



ANÁLISE DO PROCESSO DE WAVELET SHRINKAGE NA EXTRAÇÃO DE
RUÍDO DE SINAIS DE DESCARGAS PARCIAIS E SEPARAÇÃO DOS
DEFEITOS ASSOCIADOS

Caio Fleming Ferreira de Carvalho Cunha

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Orientadores: Mariane Rembold Petraglia
André Tomaz de Carvalho

Rio de Janeiro
Janeiro de 2019

ANÁLISE DO PROCESSO DE WAVELET SHRINKAGE NA EXTRAÇÃO DE
RUÍDO DE SINAIS DE DESCARGAS PARCIAIS E SEPARAÇÃO DOS
DEFEITOS ASSOCIADOS

Caio Fleming Ferreira de Carvalho Cunha

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE)
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR
EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. Mariane Rembold Petraglia, Ph.D.

Prof. André Tomaz de Carvalho, D.Sc.

Prof. Antonio Carlos Siqueira de Lima, D.Sc.

Prof. Carlos Augusto Duque, D.Sc.

Prof. José Gabriel Rodriguez Carneiro Gomes, Ph.D.

RIO DE JANEIRO, RJ – BRASIL
JANEIRO DE 2019

Cunha, Caio Fleming Ferreira de Carvalho

Análise do Processo de Wavelet Shrinkage na Extração de Ruído de Sinais de Descargas Parciais e Separação dos Defeitos Associados/Caio Fleming Ferreira de Carvalho Cunha. – Rio de Janeiro: UFRJ/COPPE, 2019.

XXVIII, 259 p.: il.; 29, 7cm.

Orientadores: Mariane Rembold Petraglia

André Tomaz de Carvalho

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2019.

Referências Bibliográficas: p. 198 – 220.

1. Descargas Parciais. 2. Transformada Wavelet. 3. Limiarização. 4. Otimização. 5. Redução de Ruído. 6. Detecção de Polaridade. 7. Resposta em Frequência. 8. Extração de Características. 9. Separação por Agrupamento. I. Petraglia, Mariane Rembold *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

Não apenas pratique sua arte,
mas force seu caminho dentro de seus segredos,
pois isso e conhecimento
podem elevar o homem ao Divino.

Ludwig van Beethoven

*Dedico este trabalho aos meus
pais Carlos Roberto da Cunha e
Rosemira Ferreira de Carvalho
Cunha, à minha filha Laura
Corrêa Ferreira de Carvalho
Cunha e aos meus amigos.*

Agradecimentos

Por meio deste trabalho, que simboliza um grande desafio em minha vida pessoal e profissional, gostaria de agradecer à família, em especial à minha companheira e amiga Ana Paula Corrêa dos Santos, à minha filha Laura Corrêa Ferreira de Carvalho Cunha, ambas pela paciência e compreensão nos momentos em que fui incapaz de dar-lhes a merecida atenção, e aos meus pais, Carlos Roberto da Cunha e Rosemira Ferreira de Carvalho Cunha, que sempre fizeram o possível para me contemplar com uma educação de excelência, independente das dificuldades.

Agradeço muitíssimo aos meus orientadores, Mariane Rembold Petraglia e André Tomaz de Carvalho, pela confiança depositada e pelos conselhos dados, fundamentais para o desenvolvimento e a conclusão deste trabalho.

A concepção deste trabalho não teria sido possível sem o incentivo, as discussões e os conselhos providos pelo amigo Hélio Amorim Júnior, primordial na execução do mesmo, demonstro aqui minha gratidão. Com igual importância, fico grato aos amigos João Batista da Silva Borges e Thiago Batista Rodrigues pelo auxílio dado na obtenção de grande parte dos dados experimentais aqui utilizados.

Aos demais amigos de profissão, amigos pessoais e ex-companheiros de classe, que acreditaram e possibilitaram a conquista deste novo objetivo, meu muito obrigado.

Obrigado, também, a todos os demais professores da COPPE/UFRJ, com os quais tive a oportunidade de aprender muitos dos assuntos abordados nesta pesquisa.

Por último, aos demais membros da banca. Declaro-me honrado pela participação na avaliação do meu trabalho.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

ANÁLISE DO PROCESSO DE WAVELET SHRINKAGE NA EXTRAÇÃO DE
RUÍDO DE SINAIS DE DESCARGAS PARCIAIS E SEPARAÇÃO DOS
DEFEITOS ASSOCIADOS

Caio Fleming Ferreira de Carvalho Cunha

Janeiro/2019

Orientadores: Mariane Rembold Petraglia
André Tomaz de Carvalho

Programa: Engenharia Elétrica

Neste trabalho lidamos com o processamento digital de sinais relacionados ao fenômeno de descargas parciais (DP), que se manifesta em equipamentos de alta tensão. Inicialmente, no campo de extração de ruído utilizando a transformada wavelet, novas funções de limiarização otimizadas são propostas para tratar os coeficientes wavelet dos pulsos de DP, que apresentaram resultados superiores às diversas funções comumente aplicadas. Além disso, os desempenhos de diferentes combinações de funções wavelet-mãe na filtragem de DP são verificados. Posteriormente, atenção especial é dada ao método de separação de padrões por função de autocorrelação normalizada (NACF), obtendo um melhor desempenho em relação à proposta original. Também descrevemos o projeto de um sistema de análise e separação de dados de DP. Além das técnicas habituais de processamento de sinais, o sistema engloba uma nova técnica de identificação de polaridade de pulso baseada no coeficiente de correlação entre o pulso avaliado e um pulso padrão, proporcionando um ganho expressivo na qualidade do mapa de DP discriminado por fase (PRPD) gerado em uma medição. Além disso, é apresentado um método para estimar a resposta em frequência de todo o sistema de medição, desde sua origem até o *hardware* de aquisição, uma alternativa que apresentou resultados promissores. O sistema também possui um conjunto de técnicas para extrair características dos sinais a ele apresentados, para posterior separação com métodos de agrupamento, permitindo a comparação entre eles.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

ANALYSIS OF THE WAVELET SHRINKAGE PROCESS IN PARTIAL
DISCHARGE SIGNALS DENOISING AND SEPARATION OF THE
ASSOCIATED DEFECTS

Caio Fleming Ferreira de Carvalho Cunha

January/2019

Advisors: Mariane Rembold Petraglia
André Tomaz de Carvalho

Department: Electrical Engineering

In this work we deal with the digital processing of signals related to the phenomenon of partial discharges (PD), which manifests itself in high voltage equipment. Initially, in the field of noise extraction using the wavelet transform, new optimized thresholding functions are proposed to treat the wavelet coefficients of the PD pulses, which presented superior results compared to those obtained with several functions commonly applied. In addition, the performances of different combinations of mother-wavelet functions in PD filtering are verified. Subsequently, special attention is given to the pattern separation method by normalized autocorrelation function (NACF), obtaining a better performance in relation to the original proposal. We also describe the design of a PD data analysis and separation system. In addition to the usual signal processing techniques, the system includes a new pulse polarity identification technique based on the correlation coefficient between the evaluated pulse and a standard pulse, providing an expressive gain in the quality of the phase resolved partial discharge (PRPD) map generated in a measurement. In addition, a method is presented to estimate the frequency response of the whole measurement system, from its origin to the acquisition hardware, an alternative that presented promising results. The system also has a set of techniques to extract characteristics of the signals presented to it, for later separation with clustering methods, allowing the comparison between them.

Sumário

Lista de Figuras	xii
Lista de Tabelas	xxii
Lista de Abreviaturas	xxiii
1 Introdução	1
1.1 Considerações Iniciais e Justificativas	1
1.2 Objetivos	7
1.3 Metodologia	7
1.4 Resultados e Contribuições	10
1.4.1 Trabalhos Publicados e em Desenvolvimento	12
1.4.2 Citações aos Trabalhos Publicados	13
1.5 Organização Textual	13
2 Descargas Parciais	16
2.1 Conceitos de Descargas Parciais	16
2.2 Causas e Efeitos de Descargas Parciais	17
2.3 Classificação dos Tipos de DP	18
2.3.1 Descargas Externas	19
2.3.2 Descargas Internas	20
2.3.3 Descargas Superficiais	22
2.4 Medições de DP	23
2.4.1 Padrão PRPD	24
2.4.2 Histogramas	25
2.4.3 Análises de Tendência	25
2.5 Ruído Característico em Medições de DP	27
3 Transformada Wavelet Aplicada à Extração de Sinais de Descargas Parciais Imersos em Ruído	31
3.1 Processo Wavelet de Redução de Ruído	32

3.2	Características das Diferentes Transformadas Wavelets	34
3.2.1	Transformada Wavelet Contínua (CWT)	34
3.2.2	Transformada Wavelet Rápida (FWT)	35
3.3	Funções Wavelet Aplicáveis no Processamento de Pulsos de DP . . .	37
3.4	Métodos para Determinação do Número de Níveis de Decomposição .	40
3.5	Métodos de Seleção das Bases Wavelet (Filtros de Decomposição) . .	44
3.6	Processo de Limiarização Wavelet	47
3.6.1	Fator de Reescala (Desvio Padrão do Ruído)	49
3.6.2	Métodos de Estimação do Valor de Limiar	50
3.6.3	Funções de Limiarização	53
4	Métodos de Classificação de Descargas Parciais	56
4.1	Extração de Características de sinais de DP	57
4.1.1	Operadores Estatísticos	58
4.1.2	Características de Localização Tempo e Frequência	60
4.1.3	Característica Weibull da Curva PHA	61
4.1.4	Mapeamento <i>Power Ratio</i>	61
4.1.5	Análise de Componentes Principais	62
4.1.6	Análise de Componentes Principais Kernel (KPCA)	63
4.1.7	Análise de Componentes Principais Alternativas	64
4.1.8	Incorporação Estocástica de Vizinhos (<i>Stochastic Neighbor Embedding - SNE</i>)	64
4.1.9	Técnicas de Redução de Dimensionalidade (MDS)	65
4.2	Métodos de Classificação	66
4.3	Métodos de Classificação Não Supervisionada	67
4.3.1	K-means	67
4.3.2	Gaussian Mixture Model	69
4.3.3	Hierárquico	70
4.3.4	Agrupamento Baseado na Função Autocorrelação Normali- zada	70
5	Limiarização Wavelet Destinada ao Tratamento de Sinais de DP	74
5.1	Função de Limiarização Fleming	74
5.2	Identificação dos Coeficientes Wavelet Relevantes	79
5.3	Busca da Constante de Inclinação da Função Fleming pela Mini- mização do seu Risco SURE	83
5.4	Critério de Avaliação de Filtragem Wavelet em Sinais de Descargas Parciais	88
6	Aperfeiçoamento do Método de Separação de Padrões de Descargas	

Parciais pela Função Autocorrelação Normalizada	90
6.1 Modificações Implementadas no Método de Separação NACF	90
7 Sistema de Análise e Separação de Dados de Descargas Parciais	98
7.1 Correção de Polaridade no Mapa PRPD	99
7.2 Estimativa da Resposta em Frequência do Sistema de Medição a partir dos Pulsos de Descargas Parciais	105
7.3 Estrutura de Processamento do Sistema de Análise de Descargas Parciais	114
7.4 Filtragem por caixa de <i>pixels</i>	116
8 Simulações e Avaliação dos Resultados	119
8.1 Banco de Dados Criado com Medições de Descargas Parciais	120
8.2 Avaliação da Função de Limiarização Fleming no Processo Wavelet de Redução de Ruído	125
8.2.1 Comparação entre as Funções de Limiarização Fleming	126
8.2.2 Comparação entre as Funções de Limiarização Fleming, <i>Hard</i> e <i>Soft</i>	131
8.2.3 Comparação entre Todas as Funções de Limiarização	135
8.3 Avaliação das Funções Wavelet	142
8.4 Resultados da Nova Técnica de Identificação de Polaridade de Pulsos	144
8.5 Validação do Método de Estimativa da Resposta em Frequência do Sistema Medido	149
8.6 Avaliação do Sistema de Análise e Separação de Dados de Descargas Parciais	156
8.6.1 Avaliação das Funcionalidades do Sistema de Análise	170
8.6.2 Exemplos de Caracterização e Separação dos Padrões de Descargas Parciais	180
9 Conclusões e Sugestões de Trabalhos Futuros	189
9.1 Sugestões de Trabalhos Futuros	196
Referências Bibliográficas	198
A Circuitos Aplicados nas Medições de Descargas Parciais	221
A.1 Circuito de Medição Padrão para DP	221
A.2 Impedância de Medição	223
A.3 Filtro Passa Altas	224
A.4 Atenuador	224
B Estrutura de Processamento do Sistema de Análise e Separação de	

Descargas Parciais	227
B.1 Leitura de Dados	227
B.1.1 Sincronização	228
B.2 Filtragem Digital	230
B.3 Identificação de Pulsos por cruzamento de limiar	233
B.3.1 Comprimento do Pulso Janelado	234
B.3.2 Matriz de Dados	235
B.4 Apresentação de Dados	236
B.4.1 PRPD Clássico e <i>Fingerprints</i>	237
B.4.2 Visualização da Extração de Características	238
B.4.3 Separação de Padrões de DP em Classes	243
B.4.4 Análise Pulso a Pulso	247
B.4.5 Separação em Submapas PRPD	248
B.4.6 Pulso Médio	250
B.4.7 Espectro de Potência Médio	252
B.4.8 Estimativa de Resposta em Frequência Normalizada (<i>Max</i> <i>Min Hold FFT</i>)	252
B.5 Ferramentas Gráficas e Gerador de Relatórios	253
B.6 Interfaces do Sistema	254
B.6.1 Interface Principal	254
B.6.2 Interface de Análise Pulso a Pulso	255
B.6.3 Interface de Separação	255
C Características Construtivas das Células de Carga	257

Lista de Figuras

2.1	Descarga externa: (a) modelo de corona no lado de baixa tensão; (b) modelo de corona no lado de alta; (c) corona real produzida por uma agulha no lado de alta tensão. Fonte: [109]	19
2.2	Descarga interna: (a) DP guia (<i>leader</i>) em óleo; Fonte: [102]; (b) arborescência em polimetilmetacrilato (PMMA). Fonte: [111].	20
2.3	Modelo de descargas internas.	21
2.4	Fotografia da seção transversal de uma barra estatórica, onde se observam delaminações internas no isolamento. Fonte: [44]	21
2.5	Modelo de descargas superficiais.	22
2.6	Exemplos de danos causados por descargas superficiais: (a) deterioração do isolamento de cabos com descargas de superfície entre fases; (b) trilhamento em cabo; (c) erosão em disjuntor encapsulado em resina.	22
2.7	Histograma PRPD Bipolar apresentado na forma: (a) 2D; (b) 3D. Fonte: [44]	24
2.8	Histogramas de uma medição de DP: (a) PRPD medido (b) $H_n(q)$; (c) $H_n(\varphi)$; (d) $H_{qave}(\varphi)$; (e) $H_{qmax}(\varphi)$.	26
2.9	Exemplo de visualização de tendência da amplitude de DP.	27
2.10	Exemplo de medição de DP com a presença de ruído.	29
3.1	Processo de redução de ruído pela WT.	33
3.2	FWT aplicada na extração de ruídos de DP: (a) sinal de DP medido em laboratório; (b) sinal de DP filtrado.	33
3.3	Exemplo de filtragem wavelet por FWT em 3 níveis de um sinal $x(t)$ (neste caso um sinal de DP com ruído).	38
3.4	Procedimento proposto em [153] para determinar o número de níveis de decomposição.	42
3.5	Fluxograma do algoritmo NWDLS.	42
3.6	Exemplo do procedimento de seleção do número de níveis de decomposição: (a) Sinal de DP medido; (b) Espectro de potência do sinal.	43

3.7	Valor da função custo para diferentes métodos de seleção wavelet (CBWS, EBWS, SNRBWS, MEBWS) versus número de níveis de decomposição. Fonte: [37]	44
3.8	Função de limiarização para $\lambda = 0, 4$: (a) suave; (b) abrupta.	54
5.1	Função Logística.	76
5.2	Comportamento da função de limiarização Fleming para $\lambda = 1$.	77
5.3	Comportamento da função de limiarização Fleming $\lambda = 0.05$.	78
5.4	Comportamento da função de limiarização Fleming adaptada ($\lambda = 0.05$).	79
5.5	Coefficientes wavelets e histogramas de um pulso real de DP: (a) primeiro coeficiente de detalhe (curtose = 2.9687); (b) sexto coeficiente de detalhe (curtose = 9.9612).	80
5.6	Sinal de DP decomposto em sub-bandas wavelet de detalhe e aproximação final (a esquerda) e seus respectivos histogramas (a direita). Em vermelho o sinal contaminado com ruído e em azul o sinal original. Fonte: [42]	81
5.7	Comportamento da função Fleming e suas derivadas em relação a λ .	85
5.8	Comportamento da função Fleming e suas derivadas em relação a c .	86
5.9	Evolução do risco SURE, sua derivada parcial para a constante c e da constante $c = 1/f$: (a) coeficientes de detalhe d_3 ; (b) coeficiente de detalhe d_5 ; (c) coeficiente de aproximação a_6 .	87
6.1	NACF gerado para pulso de DP: (a) Pulso de DP medido, (b) Equação (4.22), (c) Equação (6.3), (d) Equação (6.4).	92
6.2	Comparação entre métricas de distância da NACF: (a) todos os 866 pulsos de DP, (b) visão aproximada com os primeiros 25 pulsos de DP.	94
6.3	Exemplo de separação pelo método NACF: (a) PRPD medido; (b) PRPD separados com seus respectivos pulsos médios. O coeficiente de correlação entre as classes é $p_{c_{1,2}} = 0.5881$, $p_{c_{1,3}} = 0.6369$ e $p_{c_{2,3}} = 0.9375$.	96
6.4	Fluxograma do método de agrupamento de mapas PRPD por similaridade de pulso médio.	97
7.1	Exemplos de pulsos de DP.	101
7.2	Processo de identificação de polaridade de um pulso de DP.	104
7.3	Histograma PRPD: (a) usando o método tradicional de identificação de polaridade; (b) usando o novo método de identificação de polaridade.	104
7.4	Pulso de DP identificado como pulso negativo pelo segundo método.	105

7.5	Exemplo de rastreamento da resposta em frequência usando um analisador de espectro na função e um gerador de funções para realizar a varredura de frequência. <i>Max Hold</i> . Fonte: [189]	106
7.6	Representação de um sistema no tempo contínuo.	106
7.7	(a) DFT Normalizada de todos os pulsos detectados; (b) DFT normalizada para a retenção de máximo (RF estimada), retenção de mínimo e média.	109
7.8	Processo de reconstrução do sinal de DP a partir da RF estimada: (a) RF estimada e normalizada $H'_N(e^{j\omega})$ com um exemplo de sinal de DP estimado $x'_N[n]$; (b) sinal de DP estimado normalizado $x'_N[n]$ (ampliado); (c) sinal de DP de saída $y'[n]$ estimado a partir da convolução $x'_N[n]*h'_N[n]$; (d) comparação entre o sinal de saída estimado $y'[n]$ com o sinal de saída adquirido $y[n]$ (coeficiente de correlação de 0.9621).	112
7.9	Processo de reconstrução do sinal de DP: (a) RF estimada e normalizada $H'_N(e^{j\omega})$ com um exemplo de sinal de DP estimado normalizado $x'_N[n]$; (b) sinal de DP estimado $x'_N[n]$ (ampliado); (c) sinal de DP de saída $y'[n]$ estimado a partir da convolução $x'_N[n]*h'_N[n]$; (d) comparação entre o sinal de saída estimado $y'[n]$ com o sinal de saída adquirido $y[n]$ (coeficiente de correlação de 0.0334).	113
7.10	Estrutura de processamento do sistema de análise e separação de dados de DP.	114
7.11	Fluxograma para algoritmo de filtragem por caixa de <i>pixels</i>	117
7.12	Ilustração do comportamento da filtragem por caixa de <i>pixel</i> em um PRPD Clássico obtido a partir de uma medição.	118
7.13	Mapas PRPD gerados após a filtragem por caixa de <i>pixels</i> com tamanho: (a) 10×10 ; (b) 5×5 ; (c) 3×3 ; (d) 2×2	118
8.1	Todas as células de carga conectadas em paralelo.	121
8.2	Componentes do circuito: (a) Controle da Fonte de AT; (b) Fonte de AT; (c) Filtro de AT; (d) Capacitor de acoplamento 437 pF e impedância de medição Z_m (caixa metálica).	122
8.3	Sensores utilizados: (a) HFCT; (b) Antena Monopolo.	123
8.4	Circuitos ensaiados em laboratório: (a) todas as células em paralelo; (b) barra B1; (c) célula C4; (d) todas as barras em paralelo; (e) célula C6;	124

8.5	Detecção de DP usando câmera UV (Deycor): (a) descarga corona na célula C1 sob tensão de 18 kV; (b) descarga de superfície na célula C4 sob tensão de 17 kV; (c) descarga de superfície na barra B1 sob tensão de 18 kV (estimulada por contaminação com carbono); (d) descarga entre barras cruzadas do mesmo modelo da barra B1 sob tensão de 8 kV (barra superior em alta tensão e barra inferior aterrada pelos terminais de conexão e não pela malha que envolve o revestimento isolante)	125
8.6	Resultados de melhor filtragem obtida entre as funções Fleming com constante de inclinação $c = 5$	131
8.7	Comparação de resultados de melhor filtragem obtida entre as funções Fleming, <i>hard</i> e <i>soft</i>	132
8.8	Comparação de resultados de melhor filtragem obtida entre as todas as funções Fleming, <i>a hard</i> e <i>a soft</i>	133
8.9	Comparação de resultados de melhor filtragem obtida entre a função Fleming, <i>a hard</i> e <i>a soft</i>	133
8.10	Comparação de resultados de melhor filtragem obtida entre a função Fleming 2, <i>a hard</i> e <i>a soft</i>	134
8.11	Comparação de resultados de melhor filtragem obtida entre a função Fleming 3, <i>a hard</i> e <i>a soft</i>	134
8.12	Comparação de resultados de melhor filtragem obtida entre a função Fleming 2 LMS, <i>a hard</i> e <i>a soft</i>	135
8.13	Comparação de resultados de melhor filtragem obtida entre a função Fleming 3 LMS, <i>a hard</i> e <i>a soft</i>	135
8.14	Exemplo 1 de filtragem wavelet para as diferentes funções de limiarização em um sinal de DP simulado.	140
8.15	Exemplo 2 de filtragem wavelet para as diferentes funções de limiarização em um sinal de DP medido.	141
8.16	Comparação de resultados de melhor filtragem obtida para diferentes bibliotecas wavelet com cada função de limiarização.	144
8.17	Comparação entre mapas PRPD obtidos na medição de um gerador: (a) gerado pelo método tradicional de identificação de polaridade; (b) gerado pelo novo método de identificação de polaridade.	145
8.18	Verificação de pulsos: (a) pulso selecionado no PRPD usando o método tradicional; (b) pulso negativo erroneamente atribuído como positivo pelo método tradicional; (b) pulso selecionado no PRPD gerado pelo novo método; (d) pulso negativo corretamente atribuído como negativo pelo novo método.	145

8.19	Comparação entre mapas PRPD obtidos na medição de um gerador: (a) gerado pelo método tradicional de identificação de polaridade; (b) gerado pelo novo método de identificação de polaridade.	146
8.20	Verificação de pulsos: (a) pulso selecionado no PRPD usando o método tradicional; (b) pulso negativo erroneamente atribuído como positivo pelo método tradicional; (b) pulso selecionado no PRPD gerado pelo novo método; (d) pulso negativo erroneamente atribuído como positivo pelo novo método	147
8.21	Comparação entre mapas PRPD obtido na medição de um gerador: (a) gerado pelo método tradicional de identificação de polaridade; (b) gerado pelo novo método de identificação de polaridade.	148
8.22	Verificação de pulsos: (a) pulso selecionado no PRPD usando o método tradicional; (b) pulso negativo erroneamente atribuído como positivo pelo método tradicional; (b) pulso selecionado no PRPD gerado pelo novo método; (d) pulso negativo corretamente atribuído como negativo pelo novo método.	148
8.23	Barra estatórica ensaiada em laboratório.	149
8.24	Programa em LabVIEW para cálculo a parâmetros distribuídos em cabos coaxiais.	150
8.25	Circuito de medição de DP aplicado em laboratório.	150
8.26	Circuito de medição de DP com impedância e filtro PA: (a) Bode de módulo saída DP; (b) Bode de fase saída DP; (c) Bode de módulo saída sincronismo com DP ; (d) Bode de fase saída sincronismo com DP.	151
8.27	Circuito de medição de DP com impedância (filtro PA foi retirado do circuito mostrado na Figura 8.25) e cabo coaxial com 4.60 m de comprimento: (a) Bode de módulo; (b) Bode de fase.	152
8.28	Pulso de DP simulado no gerador de formas de onda arbitrárias. . .	153
8.29	Pulsos medidos no canais A (azul) e B (vermelho) do osciloscópio. .	153
8.30	Resposta em frequência real do circuito: (a) para a saída da impedância; (b) para a saída do filtro PA.	154
8.31	Resposta em frequência real do circuito para a saída da impedância sem ter o filtro PA acoplado.	154
8.32	Resposta em frequência real do circuito: (a) saída da impedância com o filtro PA acoplado; (b) saída do filtro PA.	155
8.33	Resposta em frequência real do circuito para a saída da impedância sem ter o filtro PA acoplado.	156
8.34	Resultados para medição com 744 pulsos: (a) tempo médio; (b) índice de Dunn.	161

8.35	Resultados de separação para medição de célula de carga usando método K-means na característica extraída: (a) Tempo x Frequência; (b) Parâmetro Weibull; (c) PRPD separado pelo método Tempo x Frequência; (d) PRPD separado pelo método Parâmetro Weibull. . . .	162
8.36	Resultados para medição com 2670 pulsos: (a) tempo médio; (b) índice de Dunn.	163
8.37	Resultados de separação para medição de um hidrogerador com o uso do método K-means na característica extraída: (a) Tempo x Frequência; (b) Parâmetro Weibull; (c) PRPD separado pelo método Tempo x Frequência; (d) PRPD separado pelo método Parâmetro Weibull.	164
8.38	Resultados para medição com 5783 pulsos: (a) tempo médio; (b) índice de Dunn.	165
8.39	Resultados para diferentes valores de limiar: tempo de processamento para tamanho mínimo igual a (a) 100 e (b) 300.	168
8.40	Resultados para diferentes valores de limiar: índice de Dunn para tamanho mínimo igual a (c) 100 e (d) 300.	169
8.41	Resultados para diferentes valores de limiar: número de classes para tamanho mínimo igual a (a) 100 e (b) 300.	170
8.42	Exemplos de correção de polaridade dos pulsos no mapa PRPD: (a) Medição da célula C6 usando o método convencional; (b) Medição da célula C6 usando o método proposto; (c) Medição de gerador a diesel usando o método convencional; (d) Medição de gerador a diesel usando o método proposto; (e) Medição de hidrogerador usando o método convencional; (f) Medição de hidrogerador usando o método proposto.	171
8.43	Medição de barra estatórica 3: (a)sem filtragem por pixel; (b) com filtragem por pixel para caixa de tamanho 3x3; (c) com filtragem por pixel para caixa de tamanho 5x5; com filtragem por pixel para caixa de tamanho 7x7;.	173
8.44	Separação da medição de barra estatórica 3: (a)sem filtragem por pixel; (b) com filtragem por pixel para caixa de tamanho 3x3; (c) com filtragem por pixel para caixa de tamanho 5x5; com filtragem por pixel para caixa de tamanho 7x7.	174

8.45	Respostas em frequência estimadas para a célula C6 avaliada em laboratório: (a) PRPD clássico; (b) RF estimada sem a separação dos pulsos; (c) PRPD dos padrões de pulsos separados; (d) RF estimadas após a separação dos pulsos; (e) RF estimada sem a separação dos pulsos com o uso do filtro digital PB Butterworth; (f) RF estimada após a separação dos pulsos com o uso do filtro digital PB Butterworth.	175
8.46	Respostas em frequência estimadas para a célula C6 avaliada em laboratório através do canal B que recebe o sinal proveniente da impedância de medição: (a) PRPD clássico; (b) RF estimada sem a separação dos pulsos; (c) PRPD dos padrões de pulsos separados; (d) RF estimadas após a separação dos pulsos; (e) RF estimada sem a separação dos pulsos com o uso do filtro digital PB Butterworth; (f) RF estimada após a separação dos pulsos com o uso do filtro digital PB Butterworth.	176
8.47	Filtragem PRPD para medição da célula C4: PRPD clássico filtrado com Butterworth; (b) Característica Tempo x Frequência separada pelo método GMD; (c) PRPD clássico filtrado com Butterworth e WT; (d) Característica Tempo x Frequência separada pelo método GMD.	177
8.48	Filtragem PRPD para medição de um hidrogerador: (a) PRPD clássico filtrado com Butterworth; (b) Característica Tempo x Frequência separada pelo método GMD; (c) PRPD clássico filtrado com Butterworth e WT; (d) Característica Tempo x Frequência separada pelo método GMD.	178
8.49	Exemplo de um ciclo medido (azul) submetido a filtragem digital Butterworth (verde) e a filtragem wavelet (vermelho).	179
8.50	PRPD gerado para LD igual a 10 mV: (a) sem filtragem wavelet; (b) com filtragem wavelet.	179
8.51	Resultado de separação de medição na fase B do hidrogerador: (a) PRPD clássico; (b) Característica PCA da FFT 2D separada; (c) PRPD separado em classes; (d) Pulso centroide de cada classe; (e) FFT centroide de cada classe.	181
8.52	Resultado de separação de medição na fase C do hidrogerador:(a) PRPD clássico; (b) Característica PCA da FFT 2D separada; (c) PRPD separado em classes; (d) Pulso centroide de cada classe; (e) FFT centroide de cada classe.	182

8.53	Resultado de separação de medição na fase B de um gerador a diesel: (a) PRPD clássico; (b) Característica Tempo x Frequência separada; (c) PRPD separado em classes; (d) Pulso centroide de cada classe; (e) FFT centroide de cada classe.	183
8.54	Resultado de separação de medição de um TC em uma subestação:(a) PRPD clássico; (b) Característica t-SNE 2D separada; (c) PRPD separado em classes; (d) Pulso centroide de cada classe; (e) FFT centroide de cada classe.	185
8.55	Resultado de separação de medição de um TC em uma subestação (sem ruído AM):(a) PRPD clássico; (b) Característica t-SNE 2D se- parada; (c) PRPD separado em classes; (d) Pulso centroide de cada classe; (e) FFT centroide de cada classe.	186
8.56	Resultado de separação de medição das células C3 e C5 em paralelo: (a) PRPD clássico; (b) Característica Tempo x Frequência separada; (c) PRPD separado em classes; (d) Pulso centroide de cada classe; (e) FFT centroide de cada classe.	187
A.1	Circuito de medição de DP com impedância de medição Z_m em série com capacitor de acoplamento C_k	222
A.2	Circuito de medição de DP com impedância de medição Z_m em série com o objeto de teste C_a	222
A.3	Circuito da impedância de medição Z_m aplicada nas medições em laboratório e em geradores.	223
A.4	Circuito do Filtro PA com frequência e corte em 300 kHz.	224
A.5	Resposta em frequência para o Filtro PA: (a) simulada; (b) medida.	225
A.6	Circuito atenuador com relação 10:1.	225
A.7	Resposta em frequência para o atenuador: (a) simulada; (b) medida.	226
B.1	Mapas PRPD obtidos para diferentes defasagens de sincronismo: (a) 0° ; (b) -90° ; (c) $+90^\circ$	229
B.2	Pulsos e seus respectivos espectro de potência: (a) DP; (b) ruído pulsante.	230
B.3	Pulsos de DP filtrados com filtro passa banda para suprimir ruído: (a) Butterworth de 6ª ordem; (b) Butterworth de 6ª ordem com can- celamento de Fase.	231
B.4	Pulsos de DP filtrados com filtro passa banda para suprimir ruído: (a) sem filtrar; (b) filtrado.	232
B.5	Sinal processado e limiar de ruído (LD) para a detecção dos pulsos de DP, definido automaticamente. Fonte: [44]	234

B.6	Pulsos de tiristor e de DP janelados com: (a) 300 amostras; (b) 1000 amostras.	235
B.7	Apresentação de dados de DP: (a) PRPD Clássico; (b) Histograma de Amplitude - Distribuição do número de descargas sobre a amplitude; (c) Histograma de Máxima Amplitude - Distribuição da máxima amplitude das descargas sobre a fase; (d) Histograma de Amplitude Média - Distribuição da amplitude média das descargas sobre a fase; (e) Histograma de Fase - Distribuição do número de descargas sobre a fase.	237
B.8	Visualização de características extraídas: (a) Tempo x Frequência; (b) PCA 2D; (c) PCA Kernel 2D; (d) PCA Kernel Gaussiana 2D; (e) E-PCA 2D; (f) PPCA 2D; (g) PCA 3D; (h) PCA Kernel 3D.	239
B.9	Visualização de características extraídas: (a) PCA Kernel Gaussiana 3D; (b) E-PCA 3D; (c) PPCA 3D; (d) PCA da FFT 2D; (e) PCA Kernel da FFT 2D; (f) PCA Kernel Gaussiana da FFT 2D; (g) E-PCA da FFT 2D; (h) PPCA da FFT 2D.	240
B.10	Visualização de características extraídas: (a) PCA da FFT 3D; (b) PCA Kernel da FFT 3D; (c) PCA Kernel Gaussiana da FFT 3D; (d) E-PCA da FFT 3D; (e) PPCA da FFT 3D; (f) <i>Power Ratio</i>	241
B.11	Escolha automática do número de classes usando o critério Silhouette: (a) Valor Silhouette de 2 até 6 classes; (b) Característica PCA Simples dividida em 3 classes;	242
B.12	Método de seleção manual de classes: (a) PCA da FFT 2D obtida; (b) Início da seleção poligonal da 1ª classe; (c) Seleção poligonal da 1ª classe; (d) Seleção poligonal da 2ª classe; (e) Característica PCA da FFT separada; (f) PRPD separado por cor.	245
B.13	Exemplos de separação da característica PCA simples da FFT dos sinais de DP: (a) K-means ++; (b) K-medoid CLARA; (c) Fuzzy C-means; (d) Hierárquico; NACF K-means; (f) GMD.	246
B.14	Análise pulso a pulso: (a) seleção do pulso no mapa PRPD distinguido por cor; (b) visualização na janela de análise do pulso selecionado.	247
B.15	Salvando pulso analisado em diretórios organizados por: (a) tipo de equipamento que foi medido; (b) polaridade do pulso visualizado.	248
B.16	Exemplo de separação de uma medição de DP: (a) PRPD clássico; (b) Característica Tempo x Frequência separada em cor pelo método GMD; (c) Tela de separação com submapas PRPD separados.	249
B.17	PRPD separados com: (a) mesma escala; (b) escala distinta.	250

B.18	(a) Separação da característica extraída dos pulsos de DP; (b) mapas PRPD separados; (c) pulsos médios correspondentes aos mapas separados.	251
B.19	Espectros de potência médios para os PRPD mostrados a Figura B.18(b).	252
B.20	Comparação entre RF estimada sem uso de filtro digital e com uso de filtro digital passa banda Butterworth (1 MHz - 40 MHz).	253
C.1	Projeto estrutural padrão das células de carga.	258
C.2	Células de carga desenvolvidas para análise de defeitos ligados a DP: (a) C1; (b) C2; (c) C3; (d) C4; (e) C5; (f) C6.	259

Lista de Tabelas

4.1	Estatísticas dos espectros PRPD.	59
6.1	Comparação entre Métricas de Distância.	94
8.1	Valores Médios dos Parâmetros de Avaliação para cada Função de Limiarização Considerando os Melhores Resultados para cada Sinal em Diversos Valores de Constante de Inclinação.	127
8.2	Percentual de Melhores Resultados para cada Sinal em Diversos Valores de Constante de Inclinação definidos para as Funções de Limiarização Fleming.	129
8.3	Comparação Percentual de Melhores Resultados entre Funções Fleming por Constante de Inclinação.	130
8.4	Comparação do Valor Médio de J_{Apt} entre Funções Fleming por Constante de Inclinação.	130
8.5	Resultado Médio dos Parâmetros de Avaliação para todas as Funções de Limiarização.	137
8.6	Resultado Médio dos Parâmetros de Avaliação para todas as Funções de Limiarização (continuação).	138
8.7	Resultado Percentual dos Parâmetros de Avaliação para Todas as Funções de Limiarização.	139
8.8	Comparação entre Diferentes Bibliotecas de Funções Wavelet Empregadas na Decomposição dos Sinais de DP.	143
8.9	Tempo Médio dos Métodos de Extração de Características para Medições com Menos de 1000 Pulsos Detectados.	158
8.10	Tempo Médio dos Métodos de Extração de Características para Medições com Mais de 1000 Pulsos Detectados.	159

Lista de Abreviaturas

2D	2 Dimensões, p. 62
3CFRD	3 Center Frequency Relation Diagram - Diagrama de Relação de Frequência em 3 Canais, p. 24
3D	3 Dimensões, p. 62
3PARD	3 Phase Amplitude Relation Diagram - Diagrama de Relação de Amplitude em 3 Fases, p. 24
3PTRD	3 Phase Time Relation Diagram - Diagrama de Relação de Tempo em 3 Fases, p. 24
ABC	Artificial Bee Colony - Colonização Artificial por Abelhas, p. 55
AC	Alternated Current - Corrente Alternada, p. 24
ACF	Autocorrelation Function - Função Autocorrelação, p. 70
AG	Algoritmo Genético, p. 4
AM	Amplitude Modulada, p. 28
ANEEL	Agência Nacional de Energia Elétrica, p. 1
AT	Alta Tensão, p. 5
CBWS	Correlation Based Wavelet Selection - Seleção da Wavelet Baseada na Correlação, p. 4
CC	Coefficiente de Correlação, p. 45
CLARA	Clustering LARge Applications - Agrupamento para Aplicações Amplas, p. 69

CWT	Continuous Wavelet Transform - Transformada Wavelet Contínua, p. 2
DBSCAN	Density Based Spatial Clustering of Applications with Noise, p. 69
DE	Diferença de Energia, p. 89
DFT	Discrete Fourier Transform - Transformada de Fourier Discreta, p. 108
Dk	Diferença de Curtose, p. 89
DM	Deslocamento de Máxima amplitude, p. 127
DMAP	Diffusion Map - Mapa de Difusão, p. 66
DP	Descargas Parciais, p. 1
DSI	Direct Signal Interference - Interferência de Sinal Direto, p. 30
DSNR	Signal to Noise Ratio Difference - Diferença de Razão Sinal Ruído, p. 89
DTCWT	Dual-Tree Complex Wavelet Transform - Transformada Wavelet Complexa de Árvore Dupla, p. 3
DWT	Discrete Wavelet Transform - Transformada Wavelet Discreta, p. 3
EBWS	Energy Based Wavelet Selection - Seleção da Wavelet Baseada na Energia, p. 4
ECG	Eletrocardiograma, p. 8
ED	Exponential Damped - Exponencialmente Amortecido, p. 100
EIC	Electrical Insulation Conference - Conferência de Isolamento Elétrico, p. 12
E-KPCA	Análise de Componentes Principais Exponencial, p. 64
EM	Expectation Maximization - Maximização de Expectativa, p. 70
EMA	Erro Médio Absoluto, p. 126
EQM	Erro Quadrático Médio, p. 48

FA	Factor Analysis - Análise Fatorial, p. 66
FIR	Finite Impulse Response - Resposta ao Impulso Finita, p. 2
FM	Frequência Modulada, p. 28
FWT	Fast Wavelet Transform - Transformada Wavelet Rápida, p. 3
GATE	Genetic Algorithm Threshold Estimation, p. 88
GDA	Generalized Discriminant Analysis - Análise Discriminante Generalizada, p. 66
GDT	Gas Discharge Tube - Tubo protetor de Surto à Gás, p. 223
GIS	Gas Insulated Switchgear - Subestação Isolada a Gás, p. 23
GMD	Gaussian Mixture Distribution, p. 70
GMM	Gaussian Mixture Model, p. 70
HDF5	Hierarchical Data Format Version 5 - Formatação Hierárquica dos Dados Versão 5, p. 227
HF	High Frequency - Alta Frequência, p. 23
HFTC	High Frequency Current Transformer - Transformador de Corrente de Alta Frequência, p. 123
ICSD	International Conference on Solid Dielectrics - Conferência Internacional de Dielétricos Sólidos, p. 12
IFWT	Inverse Fast Wavelet Transform - Transformada Wavelet Rápida Inversa, p. 48
IIR	Infinite Impulse Response - Resposta ao Impulso Infinita, p. 2
IMA-DP	Instrumentação Monitoramento e Análise de Descargas Parciais, p. 197
ISOMAP	Landmark-Isomap, p. 66
IWT	Inverse Wavelet Transform - Transformada Wavelet Inversa, p. 3
KLT	Karhunen-Loève Transform - Transformada de Karhunen-Loève, p. 62
KPCA	Análise de Componentes Principais Kernel, p. 63

LD	Limiar de Descarga, p. 99
LDA	Linear Discriminant Analysis - Análise Discriminante Linear, p. 66
LF	LowFrequency - Baixa Frequência, p. 230
LMS	Least Mean Square - Mínimo Erro Quadrático Médio, p. 55
LPP	Linear Preserving Projection - Preservação Linear de Projeção, p. 66
LTF	Localização Tempo e Frequência, p. 60
MDS	Multidimensional Scaling, p. 66
MEBWS	Modified Energy Based Wavelet Selection - Seleção Modificada da Wavelet Baseada na Energia, p. 8
NACF	Normalized Autocorrelation Function - Função Autocorrelação Normalizada, p. 11
NCC	Coefficiente de Correlação Normalizado, p. 89
NPE	Neighborhood Preserving Embedding - Incorporação de Preservação de Vizinhança, p. 66
NQN	Normalized Quantity Number - Número de Quantidade Normalizado, p. 27
NRR	Nível de Redução de Ruído, p. 126
NWDLS	Number of Wavelet Decomposition Levels Selection - Seleção do Número de Níveis de Decomposição Wavelet, p. 8
OPTICS	Ordering Points to Identify the Clustering Structure, p. 69
PA	Passa Altas, p. 122
PAM	Partitioning Around Medoids - Particionamento ao Redor dos Medoids, p. 69
PB	Passa Banda, p. 105
PCA	Principal Components Analysis - Análise de Componentes Principais, p. 6

PCA-3D	3D Principal Component Analysis - Análise de Componentes Principais em 3 Dimensões, p. 63
PHA	Pulse Height Analysis - Análise do padrão de Amplitude dos Pulsos, p. 61
PMMA	Polimetilmetacrilato, p. 20
PPCA	Probabilistic Principal Component Analysis - Análise de Componentes Principais Probabilística, p. 64
PR	Pararraio, p. 119
PRH	Power Ratio for High frequencies - Taxa de Potência para Altas frequências, p. 61
PRL	Power Ratio for Low frequencies - Taxa de Potência para Baixas frequências, p. 61
PRPD	Phase Resolved Partial Discharge - Descargas Parciais Discriminados por Fase, p. 2
PVC	Policloreto de Vinila, p. 120
REQM	Raiz do Erro Médio Quadrático, p. 126
RF	Resposta em Frequência, p. 7
RNA	Redes Neurais Artificiais, p. 6
SEP	Sistema Elétrico de Potência, p. 16
SLIT	Sistema Linear Invariante no Tempo, p. 105
SM	Sammon Mapping - Mapeamento Sammon, p. 66
SNE	Stochastic Neighbor Embedding - Incorporação Estocástica de Vizinhos, p. 64
SNN	Shared Nearest Neighbor, p. 69
SNR	Signal to Noise Ratio - Razão Sinal Ruído, p. 3
SNRBWS	Signal to Noise Ratio Based Wavelet Selection - Seleção Wavelet Baseada na Razão Sinal Ruído, p. 8
SPE	Stochastic Proximity Embedding - Incorporação Estocástica de Proximidade, p. 66

SURE	Stein's Unbiased Risk Error, p. 51
SWT	Stationary Wavelet Transform - Transformada Wavelet Estacionária, p. 3
SWTBWS	Stationary Wavelet Transform Based Wavelet Selection - Seleção da Wavelet Baseada na Transformada Wavelet Estacionária, p. 8
TC	Transformador de Corrente, p. 119
TP	Transformador de Potência, p. 119
t-SNE	t distributed Stochastic Neighbor Embedding - Incorporação Estocástica de Vizinhos t-distribuída, p. 65
UHF	Ultra High Frequency - Frequência Ultra Alta, p. 3
UV	Ultra Violeta, p. 124
VHF	Very High Frequency - Muito Alta Frequência, p. 23
WM	Wavelet Mãe, p. 119
WPT	Wavelet Packet Transform - Transformada Wavelet em Pacotes, p. 3
WT	Wavelet Transform - Transformada Wavelet, p. 2

Capítulo 1

Introdução

No ambiente competitivo cada vez mais exigente dos dias atuais, o crescimento da demanda por energia vem sendo colocado sob a gestão de ativos físicos na geração, transmissão e distribuição de energia das indústrias de fornecimento de eletricidade. Além disso, o órgão regulamentador (Agência Nacional de Energia Elétrica - ANEEL) tem exigido melhorias nos índices que medem a continuidade e qualidade deste fornecimento. Estes ativos estão sujeitos a uma variedade de problemas (estresse térmico e mecânico, ataque químico, envelhecimento natural, sobretensão, impacto de partículas) [1], agindo de forma individual ou combinada, que acabam por danificar o isolamento durante seu funcionamento. Assim, a avaliação de Descargas Parciais (DP) surge como um meio de monitoramento das condições deste isolamento [2], [3].

