualquer distúrbio manifestado na tensão, na corrente ou no desvio de frequência que resulta na falha ou má operação dos equipamentos dos consumidores representa um problema de QEE. Entretanto, os dispositivos eletrônicos e equipamentos elétricos atualmente utilizados são mais sensíveis às variações de tensão, corrente e/ou frequência. Portanto, a degradação da QEE pode acarretar o mal funcionamento e operação dessas cargas, além de contribuir para a redução de suas vidas úteis.

Ademais, a evolução da tecnologia tem propiciado o aumento de cargas não lineares e isso tem elevado os níveis de distorções harmônicas nas redes de baixa e média tensão. Com isso, pode-se perceber, em alguns casos, o superaquecimento de motores e transformadores, vibração e falha de motores, queima de capacitores e fusíveis e ressonâncias harmônicas em determinados pontos do sistema que comprometem as instalações elétricas ([KAGAN; OLIVEIRA; ROBBA, 2000](#)).

No Brasil, a Agência Nacional de Energia Elétrica (ANEEL) é o órgão responsável pela regulamentação e fiscalização da geração, transmissão, distribuição e comercialização de energia. Tendo em vista a relevância da QEE, a ANEEL elaborou e publicou em 2008 a primeira versão do módulo 8 do Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) ([ANEEL, 2021](#)), que normatiza e padroniza as atividades técnicas relacionadas ao funcionamento e desempenho dos sistemas de distribuição de energia elétrica. Nesse sentido, o módulo 8 do PRODIST estabelece procedimentos relativos à QEE no que tange a qualidade do produto, serviço e tratamento das reclamações prestados pelas concessionárias e

permissionárias de serviços de distribuição de energia elétrica. É importante mencionar que essa norma tem sido atualizada de forma recorrente pela ANEEL e atualmente está na 12ª revisão.

No âmbito internacional, pode-se destacar as recomendações publicadas pelo *Institute of Electrical and Electronics Engineers* (IEEE), denominada 1159-2019 – *IEEE Recommended Practice for Monitoring Electric Power Quality* (IEEE, 2019), que compõe uma revisão das recomendações publicadas em 2009. Esse documento aborda técnicas para medir, quantificar e interpretar fenômenos eletromagnéticos ou distúrbios que ocorrem em SEPs.

Nesse sentido, *Smart Grids* (SG) podem contribuir de forma efetiva nos processos de detecção e classificação de distúrbios relacionados à QEE. Cabe mencionar que uma SG se baseia principalmente na integração do SEP às Tecnologias da Informação e Comunicação (TIC). Tal integração se dá por meio de dispositivos inteligentes, como por exemplo, os *Smart Meters* (SMs), visto que eles possibilitam que as concessionárias adquiram dados relativos ao estado de operação do SEP. Assim, torna-se possível o monitoramento em tempo real dos SEPs, visando maximizar sua eficiência e confiabilidade, bem como permitir ações mais efetivas em termos do planejamento das operações (DEPURU; WANG; DEVABHAKTUNI, 2011). Em concordância com esse contexto, os conceitos de *edge computing* e *cloud computing* (SHI *et al.*, 2016) podem auxiliar na tarefa de tratamento dos dados e ainda garantir o uso adequado dos canais de comunicação, ou seja, transmitir pacotes de dados que não sobrecarreguem a largura de banda disponível e mitigar perdas de dados.

Vale mencionar que os processos de detecção e classificação de distúrbios de QEE têm sido tradicionalmente realizados por meio de algoritmos de *Machine Learning*. Dentre os algoritmos, pode-se destacar as Redes Neurais Artificiais (RNAs) (KUMAR *et al.*, 2015; RODRIGUEZ *et al.*, 2014; BORGES *et al.*, 2016), Árvores de Decisão – *Decision Trees* (DTs) (KUMAR *et al.*, 2015; BORGES *et al.*, 2016), e Máquinas de Vetores de Suporte – *Support Vector Machines* (SVMs) (JANIK; LOBOS, 2006; ERIŞTI; UÇAR; DEMIR, 2010). Observa-se que as pesquisas supramencionadas, além de fazer uso dos algoritmos de *Machine Learning*, ainda realizam a extração de características dos sinais (seja no domínio do tempo ou da frequência). Contudo, uma tendência nas pesquisas é o uso de algoritmos de *Deep Learning*, principalmente das Redes Neurais Convolucionais – *Convolutional Neural Network* (CNN). Porém, o uso de CNNs está condicionado, em alguns casos, à transformação dos sinais elétricos (temporais) em imagens bidimensionais, conforme Shareef, Mohamed e Ibrahim (2013), Cai *et al.* (2019b), Cai *et al.* (2019a) e Lin *et al.* (2019).

Seguindo o contexto supracitado, esta dissertação de mestrado propõem um *framework* idealizado em função das restrições técnicas dos SMs, uma vez que tais dispositivos possuem limitações em termos de processamento de dados em *hardware* e também de largura de banda para troca de dados com o meio externo. Devido a essas características dos SMs, tais dispositivos são considerados como *edge computing* e, portanto, pretende-se que eles façam a detecção dos distúrbios de QEE com um processamento dos sinais elétricos que apresente baixo esforço

computacional. Além disso, o *framework* prevê que, após transmitidos os dados à concessionária, eles serão armazenados e processados em uma arquitetura de *cloud computing*, na qual se tem alto poder de processamento. Assim, somente no lado da *cloud computing* os dados serão devidamente rotulados, isto é, os distúrbios serão classificados. Portanto, em termos da classificação dos distúrbios, serão avaliados algoritmos de *Machine Learning* baseados em aprendizado profundo (*deep learning*), mais especificamente a CNN. Ademais, devido ao poder computacional disponível no lado da *cloud computing*, ainda será analisado o potencial dos Gráficos de Recorrência – *Recurrence Plots* (RPs) (ECKMANN; KAMPHORST; RUELLE, 1987), dos *Gramian Angular Summation Fields* (GASFs) (WANG; OATES, 2015) e dos *Gramian Angular Difference Fields* (GADFs) (WANG; OATES, 2015) como novas formas de se extrair características de sinais elétricos que denotem distúrbios de QEE.

A partir desse *framework*, esta pesquisa busca contribuir com o avanço do estado da arte no que tange ao monitoramento automático dos distúrbios de QEE no contexto de SGs, uma vez que os trabalhos da área não propõem um *framework* completo, da aquisição dos sinais até a classificação dos distúrbios. Assim, o *framework* proposto pode ser sumarizado nos seguintes processos: (i) detecção e segmentação dos distúrbios; (ii) compactação dos sinais resultantes; e (iii) classificação dos distúrbios. Cabe destacar que as duas primeiras etapas integram o processamento em *edge computing*, enquanto a terceira etapa é processada em *cloud computing*.

1.1 Motivação e Justificativa

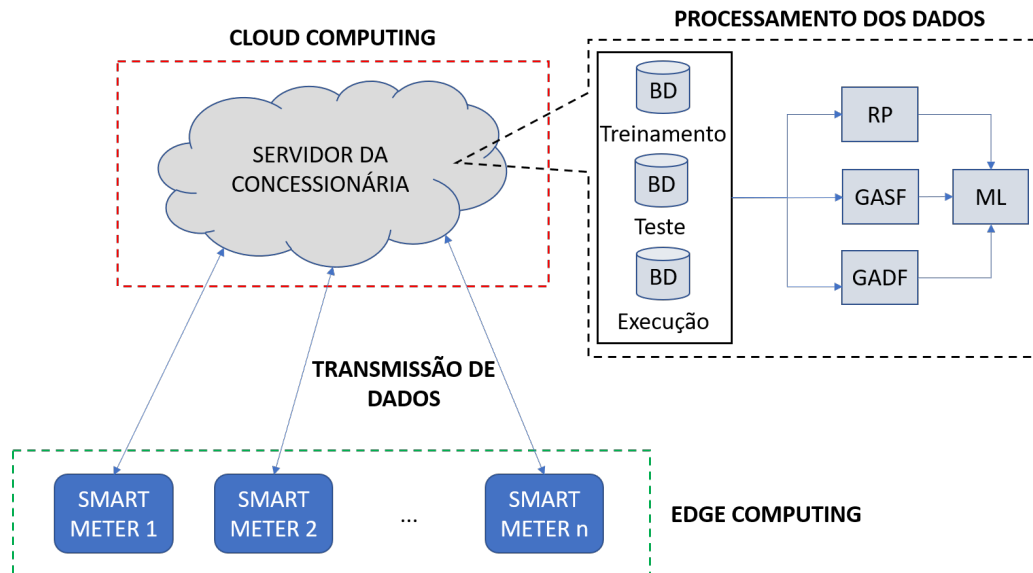
Conforme discutido, a QEE é um importante campo de pesquisa, uma vez que as cargas baseadas em dispositivos da eletrônica de potência, bem como a entrada e saída de grandes blocos de cargas e a ocorrência de faltas no sistema, têm contribuído de forma significativa para sua degradação, acarretando em distúrbios que afetam os consumidores. Por exemplo, na indústria, elevados impactos financeiros podem ser observados, os quais são resultantes da substituição de equipamentos com alto valor agregado, paralisações não programadas das linhas de produção e perda de matéria prima.

Além disso, distúrbios que interferem na QEE ocorrem de forma corriqueira ao longo dos alimentadores de distribuição de energia elétrica. Ações corretivas, efetivas e rápidas devem ser tomadas para mitigar ou não afetar o consumidor e os equipamentos da concessionária que estejam conectados ao SEP. Por isso, fazem-se necessários procedimentos que detectem e classifiquem os distúrbios para iniciar as manobras corretivas que serão executadas para manter a QEE da rede de distribuição a níveis aceitáveis determinados por normas/recomendações.

Portanto, a motivação da presente pesquisa vem da necessidade de aprimorar as técnicas existentes para o monitoramento da QEE. Vale mencionar que a modernização dos SEPs com a instalação de SMs, ao longo dos alimentadores, que disponibilizam dados em tempo real às concessionárias é um aspecto que motiva o *framework* proposto nessa dissertação, conforme

ilustrado na Figura 1.

Figura 1 – Contexto da pesquisa. BD representa a Base de Dados, RP *Recurrence Plot*, GASF *Gramian Angular Summation Field*, GADF *Gramian Angular Difference Field* e ML *Machine Learning*.



Fonte: Autoria própria.

Tem-se como hipótese que ao iniciar o processamento dos dados na borda da rede de comunicação (*edge computing*), o processo pode se tornar mais eficiente e não sobrecarregar os canais de comunicação. Seguindo as ideias básicas de *edge computing* apresentadas por [Shi et al. \(2016\)](#) e transpondo para o setor elétrico, as tarefas de detecção, segmentação e compactação dos distúrbios devem ser realizadas pelos próprios SMs.

Devido ao grande número de *edge devices* de uma concessionária, haverá a necessidade de armazenar um grande volume de dados. Assim, o uso de um serviço de *cloud computing* mostra-se vantajoso pela sua característica de escalabilidade, seja em termos de armazenamento e/ou de poder computacional. Portanto, somente na *cloud computing* são executados os procedimentos necessários à descompactação dos dados, extrações de características e classificação dos distúrbios por meio de algoritmos de *Machine Learning*.

Por fim, essas hipóteses também motivam a análise de desempenho de todo o *framework*, visto que a literatura correlata se baseia apenas em partes isoladas desse *framework* e, portanto, não se tem uma medição de desempenho geral sobre uma abordagem que busque se aproximar da realidade das SGs do ponto de vista da classificação de distúrbios de QEE.

1.2 Objetivos

Diante do exposto, destaca-se que o objetivo geral desta pesquisa consiste em desenvolver um *framework* baseado em técnicas de *Soft Computing* – algoritmos de processamento de sinais em conjunto com aprendizado de máquina – que suporte a detecção, segmentação, compressão e

classificação de distúrbios de QEE, assegurando que o mesmo possa ser aplicado no contexto de SG. Para se atingir este objetivo geral, na sequência são elencados os objetivos específicos:

- Desenvolver um algoritmo de detecção de distúrbios de QEE que possa, além de detectar a presença de distúrbios, segmentar os sinais elétricos adquiridos pelos SMs;
- Implementar um algoritmo de compressão de sinais, baseado em técnicas já existentes na literatura, que permita um bom *trade-off* entre a redução dos pacotes de dados e a perda de informação;
- Garantir que os algoritmos de detecção/segmentação e compressão apresentem bom desempenho e baixo poder computacional, de forma que possam ser adequados para aplicações em *hardware*;
- Averiguar o potencial dos RPs, GASFs e GADFs como novas características a serem extraídas dos sinais que representam os distúrbios de QEE;
- Desenvolver um algoritmo de classificação de distúrbios baseado em CNNs, buscando realizar comparações frente às abordagens encontradas na literatura correlata.

1.3 Organização da Dissertação

A dissertação está organizada em seis capítulos principais, a saber:

- Capítulo 1 – direcionado a introduzir o tema desta pesquisa, bem como apresentar os objetivos, motivações e justificativas;
- Capítulo 2 – destina-se à apresentação dos fundamentos de QEE, discorrendo sobre os distúrbios que afetam a QEE e normatizações estabelecidas por órgãos regulamentadores;
- Capítulo 3 – apresenta uma revisão bibliográfica das publicações científicas relacionadas à detecção e segmentação de distúrbios, compressão de sinais elétricos e classificação de distúrbios;
- Capítulo 4 – designado a demonstrar os aspectos do *framework* proposto, em que se detalhou cada uma das etapas que o compõe;
- Capítulo 5 – é destinado a apresentar e discutir os resultados encontrados;
- Capítulo 6 – apresenta as conclusões da dissertação.

ASPECTOS FUNDAMENTAIS DE QUALIDADE DA ENERGIA ELÉTRICA

Neste capítulo serão apresentados alguns aspectos fundamentais para a introdução do conceito de QEE, destacando os distúrbios explorados na literatura e as normatizações locais e/ou internacionais de maior relevância para a área de pesquisa.

2.1 Qualidade da Energia Elétrica

A QEE é uma área de pesquisa que tem se destacado nas últimas décadas, principalmente, devido ao aumento da ocorrência de distúrbios na rede elétrica e também pelas normatizações que buscam definir limites e indicadores que guiem a operação das redes de distribuição de energia elétrica.

Neste sentido, o movimento de desregulamentação do setor energético faz com que as concessionárias, para evitar prejuízos, busquem entregar aos consumidores um serviço de qualidade em termos de fornecimento de energia elétrica. Entretanto, os limites impostos pelas agências reguladoras tem sido cada vez mais restritivos, uma vez que as cargas dos consumidores, normalmente baseadas em dispositivos microprocessados, são mais sensíveis a variações na tensão, corrente e/ou frequência. Essas variações podem causar desde a operação indevida até a falha das cargas, podendo acarretar em perdas financeiras (DUGAN *et al.*, 2012).

Vários fatores, por sua vez, são responsáveis pela degradação da QEE em sistemas de distribuição de energia elétrica. Como exemplos, pode-se citar o crescente uso de cargas não lineares, energização/desenergização de grandes blocos de carga, descargas atmosféricas, dentre outros não menos importantes.

O PRODIST (ANEEL, 2021) define cinco categorias de distúrbios que podem afetar a QEE, que são: variação de tensão de curta duração, flutuação de tensão, distorções harmônicas,

variação de frequência e desequilíbrio de tensão. Entretanto, o IEEE *Std.* 1159-2009 (IEEE, 2019) define sete, que são: variações de tensão de curta duração, variações de tensão de longa duração, transitórios, flutuações de tensão, distorção da forma de onda, variação da frequência do sistema e desequilíbrio de tensão. Maiores detalhes sobre os distúrbios serão apresentados na Seção 2.2.


2.2 Distúrbios de QEE

2.2.1 Variações de Tensão de Curta Duração

As Variações de Tensão de Curta Duração (VTCDs) são fenômenos oriundos geralmente da energização/desenergização de grandes blocos cargas, ocorrência de falta e da interrupção do fornecimento de energia (normalmente como resultado da atuação do sistema de proteção) (DUGAN *et al.*, 2012). Dependendo do tempo de sua duração, estes eventos podem ser classificados em: variação momentânea (inferior ou igual a 3 segundos) ou variação temporária (superior a 3 segundos e inferior a 3 minutos). Entretanto, a depender de sua magnitude, ainda são classificadas em: interrupção (menor que 0,1 p.u.), afundamento (0,1 a 0,9 p.u.) ou elevação (maior que 1,1 p.u.) (ANEEL, 2021).

As interrupções se caracterizam pela brusca redução da magnitude do valor eficaz (ou *rms*) da tensão por um certo período de tempo, conforme ilustrado na Figura 2. Sua origem pode decorrer de curto-circuitos na rede elétrica, manutenção da rede, descargas atmosféricas, entre outros casos.

Figura 2 – Interrupção de Tensão.




Fonte: Autoria própria.

Segundo Dugan *et al.* (2012), os afundamentos de tensão também são caracterizados por uma redução do valor eficaz da tensão por um certo período de tempo, porém apresentando magnitudes entre 0,1 e 0,9 p.u. Isso ocorre pois os afundamentos de tensão também são oriundos

da energização de grandes blocos de carga e partida de grandes motores. Encontra-se corriqueiramente na literatura a utilização dos termos *sag* e *dip* para se referir a este tipo de distúrbio, o qual encontra-se ilustrado na Figura 3.


Figura 3 – Afundamento de Tensão.



Fonte: Autoria própria.

As elevações de tensão também são caracterizadas por sua magnitude e duração (Figura 4), sendo internacionalmente denominadas por *Swell* e são oriundas da energização de grandes blocos de cargas e bancos de capacitores (DUGAN *et al.*, 2012).

Figura 4 – Elevação de Tensão.



Fonte: Autoria própria.


2.2.2 Variações de Tensão de Longa Duração

As Variações de Tensão de Longa Duração (VTLDs) também são evidenciadas por desvios significativos na magnitude da tensão da rede elétrica. Entretanto, suas durações perduram

necessariamente por mais do que 1 minuto. Os eventos de longa duração com amplitude igual a 0 p.u. são denominados interrupções sustentadas. Ainda, tem-se as subtensões (entre 0,8 a 0,9 p.u.) e as sobretensões (entre 1,1 a 1,2 p.u.) (IEEE, 2019).


As interrupções sustentadas são originadas a partir de faltas (internas ou externas à rede) e requerem intervenção humana para reparar o sistema (DUGAN *et al.*, 2012). Por outro lado, as subtensões e sobretensões têm origem interna por causas próprias do sistema (ANEEL, 2021). Esses distúrbios são ilustrados nas Figuras 5 a 7.

Figura 5 – Interrupção Sustentada de Tensão.



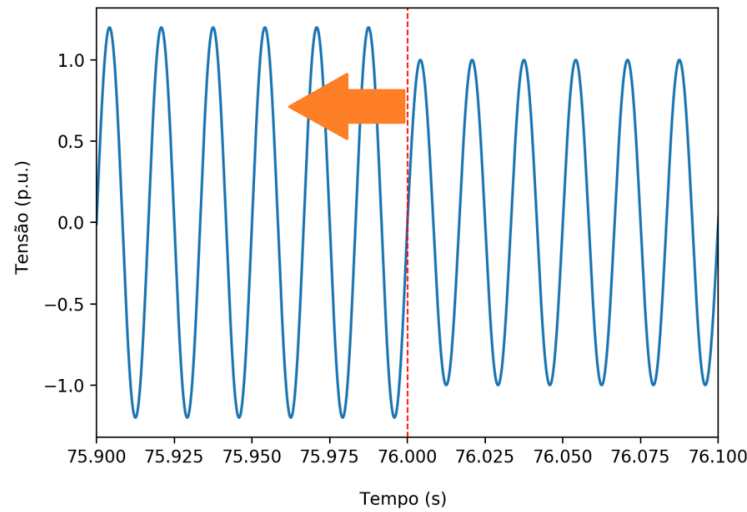
Fonte: Autoria própria.

Figura 6 – Subtensão.



Fonte: Autoria própria.

Figura 7 – Sobretensão.




Fonte: Autoria própria.

2.2.3 Transitórios

Os distúrbios transitórios são eventos rápidos, porém indesejáveis no SEP, podendo ser classificados, segundo [Dugan et al. \(2012\)](#), em: impulsivos ou oscilatórios.

Os transitórios impulsivos são resultantes de descargas atmosféricas no SEP e provocam alterações repentinas na frequência da tensão e/ou corrente, com polaridade unidirecional positiva ou negativa ([DUGAN et al., 2012](#)). A Figura 8 ilustra a ocorrência de um transitório impulsivo. Ainda, pelo tempo de duração pode ser rotulado em: nanossegundos (menor que 50 ns), microssegundos (maior que 50 ns a 1 ms) e milissegundos (maior que 1 ms) ([IEEE, 2019](#)).

Figura 8 – Transitório Impulsivo.




Fonte: Autoria própria.

É importante salientar que os transitórios impulsivos podem causar uma excitação na frequência natural do sistema e produzir transitórios oscilatórios, os quais se caracterizam pela

alternância entre a polaridade positiva e negativa (DUGAN *et al.*, 2012), conforme mostrado na Figura 9. De acordo com o conteúdo espectral (componentes de frequência), amplitude e duração, os transitórios oscilatórios podem ser classificados, segundo (IEEE, 2019), como:

- baixa frequência – componentes de frequência abaixo de 5 kHz, amplitude entre 0 e 4 p.u. e duração entre 0,3 e 50 ms;
- média frequência – componentes de frequência entre 5 e 500 kHz, amplitude entre 0 e 8 p.u. e duração de 20 μ s;
- alta frequência – componentes de frequência entre 0,5 e 5 MHz, amplitude entre 0 e 4 p.u. e duração de 5 μ s.

Figura 9 – Transitório Oscilatório.



Fonte: Autoria própria.


Os transitórios oscilatórios de baixa frequência podem ser consequentes da ferrossonância e energização de transformadores; os de média frequência são devidos à energização de bancos de capacitores em *back-to-back* e chaveamentos (manobras); e, por fim, os de alta frequência também podem dar uma resposta aos transitórios impulsivos ou a chaveamentos na rede (DUGAN *et al.*, 2012).

2.2.4 Flutuações de Tensão

As flutuações de tensão são caracterizadas por variações na magnitude em repetitivos instantes de tempo, conforme pode ser observado na Figura 10. De acordo com Malange (2010), elas podem ser causadas por cargas de potência elevada, como por exemplo os fornos a arco. Destaca-se que as flutuações de tensão são visualmente notadas, visto que causam a cintilação luminosa de lâmpadas convencionais (ANEEL, 2021), efeito denominado *flicker* (DUGAN *et al.*, 2012).

O módulo 8 do PRODIST traz um indicador denominado por Severidade de Flutuação de Tensão de Curta Duração (Pst, do inglês *Probability Short-Term*), baseado em IEC (2010), para calcular a sensação da cintilação luminosa, expressa em p.u., verificada em um período contínuo de 10 minutos. O valor do indicador Pst que for superado em apenas 5% das 1008 leituras válidas obtidas em intervalos consecutivos (período de agregação) de 10 minutos cada (Pst95%) tem como limite de aceitabilidade de 1.0 p.u. para tensões nominais menores ou iguais a 1,0 kV, de 1,5 p.u. para tensões entre 1,0 kV e 69,0 kV e 2.0 p.u. para tensões maiores ou iguais que 69,0 kV e menores ou iguais que 230,0 kV (ANEEL, 2021).

Figura 10 – Flutuação de Tensão.



Fonte: Autoria própria.

2.2.5 Distorções da Forma de Onda

As distorções de forma de onda consistem em variações no espectro de frequência em relação a um sinal senoidal ideal (DUGAN *et al.*, 2012). De acordo com o PRODIST, as distorções da forma de onda são caracterizadas pelos componentes harmônicos. Entretanto, o IEEE Std. 1159-2019 mostra-se mais abrangente, visto que ainda inclui os inter-harmônicos e *notching*.

Apesar de as normas/recomendações supracitadas não abordarem o *spike* como distorção da forma de onda, na literatura correlata existem muitos trabalhos que o inclui nessa categoria de distúrbios (MISHRA; BHENDE; PANIGRAHI, 2008; LEE; SHEN, 2011; RODRIGUEZ *et al.*, 2014; KUMAR *et al.*, 2015; SINGH; SINGH, 2017; WANG; XU; CHE, 2019).


De forma geral, as distorções harmônicas são tensões ou correntes senoidais com componentes de frequência múltiplas e inteiras da frequência fundamental de operação do SEP (Figura 11). As distorções harmônicas podem ser provocadas por cargas não lineares, cargas com núcleo magnético ou dispositivos de integração de geradores eólicos ou fotovoltaicos à rede. O limite máximo de distorção harmônica de tensão, segundo o PRODIST, é de 10% em baixa

tensão (menor ou igual que 1,0 kV), 8% em média tensão (acima de 1,0 kV e abaixo de 69,0 kV) e 5% em alta tensão (maior ou igual que 69,0 kV e menor que 230,0 kV).

Em relação aos inter-harmônicos, pode-se dizer que estes também são oriundos do comportamento não linear de determinadas cargas, como, por exemplo, conversores de frequência estáticos, fornos de indução e fornos a arco (Figura 12). Sua caracterização se dá pela existência de componentes de frequência não múltiplas inteiras da frequência fundamental (DUGAN *et al.*, 2012).

O *notching* é um caso especial de distorção oriunda da operação de dispositivos elétricos quando a corrente é comutada de uma fase para outra (Figura 13). Sua presença é notada na tensão e possui comportamento periódico. Além disso, seus componentes de frequência podem se pronunciar em altas frequências e, portanto, não podem ser medidas por equipamentos de monitoramento normalmente utilizados para análise harmônica (DUGAN *et al.*, 2012).

Figura 11 – Distorção harmônica.




Fonte: Autoria própria.

Por fim, o *spike* é caracterizado por picos periódicos no sinal tensão, que se assemelham a um transitório oscilatório (não necessariamente em termos de magnitude). Cabe destacar que, visualmente sua representação temporal (Figura 14) é a mesma do *notching*, porém com polaridade invertida.

2.2.6 Variações de Frequência


A ANEEL (2021) estabelece que o sistema de distribuição e instalações de geração conectadas a este podem operar dentro da faixa limite de 59,9 Hz a 60,1 Hz em condições normais de operação e em regime permanente. Entretanto, em caso de ocorrência de distúrbios no sistema de distribuição, é necessário que as instalações de geração retomem para a faixa de

Figura 12 – Inter-harmônicos.



Fonte: Autoria própria.

Figura 13 – Notching.




Fonte: Autoria própria.

operação de 59,5 Hz a 60,5 Hz, dentro do intervalo de 30 segundos após o evento, para permitir a recuperação do equilíbrio do sistema.

Além disso, a ANEEL (2021) dispõe que, na necessidade de corte de geração ou de carga para garantir a recuperação do equilíbrio carga-geração, é permitido durante a ocorrência do distúrbio no sistema de distribuição: a frequência não ultrapassar os limites entre 56,5 Hz e 60 Hz em condições extremas; a frequência exceder valores acima de 62 Hz por no máximo 30 segundos e acima de 63,5 Hz por no máximo 10 segundos; e a frequência permanecer abaixo de 58,5 Hz por no máximo 10 segundos e abaixo de 57,5 Hz por no máximo 5 segundos.

Figura 14 – Spike.



Fonte: Autoria própria.

2.2.7 Desequilíbrio de Tensão

Os desequilíbrios de tensão ocorrem quando há qualquer diferença nas amplitudes e/ou defasagem angular dos fasores de tensão diferente de 120° (ANEEL, 2021). Sua origem está diretamente ligada à distribuição inadequada de cargas monofásicas, o que resulta no surgimento de tensões de sequência negativa (ANDRADE, 2017).

O PRODIST faz uso do Fator de Desequilíbrio (FD) de tensão, o qual é representado pela razão entre a magnitude da tensão eficaz de sequência negativa e a magnitude da tensão eficaz de sequência positiva. Para tensões nominais menores ou iguais a 1,0 kV, o do valor indicador FD que foi superado em apenas 5% das 1008 leituras válidas (FD95%) limita-se em 3,0%, enquanto para tensões nominais entre 1 kV e 230 kV o indicador é limitado a 2,0% (ANEEL, 2021).

REFERENCIAL BIBLIOGRÁFICO

Este capítulo apresenta uma revisão bibliográfica acerca das produções científicas de maior relevância à área de pesquisa, com a intenção de destacar as técnicas utilizadas para pré-processamento de sinais referentes a distúrbios de QEE, bem como dos algoritmos de classificação comumente empregados.

Assim, sequencialmente, serão apresentados os trabalhos que propuseram a detecção e segmentação (3.1), classificação (3.3) e compressão (3.2) de distúrbios de QEE. Ainda, será feita uma análise geral sobre os trabalhos revisados e técnicas abordadas (3.4).

3.1 Detecção e Segmentação de Distúrbios de QEE

[Santoso et al. \(1996\)](#) apresentaram uma abordagem para detecção e localização de distúrbios utilizando a *Wavelet Transform* (WT). Os autores comentam que as tarefas de detecção, segmentação e classificação são importantes para a determinação das causas dos distúrbios. Levando isto em consideração, os autores propuseram o uso da WT diádica-ortonormal como ferramenta para detectar e localizar os eventos de QEE. A ideia principal da proposta consistiu em decompor o sinal em vários níveis. Por meio desta técnica, a detecção da parcela do sinal que apresenta distúrbio pode ser ressaltada nos níveis de decomposição obtidos pela WT. Os autores apontam que a escolha do banco de filtros *wavelet* é muito importante neste quesito, pois o mesmo desempenha um papel significativo em destacar a parcela do sinal que contém distúrbio. Durante os testes, foram utilizados sinais reais de distúrbios de QEE, que incluem transitório oscilatório, *notching*, ruído, entre outros. Os autores decompueram os sinais até o quarto nível e utilizaram o banco de filtros *Daubechies* de ordem 4 (*db4*). Segundo os autores, a *db4* proporciona melhor localização temporal do distúrbio.

No trabalho de [Angrisani et al. \(1998\)](#), foi utilizada a WT contínua para detecção e estimação do tempo de duração dos eventos de QEE. Os autores apontam que outros trabalhos

da literatura já vêm utilizando a WT para este mesmo fim. Sobretudo, eles identificaram que o comportamento dos máximos locais nas escalas da WT contínua auxiliam na abstração de características interessantes e úteis do sinal, uma vez que estão relacionados a pontos de variação mais acentuados no sinal. Os autores comentam que é possível detectar os pontos de início e fim de um distúrbio de forma precisa, inclusive em situações ruidosas. Os autores utilizaram um banco de filtros *Morlet*. Entretanto, os autores testaram apenas três classes de distúrbios submetidos a diferentes níveis de ruído, sendo: *notching* periódico, afundamento de tensão e transitório oscilatório. Os resultados alcançados mostraram que quanto maior o ruído, maior também será o erro percentual relativo para identificar *notching* e transitório oscilatório (erros entre 0.2% e 4%). Por outro lado, o afundamento de tensão pôde ser precisamente identificado.

[Dash et al. \(2003\)](#) propuseram o uso da *S-Transform* (ST), que representa uma forma modificada da WT. A ST utiliza uma janela Gaussiana móvel e escalável, a qual enquadra uma ampla gama de análises espectrais multirresolução. Os autores consideraram quatro casos para detecção: (i) transitório impulsivo; (ii) *flicker*; (iii) interrupção momentânea; e (iv) afundamento de tensão com distorção harmônica. A ST, segundo os testes dos autores, foi capaz de detectar e localizar claramente cada um dos distúrbios. Os autores ainda constataram que afundamentos e interrupções de tensão provocam uma redução na magnitude do contorno gerado pela ST, que é, por sua vez, análoga ao que acontece com a magnitude de tensão. Ou seja, há uma relação de comportamento entre o sinal da ST e o sinal original do distúrbio.

[Ece e Gerek \(2004\)](#) propuserem a detecção dos distúrbios por meio de representações em duas dimensões (2D). Na metodologia, a representação 2D visa compor uma matriz cujas linhas são formadas por seguimentos não sobrepostos do sinal, produzindo uma imagem ou superfície 2D. Os autores destacam que este processo permite a formação de linhas verticais e horizontais, caracterizando o comportamento do sinal. Para explorar estas características, eles utilizaram a DWT bidimensional, a qual é responsável por detectar os distúrbios de QEE, uma vez que possibilita a filtragem tanto na direção horizontal quanto vertical. Contudo, este tipo de decomposição requer duas vezes o esforço computacional necessário para uma WT tradicional com o mesmo banco de filtros. Para testar o desempenho da detecção, foram considerados sinais de tensão adquiridos a 20 kHz, nos quais estavam presentes os seguintes distúrbios: afundamento de tensão, inter-harmônico e distorção harmônica. Para esta finalidade, os filtros *Daubechies* de ordem 2 (*db2*) mostraram-se mais adequados, principalmente ao realizar a decomposição em apenas um nível. Os autores notaram que após suprimir as folhas da WT que representam as aproximações e manter apenas os detalhes, DWT 2D inversa fornece bons resultados de detecção e localização temporal do distúrbio.

[Radil et al. \(2008\)](#) aplicaram um filtro digital em conjunto com morfologia matemática e análise de *Root Mean Square* (RMS) para detectar distúrbios de QEE. Neste trabalho foi aplicado uma etapa de pré-processamento antes de iniciar o processo de detecção propriamente dito, que consistiu na normalização do segmento de sinal. A normalização, segundo os autores,

torna os estágios posteriores independentes da tensão nominal do sistema e da faixa do sinal de saída do transdutor. Feito isso, o sinal é então introduzido no estágio de detecção. Os distúrbios foram divididos em duas categorias: (i) transitórios e distorções; e (ii) afundamentos, elevações, interrupções, sobretensões e subtensões. Portanto, nota-se que basicamente os autores propõem uma separação entre distúrbios que afetam a frequência do sinal e aqueles que são caracterizados apenas pela variação de amplitude e tempo de ocorrência. Para o primeiro grupo, a abordagem proposta utiliza um filtro passa-alta para remover as componentes de baixa frequência do sinal normalizado, como por exemplo a frequência fundamental. Apesar do sinal resultante conter as características necessárias para detecção, os autores aprimoram estas características utilizando um operador morfológico do tipo Fechamento. Este operador, em suma, realiza operações de dilatação e erosão que acabam simplificando o sinal. Após a operação morfológica, a detecção fica a cargo da aplicação de um limiar sobre o sinal. Para o outro grupo de sinais, realiza-se apenas uma análise do valor eficaz (RMS) da tensão. O sinal normalizado é comparado com dois níveis de limiares (a) abaixo do valor RMS nominal e (b) acima do valor RMS nominal. Histerese é utilizada na detecção do início e do fim do evento para evitar a detecção de eventos falsos, como por exemplo nos casos em que o valor do RMS permanece próximo a um dos níveis de limiar por um período de tempo. Os resultados puderam constatar que a abordagem proposta é precisa na detecção temporal dos distúrbios, bem como apresenta menor esforço computacional do que uma WT.

O artigo de [Cho, Jang e Kwon \(2010\)](#) adotou uma análise em tempo e frequência de eventos de QEE por meio da *Gabor Transform* (GT) que é uma versão estendida da *Short-Time Fourier Transform* (STFT) e utiliza uma janela de função Gaussiana. Os autores comentam que a GT oferece boa resolução em frequência e baixa resolução no tempo para uma janela grande. À medida que o tamanho da janela é reduzido, a resolução no tempo melhora em detrimento da resolução em frequência. Ainda, foi empregada a *Wigner Distribution Function* (WDF) para auxiliar na melhora da análise no domínio tempo-frequência. No experimento, foram investigados sete tipos de distúrbios, que incluem elevação de tensão, afundamento de tensão, distorção harmônica, inter-harmônico, transitório, *flicker* e alterações de tensão com múltiplas frequências. Todos os distúrbios foram gerados de forma sintética. Os autores demonstram que a abordagem proposta, denominada por *Gabor-Wigner Transform* foi capaz de melhorar as resoluções de tempo e frequência ao mesmo tempo que superou o problema de *cross-term* (não linearidade) do WDF. Além disso, os autores observaram que o comprimento da janela ainda é um ponto crítico para análise de tempo e frequência. Eles recomendam uma janela mais ampla para detectar mudanças lentas e uma janela menor para detectar mudanças rápidas. No caso do afundamento de tensão, por exemplo, a *Gabor-Wigner Transform* forneceu a melhor resolução em frequência, comparada às técnicas GT e WDF. Com uma janela menor, a informação temporal melhorou, contudo as informações de frequência se tornaram imprecisas. Para fenômenos instantâneos e intermitentes, como transitórios e *flicker*, uma janela mais estreita forneceu maiores informações temporais. Por fim, [Cho, Jang e Kwon \(2010\)](#) complementam que, caso haja a necessidade de

detectar pequenas diferenças de frequência, é necessário a implementação de uma janela mais ampla ao custo de informações mais vagas.

Borges (2013) realizou a detecção e segmentação de distúrbios de QEE por meio do janelamento do sinal. Inicialmente foi gerado um banco de dados contendo 100 amostras de cada uma das 16 classes consideradas e cada amostra possui a dimensão de dez ciclos de sinal. O processo de janelamento ocorre deslocando-se uma janela de dados com tamanho de um ciclo de sinal e com passo unitário até percorrer todo o sinal. Cada janela é rotulada de acordo com a presença ou não do distúrbio na janela, ou seja, um problema de classificação binário. As janelas que apresentam ao menos uma amostra do distúrbio já devem ser classificadas como “presença de distúrbio”. O processo de tomada de decisão adotado pelo autor consistiu na comparação do valor RMS e Distorção Harmônica Total (DHT) extraído de janelas com valores de referência (sem distúrbio). Caso o valor da distância euclidiana entre o valor de RMS ou de DHT extraídos e suas respectivas referências ultrapasse um limiar, a janela era rotulada como “presença de distúrbio”. O autor comenta que o valor do limiar e os valores de referência devem ser ajustados de acordo com a taxa de amostragem do sinal adquirido. Nos testes, foram consideradas as taxas de amostragem de 16, 32, 64, 128 e 256 amostras discretas por ciclo de sinal. O autor observou que, apesar de a taxa de acertos ser superior a 80% em todos os casos, o erro da detecção aumenta à medida que o número de amostras por ciclo é elevado. Ademais, o autor ainda demonstra que o algoritmo de detecção proposto tem baixa taxa de acertos para as primeiras janelas que caracterizam o distúrbio, ou seja, aquelas em que o número de amostras do distúrbio é muito baixo. Sobretudo, foi possível alcançar uma taxa de acertos acima de 95% para janelas que possuam ao menos 25% das amostras que caracterizam o distúrbio na janela temporal.

Biswal *et al.* (2014) utilizaram a combinação de *Empirical Mode Decomposition* (EMD) e *Hilbert Transform* (HT) para realizar a detecção e classificação de distúrbios. Os autores comentam que a maioria dos eventos de QEE não é estacionária e, portanto, necessita da implementação de técnicas capazes de obter informações de frequência e tempo. Nessa abordagem, a EMD decompõe o sinal e disponibiliza para a HT, a fim de se obter informações de amplitude e frequência instantânea do sinal. A ideia da EMD, segundo os autores, é aplicar repetidamente um processo conhecido como *sifting* para separar as componentes oscilatórias do sinal, de modo que no final o sinal seja totalmente dividido em componentes oscilatórias simples. Os autores testaram a aplicação desta técnica para a detecção de transitórios oscilatórios com múltiplos *spikes*, inter-harmônicos e múltiplos transitórios oscilatórios. Como resultados, foi possível detectar e localizar visualmente todos os distúrbios abordados por meio do espectro de energia de Hilbert, que fornece a resposta de frequência instantânea, e do gráfico de resposta de magnitude temporal. É importante salientar que o espectro de Hilbert proporciona uma visualização intuitiva de quais frequências ocorrem durante um sinal e também destaca as regiões onde a maior parte da energia espectral está concentrada. Por fim, tendo em vista os resultados alcançados, Biswal *et al.* (2014) concluem que a EMD com HT é uma promissora ferramenta para decomposição de sinais e proporciona uma visualização clara para detecção e localização temporal dos distúrbios

analisados.