O termo descarga parcial é definido pela IEC 60270 como “uma descarga elétrica localizada que interliga parcialmente o isolamento entre condutores e pode ou não ocorrer adjacente a um condutor” [4]. Dentre as diferentes técnicas de medição disponíveis (elétrica, acústica, óptica, análise química) [5], [6], [7], [8], [9], o método elétrico é o mais utilizado devido à sua efetividade.

1.1 Considerações Iniciais e Justificativas

Um dos principais objetivos das medições de DP, a despeito da estimação de sua origem bem como de sua magnitude, é estabelecer um indicativo dos defeitos e do processo de degradação contínua dos sistemas de isolamento elétrico. Como o processo de DP se inicia bem antes que danos mais severos ocorram, é possível emitir as advertências necessárias através da medição e análise de DP. Por esta razão, uma vez que atividades de DP são apropriadamente detectadas, a informação

sobre o tipo de defeito associado é muito importante para avaliar se as descargas são preocupantes ou não. No entanto, numerosas fontes de ruído podem interferir com o sinal de DP, causando a deformação de sua forma de onda, a qual afeta negativamente a sensibilidade da detecção e do diagnóstico.

No contexto prático do monitoramento de sinais de DP pelo método elétrico, existem quatro tipos principais de interferências, denominadas: ruído pulsante periódico, ruído pulsante estocástico, ruído estocástico contínuo e interferências de espectro discreto [10], [11]. Na maioria dos casos, ruído estocástico de banda larga é o que mais acomete as medições de DP. O nível de ruído presente é um fator determinante na sensibilidade da medição, principalmente na etapa de construção dos mapas de Descargas Parciais Discriminados por Fase (*Phase Resolved Partial Discharge* - PRPD).

Diversas técnicas de filtragem têm sido reportadas na literatura. Técnicas no domínio do tempo focadas na rejeição de interferências pulsantes periódicas [12] acabam por distorcer excessivamente o pulso recuperado. Outra opção é o uso de métodos no domínio da frequência, tais como filtros de Resposta ao Impulso Infinita (*Infinite Impulse Response* - IIR) e de Resposta ao Impulso Finita (*Finite Impulse Response* - FIR), efetivamente aplicados na remoção de interferências de espectro discreto [13], [14], [15], [16], [17]. Grande parte destes métodos apresentam dificuldade em suprimir ruído de banda larga, principalmente ruído Gaussiano.

A aplicação da Transformada Wavelet (*Wavelet Transform* - WT) foi reconhecida como uma ferramenta efetiva para extração de sinais de DP envoltos em ruído de banda larga e de espectro discreto, devido ao seu potencial em prover simultaneamente informações relacionadas às mudanças no tempo e na frequência com resoluções distintas, característica que facilita a identificação de sinais de DP [18].

O uso eficiente do processamento por wavelet depende da cuidadosa seleção de parâmetros, de forma a concentrar os coeficientes significativos nos níveis de decomposição mais adequados para minimizar a perda de informações do sinal de DP. Dentre estes parâmetros temos: o tipo de WT aplicada, o número de níveis de decomposição, as funções wavelet usadas em cada um destes níveis, o método de estimação do nível de limiar dos coeficientes obtidos e a função de limiarização utilizada para anular os coeficientes ruidosos. Em muitas tentativas têm sido exploradas maneiras de aperfeiçoar esta técnica quanto a seleção dos parâmetros mais adequados para propiciar um melhor resultado de filtragem, tanto para medições *off-line* (i.e., com o equipamento fora de operação) quanto para medições *on-line* (i.e., com o equipamento em operação).

Ma *et al.* [19], [20] aplicaram a Transformada Wavelet Contínua (*Continuous*

Wavelet Transform - CWT) para reconhecimento de padrões de DP. No entanto, a CWT é computacionalmente custosa e também gera dados redundantes. Para contornar estas desvantagens, uma implementação efetiva aplicável a sinais discretos é a Transformada Wavelet Rápida (*Fast Wavelet Transform* - FWT) ou Transformada Wavelet Discreta (*Discrete Wavelet Transform* - DWT), que foi formulada usando filtros que satisfazem certas restrições matemáticas. A FWT é utilizada em [15] para prover uma redução aproximadamente ótima para sinais de DP contaminados com ruído.

Apesar da eficiência da FWT, esta possui duas desvantagens principais [21], [22]: uma é a variância ao deslocamento, significando que pequenos deslocamentos no sinal de entrada podem causar maior variação na distribuição de energia entre os coeficientes FWT em escalas diferentes; a outra é a fraca seletividade direcional para características diagonais, devido aos filtros wavelet serem reais e separáveis. Uma forma conhecida de prover invariância ao deslocamento é o uso da Transformada Wavelet Estacionária (*Stationary Wavelet Transform* - SWT) uma forma não decimada da árvore diádica, tornando-a altamente redundante e, portanto, onerosa em termos de processamento computacional. Estudos envolvendo a Transformada Wavelet em Pacotes (*Wavelet Packet Transform* - WPT) também são apresentados por outros autores em [23], [24], [25], [26], [27]. Em [21], a Transformada Wavelet Complexa de árvore Dupla (*Dual Tree Complex Wavelet Transform* - DTCWT) é explorada como uma alternativa mais eficaz em relação a FWT na filtragem de sinais de DP em Ultra Alta Frequência (*Ultra High Frequency* - UHF). Mortazavi e Shahrtash [10] comparam a performance da FWT, SWT, WPT e DTCWT para redução de ruído de espectro discreto e estocástico em sinais de DP, explicitando as vantagens e desvantagens de cada uma.

Como dito anteriormente, algumas formas de limiarização dos coeficientes gerados pela decomposição wavelet do sinal são necessárias para diferenciar o sinal de DP do ruído com base no fato de que a energia do pulso é concentrada somente em poucos níveis da WT, enquanto que o ruído estocástico contínuo se espalha uniformemente entre todos os níveis. Eliminar os níveis contendo maior concentração de ruído e preservar aqueles contendo maior energia do sinal de DP antes de aplicar a Transformada Wavelet Inversa (*Inverse Wavelet Transform* - IWT) pode reduzir substancialmente a interferência na forma de onda do sinal reconstruído com pequenas perdas do sinal desejado [28], [29]. A aplicação da função de limiarização normalmente se divide entre as funções abrupta (*hard*) e suave (*soft*), ambas apresentadas por Donoho em [30], sendo que a maior parte das publicações concordam com a ideia de que para filtragem de pulsos de DP a função abrupta tende a preservar mais informações do pulso, proporcionando uma maior Razão Sinal Ruído

(Signal to Noise Ratio - SNR) [18], [31]. Além das funções aplicadas, existem os métodos de seleção do valor de limiar, os quais estimam o nível do ruído presente nos coeficientes gerados pela decomposição wavelet; dentre os quais temos [32], [33], [34], [35]: *sqtwolog*; *rigrsure*; *heursure*; *minimaxi* e *scaledep*. Poucos trabalhos têm discursado sobre o uso de novas funções de limiarização para filtragem de sinais de DP, e menos ainda a respeito dos métodos estimação do valor de limiar.

Em [36], Partha Ray aplica a FWT para filtrar sinais de DP e usa uma nova função de limiarização que visa superar as desvantagens das funções abrupta (não diferenciável e pode produzir oscilações no sinal reconstruído devido ao fenômeno wavelet Gibbs ou Pseudo-Gibbs [37], [38]) e suave (fracamente diferenciável e atenua coeficientes wavelet, afetando características de amplitude do sinal filtrado).

Em [31], [39], os autores sugerem a otimização da filtragem wavelet aplicando Algoritmo Genético (AG) para busca do valor de limiar ideal numa nova função de limiarização, melhorando a remoção de ruído do pulso. É posto em destaque que continuidade e diferenciabilidade de ordem elevada são requeridos para problemas de otimização.

Além da estimação do limiar, a distorção de um sinal filtrado está intimamente relacionada à seleção das bases wavelet aplicadas na decomposição do sinal. Esta seleção compreende a escolha dos filtros (função wavelet) e do número de níveis de decomposição [40]. Para filtragem de sinais de DP, a maioria dos estudos de busca da função wavelet e do número de níveis ótimos se desenvolve em torno da FWT.

Em [31], a função ótima é selecionada para filtrar um sinal (pulso de DP) se a correlação entre a função wavelet e o sinal objetivo for a maior dentre todas as funções avaliadas. Este método é denominado Seleção Wavelet Baseada na Correlação (*Correlation Based Wavelet Selection - CBWS*). Um método de Seleção Wavelet Baseada na Energia (*Energy Based Wavelet Selection - EBWS*) foi proposto em [41] com o objetivo de tentar obter uma menor distorção do sinal filtrado através da seleção das funções wavelet que maximizam a energia nos coeficientes de aproximação gerados em cada nível de decomposição, diferentemente do que é feito no CBWS, onde se aplica uma única wavelet para todos os níveis.

Poucos trabalhos tratam da determinação do número de níveis adequado para decompor um sinal. E dentre estes a maioria escolhe o número máximo de níveis de decomposição, adota arbitrariamente ou por tentativa e erro o número de níveis com base em observações [20], [28], [41], [42], [43], [44], [45], [46].

Apesar dos avanços já realizados no tratamento wavelet de sinais de DP, ainda há muito para se investigar na busca pelo aperfeiçoamento de todos os parâmetros

envolvidos.

A norma IEC60270 tem limites específicos de DP para cada equipamento de potência, entretanto, numa falha do isolamento não haverá o conhecimento do tipo de descarga, o que seria importante, já que cada atividade de DP tem seu próprio efeito de degradação [47]. Os instrumentos de detecção de pico de DP armazenam ambos, a magnitude do sinal e o tempo de sua ocorrência; e sintetizam a informação provendo histogramas relevantes para distribuições de pico e fase do pulso, frequentemente representadas no mapa de PRPD. Só recentemente um esforço considerável tem sido desenvolvido para aplicar algoritmos de separação e classificação destes padrões de pulsos com intuito de identificar as várias fontes de descargas presentes e mesmo de ruído ou distúrbios não suprimidos na filtragem (analgica ou digital) aplicada.

Em geral, a posição de uma fonte de DP dentro de um equipamento de Alta Tensão (AT) é desconhecida. Os sinais detectados nos terminais do objeto sob teste são a convolução do sinal gerado pela fonte de DP com a impedância dinâmica do circuito de medição, portanto suas formas são distorcidas de maneira indeterminada.

Investigações anteriores mostram que quando ocorre falha no isolamento, este defeito tem uma característica de degradação única, a qual gera sinais com formatos similares, enquanto que fontes diferentes produzem pulsos com considerável variedade de formas de onda que possuem tempo de subida e de duração distintos [48], [49], [50], [51]. É viável utilizar este atributo especial para correlacionar os padrões de DP com o tipo de defeito e, assim, determinar a qualidade do isolamento [52], [53]. A classificação dos padrões de DP é, portanto, crucial para acessar a condição do isolamento do sistema, provendo um indício da gravidade das DP com relação a cada tipo de defeito existente. Além disso, a classificação pode ser usada para prever qualquer falha iminente do isolamento e determinar o tipo de medida corretiva necessária para sanar o problema [54].

Existem basicamente dois passos principais a serem seguidos no processo: o primeiro contempla a extração de características que irão ponderar quais os atributos representativos contidos nos dados de DP que habilitam seu reconhecimento; e o segundo é a separação dos dados por meio destas características, possibilitando a classificação de cada fonte de DP para que sejam associadas a um ou mais problemas presentes no sistema avaliado.

A extração de características é aplicada para obter informações de entrada relevantes a partir dos dados de DP para representar os pulsos associados com um defeito particular. Além disso, a extração também é uma tentativa de reduzir a dimensão

do dado original para facilitar o processamento [55]. O padrão fase ϕ , carga aparente q e número de DP N (conhecidos como *fingerprint* [2], [51]) e o mapa PRPD, obtidos em um intervalo de tempo, são comumente utilizados em classificação de DP. Parâmetros estatísticos, como curtose, média, variância, entre outros, podem ser extraídos dos histogramas gerados nas medições de descargas [56]. Em [57], são aplicadas características de tempo e frequência na separação de pulsos de DP. A decomposição multi-resolução pode ser realizada sobre uma imagem PRPD de duas dimensões para separar os pulsos [55]. Em [58] foram utilizadas técnicas de auto-correlação, uma ferramenta matemática usada para detectar padrões ocultos num sinal [58]. Já em [59] o sinal foi decomposto em seus coeficientes wavelet através do uso da WPT, em seguida os quatro primeiros cumulantes de cada um dos coeficientes foram calculados e os nós com valores similares somados para produzir parâmetros estatísticos em cada escala decomposta e serem usados como entrada num classificador. Também podem ser citadas diversas outras técnicas de extração de características, como: fractais [60], [61]; análise estatística considerando a distribuição Weibull [62]; teoria do caos [63]; espectro da transformada wavelet cruzada [64]; Análise de Componentes Principais (*Principal Components Analysis* - PCA) [65], [66], entre outras [52].

Para a etapa de classificação das diferentes fontes de DP, existe a possibilidade de aplicar classificadores supervisionados ou não-supervisionados (*clustering*). Na classificação supervisionada, é bem difundida a utilização de diversos tipos de Redes Neurais Artificiais (RNA). O problema deste tipo de classificação é que se faz necessária a presença de um banco de dados considerável de sinais de DP dos diversos tipos de defeitos associados (quatro tipos básicos: descargas internas, descargas de superfície, corona e arborescência), para que seja aplicado no treinamento da rede de forma que o erro de identificação do tipo de descarga seja pequeno. No entanto, esta coleta de dados pode ser custosa por exigir uma reprodução de cada um dos defeitos de maneira controlada em um laboratório ou uma coleta *on-line* do aparato de potência que se deseja analisar com a classificação manual de cada padrão medido por parte de um especialista. Uma saída é fazer apenas a separação das diversas fontes de DP com o uso de processamento não supervisionado, o qual permitirá separar os pulsos com características semelhantes num grupo facilmente distinguível. Este processamento normalmente utiliza técnicas de redes neurais não supervisionadas que discutiremos no Capítulo 4.

Desta forma, frente aos problemas e desafios existentes nas medições de sinais de DP, o devido destaque tem de ser dado às etapas de: filtragem por WT para a supressão das interferências que acometem tais medições, separação dos diferentes tipos de pulsos e classificação para o reconhecimento dos pulsos separados.

1.2 Objetivos

Este trabalho visa proporcionar um melhor entendimento do fenômeno de Descargas Parciais, dos desafios que cercam sua medição e das técnicas de processamento digital de sinais aplicadas no tratamento deste fenômeno, de forma tal que se consiga identificar os problemas pertinentes para, assim, propor soluções mais robustas e eficientes, melhorando a qualidade dos diagnósticos das condições do isolamento de equipamentos de AT.

Neste contexto, serão apresentados estudos para otimizar as técnicas de redução de ruído baseadas na transformada wavelet, principalmente no que diz respeito à etapa de limiarização dos coeficientes gerados com a decomposição wavelet e de escolha da biblioteca de filtros wavelet adequada para tratar sinais de DP. Também pretende-se caracterizar de maneira coerente os pulsos de DP para obtermos uma melhor separação das diversas fontes de DP e interferências presentes nas medições, além de apresentar análises comparativas de performance de algumas das principais metodologias de separação. Adicionalmente, aperfeiçoar as técnicas de formação dos histogramas PRPD, especialmente na correta designação de polaridade dos pulsos medidos, e introduzir um método de estimativa da Resposta em Frequência (RF) desde a fonte de origem da descarga até o *hardware* de aquisição. Em paralelo, como etapa que nos possibilita avaliar as metodologias aqui desenvolvidas, pretende-se construir um banco de dados representativo dos tipos de defeitos normalmente associados às DP.

Finalmente, o objetivo maior deste trabalho é integrar todas as propostas e estudos em um sistema comerciável destinado à análise e à separação de dados de DP, o que contribuirá significativamente para a avaliação e o diagnóstico do isolamento de equipamentos de AT.

1.3 Metodologia

Na dissertação de mestrado [35] o foco do trabalho foi no aperfeiçoamento das técnicas de seleção de alguns dos parâmetros necessários ao processo de redução de ruído por *wavelet shrinkage*, como o número de níveis de decomposição e as funções wavelet aplicadas em cada nível para decompor o sinal de DP. Ao longo do seu desenvolvimento e de pesquisas mais recentes, alguns tópicos para trabalhos futuros foram vislumbrados.

Em [35], [40] foi investigada a seleção do número de níveis, sendo desenvolvido

um novo algoritmo denominado Seleção do Número de Níveis de Decomposição Wavelet (*Number of Wavelet Decomposition Levels Selection* - NWDLS) para podermos identificar o número mínimo de níveis de decomposição necessário para representar precisamente um sinal sobre o domínio wavelet. Também foi extensivamente estudada a etapa de seleção das bases wavelet aplicadas na decomposição do sinal em cada nível, sendo propostos os métodos de Seleção Wavelet Modificada Baseada na Energia (*Modified Energy Based Wavelet Selection* - MEBWS) e de Seleção Wavelet Baseado na Razão Sinal Ruído (*Signal to Noise Ratio Based Wavelet Selection* - SNRBWS) [33], [35], [67], [68]. Além destes, em [40] foi desenvolvida a Seleção Wavelet Baseada na SWT (*SWT Based Wavelet Selection* - SWTBWS).

Observando a quantidade de variáveis que podiam ser definidas e como elas tinham grande influência no resultado final da filtragem dos pulsos de DP, também fizemos estudos da aplicação de algoritmos de busca evolucionária, no caso AG, para procurar pelos parâmetros capazes de prover melhores resultados na redução de ruído. Foi criada uma nova função custo composta por parâmetros frequentemente usados na avaliação da performance de filtragem wavelet, de forma a permitir identificar bons fenótipos no processo de busca evolucionária. O novo método utilizando AG, ao ser comparado com os demais, mostrou desempenho significativamente superior, mas com a desvantagem de ser mais lento em processamento, o que dificulta sua aplicação em medições *on-line*.

Com os bons resultados obtidos durante a pesquisa anterior e diante da complexidade das ferramentas de processamento de sinais utilizadas, verificamos que ainda há uma ampla área de pesquisa a ser explorada. Neste trabalho, demos continuidade às pesquisas nesta área, com a perspectiva de propor soluções em busca de inovação e refinamento das técnicas mencionadas na Seção 1.1. Após análise detalhada da literatura técnica, algumas dificuldades puderam ser verificadas:

1. Poucos trabalhos têm abordado o uso de novas funções de limiarização no processamento wavelet de DP [31], [69], [39], [70], [71] e proposto métodos de estimação do valor de limiar, ambas etapas com enorme influência no resultado do tratamento. Nos trabalhos publicados a respeito de outras funções de limiarização, maior ênfase é dada à filtragem de sinais diversos, como sinais de áudio [72], [73], [74], [75], [76], [77], [78], [79], Eletrocardiograma (ECG) [80], [81], [82] ou de imagens [83], [84], [85], [86], [87], [88], [89]. Seria interessante avaliar o desempenho destas outras funções em conjunto com os métodos desenvolvidos anteriormente;
2. Analisando as funções de limiarização aplicadas tanto na área de DP como em processamento de áudio e imagem, é notável que estas buscam melhorias com-

binando tanto as propriedades de preservação dos coeficientes e magnitudes da função abrupta quanto a diferenciabilidade e suavidade proporcionada pela função suave. Em processamento de imagens, a propriedade de suavidade é interessante para que a imagem resultante mostre contornos mais agradáveis (suaves). Já no processamento de sinais de áudio e de impulsos de DP é importante preservar a magnitude (pico) do sinal e a SNR. Por esta razão, muitos autores têm explorado funções que correspondem à interpolação das funções suave e abrupta. Ainda assim, a maioria das funções possuem uma maior tendência para a suavização dos coeficientes do que para a preservação da amplitude máxima do sinal, não percebendo que para sinais de DP é mais adequado que a função se mostre mais próxima da função abrupta do que da suave, mas devendo conservar um certo grau de suavidade (diferenciabilidade) na transição do valor de limiar. Desta forma, é possível chegar a um melhor equilíbrio na preservação de magnitudes e da forma do sinal;

3. Na decomposição wavelet, o sinal de DP tende a se concentrar em poucos dos coeficientes gerados, enquanto que o ruído branco se distribui em todos os coeficientes. Portanto, é possível aplicar uma função que gere maior atenuação nestes níveis e outra que não atenuar tanto os coeficientes próximos do valor de limiar calculado, possibilidade que ainda não foi avaliada em nenhuma publicação;
4. Em [35], [40], avaliamos os diferentes métodos propostos para uma pequena quantidade de funções wavelet, dentre estas as da família *Daubechies*, *Symlets* e *Coiflets*, as quais são todas wavelets ortogonais. Seria interessante investigar o efeito das demais wavelets nos métodos de seleção;
5. Em nossos estudos anteriores ainda não havíamos tratado da separação dos pulsos de DP, uma etapa essencial na análise e diagnóstico do isolamento de equipamentos de AT. Vários trabalhos têm sido publicados nesta área, apresentando possibilidades diversas de aperfeiçoamento ou mesmo aplicação de técnicas distintas das usuais. Um dos que chamou atenção foi o método baseado na função autocorrelação normalizada [51] dos sinais para realizar a separação de padrões de defeitos com base na técnica K-means, mas apresenta tempo de processamento consideravelmente elevado. Desta forma, é possível trabalhar para melhorar a performance de processamento deste método;
6. A correta designação de polaridade de pulsos detectados durante uma medição de DP é de grande importância para a construção de um mapa PRPD bem definido em concordância com o formato típico dos defeitos gerados pelas descargas. Em [40] mostrou-se que os métodos de cruzamento de limiar e de

amplitude máxima, usuais dos sistemas comercializados, podem produzir erros consideráveis na atribuição de polaridade dos pulsos de DP. Portanto, a proposição de um método que consiga reduzir os erros de identificação mencionados mostra-se importante.

7. Sabendo que os impulsos de corrente que ocorrem no interior do objeto sob avaliação podem ser distorcidos pela impedância resultante de todos componentes envolvidos numa medição (sensores, impedâncias de medição, cabos, filtros, atenuadores e conectores de *hardwares*), então mostra-se oportuno investigar a possibilidade de utilizar a própria resposta impulsiva de cada descarga detectada para estimar a RF do sistema medido.
8. Métodos de classificação de pulsos de DP são dependentes de redes supervisionadas para que possam funcionar de maneira adequada. Tal etapa envolve o acúmulo de diferentes fontes de DP e de ruído para formar um banco de dados extenso que represente os possíveis defeitos no isolamento de um equipamento de AT. Assim, se faz necessária a criação deste banco a partir de ensaios em laboratório, para que possamos implementar adequadamente a etapa de classificação com reconhecimento das fontes de DP.
9. O desenvolvimento das observações aqui levantadas tende a ganhar maior relevância quando deixa o território da teoria e é efetivamente aplicado na prática. Assim, temos a oportunidade de agregar todos os tópicos para criar um sistema comerciável de análise e separação de dados de DP.

1.4 Resultados e Contribuições

A formação do banco de dados foi feita com ensaios em laboratório usando células de carga e barras estáticas para diferentes configurações e combinações de circuito. Também foram adicionados ao banco, dados obtidos em ensaios realizados em campo para diferentes equipamentos de AT. Conseguimos reunir um total de 144 arquivos provenientes de medições em campo e 315 arquivos provenientes dos ensaios em laboratório (ambos contendo 60 ou 120 ciclos de dados de DP), abrindo caminho para o desenvolvimento de nossas pesquisas.

Desenvolvemos uma nova função de limiarização, da qual também surgiram algumas variações. A partir de um conjunto de 2064 pulsos de DP aplicamos a filtragem por WT para comparar o desempenho das funções propostas com as tradicionais funções abrupta e suave, além de outras 12 usadas na literatura. Os resultados mostraram a superioridade de quatro das cinco funções apresentadas, confirmando

as questões levantadas nos itens de 1 a 3 da Seção 1.3. Em seguida, comparamos a performance de filtragem wavelet para diferentes bibliotecas contendo combinações de funções wavelet, dentre elas, a família: *Daubechies*, *Symlets*, *Coiflets*, *Legendre* e *Discrete Meyer*. Com os resultados verificamos que a biblioteca formada exclusivamente por funções *Daubechies* apresentou os melhores resultados na redução de ruído de sinais de DP. E, também, a biblioteca composta por funções *Symlets* mostrou bons resultados. Vale ressaltar que em todas as comparações utilizamos o método de seleção da função wavelet SNRBWS com a escolha do número de níveis de decomposição feita pelo método NWDLS e para cálculo do valor de limiar o método *scaledep* [33], [35], [68].

Em seguida foi desenvolvido o novo método de identificação da polaridade dos pulsos obtidos numa medição. Ele calcula o coeficiente de correlação de cada pulso adquirido com um pulso positivo padrão definido a priori. Assim, se o valor de correlação for positivo (≥ 0) significa que os sinais são diretamente correlatos e, portanto, o pulso adquirido será designado como positivo, caso contrário este será visto como negativo. O método foi comparado com o aplicado comercialmente e se mostrou superior para todos os exemplos avaliados, influenciando diretamente na qualidade do PRPD gerado.

A partir da técnica que faz uso de um analisador de espectros em seu modo *max hold* para determinar a RF de um circuito qualquer a partir de impulsos abrangendo uma ampla faixa de frequência, conseguimos desenvolver uma metodologia que se utiliza de impulsos de DP para gerar uma estimativa da RF de todo o sistema avaliado (desde o ponto de origem dos pulsos). Em comparações de RF entre simulações, o método proposto utilizando DP e a aplicação direta de varredura em laboratório, verificou-se que a nossa estimativa de RF (normalizada em amplitude) foi bastante similar à RF real do sistema e, também, à simulada. Além do mais, foi possível identificar com considerável precisão os pontos de ressonância e antirressonância do sistema, o que reforça a aplicabilidade desta ferramenta na avaliação de DP.

Conseguimos melhorar a performance de processamento do método de separação por Função Autocorrelação Normalizada (*Normalized Autocorrelation Function* - NACF) que se mostrava muito lento (comparado aos demais métodos) em sua versão original. Implementadas modificações em todas as etapas do algoritmo e com a correta designação de parâmetros, reduzimos em até 25% o tempo de execução do método sem comprometer a sua qualidade de separação.

Junto ao estudo dos métodos de extração e separação aplicamos com sucesso diversos outros algoritmos nunca antes utilizados para tratar sinais de DP. Com as diversas simulações feitas concluímos que todos os métodos têm performance variável

de acordo com o tipo de pulsos capturados e que não é possível determinar um único que se mostrará sempre superior. Esta observação reforçou a ideia de se construir um sistema que possibilite ao usuário investigar qual combinação de técnicas de extração e separação a fim de obter o melhor um resultado de separação.

Ao final apresentamos o sistema de análise e separação de dados de DP, o qual agregou os métodos que criamos, as diversas técnicas de extração de características e de separação, bem como algumas ferramentas que auxiliam no diagnóstico de equipamentos de AT. Foram mostrados diferentes exemplos de uso do sistema para os dados existentes no banco criado, e os resultados fornecidos se mostraram de grande valia contribuindo para o campo de diagnóstico de equipamentos.

1.4.1 Trabalhos Publicados e em Desenvolvimento

No âmbito dos estudos e desenvolvimentos já realizados, foram publicados cinco artigos científicos, sendo dois em congressos e três em periódicos:

1. *An Improved Scale Dependent Wavelet Selection for Data Denoising of Partial Discharge Measurement* [67], apresentado no congresso internacional *11th IEEE International Conference on Solid Dielectrics (ICSD)* em Maio de 2013;
2. *A New Wavelet Selection Method for Partial Discharge Denoising* [33], publicado no periódico *Electric Power Systems Research* (fator de impacto: 1.75) em Agosto de 2015;
3. *Identification of Partial Discharges Immersed in Noise in Large Hydro-generators based on Improved Wavelet Selection Methods* [68], publicado no periódico *Measurement* (fator de impacto: 1.48) em Novembro de 2015;
4. *A New Methodology for the Evaluation of the Influence of Discrete Spectral Interference on Partial Discharge Measurements in the Field* [90], apresentado no congresso internacional *34th IEEE Electrical Insulation Conference (EIC)* em Abril 2016;
5. *Proposal of a Novel Fitness Function for Evaluation of Wavelet Shrinkage Parameters on Partial Discharge Denoising* [91], publicado no periódico *IET Science, Measurement and Technology* em Novembro de 2017 (fator de impacto: 1.389).

E já foi submetido a periódico internacional:

1. *Digital Signal Processing Algorithms for High Frequency Partial Discharge Me-*

asurement in Generators;

1.4.2 Citações aos Trabalhos Publicados

Alguns dos artigos publicados foram citados por outros autores em seus trabalhos:

- o artigo da referência [67] teve até o presente momento uma citação:
 1. Omari Tahar *et al.*, *An Automatic Wavelet Denoising Scheme for Heart Sounds*, publicado no periódico *International Journal of Wavelets Multiresolution and Information Processing* (fator de impacto: 0.42), Abril de 2015 [92].
- o artigo da referência [33] teve 25 citações, dentre as de maior destaque temos:
 1. Yong Zhou, *An Improvement Algorithm Based on Wavelet Shrinkage Denoising*, publicado no periódico *Journal of Information and Computational Science* (fator de impacto: não informado), Novembro de 2015 [93];
 2. Ramy Hussein *et al.*, *Energy Conservation-based Thresholding for Effective Wavelet Denoising of Partial Discharge Signals*, no periódico *IET Science, Measurement and Technology* (fator de impacto: 0.954), Maio de 2016 [94];
 3. Yangyang Xie *et al.*, *Period analysis of hydrologic series through moving-window correlation analysis method* no periódico *Journal of Hydrology* (fator de impacto: 3.043), Julho de 2016 [95];
 4. Dong Yang *et al.*, *Vibration condition monitoring system for wind turbine bearings based on noise suppression with multi-point data fusion* no periódico *Renewable Energy* (fator de impacto: 3.404) em Julho de 2016 [96];
 5. Daniel Guillen *et al.*, *Partial discharges location in transformer winding using wavelets and Kullback-Leibler divergence*, no periódico *Electric Power Systems Research* (fator de impacto: 1.809), Julho de 2016 [97].

1.5 Organização Textual

O presente trabalho está organizado para possibilitar ao leitor uma melhor compreensão do fenômeno de Descargas Parciais e dos desafios pertinentes de sua

medição, caracterização e classificação. Seguindo uma linha estrutural lógica, apresentamos inicialmente uma revisão de grande parte da teoria de DP e das estratégias de processamento digital aplicadas para atingir nossos objetivos, para que então possamos avaliar e propor soluções e melhorias para alguns dos problemas existentes.

Desta forma, dividimos o texto em nove capítulos. No Capítulo 1, destacamos as considerações iniciais e justificativas para os estudos aqui abordados, os objetivos deste trabalho, a metodologia de pesquisa seguida, os resultados e contribuições já obtidos, incluindo as publicações que já foram e que estão por ser efetuadas, bem como citações a estas.

No Capítulo 2 apresentamos resumidamente o que vêm a ser Descargas Parciais, as fontes causadoras deste fenômeno e seus efeitos. Servirá como base para entendimento do processo de separação de DP. Além disso, serão mostrados os tipos mais comuns de pulsos, como são feitas as medições destes sinais, as formas mais usuais de apresentação dos dados e as fontes de ruído que acometem as medições.

No Capítulo 3 abordaremos a Transformada Wavelet como ferramenta na redução de ruído em medições de DP, as características dos diferentes tipos de transformadas wavelet existentes, as funções wavelet mais indicadas no tratamento de DP, e os métodos aplicados na seleção do número de níveis de decomposição, incluindo o método que desenvolvemos em [35]. Apresentaremos, ainda, os métodos de seleção wavelet, que foram foco do trabalho desenvolvido em [35], formas de estimação dos limiares de ruído presentes nos coeficientes wavelet decompostos e os diversos tipos de funções aplicadas na limiarização destes coeficientes.

No Capítulo 4 mostraremos as formas comuns de extração das características relevantes dos sinais de DP. Em seguida, apresentamos um resumo da teoria dos métodos de classificação não supervisionada utilizados na separação de sinais de DP. Serão mostradas as formas de agrupamento que possibilitam a separação dos diversos tipos de DP e das possíveis interferências não suprimidas pela filtragem wavelet.

A fase de desenvolvimento das propostas levantadas em nossos estudos (Seção 1.3) é dividida em três capítulos: o Capítulo 5, que mostra a concepção da nova função de limiarização e suas variações, o Capítulo 6, que apresenta as modificações feitas no método de separação por função autocorrelação normalizada, e o Capítulo 7, que traz os novos métodos de identificação de polaridade dos pulsos e de estimativa de RF a partir de pulsos de DP e, por fim, a estrutura proposta para o *software* de análise e separação de dados de DP.

No Capítulo 8 apresentaremos os resultados das simulações realizadas com os

dados obtidos a partir do banco de dados criado, evidenciando que conseguimos desenvolver com sucesso todas as propostas levantadas neste trabalho.

No Capítulo 9 serão expostas as conclusões e propostas para trabalhos futuros.

Ao final, incluiremos ainda três anexos. O Anexo A mostrará os circuitos aplicados nas medições de DP em campo e em laboratório. O Anexo B, complementando a estrutura de processamento do sistema de análise e separação de dados de DP desenvolvido neste trabalho para avaliar nossas propostas. Por último, o Anexo C apresentará as características construtivas das células de carga utilizadas para ensaios em laboratório.

Capítulo 2

Descargas Parciais

Os equipamentos elétricos de alta tensão estão sujeitos a severas condições de solicitações dielétricas causadas por sobretensões provenientes de manobras no Sistema Elétrico de Potência (SEP) e/ou descargas atmosféricas (surtos). Além do mais, problemas decorrentes do próprio processo de montagem e transporte destes equipamentos, bem como seu envelhecimento natural, estresse térmico, estresse mecânico, ataque químico e impacto de partículas podem acometer a integridade do material isolante que os compõe. Portanto, é preciso submeter estes equipamentos a processos de avaliação periódicos, ou mesmo contínuos. Um dos principais mecanismos de avaliação está relacionado com a qualificação de Descargas Parciais (DP). As DP se caracterizam por impulsos de corrente que ocorrem no interior do isolamento de equipamentos de AT e são tidas como fontes potenciais de defeitos nos isolantes elétricos. O fenômeno se manifesta de forma parcial, causando danos que podem progredir lenta ou rapidamente, até que ocorra a total ruptura do isolante (i.e., um curto circuito entre as partes energizadas e o terra), danificando o equipamento. Conseqüentemente, o monitoramento de sinais de DP funciona como uma ferramenta eficaz na manutenção preventiva de equipamentos de alta tensão [2], [3], refletindo em grande economia para a empresa que o implementa.

2.1 Conceitos de Descargas Parciais

De acordo com a norma IEC 60270 [4], descargas parciais são descargas elétricas localizadas que fazem a ligação parcial entre condutores através do isolamento e podem ou não ocorrer adjacentes a um condutor.

A DP pode ser entendida como uma pequena descarga elétrica que se manifesta em uma região de imperfeição do material isolante exposto a um campo elétrico

[98], [99]. Portanto, para que uma DP ocorra, duas condições devem ser satisfeitas: o campo elétrico deve estar acima do valor de início da DP e uma quantidade mínima de elétrons deve estar disponível para iniciar o processo de descarga por efeito avalanche. Sendo a disponibilidade de elétrons um processo estocástico, os sinais de DP são gerados estocasticamente por natureza [42].

Na literatura são descritos dois modelos para avaliação do comportamento das DP no isolamento: o modelo a-b-c apresentado por Gemant e Philippoff [100], que faz a associação de elementos capacitivos; e o modelo baseado na aproximação por campo [101], o qual se utiliza da teoria de campos elétricos para explicação deste fenômeno. Maiores detalhes a respeito de cada um destes modelos podem ser encontrados em [35].

Quando a DP se manifesta no interior de um equipamento, ocorre a transferência de carga que diminui a tensão através da imperfeição, provocando uma redução proporcional da tensão em forma de um pulso com tempo de subida da ordem de poucos nanosegundos nos terminais condutores deste equipamento. Obviamente, pulsos de DP não podem ser mensurados diretamente, pois é impossível acessar seu local de ocorrência. Portanto, somente uma pequena fração da carga do pulso originada no local da DP é mensurável.

A ocorrência de DP pode se manifestar pela emissão de ondas acústicas, luz, calor e reações químicas. Diferentes técnicas de medições podem ser aplicadas para medir estas manifestações; entretanto, por questões práticas e pela maior sensibilidade, é usual aplicar o (aqui adotado) método de medição elétrica [102]. Neste método, são utilizados circuitos de medição para detectar os pulsos de tensão ou corrente resultantes das DP. Na Seção 2.4 discutiremos os principais tipos de circuitos aplicados pela norma IEC 60270 [4].

As descargas parciais são de curta duração em relação ao período da senoide de tensão aplicada (da ordem de nanosegundos), são repetitivas, têm sua frente muito íngreme e muito acentuada, podendo ser aproximadas como uma função impulso.

2.2 Causas e Efeitos de Descargas Parciais

O fenômeno das descargas parciais se manifesta em cavidades ou inclusões gasosas de constante dielétrica diferente da do material que a rodeia. Quando submetemos este material a um campo elétrico, este se distribui pelo material, submetendo a cavidade ou inclusão a um gradiente de tensão em excesso ao gradiente máximo suportável pela mesma. Este fenômeno dará origem a pequenas descargas disruptivas no interior

da cavidade, acarretando o processo de deterioração progressivo do material isolante, o que, por fim, pode gerar uma descarga completa entre os condutores e levar à destruição do sistema isolante e, portanto, perda do equipamento. Alguns efeitos das DP que podem funcionar como mecanismos de deterioração são [103]:

1. Bombardeamento iônico e eletrônico que gera aquecimento (perda de potência) do anodo e do catodo, erosão e processos químicos nestas superfícies (polimerização, quebra de moléculas, formação de gases, etc);
2. Formação de produtos químicos no gás ionizado, tais como ácido nítrico, ozônio, oxigênio, ácido oxálico, etc;
3. Formação de radiação ultravioleta e raios-X.

A agressividade com que cada efeito ataca o isolamento está intimamente ligada ao tipo de material isolante (e.g. em alguns tipos de isolantes plásticos a degradação térmica é mais grave, já em mica o efeito principal é o bombardeamento iônico).

Em materiais isolantes líquidos (óleo isolante), as DP podem gerar acetileno e metano causando a diminuição das propriedades dielétricas e assim a vida útil deste material. Já em materiais isolantes sólidos, estas são mais severas, pois diferentemente de isolantes líquidos estes são de difícil substituição.

A expectativa de vida de um dielétrico depende principalmente da taxa de ocorrência e da magnitude das descargas e, conseqüentemente, da frequência, amplitude e gradiente da tensão aplicada. Também estará relacionada com o tipo de dielétrico.

2.3 Classificação dos Tipos de DP

Descargas parciais podem ocorrer em qualquer ponto do material dielétrico, seja na junção de dois materiais dielétricos diferentes ou adjacentes a um eletrodo, seguidamente em vários pontos do dielétrico e até mesmo sem eletrodos, numa imperfeição do material dielétrico. Fisicamente, avalanches de elétrons autossustentadas só podem ocorrer em meio gasoso, então DP só surgem em regiões de inclusões gasosas, tais como bolhas, cavidades, rachaduras ou delaminações [99].

Do ponto de vista técnico, a DP envolve um amplo grupo de fenômenos de descarga, podendo ser classificada em três categorias de acordo com a sua origem: descarga superficial, descarga externa (corona) e descarga interna [104]. A identificação, por parte do sistema de medição, de cada uma dessas classes é uma etapa

essencial para a correta avaliação da qualidade do isolamento do equipamento, pois cada tipo de descarga possui suas próprias características de degradação [52]. A seguir descrevemos cada uma destas descargas.

2.3.1 Descargas Externas

São classificadas como descargas externas aquelas que geralmente ocorrem em ar ambiente, i.e., sem a presença de dielétricos sólidos ou líquidos. São referidas como descargas **corona**, as quais surgem como consequência da concentração de campo elétrico em regiões com pequenos raios de curvatura de um condutor, ionizando as partículas de gás a sua volta até perto da tensão de inepção (definido pelo tipo de gás, pressão e geometria do condutor [105]) onde surgem as descargas. Desta maneira, pode surgir uma sucessão de descargas parciais [104]. Na Figura 2.1 são mostrados os modelos de descarga externa e um exemplo real de corona captada por meio de uma câmera térmica.

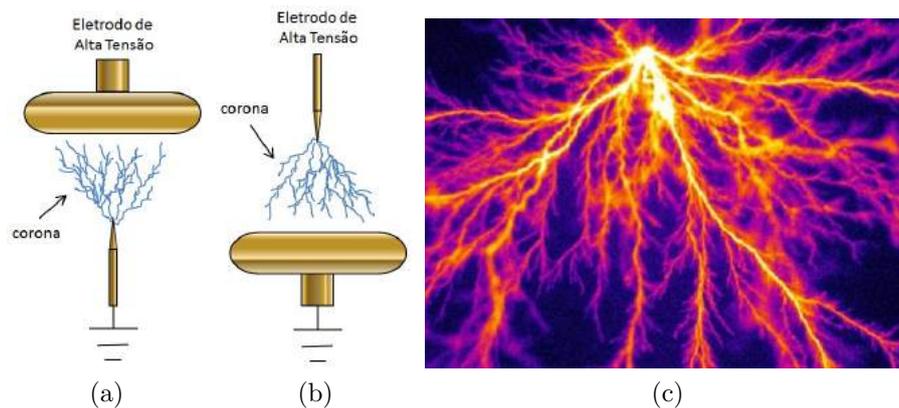


Figura 2.1: Descarga externa: (a) modelo de corona no lado de baixa tensão; (b) modelo de corona no lado de alta; (c) corona real produzida por uma agulha no lado de alta tensão. Fonte: [109]

Embora processos químicos sejam excitados pelas descargas no gás, os produtos criados são constantemente substituídos pelo gás circulante. Assim, descargas no ar puro podem ser consideradas auto-regenerativas e tipicamente inofensivas. No entanto, descargas externas que se propagem ao longo da superfície de dielétricos podem se tornar nocivas por causar uma degradação irreversível do dielétrico. Adicionalmente, a superfície do isolante sólido pode sofrer erosão progressiva devido à elevação da temperatura com a propagação de descargas guia. Também óxidos de nitrogênio em conjunto com vapores de água podem formar depósitos condutivos sobre o dielétrico, gerando o fenômeno de trilhamento (*tracking*) do material [104].

Descargas no ar ambiente diferem significativamente das descargas internas e de

superfície, tanto que a tensão de inepção de eventos de DP não aparece em ambas metades dos ciclos simultaneamente. Num primeiro instante, sequências de pulsos são iniciadas numa metade do ciclo (positiva ou negativa, dependendo se a descarga se manifesta no lado de alta tensão ou no lado de baixa tensão, respectivamente). Na outra metade do ciclo as descargas surgem após um aumento considerável da tensão. Independente da polaridade da tensão aplicada, a sequência de pulsos (pulsos de Trichel) tem a característica de sempre circundar as regiões de pico.

2.3.2 Descargas Internas

Descargas parciais originadas devido a imperfeições em isolantes sólidos e líquidos, bem como em gás comprimido são classificados como descargas internas. Conforme mencionado anteriormente, as descargas só acontecem em inclusões gasosas. Portanto, em isolantes sólidos as descargas ocorrem em cavidades preenchidas com gás, tais como vazios, trincas, delaminações ou defeitos na estrutura molecular. Para isolantes líquidos podem ocorrer em bolhas de gás, vapores de água e partículas condutoras.

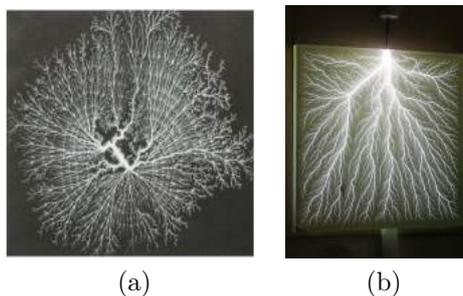


Figura 2.2: Descarga interna: (a) DP guia (*leader*) em óleo; Fonte: [102]; (b) arborescência em polimetilmetacrilato (PMMA). Fonte: [111].

Descargas internas em equipamentos isolados a gás são geradas pela presença de partículas fixas ou móveis. Suas ocorrências podem ocasionar dissociação do gás hexafluoreto de enxofre (SF_6) em componentes que podem deteriorar os isolantes sólidos ou produzir substâncias venenosas, levando ao colapso do sistema elétrico devido a transientes de sobretensão.

Descargas internas ocorrendo em grande quantidade em uma mesma região ocasionam o surgimento de arborescências elétricas (*treeing*), como ilustrado na Figura 2.2, as quais podem se propagar rápida ou lentamente. Consequentemente, um colapso pode ocorrer em pouco tempo ou levar anos até que finalmente aconteça o sinistro do equipamento por curto-circuito. As descargas internas também podem

aparecer entre interfaces de dielétricos sólidos e líquidos, tornando-se preocupantes em situações onde estas se propagam ao longo das superfícies de dielétricos sólidos.

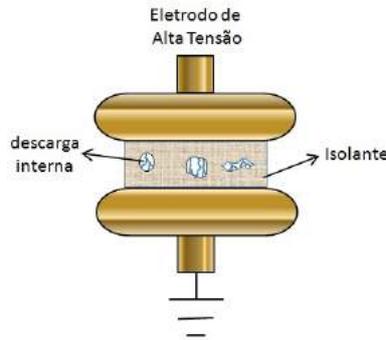


Figura 2.3: Modelo de descargas internas.

As características do pulso medido, como magnitude, duração e forma, são governadas principalmente pelo tipo e pressão do gás no interior da cavidade, por sua geometria e pela localização [99], conforme ilustrado na Figura 2.3. Como descargas internas causam o envelhecimento progressivo do isolamento, elas usualmente são tidas como irreversíveis.

A delaminação interna na isolação principal é um defeito bastante comum em barras estatóricas (Figura 2.4), que pode decorrer de falhas no processo de cura da isolação durante sua fabricação, ou ainda de estresse térmico e/ou mecânico durante a sua operação. Grandes cavidades podem se desenvolver com grandes superfícies, resultando em descargas de alta energia, que inclusive podem atacar a própria isolação num processo erosivo. A delaminação interna reduz ainda a condutividade térmica do isolamento, o que pode levar a um envelhecimento acelerado.

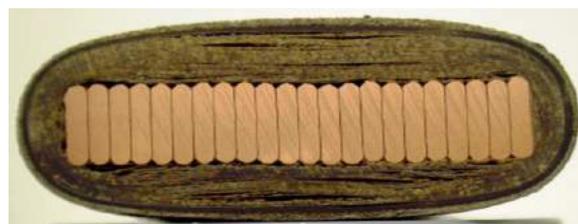


Figura 2.4: Fotografia da seção transversal de uma barra estatórica, onde se observam delaminações internas no isolamento. Fonte: [44]

Também é possível que DP internas se manifestem devido à presença de partículas condutoras no isolante (mais comuns em isolantes líquidos ou gasosos), especialmente aquelas de pequenas dimensões que podem ocasionar falhas de rápida evolução. Estas partículas podem advir de uma contaminação do isolante durante o processo de construção do equipamento, de uma manutenção inadequada ou mesmo de um processo de corrosão da própria estrutura metálica deste equipamento.

2.3.3 Descargas Superficiais

São descargas que podem se desenvolver na superfície de um material isolante quando o campo elétrico que tangencia esta superfície excede a rigidez dielétrica do gás ao seu redor [102]. Este tipo de descarga pode ocasionar a formação de trilhas condutivas (trilhamento) que se propagam ao longo da superfície do dielétrico, o que pode levar à ruptura total da isolação. Na Figura 2.5 é ilustrado um modelo com presença de descargas de superfície.

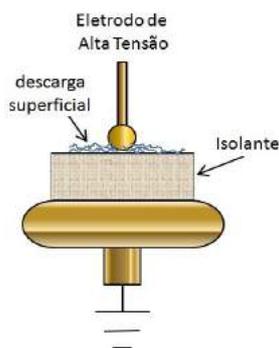


Figura 2.5: Modelo de descargas superficiais.

As descargas de superfície no ar geralmente se iniciam em uma tensão inferior àquelas que propiciam as descargas internas [104], já que a tensão de ruptura do ar ($\sim 3 \text{ kV/mm}$) é baixa em relação aos demais dielétricos. Por este motivo são frequentemente caracterizadas por uma baixa amplitude, mas taxa de ocorrência de descarga muito alta.

Terminações de cabos ou de enrolamentos de estatores são as que mais sofrem com descargas superficiais. Na Figura 2.6 são mostrados alguns exemplos reais da degradação causada ao isolamento na presença de descargas de superfície.

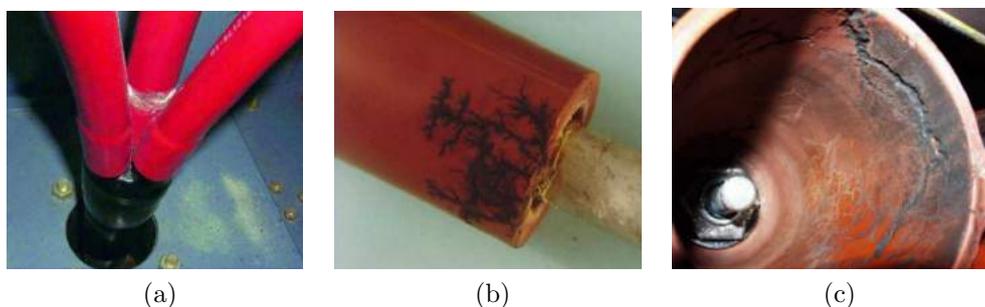


Figura 2.6: Exemplos de danos causados por descargas superficiais: (a) deterioração do isolamento de cabos com descargas de superfície entre fases; (b) trilhamento em cabo; (c) erosão em disjuntor encapsulado em resina.

2.4 Medições de DP

É conhecido que o fenômeno de DP pode se manifestar na forma de calor, luz, emissão acústica, reação química, radiação eletromagnética e corrente elétrica. Portanto, a detecção das atividades de DP pode ser feita por meio de diferentes métodos destinados a cada uma destas manifestações. Obviamente cada método possuirá sua performance no diagnóstico a respeito das DP que ocorrem no equipamento sob avaliação. Além disso, dependendo do equipamento avaliado nem todos os métodos podem ser utilizados.

Por muito tempo, o método elétrico tem sido bem desenvolvido e amplamente empregado na quantificação de atividades de DP em transformadores, geradores, cabos, disjuntores, pararraios e outros. Essa preferência vem de sua sensibilidade, praticidade (de utilização) e por abranger grande parte dos equipamentos elétricos de alta tensão. Essa técnica faz com que o instrumento de detecção de descargas se torne parte do circuito elétrico, possibilitando a detecção de pulsos de corrente (gerados pelas descargas que ocorrem no interior do equipamento) que se propagam para os terminais do objeto em teste. As normas IEC 60270 e IEEE P1434 [106] tentam unificar e consolidar procedimentos para medição de DP, fornecem várias alternativas de circuitos de ensaio e apresentam a terminologia apropriada para realizar medição de DP.

As DP são sinais impulsivos de curta duração e conseqüentemente estes podem ser detectados em uma ampla faixa do espectro de frequência, indo desde poucos kHz até GHz. Normalmente, há uma relação direta entre a faixa de frequência onde há maior incidência de pulsos de DP e o tipo de equipamento de alta tensão avaliado, por exemplo transformadores costumam emitir pulsos de algumas dezenas de kHz até cerca de 30 MHz, já Subestações Isoladas a Gás (*Gas Insulated Substations - GIS*) são afetadas por pulsos muito rápidos que vão de 300 MHz a 3 GHz [107], [108], [109], para cabos o espectro cobre frequências de 300 MHz até 1 GHz. Para atender essa variação os instrumentos de medição de DP podem ser projetados para medições em Alta Frequência (*High Frequency - HF*), Muito Alta Frequência (*Very High Frequency - VHF*) e Ultra Alta Frequência [110], [111], [112].

Em adição, as medições podem ser calibradas para assegurar que o mesmo resultado seja obtido a partir de dois sistemas diferentes que sejam usados para medir a mesma amostra.

Os circuitos básicos normalmente aplicados nas medições de DP são mostrados no Apêndice A.

2.4.1 Padrão PRPD

O estado da arte na medição e diagnóstico de DP em Corrente Alternada (*Alternating Current - AC*) adota um histograma bidimensional, em conformidade com a norma IEC 60270, conhecido como padrão ou mapa de Descargas Parciais Discriminados por Fase (PRPD) [113], [114]. Neste padrão, é condensada a contagem do número de pulsos ocorridos com uma certa amplitude e intervalo de fase da tensão AC aplicada. O resultado é um gráfico 3D usualmente apresentado como uma imagem 2D, em que o número de pulsos de DP detectados é indicado qualitativamente pelas diferentes cores (representando a terceira dimensão), conforme ilustrado na Figura 2.7.

Na prática, o histograma PRPD é uma matriz em que cada linha corresponde a uma faixa do nível de amplitude do pulso, cada coluna corresponde a uma faixa de fase e cada valor na célula corresponde à contagem de pulsos de DP dentro desta janela. Em geral, a matriz possui dimensão 256 x 256, o que fornece uma resolução apropriada ao usuário. Na Figura 2.7(a) é mostrada a forma clássica de apresentação do mapa PRPD em 2D, onde a barra de cores representa a quantidade de pulsos. Quanto mais próxima a cor de um ponto estiver do vermelho, maior é a quantidade de pulsos ocorrendo naquela região.

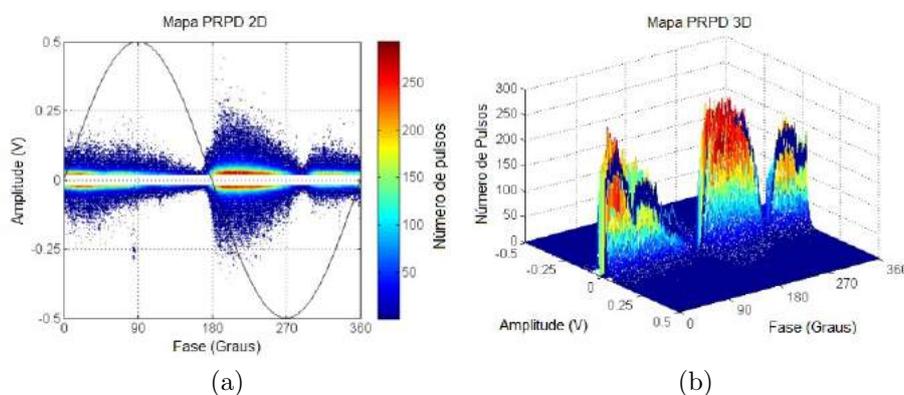


Figura 2.7: Histograma PRPD Bipolar apresentado na forma: (a) 2D; (b) 3D. Fonte: [44]

Em medições síncronas e simultâneas de canais múltiplos, como no caso de medições trifásicas, podem ser aplicados os diagramas trifásicos para reconhecimento de grupos de DP que têm origem em diferentes pontos do equipamento, possibilitando identificar e localizar as DP com maior facilidade. Exemplos destes diagramas são: o Diagrama de Relação de Amplitude em 3 Fases (*3 Phase Amplitude Relation Diagram - 3PARAD*); o Diagrama de Relação de Tempo em 3 Fases (*3 Phase Time Relation Diagram - 3PTRD*); o Diagrama de Relação de Frequência Central em 3 Canais (*3 Center Frequency Relation Diagram - 3CFRD*) [115], [116], [117], [118].

2.4.2 Histogramas

A medição usual de DP é feita por meio de quantidades mostradas no mapa PRPD: a posição de ocorrência do pulso é relacionada à fase φ da onda senoidal, à amplitude q da descarga e à quantidade n de pulsos. Outras medidas, as quais permitem uma ampla caracterização para descrever o processo de DP e, portanto, o estado dos equipamentos de alta tensão, têm sido extraídas destas quantidades, tais como [56]:

1. Distribuição do número de descargas sobre a amplitude da descarga, $H_n(q)$, contendo informação adicional das fontes de descargas sobre o tempo;
2. Distribuição do número de descargas sobre a fase da descarga, $H_n(\varphi)$, a qual representa o número de pulsos de DP em cada janela do eixo de ângulo de fase ($0^\circ - 360^\circ$);
3. Distribuição da amplitude média das descargas, $H_{qave}(\varphi)$, a qual provê a amplitude média como uma função do ângulo de fase. Esta corresponde ao número total de DP em cada janela de fase dividido pelo número de descargas ocorrendo naquela janela;
4. Distribuição da máxima amplitude das descargas, $H_{qmax}(\varphi)$, que corresponde ao máximo valor de DP observado sobre cada janela do eixo do ângulo de fase.

As distribuições são divididas para amplitudes positivas e negativas do mapa PRPD. Tomando como exemplo o padrão PRPD da Figura 2.8(a), extraímos os histogramas de interesse mostrados na Figura 2.8(b) a (e). Note a presença de duas curvas em cada gráfico, uma com o resultado de distribuição das DP positivas (em linha azul) e outra com o resultado de distribuição das DP negativas (em linha vermelha).

Conforme descreveremos mais adiante, no Capítulo 4, diversos parâmetros estatísticos, denominados impressões digitais (*fingerprints*), têm sido utilizados para prover uma análise de todas estas distribuições [51], [119]. Assim, é possível extrair características muito úteis para aplicação em algoritmos de separação e classificação de dados de DP.

2.4.3 Análises de Tendência

A DP é frequentemente um sintoma de uma falha no equipamento e não uma causa direta, sendo difícil especificar o nível quantitativo de DP para o qual o isolamento provavelmente entrará em colapso.

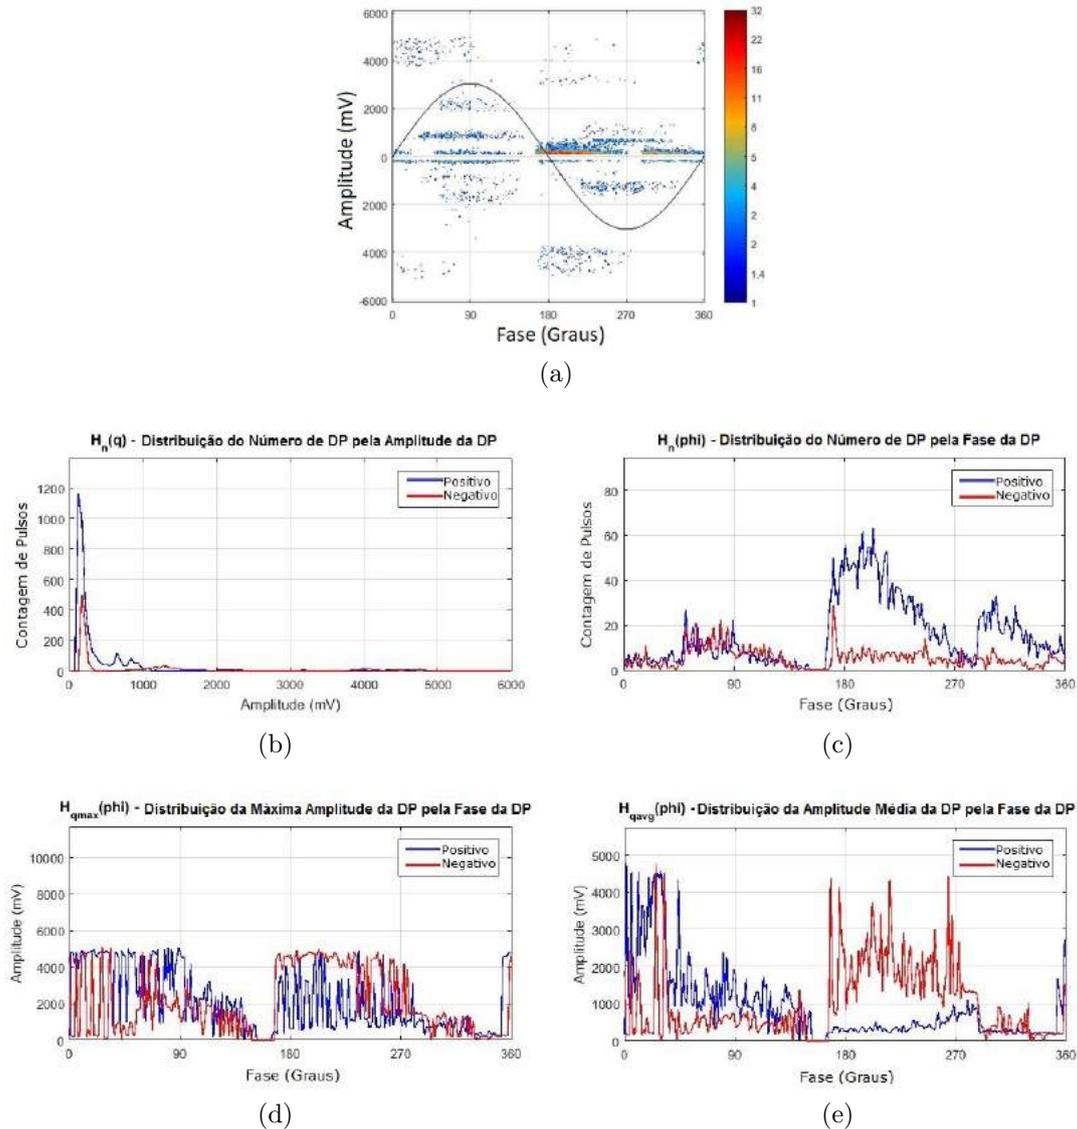


Figura 2.8: Histogramas de uma medição de DP: (a) PRPD medido (b) $H_n(q)$; (c) $H_n(\varphi)$; (d) $H_{qmax}(\varphi)$; (e) $H_{qavg}(\varphi)$.

Na análise de resultados de DP é necessário identificar se existem problemas no isolamento, indicados por níveis significantes de atividade de DP. Em um segundo passo, determinar o grau de degradação é primordial para identificar uma fonte específica de atividade de DP dentro do equipamento. Algumas das mais importantes ferramentas que podem prover estas considerações são as análises de tendência e do padrão PRPD. Conclusões relevantes também podem ser extraídas da análise de várias outras informações do equipamento, como histórico de manutenções, linha de testes, condições de operação, inspeção visual, conhecimento do projeto da máquina, entre outros dados que contribuem para o diagnóstico.

Uma maneira desejável de analisar as medições *on-line* de DP é visualizar a curva de tendência para uma quantidade característica de uma DP particular sobre

um longo período de tempo. A amplitude do pulso de DP é um parâmetro típico que pode ser usado para uma avaliação justa de tendência (verifique o exemplo da Figura 2.9). Também podem ser usadas quantidades adicionais como a corrente de descarga, a energia de DP, a potência média de DP, o Número de Quantidade Normalizado (*Normalized Quantity Number* - NQN), a frequência de repetição dos pulsos ou outros. Ambas fornecem informações significantes da degradação do sistema isolante [118].

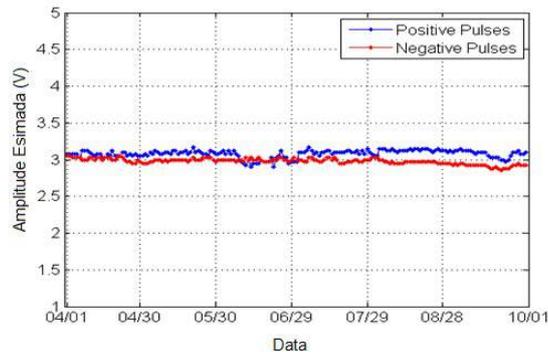


Figura 2.9: Exemplo de visualização de tendência da amplitude de DP.

Como o comportamento da DP pode ser afetado pelas condições de operação, quando analisando os parâmetros sobre o tempo, é imperativo reter simultaneamente outras informações, tais como a temperatura, o fator de potência, a tensão no terminal e a corrente do equipamento, além de umidade, temperatura e pressão ambientes.

Geralmente, se a condição do equipamento é estável ao longo do tempo, então o comportamento de tendência se manterá estável. Portanto, o isolamento não apresenta degradação significativa. No entanto, se existir alguma deterioração devido à operação, então normalmente a tendência exibirá variações consideráveis ao longo do tempo, indicando que ocorreu alguma degradação significativa.

2.5 Ruído Característico em Medições de DP

Ruído (ou interferência) pode ser definido como qualquer sinal que não esteja relacionado com o sinal de entrada. Dependendo da forma como se propagam, estes distúrbios aparecem de forma conduzida ou irradiada.

A principal dificuldade encontrada em medições de DP é o acoplamento de interferências que afetam diretamente a sensibilidade e a confiabilidade dos dados de DP adquiridos. Em casos de medições realizadas em campo, os níveis de interferências eletromagnéticas geralmente possuem amplitudes elevadas em relação

aos pulsos de DP, o que dificulta ainda mais o processamento dos dados. As mais importantes destas são [120], [121]:

Interferências de Espectro Discreto (*Discrete Spectrum Interferences - DSI*) Ruído com espectro de frequência de banda estreita proveniente de sistemas de comunicações, como ondas de rádio de Amplitude Modulada (AM), de Frequência Modulada (FM), sinais de telefonia móvel e de TV. Usualmente ruído AM exerce maior influência na medição, pois ocupa uma banda que coincide com a banda passante de grande parte dos sistemas de medição (144 - 30000 kHz) [10]. No entanto, em medições realizadas na banda de UHF são os sinais de FM, celular, TV e mesmo WIFI que podem interferir. Também podemos incluir nesta classe de interferência os harmônicos existentes na rede de alimentação, mas em geral estes são eliminados pela própria impedância de medição (filtro passa altas).

Interferências pulsantes periódicas Ruído pulsante periódico que tem origem em dispositivos de eletrônica de potência como disparo de tiristores e chaveamentos. Apresentam-se em forma de pulsos, fazendo com que cubram níveis mais altos de frequência, i.e., ocupam uma banda mais larga do espectro de frequência do que ruído senoidal.

Interferências pulsantes aleatórias (estocásticas) Ruído gerado por descargas atmosféricas, chaveamentos infrequentes, corona emitidos por equipamentos de alta tensão, arco elétrico entre contatos adjacentes, descargas eletrostáticas, centelhamentos, arcos de máquinas rotativas, descargas atmosféricas, entre outros. São interferências de difícil distinção dos sinais de DP [118], já que detêm características bastante similares às dos pulsos de DP.

Outras fontes de ruído aleatório contínuo (oriundo do ambiente ou do próprio sistema de medição) Ruído estocástico contínuo pode surgir a partir dos dispositivos eletrônicos existentes nos sistemas de medição (amplificadores, conversores A/D), ruído térmico existente na fonte de alimentação, na linha de transmissão e nos próprios equipamentos em avaliação, etc. Este tipo de interferência se distribui ao longo de toda a faixa de frequência, com uma densidade espectral de energia constante (mesma potência em uma banda de frequência com comprimento fixo). São normalmente modelados como ruído branco.

Na maioria dos casos, interferências externas produzem indicações falsas de DP, reduzindo assim a credibilidade de medição de DP como uma ferramenta de

diagnóstico. Portanto, é imperativo que um sistema de medição de DP detenha a habilidade de separar o ruído do sinal de interesse. Na Figura 2.10 ilustramos o sinal típico de medição de DP num gerador de 13.8 kV - 60 Hz. A aquisição foi feita com uma frequência de amostragem de 100 MHz e 14 bits de resolução, com o número de amostras de um período completo da tensão aplicada (1/60 s). Repare na presença de ruído branco de fundo e interferências pulsantes periódicas (provenientes de tiristores) defasados em cerca de 60° entre si e com amplitudes bem superiores (acima de 250 mV) aos pulsos de DP.

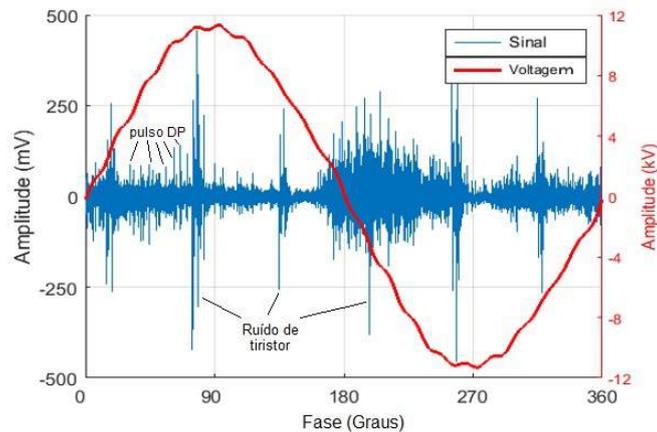


Figura 2.10: Exemplo de medição de DP com a presença de ruído.

Muitos pesquisadores têm proposto o uso de técnicas de processamento de sinais para suprimir as diferentes componentes de ruído presentes em uma medição, tais como autocorrelação, estatísticas de ordem elevada, filtros adaptativos [122], filtros *notch* [123], limiarização por FFT e métodos baseados em wavelets. Técnicas de extração de características, combinadas com métodos de agrupamento e de classificação por redes neurais, também têm sido aplicadas. Cada uma destas técnicas tem grau de sucesso variável, dependendo do tipo de ruído.

Em [90], apresentamos uma metodologia para identificação automática de frequências DSI em medições de DP e uma nova metodologia para avaliação da influência de DSI em cada medição particular de DP. Os sinais foram tratados com sucesso por meio de filtros Butterworth projetados para rejeitar um canal específico do espectro que causa a interferência. V. Nagesh e B. I. Gururaj em [121] aplicaram filtros IIR *notch* para filtragem de DSI. Estes sinais podem ser tratados com filtros digitais mais simples, já que pulsos de DP têm espectro de frequência relativamente amplo e, portanto, bem distinto do espectro de DSI.

Ruído pulsante periódico também pode ser facilmente eliminado através de filtros analógicos passa altas (passivos ou ativos), já que normalmente estes pulsos são

de decaimento lento (componentes de frequência bem inferiores aos vistos em pulsos de DP). Existe a possibilidade de usar filtros digitais como o Butterworth, filtros FIR ou mesmo fazer o tratamento no domínio do tempo. No entanto, cuidados devem ser tomados para compensar os atrasos introduzidos nas diferentes componentes do sinal após a filtragem.

A maior dificuldade está em identificar e suprimir interferências pulsantes estocásticas, já que estas possuem características em comum (tanto no domínio do tempo quanto da frequência) com os pulsos de DP. Também, o ruído pulsante é uma ocorrência de natureza aleatória, como as DP, o que agrava o processo de separação. Para sua extração muitas vezes é preciso o uso de técnicas de agrupamento ou classificação, como redes neurais artificiais, algoritmo *K-means*, lógica Fuzzy, entre outras [42], [64], [65], [51], [59], [57].

Nesta tese daremos continuidade à pesquisa realizada em [35], aprofundando as investigações das técnicas de redução de ruído por meio da transformada wavelet para atenuar interferências externas como ruído branco, Interferência de Sinal Direto (*Direct Signal Interference* - DSI) e qualquer combinação destes, presentes simultaneamente e sobrepostos com os sinais de DP. Ademais, são estudadas diferentes técnicas de agrupamento para possibilitar a separação das diversas fontes de ruído pulsante estocástico presentes nas medições de DP. Em complemento são desenvolvidas novas técnicas de processamento digital para os dados de DP, as quais também são implementadas em um sistema de análise e separação destes dados, com a finalidade de aperfeiçoar o diagnóstico de equipamentos de AT.

Capítulo 3

Transformada Wavelet Aplicada à Extração de Sinais de Descargas Parciais Imersos em Ruído

Matematicamente, a Transformada Wavelet (*Wavelet Transform* - WT) refere-se a uma representação de um sinal em termos de funções escaladas e deslocadas de uma forma de onda oscilante de comprimento finito e rápido decaimento (conhecida como função wavelet ou wavelet mãe). Esta tem sido reconhecida como uma técnica efetiva de redução de ruído no processamento de sinais e de imagens, devido ao seu potencial em manter ambas informações, no domínio do tempo e da frequência [28]. O sinal pode ser redefinido em multi-escalas via translações e expansões (compressões e dilatações), o que permite uma maior resolução no tempo em frequências mais altas e na frequência em frequências mais baixas (princípio da incerteza). Isto pode ser adaptado para atender à análise tempo-frequência do sinal em qualquer escala. Em função desta capacidade, a WT se apresenta como uma potente ferramenta de análise de fenômenos transientes, não estacionários ou variantes no tempo, como é o caso dos sinais de DP [37].

Para fins de uma melhor compreensão desta ferramenta, bem como das suas dificuldades e limitações, neste capítulo discutiremos cada uma das etapas envolvidas na redução dos níveis de ruído presentes na avaliação de sinais DP usando a WT.

3.1 Processo Wavelet de Redução de Ruído

O ruído degrada a acurácia e a precisão de uma análise, além de reduzir o limite de detecção do instrumental aplicado em medições de DP. Frequentemente a WT é uma ferramenta destinada à atenuação de ruído aleatório contínuo (ruído branco), pois após a decomposição de um sinal no domínio wavelet observa-se que a densidade média dos coeficientes é inversamente proporcional à escala diádica $1/2^j$ (j indica o nível de decomposição), i.e., metade do número dos coeficientes locais extremos não se propaga de uma escala $1/2^j$ para a próxima $1/2^{j+1}$, distribuindo-se de maneira uniforme entre as escalas. Como o padrão de distribuição dos coeficientes wavelet do sinal de DP (que tende a ter sua energia concentrada em poucos níveis de decomposição) difere do padrão do ruído, torna-se mais fácil identificar e separar os sinais de DP do ruído presente [20], [28], [29]. No entanto, não só o ruído branco pode ser atenuado na filtragem wavelet, mas também o ruído com componentes de frequência que não coincidam com as componentes de frequência dos sinais de DP.

Basicamente o processo wavelet de redução de ruído (*wavelet shrinkage process*) envolve três etapas [28], [67]:

1. Determinar a estrutura da WT a ser aplicada, o número de níveis de decomposição J e a função wavelet que será empregada em cada um dos j níveis (onde $j = 1, 2, \dots, J$) e, então, realizar a decomposição do sinal analisado em seus coeficientes wavelet;
2. Calcular os valores de limiar (*threshold*) utilizando uma das regras de seleção de limiar, as quais se baseiam numa estimativa estatística do nível de ruído presente no sinal. Aplicar o valor calculado em uma função de limiarização para, assim, reduzir os coeficientes da figura de ruído e preservar os coeficientes do sinal de interesse, o pulso de DP;
3. Reconstruir o sinal com a aplicação da Transformada Wavelet Inversa (correspondente à estrutura selecionada na primeira etapa) nos coeficientes limiarizados, para obter o sinal filtrado no domínio do tempo.

Na Figura 3.1 ilustramos melhor cada uma das etapas envolvidas no processamento wavelet de um sinal bruto que se deseja tratar.

Como diversos parâmetros estão envolvidos, os mesmos devem ser cuidadosamente selecionados de acordo com as características do sinal, a fim de maximizar seus coeficientes wavelet acima do nível de ruído. Assim, a performance da filtragem estará intimamente relacionada com cada um destes parâmetros e, obviamente, alguns destes terão uma maior influência na qualidade do resultado final. A determinação

destes parâmetros se mostra um desafio de otimização [124].

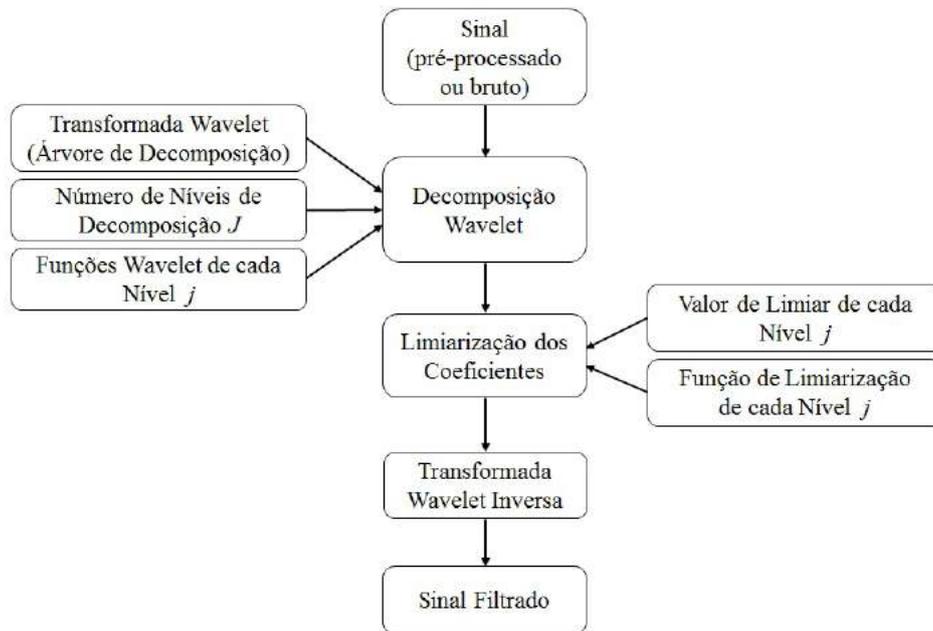


Figura 3.1: Processo de redução de ruído pela WT.

A transformada wavelet normalmente é implementada pela associação de filtros FIR, podendo-se utilizar decimadores (*downsamplers*) e interpoladores (*upsamplers*) entre cada nível de filtros [16], [113], [121] dependendo da estrutura da transformada wavelet utilizada. Na Seção 3.2 discutiremos as diferentes topologias de decomposição wavelet que podem ser aplicadas.

Na Figura 3.2 apresentamos um sinal de DP típico medido numa barra de gerador em laboratório. Este sinal foi tratado com a clássica Transformada Wavelet Rápida (*Fast Wavelet Transform - FWT*), usando a metodologia apresentada em [33], [35], [90], sendo que o pulso de DP fica evidente após a filtragem.

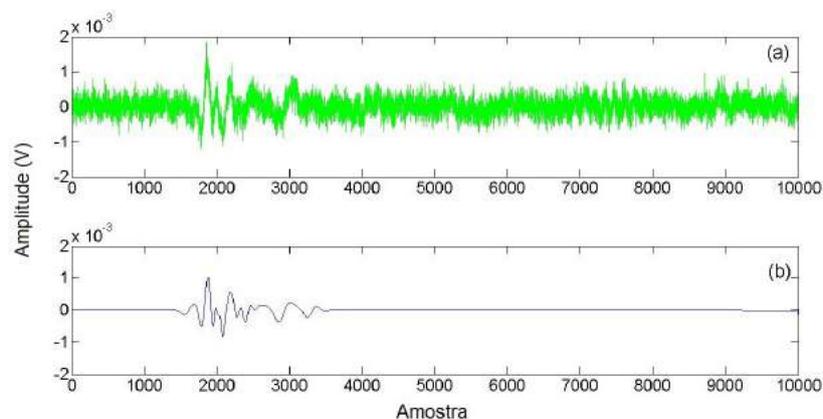


Figura 3.2: FWT aplicada na extração de ruídos de DP: (a) sinal de DP medido em laboratório; (b) sinal de DP filtrado.

Em [56], aperfeiçoamos os métodos de seleção do número de níveis e das funções wavelet, os quais forneceram excelentes resultados. No entanto, fica em aberto o estudo aprofundado das técnicas de limiarização. Portanto, um dos objetivos deste trabalho é investigar mais a fundo a seleção desta variável, em busca de melhores resultados.

3.2 Características das Diferentes Transformadas Wavelets

No processamento wavelet de sinais de DP são aplicáveis diversos tipos de transformadas, dentre as quais podemos destacar: a FWT, a Transformada Wavelet em Pacotes (*Wavelet Packet Transform* - WPT), a Transformada Wavelet Estacionária (*Stationary Wavelet Transform* - SWT) e a Transformada Wavelet Complexa de Árvore Dupla (*Dual-Tree Complex Wavelet Transform* - DTCWT) [10], [125], [126], [127]. Estas se diferenciam basicamente pela estrutura dos bancos de filtros e/ou pela presença de decimadores e interpoladores entre cada sub-banda j de análise e síntese, respectivamente.

Em boa parte das pesquisas, é dada preferência à filtragem pela FWT, devido à facilidade de implementação e à velocidade de processamento numa estrutura que decompõe somente os coeficientes de aproximação gerados a cada nível e reduz o número de amostras dos coeficientes nestes níveis com o uso de decimadores.

Nas Subseções que se seguem fornecemos uma breve explicação da Transformada Wavelet Contínua (*Continuous Wavelet Transform* - CWT), necessária à compreensão das demais transformadas e da popular FWT. Por não fazer parte de nossa proposta de estudo avaliar a performance das outras transformadas wavelet mencionadas, não entraremos em mais detalhes sobre as mesmas e indicamos como referências complementares [128], [23], [25], [26], [27], [67],[129], [130], [131], [132], [133] e [134].

3.2.1 Transformada Wavelet Contínua (CWT)

A transformada wavelet contínua de um sinal $x(t)$ unidimensional contínuo no tempo e pertencente ao espaço das funções de quadrado integrável $\mathcal{L}^2(\mathbb{R})$, definida na Equação (3.1), executa a decomposição deste sinal em um conjunto de funções base formadas pelas expansões (compressões e dilatações) e deslocamentos de uma única função wavelet $\psi(t)$ (denominada wavelet mãe).

$$W_\psi(a, b) = \int_{-\infty}^{+\infty} x(t) \psi_{a,b}^*(t) dt = \int_{-\infty}^{+\infty} x(t) \psi_a^*(b-t) dt, \quad a, b \in \mathbb{R}, a \neq 0, \quad (3.1)$$

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), \quad (3.2)$$

onde a corresponde ao fator de escala e b ao operador de translação. Na Equação (3.1) é possível notar que quanto maior o valor de a maior será a resolução na frequência e menor a resolução no tempo. A variável b promove o deslocamento (translação) da wavelet no tempo. O termo $a^{-1/2}$ é um fator de normalização que garante que a energia de $\psi_{a,b}(t)$ seja independente de a e b . A CWT também pode ser representada com o operador convolução \otimes , como se segue:

$$W_\psi(a, b) = (x \otimes \psi_a^*)(b), \quad \psi_a^* = \frac{1}{\sqrt{a}} \psi^*\left(\frac{-b}{a}\right). \quad (3.3)$$

O valor de $W_\psi(a, b)$ representa uma medida de similaridade entre o intervalo examinado do sinal e as wavelets escaladas e deslocadas.

Portanto, a CWT mapeia um sinal unidimensional no tempo numa representação bidimensional tempo-escala através de filtros passa-banda com frequências centrais variáveis (dependentes da escala a), fornecendo, assim, a localização simultânea do sinal em ambos os domínios, do tempo e da frequência, o que não pode ser obtido com a transformada de Fourier.