Manikandan, Samantaray e Kamwa (2015) promoveram a detecção usando a técnica de *Sparse Signal Decomposition* (SDD) com *Overcomplete Hybrid Dictionaries* (OHDs). A combinação destas técnicas promove a decomposição do sinal em dois sub-sinais: o sinal de detalhe contendo transitórios e distorções da forma de onda (harmônicos, inter-harmônicos, *spike*, transitório impulsivo, notching e ruído) e sinal de aproximação contendo o sinal fundamental e outros distúrbios (*flickers*, afundamento, elevação, interrupção, entre outros). Os autores apontam que a representação esparsa vem sendo utilizada com sucesso no processamento de sinais e os OHDs podem auxiliar em uma melhor representação na composição do sinal, que podem incluir componentes estacionárias e não estacionárias. Nessa abordagem, ainda são extraídas características como RMS dos detalhes e aproximações para a detecção a presença dos distúrbios. Para demonstrar a efetividade da técnica, foram considerados sinais sintéticos gerados com a adição de ruído gaussiano de 45 dB. Com base nos resultados, os autores evidenciaram a capacidade de detecção de distúrbios da abordagem proposta. Entretanto, houve a necessidade de se estabelecer limiares nos sinais de aproximação e detalhe para aumentar a taxa de acertos, principalmente por causa dos ruídos.

O trabalho de Singh *et al.* (2019) implementou a *Orthogonal Empirical Mode Decomposition* (OEMD) em *Field-Programmable Gate Array* (FPGA) para detecção de afundamentos de tensão e *notching*. Eles justificaram o uso da OEMD devido à técnica não provocar a perda de características do sinal quando decomposto em níveis sucessivos. Os autores conduziram o experimento envolvendo dados simulados e reais obtidos por meio de um experimento laboratorial. A capacidade de detecção da técnica embarcada foi comparada com a da DWT e a EMD. Nos resultados, os autores constataram que a DWT foi capaz de detectar os distúrbios somente em situações em que não houve a adição de ruído ao sinal, enquanto o desempenho da EMD se degradou à medida que o nível de ruído no sinal foi elevado. A OEMD, por sua vez, mostrou-se mais consistente na detecção de distúrbios, mesmo em condições ruidosas.

Bastos *et al.* (2019) propuseram um método baseado na tensão RMS para determinar os instantes de início e fim da ocorrência de afundamentos e elevações de tensão. Os autores comentam que o método tradicional calcula a tensão RMS sobre uma janela deslizante de tamanho de 1 ciclo de sinal e o valor RMS da tensão é atualizado a cada $\frac{1}{2}$ ciclo de sinal. Assim, valores RMS abaixo de um limiar são definidos como afundamento, enquanto valores acima de outro limiar são definidos como elevações. Os autores demonstram que este método não é tão preciso para segmentar a parcela de distúrbio contida no sinal. Em vista disso, eles introduziram um novo método baseado na diferença absoluta entre o valor RMS passado e o valor RMS futuro. Caso o resultado desta diferença resulte em um valor próximo a zero, entende-se que o distúrbio ainda não iniciou ou que ele já terminou. O instante de início ou fim do distúrbio se dá quando a diferença entre o RMS passado e o RMS futuro atinge um ponto de máximo. No experimento, os autores realizaram uma comparação de desempenho da técnica envolvendo a técnica tradicional

com atualização de RMS a cada $\frac{1}{2}$ ciclo e a cada amostra de discreta. Os autores identificaram, com base em dados reais de tensão, que a abordagem proposta desempenhou melhor a tarefa de identificação do início e fim do distúrbio. A maior latência constatada pelos autores foi de três amostras de sinal em relação ao instante de tempo exato de início/fim, enquanto para o método tradicional foi acima de 116 amostras. Para maior eficiência da abordagem, os autores ainda recomendam o uso de janelas deslizantes curtas ($\frac{1}{2}$ ciclo) para eventos rápidos e janelas mais longas quando há a presença de distorção harmônica acima de um nível pré-determinado. Em alguns casos também é necessário aplicar um filtro passa-baixa antes da aplicação desta técnica.

Moraes e Fernandes (2019) propuseram uma abordagem de detecção de distúrbios para ser implementada no âmbito de *edge computing*, em que os SMs são os *edge devices* em uma SG. Os autores apontam que a identificação precisa dos instantes de início e fim da ocorrência de um distúrbio, quando realizada diretamente pelo SM, contribui para a redução do pacote de dados a ser transmitido à concessionária e, ainda, permite uma tomada de decisão mais rápida e adequada por parte dos engenheiros de QEE. Para tanto, os autores propuseram a detecção e segmentação dos distúrbios aplicando um processo de janelamento de sinal, similar ao adotado por Borges (2013). Contudo, novas características foram extraídas dos sinais e utilizadas como entradas aos algoritmos de *Machine Learning* para realizar a detecção da presença ou ausência de distúrbios. Os algoritmos testados foram RNA, DT e Regressão Logística (RL). Entretanto, buscando reduzir o esforço computacional dos classificadores, realizou-se uma etapa de seleção de características por meio do algoritmo *Correlation-Based Feature Selection* (CFS). Neste sentido, somente as seguintes características foram consideradas no processo de classificação: DHT, desvio padrão, desvio médio, *kurtose*, entropia, entropia de *Shannon*, entropia de *Rényi*, valor RMS, valor de pico e diferença entre o maior e o menor valor da janela. A abordagem proposta foi avaliada por meio de sinais sintéticos que englobam oito classes de distúrbios, a saber: afundamento, elevação, flutuação de tensão, distorção harmônica, interrupção momentânea, *notching*, *spike* e transitório oscilatório. Os autores comentam que, para garantir maior similaridade entre os sinais sintéticos e reais, foram adicionados ruídos entre 20 e 45 dB. Nos testes, a DT apresentou o melhor resultado de classificação, mesmo nas situações em que a relação sinal-ruído era alta (97,99%). O pior desempenho ficou à cargo da RL, que apresentou um desempenho de acerto médio de 82,22% para a alta incidência de ruído.

Junior *et al.* (2021) propuseram uma metodologia similar à de Borges (2013). Entretanto, embarcando a técnica de detecção de distúrbios em um *hardware* de medição de baixa tensão que usa um ARM Cortex M4 para simular um sistema operacional em tempo real. O processo de tomada de decisão para julgar se uma janela de dados contém ou não a presença de distúrbios de QEE também se baseou na comparação de valor RMS e DHT com valores de referência previamente definidos. Para a condução da pesquisa, foram gerados sinais sintéticos a uma taxa de amostragem de 64 amostras/ciclo, que incluem as seguintes classes de distúrbios: afundamento de tensão, elevação de tensão, *flicker*, distorção harmônica, transitório impulsivo, interrupção de tensão, transitório oscilatório, afundamento de tensão com distorção harmônica, elevação de

tensão com distorção harmônica, *flicker* com distorção harmônica, afundamento de tensão com transitório oscilatório e elevação de tensão com transitório oscilatório. O método proposto pelos autores obteve uma acurácia de 81,33% para a detecção de janelas com distúrbio e 98,03% para janelas sem distúrbio. Nota-se ainda que o modelo proposto pelo autores atingiu uma acurácia acima de 90% para janelas que continham 23 ou mais amostras de distúrbio.

Com base nos trabalhos revisados, nota-se que a WT foi uma das primeiras técnicas utilizadas para a detecção/segmentação de distúrbios e há uma vasta gama de tipos de filtro *wavelet* e níveis de decomposição que podem ser aplicados. Contudo, a escolha do melhor filtro e nível de decomposição para todas as classes de distúrbio não é uma tarefa trivial. Além disso, conforme o estudo realizado por [Singh et al. \(2019\)](#), foi constatado que a WT não responde bem a cenários ruidosos. Ademais, uma outra tarefa desafiadora que permeia o uso de técnicas de transformação, como WT, ST e EMD, é a de encontrar um limiar ótimo, que possa detectar e segmentar o maior número de classes de distúrbios de QEE, incluindo os eventos mais expressivos como afundamento e elevação de tensão, e os mais sutis, como transitório impulsivo, *notching* e *spike*, por exemplo. [Morales e Fernandes \(2019\)](#), [Bastos et al. \(2019\)](#) e [Junior et al. \(2021\)](#) trazem novas abordagens para a detecção/segmentação de distúrbios, as quais se baseiam na análise janelada do sinal de tensão e que não necessita da aplicação de limiar, qualificando, portanto, um avanço do estado da arte perante as técnicas anteriormente utilizadas.

3.2 Compactação de Distúrbios de QEE

[Santoso, Powers e Grady \(1997\)](#) utilizaram uma técnica baseada na WT para compressão de distúrbios de QEE. Eles enfatizam que o volume crescente de dados capturados por instrumentos de monitoramento impacta em um elevado custo para armazenamento destes dados, o que torna a compressão uma ferramenta altamente desejável. Neste sentido, o processo de compressão proposto pelos autores incluiu a decomposição do sinal, eliminação de alguns valores da decomposição por meio da aplicação de um limiar e reconstrução do sinal. A decomposição foi executada por meio da aplicação da DWT, que separou o sinal em coeficientes de aproximação e detalhe. Então, o limiar foi definido com base no valor máximo absoluto dos coeficientes de detalhes associados a cada nível de decomposição da DWT, em que valores abaixo do limiar são igualados a zero. Esta etapa do processo descarta cerca de 90% do total dos coeficientes da WT, que majoritariamente estão associados a ruídos no sinal. A reconstrução, por sua vez, ficou por conta da DWT inversa. Entretanto, os autores colocam que, apesar de ocorrer perdas de informação no processo de compressão, a reconstrução do sinal apresenta alta fidelidade e a maioria dos distúrbios são bem preservados. Para tanto, foram analisadas situações de transitórios e *notching*. No experimento, os autores constataram que o sinal, quando decomposto até o terceiro nível de uma WT com banco de filtro *Daubechies* de ordem 4 (*db4*) obtém uma taxa de compressão maior do que se decomposto até o primeiro ou segundo nível. Contudo, quanto maior o nível de decomposição, menor será a fidelidade do sinal reconstruído.

Hsieh, Huang e Huang (1998) também abordaram uma técnica de compactação de distúrbios de QEE baseado na WT. Entretanto, os autores adotaram uma nova estratégia que busca extrair a diferença entre o sinal original e o sinal de referência senoidal, de modo a filtrar informações não relevantes antes do processo de decomposição pela WT. Para os autores, as técnicas de compressão são uma viável alternativa para não sacrificar importantes características do sinal da rede em face do crescente aumento no volume de dados requeridos para análise em um SEP. Nessa abordagem, o sinal é decomposto em apenas um nível utilizando também uma *db4*. Durante as análises, foram considerados afundamentos de tensão, distorções na forma de onda e interrupções momentâneas de tensão, sendo todos gerados sinteticamente. Por meio dos resultados obtidos nos testes, os autores demonstram que a proposta não apenas reduziu o tamanho do pacote de dados, mas também a capacidade de reconstrução do sinal ainda que com um pequeno erro.

Littler e Morrow (1999) propuseram um trabalho comparativo, em termos de compressão de sinais de QEE. Para tanto, consideraram os seguintes algoritmos: DWT, *Wavelet Packet Transform* (WPT) e *Discrete Cosine Transform* (DCT). Os autores mencionam que os dispositivos de medição frequentemente devem transmitir os dados para o centro de controle e operações da concessionária, onde deverão ser minuciosamente estudados. Entretanto, ao monitoramento um SEP, poderá haver dezenas e/ou centenas de unidades que deverão transmitir os dados por uma mesma banda de comunicação. Dessa forma, é notável a necessidade de se aplicar técnicas de compressão que garantam a redução dos pacotes de dados. Neste contexto, os autores mencionam que a WT é uma importante ferramenta de compressão, pois a mesma proporciona a preservação da integridade das características do sinal e a remoção de redundâncias. No entanto, nesse estudo, os autores propõem o uso de um banco de filtros *Daubechies* de ordem 20 (*db20*) para a DWT e a WPT, bem como um limiar baseado no cálculo da energia das folhas de aproximação e/ou detalhe. Notou-se que as melhores reconstruções dos sinais foram realizadas pela DWT e WPT, além de removerem ruídos de baixa amplitude, a uma taxa de compressão 10:1.

O trabalho de Panda *et al.* (2002) apresenta uma abordagem para compressão usando a Transformada *Slantlet*, que é uma DWT com dois momentos nulos e que permite a aplicação de diferentes filtros em cada escala. O volume de informações referentes a eventos de QEE, bem como a taxa de amostragem dos dispositivos de monitoramento, são elevados. Conforme exemplificação dos autores, 100 eventos com comprimento de 4 períodos e 128 amostras por ciclo requerem 3686 Kb, o que evidencia a necessidade da compressão dos dados antes de seu envio. Nesta proposta, os autores definem três distintos passos para a compressão e reconstrução dos sinais, que são: transformação do sinal de entrada utilizando a Transformada *Slantlet*, aplicação de um limiar nos coeficientes da transformada e a reconstrução do sinal. Todos os dados foram gerados computacionalmente a uma taxa de amostragem de 3 kHz e incluem afundamentos e elevações de tensão, distorções harmônicas, interrupções momentâneas de tensão, *flickers*, transitórios oscilatórios e impulsivos. Os sinais foram decompostos até o segundo nível, o valor do limiar definido pelo método do valor máximo absoluto e a taxa de compressão foi fixada

em 10:1. Em relação aos resultados alcançados, os autores constataram uma melhor precisão na reconstrução quando comparada a outros algoritmos como DWT e DCT.

O artigo apresentado por [Hamid e Kawasaki \(2002\)](#) aplica o critério de *Minimum Description Length* (MDL) para aprimorar a compressão de distúrbios utilizando DWT e WPT. Entretanto, a escolha do filtro *wavelet* é um ponto crítico, uma vez que este impacta na qualidade do sinal reconstruído. Neste sentido, a MDL auxilia na seleção do banco de filtros e também na quantidade de coeficientes. Esta abordagem testou 22 distintos bancos de filtros, que incluem as famílias *Daubechies*, *Coiflets* e *Symlets*. Na DWT, a compressão foi realizada pela decomposição do sinal até o quarto nível. Por outro lado, na WPT, a decomposição utilizou o critério da entropia mínima. Adicionalmente, os autores ainda empregaram métodos de compressão sem perdas (*Huffman Coding*, *Lempel-Ziv-Welch* e *Lempel-Ziv-Haruyasu*). Os procedimentos propostos nesse trabalho permitiram a obtenção de taxas de compressão de até 11%.

No estudo proposto por [Dash et al. \(2003\)](#), os autores embarcaram a *Spline Wavelet Transform* (SWT), que é uma WT construída usando uma função *spline*. No processo de compactação, após a decomposição do sinal até o terceiro nível de resolução, aplicou-se em cada um dos níveis um limiar baseado no valor máximo absoluto dos coeficientes da transformada para auxiliar na redução do pacote de dados. Os distúrbios analisados incluem transitório impulsivo, variação de frequência, interrupção momentânea e distorção harmônica, sendo todos os sinais amostrados a 10 kHz. Por meio dessa abordagem foi possível obter taxas de compressão entre 6.45 e 7.14, com erro médio quadrático normalizado na ordem de 10^{-4} a 10^{-6} . [Meher, Pradhan e Panda \(2004\)](#) propuseram uma abordagem semelhante, entretanto consideraram uma etapa de processamento por uma *Radial Basis Function Neural Network* (RBFNN) após a aplicação do limiar. A RBFNN desempenha o papel de intensificar o processo de compactação. Foram executados testes utilizando dados de transitório impulsivo, afundamento de tensão, elevação de tensão, distorção harmônica, interrupção momentânea de tensão, transitório oscilatório e flutuação de tensão a uma frequência de amostragem de 3 kHz. Nesse estudo, foi considerada uma taxa de compressão fixa de 15.

[Ribeiro, Romano e Duque \(2004\)](#) introduziram uma nova técnica de codificação de sinais senoidais para propósitos de monitoramento da QEE. A proposta dos autores apresenta um comportamento adaptativo, o qual busca estimar a componente senoidal fundamental do sinal e separá-la da resposta transitória de eventos. O processo de compressão proposto pelos autores consiste em: (i) estimar a amplitude e fase do sinal fundamental contido na janela de dados utilizando o filtro de Kalman; (ii) estimar a frequência da componente fundamental do sinal contido na janela de dados por meio de um filtro adaptativo do tipo *notch*; (iii) gerar o sinal fundamental baseado nos parâmetros estimados; (iv) subtrair o sinal original do fundamental gerado; (v) decompor o sinal resultante da etapa anterior utilizando a DWT; (vi) aplicar um limiar rígido pré-definido nos coeficientes da DWT (compressão com perdas); e (vii) aplicar uma compressão sem perdas usando o algoritmo *Lempel-Ziv-Welch*. No entanto, a complexidade

do filtro de Kalman depende da relação sinal-ruído e, com a inserção de uma etapa de pré-processamento do ruído, o desempenho deste algoritmo é aprimorado. Já em relação à estimação da frequência, foi escolhido o filtro adaptativo do tipo *notch* com atualização do ganho pelo *Recursive Least Square* (RLS). Nos experimentos foram considerados os seguintes distúrbios: *notching*, transitório oscilatório e distorção harmônica com transitório oscilatório de baixa frequência. Cada amostra de sinal, continha 5 ciclos e gerados sinteticamente a 60k amostras por ciclo e 12 bits de quantização. Nos testes, os autores perceberam que, utilizando a *db4*, a presença de componentes harmônicos e inter-harmônicos comprometem a eficácia da abordagem proposta e que se o sinal transitório tiver uma característica de banda curta, a melhor solução é executar a DWT com mais níveis de decomposição.

Ibrahim e Morcos (2005) trouxeram uma nova técnica de compressão de sinais de QEE vinculada a sistemas neuro-*fuzzy* adaptativos. Para lidar com o problema do volume de dados envolvido no monitoramento de SEPs, os autores propuseram a combinação das funções de pertinência de dois sistemas de inferência *fuzzy* para produzir um terceiro sistema de inferência *fuzzy* capaz de aprender a forma de onda de um transitório rápido. Por meio desse processo, o terceiro *fuzzy* é capaz de reproduzir a forma de onda com precisão, sem a necessidade de armazenar nenhum dos pontos de amostra de dados originais. Nos testes, foram considerados eventos de distorção da forma de onda e transitórios classificados como rápidos e muito rápido. Os resultados alcançados também mostraram a flexibilidade do sistema a uma variedade de taxas de amostragem (entre 128 e 16640 amostras por ciclo). Para avaliação dos resultados, foram empregados o erro médio quadrático e a taxa de compressão.

Ribeiro *et al.* (2007) apresentaram uma generalização da técnica proposta pelo mesmo grupo de pesquisa (RIBEIRO; ROMANO; DUQUE, 2004). Segundo os autores, os componentes harmônicos também podem ser modelados como funções senoidais determinísticas e, além disso, podem ser compactadas de uma forma mais eficiente por meio da quantização de parâmetros. Os autores ressaltam o banco de filtros e a quantização da técnica de compressão baseada na WT pode ser otimizada. As principais características dessa nova abordagem consistem em: (i) generalizar a técnica apresentada em Ribeiro, Romano e Duque (2004) pelo uso da Transformada de Fourier Discreta e da *Warped Discrete Fourier Transform* (WDFT) em conjunto a um filtro do tipo *notch* para a detecção, estimação e subtração dos componentes fundamental e harmônicos do sinal; e (ii) utilizar o critério MDL para seleção do banco de filtros *wavelet* e do nível de decomposição e quantização (aplicação de limiar) dos coeficientes do banco de filtros. Nesta aplicação, o filtro *notch* auxilia na separação/eliminação de cada componente senoidal contido no sinal. Cada componente é disponibilizada separadamente para uma WDFT a fim de que sejam extraídas características do sinal e assim proceder à estimação da magnitude, frequência e ângulo de fase utilizando uma RNA. Ademais, após a extração de componentes fundamentais e harmônicos, o sinal restante será composto apenas do distúrbio e ruído. Na etapa de compressão, os autores aplicaram o critério MDL. Nos testes, quatro categorias de sinais foram gerados sinteticamente, a saber: distorções harmônicas, *notching* e transitórios. Foram

ainda avaliadas as seguintes famílias de *wavelets*: *Symlet*, *Daubechies* e *Meyer*. O nível máximo de decomposição permitido foi 4. O desempenho da compactação foi medido pelo erro médio quadrático, considerando distintas taxas de *bits*. Os autores ressaltam que os bancos de filtros *wavelet* devem ser cuidadosamente selecionados para que cada *wavelet* possa representar o distúrbio com diferentes características espectrais. Além disso, concluem que quanto maior o número de *wavelets*, menor o erro de compressão. Por outro lado, o aumento na complexidade da compressão é proporcional ao aumento no número de *wavelets*.

Os trabalhos anteriormente apresentados testaram a compressão de sinais de QEE dispostos de forma unidimensional. [Gerek e Ece \(2008\)](#), no entanto, realizaram experimentos para avaliar a compressão de dados utilizando uma representação bidimensional. No contexto do trabalho, a representação 2D consiste em uma matriz cujas linhas correspondem a segmentos não sobrepostos do sinal do distúrbio. Praticamente, os segmentos de tempo, que são colocados nas linhas, devem ter a duração de um múltiplo inteiro do período do sinal. Segundo os autores, a representação 2D ainda auxilia na capacidade de detecção e classificação dos distúrbios de QEE. Para testar o desempenho da técnica de compressão, foram utilizados distúrbios de QEE adquiridos a 20 kHz em um sistema experimental trifásico, conectado em estrela a motores de indução trifásicos acoplados a diferentes cargas mecânicas. Componentes harmônicas também foram inseridas neste sistema por meio da inclusão de inversores de frequência para controlar os motores de indução. Na abordagem, foi realizada uma análise comparativa entre dados unidimensionais e bidimensionais por meio da DWT. Os autores constataram que ao usar o mesmo número de níveis de aproximação e detalhe, o erro introduzido na representação 2D é significativamente menor. Em uma outra etapa do estudo, foram testados codificadores comerciais. Assim, foi possível notar que tanto o codificador proposto como os codificadores comerciais foram capazes de obter cerca de 1,5 vezes mais compressão em relação aos seus modos sem perdas. Porém a compressão 2D atingiu taxas de compressão cerca de 30% superiores em relação à unidimensional.

[Tse et al. \(2012\)](#) mencionam que, para garantir monitoramento em tempo real, é necessário: (i) uma ótima taxa de compressão de dados para atender às restrições da rede de comunicação e preservar as características significantes do sinal; e (ii) um cálculo rápido, simples e eficiente. Para tanto, os autores propuseram remover as componentes estacionárias do sinal de interesse e, além disso, adotar medidas que simplifiquem o processo computacional de compressão. A *Fast Fourier Transform* (FFT) e um algoritmo de *lobe scope* foram utilizados para a extração das componentes não estacionárias do sinal para, na sequência, ser processado pela *Integer Lifting Wavelet*. Esse tipo de WT possui uma estrutura que requer menos operações aritméticas do que a WT convencional e proporciona um processo sem perdas e totalmente reversível. Um limiar adaptativo inspirado no método de *Otsu* foi aplicado nos coeficientes da WT para localizar e preservar as informações relevantes do sinal. O limiar adaptativo proposto contempla um bloco de controle que estima a taxa de compressão ideal por meio do cálculo dos *bits* necessários para representar os coeficientes da *wavelet* que sejam diferentes de zero. Por fim, o método de

compressão sem perdas, denominado *Huffman Coding*, foi aplicado para reduzir a dimensionalidade dos dados. Os dados estudados incluíram 10 classes de distúrbios gerados por dispositivos eletrônicos. Cada amostra de sinal continha 10 ciclos. O sinal não estacionário foi decomposto até o quarto nível pela *db4*. Os resultados foram avaliados pela taxa de compressão e pela relação sinal-ruído.

He *et al.* (2019) utilizaram a incerteza de *Heisenberg* para desenvolver um eficiente método de compressão de sinais oriundos de distúrbios. Os autores propuseram representar cada componente do distúrbio utilizando o menor número possível de coeficientes diferentes de zero pela restrição do princípio da incerteza, de modo a alcançar uma alta taxa de compressão e alta acurácia na reconstrução do sinal. Este método foi inspirado na decomposição da união de bases (DONOHO; HUO, 2001; ELAD; BRUCKSTEIN, 2002), otimizado por *Orthogonal Matching Pursuit* (OMP) (ZHANG *et al.*, 2015) e intensificado por compressão sem perdas (*Lempel-Ziv-Welch*). Em uma primeira etapa, foram realizados testes de compressão envolvendo distúrbios simulados e os resultados foram comparados com o desempenho da WT. Os distúrbios gerados foram: transitório impulsivo, afundamento de tensão com transitório oscilatório, distorção harmônica variável no tempo com modulação de componentes de decaimento e afundamento de tensão com transitório oscilatório e ruído. Observou-se que a taxa de compressão e a raiz quadrada do erro médio normalizado percentual demonstraram o melhor desempenho do método proposto, com destaque para a compressão de transitórios impulsivos.

Silva, de Andrade Filho e Duque (2019) conduziram um estudo comparativo sobre (*greedy algorithms*) para obter representação esparsa mais adequada em aplicações no âmbito de QEE. A Representação Esparsa pode garantir a eliminação da informação desnecessária e permitir a reprodução aproximada do sinal. Nesta abordagem, foram testados 5 algoritmos distintos, que são: OMP, *Matching Pursuit* (MP), *Stagewise Orthogonal Matching Pursuit* (StOMP), *Regularized Orthogonal Matching Pursuit* (ROMP) e *Regularized Matching Pursuit* (RMP). O desempenho destes algoritmos foi comparado de acordo com: (i) a qualidade do sinal compactado, em termos de seu coeficiente de correlação relacionado ao sinal original; (ii) o número de elementos na representação que está relacionado à taxa de compressão; e (iii) a complexidade computacional. Para isso, foram testados transitórios oscilatórios, distorções harmônicas, distorções harmônicas variantes no tempo, afundamentos e elevações de tensão. Os resultados mostraram que todos os algoritmos possuem capacidade de representar o sinal com boa qualidade. Entretanto, o ROMP proporcionou menor complexidade computacional.

No trabalho de Wang, Xu e Che (2019) foi proposto um método de compressão baseado em *Compressed Sensing* (CS). No entanto, seu processo de recuperação e reconstrução da informação é computacionalmente oneroso, o que dificulta sua aplicação em um contexto que envolve grandes volumes de dados. Contudo, os autores conseguiram superar este problema propondo um algoritmo de aprendizado profundo para classificar diretamente os sinais compactados. Nos testes, foram utilizados sinais de 15 distúrbios gerados de forma sintética e também

sinais fornecidos pela *IEEE Power and Energy Society*. Os autores comentam que o algoritmo, apesar de garantir a compressão de sinais, ainda apresenta um erro considerável na recuperação e reconstrução de sinais que pode ter efeito negativo na posterior classificação dos sinais.

[Andrade et al. \(2019\)](#) implementou um bloco de compressão de sinais após a etapa de segmentação e classificação de distúrbios de QEE. No processo de compressão de sinais, os autores utilizaram a WT, um quantificador (aplicação de limiar) e um algoritmo de compressão sem perdas. Além disso, para otimizar este processo, utilizaram a *Non-dominated Sorting Genetic Algorithm II* (NSGA-II) para seleção da família *wavelet*, dos parâmetros do quantificador e das tabelas de probabilidade para codificação de entropia. A função objetivo visa minimizar a taxa de compressão e a distorção, de acordo com o erro médio quadrático normalizado. Os autores justificam o uso do algoritmo multiobjetivo NSGA-II, devido à complexidade da função de custo e à variedade de parâmetros. Sinais sintéticos foram utilizados no processo de otimização e testes da metodologia de compressão, que incluem 14 tipos de distúrbios (8 simples e 6 combinados). Os algoritmos de compressão sem perdas abordados foram *Huffman* e *Arithmetic*, que são amplamente aplicados no campo de compressão. Ademais, foi realizada uma comparação entre o desempenho da literatura e o da metodologia adotada. O algoritmo NSGA-II encontrou a *wavelet* Biorthogonal 3.1 como a melhor solução para todos os distúrbios e o desempenho foi comparado ao da *db4*. Os resultados demonstraram a efetividade do método de compressão proposto, uma vez que foi 56% maior do que a literatura. Ainda vale destacar que o uso da *wavelet* (*bior3.1*), em conjunto ao algoritmo *Arithmetic*, proporcionou o melhor desempenho de compressão.

Como pôde ser visto, vários trabalhos foram desenvolvidos no contexto de compressão de sinais de QEE. Entretanto, constata-se que não houveram muitos avanços significativos ao longo dos anos, uma vez que a maioria das técnicas revisadas permeiam a WT. A ferramenta em questão apresenta um bom desempenho de compressão, porém a quantidade de informações que trafegarão pelos canais de comunicação irão aumentar rapidamente com a expansão das SG, sendo necessários métodos de compressão mais eficientes e compatíveis com a limitação do hardware dos *smart meters*, de modo a permitir um bom *trade-off* entre a redução dos pacotes de dados e a perda de informação, bem como evitar problemas oriundos da saturação dos canais de comunicação.

3.3 Classificação de Distúrbios de QEE

Um classificador baseado em *Learning Vector Quantization* (LVQ) visando a identificação de distúrbios de QEE é proposto em [Santoso et al. \(2000a\)](#) e [Santoso et al. \(2000b\)](#). Entretanto, foi utilizada uma WT para extrair características dos distúrbios. Na sequência, a LVQ é treinada e validada. Porém, a tomada de decisão é feita por um esquema de votação e pela teoria da evidência de *Dempster-Shafer*. Nos experimentos, foram selecionados 6 tipos predominantes de sinais, sendo: afundamentos de tensão, interrupções momentâneas, transitórios impulsivos,

transitórios oscilatórios de alta frequência, transitórios oscilatórios de baixa frequência e sinais sem distúrbios. Os afundamentos e interrupções momentâneas de tensão foram identificados por meio do rastreamento os mínimos e máximos de tensão a cada ciclo. Os demais distúrbios, por sua vez, foram identificados pela LVQ, sendo capaz de atingir uma acurácia acima de 90%.

Huang, Negnevitsky e Nguyen (2002) apresentaram uma metodologia para classificação de distúrbios utilizando um modelo híbrido baseado em RNA e sistema *Fuzzy*. As RNAs foram treinadas utilizando uma base de dados contendo 13 tipos de distúrbios, os quais foram separados em três categorias. Dessa forma, as RNAs determinam as fronteiras de decisão que separam tais categorias. Para lidar com possíveis incertezas neste processo, as saídas da rede neural foram utilizadas para ativar a *Fuzzy Associative Memory* (FAM) e identificar o tipo de distúrbio mais provável que o sinal de entrada se enquadra. É importante salientar que os autores utilizaram a WT na etapa de pré-processamento do sinal para remover redundâncias e extrair de características do sinal. Os resultados apresentaram uma acurácia média acima de 93%.

Gaing (2004) introduziu uma abordagem que consiste em: (i) aplicação da WT e do Teorema de Parseval para a extração de características referentes à distribuição de energia do sinal em diferentes níveis de resolução; e (ii) aplicação da *Probabilistic Neural Network* (PNN) para classificar os distúrbios. Segundo os autores, o uso do Teorema de Parseval permite a redução do número de características sem perder as propriedades do sinal. Nos testes, foram usados sinais sintéticos que incluem: a forma de onda pura, interrupção momentânea, afundamento de tensão, elevação de tensão, transitório oscilatório, distorção harmônica e *flicker*. Por fim, foi obtida uma acurácia média de 90%.

A WT também foi usada por Janik e Lobos (2006), porém buscando detectar a presença de distúrbios, enquanto a classificação dos mesmos foi realizada por uma SVM que ainda foi comparada a uma RBFNN. Diferentes classes de distúrbios foram simuladas por meio de modelos paramétricos, a fim de treinar e testar o desempenho dos modelos preditivos. As classes geradas foram: sinal senoidal puro, elevação de tensão, *flicker*, distorção harmônica, transitório oscilatório e afundamento de tensão. Os autores também propõem uma fase extração de características, a qual é realizada por Fator Espacial Complexo. Os resultados mostraram que a SVM demonstra estabilidade ao testá-la com sinais ruidosos (até 5%), diferente do que ocorreu com a RBFNN. A acurácia da SVM ficou acima de 97%.

No trabalho de Reaz *et al.* (2007), os autores apresentaram um classificador similar ao de Huang, Negnevitsky e Nguyen (2002). Uma etapa de pré-processamento foi realizada por *wavelet db4* (até o quinto nível de decomposição), visando a extração de características. Uma *Univariate Randomly Optimized Neural Network* (URONN) foi utilizada na classificação. Por fim, as saídas da URONN são dadas como entrada a um sistema *fuzzy* que define o grau de pertinência do distúrbio a uma das classes de distúrbio. Os distúrbios testados incluem afundamento, elevação, transitório, *flicker* e interrupção, os quais foram gerados sinteticamente a uma frequência de amostragem 12,8 KHz. A precisão de classificação alcançou a marca de 98,19%.

O artigo de [Mishra, Bhende e Panigrahi \(2008\)](#), por sua vez, propõe o uso da Transformada S na etapa de pré-processamento, a qual é devidamente justificada pela sua maior imunidade a ruídos. Na sequência, as características extraídas pela Transformada S (raias de frequência) são usadas como entradas de uma PNN para classificação dos distúrbios. Onze tipos de distúrbios foram considerados, sendo todos obtidos a uma frequência de amostragem de 3,2 KHz. Comparou-se a PNN a outras duas redes neurais, sendo uma *Multilayer Perceptron* (MLP) e uma LVQ. Analisando os resultados, a LVQ e a MLP obtiveram acurácias de 51% e 88%, respectivamente. No entanto, a PNN alcançou 97,4%. Sob condições de ruído gaussiano, a PNN obteve uma acurácia média de 93,2%.

[Biswal, Dash e Panigrahi \(2009\)](#) realizaram a extração de características utilizando a Transformada S. Na sequência, houve uma clusterização dos distúrbios por meio de uma abordagem híbrida baseada em *Fuzzy C-Means* e *Particle Swarm Optimization* (PSO). Nos testes, foram consideradas nove classes de distúrbios gerados sinteticamente. A acurácia média da abordagem proposta foi de 96,3%.

[Rodriguez et al. \(2014\)](#) utilizaram duas RNAs para detecção e classificação de distúrbios simples e combinados. Uma RNA do tipo *Adaptive Linear* (ADALINE) foi responsável pela estimação de componentes harmônicos e inter-harmônicos. A partir da estimação, calcula-se tensão RMS e a DHT da tensão. Assim, o valor RMS foi utilizado na identificação de afundamentos, elevações e interrupções de tensão. A DHT permite a classificação de distorção harmônica e inter-harmônica. Por outro lado, uma RNA do tipo MLP foi utilizada no reconhecimento de padrões de *spike*, *notching* e transitório oscilatório. Dados sintéticos e reais foram considerados na validação da metodologia. Vale destacar que os distúrbios foram classificados a partir de janelas de $\frac{1}{2}$ ciclo. Os resultados evidenciaram melhores acurácias na classificação de distúrbios simples em vez de combinados. Notou-se acurácias médias de 96,3% (sinais sintéticos sem ruído), 88,2% (sinais sintéticos com ruído) e 95% (sinais reais).

A abordagem proposta por [Kumar et al. \(2015\)](#) iniciou-se pela extração da amplitude máxima *versus* tempo e amplitude de frequência *versus* frequência (normalizada), obtidas por meio da Transformada S. Na sequência, os distúrbios foram separados em dois grupos: (G1) com um pico de amplitude em frequência; ou (G2) com mais de um pico. Os picos confirmam a presença de mais de uma frequência presente no sinal analisado. Portanto, afundamentos, elevações e interrupções de tensão, bem como *flickers* e o sinal senoidal sem distúrbio fazem parte de G1. Por outro lado, transitórios oscilatórios, *spikes*, *notches*, distorções harmônicas, distorção harmônicas com afundamento, distorções harmônicas com elevação, distorção harmônicas com *flicker* e distorção harmônicas com interrupção foram incluídas em G2. Os distúrbios de G1 foram classificados analisando o tempo e magnitude do vetor de máxima amplitude *versus* tempo. No entanto, para classificar os distúrbios de G2, houve a necessidade de empregar uma RNA. Assim, para compor as entradas de uma RNA do tipo MLP, ainda foram extraídas, do vetor de amplitude máxima *versus* tempo, características estatísticas, como *skewness* e *kurtosis*. A RNA

foi treinada com o algoritmo *scaled conjugate gradient backpropagation*. Os autores citam que os distúrbios testados foram gerados por modelos numéricos, com extensão de 10 ciclos de sinal e de acordo com padrões internacionais. Essa abordagem foi capaz de classificar os distúrbios com acurácia média de 99,9%.

No trabalho de [Borges et al. \(2016\)](#) foi apresentada uma metodologia destinada à extração de características para obter informações relevantes à classificação de distúrbios. No presente estudo, os autores abordaram dezesseis ferramentas para extração de características, as quais foram categorizadas em: estatísticas (Média Harmônica, Desvio Padrão, Desvio Médio e *Kurtose*); entropias (Entropia, Entropia de *Shannon* e Entropia de *Rényi*); intrínsecas ao sinal (valor RMS, valor de Pico e diferença entre Amplitude Máxima e Mínima); e componentes de frequência (DHT, Magnitude do Sinal Fundamental, Magnitude da Segunda Harmônica, Magnitude da Terceira Harmônica, Magnitude da Quarta Harmônica e Magnitude da Quinta Harmônica). As características que representam componentes de frequência foram extraídas pela FFT, visto que garante um baixo custo computacional e já utilizada rotineiramente em *hardware*. Para validar a metodologia proposta, os autores analisaram a resposta de classificação de DT do tipo C4.5 e RNAs do tipo MLP em torno de oito distúrbios, que incluíam: afundamento de tensão, elevação de tensão, *flicker*, distorção harmônica, interrupção de tensão, transitório oscilatório, afundamento de tensão com distorção harmônica e elevação de tensão com distorção harmônica. Cabe mencionar que essa proposta analisa sinais janelados com tamanho de 1 ciclo e com passo de uma amostra. Além disso, para verificar a relevância das características extraídas, foi realizada uma etapa de seleção de atributos por meio do *software Waikato Environment for Knowledge Analysis* (WEKA). No final do processo, a RNA alcançou uma precisão média de classificação de 96,03% para sinais sintéticos com relação sinal-ruído igual a 40dB e 95,65% para 35dB; a DT obteve 93,95% para 40dB e 93,90% para 35dB. Ainda foram considerados dados reais de oscilografias feitas em subestações de distribuição de energia elétrica que envolveram afundamentos, interrupções, distorções harmônicas e transitórios oscilatórios, em que a RNA alcançou a precisão média de 99,3%, enquanto a DT obteve 99,6%.

[Singh e Singh \(2017\)](#) propuseram um estudo baseado na extração de características da *Fractional Fourier Transform* (FrFT). Diferente da FFT, a FrFT utiliza um controle adicional de ordem que permite a análise do sinal no domínio do tempo, frequência e tempo-frequência, permitindo assim a formação de uma matriz de características mais robusta. Os autores abordaram quinze tipos de distúrbios sintéticos, em que nove destes são simples e seis combinados. Cada sinal possui 10 ciclos com uma frequência de amostragem de 6.4 kHz. As ferramentas estatísticas e espectrais utilizadas para a formação da matriz de características foram: variância, potência média, desvio padrão, raiz da soma dos quadrados, valor RMS, relação pico-RMS, frequência média, relação sinal-ruído e DHT. Na etapa de classificação foram utilizados DTs e *Ensemble* do tipo *Bagging*. As precisões médias de classificação da DT e do *Ensemble* ficaram em aproximadamente 91% e 95%, respectivamente (considerando dados sintéticos com ruído e sem ruído). Ao analisar dados reais referentes a oito classes de distúrbios, a DT obteve uma

precisão média de 94,59% e o *Ensemble* obteve 97,30%. Por fim, considerando o tempo e a precisão do processamento, a DT é mais adequada para aplicações em tempo real.