O resultado do produto de largura de banda de tempo de uma transformada wavelet contínua é o quadrado daquela do sinal, sendo extremamente redundante. Para a maioria das aplicações, entretanto, o objetivo do processamento de sinais é representar o sinal eficientemente com poucos parâmetros. O uso de uma transformada discreta pode reduzir o resultado do produto de largura de banda de tempo.

3.2.2 Transformada Wavelet Rápida (FWT)

A transformada wavelet discreta é obtida pela caracterização da variável escala a em $a = 2^m$ e assumindo a variável b como $b = n2^m$ em uma dada escala m (m, n sendo valores inteiros), onde a escala $m \in \mathbb{Z}$ e $n \in \mathbb{Z}$. Desta maneira é possível evitar o consumo de tempo no cálculo dos coeficientes e eliminar as redundâncias dos coeficientes wavelet. A transformada wavelet discreta rápida implementada baseada

no esquema de filtragem de pares de filtros $h_j(-n)$ e $g_j(-n)$ arranjados em diferentes escalas numa estrutura em árvore, como ilustrado na Figura 3.3. As respostas ao impulso dos filtros de análise $h_j(-n)$ e $g_j(-n)$ representam, respectivamente, os filtros passa-altas, formados pela função wavelet, e os filtros passa-baixas, formados pela função escala, para o nível de decomposição j . Quando o sinal $x(t)$ com k amostras passa através desse par de filtros $h_j(-n)$ e $g_j(-n)$, a WT permite obter as componentes de baixas frequências e as componentes de altas frequências do sinal, respectivamente, os primeiros conhecidos como coeficientes de aproximação c_j e os outros conhecidos como coeficientes de detalhe d_j .

A função escala $\phi(t)$ e a função wavelet $\psi(t)$ são definidas por:

$$\phi(t) = \sum_{n=-\infty}^{\infty} h(n) \sqrt{2} \phi(2t - n), \quad (3.4)$$

$$\psi(t) = \sum_{n=-\infty}^{\infty} g(n) \sqrt{2} \phi(2t - n). \quad (3.5)$$

Os coeficientes de aproximação e de detalhe no nível j são obtidos, respectivamente, pelo produto interno entre o sinal de entrada e a função escala e pelo produto interno entre o sinal de entrada e a função wavelet, ou seja,

$$c_j(k) = \langle x(t), \phi_{j,k}(t) \rangle = \int x(t) \phi_{j,k}(t) dt, \quad (3.6)$$

$$d_j(k) = \langle x(t), \psi_{j,k}(t) \rangle = \int x(t) \psi_{j,k}(t) dt, \quad (3.7)$$

onde

$$\phi_{j,k}(t) = 2^{j/2} \phi(2^j t - k), \quad (3.8)$$

$$\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k). \quad (3.9)$$

O sinal pode ser perfeitamente reconstruído usando a transformada inversa discreta rápida a partir dos coeficientes de detalhes d_j e de aproximação final c_J . Em cada nível de síntese, ambos os coeficientes serão inicialmente interpolados por um fator igual a 2 e, então, convoluídos com os filtros de síntese $h_j(n)$ e $g_j(n)$ para

produzir um sinal de aproximação. Os coeficientes do filtro de síntese são versões inversas, no arranjo de tempo, dos filtros de decomposição (de análise) $h_j(-n)$ e $g_j(-n)$, ou seja, versões espelhadas um do outro.

Esta transformada é bastante útil na redução de ruído em sinais de DP, principalmente em função de seu rápido processamento. Para efeitos de extração de ruído, é aplicada uma etapa de limiarização (que será discutida na Seção 3.6) dos coeficientes obtidos após a decomposição do sinal. Com esta medida é possível obter o sinal de DP filtrado. Para exemplificar, a Figura 3.3 ilustra o processo completo de uma filtragem de um sinal pela FWT para uma função wavelet da família *Symlet 6* (*sym6*), número de escalas $J = 3$ e função de limiarização abrupta.

3.3 Funções Wavelet Aplicáveis no Processamento de Pulsos de DP

Para ser dita wavelet, uma função $\psi(t)$ deve atender as seguintes condições:

1. A área total sob a curva da função é nula, ou seja, $\int_{-\infty}^{\infty} \psi(t) dt = 0$;
2. A energia da função é finita, ou seja $\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty$;

Estas condições são equivalentes a dizer que $\psi(t)$ é uma função quadrado integrável, i.e., que pertence ao conjunto $\mathcal{L}^2(\mathbb{R})$ das funções quadrado integráveis. As propriedades acima sugerem que $\psi(t)$ tende a oscilar acima e abaixo do eixo t , e que tem sua energia concentrada em uma certa área.

Essa característica de energia concentrada em uma área é o que diferencia a análise usando wavelets da análise de Fourier, já que esta última usa as funções de seno e cosseno que são periódicas e de duração infinitas.

A propriedade de ortonormalidade é importante no processamento wavelet, e é obtida através da decomposição do sinal por meio de duas funções $\psi(t)$ e $\varphi(t)$, a função wavelet e a função escala, respectivamente. A função escala é uma função contínua e quadrado integrável, mas não satisfaz a premissa 1; em geral, seu valor médio é normalizado em 1. As funções wavelet e escala descrevem o banco de filtros passa-faixa a ser empregado na etapa de análise e síntese e precisam atender à chamada condição de reconstrução perfeita.

Uma extensa quantidade de funções wavelet é descrita na literatura [135], [136], [137], [138]. No entanto, apenas algumas são aplicáveis no processamento de pulsos de DP, por apresentarem propriedades relevantes no tratamento de pulsos irregulares

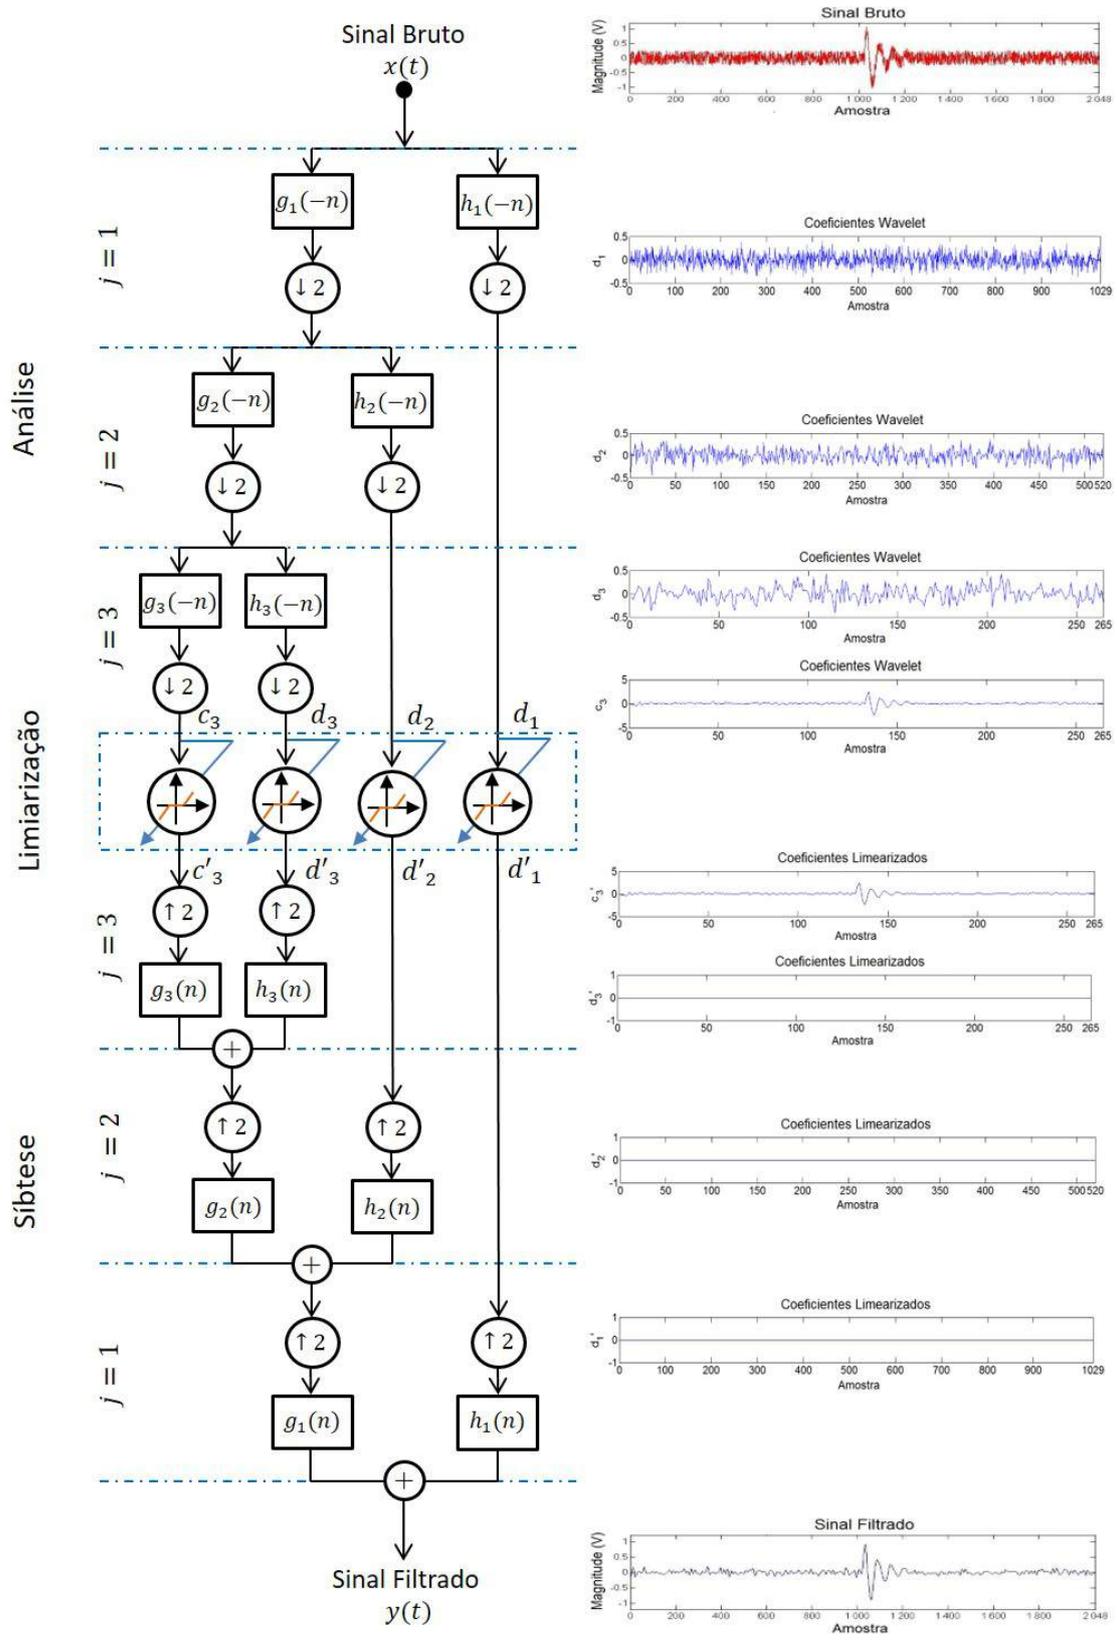


Figura 3.3: Exemplo de filtragem wavelet por FWT em 3 níveis de um sinal $x(t)$ (neste caso um sinal de DP com ruído).

e de rápido transiente, como é o caso de pulsos de descarga. Dentre tais propriedades, merecem destaque as seguintes [20], [41], [67], [118]: ortogonalidade, duração limitada, regularidade, algoritmo rápido e assimetria. Também é desejável que estas funções possam ser utilizadas na estrutura de análise por wavelet discreta, já que a maioria das aplicações em filtragem de DP emprega esta transformada.

Em [126], são descritos cinco tipos de wavelets:

- ortogonais com filtros FIR - podem ser definidas apenas pelo filtro passa-baixas de escala g , já que os filtros passa-altas (representados pela função wavelet) são filtros espelhados em quadratura. O filtro é usado tanto para decomposição (análise) quanto para reconstrução (síntese). Enquadram-se nestas as famílias *Haar*, *Daubechies*, *Coiflets*, *Symlets*, *Legendre*, *Beylkin* e *Discrete Approximation Meyer*;
- biortogonais com filtros FIR - podem ser definidas por meio de dois filtros de escala g_d e g_r , para decomposição e reconstrução, respectivamente. Exemplos são as famílias *Biorthogonal Splines* e *Reverse Biorthogonal*;
- ortogonais sem filtros FIR e com função de escala - estas wavelets podem ser definidas através das funções wavelet e de escala contínuas. A wavelet da família *Meyer* é uma destas e só pode ser utilizada na CWT;
- sem filtros FIR e sem função de escala - são definidas a partir somente da função wavelet. Incluem as wavelets da família *Morlet* e *Mexican Hat*. Também são aplicáveis apenas na CWT;
- complexa sem filtros FIR e sem função de escala - também são definidas através apenas da função wavelet. As famílias *Complex Gaussian*, *Shannon*, *Complex Frequency B-spline* e *Complex Morlet* são exemplos destas wavelets. Todas estas podem ser aplicadas apenas na Transformada Wavelet Contínua Complexa.

Levando em conta estas propriedades e o fato de que grande parte dos estudos voltados ao processamento wavelet de sinais de DP utiliza FWT, WPT ou SWT [10], [139], [140], [24], [25], [26], [27], [42], [97], [125], ficamos limitados às funções wavelet dos tipos ortogonais e biortogonais com filtros FIR. Em [21], os autores sugerem o uso da Transformada Wavelet Contínua Complexa, na qual foi utilizada uma das famílias de funções wavelet complexas disponíveis.

No trabalho desenvolvido em [35], fizemos análises apenas com as funções wavelet das famílias *Daubechies*, *Symlets* e *Coiflets*, por serem bastante difundidas na extração de ruído de pulsos de DP [20], [41], [67], [118], [141]. Pretende-se neste

trabalho avaliar a performance dos algoritmos de redução de ruído com as wavelets das famílias *Legendre*, *Beylkin* e *Discrete Approximation Meyer*, e com as wavelets biortogonais.

3.4 Métodos para Determinação do Número de Níveis de Decomposição

Muito tem se discutido a respeito do número de níveis de decomposição adequado para filtragem de pulsos de DP. Este tópico ainda é um desafio que, por vezes, é deixado de lado em diversas publicações [1], [15], [17], [41], [67], [124], onde os autores selecionam empiricamente, com base em uma simples verificação visual de que um número de níveis J produz um bom resultado na atenuação do ruído presente no pulso. Mortazavi *et al.* [10] sugeriram que o número de níveis depende das características de frequência dos sinais de DP e do ruído, e que poderia ser determinado por tentativa e erro. Existem ainda publicações [142] onde sequer é apresentada uma justificativa para escolha deste parâmetro.

Xiaorong *et al.* [45], porém, chamam a atenção para o fato de que um nível de resolução baixo levará a um resultado ruim na filtragem, pois o sinal e os componentes de interferência do pulso de DP podem ficar agrupados nos mesmos coeficientes, dificultando a separação [11]. No entanto, se o valor selecionado for muito alto, pode não ocorrer uma melhora expressiva no sinal tratado, com o custo de um aumento considerável no tempo de processamento.

O número máximo de níveis com o qual um sinal de comprimento N pode ser decomposto é determinado por $J_{max} = \text{fix}(\log_2 N)$, onde *fix* arredonda o valor entre parêntese para o inteiro mais próximo. No entanto, o filtro wavelet usado impõe uma restrição sobre este número máximo, de tal forma que o comprimento do sinal no nível mais alto de decomposição não pode ser menor do que o comprimento N_w do filtro wavelet que estiver sendo aplicado, ou seja,

$$J_{max_M} = \text{fix} \left(\log_2 \left(\frac{N}{N_w - 1} \right) \right). \quad (3.10)$$

Em [143], Shetty *et al.* sugerem que o número de decomposições para FWT seja calculado de acordo com a frequência de amostragem F_s e a frequência de corte F_d do circuito detector utilizado na medição do sinal de DP, como se segue:

$$J = \text{fix} \left(\frac{\log_2(F_s) - \log_2(F_d)}{\log(2)} - 1 \right). \quad (3.11)$$

Em [20], Zhou *et al.* afirmaram que a filtragem pode ser melhorada pelo conhecimento prévio da distribuição da energia nos diversos níveis da FWT, a qual dependerá fundamentalmente do espectro dos sinais de DP e da taxa de aquisição utilizada no sistema de medição.

R. Umamaheswari e R. Sarathi [143] descreveram uma equação para tentar determinar a escala ideal de decomposição para a estrutura da WPT. Nesse caso a escolha é feita de acordo com a sub-banda de interesse, em que a energia do sinal está concentrada. A escala efetiva de decomposição é, então, definida por:

$$J = \text{round} \left(\log_2 \left(\frac{F_s}{f_{min}} \right) \right) - 1, \quad (3.12)$$

onde f_{min} é a menor frequência da sub-banda de interesse do sinal e *round* arredonda para o inteiro mais próximo. O objetivo é conseguir coeficientes wavelet suficientes para representar o sinal e ao mesmo tempo diminuir tanto quanto possível o tempo de processamento, o qual é um fator crítico para a árvore de análise da WPT uma vez que a quantidade de sub-bandas geradas cresce à razão de 2^J .

Junhyuck Seo *et al.* [144] sugerem que o número de níveis de decomposição seja determinado pelo cálculo da energia normalizada dos sinais reconstruídos, os quais são obtidos depois da limiarização multi-escalar do nível de decomposição corrente. Se a diferença entre a energia no nível de decomposição corrente e no nível anterior é insignificante, o algoritmo de busca é parado e então o nível anterior é selecionado como o nível desejado, conforme exposto na Figura 3.4.

Em estudos mais recentes implementamos um algoritmo denominado NWDLS [33], [35], [40], [68] para identificar o número mínimo de níveis de decomposição na FWT, necessário para representar precisamente um sinal particular no domínio wavelet e conseguir bons resultados de filtragem. A determinação do número de níveis depende do conhecimento prévio da distribuição de energia do sinal ao longo das várias sub-bandas da FWT. Tal distribuição dependerá da densidade espectral de energia do sinal de DP e, por consequência, da taxa de amostragem do sistema de medição. Foi a partir da propriedade de divisão do espectro em $J + 1$ sub-bandas (componentes wavelet) e da frequência mínima F_{min} a representar neste espectro, que é sugerida a busca do número de níveis através do espectro de energia do sinal por

$$J = \text{fix} \left(\log_2 \left(\frac{F_s}{F_{\min}} \right) \right). \quad (3.13)$$

Para determinar a frequência F_{\min} , foi desenvolvido um algoritmo que calcula a quantidade de níveis M na qual pelo menos $(100 - p)\%$ da energia total do sinal é decomposta em subespaços de detalhe, conforme o fluxograma visto na Figura 3.5.

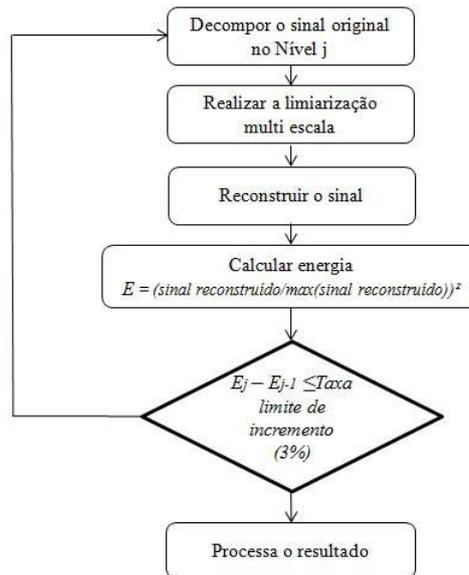


Figura 3.4: Procedimento proposto em [153] para determinar o número de níveis de decomposição.

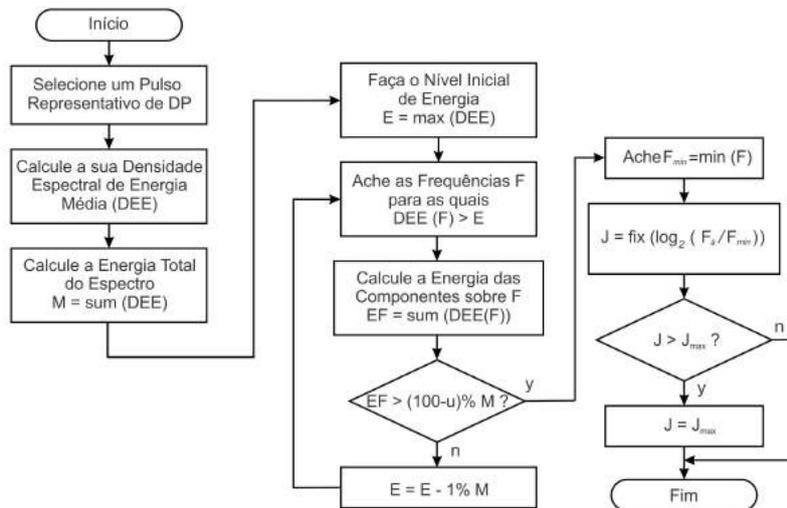


Figura 3.5: Fluxograma do algoritmo NWDL.

Como o algoritmo não considera nem o número de amostras do sinal nem o número de coeficientes dos filtros de decomposição, existe a possibilidade de que o

número de níveis calculado exceda o número máximo de níveis possível, dado pela Equação (3.10). Nesse caso, o número máximo J_{max} deve ser adotado.

Considere o exemplo de um pulso de DP de comprimento $N = 10000$ amostras, ilustrado na Figura 3.6(a), amostrado com $F_s = 1$ GHz, cujo espectro de potência é mostrado na Figura 3.6(b). A linha pontilhada horizontal indica o ponto no qual a frequência f corresponde a $p = 10\%$ da energia total do sinal e a linha pontilhada vertical indica a frequência com menor potência imediatamente maior do que a indicada pela linha horizontal, neste caso dada por $F_{min} = 1,099$ MHz. Substituindo este valor na Equação (3.13) encontramos $J = 9$ níveis de decomposição. Tal valor é suficiente para permitir separar as componentes de frequência presentes no sinal de DP, fornecendo um bom resultado de filtragem, sem a necessidade de decompor até J_{max} , que neste caso seria igual a 13 níveis.

Em resumo, concluímos que o algoritmo NWDLS, além de ser computacionalmente eficiente, representa um avanço na determinação do tipo de decomposição wavelet mais adequada para o processamento de sinais de DP por limiarização dos coeficientes wavelet.

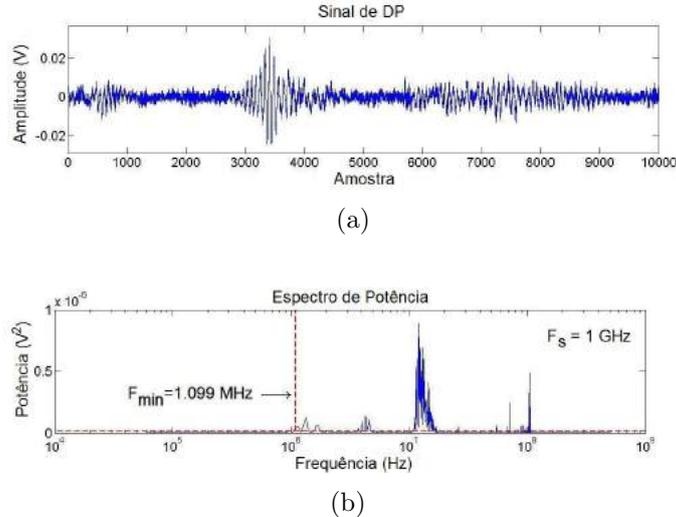


Figura 3.6: Exemplo do procedimento de seleção do número de níveis de decomposição: (a) Sinal de DP medido; (b) Espectro de potência do sinal.

O algoritmo também pode ser estendido para wavelets biortogonais, onde o espectro não necessariamente é dividido simetricamente em cada nível de decomposição. Neste caso, o número de níveis pode ser calculado como [68]:

$$J = \text{fix} \left(\frac{\log_2 \left(\frac{F_s}{2\lambda F_{min}} \right)}{\log_2 \left(\frac{1}{\lambda} \right)} \right), \quad (3.14)$$

onde λ (sempre menor que 1) corresponde à proporção pela qual o banco de filtro biortogonal divide o espectro normalizado.

Em [35], avaliamos extensivamente a influência da variação no número de níveis na efetividade da redução de ruído de pulsos de DP e notamos que, ao contrário do que se poderia esperar, utilizar o número máximo de níveis J_{max} numa decomposição wavelet pode ocasionar uma piora no resultado obtido em relação a um número J menor. Na Figura 3.7 é ilustrada tal constatação para diversos métodos de seleção da função wavelet (que serão discutidos na Seção 3.5), onde se observa que para um sinal de DP (aquisitado com 10000 amostras) decomposto até o nível $J_{max} = 13$ houve uma queda significativa da função custo [35] utilizada para indicar a eficiência da extração de ruídos. Nesse caso a melhor escala de decomposição é $J = 5$, sendo que o algoritmo NWDLS encontrou $J = 6$ para o sinal deste exemplo, i.e., um valor bem próximo do ideal. Verifica-se ainda que a performance varia de um método de seleção para outro, portanto, o melhor nível também está correlacionado com as funções wavelet (filtros) aplicadas.

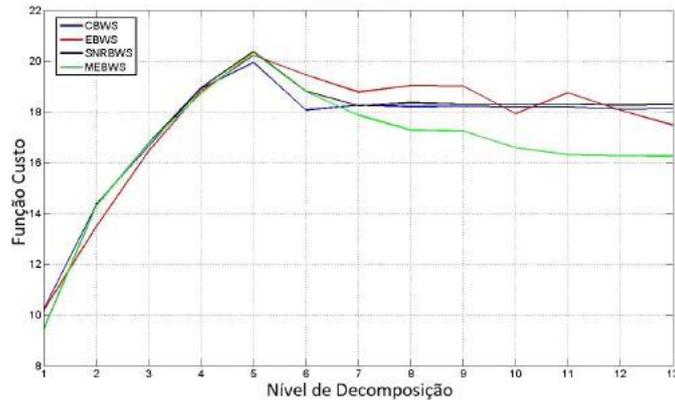


Figura 3.7: Valor da função custo para diferentes métodos de seleção wavelet (CBWS, EBWS, SNRBWS, MEBWS) versus número de níveis de decomposição. Fonte: [37]

3.5 Métodos de Seleção das Bases Wavelet (Filtros de Decomposição)

A seleção da base pode ser considerada a etapa mais crítica do processamento wavelet de sinais, pois as bases wavelet aplicadas ditam os pares de filtros de análise ($h_j(-n)$ e $g_j(-n)$) e de síntese ($h'_j(n)$ e $g'_j(n)$) em cada escala j . Portanto, a escolha adequada destes filtros permitirá representar as características de um sinal em um número reduzido de coeficientes wavelet que, concentrando a energia do sinal, terão maiores amplitudes e facilitarão, assim, o processo de filtragem [40].

Wang *et al.* sugerem que a função wavelet seja selecionada conforme o sinal processado. De acordo com [1], [142], para considerações de análise e síntese numa filtragem, a wavelet mais adequada para um sinal é aquela capaz de gerar em uma certa escala coeficientes (não ruidosos) com os maiores valores possíveis dentro do domínio tempo-escala. Para tanto, estes afirmam que quanto maior a similaridade entre a forma de onda do sinal desejado e a função wavelet, maior será a amplitude dos coeficientes que preservam as componentes importantes do sinal de interesse.

Chang *et al.* [23] propuseram um método heurístico que inicialmente decompõe o sinal em 4 níveis com a WPT, e busca a wavelet que minimiza o valor médio dos seus coeficientes, em módulo, que estão abaixo do valor de limiar, ou seja, minimiza os coeficientes ruidosos.

Assim como ocorre na seleção do número de níveis, em muitas publicações [2], [11], [15], [145] a função wavelet é determinada aleatoriamente, por tentativa e erro [11] ou por semelhança visual entre a forma de onda do sinal a ser tratado e a função wavelet.

Gouda *et al.* [124] selecionam funções wavelet com base num número maior de momentos nulos, i.e., wavelet de ordem maior. Isso permite aumentar a suavidade do espectro de cada filtro nos entornos de zero e π , minimizando o vazamento espectral na análise multirresolução do sinal.

Métodos mais eficientes de seleção das funções wavelet para aplicações de DP foram desenvolvidos por alguns autores, sendo estes bem aceitos pela comunidade científica. Dentre estes métodos podemos destacar:

- CBWS realiza a busca pela função wavelet que mais se assemelha com o pulso de DP, usando o Coeficiente de Correlação (CC) de Pearson para avaliar o grau de similaridade entre o sinal e cada função pertencente a um grupo predefinido de funções. Portanto, a função escolhida é aquela que maximiza o CC; entretanto, o método exige que tanto a função quanto o sinal sejam reescalados e deslocados para que coincidam em amplitude máxima e no primeiro cruzamento por zero após o máximo de cada forma de onda.
- EBWS assume que a energia do pulso de DP sempre se concentra sobre a banda de aproximação. Assim o método busca pela função wavelet que maximiza o nível de energia no coeficiente de aproximação para cada nível decomposto, o que faz deste um método dependente da escala de decomposição, podendo fornecer funções distintas para cada nível. No entanto, a partir de um certo nível de decomposição, esta prerrogativa não é necessariamente verdade. Nestes casos, o EBWS estaria operando de forma contrária à maximização dos

coeficientes wavelet do pulso de DP. Outro ponto é que funções wavelet de menor ordem tendem a concentrar maior energia nas bandas de aproximação; entretanto, wavelets de menor ordem não são tão suaves quanto as funções de maior ordem, causando em geral maior distorção na filtragem de pulsos de DP.

A fim de tentar contornar os problemas encontrados nos métodos anteriores e fornecer uma maneira mais concisa de seleção dos filtros wavelet, propusemos os seguintes métodos [35], [40], [67], [41], [68]:

- MEBWS, desenvolvido durante os estudos para tentar sanar os problemas observados no método EBWS, buscando pelas funções que maximizam a energia nos coeficientes de maior importância para recuperar o pulso de DP ao invés de maximizar a energia somente nos coeficientes de aproximação, de modo a melhorar os resultados de filtragem. Ainda assim, o método compartilha a desvantagem do EBWS pela tendência em selecionar wavelets de baixa ordem.
- SNRBWS, também desenvolvido para tentar sanar os problemas observados no método EBWS, buscando pelas funções que maximizam a razão entre os coeficientes da sub-banda identificada como a banda do pulso de DP e o máximo dos coeficientes da sub-banda assumida como a que contém a maior parte do ruído, ambos tomados em valores absolutos. Desta forma, as wavelets selecionadas para cada nível tendem a concentrar os coeficientes do sinal nas sub-bandas mais importantes para obter o sinal de DP. Além do mais, diferentemente do algoritmo EBWS, o método tende a fornecer wavelets de maior ordem. A proposta se mostrou superior aos demais métodos para o grupo de sinais avaliados.
- SWTBWS, apresentado em [40], assim como o CBWS, propõe o uso de uma única função para todos os níveis de decomposição, pela seleção do filtro que produz o máximo valor absoluto dentre os coeficientes calculados da SWT do pulso de DP. O método busca melhorar o CBWS em dois aspectos. Primeiro, a FWT calcula, em cada nível, o produto interno discreto (e não a correlação) entre o sinal e o filtro equivalente de cada nó da árvore de decomposição. Segundo, a função wavelet aproximada, obtida com um número suficientemente grande de iterações, não corresponde exatamente ao banco de filtro com o qual o produto interno é calculado.

3.6 Processo de Limiarização Wavelet

A capacidade fundamental de compressão ou esparsidade da WT faz com que sinais reais tendam a ter poucos coeficientes elevados que contenham a energia principal do sinal e outros pequenos coeficientes que podem ser ignorados [146].

Além disso, a energia do ruído é espalhada entre todos os coeficientes no domínio wavelet (principalmente a do ruído branco). Devido ao fato de que a transformada wavelet de um sinal ruidoso é uma combinação linear da WT de um ruído e do sinal original, através da aproximação por limiarização a potência do ruído pode ser reduzida consideravelmente com o valor de limiar adequado enquanto que as características do sinal são bem preservadas.

No método de redução de ruído no domínio wavelet, que é denominado de encolhimento wavelet (*wavelet shrinkage* [30]), os coeficientes wavelet de um sinal ruidoso são divididos em coeficientes importantes e não importantes, e cada um destes grupos é modificado por certas regras. Um valor de limiar muito baixo pode levar à inclusão de algum ruído, enquanto que um valor muito alto pode levar a perda de informação dos sinais de DP. Portanto, a funcionalidade do processo *shrinkage* se deve ao valor de limiar e à regra de limiarização (função de limiarização). As funções abrupta (*hard*) e suave (*soft*) são as mais básicas e foram introduzidas por Donoho e Johnstone [30]. Na próxima seção explicaremos estes métodos, mas por hora basta saber que os coeficientes abaixo do valor de limiar são zerados. Na limiarização abrupta, os coeficientes acima do valor de limiar permanecem inalterados. Na função suave os coeficientes acima do limiar são reduzidos pelo valor absoluto do limiar.

Além da função de limiarização, a seleção do valor ótimo de limiar para cada escala da WT é uma etapa essencial no processo de redução de ruídos. Os métodos de cálculo do valor ótimo de limiar podem ser divididos em três grupos principais:

1. Limiar universal (*universal-threshold*), onde um único valor de limiar é escolhido e aplicado a todos os coeficientes da WT. O método mais conhecido, o *Visu Shrink*, é descrito por D. L. Donoho *et al.* em [30] como a primeira técnica prática em filtragem de sinais;
2. Limiar em sub-bandas adaptativos, onde um valor de limiar é selecionado para cada sub-banda de detalhe gerada na decomposição wavelet [30], [87];
3. Limiar espacialmente adaptativo, selecionado para cada coeficiente wavelet ou para um grupo destes [147].

Seja um sinal ruidoso representado por um vetor $\boldsymbol{\omega} = [\omega_1, \omega_2, \dots, \omega_N]^T$, onde

cada amostra é dada por:

$$\omega_i = x_i + n_i, \quad i = 1, 2, \dots, N, \quad (3.15)$$

sendo x_i a i -ésima amostra de um sinal livre de ruído e n_i o i -ésima amostra de ruído, assumido como Gaussiano com distribuição idêntica independente (*independent identical distribution* - i.i.d.), i.e., $n_i \sim N(0, \sigma^2)$, a proposta da filtragem é encontrar uma aproximação $\hat{\mathbf{x}}$ da função original \mathbf{x} , com o menor Erro Quadrático Médio (EQM), i.e., minimizar o risco l^2 para um dado sinal ruidoso. O EQM entre x_i e \hat{x}_i é definido por:

$$EQM(\hat{\mathbf{x}}, \mathbf{x}) = \frac{1}{N} \|\hat{\mathbf{x}} - \mathbf{x}\|^2 = \frac{1}{N} \sum_{i=1}^N (\hat{x}_i - x_i)^2, \quad (3.16)$$

onde $\mathbf{x} = [x_1, x_2, \dots, x_N]^T$ e $\hat{\mathbf{x}} = [\hat{x}_1, \hat{x}_2, \dots, \hat{x}_N]^T$. Note que é usada a média ao invés da esperança estatística, pois a solução ótima é desejada para cada função individual ruidosa [72].

Após aplicar a FWT e assumirmos que esta é ortonormal, a Equação(3.15) pode ser reescrita como:

$$\omega_{j,k} = \mu_{j,k} + n_{j,k}, \quad (3.17)$$

sendo $\omega_{j,k}$ os coeficientes wavelet de $\boldsymbol{\omega}$, contendo k amostras na j -ésima escala de decomposição ($j = 1, 2, \dots, J$) e $\mu_{j,k}$ corresponde aos coeficientes wavelet livres de ruído. Já que a FWT é uma transformada ortonormal, o ruído permanece Gaussiano com mesma estatística no domínio wavelet ortonormal, i.e., $n_{j,k} \sim N(0, \sigma^2)$. Seja $\eta(\cdot)$ uma função de limiarização wavelet, então, a estimativa $\hat{\mathbf{x}}$ pode ser encontrada através de:

$$\hat{\mathbf{x}} = IFWT(\eta(FWT(\boldsymbol{\omega}))) = IFWT(\hat{\mu}_{j,k}). \quad (3.18)$$

Assim, a função risco dada na Equação(3.16) pode ser expressa como [79]:

$$EQM(\hat{\mathbf{x}}, \mathbf{x}) = \frac{1}{N} \sum_{i=1}^N (\hat{x}_i - x_i)^2 = \frac{1}{N} \sum_{j,k=1}^N (\hat{\mu}_{j,k} - \mu_{j,k})^2, \quad (3.19)$$

onde a estimativa dos coeficientes de wavelet $\hat{\mu}_{j,k}$ é igual a $\eta(\omega_{j,k})$.

O desenvolvimento apresentado visa demonstrar que a maioria dos coeficientes em uma WT com pouco ruído são efetivamente nulos. Portanto, podemos reformular o problema de recuperar x como o de recuperar os coeficientes significativamente não nulos, contra um ruído branco Gaussiano de fundo.

Isto justifica o uso de um esquema de limiarização para eliminar amostras de $\omega_{j,k}$ com valores pequenos e preservar amostras de $\omega_{j,k}$ com valores grandes.

Todo o processo de limiarização dos coeficientes wavelet pode ser descrito em três etapas:

1. Determinar fator de reescala para ajuste do valor de limiar;
2. Calcular o valor de limiar;
3. Usar o valor de limiar reescalado em conjunto com a função de limiarização para eliminar o ruído nos coeficientes wavelet gerados.

3.6.1 Fator de Reescala (Desvio Padrão do Ruído)

O fator de reescala nada mais é que a variável que indica o desvio-padrão do ruído σ_n presente num sinal. Na prática, entretanto, não se conhece o valor exato deste desvio-padrão; portanto, temos de fazer uma estimativa deste valor $\hat{\sigma}_n$. Em [148], é indicado determinar este valor usando um estimador de mediana dos coeficientes wavelet $\omega_{j,k}$ de detalhe gerados na primeira escala de decomposição ($j = 1$), composta praticamente por informação ruidosa, ou seja,

$$\sigma_n \cong \hat{\sigma}_n = \frac{\text{mediana}(|\omega_{j,k}| \mid j, k \in V_1)}{q} = \frac{\text{mediana}(|\omega_{1,k}|)}{q}, \quad (3.20)$$

onde a constante q pode variar entre 0.4 e 1, mas é normalmente aplicada com valor igual a 0.6745.

Sabendo-se que o dado ruidoso pode ser descrito por $\boldsymbol{\omega} = \boldsymbol{\mu} + \boldsymbol{n}$, com $\boldsymbol{\mu}$ e \boldsymbol{n} independentes um do outro, então

$$\sigma_{\boldsymbol{\omega}}^2 = \sigma_{\boldsymbol{\mu}}^2 + \sigma_{\boldsymbol{n}}^2, \quad (3.21)$$

onde $\sigma_{\boldsymbol{\omega}}$ é o desvio-padrão de $\boldsymbol{\omega}$. Já que \boldsymbol{n} é modelado com média zero ($\bar{\boldsymbol{n}} = 0$), $\sigma_{\boldsymbol{\omega}}^2$ pode ser definido empiricamente por [87]:

$$\sigma_{\omega}^2 = \frac{1}{N^2} \sum_{j,k=1}^N \omega_{j,k}^2, \quad (3.22)$$

em que N é o tamanho da sub-banda em consideração. Assim,

$$\hat{\sigma}_{\mu} = \sqrt{\max(\hat{\sigma}_{\omega}^2 - \hat{\sigma}_{\mathbf{n}}^2, 0)}. \quad (3.23)$$

No caso de $\hat{\sigma}_{\mathbf{n}}^2 \geq \hat{\sigma}_{\omega}^2$, $\hat{\sigma}_{\mu}^2$ é igualado a zero. Tal desenvolvimento pode ser usado para descrever o método Bayesiano [87], que faz uma estimativa dos parâmetros generalizados da distribuição Gaussiana dos coeficientes wavelet, possibilitando determinar o valor de limiar de maneira adaptativa para as características de cada sub-banda.

Uma forma mais robusta de estimativa do desvio-padrão dependente da escala $\sigma_{\mathbf{n}_j}$ dos coeficientes wavelet (e não mais apenas dos coeficientes da primeira escala de decomposição) é dada por:

$$\sigma_{\mathbf{n}_j} = \frac{\text{mediana}(|\omega_{j,k}| \mid j, k \in W_j)}{q}. \quad (3.24)$$

Também é possível realizar o processo de limiarização sem aplicar o fator de reescala, fazendo $\sigma_{\mathbf{n}_j} = 1$.

Em [79], o autor afirma ter obtido melhores resultados de filtragem usando o seguinte fator:

$$\sigma_{\mathbf{n}_p} = \frac{\text{mediana}(|\omega_{j,k}| \mid j, k \in W_1)}{0.6745} \times \sqrt{\frac{2p}{p+1}}, \quad (3.25)$$

onde p corresponde ao número de momentos nulos da função wavelet ortonormal aplicada na decomposição. Consequentemente, tal proposta é dependente também da função wavelet aplicada.

3.6.2 Métodos de Estimação do Valor de Limiar

Antes de tudo é preciso determinar como será calculado o valor de limiar λ , etapa frequentemente realizada através de um dos seguintes métodos originalmente propostos por Donoho *et al.* [126]:

Limiar Universal É uma forma fixa de limiar, para todos os níveis, que emprega o limiar universal $\lambda_F = \sqrt{2 \times \log(N)}$, onde N é o número de amostras do sinal.

Limiar Universal Dependente da Escala São estimadores propostos a partir da forma de limiar fixo λ_F , mas que variam de acordo com a escala j do coeficiente decomposto. A ideia principal é obter um estimador mais robusto do nível de ruído em cada escala, já que com o estimador fixo boa parte da energia do sinal desejado pode ser eliminada durante a filtragem. Em [126] Donoho também propôs uma modificação, adotando uma estimação de limiar dependente da escala λ_{DE} , dada por:

$$\lambda_{DE} = \sqrt{2 \times \log(N_j)}, \quad (3.26)$$

onde N_j é comprimento do vetor do j -ésimo coeficiente wavelet. A junção deste limiar com um fator de reescala também dependente da escala tem sido bastante aplicada na análise de sinais de DP [10], [20], [29], [33], [39].

Limiar SURE É uma estimação adaptativa a qual minimiza o risco do valor de limiar baseada no *Stein's Unbiased Risk Estimate* (SURE) uma das mais práticas estimações de EQM [149] definida como:

$$R_s(\lambda, \mathbf{x}) = N + \|\mathbf{g}(\mathbf{x})\|^2 + 2\nabla_x \mathbf{g}(\mathbf{x}), \quad (3.27)$$

com $\mathbf{g}(\mathbf{x}) = \hat{\mathbf{u}}(\mathbf{x}) - \mathbf{x}$, onde $\hat{\mathbf{u}}(\mathbf{x})$ é um estimador de limiar (função de limiarização) $\omega(\mathbf{x}, \lambda)$ e $\mathbf{g}(\mathbf{x}) = [g_0, g_1, \dots, g_{N-1}]^T$ é uma função de R^N para R^N .

Este método oferece grande flexibilidade, a qual pode ser importante para certos tipos de dados nos quais o ruído depende do nível de resolução.

Limiar Híbrido O princípio SURE não é adequado em situações em que os coeficientes wavelet são muito esparsos, pois nestes casos as muitas coordenadas em que o sinal é nulo fazem com que a raiz do EQM não tenda a zero linearmente quando a esparsidade tende a zero.

Por outro lado o limiar fixo independe dos dados. Assim, quando aplicado a coeficientes muito esparsos apresenta resultados mais satisfatórios do que os obtidos por meio do método SURE. Já em situações onde o sinal é mais denso, i.e., sem tantos coeficientes nulos, o método SURE tende a ser melhor que o estimador fixo.

Com isso Donoho *et al.* criaram um algoritmo híbrido (*SureShrink*) que combina os dois métodos. Neste caso, o valor de limiar é calculado pelo limiar fixo quando o sinal é esparso e pelo método SURE (considerando o estimador de limiar suave) quando o sinal é mais denso.

Limiar Minimaxi É usado como uma forma fixa de limiar, o qual é escolhido para permitir uma performance Minimax para o EQM. O princípio *minimax* é usado na teoria de decisão estatística em face de problemas de estimação de um parâmetro determinístico a partir de uma observação. O estimador *minimax* realiza o mínimo do máximo EQM obtido para a pior função num dado conjunto.

Limiares Alternativos Outras propostas de cálculo do limiar adaptativas têm sido apresentadas em alguns artigos. O método Bayesiano, mencionado anteriormente, realiza o cálculo do nível de limiar através da razão entre as estimativas do desvio-padrão, ou seja,

$$\lambda_{Bayesiano} = \lambda(\hat{\sigma}_{\mu}) = \frac{\hat{\sigma}_{\mathbf{n}}}{\hat{\sigma}_{\mu}}. \quad (3.28)$$

Quando $\hat{\sigma}_{\mathbf{n}}^2 \geq \hat{\sigma}_{\omega}^2$, $\hat{\sigma}_{\mu}^2$ é igualado a zero, o que equivale a $\lambda_{Bayesiano}$ ser infinito. Na prática, $\lambda_{Bayesiano} = \max(|\omega_{j,k}|)$, e todos os coeficientes são zerados. Isso ocorre quando a presença de ruído na sub-banda ($\hat{\sigma}_{\mathbf{n}}$) é muito grande.

Em [78], [80], os autores citam uma alternativa para o limiar fixo aplicada no tratamento de sinais, dada por:

$$\lambda_{Liu} = \sigma_{\mathbf{n}j} \left(\frac{\sqrt{2 \times \log(N)}}{\log(j+1)} \right) = \sigma_{\mathbf{n}j} \left(\frac{\lambda_F}{\log(j+1)} \right). \quad (3.29)$$

Algumas outras formas de cálculo do limiar dependentes do j -ésimo nível de decomposição são apresentadas por M. Biswas *et al.* em [88] para tratar imagens, o qual pode ser facilmente adaptado para tratamento de sinais, conforme

$$\lambda_{Biswas1} = \sigma_{\mathbf{n}} \sqrt{2 \log \left(\frac{N}{2^j} \right)}. \quad (3.30)$$

Segundo os autores, outra forma mais eficiente faz uso de uma função exponencial que leva ao decaimento dos coeficientes wavelet através das escalas, ou seja,

$$\lambda_{Biswas2} = \sigma_{\mathbf{n}} e^{-\frac{t}{t+1}} \sqrt{2 \log \left(\frac{N}{2^j} \right) - j}, \quad (3.31)$$

onde $t > 0$ é um inteiro.

Han *et al.* [79] melhoraram a função de limiarização suave com um limiar dependente da escala de acordo com a distribuição de energia dos coeficientes wavelet em diferentes níveis. O limiar dependente da escala é dado por

$$\lambda_{sd} = \begin{cases} \sigma_{\mathbf{n}_j} \times \sqrt{2 \log(N) / \sqrt{j}} & j = J \\ \sigma_{\mathbf{n}_j} \times \sqrt{2 \log(N) / \log(j+1)} & j = 2, \dots, J-1, \\ \sigma_{\mathbf{n}} \times \sqrt{2 \log(N)} & j = 1 \end{cases} \quad (3.32)$$

onde j é a escala de decomposição e $\sigma_{\mathbf{n}_j}$ é o desvio-padrão dos coeficientes wavelet na escala j . Pode-se observar que o valor de limiar λ_{sd} aumenta com N .

Para a WPT onde as bases são escolhidas adaptativamente, Donoho *et al.* [150] propõem que o valor de limiar seja calculado como se segue:

$$\lambda = \sigma_{\mathbf{n}} \times \sqrt{2 \log(N \times \log_2 N)}. \quad (3.33)$$

Este limiar, entretanto, não é ótimo e pode eliminar alguma das características relevantes do sinal, mas ainda assim reduz a probabilidade de presença de coeficientes ruidosos no sinal reconstruído.

3.6.3 Funções de Limiarização

É a função de limiarização que dita a forma como os coeficientes wavelet abaixo do valor de limiar de ruído serão zerados. Na literatura voltada à filtragem de sinais no domínio wavelet, as duas funções de limiarização dos coeficientes wavelet mais aplicadas são a limiarização suave (*soft thresholding*) e a limiarização abrupta (*hard thresholding*), ambas apresentadas em [87] e mostradas na Figura 3.8b.

A função de limiarização suave é descrita por:

$$\eta_{soft}(\omega_{j,k}, \lambda) = \begin{cases} \text{sign}(\omega_{j,k}) \cdot (|\omega_{j,k}| - \lambda), & |\omega_{j,k}| \geq \lambda \\ 0, & |\omega_{j,k}| < \lambda \end{cases}. \quad (3.34)$$

A função de limiarização abrupta é dada por:

$$\eta_{hard}(\omega_{j,k}, \lambda) = \begin{cases} \omega_{j,k}, & |\omega_{j,k}| \geq \lambda \\ 0, & |\omega_{j,k}| < \lambda \end{cases}, \quad (3.35)$$

onde η é o coeficiente wavelet modificado em função de $\omega_{j,k}$ e λ , que correspondem aos coeficientes wavelet e ao valor de limiar obtido a partir de um dos métodos de cálculo de limiar anteriormente descrito. A limiarização abrupta preserva melhor as características de amplitude dos coeficientes do que a limiarização suave, por não reduzir os coeficientes acima dos valores do limiar. Segundo Xiaorong et al. [45] isto permite que sinais impulsivos como os de DP sejam reconstruídos de forma a prover uma melhor razão sinal ruído [15], [83].

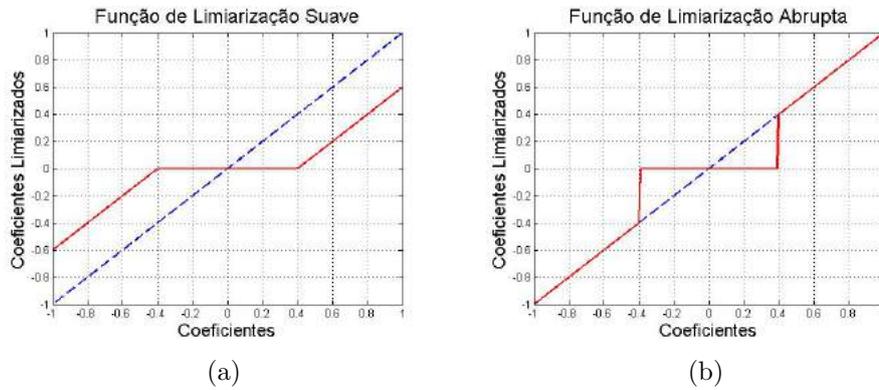


Figura 3.8: Função de limiarização para $\lambda = 0,4$: (a) suave; (b) abrupta.

Em [15], foi relatado que a limiarização suave reduziu demasiadamente a amplitude dos sinais, ao ponto da localização das descargas deixar de ser evidente, ao passo que a limiarização abrupta preservou de forma mais adequada a amplitude dos pulsos processados.

A função abrupta não é diferenciável, pois os coeficientes wavelet no valor de limiar não apresentam continuidade e, assim, pode fazer com que o sinal reconstruído oscile com o fenômeno pseudo-Gibbs [37], [38], [80], sendo mais instável a pequenas mudanças nos dados [151]. Já a função suave é considerada como fracamente diferenciável por possuir apenas a primeira derivada, além de atenuar excessivamente os coeficientes wavelet, afetando significativamente o sinal reconstruído, e até mesmo causando distorções e perturbações de borda e, em particular, atenuando a amplitude do sinal.

Diversos autores têm apontado estas desvantagens nas funções de limiarização clássicas e alguns artigos publicados sugerem o uso de novas funções de limiarização,

que nada mais são que funções intermediárias das funções abrupta e suave, com o objetivo maior de tentar superar as desvantagens de cada função, um ponto chave, que muitos autores têm enfatizado, é a necessidade da função de limiarização com alta ordem derivativa, o que faz estas mais convenientes para alguns tipos de disposições matemáticas, como métodos de minimização e otimização [76]: Mínimo Erro Quadrático Médio (*Least Mean Square* - LMS), Algoritmo Genético (AG), Colonização Artificial por Abelhas (*Artificial Bee Colony* - ABC), entre outros.

No entanto, a maioria dos artigos apresentam funções destinadas ao tratamento de imagens ou a outros tipos de sinais com características distintas e muito pouco tem sido discutido sobre novas funções de limiarização para tratamento de sinais de DP. Em nosso desenvolvimento, mostraremos uma nova função de limiarização de elevada ordem derivativa que tende a preservar as características de amplitude do sinal de DP (um fator muito importante) e ao mesmo tempo melhorar a atenuação dos coeficientes ruidosos, com vista a superar não só as funções clássicas utilizadas bem como algumas outras funções de limiarização propostas, como: a função Garrote por Nasiri *et al.* em [83], Non Negative Garrote descrita em [76], *Adaptive Shrinkage* mostrada por Partha Ray em [151], Liu desenvolvida por Shan Liu em [80], Hui apresentada em [152], as funções descritas por Zhang *et al.* em [72], [153] e as funções Stein e *Semi-Soft* em [75].

Capítulo 4

Métodos de Classificação de Descargas Parciais

Como discutido anteriormente, a medição de DP tem recebido grande aceitação como ferramenta efetiva de diagnóstico, com capacidade de acessar e monitorar a integridade do sistema isolante de um equipamento após sua manufatura e durante sua operação [154]. A norma IEC estabelece um limite específico de magnitude para todos os equipamentos de potência. No entanto, a DP não é sempre proporcional ao dano causado, já que uma DP com magnitude pequena pode rapidamente levar a um crescimento do defeito existente no isolamento elétrico. Portanto, é fundamental que a atividade de DP possa ser detectada e quantificada num estágio precoce, para que medidas corretivas possam ser tomadas em tempo hábil.

Na prática, várias fontes de descarga podem existir dentro de um aparato de potência e podem estar ativas ao mesmo tempo. Tais fontes de DP, usualmente, são de tipos diferentes, ou do mesmo tipo, mas ocorrendo em localizações diferentes e com intensidades distintas. É conhecido que grande parte dos detectores de DP comerciais vigentes não proveem quaisquer informações sobre o tipo (fonte) de DP quando ocorre uma falha no isolamento [47]. Desse modo, a separação e identificação precisa das múltiplas fontes de DP é primordial para acessar a integridade dos ativos de potência em serviço, evitando os erros de interpretação e o risco de uma avaliação inadequada, que podem advir dos métodos convencionais de análise de DP (padrões PRPD e histogramas de estatísticas derivados destes [155]). Como cada tipo de defeito tem suas próprias características de degradação, então é possível utilizar estes atributos para correlacionar o padrão de DP com o tipo de defeito e determinar a influência de cada fonte de defeito na qualidade do isolamento [53]. Fora isso, a classificação de DP pode ser usada para identificar qualquer falha iminente e informar sobre a necessidade de substituição ou reparo do sistema isolante existente.

Com os avanços das técnicas de DSP, esforços consideráveis têm sido feitos para aplicar técnicas de inteligência artificial. No entanto, ainda permanecem desafios consideráveis a aplicação bem sucedida destas técnicas para classificação de fontes de DP. Podemos citar três desafios chaves [156]: (1) extrair as características desejáveis a partir dos dados obtidos das medições de DP; (2) aplicar algoritmos de reconhecimento de padrões adequados para separação das fontes de DP; (3) identificar (classificar) as múltiplas fontes de DP, que podem ocorrer no equipamento avaliado.

O foco deste capítulo será na descrição destas etapas que envolvem o processo de classificação de DP. Descreveremos, de forma sucinta, as principais características que podem ser extraídas dos sinais medidos, em seguida os métodos de classificação não supervisionada úteis na separação dos sinais de DP e, por fim, os métodos de classificação supervisionadas que se aplicam na identificação do tipo de defeito (fonte de DP) associado com cada pulso.

4.1 Extração de Características de sinais de DP

O objetivo da extração de características é obter atributos representativos dos dados adquiridos nas medições de DP, sejam estes brutos ou tratados para redução de ruído. Serão estas características que nos permitirão separar e reconhecer cada fonte de DP associada com um defeito, ou mesmo com ruído que possa existir. Portanto, pode-se dizer que este é o aspecto mais importante de qualquer problema de classificação ou agrupamento (*clustering*) [64].

No Capítulo 2 descrevemos as formas convencionais de apresentação dos dados de DP como o mapa PRPD e os espectrogramas extraídos deste mapa, popularmente referidos como **impressão digital DP** (*PD fingerprint*) [2]. Ademais, a extração de características também tenta diminuir a dimensão do dado original para facilitar o processamento. O dado contido em cada padrão de DP armazenado pode ser muito grande para permitir sua manipulação. Assim, normalmente é requerida uma forma de redução do tamanho da matriz de dados [154].

Em geral, as características que representam eventos DP podem ser categorizadas em componentes no domínio do tempo e da frequência. Métodos baseados no domínio do tempo são desejáveis para representar as características de uma única fonte e tipo de DP. No entanto, nos casos em que existem mais de uma fonte DP, pode ser aplicada a análise no domínio da frequência usando espectro de frequência e/ou análise wavelet como métodos mais efetivos para discriminar e localizar fontes

diferentes de pulsos. O domínio da frequência possui tal habilidade, pois o sinal capturado pelo sensor é obtido a partir da convolução do sinal original na fonte de DP e a função transferência do circuito equivalente do ponto de defeito até o sensor acoplado. Por outro lado, análises no domínio do tempo são uma importante ferramenta para representar as características estocásticas, estatísticas e físicas do evento DP.

As seções que se seguem proveem uma breve revisão de algumas aproximações que consideramos importantes para o desenvolvimento de nossos trabalhos e que têm sido utilizadas pelos pesquisadores na extração de parâmetros de entrada para classificação de DP. Em [52] os autores discutem outras técnicas que não utilizaremos, por exemplo: processamento de imagens, parâmetros fractais, transformada wavelet cruzada, coeficientes wavelet gerados pela FWT ou WPT, coeficientes da oitava frequência cepstral, características baseada na autocorrelação, teoria do Caos e matriz amplitude da transformada Stockwell.

4.1.1 Operadores Estatísticos

Nesta aproximação, usualmente, um número de operadores estatísticos são extraídos dos histogramas $H_{qmax}(\varphi)$, $H_{qave}(\varphi)$, $H_n(\varphi)$ e $H_n(q)$ (descritos no Capítulo 2) derivados do padrão PRPD. Alguns dos histogramas podem ser divididos em duas distribuições distintas, uma para o ciclo positivo (+) e outra para o ciclo negativo (-). Estes são fortemente correlacionados com o tipo de defeito, permitindo que sejam descritos por diversos parâmetros estatísticos [155, 157], como:

- média é o valor que aponta para onde se concentram os dados de uma distribuição;

$$\mu = \frac{\sum_{i=1}^N x_i f(x_i)}{\sum_{i=1}^N f(x_i)} \quad (4.1)$$

- variância descreve o quanto um grupo de números está espalhado. Variância nula significa que todos os valores são idênticos;

$$\sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2 f(x_i)}{\sum_{i=1}^N f(x_i)} \quad (4.2)$$

- obliquidade (*Skewness*) descreve a assimetria de uma distribuição com respeito a distribuição normal. Obliquidade positiva representa assimetria mais acentuada para a esquerda, nula representa simetria e negativa mostra assimetria mais acentuada para a direita [158];

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

- curtose (*Kurtosis*) descreve o grau de acuidade (*sharpness*) de uma distribuição com respeito a distribuição normal. Curtose nula representa uma distribuição normal, curtose positiva representa uma distribuição mais aguda e curtose negativa descreve uma distribuição mais achatada [159];

$$K_u = \frac{\sum_{i=1}^N (x_i - \mu)^4 f(x_i)}{\sigma^4 \sum_{i=1}^N f(x_i)} - 3 \quad (4.4)$$

- picos (*Peaks*) conta o número de picos na metade positiva ou negativa de um ciclo da distribuição;
- assimetria representa a característica assimétrica dos pulsos DP nos ciclos positivos e negativos;

$$Asy = \frac{N^+ \sum_{i=1}^N q_i^-}{N^- \sum_{i=1}^N q_i^+} \quad (4.5)$$

- fator de Correlação Cruzada (*CC*) denota a dissimilaridade na forma das distribuições nos ciclos positivos e negativos. Fator de *CC* nulo significa forma totalmente assimétrica enquanto que fator de *CC* unitário indica formas completamente simétricas;

$$CC = \frac{\sum_{i=1}^N x_i^+ x_i^- - \sum_{i=1}^N x_i^+ \sum_{i=1}^N x_i^- / N}{\sqrt{\left[\sum_{i=1}^N (x_i^+)^2 - (\sum_{i=1}^N x_i^+)^2 / N \right] \left[\sum_{i=1}^N (x_i^-)^2 - (\sum_{i=1}^N x_i^-)^2 / N \right]}} \quad (4.6)$$

Cada parâmetro indica um tipo de informação escondida no espectro da DP. Na tabela 4.1 expomos de maneira compacta as estatísticas retiradas dos espectros PRPD, na qual + se refere ao pulsos de DP positivos e - aos pulsos de DP negativos.

Tabela 4.1: Estatísticas dos espectros PRPD.

Parâmetros Estatísticos	$H_{qmax}(\varphi)$		$H_{qave}(\varphi)$		$H_n(\varphi)$		$H_n(q)$
	+	-	+	-	+	-	
Obliquidade	x	x	x	x	x	x	x
Curtose	x	x	x	x	x	x	x
Pico	x	x	x	x	x	x	x
Média	x	x	x	x	x	x	x
Mediana	x	x	x	x	x	x	x
Variância	x	x	x	x	x	x	x
Assimetria		x		x		x	
<i>CC</i>		x		x		x	

Em [55], [66], [160], [161], os autores usam apenas a curtose e a obliquidade como parâmetros de entrada de seus algoritmos de classificação. Já em [155], [156] são aplicados os cinco últimos parâmetros listados anteriormente. A. Cotin *et al.* [58] descreve a análise de pulsos de DP por meio da média, variância, curtose e obliquidade.

4.1.2 Características de Localização Tempo e Frequência

Em [65], os autores propuseram o uso das características de Localização Tempo e Frequência (LTF) para classificação dos pulsos.

Considere um sinal de DP $x(t_i)$, $i = 1, 2, \dots, N$. Uma maneira de se caracterizar simultaneamente tempo e frequência é considerar sua localização média e dispersão em cada uma destas representações. Isto pode ser obtido considerando $|x(t_i)|^2$ e $|X(f_i)|^2$ como distribuições de probabilidade, e analisando seus valores médios e desvios padrão. O espalhamento de $x(t_i)$ pode ser dado por:

$$T = \sqrt{\left(\frac{1}{\sum_{i=1}^N |x(t_i)|^2}\right) \sum_{i=1}^N (t_i - t_o)^2 |x(t_i)|^2}, \quad (4.7)$$

enquanto que o baricentro do tempo t_o é dado por:

$$t_o = \frac{\sum_{i=1}^N t_i |x(t_i)|^2}{\sum_{i=1}^N |x(t_i)|^2}. \quad (4.8)$$

Seja $X(f_i)$ o componente de frequência do sinal DP obtido pela FFT. A localização na frequência de $x(t_i)$ pode ser calculada por:

$$W = \sqrt{\left(\frac{1}{\sum_{i=1}^N |X(f_i)|^2}\right) \sum_{i=1}^N (f_i)^2 |X(f_i)|^2}. \quad (4.9)$$

Desta forma, o sinal pode ser facilmente caracterizado no plano tempo-frequência (T, W) . Os pulsos DP com formatos similares podem ser sintetizados em área bem definidas deste plano. Assim como as demais técnicas de compressão de dados, este procedimento traz uma perda de informação com respeito ao formato do pulso, mas este pode ser considerado como um bom compromisso entre os requerimentos de complexidade computacional e análise em tempo real.

Em [65] os autores realizam uma modificação da localização na frequência, em que também aplicam a ideia de utilizar um baricentro,

$$B = \sqrt{\left(\frac{1}{\sum_{i=1}^N |X(f_i)|^2}\right) \sum_{i=1}^N (f_i - f_o)^2 |X(f_i)|^2}, \quad (4.10)$$

sendo o baricentro da frequência f_o dado por:

$$f_o = \frac{\sum_{i=1}^N f_i |X(f_i)|^2}{\sum_{i=1}^N |X(f_i)|^2}. \quad (4.11)$$

Esta medida nos permite caracterizar o sinal no plano tempo-frequência por meio de suas posições médias (t_o, f_o) e desvios padrão (T, B).

4.1.3 Característica Weibull da Curva PHA

A análise da distribuição estatística de Weibull oferece uma aproximação matemática para a Análise do padrão de Amplitude dos Pulsos (*Pulse Height Analysis* - PHA). Supõe-se que a distribuição de probabilidade da taxa (F) pela magnitude (q) do pulso de DP possa ser expressa pela função Weibull [55],

$$F(q; \alpha, \beta) = 1 - \exp\left(-\left(\frac{q}{\alpha}\right)^\beta\right), \quad (4.12)$$

onde α e β representam cada curva PHA fonte única, e q representa a amplitude do pulso de DP. As características $\alpha^+, \beta^+, \alpha^-, \beta^-$ são extraídas a partir das curvas PHA positiva e negativa, respectivamente. O método Weibull comprime o padrão PHA para análise digital, bem como retém sua informação relevante.

Uma forma simples para avaliar a habilidade de α e β em distinguir os diferentes tipos de DP é através de um gráfico de dispersão, criado calculando a estimativa de máxima verossimilhança (*maximum likelihood*) dos parâmetros da distribuição de Weibull para cada pulso avaliado, i.e., os parâmetros α e β que fornecem uma distribuição Weibull mais próxima daquela dos pulsos (em valor absoluto).

4.1.4 Mapeamento *Power Ratio*

A referência [162] apresenta uma técnica de agrupamento por espectro de potência, que é baseada em um mapa bidimensional para a Taxa de Potência (*Power Ratio map*), representando o conteúdo de potência espectral relativa em dois intervalos de frequência: PRL (*Power Ratio for Low frequencies*) e PRH (*Power Ratio for High frequencies*). Para obter estes parâmetros, a FFT de cada pulso é calculada

e o espectro é dividido em dois intervalos de frequência que são explicitamente representados em um plano. A potência espectral acumulada é calculada para os dois intervalos de frequência e normalizada para a potência espectral total. As quantidades obtidas são definidas como razões de potência da FFT do pulso x_i , uma para o intervalo de frequência mais alta $[f_{1H} f_{2H}]$, PRH, e outra para o intervalo de frequência mais baixa $[f_{1L} f_{2L}]$, PRL, como se segue:

$$PRL = \frac{\sum_{f_{1L}}^{f_{2L}} |X(f_i)|^2}{\sum_0^{f_T} |X(f_i)|^2} \times 100, \quad (4.13)$$

$$PRH = \frac{\sum_{f_{1H}}^{f_{2H}} |X(f_i)|^2}{\sum_0^{f_T} |X(f_i)|^2} \times 100. \quad (4.14)$$

4.1.5 Análise de Componentes Principais

Por ser uma técnica bastante aplicada na separação de sinais de DP, daremos uma maior atenção na explicação da mesma.

A Análise de Componentes Principais (*Principal Components Analysis* - PCA) é uma ferramenta utilizada com o objetivo de encontrar uma transformação ortogonal linear para converter um conjunto de observações de dados possivelmente correlacionados a um conjunto de valores de variáveis linearmente descorrelacionadas, i.e., as Componentes Principais (*Principal Components* - PC). O número de PC é menor que o número de variáveis originais, propriedade esta que é desejável em separação e classificação de dados. As PC são arranjadas de forma tal que a primeira componente principal possui a maioria da variação do conjunto de dados original e cada componente seguinte, por sua vez, tem a máxima variância sob a restrição de ser ortogonal (i.e., não correlacionado com) aos componentes anteriores [163]. A PCA é sensível à escala relativa das variáveis originais. Dependendo da área de aplicação, a PCA também é conhecida como transformada de Karhunen-Loève (*Karhunen-Loève Transform* - KLT) discreta.

A PCA é definida como uma transformação linear ortogonal que transforma os dados para um novo sistema de coordenadas de forma que a maior variância por qualquer projeção dos dados fica ao longo da primeira coordenada (a chamada primeira componente \mathbf{a}_1), a segunda maior variância fica ao longo da segunda coordenada \mathbf{a}_2 , e assim por diante. Portanto, pode-se obter uma boa representação dos dados utilizando poucas componentes, sejam as duas (2D) ou as três (3D) primeiras.

Assim sendo, a PCA pode ser usada como um método de redução de dimensões

de um dado, o que permite sua aplicação na extração de características de pulsos de DP e estas podem ser usadas para separação das diversas fontes de DP presentes em uma medição. A redução de dimensão PCA realiza automaticamente o agrupamento dos dados, onde padrões coerentes podem ser detectados mais claramente [164].

Em [165], a PCA foi usada na extração de características. Em [166] os autores aplicaram a extração de parâmetros estatísticos como curtose e obliquidade de diversos intervalos do espectro de frequência dos pulsos de DP e usaram a PCA para reduzir a dimensão para 3 coeficientes (3D-PCA). Já em [160], a mesma estratégia foi utilizada, só que a PCA foi calculada até o quarto coeficiente, fornecendo quatro características para seus respectivos algoritmos de classificação. Em [65], R. Liao *et al.* demonstram a superioridade de performance do método PCA de extração de características perante os métodos de extração por decomposição DWT e pela localização tempo frequência. H. Ma *et al.* [156] também utilizam a PCA para extração de características dos pulsos de DP. Tais aplicações demonstram o potencial da PCA na classificação de fontes de DP.

4.1.6 Análise de Componentes Principais Kernel (KPCA)

A KPCA é um método de extração de características não lineares [167], que surgiu como uma extensão da PCA utilizando técnicas do método Kernel.

Um conjunto de dados com N pontos não pode, em geral, ser linearmente separado numa dimensão $d < N$, mas quase sempre pode quando em uma dimensão $d \geq N$. Isto é, dados N pontos \mathbf{x}_i , se o mapearmos para um espaço N -dimensional com $\Phi(\mathbf{x}_i)$ onde $\Phi: \mathbb{R}^d \rightarrow \mathbb{R}^N$, é possível construir um hiperplano que divide os planos em grupos arbitrários. Na KPCA a função Φ escolhida é o kernel que transforma o dado original em um espaço de características. Os elementos desta função kernel são dados por:

$$K_{ij} = \kappa(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j), \quad (4.15)$$

onde \mathbf{x}_i e \mathbf{x}_j são os diferentes pontos no conjunto de dados $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N]$. A KPCA calcula os autovetores \mathbf{a}_i da matriz covariância no espaço de características acima.

Para obter os dados $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_N]$ de menor dimensão, os dados no conjunto original são projetados sobre os autovetores da matriz covariância \mathbf{a}_i , ou seja,

$$\mathbf{Y}_i = \left\{ \sum_{j=1}^N \mathbf{a}_1^{(j)} \kappa(\mathbf{x}_i, \mathbf{x}_j), \dots, \sum_{j=1}^N \mathbf{a}_d^{(j)} \kappa(\mathbf{x}_i, \mathbf{x}_j) \right\}. \quad (4.16)$$

Os elementos \mathbf{y}_i formarão o conjunto de características, assim como ocorre na PCA.

Quando a função transformação usada é a função Gaussiana Kernel, temos um método variante denominado Gaussian Kernel PCA.

4.1.7 Análise de Componentes Principais Alternativas

Dentre outras variantes temos a PCA Probabilística (*Probabilistic PCA* - PPCA) que é frequentemente usada quando existem valores ausentes nos dados ou para escalonamento multidimensional. Um conjunto de vetores de dados observados podem ser determinados através da estimativa de máxima verossimilhança (*maximum-likelihood*) de parâmetros num modelo de variáveis latentes (dados pelos vetores direção e distância) que está intimamente relacionado à análise fatorial [168]. Pode-se dizer que PCA Clássica é um caso específico da PPCA quando a covariância do ruído se torna infinitamente pequena, $\sigma^2 \rightarrow 0$.

Com base na interpretação da máxima verossimilhança, podemos substituir a distribuição gaussiana por distribuições gerais, por exemplo a família exponencial, para estender naturalmente a PCA a outros modelos de ruído. A Análise de Componentes Principais Exponencial (E-PCA) estende as aplicações do PCA Clássica para dados contendo vários tipos de informações. Uma versão esparsa da E-PCA ajuda a superar a inconsistência do modelo e melhora a interpretabilidade quando aplicado a dados de alta dimensão.

4.1.8 Incorporação Estocástica de Vizinhos (*Stochastic Neighbor Embedding* - SNE)

A SNE tenta reter distâncias entre pares de dois pontos de dados em um espaço de baixa dimensão [169]. Na SNE, a probabilidade p_{ij} de que os pulsos adquiridos \mathbf{x}_i e \mathbf{x}_j sejam gerados pela mesma Gaussiana é calculado para todos os pares possíveis de pulsos em todo o conjunto de dados de DP $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N]$, onde N é o número de pulsos DP. As probabilidades q_{ij} das características correspondentes dos pulsos adquiridos num espaço dimensional menor, i.e., \mathbf{y}_i e \mathbf{y}_j gerados pela mesma Gaussiana, também estão conectados. Estas duas matrizes de probabilidades são denotadas por \mathbf{P} e \mathbf{Q} , respectivamente. O SNE minimiza a diferença entre

as distribuições de probabilidade \mathbf{P} e \mathbf{Q} através da minimização do somatório das divergências Kullback-Leibler

$$\varphi(\mathbf{P} \parallel \mathbf{Q}) = \sum_i \sum_j p_{ij} \log \frac{p_{ij}}{q_{ij}}. \quad (4.17)$$

A minimização de $\varphi(\mathbf{P} \parallel \mathbf{Q})$ pode ser realizada usando o método gradiente descendente. O resultado desta otimização é um mapa que reflete bem as semelhanças entre as entradas de elevada dimensão. Os elementos \mathbf{y}_i formarão o conjunto de características $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_N]$. A dimensão do conjunto de características \mathbf{Y} é denominada dimensionalidade intrínseca. E esta deve ter um número mínimo de características para contabilizar toda a informação dos dados de DP. A dimensionalidade intrínseca d de um conjunto de dados pode ser determinada usando a estimação de verossimilhança máxima (*maximum likelihood estimation*) [170].

Uma variante deste método, denominada Incorporação Estocástica de Vizinhos t -distribuída (*t distributed Stochastic Neighbor Embedding* - t-SNE) foi desenvolvida por Laurens van der Maaten and Geoffrey Hinton em [171]. Ao invés de lidar com a função de distribuição Gaussiana, considera uma distribuição t-Student de cauda pesada (com um grau de liberdade, que é o mesmo que uma distribuição de Cauchy). O algoritmo não linear tem a capacidade para realizar diferentes transformações sobre regiões distintas. O método pode ser ajustado através de um parâmetro denominado perplexidade, o qual diz como equilibrar a atenção entre os aspectos locais e globais dos dados. O parâmetro é, em certo sentido, um palpite sobre o número de vizinhos próximos que cada ponto possui. O valor de perplexidade tem um efeito complexo nas imagens resultantes. Para nossa aplicação, escolhemos uma perplexidade de 30 para um número de iterações de 1500 como um valor aceitável para trabalhar com dados PD. No entanto, podem não ser gerados bons resultados, já que a performance do método está intimamente ligada ao valor de perplexidade, e definir um ótimo para tal necessitaria de uma investigação para cada caso de dados de DP medidos.

4.1.9 Técnicas de Redução de Dimensionalidade (MDS)

Diversas outras técnicas de Redução de Dimensionalidade (*Multidimensional Scaling* - MDS) para extração de informações de um grande volume de dados estão disponíveis na literatura. Estas podem ser lineares, como é o caso da PCA, ou não lineares.

Para não estendermos em demasiado o conteúdo teórico, vamos nos limitar ape-

nas em citar algumas dessas metodologias de redução que serão utilizadas ao longo de nosso trabalho. Portanto, temos: Mapa de Difusão (*Diffusion Map* - DMAP), Análise Fatorial (*Factor Analysis* - FA), Análise Discriminante Generalizada (*Generalized Discriminant Analysis* - GDA), Landmark-Isomap (ISOMAP), Análise Discriminante Linear (*Linear Discriminant Analysis* - LDA), Preservação Linear de Projeção (*Linearity Preserving Projection* - LPP), Incorporação de Preservação de Vizinhança (*Neighborhood Preserving Embedding* - NPE), Mapeamento Sammon (*Sammon Mapping* - SM) e Incorporação Estocástica de Proximidade (*Stochastic Proximity Embedding* - SPE).

Mais detalhes a respeito das teorias que envolvem estas técnicas podem ser encontrados em [172].

4.2 Métodos de Classificação

Os sinais de DP podem ser classificados em diferentes categorias. Alguns métodos tentam classificar o tamanho das cavidades onde as DP ocorrem [173]. Também têm sido apresentadas pesquisas para determinar a fase da DP em linhas de transmissão trifásicas [174]. No entanto, grande parte dos estudos são voltados para separação e identificação dos tipos de problemas no isolamento que levam as DP a ocorrerem, i.e., as fontes que originaram as DP. Basicamente é possível citar quatro tipos principais de padrões de DP: descargas de superfície, corona, cavidades ou bolhas e arboreamento.

No processo de separação recorre-se ao uso de métodos de classificação não supervisionada que fazem o agrupamento de fontes de DP semelhantes entre si. Já na etapa de classificação, é preciso o uso de técnicas supervisionadas de redes neurais, as quais necessitam ser treinadas com um banco de dados representativo de cada tipo de defeito associado à DP que se deseja identificar. Nesta seção apresentaremos alguns dos métodos de classificação não supervisionada que podem ser aplicados na separação de fontes de DP. A etapa de identificação, que envolve técnicas de classificação supervisionada, será desenvolvida na continuidade do trabalho, já que qualquer avaliação destas técnicas dependerá de um banco de dados de causa e efeito. O banco será criado a partir de ensaios no laboratório do Cepel com células de carga que simulam os defeitos usuais associados às DP.

4.3 Métodos de Classificação Não Supervisionada

4.3.1 K-means

O termo K-means foi empregado primeiramente por James MacQueen em 1967 [175]. É um dos algoritmos mais simples para resolução de problemas de agrupamento. O procedimento segue uma maneira simples e fácil para separar um conjunto de vetores de observação através de um certo número k de grupos de dados (k *clusters*) fixados a priori. A ideia principal é definir k centroides, um para cada *cluster*. Estes centroides devem ser escolhidos de uma forma adequada, pois localizações diferentes provavelmente produzirão resultados diferentes. Portanto, a melhor escolha é colocá-los tanto quanto possível longe um do outro. O próximo passo é tomar cada vetor de observação pertencente a um determinado conjunto de dados e associá-lo ao centroide mais próximo. Quando nenhum ponto está pendente, a primeira etapa é concluída e o agrupamento inicial está feito. Neste ponto temos de voltar a calcular k novos centroides como baricentros dos *clusters* resultantes da etapa anterior. Depois de obter os k novos centroides, uma nova associação tem de ser feita entre os mesmos vetores do conjunto de dados e o novo centroide mais próximo. Este processo se repete de forma cíclica. Como resultado deste ciclo os k centroides mudam de localização passo a passo até que as mudanças não sejam significativas. Em outras palavras, até que os centroides não se movam mais.

O algoritmo K-means tenta minimizar uma função objetivo, frequentemente definida como a soma das distâncias quadradas entre cada vetor de observação e seu centroide dominante. Cada passo do algoritmo refina as escolhas dos centroides para reduzir a distorção. Para finalizar o algoritmo, podem ser adotados um ou mais dos seguintes critérios de parada: a variação da função objetivo torna-se inferior a um limiar definido a priori, os centroides não se modificam mais e/ou o algoritmo atinge um número máximo de iterações.

A função objetivo usualmente aplicada é:

$$J = \sum_{j=1}^k \sum_{i=1}^N \left\| x_i^{(j)} - c_j \right\|^2, \quad (4.18)$$

onde $\left\| x_i^{(j)} - c_j \right\|^2$ é a distância medida entre o dado $x_i^{(j)}$ e o centroide c_j do grupoamento ao qual este dado pertence. Serve como um indicador da distância dos N

vetores de dados do centro de seus respectivos *clusters*. Neste caso, o indicador equivale ao quadrado da bem conhecida distância Euclidiana, mas outras funções podem ser aplicadas para fornecer este indicativo. Dentre as quais podemos citar: a distância *Manhattan* (*Cityblock*) ou distância do valor absoluto, na qual cada centroide é a mediana dos dados dentro do grupo; a distância de similaridade cosseno também definida como distância angular (dada por 1 menos o cosseno do ângulo normalizado entre dois pontos tratados como vetores), onde cada centroide é a média dos pontos num grupo; a distância por correlação, que é uma medida da dependência entre dois vetores, sendo nula em caso de vetores estatisticamente independentes e unitária se dependentes (é implementada no Matlab como 1 menos a correlação entre dois dados normalizados com média zero e desvio padrão unitário); a distância *Hamming* que fornece uma percentagem de bits que diferem (desejável somente para dados binários), sendo cada centroide a mediana dos pontos num grupo.

Considere um conjunto de observações $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N]$, onde cada observação \mathbf{x}_i é um vetor real d -dimensional de características. No problema de agrupamento, tendo \mathbf{X} desejamos separar os N vetores em k grupos tal que o agrupamento seja ótimo.

O algoritmo inicia com a escolha dos k elementos do conjunto \mathbf{X} para formar os centroides iniciais c_j . Esta escolha pode ser feita de muitas formas, entre elas:

- selecionando as k primeiras observações;
- selecionando k observações aleatoriamente;
- selecionando k observações de modo que seus valores sejam bastante diferentes. Por exemplo, ao se agrupar uma população em três grupos de acordo com a altura dos indivíduos, poderia se escolher um indivíduo de baixa estatura, um de estatura mediana e um alto.

Em seguida o algoritmo se processa alternando entre dois passos:

Passo de atribuição: calcula a distância de cada observação em relação à cada um dos centroides, atribuindo o elemento ao grupo que possui a menor distância (maior similaridade) e recalculando o centroide;

Passo de atualização: calcula a nova posição dos k centroides por meio da média dos elementos pertencentes ao grupo.

O processo é repetido até que as atribuições de todos os grupos não se alterem mais. Como ambos os passos otimizam a função objetivo, e existe um número finito de partições, o algoritmo deve convergir para um ótimo local. Não é possível garantir

a convergência do algoritmo para um ótimo global.

Por ser de aplicação bastante simples computacionalmente e funcionar bem em muitos casos, ele é um dos principais e mais usados métodos de agrupamento.

Além da aplicação em agrupamento, o método também encontra aplicações em quantização vetorial e aprendizagem de carácter [176].

Na prática, existem diversas variações deste algoritmo que empregam operações de particionamento, união e descarte dos grupos resultantes. Dentre estas podemos citar as técnicas de agrupamentos: **K-means++** [177], que é um algoritmo que faz a escolha dos valores iniciais, evitando que grupos inadequados sejam encontrados para o algoritmo K-means padrão; **K-medians** [178] que usa a mediana em cada dimensão ao invés da média, minimizando a norma l_1 ; **K-medoids** [179], que usa o medoid ao invés da média, e minimiza o somatório das distâncias para funções distância arbitrárias, sendo as realizações mais comuns o algoritmo **PAM** (*Partitioning Around Medoids* - Particionamento ao Redor dos Medoids) e o algoritmo **CLARA** (*Clustering LARge Applications* - Agrupamento para Aplicações Amplas) sugerido por Kaufman e Rousseeuw em [180], o qual estende a aproximação K-medoids para um amplo número de objetos; **Fuzzy C-Means** [181]. que é uma versão em que cada dado é atribuído a cada grupo com um grau fuzzy; técnica de agrupamento hierárquico como **G-means** [182], entre outras variações mais adequadas para lidar com certos tipos de dados (dados textuais, etc). Outras técnicas englobam o agrupamento baseado em densidade, que funciona pela identificação de grupos densos de pontos, permitindo a este identificar grupos de formato arbitrário, bem como distinguir ruído (*outlier*) no espaço dimensional. Como exemplo podemos citar os algoritmos **DBSCAN** (*Density Based Spatial Clustering of Applications with Noise*), proposto por Martin Ester *et al.* em [183], **OPTICS** (*Ordering Points to Identify the Clustering Structure*) e o **SNN** (*Shared Nearest Neighbor*).

4.3.2 Gaussian Mixture Model

Algumas limitações do K-means são que:

1. se torna difícil a atribuição de pontos que não pertençam totalmente a um *cluster*;
2. não existe a noção de uma atribuição fracionária (ou seja, probabilidade de ser atribuída a cada *cluster*);
3. geralmente não funciona quando os grupos não são arredondados, e/ou se

sobrepõem, e/ou são desiguais.

Gaussian Mixture Model (GMM), também denominado *Gaussian Mixture Distribution* (GMD), é uma abordagem probabilística de agrupamento (estimativa de densidade) que pode resolver muitos destes problemas. Usando uma técnica iterativa chamada Maximização de Expectativa (*Expectation Maximization* - EM), o processo e o resultado são muito semelhantes aos do agrupamento K-means. A diferença é que os grupos são assumidos para que cada um tenha uma distribuição Gaussiana independente, cada qual com sua própria média e matriz de covariância. Portanto, o agrupamento GMM levará em conta a covariância quando formando um *cluster*.