Liu *et al.* (2018) apresentaram uma nova proposta para identificação de distúrbios utilizando em conjunto as técnicas de *Multivariate Singular Spectrum Analysis* (MSSA), *Curvelet Transform* (CT) e *Deep Convolutional Neural Network* (DCNN). As duas primeiras técnicas foram empregadas para extração de características dos sinais, enquanto a última realiza a classificação dos distúrbios. Segundo os autores, a MSSA é uma técnica não paramétrica que fornece uma forma eficaz de reconhecer transitórios sutis no sinal. A etapa de extração de características foi dividida em dois estágios: (i) construção de uma matriz de covariância com atraso por meio do Algoritmo da Matriz de Trajetória; e (ii) decomposição dos sinais por meio de MSSA e CT. Neste artigo, seis bandas de frequência foram construídas e as três bandas iniciais foram utilizadas como características. A MSSA foi usada para decompor os pequenos sinais transitórios, sendo decompostos em seis níveis. Neste sentido, as características extraídas foram dadas como entradas à DCNN para identificação de 31 classes de distúrbios, simples e combinadas, geradas sinteticamente. Sinais sintéticos com ruído e reais também foram considerados para testar a metodologia. As acurácias médias de classificação atingidas pela DCNN ficaram acima de 99%. Ainda, foi realizado um teste comparativo envolvendo uma SVM, que obteve uma acurácia média superior a 98%.

Wang, Xu e Che (2019) propuseram uma abordagem de classificação a partir de dados comprimidos por CS, utilizando uma CNN. Visto que a CS é lenta e pouco adequada à recuperação e reconstrução de um número grande de sinais, os autores buscaram realizar a classificação sem a etapa de descompressão dos sinais. No experimento, foram adotadas quinze classes de distúrbios, geradas por modelos matemáticos, que abrangem dez classes de eventos simples e cinco combinados. Os resultados foram comparados com outros métodos existentes na literatura, como PNN, SVM e *Extreme Learning Machines* (ELM). Ainda, foram utilizados dados reais disponibilizados pela IEEE *Power and Energy Society*. Nos testes envolvendo vários níveis de ruído, a CNN obteve uma acurácia média acima de 99%, superando os demais algoritmos utilizados na análise comparativa.

O trabalho de Wang e Chen (2019) utilizou uma versão melhorada da DCNN na classificação de distúrbios. Os autores modificaram a CNN tradicional de modo a deixá-la com apenas uma unidade para extração e seleção automática de características. Para validação da metodologia, foi conduzida uma comparação com outros algoritmos de *deep learning*, como ResNet50, *Long Short-Term Memory* (LSTM), *Gated Recurrent Units* (GRU) e *Stacked Auto-Encoder* (SAE). Os conjuntos de dados para treinamento e testes incluíram dez tipos de distúrbios simples e seis combinados, que foram gerados por equações paramétricas. A frequência de amostragem foi definida em 3.2 KHz, que, segundo os autores, é comumente utilizada em equipamentos de monitoramento de QEE. Um modelo de microrrede também foi construído para simular os distúrbios causados pelas gerações distribuídas, cargas não lineares, faltas e mudanças de

operação no sistema. Os autores comentam que a identificação de distúrbios em microrredes é muito mais complexa. A CNN proposta alcançou a melhor acurácia na validação (99,5%), seguida pela LSTM (99,4%), GRU (99,3%), ResNet50 (98,9%) e SAE (96,5%).

Cai *et al.* (2019a) propuseram a combinação de *Wigner-Ville Distribution* (WVD) e CNN. A WVD é utilizada para a transformação do sinal temporal em imagem 2D, enquanto a CNN é responsável pela classificação dos distúrbios. O objetivo do uso da WVD é reduzir a função de densidade espectral para sinais temporais e, com isso, obter uma autocorrelação não estacionária. Portanto, um sinal de tensão temporal pode ser expresso no domínio da frequência temporal e transferido para uma imagem de frequência temporal. O desempenho do método proposto é testado em nove tipos de distúrbios sintéticos, bem como medições reais disponibilizadas pela *IEEE Power and Energy Society*. Os dados sintéticos incluem afundamento, elevação, interrupção, *flicker*, distorção harmônica, transitório oscilatório, *spike*, afundamento com distorção harmônica, interrupção com distorção harmônica e elevação com distorção harmônica. Os dados reais incluem *flicker*, elevação e afundamento com distorção harmônica. Cada sinal foi representado por uma imagem de dimensão 200x200 *pixels*. Além disso, o efeito da classificação incorreta foi analisado aplicando a técnica de visualização denominada *Class Activation Map* (CAM), que gera . O CAM gera um mapa de calor de ativação de classe sobre a imagem de entrada. Nos testes com dados sintéticos, foram utilizadas 100 amostras e a acurácia obtida pelo modelo foi de 99,67%. Ao adicionar dados reais ao conjunto de teste, o modelo preditivo obteve acurácia média de 92%.

Um sistema híbrido combinando *Phase Space Reconstruction* (PSR) e CNN foi apresentado por Cai *et al.* (2019b). Nessa metodologia, a PSR produz imagens em escala de cinza, na dimensão de 200x200 *pixels*. Valores altos na matriz da imagem são apresentados em *pixels* brancos, enquanto os valores baixos têm *pixels* mais próximos do preto. A CNN é utilizada para classificar os distúrbios diretamente das imagens, uma vez que ela extrai automaticamente os mapas de características. Para ilustrar o desempenho de classificação do método proposto, os autores geraram sinteticamente dez tipos de distúrbios, que são: afundamento, elevação, interrupção, *flicker*, distorção harmônica, transitório oscilatório, *spike*, afundamento com distorção harmônica, interrupção com distorção harmônica e elevação com distorção harmônica. Os resultados dos testes foram comparados com outros métodos existentes na literatura. A metodologia proposta obteve uma acurácia média de 99,8%, superando o desempenho das outras técnicas abordadas. Uma outra etapa de validação foi utilizada pelos autores, que consistiu em formar um conjunto de treinamento com dados sintéticos e reais, adotando um conjunto de teste formado apenas por dados reais. Neste caso, foi possível alcançar uma acurácia média de 98,8%.

Lin *et al.* (2019) apresentaram um método de reconhecimento de padrões referentes a distúrbios de QEE baseado em técnicas de aprimoramento de imagem e análise de importância de características. Nessa metodologia, os sinais são convertidos em imagens em escala de cinza, levando em consideração o valor da amplitude do sinal em cada ponto de amostragem. Três

técnicas de tratamento de imagem, que incluem correção gama, detecção de borda e detecção de picos e vales foram usadas para gerar as imagens e realçar a presença dos distúrbios. Métricas como área, valor médio, variância e entropia foram utilizadas para extrair características destas imagens. Assim, a relevância de cada característica foi avaliada por uma *Random Forest* (RF) e ranqueada pelo índice de Gini. Os autores empregaram ainda o algoritmo de *Sequence Forward Search* (SFS) para encontrar o subconjunto de características otimizado para a classificação dos distúrbios. Foram simulados eventos de afundamento, elevação, interrupção, *flicker*, transitório, distorção harmônica, *notch* e *spike*. Para garantir a confiabilidade e autenticidade dos sinais simulados, o tempo de início e parada, a amplitude e a frequência de oscilação de cada sinal foram gerados de forma aleatória. Ruído entre 20 e 50 dB também foi adicionado ao sinal. A classificação dos distúrbios também ficou a cargo de uma RF, a qual foi comparada a outros algoritmos (SVM, ELM e DT). Os resultados mostraram que a abordagem dos autores apresentou o melhor desempenho de classificação. Sob uma faixa de ruído entre 50dB e 30dB, a RF proporcionou uma acurácia média acima de 99,4%; entretanto, com ruídos abaixo de 30dB, a acurácia média ficou em 96,2%.

Uma abordagem de classificação de distúrbios de QEE baseada em filtro de *Kalman*, ST e RNA foi estudada por [Xi et al. \(2020\)](#). O filtro de *Kalman* é utilizado para a remoção de ruído dos sinais, a fim de possibilitar uma extração de *features* precisa em altos níveis de ruído. A ST é implementada para auxiliar no processo de extração de *features* dos distúrbios. Quatro *features* são extraídas diretamente do sinal, sendo três provenientes de medidas estatísticas e DHT; e outras duas *features* estatísticas extraídas da ST. A RNA, por sua vez, é responsável por processar essas *features* e promover a identificação das classes de sinais de QEE. Para a realização deste estudo, os autores geraram uma base de dados sintéticos, considerando uma taxa amostral de 200 amostras/ciclo e com a adição de ruídos de 20, 30 e 40dB. As classes de sinais testadas incluem afundamento de tensão, elevação de tensão, distorção harmônica, interrupção de tensão, transitório oscilatório, *flicker*, afundamento de tensão com distorção harmônica, elevação de tensão com distorção harmônica, interrupção de tensão com distorção harmônica, *flicker* com distorção harmônica, afundamento de tensão com *flicker* e elevação de tensão com *flicker*. Os resultados de classificação mostraram que a acurácia média da abordagem foi acima de 97%.

No trabalho de [Tang, Qiu e Zhou \(2020\)](#), os autores propuseram um classificador de distúrbios utilizando uma ST otimizada e um *Kernel Support Vector Machine* (KSVM). Neste contexto, a ST tem a função de extrair informações em tempo-frequência dos sinais e a KSVM de promover a classificação. Segundo os autores, a ST proposta otimiza diferentes parâmetros da janela de dados a fim de melhorar a resolução em tempo-frequência. Nessa metodologia, *features* extraídas dos sinais e também da decomposição tempo-frequência são as entradas do classificador. Para lidar com essas *features*, os autores propuseram uma combinação linear ponderada de *kernels* para mapear os dados de entrada e assim possibilitar a busca de um melhor hiperplano de decisão. O desempenho do método proposto é testado em 24 tipos de sinais de QEE, sob condições de ruído e sem ruído, gerados sinteticamente a uma taxa amostral de 64 amostras/ciclo. Para ruído

de 20 dB, que representa o maior nível ruído considerado, o modelo alcançou uma acurácia média de 98,82%. Por fim, para validar o modelo com sinais experimentais, o classificador apresentou uma acurácia média de 97,08% na classificação de sinais puros, elevação de tensão, afundamento de tensão, interrupção de tensão, distorção harmônica, elevação de tensão com distorção harmônica, afundamento com distorção harmônica e *flicker*.

[Kaushik et al. \(2020\)](#) introduziram um modelo que faz uso de *features* híbridas extraídas das HT e ST para a identificação de distúrbios de QEE simples e combinados. Neste contexto, duas *features* são extraídas do sinal de tensão por meio o uso da HT e ST. Na sequência, quatro novas *features* estatísticas são calculadas a partir das anteriores. Então, estas novas *features* são disponibilizadas ao classificador DT para identificação dos padrões. Dentre os sinais estudados nesta pesquisa, incluem-se o sinal puro, nove sinais simples e seis combinados, que foram gerados sinteticamente por modelos matemáticos à uma taxa de amostragem de 64 amostras por ciclo de sinal. No final da pesquisa, os autores obtiveram uma acurácia média de 99,63% para amostras de sinais sem ruído e 98,81% para amostras com ruído de 10 dB. Por fim, os autores comentam que a abordagem proposta é pouca afetada pela presença de ruído, possui baixa complexidade computacional e resultou em um desempenho superior a algoritmos baseados na HT e ST na literatura comparada.

[Junior et al. \(2021\)](#) propuseram uma abordagem similar ao do trabalho de [Borges et al. \(2016\)](#), contudo utilizando um sistema operacional em tempo real, embarcado em um *hardware* de medição de baixa tensão que usa um ARM Cortex M4. Na etapa de extração de *features* dos sinais de tensão, os autores calcularam as mesmas características utilizadas por [Borges et al. \(2016\)](#). No processo de classificação, foi utilizada uma DT do tipo C4.5. Para a condução da pesquisa, a base de dados foi composta por amostras de afundamento de tensão, elevação de tensão, *flicker*, distorção harmônica, transitório impulsivo, interrupção de tensão, transitório oscilatório, afundamento de tensão com distorção harmônica, elevação de tensão com distorção harmônica, *flicker* com distorção harmônica, afundamento de tensão com transitório oscilatório e elevação de tensão com transitório oscilatório. Estes padrões de sinais, por sua vez, foram gerados sinteticamente a uma taxa de amostragem de 64 amostras por ciclo de sinal. Como resultados, a DT proporcionou uma acurácia média de 94,9% na identificação de distúrbios com ruídos de 25, 30 e 45 dB. Em um segundo teste envolvendo sinais reais de afundamento de tensão, distorção harmônica, interrupção de tensão e transitório oscilatório, a DT proporcionou uma acurácia de 99,7%.

[Liu et al. \(2021\)](#) propuseram um estudo envolvendo uma nova abordagem de classificação de sinais baseada nas técnicas *Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise* (ICEEMDAN), *Time-Dependent Spectral Features* (TDSFs) e *Adaptive K-Nearest Neighbor with Excluding Outliers* (AdaKNNEO). No estudo, os sinais são decompostos em várias funções de modo intrínseco por meio da ICEEMDAN. Na sequência, estas funções são selecionadas levando em consideração o coeficiente de correlação e a *kurtosis*. Então os oito

autovalores de cada uma das funções de modo intrínseco são extraídos por meio da TDSFs. Os autores comentam que os autovalores usados neste estudo são expressos na forma de logaritmo, pois esta forma tende a apresentar uma mudança linear, que é mais propícia à diferenciação de recursos. Ademais, antes de disponibilizar estas informações ao classificador, os autores propuseram a aplicação da técnica denominada *Linear Discriminant Analysis* (LDA) a fim de remover as informações redundantes e de ruído das informações do recurso original, reduzindo assim a dimensionalidade dos dados. Os autores complementam que, após a redução da dimensão, os três valores próprios reduzidos não têm nenhum significado físico real; entretanto o tipo de distúrbio pode ser determinado de acordo com a faixa dos autovalores reduzidos. No processo de classificação, os autores implementaram o algoritmo de clusterização AdaKNNEO para a identificação das classes dos sinais de QEE. A referida pesquisa considerou onze padrões de sinais, dos quais um representa o sinal senoidal fundamental, nove representam distúrbios simples e dois representam distúrbios combinados. Estes sinais, por sua vez, foram gerados sinteticamente, à uma taxa amostral de 128 amostras por ciclo, por modelos matemáticos. A acurácia média alcançada pelos autores foi acima de 98% envolvendo sinais sem ruído e com ruído de 30 dB. Além disso, os autores executaram um teste complementar envolvendo dados experimentais e foi possível encontrar uma acurácia média acima de 96%.

Machlev *et al.* (2021) realizaram testes comparativos de desempenho entre CNN e *Bidirectional Long Short-Term Memory* (BiLSTM) no que tange à classificação de distúrbios. Em ambos os algoritmos, os dados de entrada são os próprios dados de tensão, ou seja, sem passar por qualquer tratamento prévio. Para a condução do estudo, foram gerados dezesseis padrões de distúrbios de QEE utilizando modelos matemáticos, com taxa amostral de 64 pontos por ciclo. Os padrões de sinais gerados incluem sinal puro, afundamento de tensão, elevação de tensão, interrupção de tensão, distorção harmônica, *flicker*, transitório oscilatório, transitório impulsivo, *notching*, *spike*, afundamento de tensão com distorção harmônica, elevação de tensão com distorção harmônica, interrupção de tensão com distorção harmônica, *flicker* com afundamento de tensão, *flicker* com elevação de tensão e *flicker* com interrupção de tensão. Foram utilizadas duas bases de dados. A primeira base inclui sinais sem a presença de ruído e a segunda base consiste em sinais com a adição aleatória de ruído branco na faixa de 20 a 50 dB. Realizando-se o treinamento e teste dos algoritmos com apenas dados da primeira base, a CNN proporcionou uma acurácia média de 99,28% nos testes, enquanto a BiLSTM garantiu apenas 96,29%. Já em relação apenas a base de dados com adição de ruído, a CNN apresentou uma acurácia média de 99,75% e a BiLSTM de 98,14%. Portanto, os autores concluíram que a CNN demonstrou desempenho superior a BiLSTM em termos da acurácia média.

Sindi *et al.* (2021) apresentaram um modelo de *deep learning* híbrido que realiza classificações por meio da combinação de representações 1D e 2D dos sinais. O método proposto consiste na combinação de duas CNNs, em que uma é responsável por processar o sinal 1D e a outra pelo sinal 2D. Arquiteturas de CNN pré-treinadas, como GoogLeNet, ResNet-50 e VGG-16 foram testadas para integrar a parcela que processa os sinais 2D. Portanto, as *features*

extraídas de cada uma destas CNNs são combinadas na forma de um único vetor 1D e este então é processado por uma camada de neurônios totalmente conectada a fim de proceder a classificação final. A conversão do sinal 1D para 2D se dá pela geração de gráfico resultante da variação da tensão ao longo do tempo. Os autores comentam que o método proposto cria uma nova abordagem para classificação, que usufrui das vantagens proporcionadas pelas duas abordagens de CNN distintas. Para a avaliação do método proposto, foram utilizadas amostras de sinal puro, afundamento de tensão, elevação de tensão, interrupção de tensão, transitório oscilatório, transitório impulsivo, *flicker*, distorção harmônica, afundamento de tensão com distorção harmônica, elevação de tensão com distorção harmônica, interrupção com distorção harmônica, *flicker* com afundamento de tensão e *flicker* com elevação de tensão. A adição de ruídos aleatórios entre 0 e 50 dB nos sinais gerados foram considerados para, segundo os autores, criar uma base de dados mais realista. Além disso, os autores inseriram algumas amostras de sinais sem ruído na base de dados. Como resultados, os autores constaram um melhor desempenho da GoogLeNet no processamento dos sinais 2D e obtiveram uma acurácia média de 99,97% na classificação de distúrbios.

Portanto, observa-se que o estado da arte na área de classificação está bastante avançado. Um ponto importante que ainda pode ser explorado é a capacidade de classificação dos distúrbios a partir de dados que passaram pelo processo de detecção e compressão, uma vez que perdas de informações podem ocorrer das etapas anteriores à classificação. Sobretudo, é importante destacar que os trabalhos revisados não incorporam na metodologia as etapas de detecção/segmentação, compressão e classificação, que são minimamente essenciais para o processo de monitoramento da QEE. Logo, em um ambiente real de operação, as ferramentas integrantes do *framework* de monitoramento devem garantir um bom desempenho em sua operação conjunta, ou seja, devem permitir uma interoperabilidade entre si e para garantir bons resultados ao final do processo.

3.4 Análise Geral

Como pôde ser observado, existe uma gama muito grande de técnicas utilizadas para fins de detecção/segmentação, de compressão e de classificação de distúrbios de QEE. Nota-se ainda que a maior parte das abordagens propostas buscam atingir melhores acurácias, porém nem sempre avaliam a real aplicabilidade em campo. Neste sentido, a limitação de *hardware* é uma questão de extrema importância no contexto prático, visto que apesar de existirem técnicas robustas, muitas delas dificilmente seriam embarcadas em *hardware*. Dessa forma, deve-se avaliar o esforço computacional das abordagens frente aos *hardwares* de *smart meter* comerciais.

A maioria das implementadas na detecção/segmentação envolvem a decomposição do sinal e aplicação de um limiar. Apenas três dos trabalhos revisados aplicam um método diferente, baseado na extração de características de janelas deslizantes. A análise por meio de janelas deslizantes é bastante válida no âmbito de *hardware*, visto que os *smart meters* têm *buffers*

circulares que precisam ser considerados. Além disso, dificilmente, esses *buffers* suportariam o armazenamento de 10 ciclos de sinal para posteriormente tomar uma decisão. Dessa forma, a decisão deve ser tomada em janelas com até 1 ciclo de sinal. Apesar de a análise por janelas deslizantes contribuir na identificação de nuances relacionadas à transição entre o sinal normal e a ocorrência do distúrbio, há uma perda de desempenho em relação à análise de sinais completos com mais de 10 ciclos.

No que tange a compressão, é importante destacar que o uso de ferramentas de transformação de sinal está presente na maioria dos trabalhos. Além disso, apesar de simples, têm auxiliado na remoção de redundâncias do sinal. Alguns autores obtiveram resultados melhores ao utilizar algoritmos de compressão sem perdas, como *Huffman Code* e *Lempel-Ziv-Welch*.

Em termos de classificação, nota-se que todas as metodologias necessitam de um estágio de extração de características e outro de classificação que demandam um esforço computacional elevado. Dessa forma, não seria desejável realizar tais estágios em *hardware*. Dessa forma, é evidente que a execução dessas tarefas em *cloud computing* seria capaz de sobrepor a essas limitações, permitindo a aplicação de técnicas mais robustas como as representações 2D e classificação por algoritmo de *deep learning*, combinação que tem se mostrado eficiente nos últimos anos.

Na sequência, a Tabela 1 sumariza as pesquisas em termos de detecção/segmentação, compressão e classificação de distúrbios de QEE.

Tabela 1 – Análise do estado da arte em termos de detecção/segmentação, compressão e classificação de distúrbios de QEE.

Autores	Detecção/Segmentação		Compactação		Classificação		Distúrbios				Amostras/ Ciclo		
	Método	Resultado	Método	Resultado	Método	Resultado	DS	DC	VTCD	T		F	D
Sindi <i>et al.</i> (2021)					CNN 1D + CNN 2D	99,97%	✓	✓	✓	✓	✓	✓	128
Machlev <i>et al.</i> (2021)					CNN	<=99,75%	✓	✓	✓	✓	✓	✓	64
Liu <i>et al.</i> (2021)					ICEEMDAN								
					TDSFs	>96,1%	✓	✓	✓	✓	✓	✓	128
					AdaKNNEO								
Junior <i>et al.</i> (2021)	Janelamento												
	RMS	>81%			DT	94,9%	✓	✓	✓	✓	✓	✓	64
	DHT												
Kaushik <i>et al.</i> (2020)					HT+ST+DT	99,22%	✓	✓	✓	✓	✓	✓	64
Tang, Qiu e Zhou (2020)					ST+KSVM	98,82%	✓	✓	✓	✓	✓	✓	64
Xi <i>et al.</i> (2020)					ST+RNA	<=98%	✓	✓	✓	✓	✓	✓	200
Singh <i>et al.</i> (2019)	OEMD	Visual					✓		✓			✓	400
Bastos <i>et al.</i> (2019)	Diferença RMS	Erro de 3 amostras					✓		✓				128
	Janelamento												
Moraes e Fernandes (2019)	RNA	>81%					✓		✓	✓	✓	✓	128
	DT												
	RL												
He <i>et al.</i> (2019)			Heisemberg	PRDN = 1,25%	OMP	CR<11	✓	✓	✓	✓		✓	128/256
			Lempel Ziv Welch		SR								
Silva, de Andrade Filho e Duque (2019)			greedy algorithms		Visual		✓		✓	✓		✓	128
Wang, Xu e Che (2019)					CS	CR=4 EM=7e-4	✓	✓	✓	✓	✓	✓	128
Andrade <i>et al.</i> (2019)	DWT+NSGA II		DWT+NSGA-II	CR=25 NMSE=1e-5	RNA+NSGA-II	98,21%	✓	✓	✓	✓	✓	✓	128
Wang e Chen (2019)					CNN	99,5%	✓	✓	✓	✓	✓	✓	64
Cai <i>et al.</i> (2019b)					PSR+CNN	99,8%	✓	✓	✓	✓	✓	✓	128
Cai <i>et al.</i> (2019a)					WVD+CNN	99,7%	✓	✓	✓	✓	✓	✓	128
Lin <i>et al.</i> (2019)					Imagem Cinza+RF	>=96,2%	✓		✓	✓	✓	✓	64
Liu <i>et al.</i> (2018)					MSSA+CT+DCNN	99,5%	✓	✓	✓	✓	✓	✓	-
Singh e Singh (2017)					FrFT+BT/BP	>=94%	✓	✓	✓	✓	✓	✓	128
Borges <i>et al.</i> (2016)					Janelamento								
					RNA/DT	>=93%	✓	✓	✓	✓	✓	✓	128
Kumar <i>et al.</i> (2015)					ST+DT+RNA	99,9%	✓	✓	✓	✓	✓	✓	64

Continua na próxima página

Tabela 1 continuação da página anterior.

Autores	Detecção/Segmentação		Compactação		Classificação		Distúrbios					Amostras/ Ciclo	
	Método	Resultado	Método	Resultado	Método	Resultado	DS	DC	VTCD	T	F		D
Manikandan, Samantaray e Kamwa (2015)	SDD+OHDs	Visual			Hierarchical DT	82-90%	✓	✓	✓	✓	✓	✓	400
Biswal <i>et al.</i> (2014)	EMD+HT	Visual			Neural-Tree	97,9%	✓	✓	✓	✓	✓	✓	-
Rodriguez <i>et al.</i> (2014)	RNA	-			RNA	88,2%	✓	✓	✓	✓	✓	✓	100
	Histogramas				Tresholding								
Borges (2013)	Janelamento				Janelamento								
	RMS	>80%			DT	44-97%	✓	✓	✓	✓	✓	✓	16 a 256
	DHT												
Tse <i>et al.</i> (2012)			FFT+WT+Huffman	CR<=80 SNR=40dB			✓	✓	✓	✓	✓	✓	256
Cho, Jang e Kwon (2010)	GT+WDF	Visual					✓		✓	✓	✓	✓	50
Biswal, Dash e Panigrahi (2009)					ST+Fuzzy+PSO	96,3%	✓	✓	✓	✓	✓	✓	64
	Filtro				Filtro								
Radil <i>et al.</i> (2008)	Morfologia	Visual			Morfologia	-	✓		✓	✓		✓	1000
	RMS				RMS								
Gerek e Ece (2008)			DWT 2D	CR=32:1 SNR>43			✓		✓				400
Mishra, Bhende e Panigrahi (2008)	ST	Visual			ST+PNN	93,2%	✓	✓	✓	✓	✓	✓	64
Ribeiro <i>et al.</i> (2007)			WDFT+MDL	BR<8 MSE>-100 dB			✓			✓		✓	512
Reaz <i>et al.</i> (2007)					DWT+Neuro-Fuzzy	98,18%	✓		✓	✓	✓		256
Janik e Lobos (2006)	DWT	Visual			DWT+SVM	98,7%	✓		✓	✓	✓	✓	100
Ibrahim e Morcos (2005)			Neuro-Fuzzy	CR <30:1 NMSE>6e-4			✓			✓		✓	256
Ece e Gerek (2004)	DWT 2D	Visual					✓		✓			✓	160
Ribeiro, Romano e Duque (2004)			Filtros	CR <49:1 SNR>			✓	✓		✓		✓	-
			DWT										
			Lempel-Ziv-Welch		DWT+PNN	90%	✓		✓	✓	✓	✓	256
Gaing (2004)							✓		✓	✓	✓	✓	60
Meher, Pradhan e Panda (2004)			SWT+RBFNN	MSE >= -25,76 PER>96			✓		✓	✓	✓	✓	60
Dash <i>et al.</i> (2003)	ST	Visual	SWT	NMSE <= 1e-4 CR<7,2	Conjunto de regras	<=97%	✓		✓	✓	✓	✓	200
Panda <i>et al.</i> (2002)			Transf. Slantlet	CR=10 MSE>= -19,78 dB			✓		✓	✓	✓	✓	60
Hamid e Kawasaki (2002)			MDL+DWT/WPT	MSE<11% CR<11%			-	-	-	-	-	-	-
Huang, Negnevitsky e Nguyen (2002)					WT+Neuro-Fuzzy	93,3%	✓	✓	✓	✓	✓	✓	512
Santoso <i>et al.</i> (2000b)					WT+LVQ	>=90%	✓		✓	✓	✓	✓	256

Continua na próxima página

Tabela 1 continuação da página anterior.

Autores	Detecção/Segmentação		Compactação		Classificação		Distúrbios					Amostras/ Ciclo	
	Método	Resultado	Método	Resultado	Método	Resultado	DS	DC	VTCD	T	F		D
Little e Morrow (1999)			DWT/WPT/DCT	PRD =<8% CR<=10			-	-	-	-	-	-	-
Hsieh, Huang e Huang (1998)			DWT+Subtrator	NMSE>=7,74e-7 textless59% (nº pontos)			✓		✓				-
Angrisani <i>et al.</i> (1998)	WT	EM <4%					✓		✓	✓		✓	256
Santoso, Powers e Grady (1997)			DWT	NMSE <= 10e-5 CR <6			✓			✓		✓	256
Santoso <i>et al.</i> (1996)	WT	Visual					✓			✓		✓	-

DS: Distúrbio Simples; DC: Distúrbio Combinado; VTCDs: Variações de Tensão de Curta Duração; T: Transitório; F: Flutuação; D: Distorção; EM= Erro Médio; BR: *Bit Rate*; PER: Energia Retida Percentual; PRDN: Diferença RMS Normalizada Percentual; PRD: Diferença RMS Percentual.

METODOLOGIA

Este capítulo é destinado à apresentação e detalhamento da metodologia adotada neste trabalho, que envolve a detecção/segmentação, a compressão e a classificação de distúrbios de QEE.

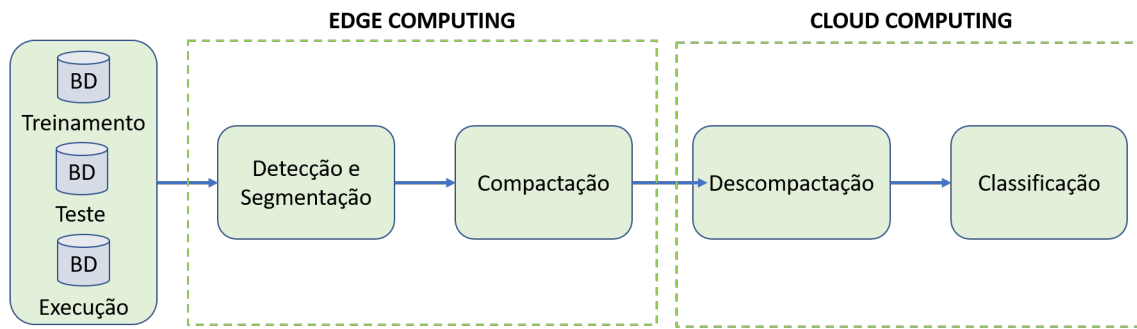
4.1 Visão Geral

Dada a importância em se monitorar o desempenho da operação das SGs e, consequentemente, da QEE que é entregue aos consumidores, é fundamental automatizar a detecção/segmentação, a compressão e a classificação de distúrbios. Dessa forma, as concessionárias poderiam adotar medidas de mitigação desses distúrbios e aprimorar a qualidade do serviço.

Como pôde ser observado no Capítulo 3, diversas técnicas foram propostas à detecção/segmentação, compactação e classificação de distúrbios. No entanto, o objetivo deste trabalho consiste em desenvolver um *framework* que comporte todos esses estágios, considerando ainda as limitações práticas dos *smart meters*. Ainda, nas publicações mais recentes, observa-se uma tendência em termos da transformação dos sinais temporais em imagens 2D, visto que os algoritmos de *deep learning* se mostraram eficientes na classificação dos distúrbios. Neste sentido, a presente dissertação investiga o uso de RP, GASF e GADF como novas ferramentas para transformação de sinais em imagens, as quais buscam extrair *features* dos distúrbios de QEE e, portanto, aprimorar o processo de classificação. A Figura 15 apresenta, de forma sumarizada, a sequência das principais etapas que integraram esta pesquisa. Maiores detalhes serão fornecidos nas seções seguintes.

As etapas de detecção/segmentação e de compressão dos distúrbios de QEE representam o processo que deve ocorrer diretamente no *smart meter*, ou seja, na borda do sistema (*edge computing*). E a descompactação e a classificação representam as etapas que devem ocorrer diretamente nos servidores de *cloud computing* da concessionária.

Figura 15 – Visão geral da metodologia proposta.



Fonte: Autoria própria.

4.2 Modelagem e Geração da Base de Dados Sintéticos

Para a realização desta pesquisa, foi gerada uma base de dados sintéticos obtidos por meio de modelos matemáticos adaptados da literatura (HOOSHMAND; ENSHAEI, 2010; LEE; SHEN, 2011; WANG; XU; CHE, 2019). Esta base inclui 15 classes de distúrbios que são frequentemente abordadas na literatura, das quais 9 são formadas por distúrbios simples e 6 por distúrbios combinados. A Tabela 2 apresenta os distúrbios sintéticos considerados nesta metodologia.

Tabela 2 – Distúrbios de QEE modelados matematicamente para geração de sinais sintéticos.

Sigla	Tipo de Distúrbio
D1	Afundamento
D2	Elevação
D3	Interrupção
D4	Transitório Oscilatório
D5	Transitório Impulsivo
D6	Flutuação de tensão
D7	Distorção Harmônica
D8	<i>Notching</i>
D9	<i>Spike</i>
D10	Afundamento com Distorção Harmônica
D11	Elevação com Distorção Harmônica
D12	Flutuação de tensão com Afundamento
D13	Flutuação de tensão com Elevação
D14	Afundamento com Transitório Oscilatório
D15	Elevação com Transitório Oscilatório

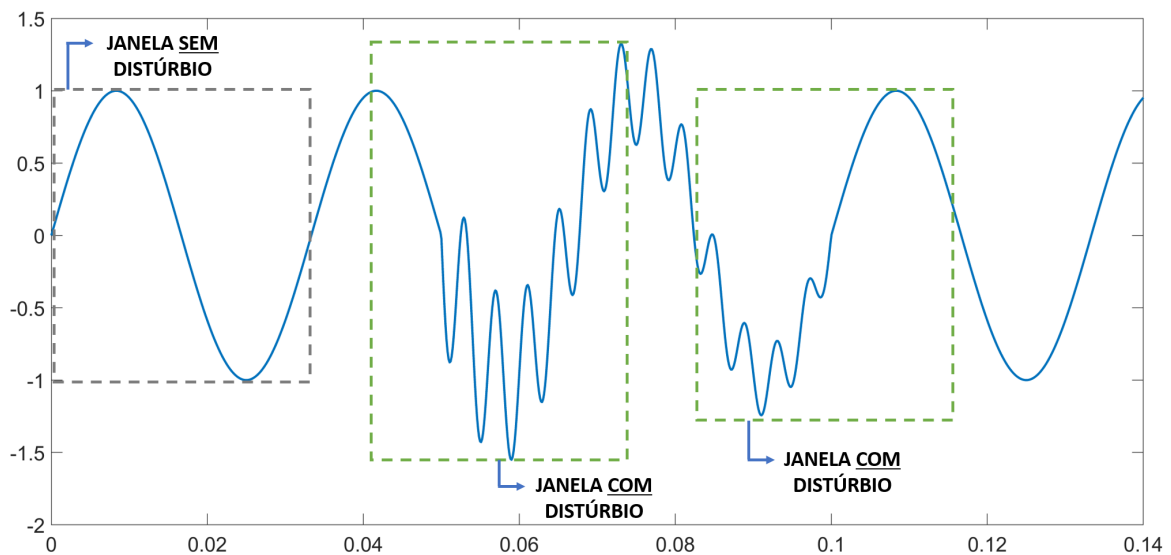
Duzentas amostras de cada classe de distúrbio (D1–D15) foram modeladas e geradas com parâmetros aleatórios, respeitando os limites recomendados pelo Módulo 8 do PRODIST e pela IEEE *Std.* 1159-2019. Cada janela de sinal gerada possui a extensão de 10 ciclos, frequência de 60 Hz e taxa de amostragem de 256 amostras/ciclo (15360 Hz) (BORGES, 2013). Os modelos matemáticos, bem como os limites de seus parâmetros, estão dispostos na Tabela 3. Considerando as 200 amostras geradas para cada distúrbio, a base de dados foi então composta por um total de

3000 amostras. Dessas, pela característica supervisionada do *framework* proposto, 70% foram utilizadas na etapa de treinamento, 20% na etapa de testes e 10% na etapa de execução.

A fim de proporcionar maior similaridade entre os sinais sintéticos e os reais, foram adicionados ruídos gaussianos brancos com relação sinal-ruído de 20 a 45 dB. Aos conjuntos de treinamento e testes foram adicionados ruídos de 20, 30 e 45 dB, enquanto ao conjunto de execução foram inseridos ruídos na ordem de 25, 35 e 40 dB, em consonância com o trabalho de Junior *et al.* (2021). É relevante citar que a base de execução verificará a capacidade de generalização do *framework* deste trabalho para níveis de ruído diferentes das outras bases de dados envolvidas.

Na sequência, foi realizado o processo de janelamento de cada amostra de sinal, que consiste no deslocamento de uma janela de dados de tamanho de um ciclo de sinal (256 pontos de discretização) e com avanço unitário até percorrer toda a extensão do sinal. Cada janela adquirida é rotulada de acordo com a presença ou ausência de distúrbio, conforme a Figura 16. Visto que cada sinal possui 10 ciclos de extensão (ou seja, um total de 2560 amostras discretas), o processo de janelamento gerou 2305 janelas (de 256 amostras) para cada sinal. Portanto, a base de dados de treinamento (BD1) do *framework* foi composta por um total de 19.362.000 janelas, a base de dados de testes (BD2) por um total de 5.532.000 janelas e a base de execução (BD3) por um total de 2.074.500 janelas.

Figura 16 – Processo de janelamento.



Fonte: Autoria própria.

Tabela 3 – Modelos matemáticos dos distúrbios de QEE.

Classe	Expressão	Parâmetros
D1	$h(t) = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t)$	$0,1 \leq \alpha \leq 0,9; T \leq t_2 - t_1 \leq 9T$
D2	$h(t) = [1 + \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t)$	$0,1 \leq \alpha \leq 0,8; T \leq t_2 - t_1 \leq 9T$
D3	$h(t) = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t)$	$0 \leq \alpha \leq 0,1; T \leq t_2 - t_1 \leq 9T$
D4	$h(t) = \sin(\omega t) + \alpha e^{-(t-t_1)/\tau} (u(t - t_1) - u(t - t_2)) \times \sin(2\pi f_n t)$	$0,1 \leq \alpha \leq 0,8; 0,5T \leq t_2 - t_1 \leq 3T;$ $300Hz \leq f_n \leq 900Hz; 8ms \leq \tau \leq 40ms$
D5	$h(t) = \sin(\omega t) - 1,11\alpha (e^{-7,5 \times 10^{-2}(t-t_1)} - e^{-3,44 \times 10^{-2}(t-t_1)}) \times (u(t - t_1) - u(t - t_2))$	$0,2 \leq \alpha \leq 1; T \leq t_1 \leq 7T; t_2 = t_1 + 1ms$
D6	$h(t) = \sin(\omega t) [1 + \alpha \sin(2\pi\beta t) (u(t - t_1) - u(t - t_2))]$	$0,05 \leq \alpha \leq 0,1; T \leq t_2 - t_1 \leq 9T$ $8Hz \leq \beta \leq 25Hz$
D7	$h(t) = \sin(\omega t) + [\alpha_{2k} \sin((2k)\omega t) + \alpha_{2k+1} \sin((2k+1)\omega t) + \dots + \alpha_{2k-n} \sin((2k-n)\omega t)] (u(t - t_1) - u(t - t_2))$	$0,015 \leq \alpha_{2k} \leq 0,03; 0,035 \leq \alpha_{2k+1} \leq 0,06;$ $T \leq t_2 - t_1 \leq 9T; 2 \leq k \leq 25$
D8	$h(t) = \sin(\omega t) - \text{sign}(\sin(\omega t)) \times \{ \sum_{n=1}^k \alpha [u(t - (t_1 + 0,02n)) - u(t - (t_2 + 0,02n))] \}$	$0,1 \leq \alpha \leq 0,4; 0,01T \leq t_2 - t_1 \leq 0,04T;$ $2 \leq k \leq 8T$

Continua na próxima página

Tabela 3 – continuação da página anterior.

Classe	Expressão	Parâmetros
D9	$h(t) = \sin(\omega t) + \text{sign}(\sin(\omega t)) \times \left\{ \sum_{n=1}^k \alpha [u(t - (t_1 + 0.02n)) - u(t - (t_2 + 0.02n))] \right\}$	$0,1 \leq \alpha \leq 0,4; 0,01T \leq t_2 - t_1 \leq 0,04T;$ $2 \leq k \leq 8T$
D10	$h(t) = [1 - \alpha(u(t - t_1) - u(t - t_2))] \times [\sin(\omega t) + [u(t - t_3) - u(t - t_4)] \times (\alpha_{2k} \sin((2k)\omega t) + \alpha_{2k+1} \sin((2k+1)\omega t) + \dots + \alpha_{2k-n} \sin((2k-n)\omega t))]$	$0,1 \leq \alpha \leq 0,9; T \leq t_{2,4} - t_{1,3} \leq 9T; 2 \leq k \leq 25;$ $0,015 \leq \alpha_{2k} \leq 0,03; 0,035 \leq \alpha_{2k+1} \leq 0,06$
D11	$h(t) = [1 + \alpha(u(t - t_1) - u(t - t_2))] \times [\sin(\omega t) + [u(t - t_3) - u(t - t_4)] \times (\alpha_{2k} \sin((2k)\omega t) + \alpha_{2k+1} \sin((2k+1)\omega t) + \dots + \alpha_{2k-n} \sin((2k-n)\omega t))]$	$0,1 \leq \alpha \leq 0,8; T \leq t_{2,4} - t_{1,3} \leq 9T; 2 \leq k \leq 25;$ $0,015 \leq \alpha_{2k} \leq 0,03; 0,035 \leq \alpha_{2k+1} \leq 0,06$
D12	$h(t) = [1 - \alpha_f \sin(2\pi\beta t)(u(t - t_1) - u(t - t_2))] \times \{ [1 - \alpha(u(t - t_3) - u(t - t_4))] \sin(\omega t) \}$	$0,1 \leq \alpha \leq 0,9; T \leq t_{2,4} - t_{1,3} \leq 9T;$ $0,05 \leq \alpha_f \leq 0,1; 8Hz \leq \beta \leq 25Hz$
D13	$h(t) = [1 - \alpha_f \sin(2\pi\beta t)(u(t - t_1) - u(t - t_2))] \times \{ [1 + \alpha(u(t - t_3) - u(t - t_4))] \sin(\omega t) \}$	$0,1 \leq \alpha \leq 0,8; T \leq t_{2,4} - t_{1,3} \leq 9T;$ $0,05 \leq \alpha_f \leq 0,1; 8Hz \leq \beta \leq 25Hz$
D14	$h(t) = [\alpha e^{-(t-t_1)\tau} \sin(2\pi f_n t)(u(t - t_1) - u(t - t_2))] + \{ [1 - \alpha(u(t - t_3) - u(t - t_4))] \times \sin(\omega t) \}$	$0,1 \leq \alpha_{ot} \leq 0,8; 0,5T \leq t_2 - t_1 \leq 3T; 300Hz \leq f_n \leq 900Hz;$ $8ms \leq \tau \leq 40ms; 0,1 \leq \alpha \leq 0,9; T \leq t_4 - t_3 \leq 9T$
D15	$h(t) = [\alpha e^{-(t-t_1)\tau} \sin(2\pi f_n t)(u(t - t_1) - u(t - t_2))] + \{ [1 + \alpha(u(t - t_3) - u(t - t_4))] \times \sin(\omega t) \}$	$0,1 \leq \alpha_{ot} \leq 0,8; 0,05T \leq t_2 - t_1 \leq 3T; 300Hz \leq f_n \leq 900Hz;$ $8ms \leq \tau \leq 40ms; 0,1 \leq \alpha \leq 0,8; T \leq t_4 - t_3 \leq 9T$

4.3 Lado da Computação em Borda (*Edge Computing*)

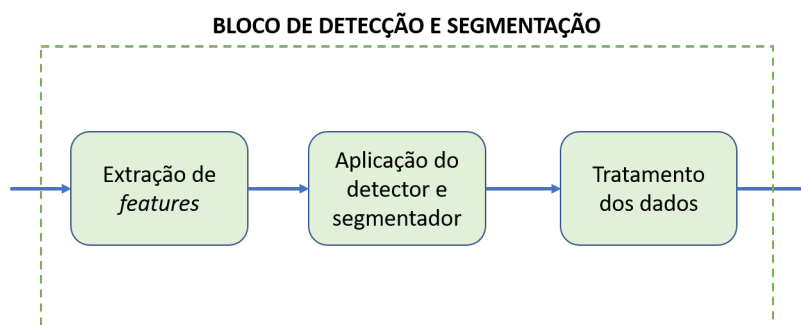
O conceito de computação em borda é muito adequado à modernização do SEP. Iniciar o processo de manipulação das informações logo na borda da rede/sistema, ou seja, próximo ao consumidor, contribui para melhorar o tráfego pela rede de dados que conecta os *smart meters*. Essa afirmação torna-se ainda mais evidente ao considerar que cada unidade consumidora, bem como cada ponto estratégico da rede, terá um *smart meter* instalado. Dessa forma, o volume de informações que trafegarão, em tempo real, pela rede de comunicação será enorme e se tornará cada vez mais intenso à medida que novos pontos de medição forem instalados ao longo da rede de distribuição. Este fato poderá, por sua vez, criar gargalos no sistema de comunicação e prejudicar a efetividade do serviço prestado.

Entretanto, para as concessionárias, é apenas interessante ter conhecimento sobre a parcela do sinal de tensão e/ou corrente correspondente ao distúrbio que afetou a QEE, pois a tomada de decisão para mitigá-lo partirá da análise destas informações. Portanto, segmentar apenas a porção do sinal correspondente ao distúrbio será suficiente para a concessionária, além de contribuir na redução do fluxo de dados que trafegará pelos canais de comunicação.

É importante mencionar que a *edge computing* permite uma descentralização do processo de pré-processamento do sinal. Apesar dos serviços de *cloud computing* possibilitarem um alto poder de processamento, o custo financeiro ainda pode ser considerado elevado. Com isso, a tarefa de descentralização proporcionará, mesmo que pequena, uma economia às concessionárias.

Como pode ser visto no Capítulo 3, diversas técnicas foram utilizadas para realizar a detecção/segmentação e a compactação de distúrbios de QEE. Observa-se que técnicas de *soft computing*, com destaque para WT e algoritmos de *machine learning*, se tornaram populares na área de QEE. Portanto, para realizar a detecção/segmentação dos sinais será feito um estudo comparativo entre DT e Regressão, visto que ambos os algoritmos podem apresentar menor esforço computacional para serem adquiridos em *smart meters*. Vale citar que este é um problema de classificação binária, uma vez que visa prever a existência ou não de distúrbio em determinada janela de dados. As ações realizadas dentro do bloco de detecção/segmentação estão representadas na Figura 17.

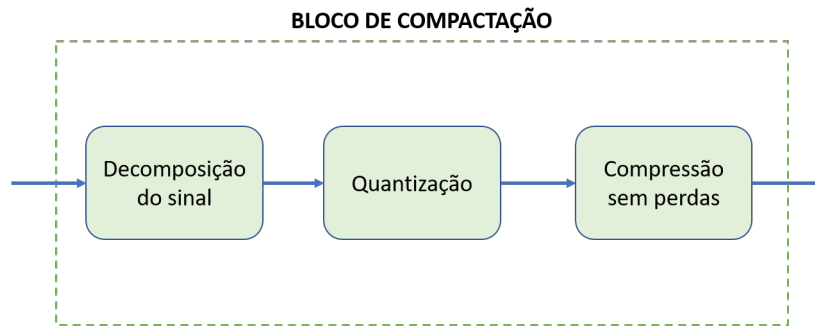
Figura 17 – Processo de detecção/segmentação adotado.



Fonte: Autoria própria.

Em relação à compressão, percebe-se que a WT tem sido a técnica mais aplicada. Como a compressão não é o foco principal deste trabalho, baseou-se na combinação de técnicas consolidadas na literatura. Portanto, a compressão adotada neste trabalho baseou-se na utilização da DWT em conjunto com um algoritmo de compressão sem perdas do tipo *Huffman Code* (ANDRADE *et al.*, 2019). A Figura 18 ilustra o processo de compactação adotado.

Figura 18 – Processo de compactação adotado.



Fonte: Autoria própria.

4.3.1 Extração de características para detecção/segmentação de distúrbios

Em problemas que visam a classificação de padrões, as etapas de extração e seleção de características são de grande relevância para preservar e destacar as informações singulares e úteis contidas nos dados, além da redução de sua dimensionalidade. Neste sentido, foram extraídas, por meio de cálculos matemáticos, as seguintes características, com base em Borges *et al.* (2016):

- Características estatísticas: Média Harmônica (C1), Desvio Padrão (C2), Desvio Médio (C3) e *Kurtosis* (C4);
- Características de quantidade de informação: Entropia (C5), Entropia de *Shannon* (C6) e Entropia de *Rényi* (C7);
- Características de amplitude do sinal: Valor Eficaz (C8), Valor de Pico (C9) e Diferença entre o maior e o menor valor da janela (C10);
- Característica em frequência: Distorção Harmônica Total (C11).

As métricas C1 a C11 foram calculadas por meio das seguintes equações (BORGES *et al.*, 2016):

$$C_1 = \frac{N}{\sum_{j=1}^N \frac{1}{d_j}}, \quad (4.1)$$

$$C_2 = \sqrt{\frac{\sum_{j=1}^N (d_j - \text{media})^2}{N-1}}, \quad (4.2)$$

$$C_3 = \frac{\sum_{j=1}^N |d_j - \text{media}|}{N-1}, \quad (4.3)$$

$$C_4 = \frac{\frac{1}{N} \sum_{j=1}^N (d_j - \text{media})^4}{\left[\frac{1}{N} \sum_{j=1}^N (d_j - \text{media})^2 \right]^2}, \quad (4.4)$$

$$C_5 = \sum_{j=1}^N \log(d_j^2), \quad (4.5)$$

$$C_6 = - \sum_{j=1}^N d_j^2 \log(d_j^2), \quad (4.6)$$

$$C_7 = \frac{1}{1-0.4} \log \sum_{j=1}^N \log(d_j^{0.4}), \quad (4.7)$$

$$C_8 = \sqrt{\frac{1}{N} \sum_{j=1}^N |d_j|}, \quad (4.8)$$

$$C_9 = \max(d_j), \quad (4.9)$$

$$C_{10} = \max(d_j) - \min(d_j), \quad (4.10)$$

$$C_{11} = \frac{\sqrt{\sum_{k=2}^M X_k^2}}{X_1}, \quad (4.11)$$

onde d_j representa cada amostra de dados, j é o índice de cada elemento na janela de dados (posição), N é a quantidade de amostras da janela (dimensão), X_k é a amplitude da componente harmônica, k é a ordem de cada componente e M representa a máxima componente harmônica considerada, que neste caso é igual a 25 ($M = 25$).

O valor da característica C11 foi estimada com o auxílio da FFT, uma vez que proporciona menor esforço computacional do que a *Discrete Fourier Transform* (DFT).

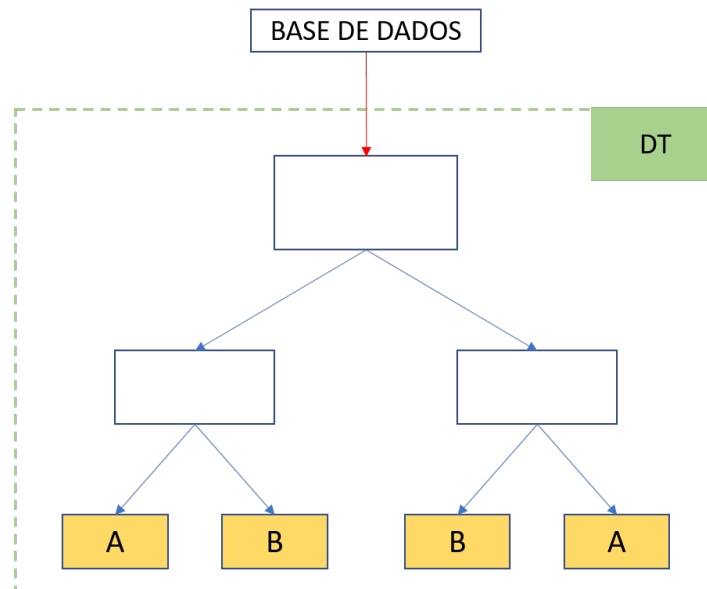
No final do processo de extração de características, cada amostra de sinal foi transformada em um vetor de características ($A = [C1, C2, C3, \dots, C11]$). Assim, os vetores gerados são utilizados como entradas aos classificadores.

4.3.2 Algoritmos utilizados na segmentação e detecção de distúrbios

4.3.2.1 Decision Tree

Dentre os modelos de predição supervisionados, pode-se destacar as DTs, as quais são usadas em problemas de classificação e regressão. Para tanto, elas utilizam uma representação em árvore, sendo hierarquicamente estruturadas em um conjunto de nós interconectados. Cada nó interno representa um teste condicional do tipo (*se <condição> então ...; senão ...*) sobre determinada característica de entrada (atributo). Assim, cada ramificação representará o resultado do teste e cada nó folha será o rótulo de uma classe (WITTEN; FRANK; HALL, 2011). Portanto, esse método realiza um procedimento iterativo para dividir as variáveis independentes de uma amostra em subgrupos progressivamente menores, até chegar na estratificação das folhas para a classificação propriamente dita. As regras de classificação para cada classe podem ser visualizadas percorrendo o caminho da raiz até as folhas da árvore. Um esquema básico de uma DT é ilustrado na Figura 19.

Figura 19 – Esquema genérico de um classificador baseado em DT.



Fonte: Autoria própria.

Para a implementação deste classificador, foi utilizado a função *DecisionTreeClassifier*, disponível na biblioteca *Scikit-Learn* da linguagem *Python*. O algoritmo foi configurado para lidar com dados desbalanceados e definida a profundidade máxima de crescimento da árvore como 3. Uma profundidade máxima de crescimento pequena permite a criação de um modelo final mais simples e que exija menos poder computacional no *hardware*.

4.3.2 Regressão Logística

A RL é um algoritmo de *machine learning* empregado para problemas de classificação, que se baseia no conceito da probabilidade e é alcançado por meio de um modelo logístico. O núcleo de uma regressão logística é a função sigmoideal, que representa uma curva em forma de S e mapeia valores reais no intervalo $[0, 1]$ (BISONG, 2019).

Na operação da RL, os valores de entrada são linearmente combinados utilizando pesos ou coeficientes para prever a saída. A principal diferença entre a RL e regressão linear é que o valor de saída que está sendo modelado é um valor binário (0 ou 1) em vez de um valor numérico contínuo. Logo, em um problema de classificação binária de detecção de distúrbios de QEE, a regressão logística buscará prever a probabilidade de um padrão de entrada pertencer ou não a uma classe (com distúrbio ou sem distúrbio).


Por se tratar de um modelo determinístico, ele sempre chegará em uma mesma solução toda vez que for treinado para a mesma base de dados. Diferentemente do que ocorre com um modelo estocástico.

Para a implementação deste modelo de classificador, foi utilizada a função *LogisticRegression* da biblioteca *Scikit-Learn* configurado para operar com dados desbalanceados.

4.3.3 Tratamento dos dados após a aplicação do algoritmo de detecção e segmentação

Falhas no processo de detecção e segmentação, intrínsecas do modelo gerado pelo algoritmo de classificação, pode comprometer a qualidade do resultado final do processo. A ocorrência de falsos negativos, por exemplo, podem fragmentar um único distúrbio em mais de uma parte, conforme exemplificado na Figura 20. Neste caso genérico, os *outliers* iniciam no instante de tempo $t = 1853$ e terminam em $t = 1856$, formando uma região/aglomerado de falsos negativos com 4 unidades de comprimento/extensão. Como resultado, o distúrbio representado foi fragmentado em duas partes.

Figura 20 – Exemplificação da ocorrência de falsos negativos na detecção de distúrbios.




Fonte: Autoria própria.

Para verificar como essas regiões/aglomerados de falsos negativos nos dados se formam, ou seja, a distribuição do comprimento/extensão, em unidades, dos aglomerados de falsos negativos presentes em cada classe de distúrbio, foi utilizada a análise de *Box plots* (MCGILL;

(TUKEY; LARSEN, 1978). Em suma, o *Box plot* representa graficamente grupos de dados numéricos por meio de seus quartis em diagramas de caixas. Estes diagramas podem também ter linhas que se estendem desde as caixas (*whiskers*), indicando a variabilidade fora os quartis superior e inferior. Os pontos individuais (discrepantes) são plotados como *outliers*. Além disso, o *Box plot* permite a exibição da variação em amostras de uma população estatística sem fazer quaisquer suposições da distribuição estatística subjacente.

A fim de mitigar a ocorrência de aglomerados de falsos negativos que acabam fracionando em duas ou mais partes a detecção de um único do distúrbio, assumiu-se que, se a distância entre duas janelas classificadas com a presença de distúrbio (verdadeiro positivo) é menor ou igual ao maior extensão de aglomerados de falsos negativos encontrada no *Box plot*, todas as janelas nesse intervalo classificadas sem a presença de distúrbio serão substituídas pela presença do distúrbio (ou seja, troca-se um *bit* 0 por 1. Por exemplo, o *Box plot* forneceu a informação de que a classe D6 de distúrbio apresentou a região com maior extensão de falsos negativos, que é igual a 4 unidades (Figura 20). Portanto, após aplicação deste tratamento de dados, os 4 *outliers* localizados entre $t = 1853$ e $t = 1856$ passarão a ser representados por 1 em vez de 0, removendo o fracionamento do distúrbio.

Figura 21 – Exemplificação da mitigação de falsos negativos na detecção do distúrbios.



Fonte: Autoria própria.

Ademais, em um cenário ideal, o processo de detecção seria capaz de identificar o início/fim do distúrbio com apenas um ponto de distúrbio na janela deslizante. Entretanto, também por problemas de sensibilidade do modelo construído, seja necessário a existência de mais pontos de distúrbios dentro da janela de dados para que o algoritmo comece a perceber o início/fim do distúrbio. Neste contexto, faz-se necessário a adição de algumas amostras discretas prévias à primeira amostra detectada pelo algoritmo, bem como adição de algumas amostras discretas após à última amostra detectada, a fim de garantir que o distúrbio seja, na medida do possível, inteiramente capturado, incluindo as suas bordas de início e fim. Deste modo, no processo de reconstrução do sinal detectado, utilizou-se o intervalo de confiança de 95% da medida estatística Desvio Padrão, que fornece a informação necessária da variação em torno da média, para verificar a quantidade de amostras que deverão ser adicionadas no início e fim do distúrbio.

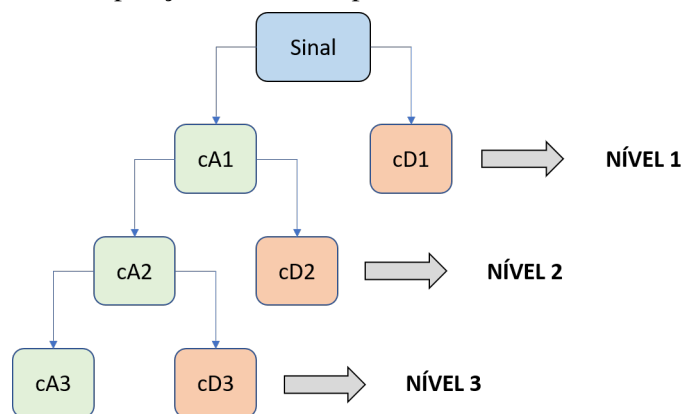
4.3.4 Compressão de sinais

Após detecção e segmentação da parcela do sinal que contém o distúrbio, ou seja, após detectadas a parcela de distúrbio contida na amostra de sinal, inicia-se o processo de compressão.

4.3.4.1 Transformada Wavelet Discreta

A DWT é um método matemático que possibilita a decomposição de um sinal temporal em componentes de alta e baixa frequência, denominados coeficientes de detalhes (cD) e de aproximação (cA), respectivamente. O processo de decomposição pode ser realizado repetidamente até que a resolução de frequência e tempo desejada seja alcançada. Cada estágio de decomposição costumeiramente é chamado de nível de decomposição ou nível de resolução. À medida em que se avança pelos níveis de decomposição, a resolução em frequência tende a se aperfeiçoar; entretanto, a resolução temporal é degradada. A Figura 22 ilustra um processo de decomposição.

Figura 22 – Esquema de decomposição de um sinal por meio da DWT até o terceiro nível de resolução.



Fonte: Autoria própria.

A DWT possui uma ampla família de filtros. Cada filtro possui formas e características particulares, que podem ser aplicadas para análises contínuas e discretas dos sinais. A escolha da família de *wavelets* depende da natureza da aplicação, assim como pelas características particulares do sinal em estudo. Ainda, as *wavelets* são classificadas dentro da família pelo número de momentos nulos (*vanishing moments*), que está ligado à suavidade do filtro (UZINSKI, 2013).

No que tange a compressão de dados, esta ferramenta contribui na remoção da redundância sem prejudicar a integridade da característica do sinal (LITTLER; MORROW, 1999), reduzindo sua dimensionalidade. Conforme mostrado no Capítulo 3, diversas abordagens se basearam na compactação por WT.

Nesta etapa da metodologia, foram realizados testes envolvendo os filtros *wavelets db4* e *bior3.1*, pois mostraram excelentes resultados na literatura analisada. Além disso, testou-se a decomposição até o segundo (para *db4*) e quarto (para *bior3.1*) níveis de resolução.

4.3.4.2 Quantização

Em SEP, os sinais de tensão/corrente, além de serem afetados por distúrbios, normalmente, ainda possuem ruídos de alta frequência. Entretanto, conforme mencionado, a decomposição de um sinal por meio da DWT separa componentes de alta e baixa frequência nos múltiplos níveis de resolução. Visto que os componentes de alta frequência são indesejáveis e podem prejudicar o processo de compressão do sinal, deve-se estabelecer um ponto de corte (limiar). Quanto maior a eliminação de coeficientes decompostos por uma DWT (pela substituição dos valores contidos nos coeficientes por zero), maior será a taxa de compactação e também a perda de informação na etapa de reconstrução do sinal.

Nesse sentido, [Santoso, Powers e Grady \(1997\)](#) propuseram uma forma simples para eliminar os coeficientes da DWT abaixo de um limiar que se baseia no valor máximo absoluto de cada nível dos coeficientes dos detalhes. Matematicamente, o valor do limiar pode ser obtido da seguinte forma:

$$\text{limiar}(n) = (1 - u) \times \max\{|cD(n)|\}, \quad (4.12)$$

onde n representa o n -ésimo nível de decomposição e u pertence ao intervalo $[0, 1]$. Foram testados os valores de u 0,1 a 0,9, com passo incremental de 0,1.

A partir da ideia de que valores abaixo do limiar são descartados, pode-se reescrever o novo cD como:

$$cD(n) = \begin{cases} cD(n), & \text{se } |cD(n)| \geq \text{limiar} \\ 0, & \text{se } |cD(n)| < \text{limiar} \end{cases} \quad (4.13)$$

Em síntese, após calculado o valor do limiar, ao módulo dos valores dos coeficientes cD que estiverem abaixo desse limiar é atribuído o valor zero e os demais valores não sofrem alteração. Portanto, este método de quantização funciona como um filtro para remover impurezas de componentes de alta frequência que não agregam benefícios ao processo de compressão.

4.3.4.3 Compressão sem perdas: Huffman Code

Métodos de compressão, em suma, são utilizados para encontrar uma forma de reduzir o número de *bits* de um dado, a fim de representá-lo de forma mais compacta, ou seja, um arquivo de menor tamanho (em *bytes*). Na literatura, encontram-se duas tipologias de compressão, sem perdas (*lossless*) e com perdas (*lossy*). Apesar de, em geral, essas tipologias serem distintas, o propósito é o mesmo, isto é, remover a redundância dos dados originais e garantir uma representação mais compacta do mesmo ([SALOMON, 2007](#)).

Nesta dissertação, foi implementado o algoritmo de compactação sem perdas denominado *Huffman Code*. O método de *Huffman* é um algoritmo dinâmico que constrói uma árvore binária,

denominada *Huffman Tree*, baseada na frequência de ocorrência de um caractere (símbolo). Cada folha desta árvore representa um caractere e o caminho do início (raiz) até a folha determina a representação codificada desse caractere (MALLAT, 2009; SALOMON, 2007). Como resultado, o algoritmo busca representar cada caractere com o menor número de *bits* possível e, assim, reduzir a dimensionalidade do pacote de dados.

O processo de quantização é um grande aliado do *Huffman Code*. Com a aplicação do limiar do quantizador, vários valores dos coeficientes da DWT são substituídos por zero. Então, a eficiência do resultado da compressão do *Huffman Code* é aumentada, uma vez que a variedade de caracteres distintos entre si é reduzida.

Por fim, é importante ressaltar, que a natureza do dado é importante também para a eficiência da compressão. Dependendo da informação contida em um pacote de dados, pode não ser possível alcançar uma grande eficiência na compactação.

4.4 Lado da Computação em Nuvem (*Cloud Computing*)

Ao fim do processo de manipulação do sinal na borda do SEP, os dados então são encaminhados para os servidores de *cloud computing* da concessionária por meio dos canais de comunicação. Em posse desses dados, a concessionária inicia o processo de descompactação e classificação dos distúrbios detectados pelos *smart meters*. É importante mencionar que não faz parte do escopo deste trabalho a definição de algum protocolo de comunicação, assim como a implementação de algum método para lidar com as perdas de pacotes de dados inerentes ao processo de transmissão dos *smart meters* à concessionária.

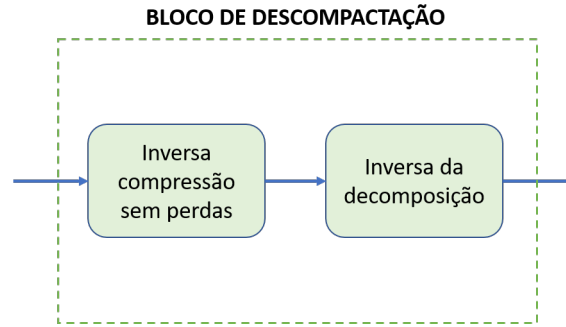
Em virtude da escalabilidade proporcionada por infraestruturas de *cloud computing*, à medida que é exigido maior poder de processamento e armazenamento de dados, a concessionária pode ampliá-los. Além disso, sistemas de *cloud computing* são capazes de responder rapidamente a essas demandas.

Inicialmente, o sinal deverá ser descompactado, conforme ilustrado na Figura 23. Nas etapas que constituem esse processo, as técnicas já aplicadas na compactação serão novamente utilizadas.

Na literatura, a maioria das ferramentas utilizadas na classificação de distúrbios, conforme constatado no Capítulo 3, utilizam algoritmos de *machine learning*. Neste sentido, esta dissertação irá testar e comparar o desempenho de uma CNN convencional e uma CNN pré-treinada do tipo *VGG16*. Entretanto, diferente das abordagens analisadas, é proposta uma etapa de extração de características dos sinais baseada em RP, GASFs e GADFs, em que serão geradas imagens 2D binárias (RP) e coloridas (GASF/GADF). A Figura 25 ilustra esse processo.

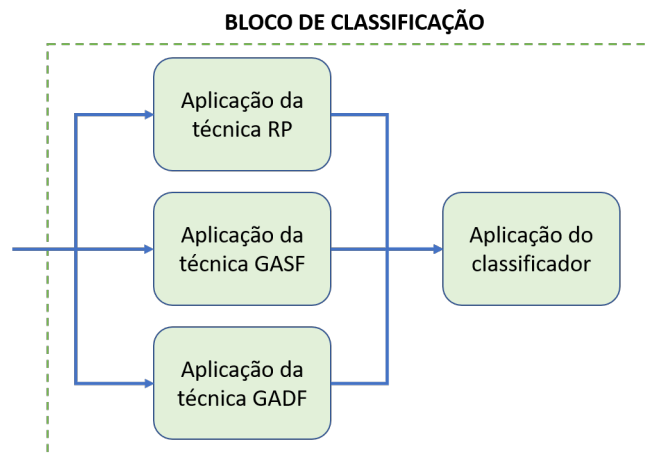
Cada classificador é treinado para reconhecer um único tipo de distúrbio. Por exemplo, se uma janela de dados com afundamento de sinal entrar na cadeia de classificadores, apenas o

Figura 23 – Esquema de descompactação do sinal.



Fonte: Autoria própria.

Figura 24 – Esquema de classificação de distúrbio de QEE.



Fonte: Autoria própria.

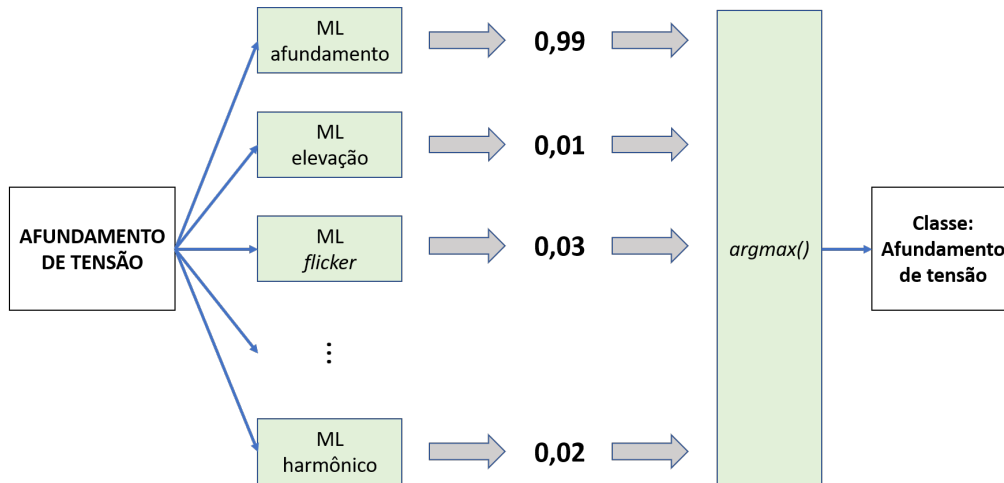
classificar destinado à identificação de afundamento de tensão responderá com o maior valor de saída (verdadeiro) perante os demais classificadores. A função $argmax()$ ficará responsável por indicar qual classificador produziu a maior saída. A ilustração deste exemplo por ser visto na Figura 25. Cita-se também que foi incluído um classificador para a identificação de amostras de sinais de tensão puro (D0: sem distúrbio) para garantir que possíveis falhas no processo de detecção/segmentação não prejudiquem a qualidade do resultado da classificação dos distúrbios.

Os melhores classificadores de cada classe de sinal (D0–D15), dentre todas as estruturas (tipo de entrada: RP, GASF ou GADF) e topologias (CNN ou *VGG16*) testadas serão selecionados para compor o conjunto (*ensemble*) de classificadores que efetivamente integrará o processo de identificação de padrões na *cloud*.

4.4.1 Descompactação de sinais

Visto que tanto a técnica de *Huffman Code* quanto a DWT possuem suas operações inversas, a descompactação dos dados torna-se uma tarefa menos complexa. Portanto, ao se aplicar a inversa da *Huffman Code*, tem-se como saída os coeficientes de decomposição da DWT. Assim, para reconstruir o sinal do distúrbio, aplica-se a inversa da DWT, garantindo similaridade necessária entre o sinal original e o sinal descompactado. Uma pequena perda de informação

Figura 25 – Exemplo genérico do processo de classificação.



Fonte: Autoria própria.

ocorrerá devido ao processo de quantização.

4.4.2 Extração de características para classificação de distúrbios

Para a realização desta etapa, conforme previamente mencionado, foram extraídas imagens binárias por meio de Gráficos de Recorrência (RPs) e imagens não binárias por meio dos *Gramian Angular Fields* (GAFs), utilizando a biblioteca *Pyts* do *Python* em ambos os casos.

4.4.2.1 Gráficos de Recorrência

Identificar a ocorrência de padrões não lineares em sinais temporais ainda é uma tarefa desafiadora, sobretudo se analisados no domínio do tempo. [Eckmann, Kamphorst e Ruelle \(1987\)](#) propuseram uma análise de imagens por meio de RPs, em que se define uma matriz $M \times M$ extraída de um sinal temporal com M amostras, expressa por:

$$R_{i,j} = \Theta(\varepsilon - \|x'_j - x'_i\|), \quad (4.14)$$

onde x' corresponde a série temporal de uma dimensão; $i, j = 1, 2, \dots, M$; M é o número de estados considerados; ε é o raio da vizinhança (limite) em determinado ponto x'_j ou x'_i ; $\|\cdot\|$ geralmente considerada a norma Euclidiana; e θ é a função *Heaviside*, responsável por mapear o resultado encontrado em uma matriz binária.

De forma resumida, este método busca destacar os momentos em que a trajetória do espaço de fase de um sistema dinâmico visita aproximadamente a mesma área no espaço de fase ([ECKMANN; KAMPHORST; RUELLE, 1987](#)).

Entretanto, para que a série temporal unidimensional seja processada pela Equação (4.14), é necessário realizar sua expansão por meio da técnica denominada *Reconstruction of*

Phase Space (RPS). Baseado na teoria do tempo de atraso e dimensão de imersão (HONG, 2020), tem-se que:

$$X = \begin{pmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(n-1)\tau} \\ x_2 & x_{2+\tau} & \cdots & x_{2+(n-1)\tau} \\ x_3 & x_{3+\tau} & \cdots & x_{3+(n-1)\tau} \\ \vdots & \vdots & \ddots & \vdots \\ x_{M-(n-1)\tau} & x_{M-(n-2)\tau} & \cdots & x_M \end{pmatrix} \quad (4.15)$$

onde X é o RPS, x_i representa a série temporal, $n \geq 2$ (dimensão de imersão, do inglês *embedding dimension*) e $\tau \geq 1$ (tempo de atraso, do inglês *time delay*).

A matriz resultante, representada por X , é inserida na Equação (4.14) e então pode-se obter seu respectivo RP, representado por uma matriz de zeros e uns. Então, a partir do resultado obtido, um RP pode ser interpretado da seguinte maneira:

- Se $R_{i,j} = 1$, o estado é recorrente, um *pixel* preto é marcado no RP;
- Caso contrário, se $R_{i,j} = 0$, o estado não é recorrente e, conseqüentemente, um *pixel* branco é marcado no RP.


A formação de texturas, compostas por *pixels* isolados, linhas diagonais, linhas verticais e/ou linhas horizontais, pode ser identificada visualmente na matriz R resultante e, desta forma, várias informações importantes podem ser extraídas para caracterizar o comportamento da série temporal. Segundo Marwan *et al.* (2007), tem-se que:

- a homogeneidade representa a estacionariedade do processo;
- interrupções indicam que o processo é não estacionário ou que transições podem ter ocorrido;
- padrões periódicos garantem que o processo é cíclico;
- linhas diagonais paralelas à diagonal principal (linha identidade) indicam que a evolução dos estados do sistema é similar em diferentes épocas e que o processo pode também ser determinístico.

A Figura 26 apresenta o RP de um sinal senoidal ideal, o RP de um sinal senoidal com afundamento de tensão e o RP de um sinal senoidal com elevação de tensão.

Com o intuito de gerar imagens binárias que denotem a singularidade dos estados, ou seja, dos distúrbios de QEE, há a necessidade de ajustar os parâmetros de dimensão de imersão (n) e tempo de atraso (τ) do RPS e raio de vizinhança (ϵ) do RP.

Figura 26 – (a) RP de um sinal senoidal ideal; (b) RP de um afundamento de tensão; e (c) RP de uma elevação de tensão.



Fonte: Autoria própria.

O ajuste dos parâmetros foi realizado de forma empírica, baseando-se em percepções visuais, de modo a encontrar um conjunto de parâmetros que melhor represente singularmente cada classe de sinal abordado neste trabalho. Para tanto, foram geradas amostras de sinal para cada um dos 15 distúrbios. Os testes foram executados variando os parâmetros dentro das seguintes faixas: 2 a 10 (para dimensão e tempo de atraso) e 0,1 a 1 (para ϵ).

4.4.2.2 Gramian Angular Fields (GAFs)

Assim como o RP, os GAFs, que incluem GASF e GADF, são técnicas matemáticas que permitem a transformação de séries temporais em imagens 2D (WANG; OATES, 2015). Em suma, o GAF realiza o mapeamento de uma série temporal, representada em coordenadas cartesianas, para o sistema de coordenadas polares. Segundo Wang e Oates (2015), a transformação polar permite identificar a correlação temporal dentro de diferentes intervalos de tempo por meio da soma ou diferença trigonométrica das componentes angulares entre cada ponto.

No processo de transformação GAF, os dados precisam ser normalizados. Portanto, para uma série temporal $X = \{x_1, x_2, x_3, \dots, x_n\}$, em que n é o número de amostras, a normalização para o intervalo de $[-1, 1]$ pode ser feita pela Equação 4.16. Caso o intervalo desejado seja de $[0, 1]$, a normalização pode ser obtida pela Equação 4.17.

$$\tilde{x}_i^{[-1,1]} = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (4.16)$$

$$\tilde{x}_i^{[0,1]} = \frac{x_i - \min(X)}{\max(X) - \min(X)} \quad (4.17)$$

Na sequência, cada elemento da série temporal normalizada deve ser mapeado para o

sistema de coordenadas polares. Para tanto, tem-se:

$$\begin{cases} \phi_i = \arccos(\tilde{x}_i), & -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r_i = \frac{t_i}{N}, & t_i \in \mathbb{N} \end{cases} \quad (4.18)$$

em que ϕ_i e r_i representam a coordenada polar; t_i é o instante de tempo de visualização (*time stamp*) e N é um fator constante que regulariza a amplitude do sistema de coordenadas polares.

Como mencionado anteriormente, a correlação temporal entre diferentes intervalos de tempo pode ser facilmente explorada considerando a soma ou diferença trigonométrica entre cada ponto no sistema de coordenadas polares. Neste sentido, GASF e GADF são definidos como (WANG; OATES, 2015):


$$GASF = \begin{pmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{pmatrix} \quad (4.19)$$

$$GADF = \begin{pmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \vdots & \ddots & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{pmatrix} \quad (4.20)$$

Os resultados das transformações GASF e GADF proporcionam também a formação de texturas na imagem, porém coloridas, que expressam graficamente características do comportamento do sinal analisado, como pode ser observado nas Figuras 27 e 28.


A Figura 27 ilustra um exemplo da transformação GASF para um sinal senoidal ideal (a), para um sinal de afundamento de tensão (b) e para um sinal de elevação de tensão (c). E a Figura 28 exemplifica a transformação GADF para os mesmos três tipos de sinais abordados na Figura 27.

Figura 27 – (a) GASF de um sinal senoidal ideal; (b) GASF de um afundamento de tensão; e (c) GASF de uma elevação de tensão.



Fonte: Autoria própria.

Figura 28 – (a) GADF de um sinal senoidal ideal; (b) GADF de um afundamento de tensão; e (c) GADF de uma elevação de tensão.




Fonte: Autoria própria.