Um outra diferença importante em relação ao K-means é que o último faz a atribuição de cada ponto de dados ao grupo mais próximo. Com o método GMM, se obtém uma coleção de distribuições Gaussianas independentes, e assim, para cada ponto de dados, teremos uma probabilidade de que ele pertença a cada uma dessas distribuições (*cluster*).

4.3.3 Hierárquico

O agrupamento Hierárquico envolve criar grupos que tenham ordenamento pré determinado análogo a uma hierarquia hierárquica. Existem dois tipos de algoritmos, o Divisivo (agrupamento de cima pra baixo) e o Aglomerativo (agrupamento de baixo pra cima).

O método se inicia tratando cada observação como um grupo separado. Então, executa iterativamente os seguintes passos [184]: identificar dois grupos que estão mais próximos uns dos outros e misturar os dois grupos mais similares. O processo continua até que os grupos estejam mesclados.

4.3.4 Agrupamento Baseado na Função Autocorrelação Normalizada

Especialmente desenvolvido para tratamento de sinais de DP, este método foi apresentado por Alfredo Continn e Stefano Pastore em [51], onde propõem o uso da Função Autocorrelação Normalizada (NACF) em conjunto com o algoritmo de agrupamento K-means, que faz a seleção automática do número de grupos.

A separação do método baseia-se na comparação entre a Função Autocorrelação (*Autocorrelation Function* - ACF) de sinais pertencentes a um conjunto de N sinais $s(t)$. A ACF, $R_s(\tau)$, de um sinal real contínuo contendo energia finita é dada por:

$$R_s(\tau) = \int_{-\infty}^{\infty} s(t) s(t + \tau) dt. \quad (4.19)$$

A ACF detém propriedades muito úteis para a separação. Dentre as quais é possível destacar:

- a transformada de Fourier da $R_s(\tau)$ de um sinal de energia finita, i.e., a densidade espectral de energia $G_s(f)$, também preserva os conteúdos de harmônicos que seriam obtidos pela transformada de Fourier do sinal $S(f)$, uma vez que

$$|\mathfrak{F}\{R_s(\tau)\}| = |G_s(f)| = |S(f)|^2; \quad (4.20)$$

- a habilidade de sintetizar ambas as características dependentes do tempo e da frequência de um sinal;
- permanece proporcional à relação tempo/frequência de um sinal;
- $R_s(\tau)$ é uma função par $R_s(\tau) = R_s(-\tau)$, tal que somente a metade desta pode ser utilizada na comparação, mantendo o mesmo número de amostras do sinal medido;
- a máxima amplitude da ACF ($R_s(0) = \max(R_s(\tau))$) corresponde à energia total do sinal $W(s(t))$ (Identidade de Parseval), dada por:

$$R_s(\tau = 0) = \int_{-\infty}^{\infty} s^2(t) dt = \int_{-\infty}^{\infty} |S^2(f)| df = W(s(t)); \quad (4.21)$$

- a forma da ACF é menos afetada pela superposição de ruído de alta frequência, truncamento aleatório e deslocamento do sinal.

Portanto, as similaridades entre sinais diferentes podem ser melhor acessadas com a ACF [51].

Para preservar sinais com formas similares e energias diferentes de modo a serem atribuídos a diferentes classes é adotada uma normalização da ACF. Para um sinal com N_c amostras, a NACF é dada por:

$$R_s[k] = \frac{\sum_{i=1}^{N_c} s(i) s(i+k)}{N_c} \times \frac{1}{\left(\frac{\sum_{i=1}^{N_c} s^2(i)}{N_c}\right)}. \quad (4.22)$$

Note que o denominador à direita corresponde à energia total do sinal avaliado, fazendo com que a NACF dependa somente da forma do sinal.

O método de agrupamento K-means é usado para checar a distância (geralmente Euclidiana) do centroide para todos os pontos avaliados. Entretanto, estamos lidando com sinais e não pontos, então adota-se uma distância métrica, como se segue:

$$d_p = \sqrt{2(1 - p_c)}, \quad (4.23)$$

onde p_c é o coeficiente de correlação entre a NACF do centroide e do sinal avaliado, sendo que tal coeficiente varia de 0 a 1. Para $d_p = 0$ tem-se que $p_c = 1$ e as NACF's serão idênticas (sinais iguais). Portanto, a distância entre os sinais varia em uma hipersfera de raio igual a 1.

O critério que determina a designação de um sinal dentro de uma classe é definido por um valor de limiar, e se a distância é menor do que este, o sinal é considerado similar o bastante, sendo designada a ele a mesma classe do centroide testado. Portanto, cuidado é necessário para determinar este valor, já que um valor muito baixo tenderá a classificar os sinais em vários grupos (discriminação forte) e valores altos podem produzir uma única classe ou mais classes onde sinais de fontes distintas podem vir a ser agrupados numa mesma classe (discriminação fraca).

Em [51], os autores sugerem o uso de um valor de limiar igual a 0.4, mas é preciso atentar para casos em que o número de sinais avaliados é muito grande. Nesta situação, pode ser considerada a possibilidade do uso de um valor ligeiramente mais alto para não se gerar tantas classes e acelerar a execução do algoritmo.

O processo de classificação é composto basicamente de três estágios:

1. Primeiramente as NACF's são calculadas para todos os sinais em análise. A classificação inicial é realizada comparando a NACF do primeiro sinal com todos os demais através do valor de d_p . Sinais tendo d_p menor que o *limiar* são considerados similares o bastante para serem atribuídos à mesma classe. Assim, uma classe é gerada e os indivíduos remanescentes irão formar uma classe auxiliar, a qual deverá ser tomada como um novo conjunto e submetida ao mesmo processo. O procedimento é repetido até que não restem amostras na classe auxiliar. Já que podem ser geradas classes com poucos sinais agrupados, então é necessário considerar para o próximo passo somente as M classes com número de sinais maiores do que 100 [41] e as classes remanescentes serão desconsideradas (não classificados);

2. Os M centroides são determinados pela média das NACF's de cada classe. O algoritmo K-means é aplicado usando a d_p para comparar cada NACF com os M centroides e o sinal será atribuído à classe do centroide mais próximo. Depois disso, este novo centroide pode ser calculado e o processo repetido até que a variação do centroide seja nula ou muito pequena. Assim, são obtidas M classes com centroides bem definidos, os quais podem ser usados para avaliar novos sinais adquiridos pela comparação de distância;
3. Finalmente, como podem ser geradas classes com localizações similares uma das outras (no mapa PRPD), um algoritmo é adotado para julgar se os pares de classes podem ser agrupados. Tal informação é dada através de um procedimento denominado teste *chi*-quadrado, proposto em [43]. A análise de similaridade é feita entre o mapa PRPD de uma classe A, h_A , e o PRPD de uma outra classe B, h_B . Para levar em conta somente a posição magnitude-fase do sinal e desconsiderar o número de ocorrências, n , na janela PRPD, este é alterado para apresentar um valor igual a 1 se $n \geq 1$ e caso contrário igual a 0 (tal procedimento na verdade é equivocado, pois deveria levar em conta toda a distribuição dos pulsos dentro do PRPD medido). O cálculo é feito para cada combinação possível das M classes geradas e se os valores encontrados forem baixos significa que as classes têm PRPD similares e podem ser agrupadas. Caso contrário, as classes devem ser mantidas separadas, para evitarmos que classes muito similares no PRPD (situação em que existe altas chances de que o fenômeno sejam o mesmo) se mantenham separadas, reduzindo o número de grupos. Desta maneira, para evitarmos que classes muito similares no PRPD se mantenham separadas, reduzindo o número de grupos. O teste *chi*-quadrado mede a distância entre duas distribuições, $H_A(q_i, \varphi_i)$ e $H_B(q_i, \varphi_i)$, via estatística χ^2 :

$$\chi^2 = \sum_{j=1}^N \sum_{i=1}^N \frac{\sqrt{\frac{H_B}{H_A}} h_A(q_i, \varphi_i) - \sqrt{\frac{H_A}{H_B}} h_B(q_i, \varphi_i)}{h_A(q_i, \varphi_i) + h_B(q_i, \varphi_i)}, \quad (4.24)$$

onde

$$H_A = \sum_{j=1}^N \sum_{i=1}^N h_A(q_i, \varphi_i), \quad (4.25)$$

$$H_B = \sum_{j=1}^N \sum_{i=1}^N h_B(q_i, \varphi_i). \quad (4.26)$$

Capítulo 5

Limiarização Wavelet Destinada ao Tratamento de Sinais de DP

Com base na teoria de filtragem por transformada wavelet abordada no Capítulo 3, será desenvolvida uma função de limiarização wavelet destinada ao aperfeiçoamento na redução de ruído em medições de DP. Esta nova função foi inspirada na função logística [185], a qual é bastante conhecida por sua utilidade em inúmeras áreas. A mesma foi convenientemente denominada função de limiarização Fleming, pois é de praxe a associação de novas funções deste tipo com algo que as remeta ao nome de seu desenvolvedores (e.g., [83]).

Ao longo deste estudo veremos algumas variações na aplicação da função Fleming, como a possibilidade desta ser aplicada de maneira similar ao algoritmo SNRBWS [33], [35], [67], [68] numa tentativa de identificar os níveis onde a limiarização deve ser mais rigorosa e aqueles em que pode ser mais branda, elevando sua efetividade na remoção de coeficientes ruidosos. Além disso, será explorado concomitantemente o algoritmo minimização LMS do risco SURE [31, 76], a fim de viabilizar a busca automática da variável de ajuste que compõe a nova função.

5.1 Função de Limiarização Fleming

Em grande parte da literatura de filtragem wavelet, principalmente aquela destinada ao tratamento de sinais de DP, a escolha da função de limiarização normalmente divide-se entre a função abrupta e a função suave, conforme descrito na Seção 3.6. Ademais, é de comum acordo que para filtragem de pulsos de DP a função abrupta tende a preservar mais informações do sinal, proporcionando maior SNR e

menor Erro de Amplitude (EA). No entanto, a estimativa abrupta possui descontinuidades, não diferenciáveis, o que acaba provocando problemas de instabilidade e sensibilidade às pequenas mudanças no dado - efeito pseudo-Gibbs. Já a função suave é fracamente diferenciável e produz uma atenuação elevada dos coeficientes, resultando na redução de amplitude do sinal resultante.

Muitas alternativas vêm sendo propostas numa tentativa de contornar estes problemas. A ideia principal é gerar uma função de limiarização de ordem derivativa elevada, o que contribui para seu uso conjunto em algoritmos de otimização que buscam os parâmetros ótimos a serem aplicados na limiarização de cada sinal. Portanto, a função torna-se adaptável ao sinal que se deseja filtrar, podendo melhorar a qualidade do sinal filtrado.

Em análise das funções de limiarização aplicadas, sejam elas na área de DP ou de processamento de áudio, ECG e imagem, é notável que aquelas buscam melhorias combinando tanto as propriedades de preservação dos coeficientes e magnitudes da função abrupta, quanto a diferenciabilidade e suavidade proporcionada pela função suave. Em processamento de imagens, a propriedade de suavidade é interessante para que a imagem resultante mostre contornos mais agradáveis. Já no processamento de sinais, como de áudio, de ECG e de pulsos de DP é importante conseguir uma melhor preservação da magnitude (pico) do sinal e da razão sinal ruído.

Por esta razão, muitos autores têm explorado funções que correspondem à interpolação das suave e abrupta. No entanto, a maioria das funções não pode se adaptar aos diferentes sinais devido à curva de transição fixa no valor de limiar. Existe ainda, nestas funções, uma maior tendência para a suavização dos coeficientes do que para a preservação destes, não percebendo que para sinais de DP é adequado que a função mostre-se mais próxima da função abrupta à suave, desde que se preserve um pouco da diferenciabilidade na transição do valor de limiar, o que permitirá uma melhora no EQM e no CC.

Seguindo esta linha de raciocínio, propomos uma nova função de limiarização semelhante à abrupta, mas sendo diferenciável para ordens mais elevadas e podendo ajustar-se a cada sinal. Esta proposta se baseia na conhecida função logística, mostrada na Figura 5.1, muito utilizada em redes neurais artificiais, demografia, economia, probabilidade, estatísticas, química, etc. A Equação (5.1) representa a função logística, onde H é o valor máximo da curva, α controla a inclinação desta curva e x_0 corresponde ao valor de x no ponto médio da curva sigmóide ditado pelo valor do numerador. Quando os valores de x tendem a $+\infty$ a curva se aproxima de H e quando tende a $-\infty$ se aproxima de zero.

$$f(x) = \frac{H}{1 + e^{-\alpha(x-x_0)}}. \quad (5.1)$$

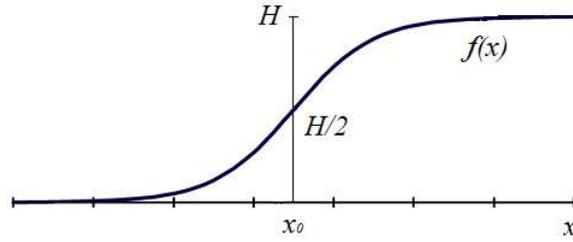


Figura 5.1: Função Logística.

A Equação (5.1) possibilitou o desenvolvimento da função de limiarização para filtragem de sinais de tal forma que contorna os problemas descritos anteriormente. Como na função de limiarização o objetivo é preservar os coeficientes acima do valor de limiar, é fácil perceber que o valor máximo H será o próprio coeficiente wavelet decomposto $w_{j,k}$ (que corresponde à variável x). Assim, a função manterá a simetria quando variarmos a constante c de inclinação da curva. Por último, é preciso deslocar a função ao longo do eixo das abcissas para que o gráfico apresentado na Figura 5.1 fique sobre o valor de limiar, isso é feito subtraindo-se à variável x o valor onde desejamos deslocar a função (x_0), ou seja, o valor dos coeficientes $w_{j,k}$ deve ser subtraído do valor de limiar λ . Realizando estas adaptações obtemos a seguinte função de limiarização:

$$\eta_f(w_{j,k}, \lambda, c) = \frac{w_{j,k}}{1 + e^{-c((w_{j,k}-\lambda))}} = \frac{w_{j,k}}{1 + e^{c((-w_{j,k}+\lambda))}}. \quad (5.2)$$

Para uma implementação mais eficiente, em que não seja necessário se preocupar com o fato do coeficiente $w_{j,k}$ ser positivo ou negativo, a Equação (5.2) pode ser reescrita utilizando a função signum ($sign$), que retorna $+1$ caso o valor seja positivo e -1 caso o valor seja negativo. Assim, temos:

$$\eta_f(w_{j,k}, \lambda, c) = \frac{w_{j,k}}{1 + e^{c((-sign(w_{j,k}) \times w_{j,k} + \lambda))}}. \quad (5.3)$$

Com valores de c elevados, a inclinação da curva no ponto de limiar é tal que se aproxima da função abrupta, mas com uma transição mais suave (diferenciável). Para valores baixos de c a inclinação da função atuará com menor intensidade sobre os coeficientes inferiores ao valor de limiar e com maior intensidade nos coeficientes superiores a este valor, ou seja, poderá passar uma grande quantidade de coeficientes

ruidosos e haverá perda de informação naqueles que representam o sinal de interesse, no caso o pulso de DP. Com a escolha adequada do valor de c para cada sinal processado é possível obter uma melhora significativa no resultado final de filtragem de DP por WT em relação às funções abrupta e suave.

Na Figura 5.2, com valor de limiar $\lambda = 1$, é mostrado o comportamento da nova função de limiarização (denominada função Fleming) para diferentes valores de inclinação c (3, 10, 20, 30, 50, 80, 100 e 200). Com valores muito baixos de c há a possibilidade de passar grande quantidade de coeficientes ruidosos, portanto é indicado que o valor da constante seja maior ou igual a 5.

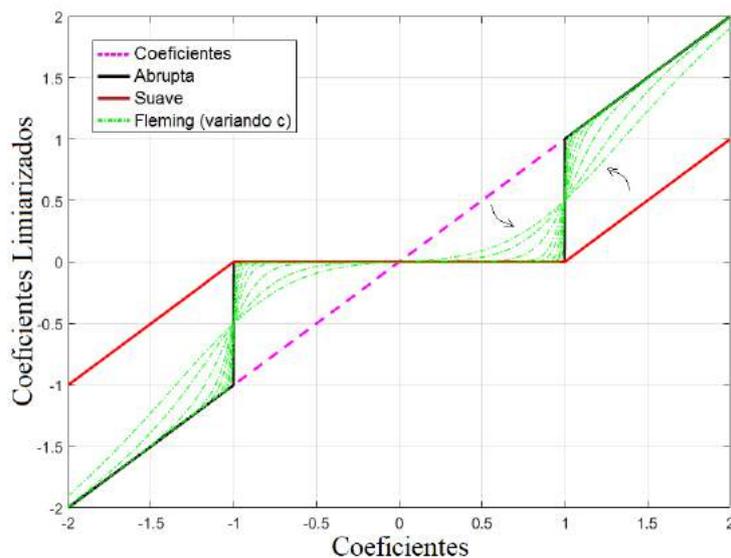


Figura 5.2: Comportamento da função de limiarização Fleming para $\lambda = 1$.

Numa avaliação de DP a maioria das medições fornecem sinais com amplitude da ordem de mV. Desta forma, caso seja aplicada a técnica de WT para filtrar os sinais, seus coeficientes decompostos também serão na faixa de mV e ao usar uma regra de limiarização (em nosso caso, *scaledep*) o valor de limiar λ será pequeno e normalmente menor do que 1, principalmente para os coeficientes que contenham mais ruído do que componentes de DP. Quando avaliamos a nova função de limiarização para um valor de limiar pequeno (e.g., $\lambda = 0.05$), o rigor com que os coeficientes são atenuados se torna menor, conforme ilustrado na Figura 5.3. Observe que, mesmo para o valor de $c = 200$ a quantidade de coeficientes ruidosos que pode passar ainda é grande, diferentemente do que se viu para o valor de limiar $\lambda = 1$.

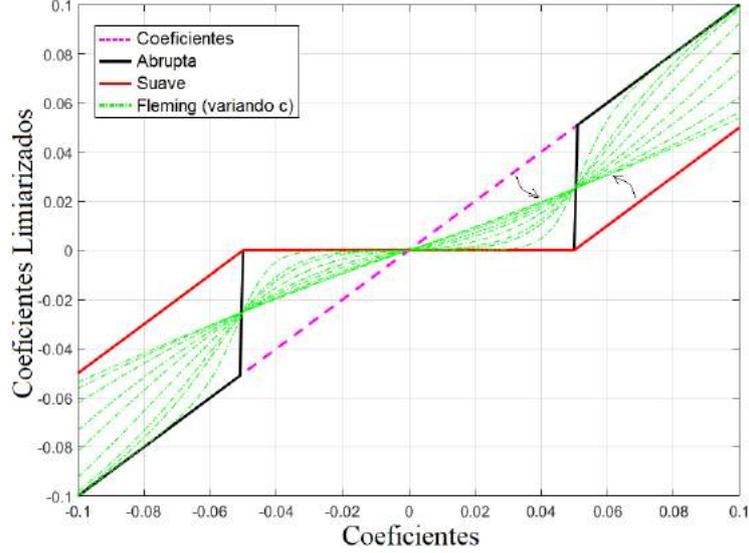


Figura 5.3: Comportamento da função de limiarização Fleming $\lambda = 0.05$.

Uma solução para contornar este problema foi adaptar a Equação (5.3) de acordo com o valor de limiar quando este for considerado pequeno (entenda como pequeno um $\lambda < 0.5$), bastando alterar a constante c que controla a inclinação proporcionalmente a λ . Com isso podemos reescrever a Equação (5.3) da seguinte forma:

$$\eta_f(w_{j,k}, \lambda, c) = \begin{cases} \frac{w_{j,k}}{1+e^{c((-sign(w_{j,k}) \times w_{j,k} + \lambda))}} & se \lambda \geq 0.5 \\ \frac{w_{j,k}}{1+e^{(c/\lambda)((-sign(w_{j,k}) \times w_{j,k} + \lambda))}} & se \lambda < 0.5 \end{cases}, \quad (5.4)$$

assim, quando $\lambda < 0.5$ quanto menor o valor de limiar λ maior será o rigor no descarte dos coeficientes (mais próximo da função *hard*), havendo uma melhora expressiva no comportamento da função, conforme mostra a Figura 5.4.

Portanto, temos uma função capaz de se adaptar aos diferentes tipos de coeficientes wavelet, variando entre as funções suave e abrupta de acordo com o valor de inclinação c definido. Com isso, surge a necessidade de definir como (e qual) o valor de inclinação deve ser aplicado aos coeficientes.

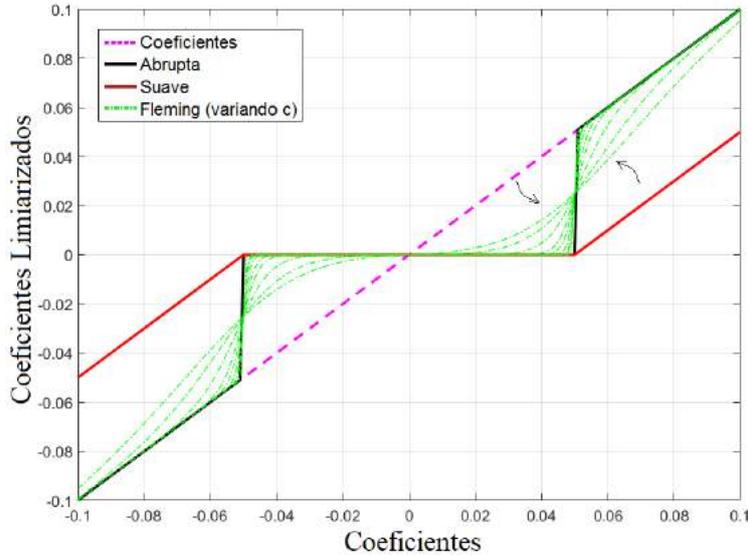


Figura 5.4: Comportamento da função de limiarização Fleming adaptada ($\lambda = 0.05$).

5.2 Identificação dos Coeficientes Wavelet Relevantes

A partir da ideia de identificação dos coeficientes de maior importância para formar o sinal de DP, usada para o método SNRBWS, pudemos realizar uma variante na função de limiarização. Neste caso, optamos por usar a curtose (K_u) como uma medida estatística do achatamento da curva de distribuição de probabilidade [186] do coeficiente $w_{j,k}$, pois quanto mais afunilada esta curva, mais distante da curva de distribuição de probabilidade Normal (Gaussiana), a qual é característica indicativa da presença de ruído branco. Portanto, a curtose servirá como um indicativo para sabermos se estamos lidando com coeficientes contendo ruído (curtose próxima de 3) ou componentes de DP (curtose elevada ≥ 3).

A Figura 5.5 mostra os coeficientes de detalhe no nível $j = 1$ e os coeficientes de detalhe no nível $j = 6$ com seus respectivos histogramas. Perceba que na Figura 5.5(a), formada quase que exclusivamente por componentes de ruído, o histograma aproxima-se muito da distribuição de probabilidade Normal, fato que é confirmado pelo valor de curtose igual a 2.9687; já na Figura 5.5(b) os coeficientes possuem informações significativas do pulso de DP e o histograma é mais afunilado (leptocúrtico), se afastando da distribuição Normal, conforme indicado pelo valor de curtose de 9.9612.

Então, para cumprir a tarefa de identificação dos coeficientes mais relevantes

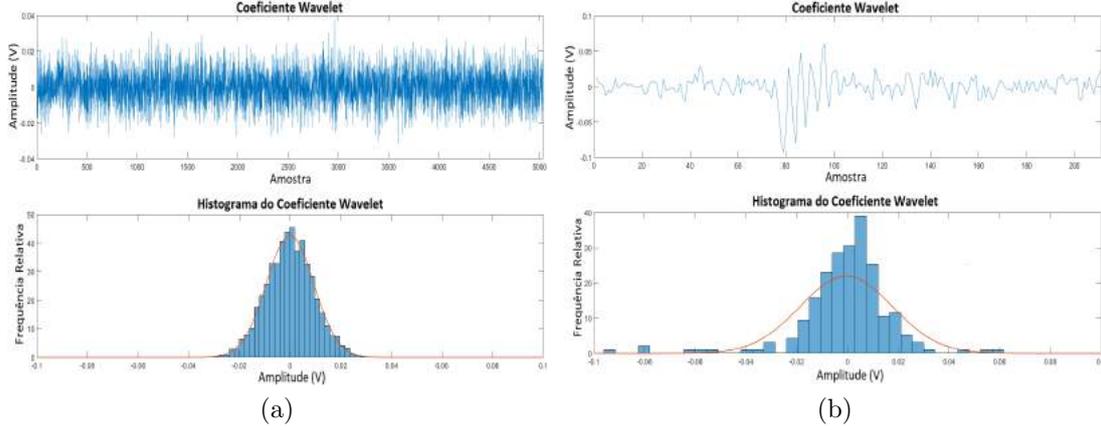


Figura 5.5: Coeficientes wavelets e histogramas de um pulso real de DP: (a) primeiro coeficiente de detalhe (curtose = 2.9687); (b) sexto coeficiente de detalhe (curtose = 9.9612).

para formar o sinal de DP, basta assumir a seguinte condição com relação ao valor de curtose: se a curtose do coeficiente for maior que 4, este deve ser considerado importante e a função de limiarização fará uso de uma constante de inclinação c mais baixa, para permitir a passagem de mais coeficientes, caso contrário os coeficientes serão considerados ruidosos e uma constante inclinação muito maior deverá ser atribuída (no caso $c = 10^{20}$), o que nos leva à função *hard* que eliminará uma quantidade maior destes coeficientes de ruído. Em termos equacionais, temos:

$$\eta_f(w_{j,k}, \lambda, c) = \begin{cases} \frac{w_{j,k}}{1+e^{(10^{20})((-sign(w_{j,k}) \times w_{j,k} + \lambda))}} & se K_u(w_{j,k}) \leq 4 \\ \begin{cases} \frac{w_{j,k}}{1+e^{c((-sign(w_{j,k}) \times w_{j,k} + \lambda))}} & se \lambda \geq 0.5 \\ \frac{w_{j,k}}{1+e^{(c/\lambda)((-sign(w_{j,k}) \times w_{j,k} + \lambda))}} & se \lambda < 0.5 \end{cases} & se K_u(w_{j,k}) > 4 \end{cases} \quad (5.5)$$

Em [69] foi apresentado um método para cálculo do coeficiente de limiarização em que se investiga o histograma de cada coeficiente a ser limiarizado para calcular valores de limiar distintos, um para a parte negativa (λ_j^-) e outro para a parte positiva do sinal (λ_j^+). A Figura 5.6 mostra um sinal de DP contaminado com ruído real (em vermelho) e o sinal livre de ruído (em azul), ambos decompostos (até o nível $J = 6$) em seus coeficientes de detalhe ($d_1 - d_6$) e de aproximação final (a_6) à esquerda e seus respectivos histogramas à direita. Note que a distribuição no lado positivo é diferente da distribuição no lado negativo, em cada sub-banda, o que fornece suporte para observação de se atribuir dois valores distintos de limiar para

cada uma destas sub-bandas, em seus coeficientes de detalhe. A ideia apresenta-se interessante, já que o nível de ruído pode variar de forma distinta para valores negativos e positivos, além de determinar um limiar a cada parte, o que pode trazer resultados superiores de filtragem. O autor peca apenas em utilizar sua função de limiarização truncando os coeficientes com valores abaixo do limiar negativo e, os coeficientes acima do limiar positivo, conforme mostrado na Equação (5.6). Desta forma, os coeficientes importantes para formar o sinal de DP serão reduzidos ao invés de preservados como ocorre na função *hard*, causando uma perda de informação no sinal filtrado. Outra desvantagem é que, segundo o autor, para sinais medidos em campo é preciso utilizar uma tabela de referência que determina os valores de limiar a serem aplicados para níveis diversos de SNR entre o sinal e o ruído presente neste (estimado pelos coeficientes da primeira sub-banda de detalhe).

$$\eta_h(w_{j,k}, \lambda_j^-, \lambda_j^+) = \begin{cases} \lambda_j^-, & \text{se } w_{j,k} \leq \lambda_j^- \\ w_{j,k}, & \text{se } \lambda_j^- < w_{j,k} < \lambda_j^+ \\ \lambda_j^+, & \text{se } w_{j,k} \geq \lambda_j^+ \end{cases} \quad (5.6)$$

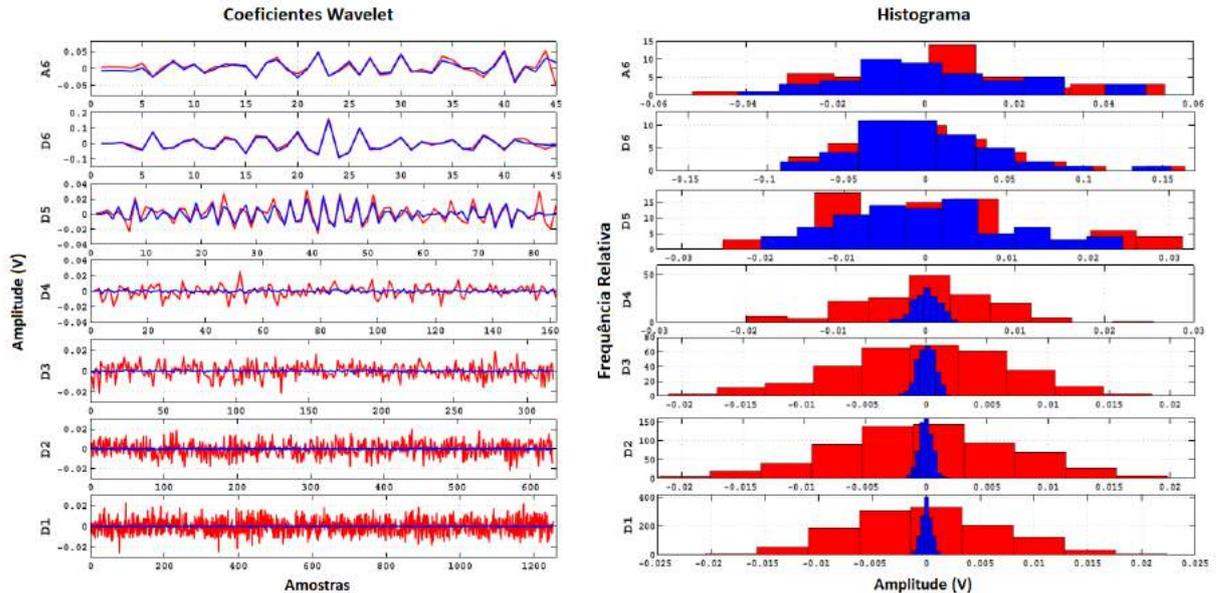


Figura 5.6: Sinal de DP decomposto em sub-bandas wavelet de detalhe e aproximação final (a esquerda) e seus respectivos histogramas (a direita). Em vermelho o sinal contaminado com ruído e em azul o sinal original. Fonte: [42]

A fim de criar um método no qual o uso de tabelas comparativas não seja necessário, e que ao invés de truncar, preserve os coeficientes fora dos limites impostos pelos valores de limiar, recorreremos à Seção 3.6, a qual mostra que o cálculo do coeficiente de limiarização é feito com base numa estimativa estatística do nível de

ruído presente nos coeficientes, e o valor obtido é aplicado de igual forma tanto para os coeficientes positivos, quanto para os negativos. Tomando como base a estimativa do valor de limiar *scaledep* [33], [35], [92] que combina o fator de reescala da Equação (3.20) com o método de estimativa dado pelo Limiar Universal Dependente da Escala (Equação (3.26)), basta identificar as componentes positivas e negativas, no nível de decomposição de interesse e calcular o coeficientes para cada um destes usando a estimativa desejada (no caso a *scaledep*), assim:

$$\lambda_p = \lambda_{scaledep_p} = \sigma p_{n_j} \cdot \lambda_{p_{DE}} = \left(\frac{\text{mediana}(|\omega_{p_{j,k}}|_{j,k \in W_j})}{0,6745} \right) \cdot \sqrt{2 \times \log(Np_j)}, \quad (5.7)$$

$$\lambda_n = \lambda_{scaledep_n} = \sigma n_{n_j} \cdot \lambda_{n_{DE}} = \left(\frac{\text{mediana}(|\omega_{n_{j,k}}|_{j,k \in W_j})}{0,6745} \right) \cdot \sqrt{2 \times \log(Nn_j)}, \quad (5.8)$$

onde p e n referem-se a positivo e negativo, respectivamente. Os coeficientes $\omega_{p_{j,k}}$ são encontrados buscando pelas amostras do coeficiente original maiores iguais a zero e, $\omega_{n_{j,k}}$ pelas amostras menores que zero, com a quantidade de amostras encontradas em cada caso correspondendo às variáveis Np_j e Nn_j , respectivamente. Portanto, surge uma terceira variação para se aplicar à função de limiarização Fleming ao utilizar valores de limiar distintos nos casos em que os coeficientes decompostos forem considerados importantes ($curtose(w_{j,k}) > 4$), para obter um pulso de DP livre de ruídos. Assim,obtemos a seguinte equação:

$$\eta_f(w_{j,k}, \lambda, \lambda_p, \lambda_n, c) = \begin{cases} \frac{w_{j,k}}{1+e^{(10^{20})((-sign(w_{j,k}) \times w_{j,k} + \lambda))}} & \text{se } K_u(w_{j,k}) \leq 4 \\ \left\{ \begin{cases} \frac{w_{j,k}}{1+e^{c((-sign(w_{j,k}) \times w_{j,k} + \lambda_p))}} & \text{se } \min(\lambda_p, \lambda_n) \geq 0.5 \\ \frac{w_{j,k}}{1+e^{(c/\lambda_p)((-sign(w_{j,k}) \times w_{j,k} + \lambda_p))}} & \text{se } \min(\lambda_p, \lambda_n) < 0.5 \end{cases} \right. & \text{para } (w_{j,k}) \geq 0 \\ \left\{ \begin{cases} \frac{w_{j,k}}{1+e^{c((-sign(w_{j,k}) \times w_{j,k} + \lambda_n))}} & \text{se } \min(\lambda_p, \lambda_n) \geq 0.5 \\ \frac{w_{j,k}}{1+e^{(c/\lambda_n)((-sign(w_{j,k}) \times w_{j,k} + \lambda_n))}} & \text{se } \min(\lambda_p, \lambda_n) < 0.5 \end{cases} \right. & \text{para } (w_{j,k}) < 0 \end{cases} \quad \text{se } K_u(w_{j,k}) > 4 \quad (5.9)$$

O desafio desta nova função e suas variações está em determinar qual o valor

ótimo de inclinação c no ponto de limiar para prover uma melhora na filtragem. Uma alternativa é a busca do valor adequado através da minimização LMS da função risco SURE [31, 76], a qual fornece uma estimativa do EQM do sinal após sua filtragem, conseqüentemente, espera-se que após a busca o sinal resultante tenha melhor EQM.

5.3 Busca da Constante de Inclinação da Função Fleming pela Minimização do seu Risco SURE

Um dos métodos mais práticos de aprendizagem por redes neurais é o algoritmo LMS. Usamos o mesmo para ajustar iterativamente o valor de limiar junto com o gradiente descendente do risco EQM. O valor de limiar no passo m para a sub-banda j é calculado da seguinte forma:

$$\lambda_j(m+1) = \lambda_j(m) + \Delta\lambda_j, \quad j = 1, 2, \dots, J(m), \quad (5.10)$$

onde o incremento $\Delta\lambda_j(m)$ é dado por:

$$\Delta\lambda_j(m) = -\alpha_j(m) \left. \frac{\partial J_{EQM}}{\partial \lambda_j} \right|_{\lambda=\lambda_j(m)}, \quad (5.11)$$

α corresponde à taxa de aprendizagem e J_{EQM} ao risco EQM. Na prática, não se conhece o sinal livre de ruídos, nestes casos é possível usar um estimador para o EQM. Um dos estimadores mais práticos do EQM é o SURE, e também será adotado na estimativa de risco de nossa função de limiarização.

Para problemas de estimação da função de limiar, temos:

$$\mathbf{g}(\mathbf{x}) = \hat{\boldsymbol{\mu}}(\mathbf{x}) - \mathbf{x}, \quad (5.12)$$

onde $\mathbf{g}(\mathbf{x}) = [g_0, g_1, \dots, g_{N-1}]^T$ é uma função forma de R^N para R^N e $\hat{\boldsymbol{\mu}}(\mathbf{x})$ é um estimador particular de um vetor $\boldsymbol{\mu}$. Em [149] Stein mostrou que quando $\mathbf{g}(\mathbf{x})$ é fracamente diferenciável, então:

$$E_\mu \|\hat{\boldsymbol{\mu}}(\mathbf{x}) - \mathbf{x}\|^2 = N + E_\mu \{ \|\mathbf{g}(\mathbf{x})\|^2 + 2\nabla_x \cdot \mathbf{g}(\mathbf{x}) \}, \quad (5.13)$$

onde $\nabla_x \cdot \mathbf{g}(x) = \sum_{i=0}^{N-1} \frac{\partial}{\partial x_i} g_i$. SURE é um estimador do risco acima, definido como:

$$R_s(\lambda) = N + \|\mathbf{g}(\mathbf{x})\|^2 + 2\nabla_x \cdot \mathbf{g}(\mathbf{x}). \quad (5.14)$$

Portanto, o risco SURE pode ser usado para estimar o valor ótimo de limiar, por meio de:

$$\frac{\partial R_s(\lambda)}{\partial \lambda} = 2 \sum_{i=0}^{N-1} g_i \frac{\partial g_i}{\partial \lambda} + 2 \sum_{i=0}^{N-1} \frac{\partial^2 g_i}{\partial x_i \partial \lambda}. \quad (5.15)$$

Usando o algoritmo LMS, em cada passo o valor de limiar ótimo no domínio wavelet é ajustado de acordo com o gradiente descendente de uma função risco, no caso a função de risco SURE. Assim, recorrendo à Equação (5.10), o limiar pode ser ajustado para a solução ótima em cada escala j como se segue [83]:

$$\Delta \lambda_j = \alpha_j(m) \cdot \left. \frac{\partial R_s^{(j)}(\lambda_j)}{\partial \lambda_j} \right|_{\lambda_j = \lambda_j(m)}. \quad (5.16)$$

A cada passo o valor de $\alpha_j(m)$ (taxa de aprendizagem) deve ser selecionado de modo que $\lambda_j(m+1) \geq 0$. Conseqüentemente a solução ótima do risco SURE, ou seja, seu argumento mínimo corresponderá a uma estimativa da solução ótima do risco EQM.

Em seguida, podemos tomar o estimador da Equação (5.12) com base na função de limiarização, obtendo então $g_i = \eta(x_i, \lambda) - x_i$. Usando a função Fleming η_f descrita pela Equação (5.4):

$$\frac{\partial g_i}{\partial \lambda} = \frac{\partial \eta_f(w_{j,k}, \lambda, c)}{\partial \lambda} - \frac{\partial (w_{j,k}, c)}{\partial \lambda} = \frac{\partial \eta_f(w_{j,k}, \lambda, c)}{\partial \lambda}, \quad (5.17)$$

$$\frac{\partial^2 g_i}{\partial \lambda} = \frac{\partial^2 \eta_f(w_{j,k}, \lambda, c)}{\partial w_{j,k} \partial \lambda} - \frac{\partial^2 (w_{j,k}, c)}{\partial w_{j,k} \partial \lambda} = \frac{\partial^2 \eta_f(w_{j,k}, \lambda, c)}{\partial w_{j,k} \partial \lambda}, \quad (5.18)$$

o que nos habilita para calcular o risco SURE $R_s^{(j)}$ e buscar o valor ótimo de limiar para cada escala j no domínio wavelet. Ademais, o gradiente baseado no algoritmo de aprendizagem, pode ser usado para buscar o valor ótimo de limiar dependente da escala no domínio wavelet sobre o risco estimado $R_s^{(j)}$ através da Equação (5.9).

O formato da função Fleming garante a sua diferenciabilidade. Na Figura 5.7, a diferenciabilidade citada é vista no comportamento das derivadas $\partial \eta_f(w_{j,k}, \lambda, c) / \partial \lambda$ e $\partial^2 \eta_f(w_{j,k}, \lambda, c) / \partial w_{j,k} \partial \lambda$ da função $\eta_f(w_{j,k}, \lambda, c)$ para um coeficiente de limiarização igual a 1.

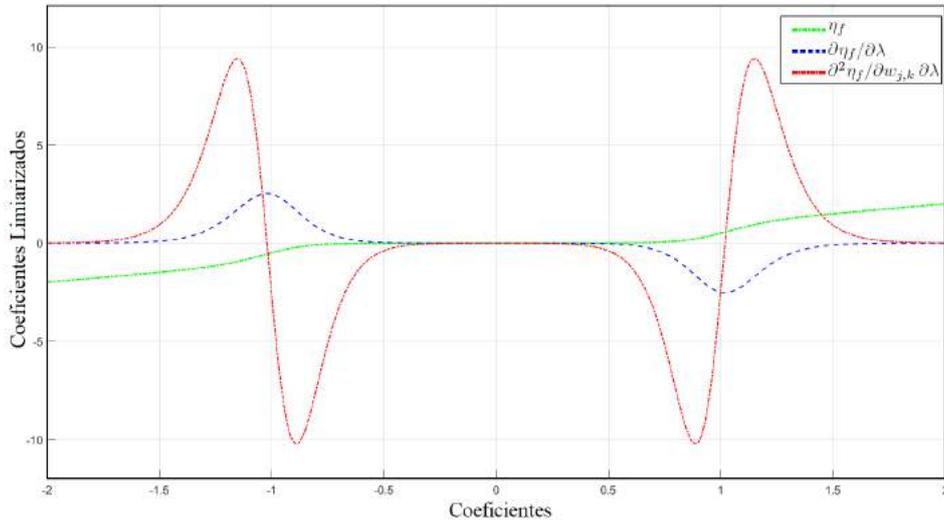


Figura 5.7: Comportamento da função Fleming e suas derivadas em relação a λ .

Vale ressaltar que não apenas a variável λ pode ser estimada usando o risco SURE, podendo ser estendida para as outras variáveis existentes na função. Em nosso caso para a constante de inclinação c , a qual realmente estamos interessados em otimizar. Então, o valor de limiar e o parâmetro de inclinação são calculados por:

$$\lambda_j(m+1) = \lambda_j(m) + \Delta \lambda_j \mid c = c_j(m), \quad (5.19)$$

$$c_j(m+1) = c_j(m) + \Delta c_j \mid \lambda = \lambda_j(m), \quad (5.20)$$

com valores de incremento dados por:

$$\Delta\lambda_j(m) = -\alpha_j(m) \cdot \left. \frac{\partial J_{EQM}}{\partial \lambda} \right|_{\lambda=\lambda_j(m)} \quad c = c_j(m), \quad (5.21)$$

$$\Delta c_j(m) = -\gamma_j(m) \cdot \left. \frac{\partial J_{EQM}}{\partial c} \right|_{c=c_j(m)} \quad \lambda = \lambda_j(m), \quad (5.22)$$

onde γ corresponde à taxa de aprendizagem para a variável c . Como em nossa função os valores de c são relativamente elevados, se comparados aos valores típicos de incremento aplicados num algoritmo LMS, é preciso adaptar esta variável para que o algoritmo não demore demais para convergir. Para tanto, basta substituir c por $1/f$. Na Figura 5.8 temos o comportamento das derivadas em relação ao parâmetro $c = 1/f$ para um coeficiente λ igual a 1.