4.4.3 Classificação de distúrbios por CNN

Redes Neurais Convolucionais, do inglês *Convolutional Neural Network* (CNN), é um algoritmo de *deep learning* bastante utilizado na área de processamento de imagens para o reconhecimento de padrões e classificação de imagens (WANG; XU; CHE, 2019; CAI *et al.*, 2019b). Uma das primeiras aplicações de sucesso da CNN na área de processamento de imagens foi proposto por Lecun *et al.* (1998). Os autores propuseram o modelo LeNet-5 para a realização da tarefa de reconhecimento de dígitos manuscritos e obtiveram uma taxa de erro de 0,8% no conjunto de dados *MNIST* (*Modified National Institute of Standards and Technology*), que representou um marco para a área de pesquisa naquela época. A Figura 29 representa a arquitetura de uma CNN genérica.

Figura 29 – Ilustração de um classificador baseado em CNN.



Fonte: Autoria própria.

Yang, Jiang e Guo (2019) comentam que a CNN possui uma melhor capacidade de utilizar informações espaciais em comparação com a RNA do tipo MLP, que é basicamente composta por uma camada de entrada, camadas neurais ocultas e uma camada neural de saída. As camadas da CNN funcionam como um filtro e, quando expostos a informações espaciais, como cantos e bordas, produzem saídas mais significativas do que a MLP. Além disso, Krizhevsky, Sutskever e Hinton (2012) citam que a CNN proporciona muito menos conexões e parâmetros do que qualquer RNA *feedforward* — topologia de RNA em que as conexões entre os nós não

formam um ciclo — com camadas de tamanho similar, o que permite um treinamento mais eficiente.

Conforme mostrado na Figura 29, em suma, a estrutura básica de uma CNN possui (CHOLLET, 2017):

- **Camadas Convolucionais** – composta por múltiplos filtros (*kernels*) de convolução, os quais têm como função extrair características das imagens. Estes *kernels* são ajustados de modo supervisionado pelo algoritmo *backpropagation*. Um mapa de características é o resultado final deste processo.
- **Camadas de Ativação** – possuem a função de promover a introdução da não linearidade no sistema, a fim de que a rede consiga aprender qualquer funcionalidade. Comumente é utilizada a função ReLU;
- **Camadas de Pooling** – responsável por reduzir o tamanho espacial da característica convolvida sem a perda de representatividade. Esta agregação reduz a quantidade de parâmetros a serem aprendidos pela CNN e contribui ao controle de *overfitting* e melhoria de desempenho do modelo;
- **Camadas de Dropout** – introduz a estratégia de remover aleatoriamente alguns neurônios e conexões na estrutura da rede a fim de reduzir o *overfitting*;
- **Camada de Densa** – diferentemente da camada convolucional, na qual os pesos são conectados apenas em uma região dos dados, a camada densa está completamente conectada com a camada anterior, como em uma MLP.

Simonyan e Zisserman (2015) propuseram um modelo de CNN, popularmente conhecido como VGG-16 que alcançou uma acurácia de 92,7% nos testes utilizando a base de dados ImageNet, a qual contém mais de 13 milhões de imagens pertencentes a 1000 classes. Sua arquitetura é composta por 7 blocos, em que o primeiro bloco é composto por duas camadas com 64 neurônios, os quais atuam como filtros convolucionais, de dimensão 3×3, seguidas por uma camada de *max pooling* de dimensão 2×2; os blocos 2 a 5 possuem a mesma composição, entretanto há 128 filtros no segundo bloco, 256 no terceiro e 512 nos quarto e quinto blocos; o sexto bloco é composto por 3 camadas de neurônios totalmente conectadas, sendo as duas primeiras compostas por 4096 neurônios e última com 1000.

Para o treinamento de um algoritmo de *deep learning*, é necessário submeter a CNN a muitos exemplos de imagem do problema desejado. Neste processo, a CNN desenvolverá um modelo matemático que, por meio da análise e comparação de imagens, buscará reconhecer a categoria (ou classe) que o dado pertence. Contudo, a execução deste processo demanda muito esforço computacional e tempo de processamento.

Levando em consideração esse cenário, a “aprendizagem por transferência” (*transfer learning*) pode ser uma das alternativas disponíveis capaz de mitigar este problema. Segundo [Pan e Yang \(2010\)](#), o objetivo da transferência de aprendizagem é aplicar o conhecimento aprendido de uma tarefa no domínio de origem para outra nova tarefa diferente, mas relacionada no domínio de destino e melhorar o desempenho da nova tarefa. Desta forma, o processo de aprendizagem da CNN não necessita começar do zero, bem como de um grande volume de dados. Ou seja, há a reutilização dos pesos de uma rede previamente treinada utilizando uma grande base dados. Portanto, a LeNet-5 e a VGG-16 são exemplos de modelos pré-treinados disponíveis para a solução de problemas de classificação de imagens.

Com base nestas informações, foi incluso na metodologia deste trabalho a realização de testes comparativos de desempenho de classificação de distúrbios de QEE entre uma CNN convencional e o modelo pré-treinado VGG-16.

A arquitetura da CNN convencional foi definida como: o primeiro bloco é composto por uma camada com 32 como filtros convolucionais, de dimensão 3×3, seguida por uma camada de *max pooling* de dimensão 2×2 e uma camada de *dropout* com taxa de remoção de 30%; os blocos 2 e 3 possuem a mesma composição, contudo o segundo bloco possui 64 filtros e o terceiro 128; o quarto bloco é composto por uma camada do tipo *flatten*, responsável pela transformação de uma matriz 2D em um vetor 1D; e por fim o quinto bloco, composto por 1 neurônio, função de ativação sigmoideal e totalmente conectado ao bloco anterior, com o encargo de computar a saída da CNN.

Em relação à estrutura da VGG-16, foram feitas algumas modificações. O sexto bloco, que contém as camadas totalmente conectadas, foi removido. Neste lugar foram inseridas: uma camada de neurônios do tipo *flatten*, uma camada totalmente conectada com 1024 neurônios, uma camada de *dropout* com taxa de remoção de 20% e uma camada de saída com um neurônio com função de ativação sigmoideal.

Toda implementação se deu por meio da biblioteca *Keras* em *Python*. E os pesos iniciais do modelo VGG-16 foram importados levando em consideração a base de dados ImageNet. Além disso, as imagens geradas pelas transformações RP, GASF e GADF passaram por um processo de redimensionamento utilizando a biblioteca *OpenCV* do *Python*, com o intuito de padronizar a dimensão das imagens entregues às entradas dos classificadores. Assim, foi selecionada a dimensão da menor imagem obtida ao se aplicar as transformações supramencionadas.

4.4.4 Método de Classificação

Em problemas de classificação binária, o principal desafio do algoritmo utilizado é encontrar um hiperplano que consiga separar os dados em duas classes distintas. Entretanto, em problemas de classificação em que há mais de duas classe de dados, faz-se necessário um conjunto de hiperplanos que consiga separar os dados em N-classes existentes ([BLANCO](#);

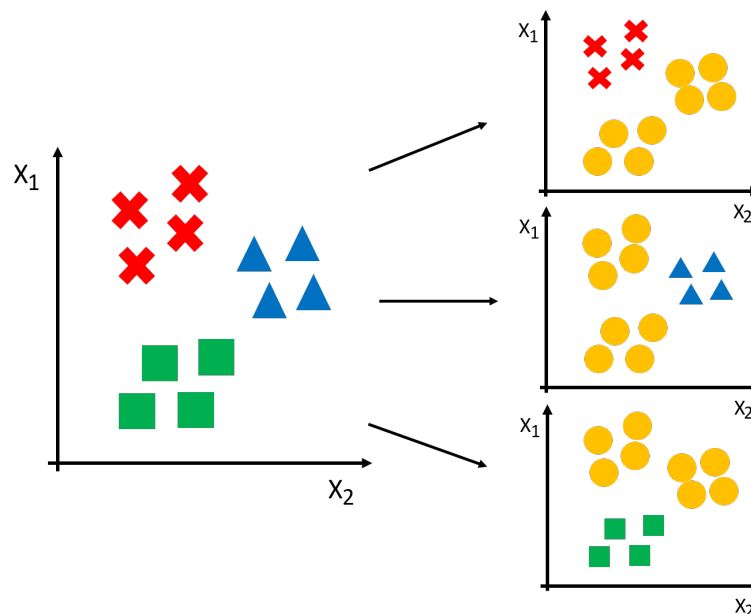
JAPON; PUERTO, 2020).

Uma CNN, assim como uma RNA multicamadas, permite também a classificação de problemas multi-classe, em que o número de neurônios da camada de saída é igual ao número de classes que o problema possui, ou seja, cada neurônio de saída representa uma classe. No processo de classificação, o neurônio que retorna o maior valor de saída indica a classe que o dado de entrada representa.

Contudo, classificadores binários podem também solucionar problemas multi-classes. Para tanto, faz-se necessário a utilização de um conjunto destes classificadores (*ensemble*) (ANAND *et al.*, 1995). O número de classes presentes na base de dados e o número de classificadores deve ser o mesmo. Na literatura correlata, esse método é chamado *One vs. All* (ou *One vs. Rest*) (ROCHA; GOLDENSTEIN, 2014). A classe resultante será representada pelo classificador que produzir o maior valor de saída.

A Figura 30 exemplifica o processo de funcionamento de um conjunto de classificadores operando no modo *One vs. All*. Neste exemplo são consideradas três classes. O primeiro classificador ficará responsável pela classificação do padrão “triângulo”, o segundo pelo “x” e o terceiro pelo “quadrado”. Para o primeiro classificador, por exemplo, a principal função será detectar os “triângulos”; quando ele for exposto a “x” ou “quadrado” ele apenas entenderá que não é “triângulo”, independentemente que seja “x” ou “quadrado”. A mesma analogia se aplica aos outros classificadores. Isto mostra, por sua vez, que cada classificador é especialista em um determinado padrão de dados, facilitando o processo de detecção se comparado ao outro método descrito anteriormente.

Figura 30 – Exemplo de classificação *One vs. All*.



Fonte: Autoria própria.

Em vista disso, a presente metodologia implementou o processo de classificação utili-

zando o método *One vs. All*. Cada CNN possui um neurônio na camada de saída e a função de ativação foi a sigmoïdal, que permite valores de saída reais entre o intervalo de [0,1]. O classificador do *ensemble* que produzir a maior saída representará a classe do dado de entrada investigado.

4.5 Métricas para Avaliação de Desempenho

Nesta seção, serão apresentadas as métricas de avaliação de desempenho das técnicas utilizadas em cada um dos módulos que compõem essa dissertação, ou seja, detecção/segmentação, compactação e classificação dos distúrbios.

4.5.1 Módulos de Detecção/Segmentação e Classificação

Devido aos sinais janelados não serem balanceados, ou seja, as classes têm distintas amostras, deve-se utilizar métricas de avaliação de desempenho que não enviesem os resultados. Deste modo foi aplicada uma métrica de análise estatística para classificação binária, denominada $F1_{score}$, a qual é expressa por (BONNIN, 2017):

$$F1_{score} = 2 \times \left(\frac{precision \times recall}{precision + recall} \right), \quad (4.21)$$

em que $precision = \frac{VP}{VP+FP}$, $recall = \frac{VP}{VP+FN}$, VP é o número de verdadeiros positivos, FP é o número de falsos positivos e FN é o número de falsos negativos. Em suma, quanto mais próxima de 1, maior a precisão de classificação.

Adicionalmente, para ir ao encontro das mesmas métricas utilizadas nos trabalhos revisados, também foi calculada a acurácia, que quantifica a taxa de previsões corretas que o modelo obteve e pode ser expressa por (BONNIN, 2017):

$$Acc = \frac{VP + VN}{VP + VN + FP + FN}. \quad (4.22)$$

em que VP , VN , FP e FN representam os verdadeiros positivos, os verdadeiros negativos, os falsos positivos e os falsos negativos, respectivamente.

Além disso, foi calculada a taxa de detecção e a taxa de fracionamento das amostras de distúrbio. A primeira taxa representa a quantidade de amostras de distúrbios detectados pelo número total de amostras, enquanto a segunda é a quantidade de distúrbios detectados que sofreram fracionamento pelo número total de amostras.

4.5.2 Módulos de Compactação e Descompactação

A avaliação de desempenho da compressão não se resume apenas à redução do pacote de dados. No processo de descompressão é necessário avaliar a qualidade da informação contida no pacote, ou seja, quantificar a perda de informação ocorrida no processo de compressão. A taxa de compressão (CR , do inglês *Compression Rate*) pode ser definida como:

$$CR = \frac{OD}{CD}, \quad (4.23)$$

onde OD e CD representam o tamanho do arquivo/pacote de dados original (sem compressão) e o tamanho do arquivo/pacote compactado, respectivamente. É importante salientar que o formato do arquivo original foi gravado no formato *txt* e o arquivo comprimido no formato *bin*.

A métrica utilizada para quantificar a perda de informação no processo de compactação foi a Entropia de *Shannon* (SHANNON, 1948), representada pela Equação 4.6, dado que ela é capaz de quantificar a variação média da entropia à medida em que se aumenta a taxa de compressão.

RESULTADOS

Este capítulo apresentará os resultados alcançados com a aplicação da metodologia proposta. Estes resultados incluem o Módulo de Detecção e Segmentação, o Módulo de Compactação e o Módulo de Classificação.

5.1 Módulo de Detecção e Segmentação

Nesta seção são apresentados os resultados obtidos pela técnica de detecção e segmentação, baseada no janelamento do sinal, com 256 pontos de amostragem por janela, e aplicação de algoritmos de *machine learning*. Deste modo, as Tabelas 4 a 13, bem como as Figuras 31 e 37, ilustram os resultados alcançados nesta etapa do processo.

É importante lembrar que a base de Teste possui amostras de eventos de QEE sem ruído e com SNR de 20, 35 e 45 dB. Por outro lado, a base de Execução possui sinais com SNR de 25, 30 e 45 dB. Portanto, a princípio, serão apresentados os resultados envolvendo a base de Teste e na sequência os resultados para a base de Execução.

Por meio da Tabela 4, é possível identificar que a RL obteve melhores índices de desempenho, levando em consideração as métricas $F1_{score}$ e Acurácia. Aprofundando um pouco mais esta análise comparativa, foram utilizadas matrizes de confusão para mostrar o número de previsões corretas em relação à resposta esperada (Tabelas 5 e 6). Por meio destas, é possível identificar que a RL possui um alto poder de detecção de janelas sem distúrbios, resultando em uma Acurácia e $F1_{score}$ acima de 94,50%, mostrando-se mais adequada que a DT neste quesito (uma diferença de 1,28% para $F1_{score}$ e 1,60% para Acurácia em favor da RL). A RL identificou uma quantidade maior de verdadeiros positivos do que a DT, alcançando uma detecção com $F1_{score}$ de 96,11% e Acurácia de 93,50% para as janelas que continham alguma amostra de distúrbio. Isto representa uma diferença superior de desempenho da RL em relação à DT na ordem de 1,27% para $F1_{score}$ e 2,74% para Acurácia. Por outro lado, o mesmo não acontece com

a capacidade de detecção de verdadeiros negativos. A DT conseguiu proporcionar uma detecção com $F1_{score}$ de 90,02% e Acurácia de 98,58% para as janelas que não continham nenhuma amostra de distúrbio. Uma diferença em favor da DT na ordem de 2,09% para $F1_{score}$ e 0,94% para Acurácia.

Tabela 4 – Resultados de Detecção por meio das métricas $F1_{score}$ e Acurácia para a base de Teste.

	Regressão Logística (%)	Árvore de Decisão (%)
$F1_{score}$	96,11	94,83
Acc	94,79	93,19

Tabela 5 – Matriz de Confusão da Detecção utilizando Regressão Logística para a base de Teste.


	Com distúrbio	Sem distúrbio	Total	$F1_{score}$ (%)	Acc (%)
Com distúrbio	3562299	247537	3809836	96,11	93,50
Sem distúrbio	40668	1681496	1722164	92,11	97,64

Tabela 6 – Matriz de Confusão da Detecção utilizando Árvore de Decisão para a base de Teste.

	Com distúrbio	Sem distúrbio	Total	$F1_{score}$ (%)	Acc (%)
Com distúrbio	3457682	352154	3809836	94,84	90,76
Sem distúrbio	24389	1697775	1722164	90,02	98,58

Na sequência, foi verificada a capacidade de acerto dos algoritmos em relação à quantidade de amostras de distúrbios contidas na janela de dados (Figuras 31 e 32).


Figura 31 – Desempenho da Regressão Logística para a base de Teste.



Fonte: Autoria própria.

Por meio destes resultados, nota-se que a RL possibilitou uma detecção menor que 50% para janelas que contenham até 8 amostras do distúrbio e maior que 90% para janelas que

Figura 32 – Desempenho da Árvore de Decisão para a base de Teste.



Fonte: Autoria própria.

tenham ao menos 87 amostras do distúrbio. Já a DT, garantiu uma detecção menor que 50% para janelas com até 11 amostras de distúrbio e maior que 90% para janelas com mais de 137 amostras do distúrbio. Com isso, fica claro que a RL consegue detectar a presença de distúrbio com menos amostras do mesmo. É importante frisar que a curva de acerto da RL ultrapassa a faixa de 95% de acerto. A DT, neste quesito, atinge no máximo a precisão de acerto de 93,94%.

Além disso, foram investigados os distúrbios não detectados e se os algoritmos testados conseguiram detectar o distúrbio sem fracioná-lo em duas ou mais partes, ou seja, sem que haja falsos negativos entre janelas verdadeiras positivas detectadas. Estas informações estão contidas nas Tabelas 7 e 8.

Tabela 7 – Extrato dos Resultados de Classificação da Regressão Logística para a base de Teste.

Distúrbio	Não detectados		Fracionados	
	Quantidade	%	Quantidade	%
D1	0	0	32	20,00
D2	0	0	38	23,75
D3	0	0	17	10,63
D4	0	0	80	50,00
D5	20	12,5	73	45,63
D6	1	0,63	158	98,75
D7	0	0	101	63,13
D8	0	0	47	29,38
D9	7	4,38	49	30,63
D10	0	0	18	11,25
D11	0	0	45	28,13
D12	0	0	106	66,25
D13	0	0	123	76,88
D14	0	0	40	25,00
D15	0	0	52	32,5
Total	28	1,17	979	40,79

Tabela 8 – Extrato dos Resultados de Classificação da Árvore de Decisão para a base de Teste.

Distúrbio	Não detectados		Fracionados	
	Quantidade	%	Quantidade	%
D1	0	0	18	11,25
D2	0	0	16	10,00
D3	0	0	0	0
D4	0	0	67	41,88
D5	61	38,13	23	14,38
D6	1	0,63	149	93,13
D7	0	0	24	15,00
D8	33	20,63	32	20,00
D9	32	20,00	33	20,63
D10	0	0	3	1,88
D11	0	0	24	15,00
D12	0	0	83	51,88
D13	0	0	105	65,63
D14	0	0	16	10,00
D15	0	0	26	16,25
Total	127	5,29	619	25,79


Analisando as Tabelas 7 e 8, é evidente que a fragilidade na detecção de distúrbios se dá para eventos que provocam variações muito rápidas no sinal. Um transitório impulsivo, por exemplo, que possui 1 ms de duração, o que resulta em apenas 15 amostras discretas dentro de uma janela de dados (considerando uma taxa de amostragem de 256 amostras/ciclo). Contudo, a RL se mostrou mais robusta que a DT na detecção. Enquanto a DT não detectou 5,29% dos distúrbios estudados, a RL falhou apenas 1,17%.

Ainda na Tabela 7, constata-se que 40,79% dos distúrbios processados pela RL sofreram fragmentações dentro da região do distúrbio pela presença de falsos negativos. Já para a DT, observa-se que somente 25,79% dos distúrbios sofreram fragmentações (Tabela 8), que representa uma diferença de 15% em favor da DT. Pode-se notar também que a maior concentração destes casos para a RL se deu nos distúrbios (com percentual de fracionamento maior ou igual a 50%): Transitórios Oscilatório (D4), Flutuação de Tensão (D6), Distorção Harmônica (D7), Flutuação de Tensão com Afundamento (D12) e Flutuação de Tensão com Elevação (D13). E para a DT: D4, D12 e D13, ou seja, duas classes a menos que a RL.

Para verificar o comportamento da presença de falsos negativos nos dados testados, ou seja, a distribuição do comprimento/extensão, em unidades, dos aglomerados de falsos negativos presentes em cada classe de distúrbio, foi utilizada uma visualização gráfica dos dados por meio de *Boxplot*. Os resultados para RL e DT podem ser observados nas Figuras 33 e 34, respectivamente.


Os pequenos círculos contidos nas Figuras 33 e 34 representam as aglomerações de classes classificadas como “sem distúrbio” identificadas pelo *Box plot* como verdadeiras ne-

Figura 33 – Regressão Logística: *Boxplot* do comprimento/extensão das regiões com falsos negativos para a base de Teste.



Fonte: Autoria própria.

Figura 34 – Árvore de Decisão: *Boxplot* do comprimento/extensão das regiões com falsos negativos para a base de Teste.



Fonte: Autoria própria.

gativas (sem distúrbio). Por ocorrer de forma mais isolada no sinal, principalmente oriundo da presença de ruído no sinal, as classificações incorretas de classes “com distúrbio” (falso positivo) proporcionam o surgimento de regiões (ou aglomerados) de classes “sem distúrbio” (verdadeiro positivo). Estas regiões, por sua vez, são maiores (ou mais extensas) que as regiões “sem distúrbio” (falso negativo) formadas entre duas parcelas de um distúrbio fracionado. Para o cenário da RL (Figura 33), constata-se que as distâncias consideradas entre duas parcelas fracionadas são muito pequenas, destacando-se as classes D3, D5 e D6 com 17 unidades. Para o cenário da DT (Figura 34), sobressaiu a classe D14 com 802 unidades. Além disso, é interessante

destacar que a altura do corpo retangular do *Boxplot* representa a variação da distância, ou seja, quanto maior a altura, maior a variação da distância. Isso indica que os resultados da DT apresentaram maior variação da distância.

Afim de mitigar a ocorrência de aglomerados de falsos negativos que acabam fracionando em duas ou mais partes a detecção de um único do distúrbio, assumiu-se que, se a distância entre duas janelas classificadas pela RL com a presença de distúrbio (verdadeiro positivo) é menor ou igual a 17 unidades (maior extensão de aglomerados de falsos negativos encontrada, correspondente às classes D3, D5 e D6), todas as janelas nesse intervalo classificadas sem a presença de distúrbio serão substituídas por “com distúrbio” (ou seja, troca-se um *bit* 0 por 1). E, caso a distância entre duas janelas classificadas pela DT com a presença de distúrbio é menor ou igual a 802 unidades (maior extensão de aglomerados de falsos negativos encontrada, correspondente à classe D14), troca-se um *bit* 0 por 1. Os resultados destes processos estão elencados na Tabela 9.

É indubitável, por sua vez, que o tratamento dos dados promoveu melhor desempenho sobre os dados obtidos pela DT. Apenas 0,04% dos dados continuaram fragmentados, contra 6,56% da RL. Outrossim, vale ressaltar que, no final do processo de detecção/segmentação, a RL identificou 1146 trechos de sinais que não continham nenhuma parcela de distúrbio (D0), porém este algoritmo classificou como "com distúrbio". Em contrapartida, a DT identificou erroneamente somente 109 trechos de sinais sem distúrbio, quase 10 vezes menor que os proporcionados pela RL.

Tabela 9 – Extrato da Classificação após o Tratamento dos Dados para a base de Teste.

Distúrbio	RL		DT	
	Quantidade	%	Quantidade	%
D1	0	0	0	0
D2	0	0	0	0
D3	0	0	0	0
D4	3	1,88	0	0
D5	0	0	0	0
D6	84	52,5	0	0
D7	15	9,38	0	0
D8	31	19,38	1	0,63
D9	35	21,88	0	0
D10	0	0	0	0
D11	0	0	0	0
D12	38	23,75	0	0
D13	38	23,75	0	0
D14	0	0	0	0
D15	0	0	0	0
Total	244	6,56	1	0,04

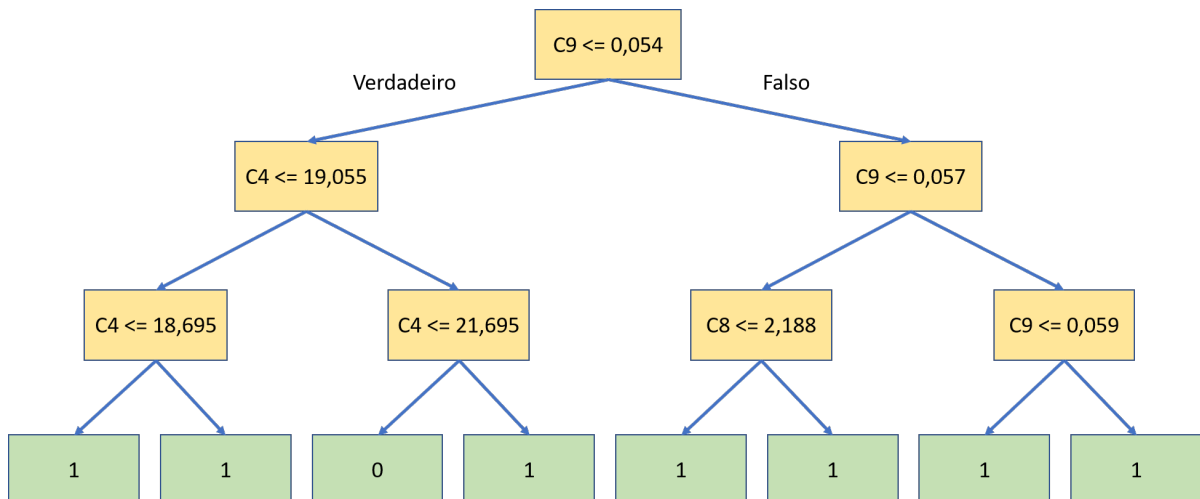
No contexto de comunicação, o volume de informações que trafegarão na rede de dados é um fator muito importante, como já dito anteriormente. Apesar de ter se destacado na maioria

dos resultados encontrados, a RL identificou um elevado número de sinais senoidais puros, que não terão nenhuma aplicação ou importância para a concessionária, e continuou apresentando fragmentações em distúrbios, mesmo após o processo de tratamento dos dados. A DT, no entanto, apresentou resultados melhores, que foram inferiores em relação à RL quanto ao número de detecções de sinais puros e fragmentações após o tratamento dos dados. Aliás, de forma geral, os demais resultados apresentados anteriormente mostram que o desempenho da DT são próximos ao da RL.

Com base nestes aspectos comparativos e levando em consideração que a técnica a ser embarcada deve ir ao encontro da aplicabilidade em um situação real, a DT foi selecionada como o melhor método testado para compor o processo de detecção e segmentação de distúrbios a ser realizado no lado do *edge computing*.

A Figura 35 ilustra o modelo de detecção obtido pela DT. Um ponto que merece destaque é que a DT utilizou apenas 3 *features* para proceder à detecção, enquanto a RL utilizou todas as *features* para o mesmo fim. Isso mostra que intrinsecamente a DT executa um processo de seleção de atributos, filtrando apenas as *features* que terão importância no modelo de detecção. Portanto, este fato mostra que o processo executado pela DT demanda menos esforço computacional no que tange à realização de cálculos matemáticos para a extração de *features* da janela de sinal.

Figura 35 – Estrutura da Árvore de Decisão obtida pelo algoritmo.




Fonte: Autoria própria.

Levando em consideração a melhor técnica selecionada, as Figuras 36 e 37 representam histogramas com um ajuste de distribuição normal dos erros para a estimação do início e do fim dos distúrbios, respectivamente. Nota-se que, em ambas as situações, a maior proporção de amostras apresentam erro muito próximo à média da distribuição gaussiana, ou seja, de 15.


A Tabela 10 resume numericamente algumas informações da distribuição dos erros de estimação. Dentre estas informações, incluem o Desvio Médio, Desvio Padrão e Intervalo de Confiança de 95% do Desvio Padrão. Este intervalo de confiança fornece a informação necessária da variação em torno da média.

Figura 36 – Distribuição do erro para a detecção do início do distúrbio para a base de Teste.



Fonte: Autoria própria.

Figura 37 – Distribuição do erro para a detecção do fim do distúrbio para a base de Teste.



Fonte: Autoria própria.

A fim de garantir que a maioria dos distúrbios detectados contemplem os instantes iniciais e finais do evento de QEE, definiu-se o início da segmentação do distúrbio com 103 amostras discretas prévias à amostra detectada pelo algoritmo, enquanto o final do distúrbio é dado pelas 228 amostras subsequentes à amostra detectada, baseando-se nos Intervalos de Confiança de 95% do Desvio Padrão encontrados anteriormente.

Buscando investigar a capacidade de generalização da DT na detecção/segmentação de eventos de QEE com níveis de ruídos distintos aos utilizados no processo de treinamento do algoritmo, foi utilizada a base de Execução. O desempenho do algoritmo se encontra ilustrado

Tabela 10 – Parâmetros das distribuições dos erros de estimação para a base de Execução.

	Início	Fim
Média	15,04	16,82
Desvio Padrão	99,65	221,81
Intervalo de Confiança (CI 95%)	[96,82; 102,64]	[215,52; 228,48]

na Tabela 13.

Tabela 11 – Resultados de Detecção por meio das métricas $F1_{score}$ e Acurácia para a base de Execução.

Árvore de Decisão (%)	
$F1_{score}$	93,65
Acc	91,62

Tabela 12 – Matriz de Confusão da Detecção utilizando Regressão Logística para a base de Teste.

	Com distúrbio	Sem distúrbio	Total	$F1_{score}$ (%)	Acc (%)
Com distúrbio	1280898	154371	1435269	93,65	89,24
Sem distúrbio	19422	619809	639231	98,46	87,70

Tabela 13 – Extrato dos Resultados de Classificação da Árvore de Decisão para a base de Execução.

Distúrbio	Não detectados		Fracionados	
	Quantidade	%	Quantidade	%
D1	0	0	7	11,66
D2	0	0	5	8,33
D3	0	0	0	0
D4	0	0	20	33,33
D5	33	55,00	10	16,67
D6	0	0	51	85,00
D7	0	0	13	21,67
D8	9	15,00	15	25,00
D9	17	28,33	19	31,67
D10	0	0	3	5,00
D11	0	0	4	6,67
D12	0	0	29	48,33
D13	0	0	41	68,33
D14	0	0	10	16,67
D15	0	0	9	15,00
Total	59	6,56	236	26,22

Após a aplicação da DT, os dados passaram pelo tratamento de mitigação de fracionamento dos distúrbios detectados. Para tanto, foram utilizados os mesmos passos e parâmetros aplicados para a base de Teste, que também usou DT. Como resultado, nenhum distúrbio apresentou fracionamento.

Portanto, comparando os resultados da DT para a base de Teste e para a base de Execução, nota-se a ocorrência de desempenhos similares. A diferença para na detecção de janelas com ou sem distúrbio foi menor que 2,32% para $F1_{score}$ e 1,63% para Acurácia. Deste modo, fica comprovado que a DT possui uma elevada capacidade de generalizar respostas para dados não foram conhecidos na etapa de treinamento.

Junior *et al.* (2021) propuseram a implementação de um sistema de detecção/segmentação de distúrbios de QEE baseado no janelamento do sinal. Contudo, eles não empregaram algoritmos inteligentes para realizar a identificação da ocorrência de distúrbio. A tomada de decisão foi amparada por comparações envolvendo de valores RMS e DHT extraídos da janela a ser analisada com valores de referência. Os autores obtiveram acurácias de 81,33% e 98,03% para janelas com distúrbio e sem distúrbio, respectivamente. É importante destacar que os autores não promoveram nenhuma análise profunda para verificar a quantidade de distúrbios não detectados e se também houve o fracionamento na detecção dos distúrbios pela ocorrência de falso negativos. Ademais, nota-se que o resultado alcançado pelos autores na identificação de janelas com distúrbios foi inferior ao obtido nessa dissertação, levando em consideração a base de dados de execução, que utiliza dados com os mesmos níveis de ruído. Com relação à identificação de janelas sem distúrbios, o método dos autores mostrou-se pouco superior.


5.2 Módulo de Compactação

Este módulo apresenta os resultados obtidos no processo de compactação dos distúrbios detectados no módulo anterior.


Conforme previamente mencionado, os resultados foram analisados em torno da taxa de compressão e da entropia de *Shannon*. Dessa forma, busca-se o melhor *trade-off* entre as métricas, considerando que a entropia do sinal original como referência. Os resultados obtidos para filtros *wavelet* das famílias *Daubechies (db4)* e *Biorthogonal (bior3.1)* com 2 e 4 níveis de decomposição são mostrados nas Figuras de 38 a 41.

Por meio destes resultados é possível notar que o ganho de informação médio aumenta à medida em que o valor da compressão é intensificado. Isso se dá pelo fato de que o incremento do limiar da equação 4.12 proporciona a substituição de muitos valores dos coeficientes da *wavelet* por zero. A linha tracejada em vermelho nestes gráficos representa o valor médio da Entropia de *Shannon* dos dados antes de serem submetidos ao processo de compactação, equivalente à 17,750, ou seja, uma referência ao sinal original. Portanto, quanto mais distante o valor médio da Entropia de *Shannon* estiver da referência, maior será a perda de informação. Contudo, maior é a compressão.

Ao analisar os resultados, ainda notou-se um comportamento dubitável da *bior3.1* com 4 níveis de resolução. Apesar do incremento do limiar, a variação da informação apurada ficou muito próxima à referência em quase todos testes, mesmo com diversos valores dos coeficientes

Figura 38 – Resultado do Filtro *db4* com 2 níveis de decomposição.

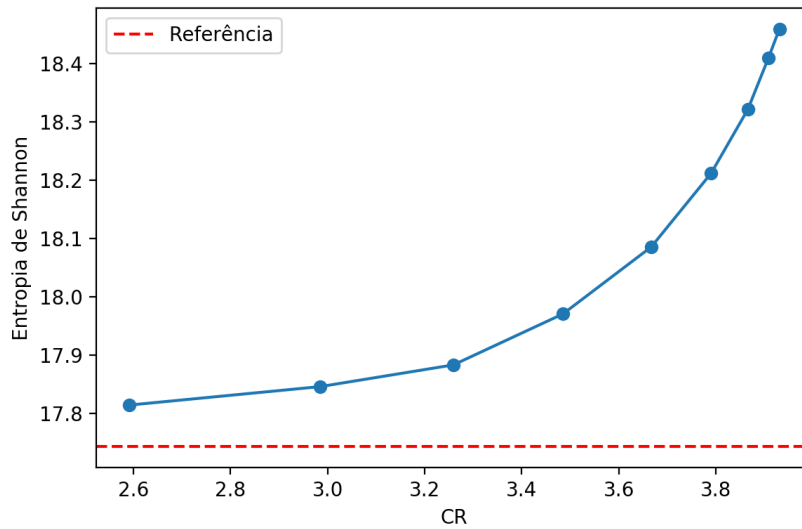
Fonte: Autoria própria.

Figura 39 – Resultado do Filtro *db4* com 4 níveis de decomposição.


Fonte: Autoria própria.

da *wavelet* sendo substituídos por zero. Então, este cenário foi descartado.

As imagens de 42 a 45 ilustram tridimensionalmente o comportamento da compressão à medida que se varia o parâmetro u do limiar da equação 4.12. Constatou-se nestes resultados uma menor variação da quantidade de informação, ou seja, valores muito próximos à referência para os valores do parâmetro u próximo a 1, principalmente no caso do filtro *db4* com 4 níveis de resolução, à uma maior taxa de compressão.

Figura 40 – Resultado do Filtro *bior3.1* com 2 níveis de decomposição.


Fonte: Autoria própria.

Figura 41 – Resultado do Filtro *bior3.1* com 4 níveis de decomposição.


Fonte: Autoria própria.

Levando em consideração todas estas informações extraídas dos resultados de compressão, foi escolhido o filtro *db4* com quatro níveis de resolução. Ele proporciona a menor perda de informação para a maior taxa de compressão ao utilizar $u = 0,8$. Esta configuração resultou em uma compressão média de 4,44 e uma perda de informação média de 0,275 em relação à referência para a base de Teste. Para a base de Execução, a compressão média foi de 3,64 e perda de informação média de 0,263. Isto mostra resultados muito similares para ambas as bases.

As Figuras de 46 a 54 ilustram sinais detectados e segmentados antes e após a aplicação do processo de compactação/descompactação. É possível concluir que o sinal que passou pelo processo de compressão/descompressão se assemelha bastante ao sinal original. É importante

Figura 42 – Resultado do Filtro *db4* com 2 níveis de decomposição em uma perspectiva 3D.

Fonte: Autoria própria.


Figura 43 – Resultado do Filtro *db4* com 4 níveis de decomposição em uma perspectiva 3D.

Fonte: Autoria própria.

destacar ainda que, principalmente, os padrões de comportamento do distúrbio no sinal se mantêm após esse processo, ou seja, a compressão não degrada este padrão.


Vale comentar que, nos trabalhos consultados, os autores que utilizam essa abordagem de compressão fazem o uso de sinais de distúrbios que apresentem um número par de pontos de amostragem. Em sistema real, um distúrbio detectado/segmentado pode conter um número ímpar ou par de pontos. Por questões intrínsecas da WT, um sinal que continha um número de pontos de amostragem ímpar antes da compressão, ganhará um ponto discreto adicional após o processo

Figura 44 – Resultado do Filtro *bior3.1* com 2 níveis de decomposição em uma perspectiva 3D.



Fonte: Autoria própria.


Figura 45 – Resultado do Filtro *bior3.1* com 4 níveis de decomposição em uma perspectiva 3D.



Fonte: Autoria própria.


de descompressão. Esse fato, por sua vez, impossibilita o uso de métricas de erro ponto a ponto e, deste modo, inviabiliza a comparação dos resultados encontrados com a literatura correlata.

Figura 46 – Comparação entre um afundamento de tensão antes (a) e após (b) a compressão/descompactação.



Fonte: Autoria própria.

Figura 47 – Comparação entre uma elevação de tensão antes (a) e após (b) a compressão/descompactação.



Fonte: Autoria própria.


5.3 Módulo de Classificação

Neste módulo serão apresentados os resultados referentes ao processo de classificação dos distúrbios de QEE. Primeiramente serão apresentados os resultados das transformações dos distúrbios em RPs; na sequência os resultados para as transformações GASFs e GADFs. E, por fim, serão expressos os resultados da classificação dos distúrbios utilizando as imagens 2D obtidas e algoritmos do tipo CNN.

5.3.1 Resultados da transformação RP


Como visto anteriormente, a técnica RP possui 3 parâmetros que precisam ser ajustados para representar um sinal temporal. Dentre as combinações realizadas, a parametrização que melhor conseguiu expressar visualmente a existência de padrões que caracterizem a presença de cada uma das classes de distúrbios consideradas foi: dimensão de imersão igual a 2; atraso de

Figura 48 – Comparação entre uma interrupção de tensão antes (a) e após (b) a compressão/descompactação.



Fonte: Autoria própria.

Figura 49 – Comparação entre um transitório oscilatório antes (a) e após (b) a compressão/descompactação.




Fonte: Autoria própria.

imersão igual a 8; e raio de vizinhança igual a 0,2. As Figuras de 55 a 70 ilustram as imagens binárias obtidas com esta configuração.

Na Figura 55, por exemplo, correspondente ao sinal senoidal ideal, é possível observar a existência de linhas diagonais contínuas paralelas à diagonal principal do RP. Como não há nenhum tipo de perturbação nesta amostra de sinal, percebe-se que este padrão de imagem implica na representação de um sistema periódico estacionário, ou seja, a figura é homogênea ao longo de sua composição.


As Figuras de 56 a 58, por sua vez, ilustram o comportamento dos RPs quando da ocorrência de um afundamento, uma interrupção e uma elevação de tensão, ou seja, variações de tensão de curta duração. Como pode ser visto, na Figura 56, o distúrbio aparece distribuído no centro da janela temporal de dados. A mesma relação fica evidente em sua representação no RP. Ainda, é possível notar a existência de três regiões dentro da imagem binária, correlacionadas

Figura 50 – Comparação entre um transitório impulsivo antes (a) e após (b) a compressão/descompactação.



Fonte: Autoria própria.

Figura 51 – Comparação entre uma flutuação de tensão antes (a) e após (b) a compressão/descompactação.




Fonte: Autoria própria.

ao sinal no tempo. A região (A) indica a parcela do sinal anterior à ocorrência do distúrbio, a região (B) é a parcela com afundamento de tensão e a última região (C) representa a parcela pós ocorrência do distúrbio. A transição de uma parcela periódica para outra também periódica, porém diferente, é destacada pelas interrupções das linhas diagonais paralelas à diagonal principal. Entretanto, é importante mencionar que dentro de cada região (A, B e C), as linhas são contínuas, implicando na periodicidade do sinal dentro destas parcelas temporais.


Para os casos de elevação e interrupção de tensão, também fica evidente a transição da operação normal do sistema para a ocorrência do distúrbio, considerando que há uma descontinuidade das diagonais e formação das mesmas três regiões, conforme mostrado nas Figuras 57 e 58. Vale destacar que à medida que a amplitude do sinal do distúrbio em relação ao valor nominal diminui, uma aglomeração de linhas verticais e horizontais surge na região do distúrbio no RP. Por meio desta observação, constata-se que a tendência da invariância de um sinal acarreta no surgimento de uma concentração de linhas, constituindo uma região densa de *pixels* pretos. Entretanto, o oposto ocorre na elevação do sinal, a variação aumenta e menos densa a região se

Figura 52 – Comparação entre uma distorção harmônica antes (a) e após (b) a compressão/descompactação.



Fonte: Autoria própria.

Figura 53 – Comparação entre um *notching* antes (a) e após (b) a compressão/descompactação.



Fonte: Autoria própria.


torna.

No caso do transitório oscilatório, é possível constatar a formação de um RP diferente dos anteriormente apresentados (Figura 59). Devido a alta variação dos valores de tensão, a descontinuidade das diagonais é tão grande que é possível ver apenas *pixels* pulverizados onde seriam as diagonais de um sistema senoidal ideal. À medida em que a variação do distúrbio diminui ao longo do tempo, a densidade da pulverização aumenta, originando em um efeito degradê na imagem. É importante registrar que este efeito também atinge a região de transição.

No transitório impulsivo, a ocorrência do distúrbio, por ser rápida (em torno de 1 ms), a fronteira de transição no RP é mais estreita, pois o comprimento da descontinuidade é pequeno, conforme mostrado na Figura 60. Isto comprova que o comprimento da descontinuidade da fronteira de transição entre o sinal senoidal ideal e a ocorrência do distúrbio, é proporcional ao tempo de ocorrência do mesmo.


Comparando-se aos casos discutidos, o RP do sinal com flutuação de tensão foi o mais

Figura 54 – Comparação entre um *spike* antes (a) e após (b) a compressão/descompactação.



Fonte: Autoria própria.

Figura 55 – Representação de sinal puro de tensão em (a) RP e (b) domínio do tempo.



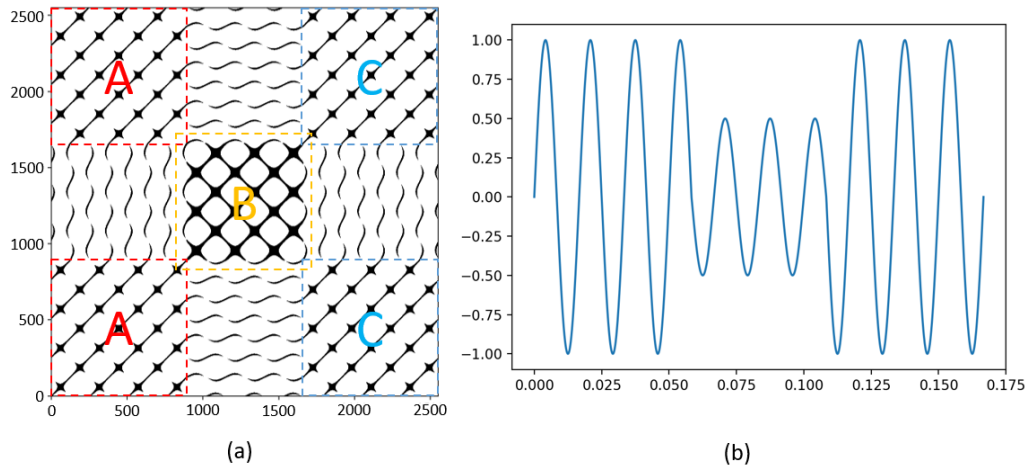
Fonte: Autoria própria.

sutil de todos, conforme mostrado na Figura 61. Sua imagem também é constituída por linhas diagonais paralelas à diagonal principal e muito similar à representação do RP obtido para um sinal senoidal ideal. Entretanto, na região em que ocorreu o distúrbio, localizada também na parte central da imagem, é possível notar a presença de descontinuidades nas linhas diagonais, apesar de discretas.

O sinal com distorção harmônica mostra um comportamento peculiar no RP (Figura 62). É possível identificar o surgimento de pequenos aglomerados sobre as diagonais principais na região do distúrbio, além do surgimento de aglomerados perpendiculares à diagonal principal. A presença destes aglomerados se dá tanto na região do distúrbio quanto na região de transição.

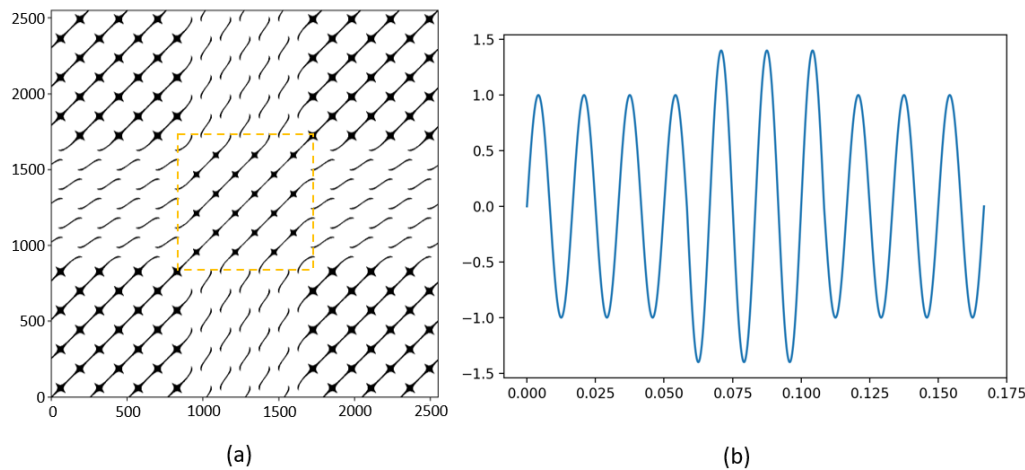
Os RPs obtidos das amostras com distúrbios da classe *notching* e *spike* (Figuras 63 e 64) também são muito similares ao sinal senoidal ideal. Em ambas as amostras, é possível identificar minúsculas descontinuidades nas linhas diagonais na região do distúrbio e o surgimento de pequenos aglomerados de *pixels* pretos perpendiculares à diagonal principal. Estes aglomerados

Figura 56 – Representação de afundamento de tensão em (a) RP e (b) domínio do tempo.



Fonte: Autoria própria.

Figura 57 – Representação de elevação de tensão em (a) RP e (b) domínio do tempo.

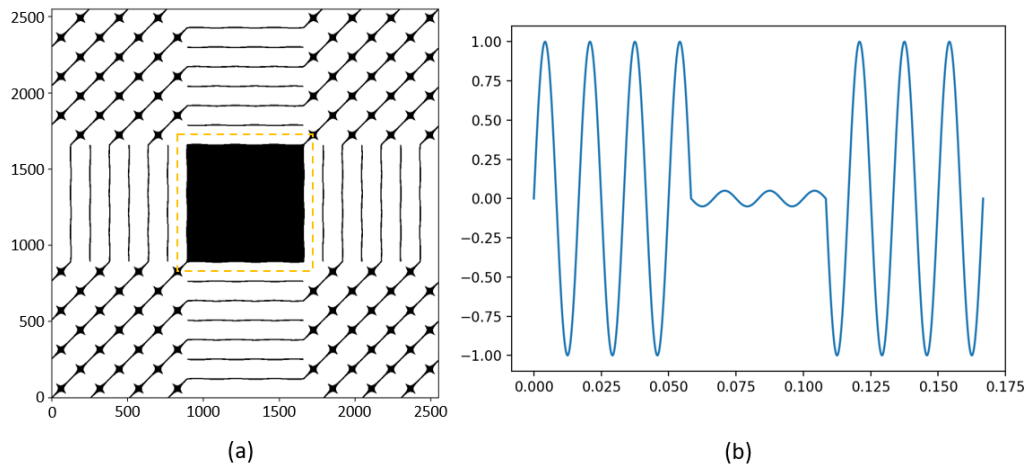


Fonte: Autoria própria.

estão presentes tanto na região do distúrbio quanto na região entre a operação normal do sistema e a ocorrência do distúrbio. A principal diferença entre o RP do *notching* e do *spike* está sutilmente na forma em que os aglomerados perpendiculares à diagonal principal se localizam espacialmente. Estes aglomerados gerados pelo *spike* ficam mais próximos às diagonais do RP, enquanto no *notching* eles ficam posicionados quase no meio, entre duas diagonais.

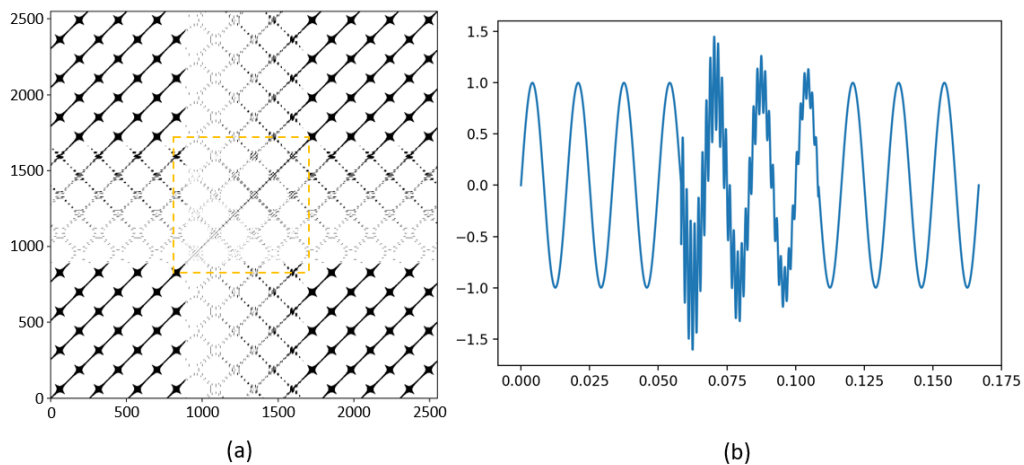
Em relação aos distúrbios combinados, como era de se esperar, eles herdam em alguns casos as características dos RPs obtidos para os distúrbios isolados. No caso do afundamento de tensão com distorção harmônica (Figura 65), nota-se uma maior densidade de *pixels* pretos na região do distúrbio e descontinuidades nas diagonais paralelas à diagonal principal. Além disso, as curvas geradas nas regiões de transição possuem pequenas descontinuidades. A elevação de tensão com distorção harmônica (Figura 66) proporciona um RP com uma menor densidade de *pixels* na região do distúrbio e a formação de oscilações com descontinuidade mais intensa do

Figura 58 – Representação de interrupção de tensão em (a) RP e (b) domínio do tempo.



Fonte: Autoria própria.

Figura 59 – Representação de transitório oscilatório em (a) RP e (b) domínio do tempo.



Fonte: Autoria própria.


que ocorre no RP da elevação de tensão isolada.

Os RPs obtidos para a flutuação de tensão com afundamento e flutuação de tensão com elevação geram padrões peculiares (Figuras 67 e 68). Eles apresentam as características de descontinuidade proporcionadas pela flutuação de tensão e a variação da densidade de *pixels* pretos oriundos do afundamento/elevação, ambos na região no distúrbio.

Por fim, o afundamento de tensão com transitório oscilatório e a elevação de tensão com transitório oscilatório resultam em RPs de fácil interpretação, conforme apresentado por meio das Figuras 69 e 70. Em ambos os casos, nota-se o efeito de esmaecimento do degradê sobre o padrão do afundamento/elevação de tensão.

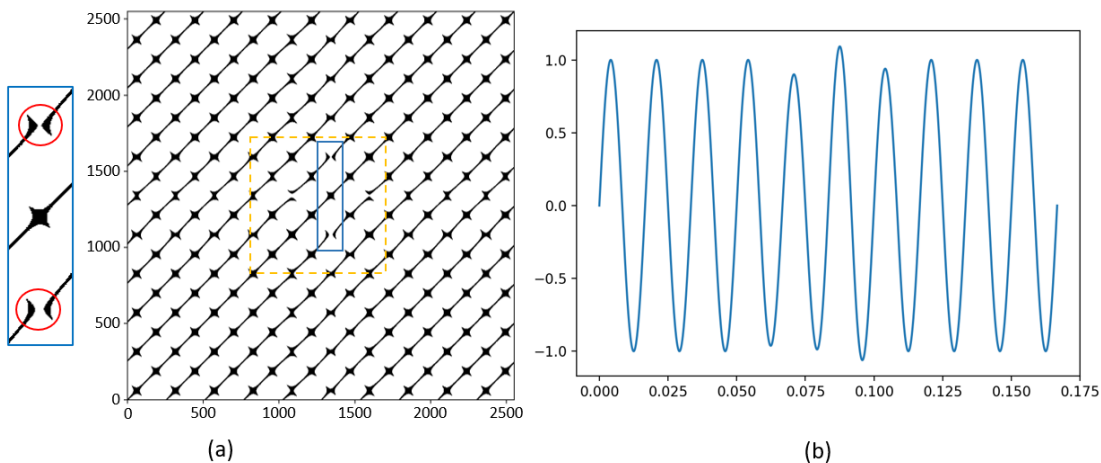
Portanto, conclui-se que é possível utilizar a técnica baseada em RP para analisar visualmente e extrair conhecimento referente à ocorrência e à categoria dos distúrbios de QEE. Em síntese, notou-se os seguintes comportamentos nas imagens binárias:

Figura 60 – Representação de transitório impulsivo em (a) RP e (b) domínio do tempo.



Fonte: Autoria própria.

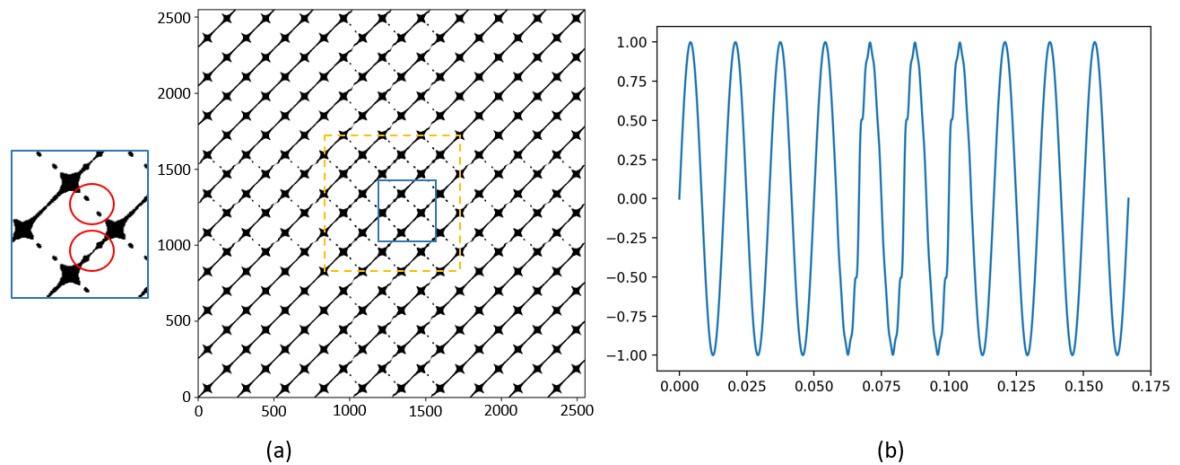
Figura 61 – Representação de flutuação de tensão em (a) RP e (b) domínio do tempo.



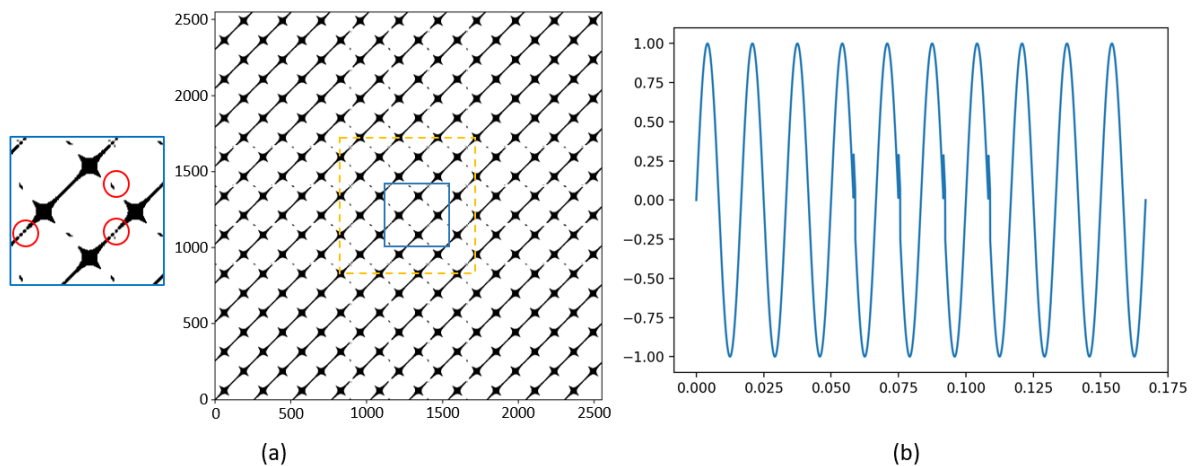
Fonte: Autoria própria.

- sinais periódicos formam linhas diagonais contínuas paralelas;
- a ocorrência de transições de padrões de sinal são demarcados por regiões com descon-tinuidade de linhas diagonais;
- amplitudes do sinal acima do valor nominal provocam a diminuição da densidade de *pixels* pretos na região do distúrbio;
- amplitudes do sinal abaixo do valor nominal contribuem para o aumento da densidade de *pixels* pretos na região do distúrbio;
- transitórios oscilatórios proporcionam a formação de uma região de distúrbio com descontinuidade das linhas diagonais, porém com densidade crescente à medida que a intensidade do transitório reduz (efeito de degradê na imagem);

Figura 62 – Representação de distorção harmônica em (a) RP e (b) domínio do tempo.




Fonte: Autoria própria.

Figura 63 – Representação de *notching* em (a) RP e (b) domínio do tempo.

Fonte: Autoria própria.

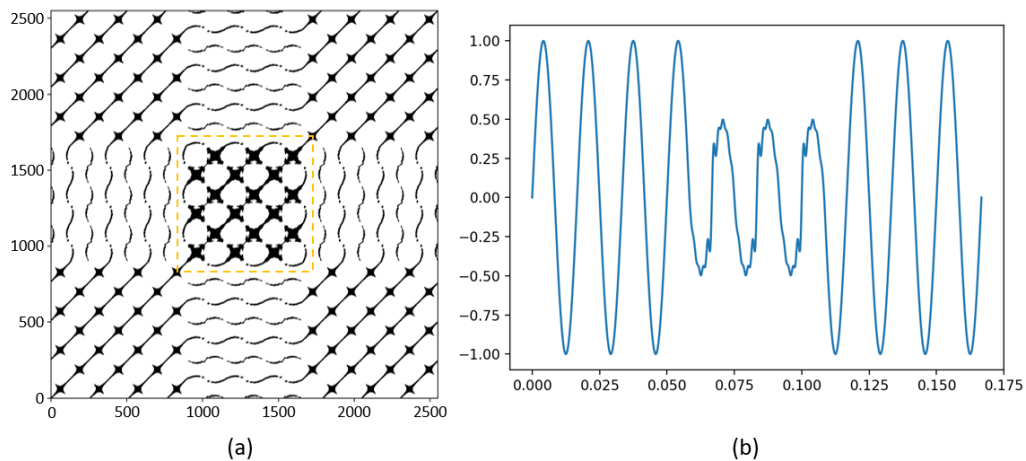
- transitórios impulsivos e flutuações de tensão provocam pequenas descontinuidades dentro da região de distúrbio. Entretanto, as regiões de transição de padrões no sinal são menores. A dimensão desta região é proporcional ao tamanho da área do distúrbio na imagem;
- distorções harmônicas provocam o surgimento de diagonais descontínuas (pequenos *pixels* isolados) perpendiculares às diagonais que representam o sinal senoidal em seu valor nominal;
- os padrões gerados por *notching* e *spike* são muito similares, pois geram minúsculas descontinuidades nas diagonais principais e nota-se ainda o surgimento de pequenos aglomerados de *pixels* perpendiculares a estas diagonais, similar ao que ocorre com as distorções harmônicas;
- por fim, a ocorrência de distúrbios combinados implicam também na combinação

Figura 64 – Representação de *spike* em (a) RP e (b) domínio do tempo.



Fonte: Autoria própria.

Figura 65 – Representação de afundamento de tensão com distorção harmônica em (a) RP e (b) domínio do tempo.



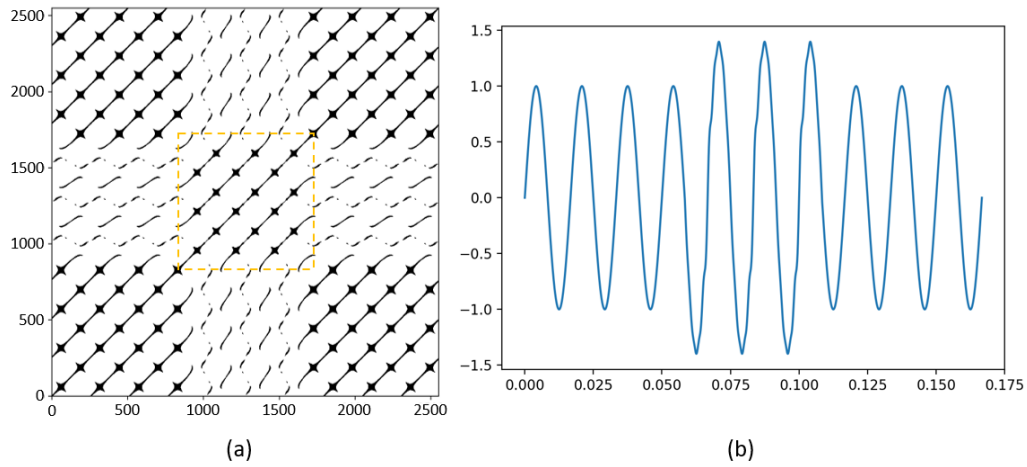
Fonte: Autoria própria.

de algumas peculiaridades dos distúrbios simples (isolados) que compõe o distúrbio. Contudo, nos distúrbios combinados que possuem distorção harmônica, apesar de gerarem padrões peculiares de imagem, não é possível constatar familiaridades que retomem ao padrão de imagem gerado por uma distorção harmônica isolada.

5.3.2 Resultados das transformações GASFs e GADFs

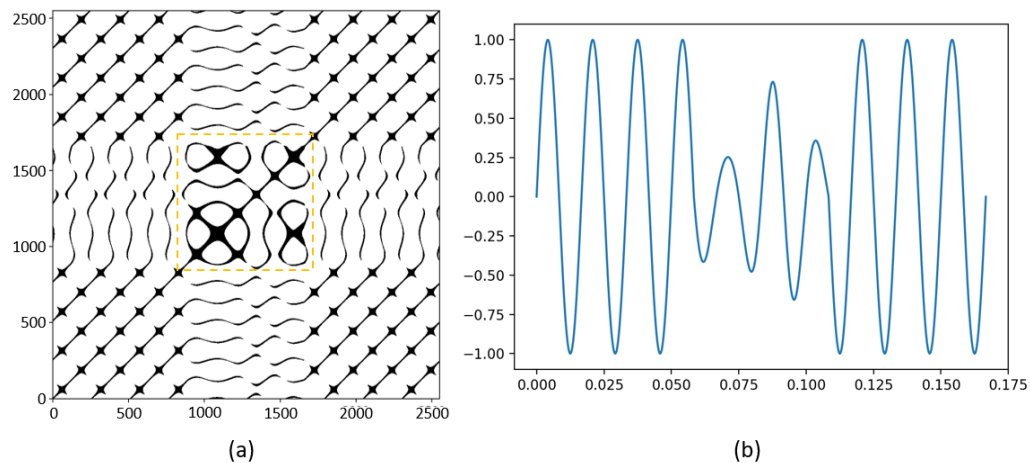
Nesta subseção serão apresentados os resultados das transformações GASF e GADF para um sinal senoidal ideal (Figura 71) e para as 15 classes de distúrbio consideradas neste trabalho (Figuras 72 a 85). É importante citar que as mesmas amostras de sinais temporais analisadas na subseção anterior também foram utilizadas para gerar as imagens GASF e GADF desta subseção.

Figura 66 – Representação de elevação de tensão com distorção harmônica em (a) RP e (b) domínio do tempo.



Fonte: Autoria própria.

Figura 67 – Representação de flutuação de tensão com afundamento em (a) RP e (b) domínio do tempo.

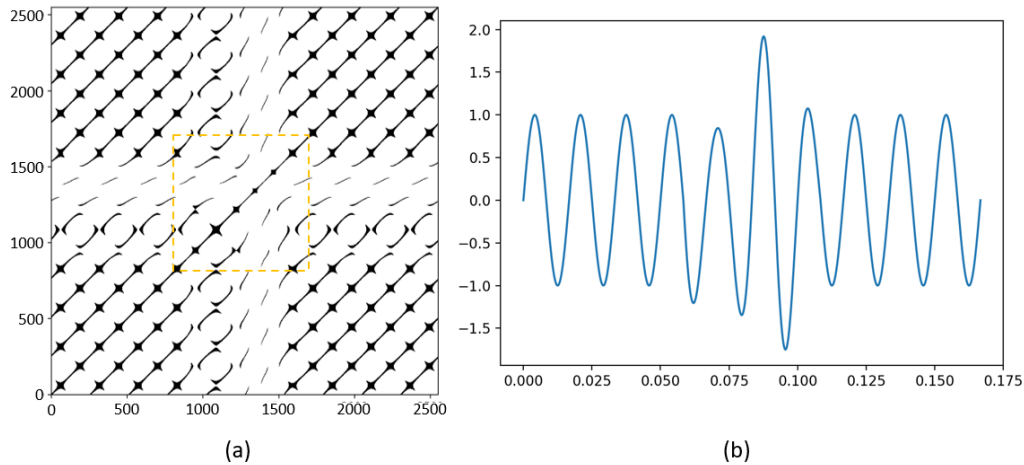


Fonte: Autoria própria.

Diferentemente do que ocorre no RP, as imagens GASF e GADF possuem uma escala de cor que varia entre os tons azul escuro e vermelho escuro. Quanto mais próximo o valor de um pixel de 1,0, mais avermelhado ele será; quanto mais próximo de -1,0, mais azulado ele será. A Figura 71 representa os resultados das transformações GASF e GADF de um sinal senoidal puro.

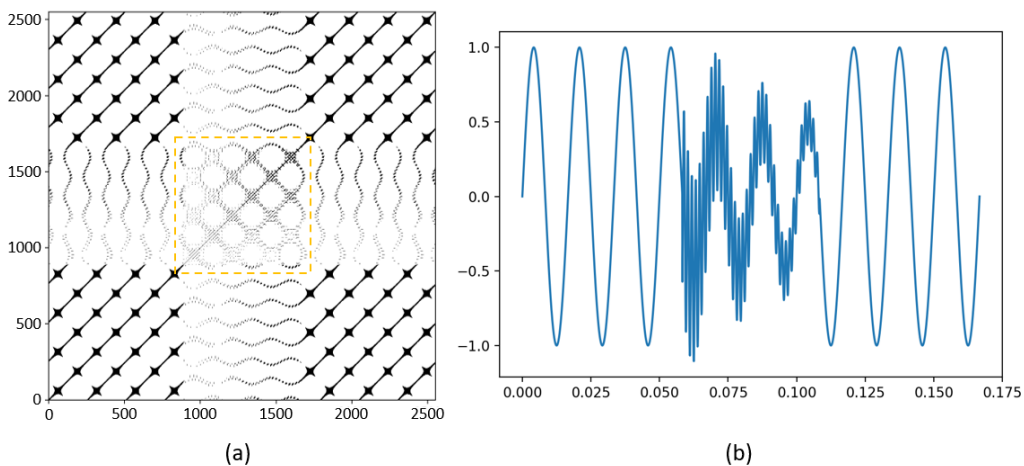
A Figura 72 representa a transformação de um sinal temporal de afundamento de tensão em GASF (a) e GADF (b). Para ambas transformações 2D, ocorre a formação de regiões com padrões visuais de pigmentação diferentes. As regiões (A) possuem um padrão de imagem similar ao que ocorre para um sinal senoidal puro. Na região (B) do GASF ocorre um aumento da concentração de *pixels* em tons azulados e o desaparecimento de *pixels* em tons avermelhados. Para região (B) GADF ocorre a intensificação da presença de *pixels* esverdeados. E nas regiões (C) das duas transformações 2D se nota a formação de ondulações coloridas.

Figura 68 – Representação de flutuação de tensão com elevação em (a) RP e (b) domínio do tempo.



Fonte: Autoria própria.

Figura 69 – Representação de afundamento de tensão com transitório oscilatório em (a) RP e (b) domínio do tempo.




Fonte: Autoria própria.

Para o sinal de elevação de tensão (Figura 73), entretanto, observa-se um comportamento divergente ao caso anterior. As regiões (A), que no caso anterior representavam um padrão de imagem característico de um sinal senoidal puro, ilustram um padrão de imagem sem vestígios de *pixels* em tons avermelhados. O padrão de imagem característico de um sinal senoidal puro aparece na região (B) de ambas representações 2D, porém com um certo grau de “desfoque”. Ademais, é importante relatar que o padrão de imagem para as regiões (C) das transformações GASF (a) e GADF (b) são distintas das observadas para o caso de afundamento de tensão (Figura 72).


As transformações GASF e GADF para a interrupção de tensão geram imagens semelhantes ao caso de afundamento de tensão. Para a Figura 74 (a), uma das diferenças está que na região central da imagem há a predominância massiva de um tom de pixel azul escuro; e

Figura 70 – Representação de elevação de tensão com transitório oscilatório em (a) RP e (b) domínio do tempo.



Fonte: Autoria própria.

Figura 71 – Representação de sinal senoidal puro em (a) GASF e (b) GADF.




Fonte: Autoria própria.

outra é que presença de faixas retilíneas nas regiões (C) e a ausência de tons avermelhados nessa região. Já para a Figura 74 (b), tem-se a presença massiva de um tom de verde na região central da imagem e faixas coloridas mais retilíneas nas regiões (C).

O transitório oscilatório promove a formação de um GASF (Figura 75 (a)) com uma redução drástica dos *pixels* em tons próximos ao vermelho ao longo de toda imagem. Nota-se ainda a aparição de sutis faixas paralelas verticais e horizontais que se cruzam na imagem. Para o GADF (Figura 75 (b)) do transitório oscilatório, observa-se um aumento da quantidade de *pixels* em tons esverdeados. Além disso, assim como no GASF, verifica-se a existência de faixas sutis verticais e horizontais no resultado da transformação GADF.


A Figura 76 ilustra as transformações GASF e GADF para um transitório impulsivo. As diferenças destas transformações 2D para os da Figura 71 são muito sutis. Tanto para o GASF e GADF, há a formação de uma linha vertical e horizontal que se encontram em um determinado ponto. Observa-se ainda o desaparecimento de alguns losangos avermelhados

Figura 72 – Representação de afundamento de tensão em (a) GASF e (b) GADF.



Fonte: Autoria própria.

Figura 73 – Representação de elevação de tensão em (a) GASF e (b) GADF.



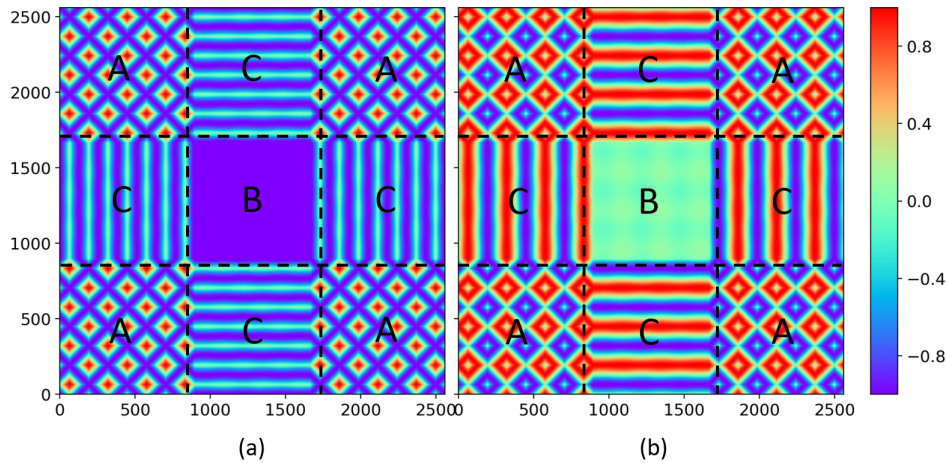
Fonte: Autoria própria.

na imagem do GASF. E, no caso do GADF, as linhas diagonais esverdeadas sofrem um leve aumento de espessura e os pequenos pontos esverdeados, que se encontram dentro dos losangos avermelhados e azulados, quase desaparecem.

Para a flutuação de tensão, os formatos dos aglomerados em tons próximos ao vermelho, na imagem do GASF (Figura 77 (a)), não são tão regulares quanto aos que aparecem em um GASF de um sinal senoidal puro. Além disso, os aglomerados avermelhados dentro da faixas destacadas da imagem possuem maior dimensão. Já para o GADF (Figura 77 (b)), nota-se o desaparecimento de aglomerados de *pixels* em tons próximos ao verde dentro dos losangos azulados e avermelhados, bem como o surgimento de linhas sutis nas direções verticais e horizontais (que estão contida dentro das região em formato de cruz destacada da imagem).


O resultado das transformações GASF e GADF para os distúrbios distorção harmônica, *notching* e *spike* estão dispostos nas Figura 78 a 80. Como pode ser observado, os resultados encontrados são altamente semelhantes aos resultados para um sinal senoidal puro, muito diferente do ocorrido para os distúrbios discutidos anteriormente, em que as alterações de

Figura 74 – Representação de interrupção de tensão em (a) GASF e (b) GADF.



Fonte: Autoria própria.

Figura 75 – Representação de transitório oscilatório em (a) GASF e (b) GADF.




Fonte: Autoria própria.

padrões nas imagens 2D são mais evidentes em uma escala macroscópica.

A combinação dos eventos de QEE afundamento de tensão e distorção harmônica proporcionam a formação de imagens 2D (Figura 81) análogas ao caso de afundamento de tensão ocorrendo de forma isolada (sem combinação). As diferenças estão mais marcantes nas regiões (C) e região central da imagem. Visualmente aparenta a ocorrência de uma “perda de resolução” na imagem GASF especificamente nestas regiões. E na transformação GADF a diferença mais marcante está no aparecimento de linhas horizontais e verticais muito finas nas regiões (C) e na região central da imagem. Já quando ocorre a combinação de uma elevação de tensão com distorção harmônica (Figura 82) não se nota diferenças macroscópicas muito perceptíveis quando comparado as imagens GASF quanto GADF correspondentes a um sinal de elevação de tensão não combinado. Há pequenas alterações em alguns grupos de *pixels* dentro da região (B).


A transformação GASF para o distúrbio que combina a flutuação de tensão com afundamento, por exemplo, gera uma imagem que se aproxima também muito do resultado de transformação GASF para um distúrbio simples de afundamento de tensão (Figura 83 (a)). As

Figura 76 – Representação de transitório impulsivo em (a) GASF e (b) GADF.



Fonte: Autoria própria.

Figura 77 – Representação de flutuação de tensão em (a) GASF e (b) GADF.




Fonte: Autoria própria.


maiores diferenças estão dispostas na região central da imagem e nas regiões (C). Na região central do imagem do distúrbio combinado aparece alguns aglomerados de *pixels* em tons mais claros, próximos a cor verde; e alguns aglomerados de *pixels* avermelhados ampliaram de tamanho e outros quase desapareceram nas regiões (C). E para a transformação GADF (Figura 83 (b)), nota-se também uma semelhança entre o GADF para um afundamento de tensão isolado. As principais diferenças estão no comportamento da distribuição espacial das cores dos pixels na região central da imagem e no padrão de apresentação das ondas coloridas formadas nas regiões (C).

Os padrões de imagem GASF e GADF para flutuação de tensão com elevação (Figura 84) diferem bastante dos padrões de imagens proporcionados por estes eventos de QEE ocorrendo de forma não combinada. Há a formação de quatro grandes áreas (A) em tons azulados e macroscopicamente não se constata tons avermelhados dentro delas. Ocorre ainda o aparecimento de duas faixas horizontais e duas verticais em tons mais claros e dentro destas faixas há pequenos aglomerados de *pixels* em tons avermelhados. Já para o GADF, observa-se também o surgimento

Figura 78 – Representação de distorção harmônica em (a) GASF e (b) GADF.



Fonte: Autoria própria.


Figura 79 – Representação de *notching* em (a) GASF e (b) GADF.

Fonte: Autoria própria.

de quatro grandes regiões (A) de padrões de imagem semelhantes entre si e o surgimento de duas faixas horizontais e duas faixas verticais.


Para a combinação do afundamento de tensão com transitório oscilatório, verifica-se que o resultado da transformação GASF (Figura 85 (a)) é semelhante ao resultado da transformação GASF para um distúrbio simples de afundamento de tensão com a junção de linhas sutis verticais e horizontais, que são características da transformação GASF para um transitório oscilatório. O mesmo comportamento ocorre para a transformação GADF (Figura 85 (b)).

Por fim, tem-se as transformações GASF e GADF para o distúrbio combinado elevação de tensão com transitório oscilatório, que estão representados na Figura 86. Os resultados encontrados se aproximam aos resultados das transformações para um distúrbio simples de transitório oscilatório. Para o GASF do distúrbio combinado ocorre a presença de *pixels* mais claros reunidos em pequenos aglomerados ao longo da imagem. E para o GADF, percebe-se a presença de linhas mais espessas em tons esverdeados ao longo da imagem do que há na imagem

Figura 80 – Representação de *spike* em (a) GASF e (b) GADF.

Fonte: Autoria própria.

Figura 81 – Representação de afundamento de tensão com distorção harmônica em (a) GASF e (b) GADF.




Fonte: Autoria própria.

do GADF para um distúrbio simples de transitório oscilatório.

Deste modo, conclui-se que, assim como a técnica RP, as técnicas baseadas em GASF e GADF também permitiram representar graficamente os distúrbios de QEE. Algumas classes de distúrbios, como afundamento de tensão, elevação de tensão, interrupção de tensão e transitório oscilatório, por exemplo, constatou-se padrões mais expressivos nas imagens, que facilitam visualmente os seus reconhecimentos. Entretanto, distorções harmônicas, *notching* e *spike*, por exemplo, apresentam padrões 2D que são muito similares entre si e também entre os padrões 2D para um sinal senoidal puro, o que torna dificultosa a identificação visual da classe de distúrbio envolvida no dado analisado. E para os distúrbios combinados, ocorre, em alguns casos, a combinação de peculiaridades nas imagens 2D características de cada evento envolvido ocorrendo de forma isolada (sem combinação), como acontece no afundamento de tensão com transitório oscilatório e elevação de tensão com transitório oscilatório.