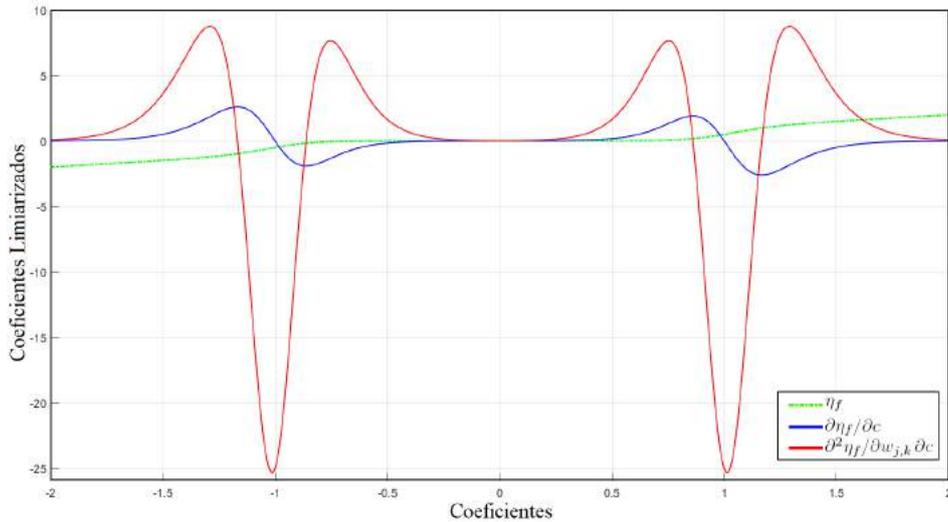


Figura 5.8: Comportamento da função Fleming e suas derivadas em relação a c .

Portanto, temos uma quarta variante para função Fleming (Equação (5.4)) combinada com o algoritmo de otimização LMS, fazendo a busca automática do parâmetro de inclinação c (decidimos por não alterar o valor de limiar λ , para reduzir o tempo de execução do algoritmo). A busca por LMS da constante c também foi estendida para a função de limiarização dada pela Equação (5.5).

É utilizado como exemplo um pulso de DP real (com 10000 amostras obtidas para $F_s = 100$ MHz) contendo ruído. Aplicamos a decomposição wavelet em $J = 6$ níveis usando o método SNRBWS para definir as funções wavelet de cada nível, o método *scaledep* para determinar o valor de limiar, além da função Fleming combinada com o cálculo LMS. Como condição inicial usamos uma constante $f = 0.1$

($c = 10$). O incremento usado foi de $\gamma = 5 \times 10^{-5}$ e o critério de parada do método é atingir um máximo de 250 passos ou apresentar uma diferença entre dois passos seguidos menor do que 10^{-7} . Na Figura 5.9 são mostrados os resultados de evolução do risco SURE (R_s), da derivada parcial $\partial R_s(c)/\partial c$ e da constante $c = 1/f$ para alguns dos coeficientes wavelet. Nota-se que a convergência pela busca de c evolui de forma distinta para cada coeficiente: para d_3 o método converge lentamente e precisaria de uma quantidade maior de passos para atingir um valor ótimo de c , enquanto que para d_5 e a_6 o algoritmo LMS converge antes mesmo do número máximo de passos.

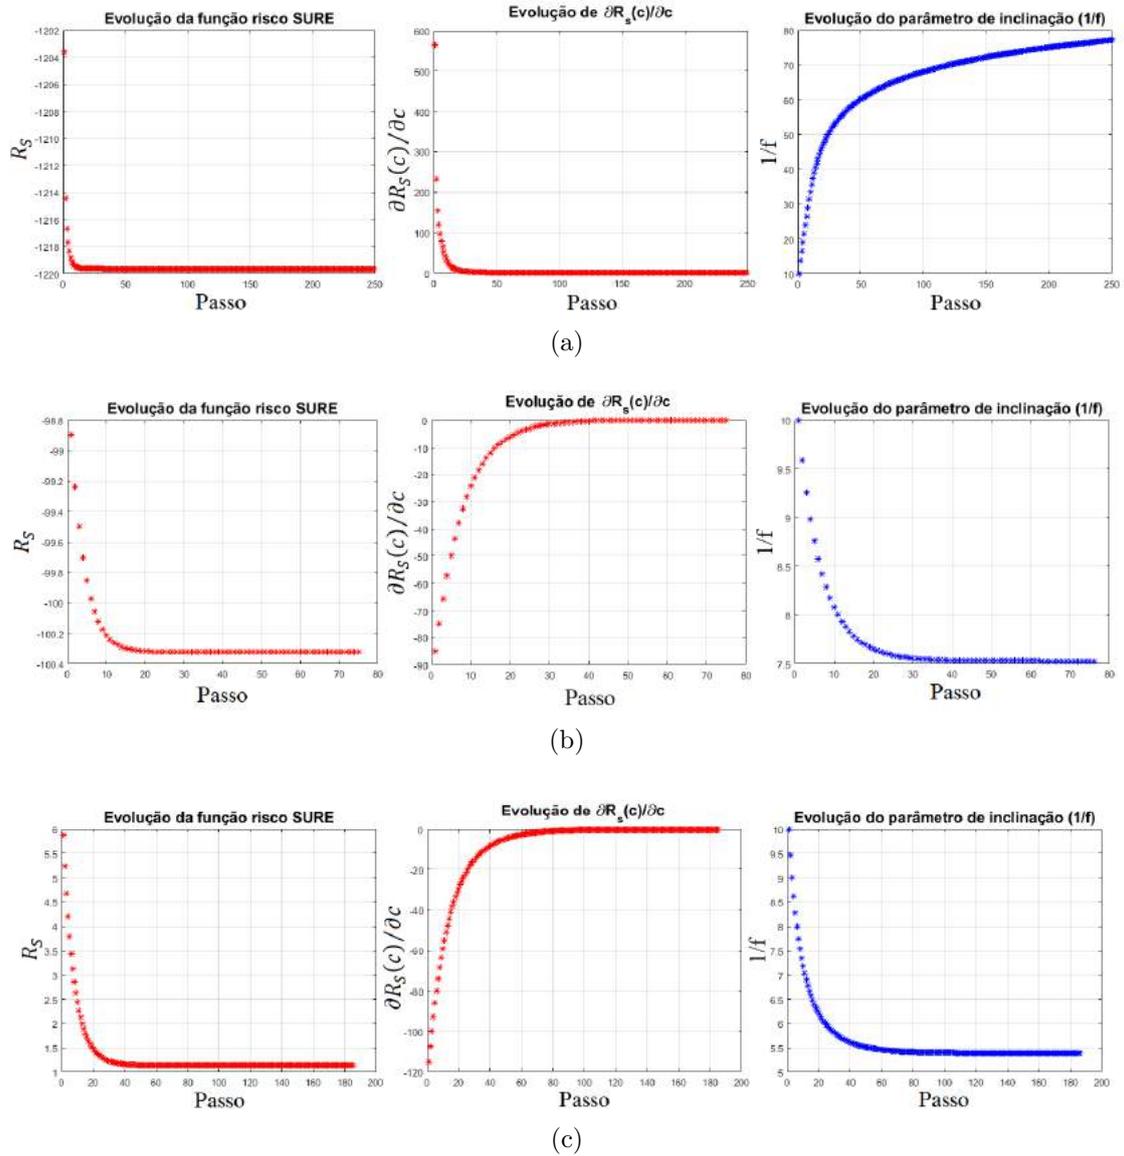


Figura 5.9: Evolução do risco SURE, sua derivada parcial para a constante c e da constante $c = 1/f$: (a) coeficientes de detalhe d_3 ; (b) coeficiente de detalhe d_5 ; (c) coeficiente de aproximação a_6 .

Alguns métodos alternativos de estimação de limiar têm sido descritos na literatura. Em [39], o método EBWS é utilizado junto com um AG com a finalidade de alcançar o melhor valor de limiar a ser aplicado em uma nova função de limiarização. O método (denominado GATE) busca pelo valor de limiar que minimiza o EQM com base na estimativa do risco SURE [144] da nova função proposta. Hong He, *et al.* também utiliza um AG para buscar os parâmetros ótimos de uma função de limiarização polinomial. A busca se baseia numa função custo resultante de uma combinação da raiz do erro quadrático médio e da suavidade do sinal filtrado [81]. Hemant e Rashmi [82] usam o algoritmo de colonização artificial por abelhas (ABC) para procurar pelo valor de limiar ótimo para uma nova função de limiarização polinomial, o método foi utilizado para filtragem de sinais diversos.

No capítulo 8 realizaremos a comparação de cada uma das variantes da função Fleming com as usuais funções suave e abrupta, além do confronto com outras funções descritas em trabalhos já publicados [70], [72], [83], [147]. Usaremos como principal indicador da qualidade da filtragem a função de aptidão descrita na Seção que se segue

5.4 Critério de Avaliação de Filtragem Wavelet em Sinais de Descargas Parciais

Em [35], desenvolvemos um novo método de otimização baseado em AG com o objetivo de encontrar os parâmetros wavelets (descritos na Seção 3.1) necessários ao processo de redução de ruído no domínio wavelet, de forma a propiciar um melhor resultado de filtragem. Num AG, o maior desafio refere-se à criação de uma função de aptidão f_{Apt} que nos permita avaliar a qualidade das variáveis envolvidas no problema (parâmetros de filtragem wavelet). Após verificar os critérios de avaliação mais utilizados na análise de performance dos resultados obtidos em filtrações de sinais de DP, chegou-se a seguinte função:

$$f_{Apt} = \left(\alpha_1 \cdot DSNR + \alpha_2 \cdot NCC + \alpha_3 \cdot \frac{1}{EQM} - \alpha_4 \cdot Dk \right) - \left(\beta_1 \cdot EA_{max} + \beta_2 \cdot EA_{min} + \beta_3 \cdot \Delta P_{max} + \beta_4 \cdot \Delta P_{min} + \beta_5 \cdot \Delta T_s \right). \quad (5.23)$$

Apesar desta função conseguir identificar adequadamente os melhores resultados numa filtragem, tivemos problemas com o Erro Quadrático Médio (EQM), pois ele muitas vezes fornecia valores extremamente pequenos, o que dava muito peso a

EQM^{-1} e mascarava os demais critérios. Desta forma, para melhorar a aplicabilidade função de aptidão, propomos substituir este critério pela Diferença de Energia (DE) entre o sinal original e o sinal filtrado, conforme se segue [91]:

$$f_{Apt} = \left(\alpha_1 \cdot DSNR + \alpha_2 \cdot NCC + \alpha_3 \cdot \frac{1}{DE} - \alpha_1 \cdot Dk \right) - \left(\beta_1 \cdot EA_{max} + \beta_2 \cdot EA_{min} + \beta_3 \cdot \Delta P_{max} + \beta_4 \cdot \Delta P_{min} + \beta_5 \cdot \Delta T_s \right), \quad (5.24)$$

onde as constantes α_i e β_i são pesos que devem ser ajustados para designar a importância de cada critério de avaliação. As seguintes informações estatísticas do resultado são extraídas: pela Diferença entre SNR do sinal estimado para o filtrado e a SNR do sinal estimado para o aquisitado ($DSNR$), Coeficiente de Correlação Normalizado (NCC) e Diferença de Curtose (Dk). As variáveis EA_{max} e EA_{min} , indicam o erro em percentagem da amplitude máxima e da amplitude mínima entre o sinal de DP estimado e o sinal de DP filtrado, nessa ordem. Já ΔP_{max} e ΔP_{min} correspondem à variações no tempo de pico máximo e à variações no tempo de pico mínimo para estes sinais, respectivamente. O critério ΔT_s indica a variação no tempo de subida (tempo entre os instantes em que a amplitude vai de 10% a 90% do valor de pico máximo) entre o sinal estimado e o sinal filtrado.

Além de todos os critérios mencionados, a Equação (5.24) também será usada em nossas análises de resultados de filtragem wavelet dos sinais de DP no Capítulo 8. Ela será considerada como o critério de maior importância nas avaliações.

Capítulo 6

Aperfeiçoamento do Método de Separação de Padrões de Descargas Parciais pela Função Autocorrelação Normalizada

O NACF é considerado destaque entre os métodos de separação, visto sua habilidade em conseguir separar características de DP. No entanto, conforme descrito na Subseção 4.3.4 seu processamento é relativamente lento, confrontado a outros métodos de separação/classificação.

Ao estudar o método verificamos que algumas modificações poderiam ser feitas numa tentativa de melhorar sua performance, sem comprometer sua eficácia na separação dos diferentes padrões de DP, ou até mesmo melhorá-la. A seguir apresentaremos as alterações realizadas em cada etapa do algoritmo.

6.1 Modificações Implementadas no Método de Separação NACF

A etapa de separação de pulsos de DP, a qual é o foco principal de nosso trabalho, foi explorada através do algoritmo NACF descrito na Subseção 4.3.4. Neste Capítulo mostraremos os resultados que obtivemos com este método na separação de pulsos de DP de formatos distintos (i.e., provenientes de fontes diferentes) no mapa PRPD. Um dos problemas desse método é o seu custo computacional, no que diz respeito a cada uma de suas três etapas:

1. Mapear o sinal adquirido em um espaço de separação, neste caso pelo uso da NACF;
2. Aplicar o algoritmo de agrupamento K-means, o qual exige o cálculo da distância dp dada pela Equação (4.23);
3. Verificar a qualidade da separação com respeito aos erros de classificação (através do teste chi-quadrado [187] aplicado na avaliação do PRPD) ou problemas de sobreclassificação (que podem ser identificados por formação de grupos semelhantes).

O algoritmo apresentado pode ser aperfeiçoado em cada uma destas etapas.

O cálculo da NACF indica que devemos dividir a ACF por sua energia para normalização. Entretanto, como a energia total do pulso é dada pela máxima amplitude da ACF, conforme descrito na Subseção 4.3.4, então basta que a ACF calculada seja dividida pelo seu valor máximo, como a seguir:

$$R_s[k] = \frac{\sum_{i=1}^{N_c} s(i) s(i+k)}{N_c} \times \frac{1}{\max\left(\frac{\sum_{i=1}^{N_c} s(i) s(i+k)}{N_c}\right)}, \quad (6.1)$$

sendo

$$\max\left(\frac{\sum_{i=1}^{N_c} s(i) s(i+k)}{N_c}\right) = \frac{1}{N_c} \times \max\left(\sum_{i=1}^{N_c} s(i) s(i+k)\right), \quad (6.2)$$

então

$$R_s[k] = \frac{\sum_{i=1}^{N_c} s(i) s(i+k)}{\max\left(\sum_{i=1}^{N_c} s(i) s(i+k)\right)}, \quad (6.3)$$

É possível melhorar a simplificação da Equação (6.3) verificando que o máximo valor de ACF é igual a $ACF(N_c)$ (já calculado), onde N_c corresponde ao compri-

mento do sinal avaliado (pulso de DP). Portanto, temos:

$$R_s [k] = \frac{\sum_{i=1}^{N_c} s(i) s(i+k)}{ACF(N_c)}. \quad (6.4)$$

Na Figura 6.1 é mostrado um pulso de DP e o resultado da NACF usando cada uma destas equações. Perceba que não existe diferença alguma entre ambas, conseqüentemente a modificação não altera o resultado de separação das diversas fontes de DP presentes no mapa medido.

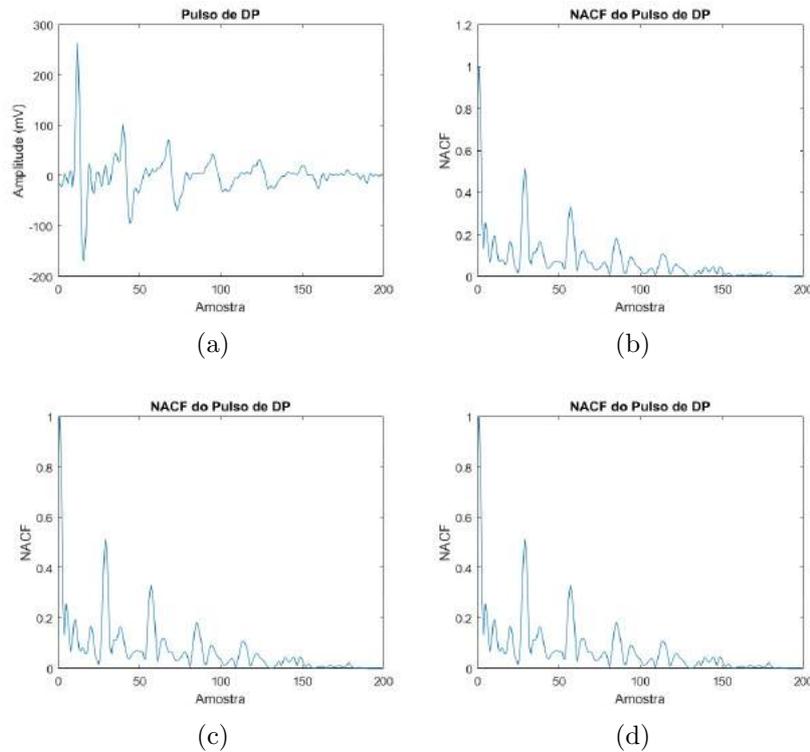


Figura 6.1: NACF gerado para pulso de DP: (a) Pulso de DP medido, (b) Equação (4.22), (c) Equação (6.3), (d) Equação (6.4).

O autor utiliza o método de agrupamento K-means combinado à distância métrica d_p calculada pela Equação (4.23). Contudo, ela consome muito tempo de processamento para avaliar a proximidade entre os sinais de DP. De imediato, ao eliminar o cálculo a raiz quadrada, o produto por dois e a subtração por 1, obtém-se o mesmo resultado em menos tempo. Tais modificações exigem apenas o ajuste do valor de limiar, que se segue:

$$limiar_{new} = 1 - (limiar^2) / 2. \quad (6.5)$$

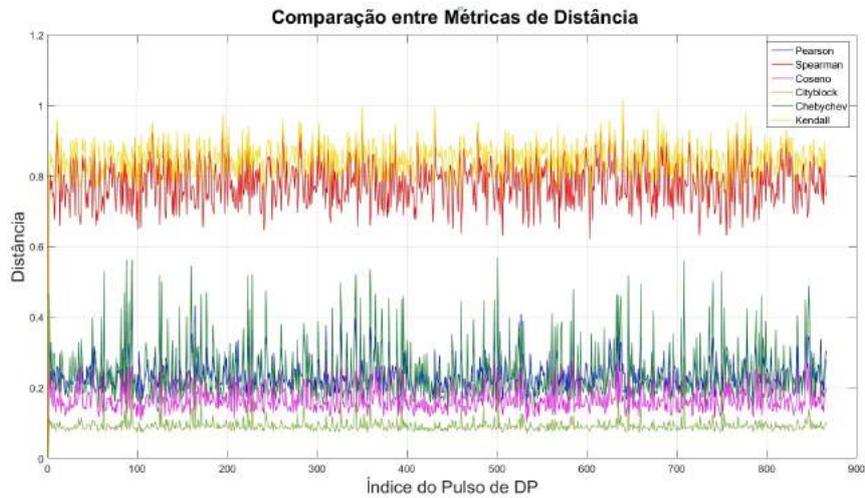
Neste caso, a regra de verificação de similaridade entre os pulsos de DP passa a ser $d_p > limiar_{new}$ e não mais $d_p < limiar$, pois temos $d_p = p_c$ e, portanto, d_p é diretamente proporcional a p_c , ou seja, deixa-se de existir uma medida de distância e passa-se a ter uma medida de similaridade.

Outra possibilidade verificada é a de se utilizar uma métrica de distância ao invés da correlação de Pearson p_c , pois esta consome um tempo considerável de processamento. Como alternativa investigamos outras seis métricas, incluindo o coeficiente de correlação de postos de Spearman, o coeficiente de correlação tau de Kendall, a similaridade Cosseno, a métrica *City block* e a distância *Chebyshev* (diferença de coordenada máxima).

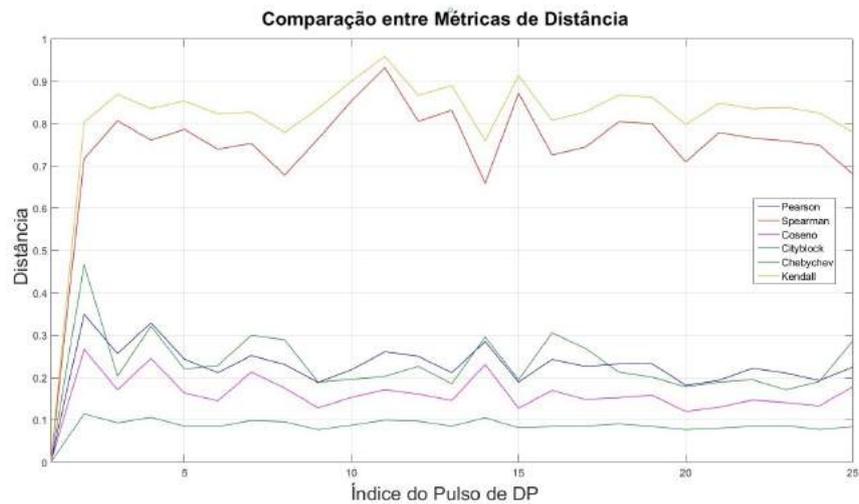
Numa análise inicial, tem-se como exemplo a medição de DP real, contendo 866 pulsos de DP. Calculamos a NACF de cada pulso de DP e aplicamos as diferentes métricas de medida de distância para comparar a similaridade do primeiro pulso, com os demais (uma etapa que faz parte do algoritmo K-means usado em [51]). Na Figura 6.2 ilustramos os resultados de cada técnica citada para avaliar a relação das medidas com o coeficiente de correlação de Pearson, que é usado no algoritmo de separação por NACF clássico. Ao verificar a Figura 6.2(b) (mostra o valor de distância para os 25 primeiros pulsos de DP), vemos que a distância Pearson está diretamente relacionada às métricas Cosseno, *City block* e *Chebyshev*, pois quando uma aumenta ou diminui as demais métricas também o fazem, entretanto, as distâncias de Spearman e de Kendall não possuem uma relação muito forte com as demais.

Além disso, mostramos na Tabela 6.1 o tempo necessário para o cálculo de cada distância e o coeficiente de correlação entre o resultado fornecido pela correlação de Pearson e o resultado dos demais métodos. Observa-se que as distâncias de Spearman e de Kendall levam mais tempo para serem calculadas e são não correlatas com a distância de Pearson, isso porque estas seguem um processo que leva em conta uma avaliação da dependência estatística por meio do ranqueamento das variáveis envolvidas: enquanto a correlação de Pearson acessa uma relação linear entre os sinais, as correlações de Spearman e de Kendall acessam uma relação monotônica entre os sinais (sejam lineares ou não). Já as demais métricas são calculadas rapidamente e são fortemente correlatas com a medida de distância dada pelo coeficiente de correlação de Pearson, tornando-as boas candidatas para servirem como indica-

dores de similaridade, desde que feitos os devidos ajustes no valor de *limiar* para cada métrica escolhida.



(a)



(b)

Figura 6.2: Comparação entre métricas de distância da NACF: (a) todos os 866 pulsos de DP, (b) visão aproximada com os primeiros 25 pulsos de DP.

Tabela 6.1: Comparação entre Métricas de Distância.

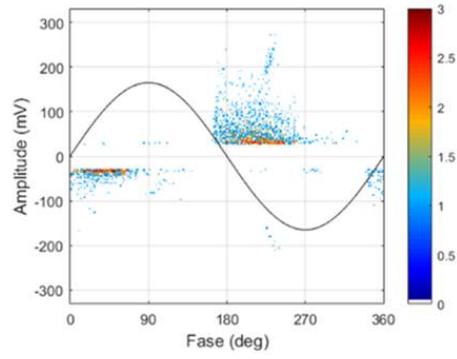
Métrica	Tempo de execução (s)	Coefficiente de Correlação
Pearson	0.1465	-
Spearman	0.2133	- 0.0143
Cosseno	0.1239	0.8878
<i>City block</i>	0.0761	0.8646
<i>Chebychev</i>	0.0755	0.8473
Kendall	0.7415	0.0131

Os autores recorreram ao teste χ^2 pra avaliar a qualidade da classificação, mas em [187], Yazici compara três outros métodos de medição de similaridade entre histogramas: correlação amostral, distâncias Kolmogorov-Smirnov I e II. Sendo que os melhores resultados foram obtidos com o método Kolmogorov-Smirnov II para histogramas em 1D, logo surge uma motivação em explorar outra alternativa para comparação de similaridade entre os histograma PRPD, separados após a execução do algoritmo NACF.

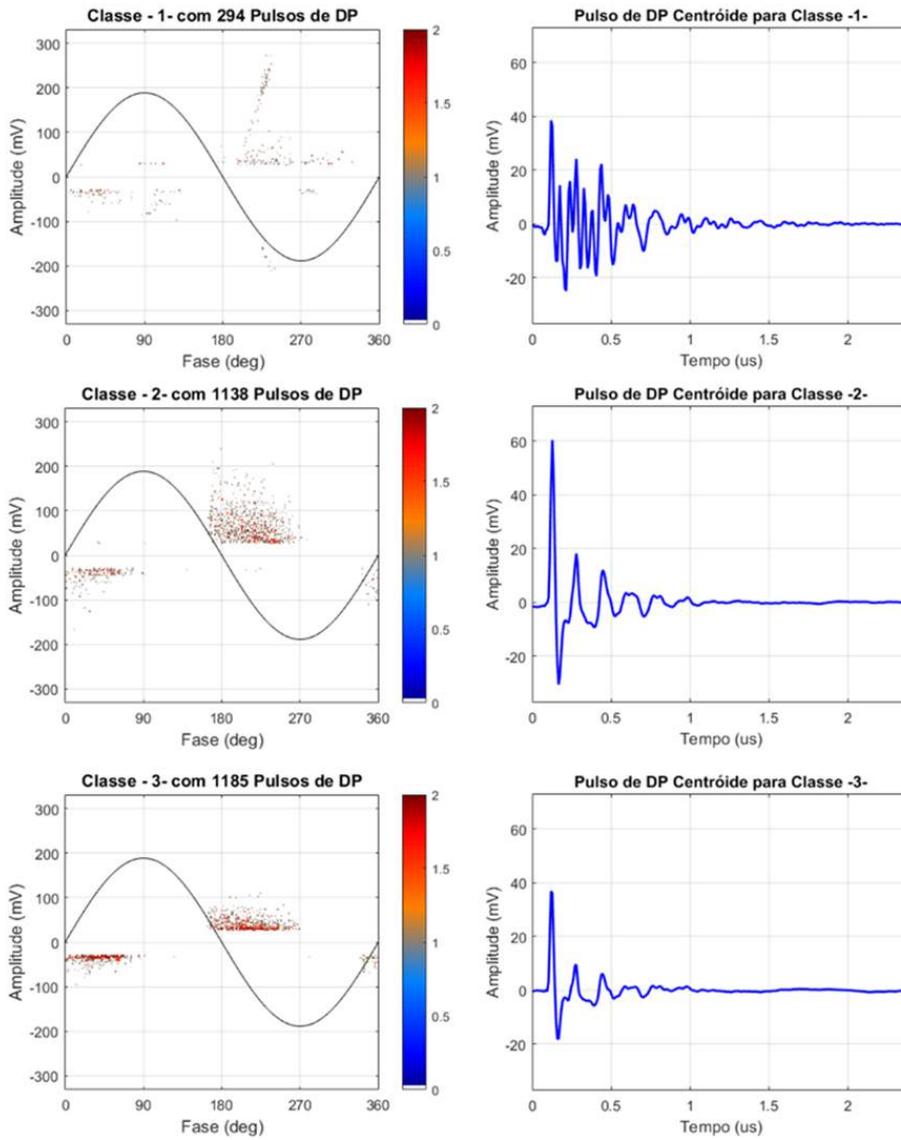
Em algumas simulações do método NACF, verificou-se que mapas PRPD com padrões semelhantes que eram separados, possuíam pulso médio (centroide) similares em formato (mesmo que com amplitudes e/ou polaridades diferentes). Portanto, a partir desta observação, verificou-se que a comparação entre os pulsos centroides com uso da correlação de Pearson seria suficiente para indicar quais padrões de mapas PRPD gerados pelo método de separação poderiam ser agrupados, assim como faz o teste χ^2 , mas com um tempo de processamento muito inferior.

Na Figura 6.3 (a) temos um mapa PRPD gerado a partir de uma medição real de DP em um hidrogerador e na Figura 6.3 (b) são mostrados os mapas PRPD com seus respectivos pulsos médios gerados após a separação através do método NACF, com métrica de distância dada pela Equação (6.5) e $limiar = 0.8$. Repare que, ao compararmos o pulso centroide de cada classe percebe-se que a classe 1 realmente é bem diferente das demais classes, no entanto, as classes 2 e 3, quando comparadas, se mostram formas de onda bastante similares, distinguindo-se mais pela amplitude do que pelo formato. Ou seja, permite concluir que, estas classes separadas, efetivamente compõem o mesmo tipo de defeito e poderiam ser agrupadas em um único mapa PRPD. O cálculo da correlação entre elas é $p_{c_{1,2}} = 0.5881$, $p_{c_{1,3}} = 0.6369$ e $p_{c_{2,3}} = 0.9375$, o qual confirma a hipótese de que este parâmetro serve como indicador de possibilidade de agrupamento entre classes.

A solução proposta é simples e necessita apenas que se faça o cálculo do coeficiente de correlação entre as classes geradas e aquelas que possuem similaridade superior a um valor definido pelo usuário serão agrupadas para formar um único mapa PRPD. No caso é sugerido aplicar um valor de $p_{c_{i,j}} \geq 0.85$, sendo $i = 1, 2, \dots, n_{classes}$ e $j = 1, 2, \dots, n_{classes}$, para $i \neq j$. Na Figura 6.4 é mostrado o fluxograma do método proposto.



(a)



(b)

Figura 6.3: Exemplo de separação pelo método NACF: (a) PRPD medido; (b) PRPD separados com seus respectivos pulsos médios. O coeficiente de correlação entre as classes é $p_{c_{1,2}} = 0.5881$, $p_{c_{1,3}} = 0.6369$ e $p_{c_{2,3}} = 0.9375$.

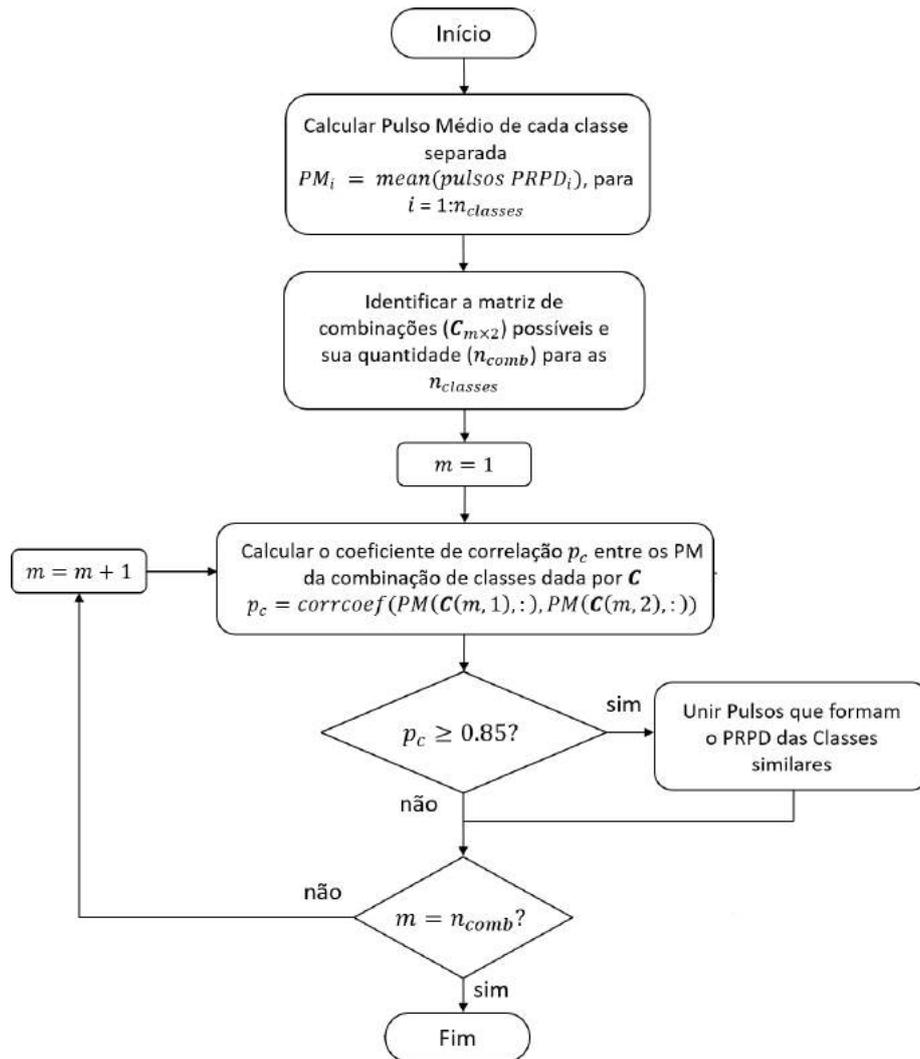


Figura 6.4: Fluxograma do método de agrupamento de mapas PRPD por similaridade de pulso médio.

Capítulo 7

Sistema de Análise e Separação de Dados de Descargas Parciais

Conforme descrito no Capítulo 4, pode existir mais do que uma fonte de pulsos de descarga, simultaneamente ativas dentro de um aparato de potência, pois estes podem se originar de fontes diferentes num mesmo equipamento, seja por sua localização ou pelo tipo de defeito que os causam.

No entanto, dentre os diversos tipos de defeitos que causam descargas, normalmente não é uma tarefa simples diferenciá-los através das formas tradicionais de consolidação dos dados, tais como o mapa PRPD, distribuições de magnitude e distribuições de fase. Sabe-se que sinais de descargas provenientes de fontes diferentes muito provavelmente apresentarão formas de onda distintas, o que nos possibilita realizar a caracterização e a separação de cada padrão presente numa medição.

Em geral, os detectores usuais de DP não proveem nenhuma informação sobre o tipo (fonte) de DP quando ocorrem falhas no isolamento. Contudo, a separação precisa das múltiplas fontes de DP é fundamental para acessar a integridade dos ativos de energia em serviço. Desta maneira, pode-se evitar interpretações errôneas e o risco de uma avaliação inadequada, a qual pode acontecer com os métodos de análise tradicionais (mapa PRPD e histogramas derivados deste). Portanto, a distinção entre fontes de DP é de grande importância para os desenvolvedores de sistemas e equipamentos. Em uma tentativa de atender esta necessidade, muitos métodos para separação têm sido propostos na literatura.

Dentre os objetivos principais deste estudo está o desenvolvimento um sistema de análise e separação de descargas parciais que permita a distinção dentre as diversas fontes de DP e ruído existentes nas medições (mesmo após procedimentos de filtragem), discriminando-as em diferentes mapas PRPD, possibilitando ao usuário

do sistema avaliar com maior precisão os dados de que dispõe.

No Capítulo 4 exploramos alguns dos principais métodos de extração de características e de agrupamento de dados. O mais adequado para o desenvolvimento de um sistema de separação de dados é apresentar um conjunto diversificado de técnicas de caracterização e de agrupamento dos diferentes padrões de DP, a fim de que outras combinações destes possam ser avaliadas na busca de um melhor diagnóstico.

Nas Subseções seguintes daremos destaque aos novos métodos de correção de polaridade e de estimativa da resposta em frequência do sistema avaliado. Ambas inovações são importantes contribuições na análise dos dados de DP. Por fim, descreveremos a estrutura do sistema de análise e separação de DP, que além das técnicas de processamento de dados usuais de quaisquer sistemas disponíveis, conta com a implementação de metodologias inovadoras no tratamento de sinais de DP.

7.1 Correção de Polaridade no Mapa PRPD

Conforme já mencionado no Capítulo 2, o histograma PRPD é formado por uma matriz em que cada linha corresponde a uma faixa do nível de amplitude do pulso, cada coluna corresponde a uma faixa de fase e cada valor na célula corresponde à contagem de pulsos de DP, dentro desta janela nível x fase. O resultado é um gráfico 3D, usualmente apresentado como uma imagem 2D, em que o número de pulsos de DP detectados é indicado pelas diferentes cores. A importância deste gráfico é considerável, já que possibilita a identificação de padrões de descargas que remetem a um defeito característico dentro do equipamento avaliado. Sendo assim, é necessário garantir uma melhor fidelidade dos dados apresentados no mapa PRPD e nos histogramas derivados do mesmo.

Existem dois métodos para se atribuir a polaridade de um pulso detectado [4]:

1. Usar a polaridade da máxima amplitude absoluta (pico) do pulso, i.e., se o valor de máximo do pulso for maior ou igual ao valor de mínimo do mesmo, então o pulso é dito positivo, caso contrário este é dito negativo;
2. Usar o primeiro cruzamento do valor de Limiar de Descarga (LD), o qual deve ser designado pelo usuário antes de se iniciar a medição, pois indica o valor mínimo de tensão de pico necessário para que um pulso não seja considerado como ruído. Portanto, se a primeira amostra de um pulso a cruzar o valor de LD for positiva, este será designado como de polaridade positiva e caso

contrário, negativa.

O primeiro método é o menos utilizado, pois a atribuição de uma polaridade ao pico de um pulso não significa que ele se inicie como um pulso da mesma polaridade de seu pico de amplitude. Isso geralmente ocorre quando estamos lidando com pulsos do tipo oscilatório exponencialmente amortecido. O segundo, apesar de ser mais eficiente por ignorar parte do ruído de fundo presente nas medições através do valor de LD , também não garante que a polaridade dos pulsos seja identificada corretamente, pois é possível que a polaridade da primeira oscilação a cruzar o LD seja diferente da real polaridade do pulso [4], este problema é muito comum quando a relação valor de pico/ LD é muito grande.

Na Figura 7.1 exemplificamos alguns tipos de pulsos de DP reais detectados para um $LD = 30$ mV. Note que em (a) temos um pulso de polaridade positiva, aplicando o método de máxima amplitude, ele seria identificado como positivo, mas se usarmos o segundo método, o primeiro cruzamento de LD é negativo e o pulso seria erroneamente identificado como tal. Um pulso positivo similar é apresentado em (b), mas neste caso ambos os métodos identificariam corretamente sua polaridade. No caso em (c) o pulso é negativo, mas seria identificado como positivo pelos dois métodos. O mesmo acontece para o pulso da Figura 7.1(d), mas neste caso o mesmo é positivo e seria classificado como negativo. Em (e) vemos um pulso positivo simples de ser identificado por parte de quaisquer métodos. No último exemplo, mostrado em (f), temos um pulso negativo que seria classificado de forma correta pelo primeiro método, mas incorreta pelo segundo.

Portanto, a tarefa de identificar a polaridade dos pulsos nem sempre é simples e pode apresentar erros que geram confusão no diagnóstico do equipamento avaliado, principalmente quando a medição é afetada por ruído que distorce a forma de onda do pulso que chega ao *hardware* de aquisição.