Ademais, é importante registrar que o processo de análise visual das imagens obtidas nas transformações GASF e GADF é mais complexo do que para o RP, uma vez que nas

Figura 82 – Representação de elevação de tensão com distorção harmônica em (a) GASF e (b) GADF.



Fonte: Autoria própria.

Figura 83 – Representação de flutuação de tensão com afundamento em (a) GASF e (b) GADF.



Fonte: Autoria própria.


transformações GASF e GADF há um aumento da variedade de cores disponíveis para integrar as imagens 2D resultantes.

5.3.3 Resultados da classificação dos distúrbios

Os resultados de classificação obtidos na metodologia proposta serão apresentados nesta subseção. Para tanto, foram testados os modelos de CNN convencional (não pré-treinada) e VGG-16 (pré-treinada), para a identificação de dezesseis padrões de sinais de QEE.


Devido a falhas intrínsecas do processo de detecção/segmentação, os dados chegam de forma desbalanceada ao módulo de classificação, ou seja, com o número diferente de amostras de distúrbios por classe considerada. Constata-se na literatura correlata que muitos autores que utilizaram CNN como, Wang, Xu e Che (2019), Wang e Chen (2019), Cai *et al.* (2019b), Sindi *et al.* (2021), realizaram a avaliação das metodologias propostas por meio de bases de dados balanceadas. Outrossim, estes autores utilizam a métrica acurácia para a avaliação dos resultados,

Figura 84 – Representação de flutuação de tensão com elevação em (a) GASF e (b) GADF.



Fonte: Autoria própria.

Figura 85 – Representação de afundamento de tensão com transitório oscilatório em (a) GASF e (b) GADF.




Fonte: Autoria própria.

que é mais eficaz quando os dados estão balanceados.

Deste modo, a fim possibilitar a comparação dos resultados desta metodologia com os trabalhos da literatura, foi realizado o balanceamento da base de testes e da base de dados de execução para fins de classificação. É importante reforçar que, as amostras incluídas nestas bases no processo de balanceamento, também foram processadas pelos módulos de detecção/segmentação e compactação. A base de dados de treinamento não foi balanceada, a fim explorar a capacidade de classificação dos algoritmos verificados nesta metodologia. E a métrica $F1_{Score}$ foi utilizada como uma ferramenta complementar.

Ademais, as imagens RP, GASF e GADF foram redimensionadas para 96x96, correspondente a menor imagem obtida nos processos de transformações, utilizando a função *resize()* da biblioteca *OpenCV* do *Python*, e então disponibilizadas aos classificadores. A Tabela 14 mostra um resumo dos resultados encontrados para a base de teste, na qual se destaca os melhores resultados por distúrbio. Os valores destacados em amarelo na Tabela 14 representam os melhores resultados alçados pelo classificador de cada tipo de padrão de sinal (D0-D15), levando

Figura 86 – Representação de elevação de tensão com transitório oscilatório em (a) GASF e (b) GADF.



Fonte: Autoria própria.

em consideração a métrica Acurácia. Informações mais detalhadas destes resultados podem ser consultadas nas Tabelas 21 a 26, contidas no Apêndice A.

Tabela 14 – Resumo dos resultados de teste.

Distúrbio	CNN-RP		VGG16-RP		CNN-GASF		VGG16-GASF		CNN-GADF		VGG16-GADF	
	Acc (%)	$F1_{Score}$ (%)	Acc (%)	$F1_{Score}$ (%)	Acc (%)	$F1_{Score}$ (%)	Acc (%)	$F1_{Score}$ (%)	Acc (%)	$F1_{Score}$ (%)	Acc (%)	$F1_{Score}$ (%)
D0	92,86	92,04	93,21	92,39	87,86	88,97	86,79	88,85	86,07	86,85	96,07	93,73
D1	94,64	90,91	89,29	90,91	91,07	91,23	91,43	91,10	91,07	91,40	92,86	94,55
D2	88,93	88,45	93,93	91,96	82,50	88,85	84,29	86,29	82,14	89,67	82,86	87,55
D3	100,00	98,07	99,64	98,59	100,00	98,07	99,64	99,47	97,86	98,21	100,00	100,00
D4	92,14	94,33	93,93	96,16	95,00	93,50	91,43	93,60	92,50	94,35	92,14	94,33
D5	87,50	88,45	87,86	87,54	88,93	87,99	81,79	83,12	81,79	83,42	86,43	90,47
D6	85,71	83,92	90,36	87,39	93,93	91,96	95,71	92,57	87,14	87,61	92,86	93,69
D7	96,79	95,76	97,50	96,30	98,57	98,40	97,50	98,20	99,64	99,29	96,07	96,76
D8	86,07	84,86	80,71	77,40	91,07	86,29	86,43	78,96	85,00	79,47	82,86	74,36
D9	81,79	82,37	69,29	75,05	80,36	86,71	76,79	78,90	77,86	77,58	70,36	73,10
D10	99,29	99,64	98,93	98,75	99,64	99,82	97,50	98,56	100,00	100,00	98,93	99,28
D11	99,64	99,11	97,14	97,84	100,00	99,82	97,50	97,67	100,00	99,47	98,93	98,75
D12	95,36	94,51	95,36	90,66	93,57	90,03	89,64	84,23	96,07	90,73	95,00	85,53
D13	96,79	96,10	94,64	93,15	99,29	99,11	94,29	96,00	100,00	99,29	97,50	95,79
D14	86,79	91,70	86,79	90,00	78,21	83,59	69,64	75,44	80,71	86,26	71,79	78,98
D15	83,21	87,10	86,79	90,67	93,93	88,85	85,36	82,99	95,36	89,90	86,79	85,26
Média	91,72	91,71	90,96	90,92	92,12	92,07	89,11	89,12	90,83	90,84	90,09	90,13

Analisando a Tabela 14, nota-se que a configuração CNN-GASF possibilitou o melhor desempenho de classificação, apresentado uma Acurácia e $F1_{Score}$ médios acima de 92%. O pior desempenho foi demonstrado pela configuração VGG16-GASF, inferior a média de 89,2% em Acurácia e $F1_{Score}$. Contudo, a diferença entre o melhor e o pior desempenho foi muito pequena, próximo a 3%. Sobretudo, investigando o desempenho individual de cada classificador de cada configuração, constata-se que algumas configurações proporcionam uma melhor resposta de identificação do que outras.

Visando criar um *ensemble* de classificadores que maximizem o resultado final de

identificação de padrões de sinais de QEE, foi selecionada para cada padrão de sinal, com base nos resultados de Acurácia apresentados anteriormente, a configuração (ou método) que melhor desempenhou a função de identificação do padrão (Tabela 15). Nos casos de empate, optou-se pela priorização da configuração que utiliza uma estrutura de CNN mais simples (menos camadas de neurônios); quando o tipo de estrutura das CNNs são equivalentes, foi utilizada a métrica $F1_{Score}$ como critério de desempate.

Foi possível obter com o novo *ensemble*, conforme disposto na tabela Tabela 15, uma Acurácia média de 94,13% e $F1_{Score}$ médio de 94,11%. Isto representa uma diferença de aproximadamente 2% superior aos resultados no caso em que se utilizou apenas classificadores de configuração VGG16-GASF para todas as classes de sinais. E o novo *ensemble* formado contém 31,25% de classificadores de configuração CNN-GADF, 31,25% de CNN-GASF, 18,75% de CNN-RP, 6,25% de VGG16-GADF, 6,25% de VGG16-RP e 6,25% de VGG16-GASF. Além disso, 75% das entradas dos classificadores utilizaram imagens do tipo GASF ou GADF, enquanto apenas 25% utilizaram imagens do tipo RP; e ainda nota-se que 81,25% dos classificadores escolhidos para o modelo final representam CNNs convencionais.

Tabela 15 – Resumo dos resultados para compor o *ensemble* de classificação final referente aos dados de teste.

Distúrbio	Melhor método encontrado	Método escolhido	Acc (%)	$F1_{Score}$
D0	VGG16-GADF	VGG16-GADF	94,29	94,62
D1	CNN-RP	CNN-RP	95,36	93,68
D2	VGG16-RP	VGG16-RP	87,50	91,59
D3	CNN-RP/CNN-GASF/VGG16-GADF	CNN-GASF	100,00	98,77
D4	CNN-GASF	CNN-GASF	96,07	94,55
D5	CNN-GASF	CNN-GASF	90,71	88,66
D6	VGG16-GASF	VGG16-GASF	90,71	93,55
D7	CNN-GADF	CNN-GADF	100,00	99,12
D8	CNN-GASF	CNN-GASF	92,50	86,91
D9	CNN-RP	CNN-RP	79,29	85,22
D10	CNN-GADF	CNN-GADF	100,00	100,00
D11	CNN-GASF/CNN-GADF	CNN-GASF	100,00	100,00
D12	CNN-GADF	CNN-GADF	97,86	96,48
D13	CNN-GADF	CNN-GADF	99,64	99,64
D14	CNN-RP/VGG16-RP	CNN-RP	88,21	92,34
D15	CNN-GADF	CNN-GADF	93,93	90,69
Média			94,13	94,11

Outrossim, observa-se na Tabela 15 que o novo conjunto de classificadores conseguiu identificar 100% dos distúrbios de interrupção de tensão de tensão (D3), distorção harmônica (D7), afundamento de tensão com distorção harmônica (D10) e elevação de tensão com distorção harmônica (D11). Os piores casos de identificação foram para as os distúrbios de elevação de tensão (D2), *spike* (D9) e afundamento de tensão com transitório oscilatório (D14), os quais apresentaram uma Acurácia inferior à 90%. Contudo, a Tabela 16 mostra que, por exemplo, o classificador destinado à identificação do distúrbio D2 julgou erroneamente que 33 amostras

de teste seriam da classe D15, que representa a elevação de tensão com transitório oscilatório. Isto demonstra que o classificador apenas conseguiu identificar nestas amostras somente o comportamento de elevação de tensão presente no sinal. Em relação ao classificador destinado à identificação do distúrbio D9, nota-se que houve uma confusão na distinção entre o tipo de distúrbio *notchin* (D8) e D9, que possuem imagens em RP muito semelhantes. Já para o classificador destinado à identificação do distúrbio D14, houve a confusão envolvendo os distúrbios afundamento de tensão (D1), flutuação de tensão com afundamento (D12) e D14. A parcela de afundamento de tensão presente nas imagens dos sinais propiciou essa falha na identificação correta.

Um outro aspecto que merece destaque na Tabela 16 é a métrica $F1_{Score}$. Enquanto a métrica média observa os acertos (verdadeiros positivos) e erros (falsos negativos) horizontalmente para cada classificador, a métrica $F1_{Score}$ também visualiza verticalmente os erros dos outros classificadores (falsos positivos) para uma determinada classe de sinal de QEE. Um exemplo disso é o classificador destinado à identificação do distúrbio D3. Neste caso foi obtida uma Acurácia de 100%, pois não houve erros horizontalmente para essa classe de sinal; entretanto o $F1_{Score}$ foi menor que 100%. Isto é decorrente do fato que os classificadores D1 e D14 (análise vertical) classificaram erroneamente alguns distúrbios (falsos positivos), indicando que seriam da classe D1.

Tabela 16 – Matriz de confusão para o *ensemble* de classificação final referente aos dados de teste.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	$F1_{Score}$ (%)
D0	264	0	0	0	3	11	1	0	1	0	0	0	0	0	0	0	94,29	94,62
D1	0	267	0	6	0	0	0	1	0	0	0	0	1	0	5	0	95,36	93,68
D2	0	0	245	0	0	0	0	0	1	1	0	0	0	0	0	33	87,50	91,59
D3	0	0	0	280	0	0	0	0	0	0	0	0	0	0	0	0	100,00	98,77
D4	0	0	0	0	269	4	3	0	4	0	0	0	0	0	0	0	96,07	94,55
D5	7	0	0	0	4	254	2	0	8	4	0	0	0	0	0	1	90,71	88,66
D6	2	1	0	0	1	5	254	0	7	9	0	0	0	1	0	0	90,71	93,55
D7	0	0	0	0	0	0	0	280	0	0	0	0	0	0	0	0	100,00	99,12
D8	1	0	0	0	2	10	1	1	259	5	0	0	0	0	0	1	92,50	86,91
D9	4	0	0	0	2	8	2	3	36	222	0	0	1	0	0	2	79,29	85,22
D10	0	0	0	0	0	0	0	0	0	0	280	0	0	0	0	0	100,00	100,00
D11	0	0	0	0	0	0	0	0	0	0	0	280	0	0	0	0	100,00	100,00
D12	0	3	0	0	0	0	0	0	0	0	0	0	274	0	3	0	97,86	96,48
D13	0	0	1	0	0	0	0	0	0	0	0	0	0	279	0	0	99,64	99,64
D14	0	19	0	1	1	0	0	0	0	0	0	0	12	0	247	0	88,21	92,34
D15	0	0	9	0	7	1	0	0	0	0	0	0	0	0	0	263	93,93	90,69

A Tabela 17 mostra um resumo dos resultados do *ensemble* em uma outra perspectiva, que leva em consideração o desempenho do classificador em relação ao nível de ruído contido no padrão de sinal. Com base nestes resultados, verifica-se que a Acurácia e o $F1_{Score}$ médios se elevam à medida em que o nível de ruído no sinal vai decaindo. Com 20dB de ruído no sinal, a Acurácia média foi de 89,11% e $F1_{Score}$ médio de 88,90%. Já para sinais com 40dB, a Acurácia média foi de 96,16% e $F1_{Score}$ médio de 96,16%, representando uma diferença de

aproximadamente 7%. Um outro ponto que merece destaque é que os classificadores destinados à identificação dos distúrbios D3, D7, D10 e D11 obtiveram Acurácias iguais a 100% em todos os níveis de ruído testados. Já os classificadores destinados à identificação dos distúrbios D10 e D11 tiveram tanto a métrica Acurácia quanto $F1_{Score}$ iguais a 100% em todos os níveis de ruído.

Informações mais detalhadas dos desempenhos dos classificadores em relação ao nível de ruído estão disponíveis nas Tabelas 27 a 29 do Apêndice A.

Tabela 17 – Resumo dos resultados de teste para o *ensemble* final de classificação levando em consideração os níveis de ruído.

Distúrbio	SNR = 20dB		SNR = 35dB		SNR = 45dB		Sem ruído	
	Acc (%)	$F1_{Score}$	Acc (%)	$F1_{Score}$	Acc (%)	$F1_{Score}$	Acc (%)	$F1_{Score}$
D0	97,14	90,67	88,57	92,54	92,86	96,30	98,57	99,28
D1	92,86	92,86	94,29	93,62	97,14	93,79	97,14	94,44
D2	82,86	89,92	87,14	91,73	90,00	91,97	90,00	92,65
D3	100,00	97,22	100,00	98,59	100,00	100,00	100,00	99,29
D4	87,14	86,52	98,57	96,50	98,57	96,50	100,00	98,59
D5	67,14	71,76	97,14	89,47	98,57	93,88	100,00	97,90
D6	80,00	84,21	92,86	94,89	94,29	97,06	95,71	97,81
D7	100,00	97,22	100,00	99,29	100,00	100,00	100,00	100,00
D8	82,86	72,05	90,00	88,11	98,57	94,52	98,57	94,52
D9	54,29	64,41	81,43	87,02	90,00	92,65	91,43	94,12
D10	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
D11	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
D12	97,14	95,77	98,57	94,52	98,57	97,87	97,14	97,84
D13	100,00	99,29	100,00	100,00	100,00	100,00	98,57	99,28
D14	85,71	90,23	85,71	91,60	90,00	93,33	91,43	94,12
D15	98,57	90,20	94,29	90,41	90,00	90,65	92,86	91,55
Média	89,11	88,90	94,29	94,27	96,16	96,16	96,96	96,96

A fim de verificar a capacidade de generalização do *ensemble* utilizado anteriormente quando exposto a imagens de sinais que possuem níveis de ruído diferentes dos utilizados no processo de treinamento dos algoritmos, utilizou-se a base de dados de execução. Os resultados encontrados estão expressos nas Tabelas 18 a 33, sendo que as três últimas se encontram disponíveis no Apêndice A.

A matriz de confusão, ilustrada na Tabela 18, mostra que apenas o classificador destinado à identificação de distúrbios da classe D11 obteve uma Acurácia igual a 100%. Contudo, os classificadores destinados à identificação de distúrbios das classes D3, D10, D11 e D12 resultaram em Acurácias acima de 97%. Os três piores desempenhos foram os proporcionados pelos classificadores destinados à identificação de distúrbios das classes D2, transitório impulsivo (D5) e D9, com Acurácias de 75%, 68,06% e 61,11%, respectivamente. Sobretudo, o *ensemble* possibilitou uma Acurácia geral média de 86,02% e $F1_{Score}$ geral médio de 86,06%. Isto representa uma diferença de aproximadamente 8% a menos em Acurácia e $F1_{Score}$ dos resultados obtidos com a base de teste.

Tabela 18 – Matriz de confusão para o *ensemble* de classificação final referente aos dados de execução.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	$F1_{Score}$ (%)
D0	64	0	0	1	0	5	0	0	2	0	0	0	0	0	0	0	88,89	84,21
D1	0	66	0	1	0	0	0	0	0	0	0	0	4	0	1	0	91,67	90,41
D2	1	0	54	0	0	0	2	0	1	2	0	0	0	0	0	12	75,00	83,08
D3	0	0	0	71	0	0	0	0	0	0	0	0	1	0	0	0	98,61	96,60
D4	1	0	0	1	59	0	2	0	8	0	0	0	0	0	0	1	81,94	85,51
D5	7	0	0	0	0	49	3	0	12	1	0	0	0	0	0	0	68,06	71,01
D6	0	0	0	0	0	1	57	0	3	6	0	0	1	4	0	0	79,17	83,82
D7	0	0	0	0	1	0	0	68	0	1	0	1	1	0	0	0	94,44	97,14
D8	5	0	0	0	1	6	0	0	56	4	0	0	0	0	0	0	77,78	66,27
D9	2	0	1	0	2	5	0	0	15	44	0	1	0	0	0	2	61,11	67,69
D10	0	0	0	1	0	0	0	0	0	0	70	0	1	0	0	0	97,22	98,59
D11	0	0	0	0	0	0	0	0	0	0	0	72	0	0	0	0	100,00	97,96
D12	0	0	0	0	0	0	0	0	0	0	0	0	71	0	1	0	98,61	91,03
D13	0	0	0	0	0	0	0	0	0	0	0	0	0	67	0	5	93,06	93,06
D14	0	8	0	0	2	0	0	0	0	0	0	0	5	0	57	0	79,17	87,02
D15	0	0	3	0	1	0	0	0	0	0	0	1	0	1	0	66	91,67	83,54

A Tabela 18 exibe um resumo dos resultados de execução para o *ensemble* final de classificação levando em consideração os níveis de ruído. Assim como observado para os dados da base de teste, verifica-se que a Acurácia, bem como o $F1_{Score}$, aumentam de valor ao passo que o nível ruído do sinal é menor. Para imagem de sinais com 25dB foi possível obter uma Acurácia de 83,59% e $F1_{Score}$ de 83,73%, para 30dB uma Acurácia de 80,99% e $F1_{Score}$ de 80,83% e para 40dB uma Acurácia de 93,49% e $F1_{Score}$ de 93,46%. Ademais, apenas o classificador destinado a identificação da classe D11 que resultou em uma Acurácia de 100% nos três níveis de ruído considerados, porém nenhum classificador proporcionou um $F1_{Score}$ igual a 100% nos três níveis de ruído, como ocorrido em alguns casos para a base de teste.

A Tabela 20 ilustra alguns dos resultados dos trabalhos revisados na literatura que aplicam técnicas de classificação de distúrbios de QEE por meio de CNN. De maneira geral, constata-se que os autores obtiveram Acurácias médias acima de 97% na identificação de distúrbios, sendo que a maioria dos distúrbios foram detectados a uma Acurácia média de 100%.

Apesar dos elevados desempenhos encontrados nestes trabalhos (Tabela 20), alguns aspectos de implementação merecem ser destacados. No modelo de classificação proposto por [Sindi et al. \(2021\)](#), por exemplo, os autores consideram que a identificação padrões se dão por meio de janelas de sinais de QEE de dimensão fixa. Ocorre que, entretanto, os eventos de QEE em um SEP real não possuem um tempo padrão fixo de duração. Deste modo, haverá problemas em relação a parcela do modelo que processa os sinais em 1D, um vez que a CNN 1D foi elaborada e treinada com um número específico de entradas, que é um parâmetro fixo do modelo.

Assim como [Sindi et al. \(2021\)](#), [Machlev et al. \(2021\)](#) e [Wang e Chen \(2019\)](#) trabalham com um modelo de identificação de padrões baseado em CNN com camada de entrada 1D. Por-

Tabela 19 – Resumo dos resultados de execução para o *ensemble* final de classificação levando em consideração os níveis de ruído.

Distúrbio	SNR = 25db		SNR = 30dB		SNR = 40dB	
	Acc (%)	F1 _{Score}	Acc (%)	F1 _{Score}	Acc (%)	F1 _{Score}
D0	83,33	83,33	87,50	76,36	95,83	93,88
D1	83,33	86,96	95,83	92,00	95,83	92,00
D2	75,00	81,82	66,67	80,00	83,33	86,96
D3	95,83	97,87	100,00	96,00	100,00	96,00
D4	75,00	81,82	70,83	75,56	100,00	97,96
D5	58,33	60,87	50,00	55,81	95,83	93,88
D6	83,33	85,11	62,50	71,43	91,67	93,62
D7	87,50	93,33	95,83	97,87	100,00	100,00
D8	79,17	61,29	70,83	56,67	83,33	85,11
D9	50,00	60,00	50,00	57,14	83,33	83,33
D10	100,00	100,00	95,83	97,87	95,83	97,87
D11	100,00	96,00	100,00	97,96	100,00	100,00
D12	100,00	87,27	100,00	90,57	95,83	95,83
D13	91,67	93,62	91,67	88,00	95,83	97,87
D14	83,33	88,89	66,67	80,00	87,50	91,30
D15	91,67	81,48	91,67	80,00	91,67	89,80
Média	83,59	83,73	80,99	80,83	93,49	93,46

tanto, estes trabalhos acabam incorrendo no mesmo ponto fragilidade mencionado na abordagem de Sindi *et al.* (2021).

Cai *et al.* (2019a), outrossim, propuseram o uso apenas de CNNs com entrada 2D no processo de classificação de sinais. Contudo, os autores não consideraram o distúrbio transitório impulsivo (D5), que é evento de QEE com pequeno tempo de duração. Apesar de os autores utilizarem uma janela de dados de tamanho fixo, em um processo real de detecção/segmentação de distúrbios, a janela de dados resultante de um evento de transitório impulsivo é muito pequena se comprada as proporcionadas pelas outras classes de distúrbios de QEE. Consequentemente, a imagem obtida pelo método de transformação proposto pelos autores, sem a aplicação de métodos de redimensionamento, será também proporcionalmente pequena. E, sobretudo, os autores não definiram qual foi o critério utilizado para a escolha da dimensão padrão das imagens que serão processadas pela CNN. Nesta dissertação de mestrado, por exemplo, foi utilizado como critério redimensionar as imagens de acordo com a menor dimensão de imagem obtida nos processos de transformação dos sinais. Em vista disso, não é possível reproduzir fielmente a abordagem dos autores Cai *et al.* (2019a).

Apesar de Cai *et al.* (2019b) abordarem o uso CNN 2D e não considerar o distúrbio transitório impulsivo, é possível identificar no corpo do trabalho imagens que ilustram e exemplificam o resultado da transformação 1D em 2D. Deste modo, torna-se possível replicar o estudo incluindo o transitório impulsivo, diferentemente do que ocorre no trabalho de Cai *et al.* (2019a). Contudo, os autores Cai *et al.* (2019b) não consideraram na abordagem eventos de QEE que

apresentem algum nível de ruído. Logo, não é possível afirmar se o modelo proposto apresentará também um alto desempenho de classificação se, por sua vez, for exposto a estes tipos de sinais, que são mais condizentes ao SEP real.

No trabalho dos Liu *et al.* (2018) é importante destacar que os autores não deixaram expresso no texto qual foi a taxa de amostragem dos sinais utilizados para treinar e testar o modelo proposto. Pelas imagens inseridas no corpo do trabalho, pressupõe-se que a taxa utilizada esteja entre 100 e 200 amostras por ciclo. Um outro aspecto que dificulta a reprodução fiel do trabalho dos autores é a omissão da informação do número de ciclos de sinal que cada amostra de dado contém. Nota-se que, por meio das imagens ilustradas no trabalho, apenas os dados reais utilizados para a validação da abordagem possuem tempos de janela diferentes entre si.

Por fim, vale a pena destacar que os autores elencados na Tabela 20, assim como outros da literatura revisada, partem do pressuposto de que a parcela de sinal com distúrbio já está contida dentro da amostra de dados a ser utilizada, excluindo do contexto as etapas de detecção, segmentação e compressão que são essenciais em uma aplicação real de monitoramento da QEE. Portanto, um classificador de distúrbios necessita da habilidade de identificar padrões de sinais a partir de dados que foram processados em etapas anteriores por ferramentas que integram o *framework* de monitoramento da QEE, a fim de ser mais condizente com uma aplicação real em uma *Smart Grids*.

Tabela 20 – Resultados de classificação de alguns dos trabalhos da literatura revisados.

	A 0 a 50dB	B sem ruído	B 20 a 50dB	C sem ruído	D 10 a 40dB	E sem ruído	E 40dB	E 30dB	E 20dB	F 20dB	F 30dB
D0	100,00	98,51	99,58	-	-	100,00	100,00	98,40	94,70	100,00	100,00
D1	100,00	99,18	100,00	100,00	98,00	98,70	99,60	99,20	99,30	100,00	100,00
D2	100,00	99,81	99,79	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
D3	99,50	97,19	100,00	98,80	99,00	100,00	100,00	99,80	99,50	100,00	100,00
D4	100,00	99,79	100,00	98,80	100,00	100,00	100,00	99,70	97,90	100,00	100,00
D5	100,00	100,00	100,00	-	-	100,00	99,50	96,70	73,50	99,89	100,00
D6	100,00	98,57	99,59	100,00	100,00	100,00	100,00	100,00	99,90	100,00	100,00
D7	100,00	99,78	98,36	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
D8	-	98,93	99,78	-	-	100,00	100,00	100,00	100,00	100,00	100,00
D9	-	100,00	100,00	100,00	-	100,00	100,00	100,00	99,90	-	-
D10	100,00	100,00	99,80	100,00	100,00	99,90	99,90	99,70	99,40	99,99	100,00
D11	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	99,61	99,87
D12	100,00	96,99	100,00	-	-	100,00	100,00	99,90	99,80	99,54	99,90
D13	100,00	100,00	100,00	-	-	100,00	100,00	100,00	100,00	99,00	99,90
D14	-	-	-	-	-	-	-	-	-	99,07	99,54
D15	-	-	-	-	-	-	-	-	-	99,23	99,53
Média	99,96	99,20	99,78	99,73	99,63	99,90	99,93	99,53	97,42	99,76	99,92

A: Sindi *et al.* (2021); B: Machlev *et al.* (2021); C: Cai *et al.* (2019b); D: Cai *et al.* (2019a); E: Wang e Chen (2019); e F: Liu *et al.* (2018).

CONCLUSÕES

Este trabalho propôs a implementação de um *framework* para fins de monitoramento automático de distúrbios de QEE no contexto de *Smart Grids*. Para tanto, foi realizada uma extensiva revisão bibliográfica para tomar conhecimento dos métodos aplicados no contexto do processamento de sinais QEE, além de ressaltar suas contribuições para o avanço do estado da arte.

Verificou-se também que o tema em questão tem despertado um grande interesse por parte das concessionárias de energia e da comunidade técnico-científica. As principais justificativas estão ligadas ao impacto financeiro-econômico gerado pelos problemas de QEE, a frequência de ocorrência destes eventos indesejados, bem como a variedade de classes que estes podem se manifestar.

A estrutura de comunicação do sistema *Smart Grids* possibilita, por sua vez, avanços significativos no monitoramento em tempo real e de forma ampla no SEP. Neste cenário, um distúrbio originado em uma unidade consumidora pode ser detectado pelo *smart meter* e encaminhado à concessionária de energia para identificação do padrão de sinal de QEE e, assim, adotar rapidamente as operações corretivas mais eficazes para o distúrbio reconhecido.

Levando em consideração os aspectos apontados em tela, a estrutura de processamento de sinais proposto por essa dissertação contempla, em síntese, a (i) detecção e segmentação dos distúrbios; (ii) compactação dos sinais de distúrbios capturados; e, por fim, a (iii) classificação destes. As duas primeiras etapas contemplam técnicas mais simples e podem, portanto, serem executadas diretamente no *smart meter*, ou seja, na borda do sistema (*edge computing*). A última etapa, que exige maior poder computacional de processamento e armazenamento, pode ser executada em um serviço de *cloud* da concessionária.

É importante comentar que o presente estudo considerou 15 classes de distúrbios, que foram gerados sinteticamente por modelos matemáticos baseados na literatura a uma taxa de amostral de 256 amostras por ciclo. E para proporcionar maior realidade ao SEP, foram

adicionados ruídos gaussianos brancos de SNR de 20 a 45dB.

Existem diversas técnicas disponíveis na literatura que podem ser aplicadas em cada uma destas etapas descritas. No caso da detecção e segmentação, por exemplo, apesar de existir técnicas propostas, é difícil encontrar uma que seja eficaz na detecção de todas as classes de distúrbios consideradas neste trabalho. Com base na revisão bibliográfica, notou-se que esta área ainda é pouco estudada. Os autores, no geral, partem do pressuposto de que o sinal já está detectado/segmentado e realiza apenas a classificação o processo de classificação. Deste modo, visando avançar o estudo da arte, foi proposta a utilização de algoritmos de *machine learning* para classificar (de forma binária) se uma janela de sinal possui ou não um distúrbio. Para isto, comprovou-se que a DT foi capaz de detecção e segmentar, por meio *features* simples calculadas das janelas de sinais, acima de 93% dos distúrbios estudados.

No que tange a compressão dos sinais, pensando na limitação de *hardware* dos *smart meters*, foi utilizado um método bem simples e já consolidado na literatura baseado WT e do algoritmo *Huffman Code*. Neste processo, foi possível alcançar uma taxa de compressão acima de 3,6 com pouca perda de informação.

Concluída a etapa anterior, os sinais detectados e segmentados podem ser encaminhados para a *cloud* da concessionária a fim de iniciar a terceira etapa dessa pesquisa, que consiste na classificação dos distúrbios após a realização do processo de descompressão dos mesmos. Neste contexto, constatou-se na literatura uma tendência pelo uso de algoritmos de *Deep Learning*, como a CNN. Portanto, a metodologia deste trabalho investigou o potencial dos RPs, GASFs e GADFs como uma nova abordagem de extração de características dos sinais de QEE para serem utilizadas em conjunto com algoritmos do tipo CNN no processo de identificação de distúrbios.

Em uma análise visual, constatou-se que técnicas RP, GASF e GADF permitiram a geração de imagens que contenham padrões de textura que auxiliem no processo de identificação da classe de distúrbio envolvida. Distúrbios como afundamento de tensão, elevação de tensão e interrupção de tensão, por exemplo, proporcionam imagens com padrões de textura mais expressivos, que facilitam sua identificação. Já os distúrbios *notching* e *spike*, por exemplo, geram padrões de textura mais sutis.

Os *ensemble* de classificadores CNN, que incluiu topologias de redes pré-treinadas e não pré-treinadas, conseguiu obter um potencial de Acurácia média de 94,13% para a base de testes e de 86,02% para a base de execução, mostrando como uma alternativa viável às abordagens que fazem parte do estado da arte. Sobretudo, métodos abordados na literatura não consideram as etapas de detecção, segmentação e compressão. Estas etapas, por sua vez, afasta o problema de um cenário ideal e o aproxima de um cenário de operação mais condizente com a realidade de operação.

Ademais, é importante destacar que a forma inovadora que foram utilizada as técnicas RP, GASF e GADF no contexto de QEE para fins de classificação de distúrbios utilizando um

ensemble de CNNs. Além disso, o trabalho proposto integrou todas as etapas necessárias para o monitoramento real da QEE em uma *Smart Grids*, diferentemente do que se encontra na literatura.

Para finalizar, as diretrizes de trabalhos futuras desta pesquisa consistem em (i) otimizar a parametrização dos RPs, a fim de buscar por melhores resultados; (ii) testar a metodologia proposta em um sistema elétrico real; e (iii) desenvolver e testar novos métodos que possam aprimorar os resultados já encontrados.

6.1 Produção Científica

Durante o período da pesquisa do mestrado, foram produzidos e aceitos os seguintes artigos em congresso nacional e internacional:

MORAES, A. L.; FERNANDES, R. A. S. Uma abordagem compacta de detecção de distúrbios de qualidade da energia elétrica no contexto de smart grids. *14ª Conferência Brasileira de Dinâmica, Controle e Aplicações (DINCON)*, 2019.

MORAES, A. L.; FERNANDES, R. A. S. Recurrence Plots: A Novel Feature Engineering Technique to Analyze Power Quality Disturbances. *IEEE PES General Meeting*, 2020.

REFERÊNCIAS

ANAND, R.; MEHROTRA, K.; MOHAN, C. K.; RANKA, S. Efficient classification for multi-class problems using modular neural networks. **IEEE Transactions on Neural Networks**, v. 6, n. 1, p. 117–124, 1995. Citado na página 65.

ANDRADE, L. C. M.; NANJUNDASWAMY, T.; OLESKOVICZ, M.; FERNANDES, R. A.; ROSE, K. Advances in Classification and Compression of Power Quality Signals. **Journal of Control, Automation and Electrical Systems**, v. 30, n. 3, p. 402–412, 2019. Citado 3 vezes nas páginas 29, 40 e 49.

ANDRADE, L. C. M. de. **Transformada Wavelet e Técnicas de Inteligência Computacional Aplicadas à Identificação, Compressão e Armazenamento de Sinais no Contexto de Qualidade da Energia Elétrica**. Tese (Doutorado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2017. Citado na página 16.

ANEEL. Módulo 8 – qualidade da energia elétrica, procedimentos de distribuição de energia elétrica no sistema elétrico nacional (PRODIST). **Rev. 12**, 2021. Citado 9 vezes nas páginas 1, 7, 8, 10, 12, 13, 14, 15 e 16.

ANGRISANI, L.; DAPONTE, P.; D’APUZZO, M.; TESTA, A. A measurement method based on the wavelet transform for power quality analysis. **IEEE Transactions on Power Delivery**, v. 13, n. 4, p. 990–998, 1998. Citado 2 vezes nas páginas 17 e 42.

BASTOS, A. F.; LAO, K.; TODESCHINI, G.; SANTOSO, S. Accurate identification of point-on-wave inception and recovery instants of voltage sags and swells. **IEEE Transactions on Power Delivery**, v. 34, n. 2, p. 551–560, 2019. Citado 3 vezes nas páginas 21, 23 e 40.

BISONG, E. **Building Machine Learning and Deep Learning Models on Google Cloud Platform: A Comprehensive Guide for Beginners**. Berkeley, CA: Apress, 2019. 243–250 p. Citado na página 52.

BISWAL, B.; BISWAL, M.; MISHRA, S.; JALAJA, R. Automatic classification of power quality events using balanced neural tree. **IEEE Transactions on Industrial Electronics**, v. 61, n. 1, p. 521–530, 2014. Citado 2 vezes nas páginas 20 e 41.

BISWAL, B.; DASH, P. K.; PANIGRAHI, B. K. Power quality disturbance classification using fuzzy c-means algorithm and adaptive particle swarm optimization. **IEEE Transactions on Industrial Electronics**, v. 56, n. 1, p. 212–220, 2009. Citado 2 vezes nas páginas 31 e 41.

BLANCO, V.; JAPON, A.; PUERTO, J. Optimal arrangements of hyperplanes for svm-based multiclass classification. **Advances in Data Analysis and Classification**, v. 14, n. 1, p. 175–199, 2020. Citado na página 65.

BONNIN, R. **Machine Learning for Developers: Uplift your regular applications with the power of statistics, analytics, and machine learning**. [S.l.]: Packt Publishing, 2017. Citado na página 66.

- BORGES, F. A. S. **Extração de Características Combinadas com Árvore de Decisão para Detecção e Classificação dos Distúrbios de Qualidade da Energia Elétrica**. Dissertação (Mestrado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2013. Citado 4 vezes nas páginas 20, 22, 41 e 44.
- BORGES, F. A. S.; FERNANDES, R. A. S.; SILVA, I. N.; SILVA, C. B. S. Feature extraction and power quality disturbances classification using smart meters signals. **IEEE Transactions on Industrial Informatics**, v. 12, n. 2, p. 824–833, 2016. Citado 5 vezes nas páginas 2, 32, 36, 40 e 49.
- CAI, K.; CAO, W.; AARNIOVUORI, L.; PANG, H.; LIN, Y.; LI, G. Classification of power quality disturbances using wigner-ville distribution and deep convolutional neural networks. **IEEE Access**, v. 7, p. 119099–119109, 2019. Citado 5 vezes nas páginas 2, 34, 40, 108 e 110.
- CAI, K.; HU, T.; CAO, W.; LI, G. Classifying power quality disturbances based on phase space reconstruction and a convolutional neural network. **Applied Sciences**, v. 9, n. 18, p. 1–15, 2019. Citado 7 vezes nas páginas 2, 34, 40, 62, 101, 108 e 110.
- CHO, S.; JANG, G.; KWON, S. Time-frequency analysis of power-quality disturbances via the gabor–wigner transform. **IEEE Transactions on Power Delivery**, v. 25, n. 1, p. 494–499, 2010. Citado 2 vezes nas páginas 19 e 41.
- CHOLLET, F. **Deep Learning with Python**. 1st. ed. USA: Manning Publications Co., 2017. Citado na página 63.
- DASH, P. K.; PANIGRAHI, B. K.; SAHOO, D. K.; PANDA, G. Power quality disturbance data compression, detection, and classification using integrated spline wavelet and s-transform. **IEEE Transactions on Power Delivery**, v. 18, n. 2, p. 595–600, 2003. Citado 3 vezes nas páginas 18, 25 e 41.
- DEPURU, S. S. S. R.; WANG, L.; DEVABHAKTUNI, V. Smart meters for power grid: Challenges, issues, advantages and status. **Renewable and Sustainable Energy Reviews**, v. 15, n. 6, p. 2736–2742, 2011. Citado na página 2.
- DONOHO, D. L.; HUO, X. Uncertainty principles and ideal atomic decomposition. **IEEE Transactions on Information Theory**, v. 47, n. 7, p. 2845–2862, 2001. Citado na página 28.
- DUGAN, R.; MCGRANAGHAN, M.; SANTOSO, S.; BEATY, H. **Electrical Power Systems Quality, Third Edition**. [S.l.]: McGraw-Hill Education, 2012. Citado 9 vezes nas páginas 1, 7, 8, 9, 10, 11, 12, 13 e 14.
- ECE, D. G.; GEREK, O. N. Power quality event detection using joint 2-d-wavelet subspaces. **IEEE Transactions on Instrumentation and Measurement**, v. 53, n. 4, p. 1040–1046, 2004. Citado 2 vezes nas páginas 18 e 41.
- ECKMANN, J.-P.; KAMPHORST, S. O.; RUELLE, D. Recurrence plots of dynamical systems. **Europhysics Letters (EPL)**, IOP Publishing, v. 4, n. 9, p. 973–977, 1987. Citado 2 vezes nas páginas 3 e 58.
- ELAD, M.; BRUCKSTEIN, A. M. A generalized uncertainty principle and sparse representation in pairs of bases. **IEEE Transactions on Information Theory**, v. 48, n. 9, p. 2558–2567, 2002. Citado na página 28.

ERİŞTİ, H.; UÇAR, A.; DEMİR, Y. Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines. **Electric Power Systems Research**, v. 80, n. 7, p. 743 – 752, 2010. Citado na página 2.

GAING, Z.-L. Wavelet-based neural network for power disturbance recognition and classification. **IEEE Transactions on Power Delivery**, v. 19, n. 4, p. 1560–1568, 2004. Citado 2 vezes nas páginas 30 e 41.

GEREK, Ö. N.; ECE, D. G. Compression of power quality event data using 2d representation. **Electric Power Systems Research**, v. 78, n. 6, p. 1047–1052, 2008. Citado 2 vezes nas páginas 27 e 41.

HAMID, E. Y.; KAWASAKI, Z. I. Wavelet-based data compression of power system disturbances using the minimum description length criterion. **IEEE Transactions on Power Delivery**, v. 17, n. 2, p. 460–466, 2002. Citado 2 vezes nas páginas 25 e 41.

HE, S.; TIAN, W.; ZHANG, J.; LI, K.; ZHANG, M.; ZHU, R. A high efficient approach for power disturbance waveform compression in the view of heisenberg uncertainty. **IEEE Transactions on Industrial Informatics**, v. 15, n. 5, p. 2580–2591, 2019. Citado 2 vezes nas páginas 28 e 40.

HONG, W.-C. **Hybrid Intelligent Technologies in Energy Demand Forecasting**. Cham: Springer International Publishing, 2020. 153–179 p. Citado na página 59.

HOOSHMAND, R.; ENSHAEE, A. Detection and classification of single and combined power quality disturbances using fuzzy systems oriented by particle swarm optimization algorithm. **Electric Power Systems Research**, v. 80, n. 12, p. 1552–1561, 2010. Citado na página 44.

HSIEH, C. T.; HUANG, S. J.; HUANG, C. L. Data reduction of power quality disturbances - a wavelet transform approach. **Electric Power Systems Research**, v. 47, n. 2, p. 79–86, 1998. Citado 2 vezes nas páginas 24 e 42.

HUANG, J.; NEGNEVITSKY, M.; NGUYEN, D. T. A neural-fuzzy classifier for recognition of power quality disturbances. **IEEE Transactions on Power Delivery**, v. 17, n. 2, p. 609–616, 2002. Citado 2 vezes nas páginas 30 e 41.

IBRAHIM, W. R. A.; MORCOS, M. M. Novel data compression technique for power waveforms using adaptive fuzzy logic. **IEEE Transactions on Power Delivery**, v. 20, n. 3, p. 2136–2143, 2005. Citado 2 vezes nas páginas 26 e 41.

IEC. Electromagnetic compatibility (EMC), Part 4-15: Testing and measurement techniques — flickermeter — functional and design specifications. **IEC 61000-4-15**, 2010. Citado na página 13.

IEEE. IEEE recommended practice for monitoring electric power quality. **IEEE Std 1159-2019 (Revision of IEEE Std 1159-2009)**, 2019. Citado 5 vezes nas páginas 2, 8, 10, 11 e 12.

JANIK, P.; LOBOS, T. Automated classification of power-quality disturbances using svm and rbf networks. **IEEE Transactions on Power Delivery**, v. 21, n. 3, p. 1663–1669, 2006. Citado 3 vezes nas páginas 2, 30 e 41.

JUNIOR, W. L. R.; BORGES, F. A. S.; RABELO, R. d. A. L.; RODRIGUES, J. J. P. C.; FERNANDES, R. A. S.; SILVA, I. N. da. A methodology for detection and classification of power quality disturbances using a real-time operating system in the context of home energy

management systems. **International Journal of Energy Research**, v. 45, n. 1, p. 203–219, 2021. Citado 6 vezes nas páginas 22, 23, 36, 40, 45 e 78.

KAGAN, N.; OLIVEIRA, C.; ROBBA, E. **Introdução aos Sistemas de Distribuição de Energia Elétrica, Segunda Edição**. [S.l.]: Editora Blucher, 2000. Citado na página 1.

KAUSHIK, R.; MAHELA, O. P.; BHATT, P. K.; KHAN, B.; PADMANABAN, S.; BLAABJERG, F. A hybrid algorithm for recognition of power quality disturbances. **IEEE Access**, v. 8, p. 229184–229200, 2020. Citado 2 vezes nas páginas 36 e 40.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. Imagenet classification with deep convolutional neural networks. **Neural Information Processing Systems**, v. 25, 01 2012. Citado na página 62.

KUMAR, R.; SINGH, B.; SHAHANI, D. T.; CHANDRA, A.; AL-HADDAD, K. Recognition of power-quality disturbances using s-transform-based ann classifier and rule-based decision tree. **IEEE Transactions on Industry Applications**, v. 51, n. 2, p. 1249–1258, 2015. Citado 4 vezes nas páginas 2, 13, 31 e 40.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998. Citado na página 62.

LEE, C.-y.; SHEN, Y.-x. Optimal feature selection for power-quality disturbances classification. **IEEE Transactions on Power Delivery**, v. 26, n. 4, p. 2342–2351, 2011. Citado 2 vezes nas páginas 13 e 44.

LIN, L.; WANG, D.; ZHAO, S.; CHEN, L.; HUANG, N. Power quality disturbance feature selection and pattern recognition based on image enhancement techniques. **IEEE Access**, v. 7, p. 67889–67904, 2019. Citado 3 vezes nas páginas 2, 34 e 40.

LITTLER, T. B.; MORROW, D. J. Wavelets for the analysis and compression of power system disturbances. **IEEE Transactions on Power Delivery**, v. 14, n. 2, p. 358–364, 1999. Citado 3 vezes nas páginas 24, 42 e 54.

LIU, H.; HUSSAIN, F.; SHEN, Y.; ARIF, S.; NAZIR, A.; ABUBAKAR, M. Complex power quality disturbances classification via curvelet transform and deep learning. **Electric Power Systems Research**, v. 163, n. Parte A, p. 1–9, 2018. Citado 4 vezes nas páginas 33, 40, 109 e 110.

Liu, Y.; Jin, T.; Mohamed, M. A.; Wang, Q. A novel three-step classification approach based on time-dependent spectral features for complex power quality disturbances. **IEEE Transactions on Instrumentation and Measurement**, v. 70, p. 1–14, 2021. Citado 2 vezes nas páginas 36 e 40.

MACHLEV, R.; CHACHKES, A.; BELIKOV, J.; Y., B.; Y., L. Open source dataset generator for power quality disturbances with deep-learning reference classifiers. **Electric Power Systems Research**, v. 195, p. 1–7, 2021. Citado 4 vezes nas páginas 37, 40, 107 e 110.

MALANGE, F. C. V. **Rede Neuro-Fuzzy-Wavelet para Detecção e Classificação de Anomalias de Tensão em Sistemas Elétricos de Potência**. Tese (Doutorado em Engenharia Elétrica) — Faculdade de Engenharia, Universidade Estadual Paulista Júlio de Mesquita Filho, Campus Ilha Solteira, 2010. Citado na página 12.

MALLAT, S. **A Wavelet Tour of Signal Processing: The Sparse Way**. 3th. ed. USA: Elsevier Inc., 2009. Citado na página 56.

MANIKANDAN, M. S.; SAMANTARAY, S. R.; KAMWA, I. Detection and classification of power quality disturbances using sparse signal decomposition on hybrid dictionaries. **IEEE Transactions on Instrumentation and Measurement**, v. 64, n. 1, p. 27–38, 2015. Citado 2 vezes nas páginas 21 e 41.

MARWAN, N.; ROMANO, M. C.; THIEL, M.; KURTHS, J. Recurrence plots for the analysis of complex systems. **Physics Reports**, v. 438, n. 5–6, p. 237–329, 2007. Citado na página 59.

MCGILL, R.; TUKEY, J. W.; LARSEN, W. A. Variations of box plots. **The American Statistician**, [American Statistical Association, Taylor Francis, Ltd.], v. 32, n. 1, p. 12–16, 1978. Citado na página 53.

MEHER, S.; PRADHAN, A.; PANDA, G. An integrated data compression scheme for power quality events using spline wavelet and neural network. **Electric Power Systems Research**, v. 69, n. 2, p. 213–220, 2004. Citado 2 vezes nas páginas 25 e 41.

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, n. 1, p. 280–287, 2008. Citado 3 vezes nas páginas 13, 31 e 41.

MORAES, A. L.; FERNANDES, R. A. S. Uma abordagem compacta de detecção de distúrbios de qualidade da energia elétrica no contexto de smart grids. In: **Anais eletrônicos da 14ª Conferência Brasileira de Dinâmica, Controle e Aplicações - DINCON 2019**. [S.l.: s.n.], 2019. Citado 3 vezes nas páginas 22, 23 e 40.

PAN, S. J.; YANG, Q. A survey on transfer learning. **IEEE Transactions on Knowledge and Data Engineering**, v. 22, n. 10, p. 1345–1359, 2010. Citado na página 64.

PANDA, G.; DASH, P. K.; PRADHAN, A. K.; MEHER, S. K. Data compression of power quality events using the slantlet transform. **IEEE Transactions on Power Delivery**, v. 17, n. 2, p. 662–667, 2002. Citado 2 vezes nas páginas 24 e 41.

RADIL, T.; RAMOS, P. M.; JANEIRO, F. M.; SERRA, A. C. Pq monitoring system for real-time detection and classification of disturbances in a single-phase power system. **IEEE Transactions on Instrumentation and Measurement**, v. 57, n. 8, p. 1725–1733, 2008. Citado 2 vezes nas páginas 18 e 41.

REAZ, M. B. I.; CHOONG, F.; SULAIMAN, M. S.; MOHD-YASIN, F.; KAMADA, M. Expert system for power quality disturbance classifier. **IEEE Transactions on Power Delivery**, v. 22, n. 3, p. 1979–1988, 2007. Citado 2 vezes nas páginas 30 e 41.

RIBEIRO, M. V.; PARK, S. H.; ROMANO, J. M. T.; MITRA, S. K. A novel mdl-based compression method for power quality applications. **IEEE Transactions on Power Delivery**, v. 22, n. 1, p. 27–36, 2007. Citado 2 vezes nas páginas 26 e 41.

RIBEIRO, M. V.; ROMANO, J. M.; DUQUE, C. A. An improved method for signal processing and compression in power quality evaluation. **IEEE Transactions on Power Delivery**, v. 19, n. 2, p. 464–471, 2004. Citado 3 vezes nas páginas 25, 26 e 41.

- ROCHA, A.; GOLDENSTEIN, S. K. Multiclass from binary: Expanding one-versus-all, one-versus-one and ecoc-based approaches. **IEEE Transactions on Neural Networks and Learning Systems**, v. 25, n. 2, p. 289–302, 2014. Citado na página 65.
- RODRIGUEZ, M. V.; TRONCOSO, R. de J. R.; OSORNIO-RIOS, R. A.; PEREZ, A. G. Detection and classification of single and combined power quality disturbances using neural networks. **IEEE Transactions on Industrial Electronics**, v. 61, n. 5, p. 2473–2482, 2014. Citado 4 vezes nas páginas 2, 13, 31 e 41.
- SALOMON, D. **Data Compression: The Complete Reference**. 4th. ed. USA: Springer, 2007. Citado 2 vezes nas páginas 55 e 56.
- SANTOSO, S.; POWERS, E. J.; GRADY, W. M. Power quality disturbance data compression using wavelet transform methods. **IEEE Transactions on Power Delivery**, v. 12, n. 3, p. 1250–1257, 1997. Citado 3 vezes nas páginas 23, 42 e 55.
- SANTOSO, S.; POWERS, E. J.; GRADY, W. M.; HOFMANN, P. Power quality assessment via wavelet transform analysis. **IEEE Transactions on Power Delivery**, v. 11, n. 2, p. 924–930, 1996. Citado 2 vezes nas páginas 17 e 42.
- SANTOSO, S.; POWERS, E. J.; GRADY, W. M.; PARSONS, A. C. Power quality disturbance waveform recognition using wavelet-based neural classifier. i. theoretical foundation. **IEEE Transactions on Power Delivery**, v. 15, n. 1, p. 222–228, 2000. Citado na página 29.
- _____. Power quality disturbance waveform recognition using wavelet-based neural classifier. ii. application. **IEEE Transactions on Power Delivery**, v. 15, n. 1, p. 229–235, 2000. Citado 2 vezes nas páginas 29 e 41.
- SHANNON, C. E. A mathematical theory of communication. **Bell System Technical Journal**, Blackwell Publishing Ltd, v. 27, n. 3, p. 379–423, 1948. Citado na página 67.
- SHAREEF, H.; MOHAMED, A.; IBRAHIM, A. A. An image processing based method for power quality event identification. **International Journal of Electrical Power & Energy Systems**, v. 46, p. 184–197, 2013. Citado na página 2.
- SHI, W.; CAO, J.; ZHANG, Q.; LI, Y.; XU, L. Edge computing: Vision and challenges. **IEEE Internet of Things Journal**, v. 3, n. 5, p. 637–646, 2016. Citado 2 vezes nas páginas 2 e 4.
- SILVA, L. R. M.; de Andrade Filho, L. M.; DUQUE, C. A. Sparse representation algorithm applied to power systems signal compression. **International Transactions on Electrical Energy Systems**, v. 29, n. 1, p. 1–12, 2019. Citado 2 vezes nas páginas 28 e 40.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. In: **International Conference on Learning Representations**. [S.l.: s.n.], 2015. p. 1–14. Citado na página 63.
- SINDI, H.; NOUR, M.; RAWA, M.; ÖZTürKM, ; POLAT, K. A novel hybrid deep learning approach including combination of 1d power signals and 2d signal images for power quality disturbance classification. **Expert Systems with Applications**, v. 174, p. 1–13, 2021. Citado 6 vezes nas páginas 37, 40, 101, 107, 108 e 110.
- SINGH, R.; MOHANTY, S. R.; KISHOR, N.; K, A. T. Real-time implementation of signal processing techniques for disturbances detection. **IEEE Transactions on Industrial Electronics**, v. 66, n. 5, p. 3550–3560, 2019. Citado 3 vezes nas páginas 21, 23 e 40.

- SINGH, U.; SINGH, S. N. Application of fractional fourier transform for classification of power quality disturbances. **IET Science, Measurement Technology**, v. 11, n. 1, p. 67–76, 2017. Citado 3 vezes nas páginas 13, 32 e 40.
- TANG, Q.; QIU, W.; ZHOU, Y. Classification of complex power quality disturbances using optimized s-transform and kernel svm. **IEEE Transactions on Industrial Electronics**, v. 67, n. 11, p. 9715–9723, 2020. Citado 2 vezes nas páginas 35 e 40.
- TSE, N. C. F.; CHAN, J. Y. C.; LAU, W.; POON, J. T. Y.; LAI, L. L. Real-time power-quality monitoring with hybrid sinusoidal and lifting wavelet compression algorithm. **IEEE Transactions on Power Delivery**, v. 27, n. 4, p. 1718–1726, 2012. Citado 2 vezes nas páginas 27 e 41.
- UZINSKI, J. C. **Momentos nulos e regularidade wavelet na detecção de falhas em sinais**. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Estadual Paulista “Júlio Mesquita Filho, Ilha Solteira, 2013. Citado na página 54.
- WANG, J.; XU, Z.; CHE, Y. Power quality disturbance classification based on compressed sensing and deep convolution neural networks. **IEEE Access**, v. 7, p. 78336–78346, 2019. Citado 7 vezes nas páginas 13, 28, 33, 40, 44, 62 e 101.
- WANG, S.; CHEN, H. A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network. **Applied Energy**, v. 235, p. 1126–1140, 2019. Citado 5 vezes nas páginas 33, 40, 101, 107 e 110.
- WANG, Z.; OATES, T. Imaging time-series to improve classification and imputation. **Computing Research Repository**, abs/1506.00327, p. 1–7, 2015. Citado 3 vezes nas páginas 3, 60 e 61.
- WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data Mining: Practical Machine Learning Tools and Techniques**. 3th. ed. Amsterdam: Morgan Kaufmann, 2011. Citado na página 51.
- XI, Y.; LI, Z.; TANG, X.; ZENG, X. Classification of power quality disturbances based on kf-ml-aided s-transform and multilayers feedforward neural networks. **IET Generation, Transmission & Distribution**, v. 14, n. 19, p. 4010–4020, 2020. Citado 2 vezes nas páginas 35 e 40.
- YANG, C.; JIANG, W.; GUO, Z. Time series data classification based on dual path cnn-rnn cascade network. **IEEE Access**, v. 7, p. 155304–155312, 2019. Citado na página 62.
- ZHANG, Z.; XU, Y.; YANG, J.; LI, X.; ZHANG, D. A survey of sparse representation: Algorithms and applications. **IEEE Access**, v. 3, p. 490–530, 2015. Citado na página 28.

RESULTADOS COMPLEMENTARES DO MÓDULO DE CLASSIFICAÇÃO

As Tabelas de 21 a 33 ilustram resultados complementares obtidos no módulo de classificação.

Tabela 21 – Matriz de confusão para os resultados de classificação utilizando CNN e imagens de RP.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	$F1_{Score}$ (%)
D0	260	0	0	2	0	11	6	0	0	1	0	0	0	0	0	0	92,86	92,04
D1	0	265	0	5	0	0	0	2	0	0	0	0	4	0	4	0	94,64	90,91
D2	0	0	249	1	1	0	1	0	2	2	0	1	0	5	0	18	88,93	88,45
D3	0	0	0	280	0	0	0	0	0	0	0	0	0	0	0	0	100,00	98,07
D4	4	0	0	1	258	0	11	1	2	2	0	0	0	0	0	1	92,14	94,33
D5	9	1	0	0	1	245	8	0	5	11	0	0	0	0	0	0	87,50	88,45
D6	2	1	0	0	0	11	240	0	12	14	0	0	0	0	0	0	85,71	83,92
D7	2	3	0	0	0	1	2	271	0	1	0	0	0	0	0	0	96,79	95,76
D8	4	0	0	0	0	3	8	6	241	16	0	0	1	1	0	0	86,07	84,86
D9	4	0	0	0	1	3	13	5	23	229	0	1	0	1	0	0	81,79	82,37
D10	0	0	0	0	0	0	0	0	0	0	278	0	1	0	1	0	99,29	99,64
D11	0	0	0	0	0	0	0	0	0	0	0	279	0	1	0	0	99,64	99,11
D12	0	9	0	1	0	0	0	0	0	0	0	1	267	0	2	0	95,36	94,51
D13	0	0	3	1	0	0	2	0	0	0	0	0	0	271	0	3	96,79	96,10
D14	0	24	0	0	0	0	0	1	0	0	0	0	12	0	243	0	86,79	91,70
D15	0	0	31	0	6	0	1	0	3	0	0	1	0	5	0	233	83,21	87,10

Tabela 22 – Matriz de confusão para os resultados de classificação utilizando CNN e imagens de GASF.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	$F1_{Score}$ (%)
D0	246	0	0	0	4	17	9	0	4	0	0	0	0	0	0	0	87,86	88,97
D1	0	255	0	11	0	0	1	0	0	0	0	0	4	0	9	0	91,07	91,23
D2	0	0	231	0	0	0	1	0	0	0	0	0	0	2	0	46	82,50	88,85
D3	0	0	0	280	0	0	0	0	0	0	0	0	0	0	0	0	100,00	98,07
D4	2	0	0	0	266	2	4	0	3	2	0	0	0	0	0	1	95,00	93,50
D5	11	0	0	0	3	249	4	3	7	3	0	0	0	0	0	0	88,93	87,99
D6	5	0	0	0	0	2	263	0	7	3	0	0	0	0	0	0	93,93	91,96
D7	1	0	0	0	1	0	2	276	0	0	0	0	0	0	0	0	98,57	98,40
D8	5	0	0	0	1	6	4	1	255	6	0	0	1	0	0	1	91,07	86,29
D9	3	0	0	0	3	10	2	1	35	225	0	0	0	0	0	1	80,36	86,71
D10	0	0	0	0	0	0	0	0	0	0	279	0	1	0	0	0	99,64	99,82
D11	0	0	0	0	0	0	0	0	0	0	0	280	0	0	0	0	100,00	99,82
D12	0	2	0	0	0	0	0	0	0	0	0	0	262	0	16	0	93,57	90,03
D13	0	0	0	0	0	0	2	0	0	0	0	0	0	278	0	0	99,29	99,11
D14	0	22	0	0	5	0	0	0	0	0	0	0	34	0	219	0	78,21	83,59
D15	0	0	9	0	6	0	0	0	0	0	0	1	0	1	0	263	93,93	88,85

Tabela 23 – Matriz de confusão para os resultados de classificação utilizando CNN e imagens de GADF.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	$F1_{Score}$ (%)
D0	241	0	0	0	1	17	13	0	7	1	0	0	0	0	0	0	86,07	86,85
D1	1	255	0	4	0	2	5	0	0	0	0	0	3	0	10	0	91,07	91,40
D2	0	0	230	0	0	0	0	0	3	0	0	0	0	2	0	45	82,14	89,67
D3	0	5	0	274	0	0	0	0	0	0	0	0	1	0	0	0	97,86	98,21
D4	7	0	0	0	259	1	4	0	5	4	0	0	0	0	0	0	92,50	94,35
D5	13	0	0	0	2	229	4	0	16	16	0	0	0	0	0	0	81,79	83,42
D6	4	1	0	0	0	16	244	0	5	7	0	0	2	1	0	0	87,14	87,61
D7	0	0	0	0	0	0	0	279	0	1	0	0	0	0	0	0	99,64	99,29
D8	2	0	0	0	0	1	2	0	238	35	0	0	1	0	0	1	85,00	79,47
D9	7	0	0	0	2	3	3	3	43	218	0	0	0	0	0	1	77,86	77,58
D10	0	0	0	0	0	0	0	0	0	0	280	0	0	0	0	0	100,00	100,00
D11	0	0	0	0	0	0	0	0	0	0	0	280	0	0	0	0	100,00	99,47
D12	0	3	0	0	0	0	0	0	0	0	0	0	269	0	8	0	96,07	90,73
D13	0	0	0	0	0	0	0	0	0	0	0	0	0	280	0	0	100,00	99,29
D14	0	14	0	0	0	0	1	0	2	0	0	0	37	0	226	0	80,71	86,26
D15	0	0	3	0	5	0	1	0	0	0	0	3	0	1	0	267	95,36	89,90

Tabela 24 – Matriz de confusão para os resultados de classificação utilizando VGG16 e imagens de RP.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	$F1_{Score}$ (%)
D0	261	0	0	0	1	9	3	0	3	2	0	0	0	0	1	0	93,21	92,39
D1	0	250	0	7	0	1	2	1	0	0	0	0	10	0	9	0	89,29	90,91
D2	0	0	263	0	0	0	1	0	0	3	0	1	0	9	0	3	93,93	91,96
D3	0	1	0	279	0	0	0	0	0	0	0	0	0	0	0	0	99,64	98,59
D4	0	0	2	0	263	3	2	1	7	1	0	0	0	0	0	1	93,93	96,16
D5	12	0	0	0	0	246	4	1	9	8	0	0	0	0	0	0	87,86	87,54
D6	3	0	0	0	0	4	253	1	14	5	0	0	0	0	0	0	90,36	87,39
D7	0	0	0	0	0	0	2	273	2	2	1	0	0	0	0	0	97,50	96,30
D8	4	0	0	0	0	7	12	6	226	20	0	0	5	0	0	0	80,71	77,40
D9	5	0	0	0	0	12	18	3	43	194	0	1	1	1	0	2	69,29	75,05
D10	0	1	0	0	0	0	0	0	0	0	277	0	2	0	0	0	98,93	98,75
D11	0	0	1	0	0	0	0	1	0	0	0	272	2	3	0	1	97,14	97,84
D12	0	4	0	0	0	0	0	0	0	0	2	0	267	0	7	0	95,36	90,66
D13	0	0	6	0	0	0	1	0	0	1	0	1	0	265	0	6	94,64	93,15
D14	0	14	0	0	0	0	0	0	0	0	1	0	22	0	243	0	86,79	90,00
D15	0	0	20	0	3	0	1	0	0	1	0	1	0	11	0	243	86,79	90,67

Tabela 25 – Matriz de confusão para os resultados de classificação utilizando VGG16 e imagens de GASF.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	$F1_{Score}$ (%)
D0	243	0	0	0	0	22	7	0	5	3	0	0	0	0	0	0	86,79	88,85
D1	0	256	0	2	0	0	0	0	0	1	0	0	6	0	15	0	91,43	91,10
D2	0	0	236	0	0	0	1	0	0	1	0	1	0	2	0	39	84,29	86,29
D3	0	0	0	279	0	0	0	0	0	0	0	0	1	0	0	0	99,64	99,47
D4	0	0	0	0	256	5	1	0	9	8	0	0	0	0	0	1	91,43	93,60
D5	14	0	0	0	0	229	6	0	19	12	0	0	0	0	0	0	81,79	83,12
D6	1	0	0	0	0	0	268	0	8	2	0	0	1	0	0	0	95,71	92,57
D7	0	0	0	0	0	0	1	273	3	3	0	0	0	0	0	0	97,50	98,20
D8	5	0	0	0	0	7	3	2	242	20	0	0	0	0	0	1	86,43	78,96
D9	4	0	0	0	1	8	1	1	47	215	0	1	0	0	0	2	76,79	78,90
D10	0	0	0	0	0	0	0	0	0	0	273	0	6	0	1	0	97,50	98,56
D11	0	0	0	0	0	0	0	0	0	0	0	273	0	0	0	7	97,50	97,67
D12	0	3	0	0	0	0	0	0	0	0	0	0	251	0	26	0	89,64	84,23
D13	0	0	1	0	0	0	8	0	0	0	0	0	0	264	0	7	94,29	96,00
D14	0	23	0	0	7	0	3	0	0	0	1	0	51	0	195	0	69,64	75,44
D15	0	0	30	0	3	0	0	0	0	0	0	4	0	4	0	239	85,36	82,99

Tabela 26 – Matriz de confusão para os resultados de classificação utilizando VGG16 e imagens de GADF.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	$F1_{Score}$ (%)
D0	269	0	0	0	0	4	1	0	6	0	0	0	0	0	0	0	96,07	93,73
D1	0	260	0	0	0	0	0	0	1	0	0	0	6	0	13	0	92,86	94,55
D2	0	0	232	0	0	0	0	0	0	6	0	0	0	2	0	40	82,86	87,55
D3	0	0	0	280	0	0	0	0	0	0	0	0	0	0	0	0	100,00	100,00
D4	4	0	0	0	258	1	3	0	7	4	0	0	0	0	0	3	92,14	94,33
D5	12	0	0	0	0	242	2	0	19	5	0	0	0	0	0	0	86,43	90,47
D6	1	1	0	0	0	1	260	0	12	4	0	0	1	0	0	0	92,86	93,69
D7	0	0	0	0	1	0	0	269	2	8	0	0	0	0	0	0	96,07	96,76
D8	3	0	0	0	1	4	1	5	232	34	0	0	0	0	0	0	82,86	74,36
D9	5	0	0	0	1	3	8	0	65	197	0	0	0	0	0	1	70,36	73,10
D10	0	0	0	0	0	0	0	0	0	0	277	0	0	0	3	0	98,93	99,28
D11	0	0	0	0	0	0	0	0	0	1	0	277	0	0	0	2	98,93	98,75
D12	0	1	0	0	0	0	0	0	0	0	1	0	266	0	12	0	95,00	85,53
D13	0	0	4	0	0	0	0	0	0	0	0	2	0	273	0	1	97,50	95,79
D14	0	8	0	0	0	0	0	2	0	0	0	0	69	0	201	0	71,79	78,98
D15	0	0	14	0	6	0	0	0	0	0	0	2	0	15	0	243	86,79	85,26

Tabela 27 – Matriz de confusão para o *ensemble* de classificação final referente aos dados de teste com SNR = 20dB.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	$F1_{Score}$ (%)
D0	68	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	97,14	90,67
D1	0	65	0	3	0	0	0	1	0	0	0	0	0	0	1	0	92,86	92,86
D2	0	0	58	0	0	0	0	0	1	0	0	0	0	0	0	11	82,86	89,92
D3	0	0	0	70	0	0	0	0	0	0	0	0	0	0	0	0	100,00	97,22
D4	0	0	0	0	61	3	2	0	4	0	0	0	0	0	0	0	87,14	86,52
D5	7	0	0	0	3	47	2	0	7	3	0	0	0	0	0	1	67,14	71,76
D6	2	1	0	0	1	2	56	0	3	4	0	0	0	1	0	0	80,00	84,21
D7	0	0	0	0	0	0	0	70	0	0	0	0	0	0	0	0	100,00	97,22
D8	1	0	0	0	2	3	1	1	58	3	0	0	0	0	0	1	82,86	72,05
D9	2	0	0	0	2	6	1	2	18	38	0	0	0	0	0	1	54,29	64,41
D10	0	0	0	0	0	0	0	0	0	0	70	0	0	0	0	0	100,00	100,00
D11	0	0	0	0	0	0	0	0	0	0	0	70	0	0	0	0	100,00	100,00
D12	0	0	0	0	0	0	0	0	0	0	0	0	68	0	2	0	97,14	95,77
D13	0	0	0	0	0	0	0	0	0	0	0	0	0	70	0	0	100,00	99,29
D14	0	4	0	1	1	0	0	0	0	0	0	0	4	0	60	0	85,71	90,23
D15	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	69	98,57	90,20

Tabela 28 – Matriz de confusão para o *ensemble* de classificação final referente aos dados de teste com SNR = 35dB.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	F1 _{Score} (%)
D0	62	0	0	0	1	6	0	0	1	0	0	0	0	0	0	0	88,57	92,54
D1	0	66	0	2	0	0	0	0	0	0	0	0	1	0	1	0	94,29	93,62
D2	0	0	61	0	0	0	0	0	0	0	0	0	0	0	0	9	87,14	91,73
D3	0	0	0	70	0	0	0	0	0	0	0	0	0	0	0	0	100,00	98,59
D4	0	0	0	0	69	0	1	0	0	0	0	0	0	0	0	0	98,57	96,50
D5	0	0	0	0	1	68	0	0	1	0	0	0	0	0	0	0	97,14	89,47
D6	0	0	0	0	0	1	65	0	2	2	0	0	0	0	0	0	92,86	94,89
D7	0	0	0	0	0	0	0	70	0	0	0	0	0	0	0	0	100,00	99,29
D8	0	0	0	0	0	5	0	0	63	2	0	0	0	0	0	0	90,00	88,11
D9	2	0	0	0	0	2	1	1	6	57	0	0	0	0	0	1	81,43	87,02
D10	0	0	0	0	0	0	0	0	0	0	70	0	0	0	0	0	100,00	100,00
D11	0	0	0	0	0	0	0	0	0	0	0	70	0	0	0	0	100,00	100,00
D12	0	1	0	0	0	0	0	0	0	0	0	0	69	0	0	0	98,57	94,52
D13	0	0	0	0	0	0	0	0	0	0	0	0	0	70	0	0	100,00	100,00
D14	0	4	0	0	0	0	0	0	0	0	0	0	6	0	60	0	85,71	91,60
D15	0	0	2	0	2	0	0	0	0	0	0	0	0	0	0	66	94,29	90,41

Tabela 29 – Matriz de confusão para o *ensemble* de classificação final referente aos dados de teste com SNR = 45dB.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	F1 _{Score} (%)
D0	65	0	0	0	1	4	0	0	0	0	0	0	0	0	0	0	92,86	96,30
D1	0	68	0	0	0	0	0	0	0	0	0	0	0	0	2	0	97,14	93,79
D2	0	0	63	0	0	0	0	0	0	1	0	0	0	0	0	6	90,00	91,97
D3	0	0	0	70	0	0	0	0	0	0	0	0	0	0	0	0	100,00	100,00
D4	0	0	0	0	69	1	0	0	0	0	0	0	0	0	0	0	98,57	96,50
D5	0	0	0	0	0	69	0	0	0	1	0	0	0	0	0	0	98,57	93,88
D6	0	0	0	0	0	2	66	0	1	1	0	0	0	0	0	0	94,29	97,06
D7	0	0	0	0	0	0	0	70	0	0	0	0	0	0	0	0	100,00	100,00
D8	0	0	0	0	0	1	0	0	69	0	0	0	0	0	0	0	98,57	94,52
D9	0	0	0	0	0	0	0	0	6	63	0	0	1	0	0	0	90,00	92,65
D10	0	0	0	0	0	0	0	0	0	0	70	0	0	0	0	0	100,00	100,00
D11	0	0	0	0	0	0	0	0	0	0	0	70	0	0	0	0	100,00	100,00
D12	0	1	0	0	0	0	0	0	0	0	0	0	69	0	0	0	98,57	97,87
D13	0	0	0	0	0	0	0	0	0	0	0	0	0	70	0	0	100,00	100,00
D14	0	6	0	0	0	0	0	0	0	0	0	0	1	0	63	0	90,00	93,33
D15	0	0	4	0	3	0	0	0	0	0	0	0	0	0	0	63	90,00	90,65

Tabela 30 – Matriz de confusão para o *ensemble* de classificação final referente aos dados de teste sem ruído.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	F1 _{Score} (%)
D0	69	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	98,57	99,28
D1	0	68	0	1	0	0	0	0	0	0	0	0	0	0	1	0	97,14	94,44
D2	0	0	63	0	0	0	0	0	0	0	0	0	0	0	0	7	90,00	92,65
D3	0	0	0	70	0	0	0	0	0	0	0	0	0	0	0	0	100,00	99,29
D4	0	0	0	0	70	0	0	0	0	0	0	0	0	0	0	0	100,00	98,59
D5	0	0	0	0	0	70	0	0	0	0	0	0	0	0	0	0	100,00	97,90
D6	0	0	0	0	0	0	67	0	1	2	0	0	0	0	0	0	95,71	97,81
D7	0	0	0	0	0	0	0	70	0	0	0	0	0	0	0	0	100,00	100,00
D8	0	0	0	0	0	1	0	0	69	0	0	0	0	0	0	0	98,57	94,52
D9	0	0	0	0	0	0	0	0	6	64	0	0	0	0	0	0	91,43	94,12
D10	0	0	0	0	0	0	0	0	0	0	70	0	0	0	0	0	100,00	100,00
D11	0	0	0	0	0	0	0	0	0	0	0	70	0	0	0	0	100,00	100,00
D12	0	1	0	0	0	0	0	0	0	0	0	0	68	0	1	0	97,14	97,84
D13	0	0	1	0	0	0	0	0	0	0	0	0	0	69	0	0	98,57	99,28
D14	0	5	0	0	0	0	0	0	0	0	0	0	1	0	64	0	91,43	94,12
D15	0	0	2	0	2	1	0	0	0	0	0	0	0	0	0	65	92,86	91,55

Tabela 31 – Matriz de confusão para o *ensemble* de classificação final referente aos dados de execução com SNR = 25dB.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	F1 _{Score} (%)
D0	20	0	0	0	0	3	0	0	1	0	0	0	0	0	0	0	83,333	83,333
D1	0	20	0	0	0	0	0	0	0	0	0	0	3	0	1	0	83,333	86,957
D2	1	0	18	0	0	0	0	0	0	0	0	0	0	0	0	5	75,000	81,818
D3	0	0	0	23	0	0	0	0	0	0	0	0	1	0	0	0	95,833	97,872
D4	0	0	0	0	18	0	1	0	5	0	0	0	0	0	0	0	75,000	81,818
D5	0	0	0	0	0	14	2	0	7	1	0	0	0	0	0	0	58,333	60,870
D6	0	0	0	0	0	0	20	0	2	1	0	0	0	1	0	0	83,333	85,106
D7	0	0	0	0	0	0	0	21	0	1	0	1	1	0	0	0	87,500	93,333
D8	1	0	0	0	0	3	0	0	19	1	0	0	0	0	0	0	79,167	61,290
D9	2	0	1	0	1	2	0	0	4	12	0	1	0	0	0	1	50,000	60,000
D10	0	0	0	0	0	0	0	0	0	0	24	0	0	0	0	0	100,000	100,000
D11	0	0	0	0	0	0	0	0	0	0	0	24	0	0	0	0	100,000	96,000
D12	0	0	0	0	0	0	0	0	0	0	0	0	24	0	0	0	100,000	87,273
D13	0	0	0	0	0	0	0	0	0	0	0	0	0	22	0	2	91,667	93,617
D14	0	2	0	0	0	0	0	0	0	0	0	0	2	0	20	0	83,333	88,889
D15	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	22	91,667	81,481

Tabela 32 – Matriz de confusão para o *ensemble* de classificação final referente aos dados de execução com SNR = 30dB.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	F1 _{Score} (%)
D0	21	0	0	0	0	2	0	0	1	0	0	0	0	0	0	0	87,50	76,36
D1	0	23	0	1	0	0	0	0	0	0	0	0	0	0	0	0	95,83	92,00
D2	0	0	16	0	0	0	1	0	1	1	0	0	0	0	0	5	66,67	80,00
D3	0	0	0	24	0	0	0	0	0	0	0	0	0	0	0	0	100,00	96,00
D4	1	0	0	1	17	0	1	0	3	0	0	0	0	0	0	1	70,83	75,56
D5	6	0	0	0	0	12	1	0	5	0	0	0	0	0	0	0	50,00	55,81
D6	0	0	0	0	0	0	15	0	1	4	0	0	1	3	0	0	62,50	71,43
D7	0	0	0	0	1	0	0	23	0	0	0	0	0	0	0	0	95,83	97,87
D8	3	0	0	0	0	3	0	0	17	1	0	0	0	0	0	0	70,83	56,67
D9	0	0	0	0	1	2	0	0	8	12	0	0	0	0	0	1	50,00	57,14
D10	0	0	0	0	0	0	0	0	0	0	23	0	1	0	0	0	95,83	97,87
D11	0	0	0	0	0	0	0	0	0	0	0	24	0	0	0	0	100,00	97,96
D12	0	0	0	0	0	0	0	0	0	0	0	0	24	0	0	0	100,00	90,57
D13	0	0	0	0	0	0	0	0	0	0	0	0	0	22	0	2	91,67	88,00
D14	0	3	0	0	2	0	0	0	0	0	0	0	3	0	16	0	66,67	80,00
D15	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	22	91,67	80,00

Tabela 33 – Matriz de confusão para o *ensemble* de classificação final referente aos dados de execução com SNR = 40dB.

	D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10	D11	D12	D13	D14	D15	Acc (%)	F1 _{Score} (%)
D0	23	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	95,83	93,88
D1	0	23	0	0	0	0	0	0	0	0	0	0	1	0	0	0	95,83	92,00
D2	0	0	20	0	0	0	1	0	0	1	0	0	0	0	0	2	83,33	86,96
D3	0	0	0	24	0	0	0	0	0	0	0	0	0	0	0	0	100,00	96,00
D4	0	0	0	0	24	0	0	0	0	0	0	0	0	0	0	0	100,00	97,96
D5	1	0	0	0	0	23	0	0	0	0	0	0	0	0	0	0	95,83	93,88
D6	0	0	0	0	0	1	22	0	0	1	0	0	0	0	0	0	91,67	93,62
D7	0	0	0	0	0	0	0	24	0	0	0	0	0	0	0	0	100,00	100,00
D8	1	0	0	0	1	0	0	0	20	2	0	0	0	0	0	0	83,33	85,11
D9	0	0	0	0	0	1	0	0	3	20	0	0	0	0	0	0	83,33	83,33
D10	0	0	0	1	0	0	0	0	0	0	23	0	0	0	0	0	95,83	97,87
D11	0	0	0	0	0	0	0	0	0	0	0	24	0	0	0	0	100,00	100,00
D12	0	0	0	0	0	0	0	0	0	0	0	0	23	0	1	0	95,83	95,83
D13	0	0	0	0	0	0	0	0	0	0	0	0	0	23	0	1	95,83	97,87
D14	0	3	0	0	0	0	0	0	0	0	0	0	0	0	21	0	87,50	91,30
D15	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	22	91,67	89,80