Propomos uma combinação destes métodos anteriores para obter uma maior precisão na identificação da polaridade dos pulsos. Além disso, usamos o conceito de correlação para ajudar a determinar a polaridade do pulso avaliado (seja este proveniente de DP ou não). A seguir, descrevemos o algoritmo de correção de polaridade, baseado no método CBWS [29] usado na busca da função wavelet:

1. Estipular um pulso padrão de polaridade positiva. Neste trabalho simulamos um pulso Exponencialmente Amortecido (*Exponential Damped* - ED) [35] dado por:

$$Pulso_{padrao} = 1 \times (e^{-10^6 t} - e^{-10^7 t}), \quad (7.1)$$

usamos uma frequência de amostragem de 60 MHz com um total de 1024

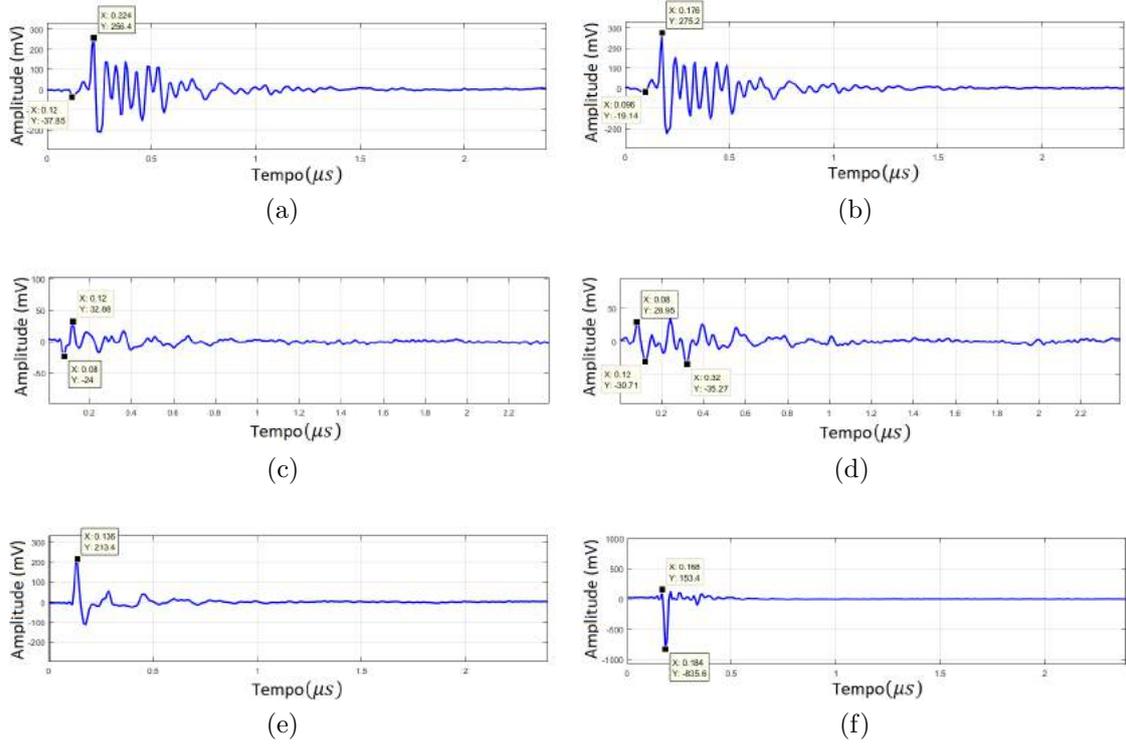


Figura 7.1: Exemplos de pulsos de DP.

amostras. Também é possível aplicar qualquer outro pulso padrão representativo de DP, seja simulado por outras equações ou adquirido na medição do equipamento avaliado, sendo necessário apenas que este seja de polaridade positiva;

2. Definido o pulso padrão ($Pulso_{padrao}$) e tendo o pulso medido ($Pulso_{medido}$) que se deseja encontrar a polaridade, deve-se centralizar ambos para que fiquem em torno do eixo das abcissas (basta subtrair cada pulso de sua própria média). Os pulsos também precisam ser normalizados para ter mesma amplitude máxima absoluta (podendo ser unitária) e o mesmo número de amostras do pulso medido. Deste modo, são obtidos o que podemos denominar de pulso padrão normalizado ($Pulso_{padrao_N}$) e pulso padrão medido normalizado ($Pulso_{medido_N}$);
3. Usando a ideia empregada no segundo método, também é usado um valor de limiar proporcional ao LD clássico. No entanto, deve-se obedecer uma heurística em que o valor de limiar (LD_{new}) é ajustado de acordo com a amplitude máxima do pulso medido, como a seguir:

$$LD_{new} = \begin{cases} \alpha \times \frac{LD}{\max(|Pulso_{medido}|)} & \text{se } \max(|Pulso_{medido}|) < (6 \times LD) \\ 0.25 \times \max(|Pulso_{medido_N}|) & \text{caso contrário} \end{cases}, \quad (7.2)$$

onde α é uma constante de proporcionalidade (optamos por usar $\alpha = 1$). A divisão do LD pela máxima amplitude absoluta do pulso medido ($Pulso_{medido}$) é necessária para normalizá-lo. Este procedimento evita que pulsos de amplitude muito alta sejam classificados erroneamente, como acontece para o exemplo mostrado na Figura 7.1(f), em que um pulso negativo de amplitude máxima elevada (-835 mV) e com oscilação positiva (135 mV) superior ao valor de LD usado (30 mV) acaba sendo identificado como um pulso positivo;

4. Os pulsos padrão e medido devem ser alinhados de acordo com o valor de amplitude máxima ou de cruzamento do valor de LD_{new} . Para tanto, é necessário encontrar os índices das amostras de máxima amplitude absoluta do pulso padrão (Ip_{max}) e do pulso medido (Im_{max}), além do índice da amostra onde ocorre o primeiro cruzamento de LD_{new} ($Ic_{LD_{new}}$). A regra a seguir define o índice por onde será feito o alinhamento:

$$I_{deslocamento} = \begin{cases} Im_{max} & \text{se não existe } Ic_{LD_{new}} \\ \begin{cases} Ic_{LD_{new}} & \text{se } \left| \frac{Pulso_{medido}(Ic_{LD_{new}})}{\max(|Pulso_{medido_N}|)} \right| \geq r_{min} \\ Im_{max} & \text{caso contrário} \end{cases} & \text{se existe } Ic_{LD_{new}} \end{cases}, \quad (7.3)$$

onde r_{min} corresponde a uma constante denominada relação mínima, a qual indicamos que não seja superior a 10% (em nossas avaliações usamos $r_{min} = 2.5\%$). Portanto, existindo $Ic_{LD_{new}}$, só o atribuiremos ao índice de deslocamento ($I_{deslocamento}$) se a relação entre a amplitude da amostra do pulso nesse cruzamento e o seu valor de máximo absoluto não for muito pequena, i.e., se for maior ou igual a r_{min} . Esta medida ajuda a evitar problemas com pulsos mais lentos, nos quais a amostra do primeiro cruzamento de $Ic_{LD_{new}}$ costuma ocorrer muito antes da amostra de amplitude máxima absoluta, como acontece no pulso mostrado na Figura 7.1(d);

5. Buscar o índice de cruzamento por zero do sinal padrão (Ip_{ncross}). Já para o sinal medido deve-se procurar pelo n -ésimo índice de cruzamento por zero (Im_{ncross}) e não pelo primeiro cruzamento por zero, o que faz com que seja considerada uma quantidade maior de amostras do pulso na etapa de verificação do coeficiente de correlação, contribuindo com uma identificação mais precisa da polaridade deste pulso. Em nossas análises aplicamos um número de cruzamentos $n_{cross} = 10$ e indicamos que seu valor esteja entre 4 e 10. Para o pulso padrão, essa busca pode ser feita incrementando-se amostra por amostra a partir do valor de máximo absoluto do pulso, até que atinja um valor igual zero ou ocorra uma mudança no valor da amplitude (de positivo para

negativo ou vice e versa); já para o pulso medido iniciar a partir do $I_{deslocamento}$ calculado no item 4;

6. Calcular a seguinte variação de tempo (em amostras) do pulso padrão (Δtp) e do pulso medido (Δtm) :

$$\Delta tp = |Ip_{n_{cross}} - Ip_{max}|, \quad (7.4)$$

$$\Delta tm = |Im_{n_{cross}} - Im_{max}|. \quad (7.5)$$

7. Usando os valores de variação de tempo calculados no item 6, mudar a escala de tempo do pulso padrão ou do pulso medido. Se o valor de variação Δtp for maior ou igual ao valor de variação Δtm , reamostrar uniformemente o pulso medido na taxa $\Delta tm/\Delta tp$, caso contrário, reamostrar o pulso padrão na taxa $\Delta tp/\Delta tm$; Isso fará com que o índice da amostra de cruzamento por zero do pulso padrão coincida com o n -ésimo índice de cruzamento por zero do sinal medido. Esta medida é necessária para que se leve em conta uma maior quantidade de oscilações (cruzamentos por zero) do pulso medido, a fim de que ocorra uma melhor precisão na etapa de cálculo do coeficiente de correlação dos pulsos;
8. Alinhar o índice de máxima amplitude absoluta do pulso padrão com o índice $I_{deslocamento}$ calculado no item 4 para o pulso medido. É possível que nas etapas de reamostragem os pulsos padrão e medido fiquem com número de amostras diferentes, e com isso é preciso preencher com zeros um destes sinais para que ambos tenham o mesmo tamanho;
9. Calcular o coeficiente de correlação ($CC_{p,m}$) entre os pulsos padrão e medidos já normalizados, reamostrados e alinhados;
10. Identificar a polaridade do pulso avaliado de acordo com a seguinte regra

$$polaridade = \begin{cases} +1 & \text{se } CC_{p,m} \geq 0 \\ -1 & \text{caso contrário} \end{cases}, \quad (7.6)$$

ou seja, se o coeficiente de correlação for positivo a polaridade do pulso analisado será designada como positiva, caso contrário será negativa.

A Figura 7.2 ilustra a ideia por traz do novo algoritmo de identificação da polaridade de um pulso de DP (janelado com 300 amostras). Neste caso, temos um pulso negativo, o qual foi extraído do mapa PRPD mostrado na Figura 6.3(a). Para este exemplo, o coeficiente de correlação calculado foi de $CC_{p,m} = -0.3580$, consequen-

temente o pulso foi identificado como de polaridade negativa ($polaridade = -1$).

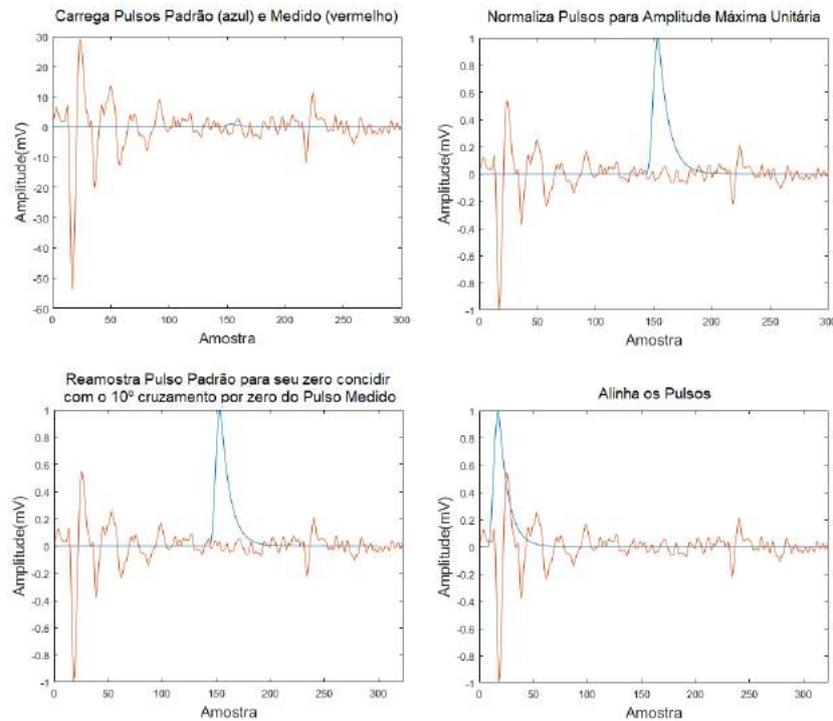


Figura 7.2: Processo de identificação de polaridade de um pulso de DP.

Na Figura 7.3 mostramos o efeito obtido no mapa PRPD final quando aplicamos o novo algoritmo de identificação de polaridade. A medição utilizada é a mesma da Figura 6.3 (a), mostrada novamente na Figura 7.3(a) para uma melhor comparação. O mapa resultante do novo algoritmo é mostrado na Figura 7.3(b), neste caso os pulsos anteriormente identificados como negativos agora são tidos como positivos e também temos um mapa mais “limpo”.

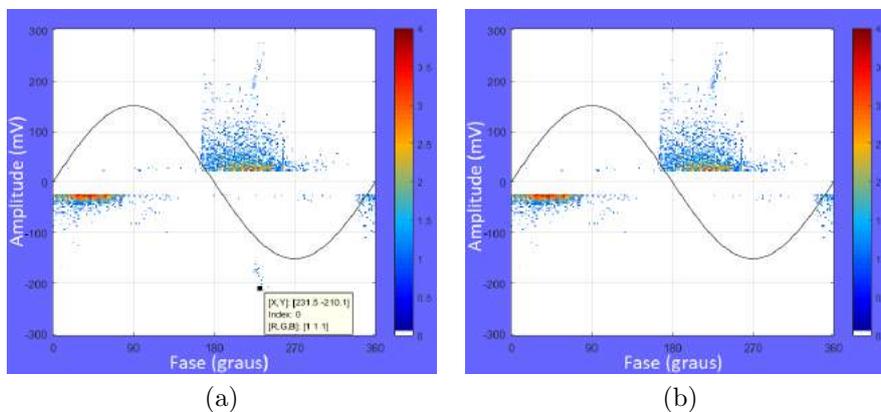


Figura 7.3: Histograma PRPD: (a) usando o método tradicional de identificação de polaridade; (b) usando o novo método de identificação de polaridade.

É exibido na Figura 7.3 a identificação correta da polaridade dos pulsos, por meio do método proposto, onde ilustramos a forma de onda correspondente ao pulso selecionado (ponto em preto). Já na Figura 7.3(a), o erro de designação na polaridade do pulso foi causado pelo fato de haver uma oscilação negativa, anterior ao pico, com amplitude de -37.85 mV, a qual ultrapassa o valor de LD inferior especificado na medição (neste caso ± 25 mV). Outra observação a ser feita é que este pulso aparece no mapa da Figura 6.3(a) com seu valor de mínima amplitude 210.1 mV, pois foi definido como um pulso negativo. Desta maneira, ao ter a polaridade corrigida pelo nosso algoritmo, o pulso será representado no mapa PRPD pelo seu valor de máximo (neste caso 256.4 mV).

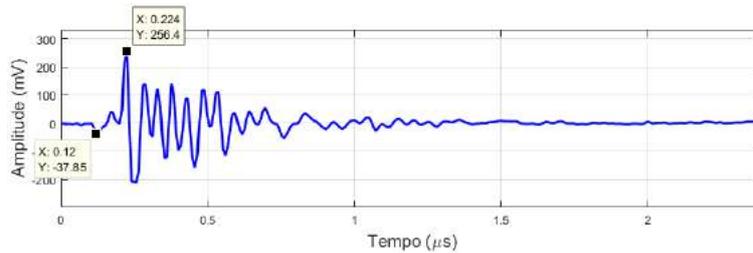


Figura 7.4: Pulso de DP identificado como pulso negativo pelo segundo método.

7.2 Estimativa da Resposta em Frequência do Sistema de Medição a partir dos Pulsos de Descargas Parciais

A ideia de estimar a resposta em frequência (RF) do sistema de medição (incluindo o equipamento avaliado) de DP a partir dos pulsos detectados vem do uso combinado de um analisador de espectro e de um gerador de sinal para determinar a RF de um circuito. Em geral, é preferível aplicar um gerador de varredura para este tipo de análise de uma rede escalar, uma vez que este tem sua frequência central em sincronia com a do filtro Passa Banda (PB) de um analisador de espectro. No entanto, é possível usar um gerador de sinal para percorrer uma faixa de frequência desejada e obter medidas de amplitude versus frequência semelhantes [188].

Como a sincronização entre o gerador e o analisador não pode ser garantida, o método de varredura é desejável somente para analisar redes que não variam significativamente com o tempo, ou seja, deve-se considerar que estamos lidando com um Sistema Linear Invariante no Tempo (SLIT), condição que pode ser considerada verdadeira pelo curto período de tempo necessário para obter os dados de DP nos vários tipos de equipamentos de alta tensão.

A Figura 7.5 mostra a RF de um filtro PB na utilização do analisador de espectro em conjunto com o gerador de sinais para varredura de frequência. Usando o modo de retenção de máxima amplitude (*Max Hold*) do analisador de espectro é possível verificar a informação de amplitude em todos os pontos de frequência, principalmente nas frequências relevantes (banda passante e ressonâncias).

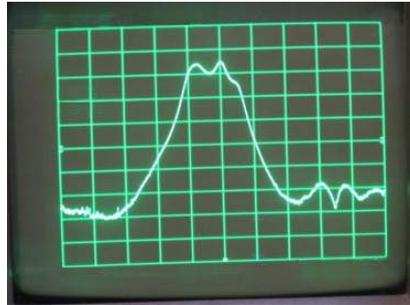


Figura 7.5: Exemplo de rastreamento da resposta em frequência usando um analisador de espectro na função e um gerador de funções para realizar a varredura de frequência. *Max Hold*. Fonte: [189]

Portanto, podemos explorar essa técnica em nosso benefício. Sabemos *a priori* que os pulsos capturados numa medição de DP cobrem uma ampla faixa de frequência [4]. Logo, estes pulsos podem cumprir o mesmo papel do gerador de sinais. Embora não seja identificada a real amplitude dos pulsos na entrada do sistema (descarga no ponto de defeito no interior do equipamento), ainda conseguimos uma boa precisão no domínio da frequência. Para contornar o problema da amplitude, é plausível assumir uma relação normalizada de acordo com a máxima magnitude do pulso na saída do sistema (descarga medida), ou seja, assume-se que o valor de pico do sinal de entrada será o mesmo do sinal medido.

Recorrendo à teoria de sistemas lineares, temos que um sistema no tempo contínuo é definido matematicamente como uma transformação que mapeia um sinal de entrada (excitação) com valor $x(t)$ em um sinal de saída (resposta) com valor $y(t)$, isto é:

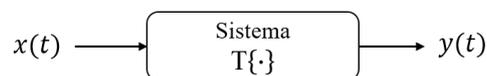


Figura 7.6: Representação de um sistema no tempo contínuo.

$$y(t) = T \{x(t)\}. \quad (7.7)$$

A mesma analogia é válida para sistemas de tempo discreto, assim:

$$y[n] = T\{x[n]\}. \quad (7.8)$$

Assumimos que, durante a janela de tempo de uma medição, o sistema avaliado é aproximadamente SLIT, isto é, respeita as propriedades de aditividade e homogeneidade (condições para a linearidade) e sua saída depende unicamente da entrada e não do instante de tempo em que é aplicada (condições para a invariância no tempo). Então, pode-se representar a resposta deste sistema $T\{\cdot\}$ por sua resposta ao impulso num instante k :

$$h_k[n] = T\{\delta[n-k]\} = h[n-k]. \quad (7.9)$$

Se a entrada $x[n]$ é representada por um somatório de impulsos

$$x[n] = \sum_{k=-\infty}^{+\infty} x[k] \delta[n-k], \quad (7.10)$$

então, de acordo com as Equações 7.8 e 7.9, a saída será:

$$y[n] = T\left\{\sum_{k=-\infty}^{+\infty} x[k] \delta[n-k]\right\} = \sum_{k=-\infty}^{+\infty} x[k] h[n-k]. \quad (7.11)$$

Num SLIT, conhecida a resposta ao impulso $h[n]$, é possível calcular a resposta a qualquer sinal de entrada, através do somatório das convoluções, ou seja,

$$y[n] = x[n] * h[n] = \sum_{k=-\infty}^{+\infty} x[k] h[n-k]. \quad (7.12)$$

Se considerarmos que um sinal de entrada de um SLIT é uma sequência de funções exponenciais complexas (senoides) $x[n] = e^{j\omega n}$, então a saída é:

$$y[n] = \sum_{k=-\infty}^{+\infty} h[k] e^{j\omega(n-k)} = e^{j\omega n} \sum_{k=-\infty}^{+\infty} h[k] e^{-j\omega k}. \quad (7.13)$$

Aqui temos o produto da entrada com outra função somente de ω (ou de $e^{j\omega}$) de período 2π :

$$H(e^{j\omega}) = \sum_{k=-\infty}^{+\infty} h[k] e^{-j\omega k} = |H(e^{j\omega})| e^{j\angle H(e^{j\omega})}. \quad (7.14)$$

A função $H(e^{j\omega})$ nada mais é do que a função transferência do sistema, através da qual a exponencial de entrada é escalada e transladada por $|H(e^{j\omega})|$ e $\angle H(e^{j\omega})$.

A definição da transformada de Fourier de uma sequência $x[n]$ é dada por

$$X(e^{j\omega}) = \sum_{n=-\infty}^{+\infty} x[n] e^{-j\omega n}, \quad (7.15)$$

contanto que $x[n]$ seja absolutamente somável, i.e., estável: $\sum_{n=-\infty}^{+\infty} |x[n]| < \infty$, a sequência pode ser reconstruída a partir da sua transformada:

$$x[n] = \frac{1}{2\pi} \int_{-\pi}^{\pi} X(e^{j\omega}) e^{-j\omega n} d\omega. \quad (7.16)$$

Conclui-se que a resposta em frequência é a transformada de Fourier da resposta impulsiva.

A partir deste conceito, podemos estimar a resposta em frequência do sistema medido. Pulsos de DP correspondem a impulsos (escalados) de frequência variada dentro da banda de medição, portanto, podemos estimar a RF $H(e^{j\omega})$ do sistema de medição com uma quantidade considerável destes impulsos cobrindo tal banda de interesse. O algoritmo necessário para estimar a RF é descrito a seguir:

1. De posse do pulso de DP $y[n]$ (saída do sistema), amostrado no tempo pelo *hardware* de aquisição, encontrar a TF Discreta (*Discrete Fourier Transform* - DFT) deste pulso $Y(e^{j\omega})$;
2. Armazenar o vetor calculado anteriormente numa matriz **dft**;
3. Repetir as etapas de 1 a 2 até que todos os pulsos detectados tenham sido processados;
4. Obter o valor de pico máximo $DFT_{max} = \max(|Y(e^{j\omega})|)$, se desejado podem ser calculados os valores da média $DFT_{mean} = \text{mean}(|Y(e^{j\omega})|)$ e do mínimo $DFT_{min} = \min(|Y(e^{j\omega})|)$;
5. Obter a resposta em frequência estimada $H'(e^{j\omega})$ para o sistema numa banda de frequência limitada pela frequência de amostragem do *hardware* usado na

medição:

$$H' (e^{j\omega}) = \max (DFT_{max}); \quad (7.17)$$

6. Normalizar $H' (e^{j\omega})$ pelo seu valor de pico, i.e.,

$$H'_N (e^{j\omega}) = H' (e^{j\omega}) / \max(H' (e^{j\omega})); \quad (7.18)$$

7. Para gerar o gráfico da RF estimada é desejável que seu módulo seja convertido para dB e o eixo de frequência apresentado em escala logarítmica.

Na Figura 7.7(a) ocorre a sobreposição de todos os pulsos detectados durante uma medição de DP. Note que a cada novo pulso novos máximos em frequências variadas podem surgir e a proposta do algoritmo é guardar cada novo máximo que surge na banda de frequência avaliada para, ao final do processamento de todos os pulsos, formar a RF estimada. Além dos valores máximos, também é possível observar os valores mínimos e médios para se avaliar a variação da DFT de cada pulso, conforme indicado na Figura 7.7(b).

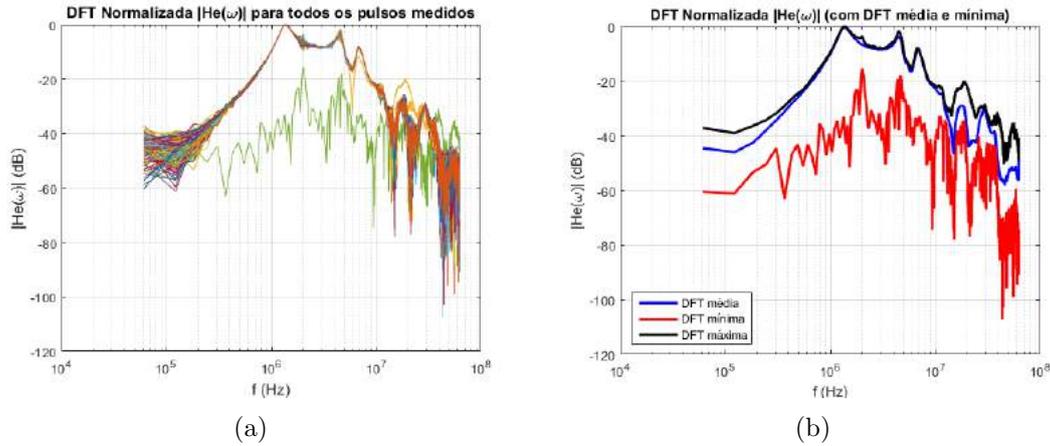


Figura 7.7: (a) DFT Normalizada de todos os pulsos detectados; (b) DFT normalizada para a retenção de máximo (RF estimada), retenção de mínimo e média.

Num processo de separação por classes de padrões de defeitos provocados por DP, a estimativa da RF pode ser útil para identificar pulsos mal classificados. Observe que na Figura 7.7(a) as DFTs dos pulsos estão próximas da DFT estimada pelos valores máximos, enquanto que a DFT estimada pelos valores mínimos está bem distante e apresenta formato diferente das demais, indicando que provavelmente o pulso que gerou a DFT com os valores mínimos seja de um padrão distinto e, portanto, deveria ser atribuído a outra classe.

Considerando a Equação 7.12 que representa o SLIT no problema, percebe-se que a saída $y[n]$ é o pulso de DP adquirido. Já a resposta ao impulso $h[n]$ equivale à DFT inversa da resposta em frequência $H(e^{j\omega})$, que por sua vez pode ser considerada próxima da resposta em frequência estimada $H'_N(e^{j\omega})$. Conseqüentemente, é possível estimar o pulso de entrada $x[n]$ (que ocorre no interior do equipamento) do sistema reescrevendo a Equação 7.12 da seguinte forma:

$$x'[n] = \frac{1}{h(0)} \left(y[n] - \sum_{k=0}^{n-1} x[k] h[n-k] \right), \text{ para } h(0) \neq 0 \xleftrightarrow{DFT} X'(e^{j\omega}) = \frac{Y(e^{j\omega})}{H'_N(e^{j\omega})}. \quad (7.19)$$

Nesse caso, encontrar a estimativa do sinal de entrada $x'[n]$ corresponde à resolução de uma divisão polinomial, ou seja, à deconvolução de $y[n]$ por $h'[n]$. A resposta ao impulso estimada pode ser extraída com o uso de um método dos mínimos quadrados para encontrar um filtro recursivo (IIR) [172] de N -ésima ordem que se aproxima da resposta em frequência $H'_N(e^{j\omega})$.

Conforme mencionado anteriormente, desejamos normalizar a amplitude de pico do sinal de entrada estimado, de acordo com a amplitude de pico do sinal adquirido. Para tanto, basta fazer:

$$x'_N[n] = \frac{x'[n]}{\max(x'[n])} \times \max(y[n]). \quad (7.20)$$

Conhecer a estimativa do pulso em sua origem pode ser útil para encontrar uma medida mais precisa da carga deste pulso em pC , a qual é digitalmente calculada, integrando-se o pulso de saída $y[n]$ adquirido (analogicamente o mais adequado seria utilizar um circuito detector de envoltória do pulso) [4],[99]. Outra aplicação possível seria utilizar $x'_N[n]$ como sinal de entrada para o algoritmo de detecção de polaridade, pois já que o pulso estimado tende a ser uma melhor representação do verdadeiro pulso que ocorre no interior do equipamento, é de se esperar que este também represente melhor as características de polaridade.

Em contrapartida, antes de utilizar o pulso estimado, é preciso saber o quão bem a RF estimada está representando o sistema de medição. A primeira exigência é que $H'_N(e^{j\omega})$ tenha sido estimada para uma quantidade considerável de pulsos, de modo a aumentar a precisão da estimativa; a segunda é que como podem existir diversos padrões de pulsos ou interferências, os quais provavelmente terão amplitude e componentes de frequência em bandas distintas, é adequado que cada padrão seja isolado em seu grupo correspondente (separação em classes), a fim de que possamos

extrair diferentes respostas em frequência mais precisas para cada padrão de defeito ou ruído, ao invés de estimar uma única RF que pode não representar bem todos os padrões de pulsos, principalmente se a quantidade de pulsos de cada padrão não estiver equilibrada.

Uma forma trivial de verificar a efetividade da RF obtida é usar cada pulso $x'_N[n]$ como entrada do sistema para, assim, obter o sinal de saída “estimado” e, então, compará-lo com pulso correspondente detectado. Se $H'_N(e^{j\omega})$ e $x'_N[n]$ são uma boa representação da RF real do sistema e do pulso real na origem, o sinal obtido pela convolução $y'_N[n] = x'_N[n] * h'_N[n]$ deve ser o mais próximo possível do pulso medido $y[n]$. Para comparar a semelhança entre dois sinais podemos usar o coeficiente de correlação de Pearson, assim como foi feito para o algoritmo NACF descrito na Seção 6.1. Um cuidado que se deve ter é garantir que $y[n]$ e $y'_N[n]$ estejam normalizados pela amplitude de pico e que estejam alinhados de forma a fornecer o maior valor de correlação possível. O cálculo é realizado para todos os pulsos contidos na mesma classe. E, por fim, a média dos coeficientes calculados (em valor absoluto) pode ser considerada como indicador numérico da efetividade da qualidade da RF estimada. Assim, quanto mais próximo de 1 estiver o indicador, melhor será a nossa estimativa.

A Figura 7.8 ilustra um exemplo de um sinal de entrada reconstruído a partir da RF estimada com os pulsos adquiridos de uma medição real. Na Figura 7.8(a) é mostrada a RF estimada e normalizada $H'_N(e^{j\omega})$ junto com um sinal $x'_N[n]$ estimado a partir de seu pulso correspondente de saída $y[n]$ usando a Equação 7.19. Na Figura 7.8(b) é mostrado o sinal $x'_N[n]$ ampliado, o sinal de saída estimado $y'_N[n]$ visto na Figura 7.8(c) possui quantidade de amostras dada pela convolução de $x'_N[n] * h'_N[n]$. Para obter o sinal com o mesmo número de amostras do pulso $y[n]$ basta truncar o sinal até o número de amostras $y[n]$. O sinal de saída medido (vermelho) e o sinal de saída estimado (alinhados pelo pico máximo absoluto) são mostrados na Figura 7.8(d). Neste caso, os sinais são bem próximos, com coeficiente de correlação de 0.9621, o qual indica que a RF estimada esta representando bem o sistema no eixo da frequência.

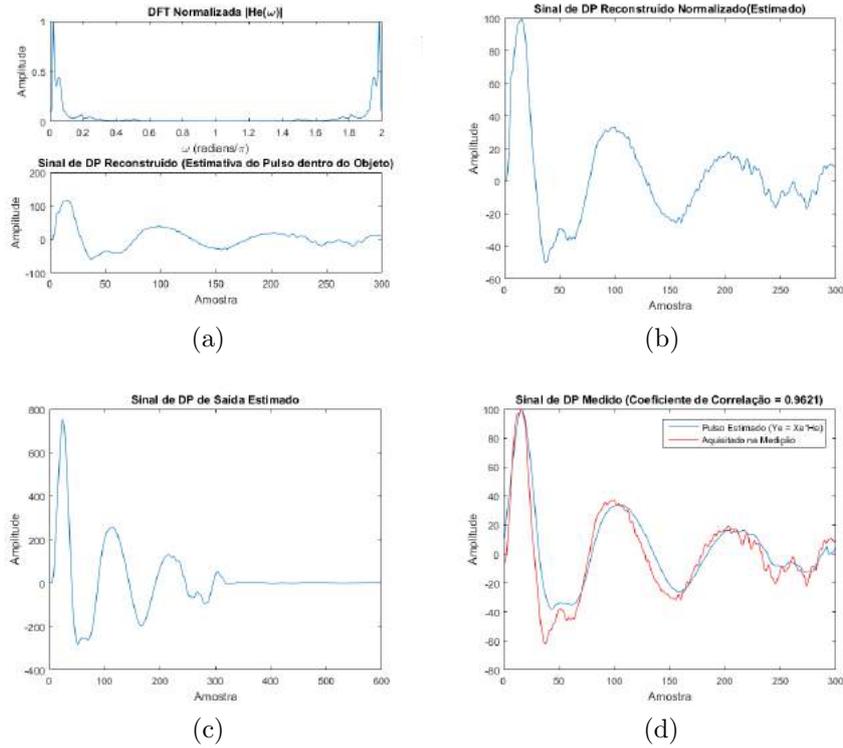


Figura 7.8: Processo de reconstrução do sinal de DP a partir da RF estimada: (a) RF estimada e normalizada $H'_N(e^{j\omega})$ com um exemplo de sinal de DP estimado $x'_N[n]$; (b) sinal de DP estimado normalizado $x'_N[n]$ (ampliado); (c) sinal de DP de saída $y'[n]$ estimado a partir da convolução $x'_N[n] * h'_N[n]$; (d) comparação entre o sinal de saída estimado $y'[n]$ com o sinal de saída aquisitado $y[n]$ (coeficiente de correlação de 0.9621).

Outro exemplo é mostrado na Figura 7.9 para um pulso que tem um padrão distinto dos demais pulsos detectados numa medição, ou seja, um pulso com pouca representatividade em relação aos demais na formação da RF estimada. Veja que a correlação de 0.0334 entre o pulso de saída estimado e o pulso de saída aquisitado é baixa. Não obstante é configurado um sinal que se aproxima de uma envoltória do pulso real.

Estimativas insatisfatórias podem ter como causa principal uma quantidade pouco representativa de um dado padrão de pulsos, e diante da impossibilidade de melhorar, devemos desconsiderar a estimativa para análise e diagnóstico do equipamento ou mesmo reagrupar os padrões diferentes para tentar obter uma melhor precisão.

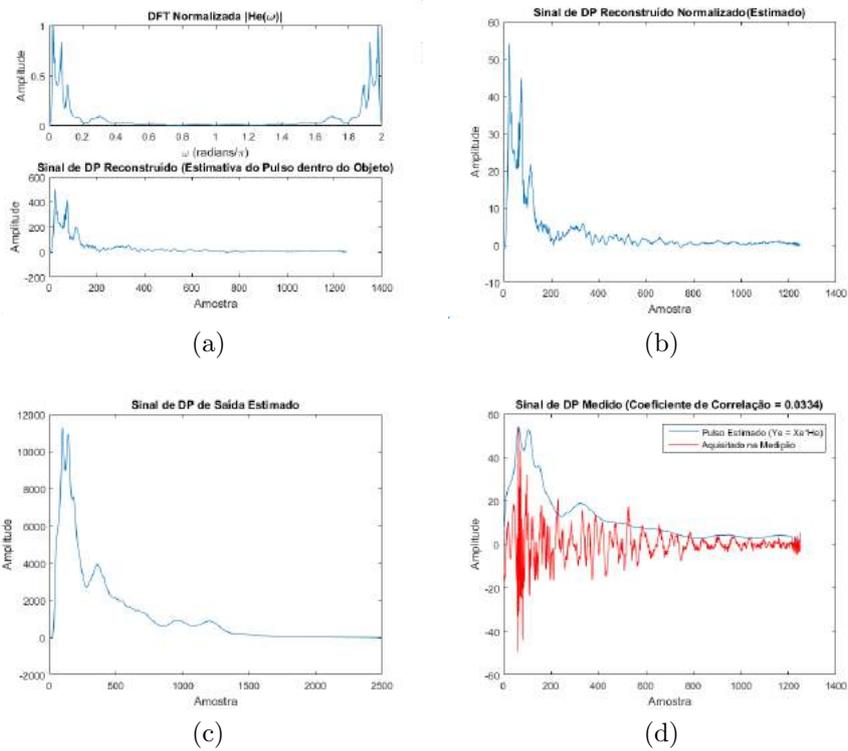


Figura 7.9: Processo de reconstrução do sinal de DP: (a) RF estimada e normalizada $H'_N(e^{j\omega})$ com um exemplo de sinal de DP estimado normalizado $x'_N[n]$; (b) sinal de DP estimado $x'_N[n]$ (ampliado); (c) sinal de DP de saída $y'_[n]$ estimado a partir da convolução $x'_N[n] * h'_N[n]$; (d) comparação entre o sinal de saída estimado $y'_[n]$ com o sinal de saída adquirido $y[n]$ (coeficiente de correlação de 0.0334).

7.3 Estrutura de Processamento do Sistema de Análise de Descargas Parciais

A figura 7.10 mostra o fluxograma do sistema desenvolvido para permitir a análise dos dados de medições de DP.

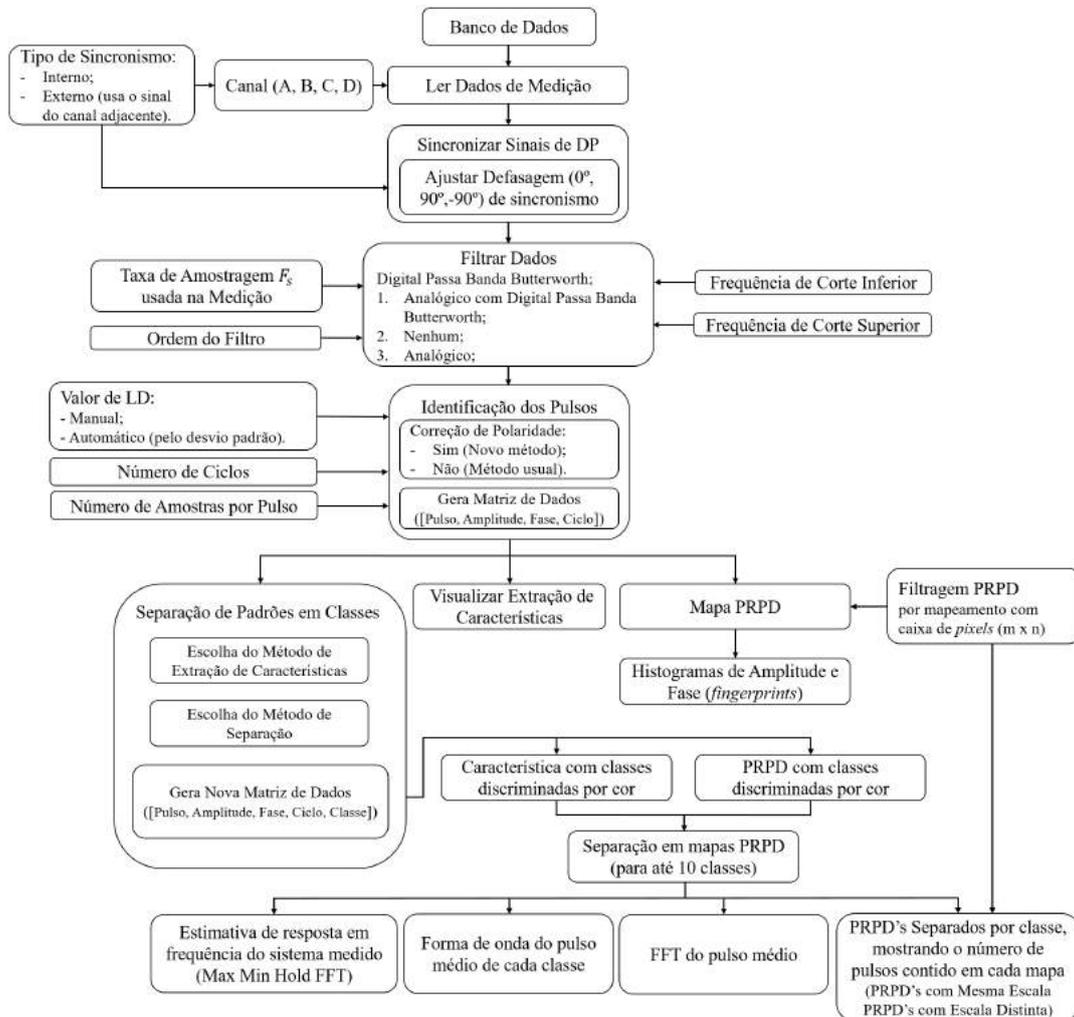


Figura 7.10: Estrutura de processamento do sistema de análise e separação de dados de DP.

O foco do sistema de análise é na separação dos padrões de DP existentes numa medição feita *a priori* por um sistema de aquisição de dados de descargas, o qual foi descrito na tese [40]. Portanto, inicialmente é necessário dispor do arquivo de DP medido, podendo este ser armazenado em um banco de dados. O arquivo de dados deverá conter a forma de onda original detectada através do circuito de medição (impedância, transformadores de corrente de alta frequência, bobina de Rogowski, antena, sensores indutivos, etc. [35]) em ciclos da frequência fundamental de operação do equipamento de alta tensão (um número mínimo de 30 ciclos é recomendado para

formar um conjunto representativo de pulsos). Juntamente com os sinais de DP, é requerido que a forma de onda medida contenha uma referência atenuada da tensão de alimentação AC, para posterior sincronismo do mapa PRPD. Tal referência e o sinal de DP poderão ser detectados pelo mesmo canal (Sincronismo Interno) ou em canais distintos (Sincronismo Externo) do *hardware* de aquisição (osciloscópio). A definição das características mínimas do *hardware* adequado dependerá da banda de medição que se deseja avaliar. Em nosso caso, optamos por um aquisitor com frequência de amostragem de até 125 MHz e resolução de 14 bits para uma faixa dinâmica de 20 V (-10 V até +10 V) em dois canais, sendo capaz de operar com tranquilidade na banda de Alta Frequência (High Frequency - HF) descrita pela norma técnica IEC 60034-27-2 [189] (entre 3 e 30 MHz).

Essencialmente, para consolidação dos dados medidos em um mapa PRPD, um sistema de medição de DP deverá registrar, para cada pulso: sua amplitude, o instante ou o ângulo de fase de sua ocorrência em relação à tensão aplicada, e o valor desta tensão AC naquele instante. Em [40] foi descrito o algoritmo necessário para identificar os pulsos por cruzamento de nível (*LD*), o qual foi empregado em nosso sistema. Ainda foi necessário acrescentar à rotina do algoritmo uma etapa que armazenasse, em memória, as formas de onda de cada pulso detectado, já que a nossa intenção é usar a forma de onda do pulso para realizar uma análise pulso a pulso e fazer a extração de características que permitam sua diferenciação em classes distintas.

É importante salientar que em algumas análises de DP a medição é feita com circuitos que geram defasagem do sinal de tensão AC de referência, medido em relação à tensão aplicada sobre o equipamento testado. Portanto, para não haver erros na construção do PRPD, o sistema permite ao usuário setar a compensação de fase por 90° ($+90^\circ$ para a medição usual pela impedância Z_m e -90° para a medição conjunta com filtro analógico).

Após carregar o dado de DP, um estágio de pré-processamento que compreende a sincronização do sinal, remoção de ruídos harmônicos, a filtragem passa banda para a faixa de HF desejada (normalmente 1MHz - 30MHz). Esta etapa remove ruído de baixa frequência, ruído fora da banda de medição desejada e algumas das interferências de espectro discreto como sinais de telecomunicações. Logo, a filtragem assume um papel importante para o tratamento adequado de ruído, para assim assegurar a efetividade do algoritmo de identificação de pulsos por cruzamento de *LD*.

Na fase de detecção de pulsos, para cada ciclo é feita uma varredura com uma janela de amostras de tamanho definido pelo usuário, em que é verificado se o pico de

amplitude do sinal nesta janela é maior que o valor de LD . Este valor de LD pode ser especificado manualmente ou calculado automaticamente com base numa relação de sete vezes o desvio padrão de todo o sinal de DP filtrado. Sendo o sinal janelado superior ao LD , ele é então registrado como um pulso e, em seguida, é verificada a sua polaridade ou pelo 2º método ou pelo método proposto (descritos na Seção 5.3). Se o pulso for designado como positivo, seu valor de amplitude máxima é armazenado, caso contrário seu valor de amplitude mínima é que será armazenado. Após a leitura de toda a quantidade de ciclos especificada pelo usuário, é obtida a Matriz de Dados, composta pela forma de onda de cada pulso detectado (comprimento do sinal igual ao número de amostras por pulso), sua amplitude, seu índice de ocorrência (Fase) e o ciclo em que o pulso ocorreu.

É a partir da Matriz de Dados que se torna possível extrair todas as informações desejadas, como: PRPD; histogramas de amplitude e fase (*fingerprints*); visualizar a extração de características; análise pulso a pulso; separação dos diferentes padrões de DP que possam existir; PRPD discriminado por cor; característica discriminada por cor; mapas PRPD separados por sua respectiva classe; pulso médio por classe; espectro de potência por classe; estimativa da resposta de frequência do sistema medido para cada classe; geração de relatório.

No Apêndice B é explicada mais detalhadamente cada etapa vista no fluxograma da Figura 7.10.

Por não ter sido verificada na literatura a aplicação da técnica de filtragem por caixa de *pixel* (usual da área de processamento de imagens) [172], esta é detalhada na seção que se segue.

7.4 Filtragem por caixa de *pixels*

Podemos aplicar ao PRPD uma técnica similar à utilizada em filtragem de imagens, a qual usa uma caixa de *pixels* para identificar pontos (*pixels*) de ruído. Esta técnica foi adaptada para lidar com os dados mostrados no mapa PRPD. O algoritmo de filtragem por caixa de *pixels* usa uma “caixa” de tamanho ($p_m \times p_n$), especificado pelo usuário, para varrer toda a matriz de pontos do gráfico PRPD (256×256). Durante a varredura é verificado se existe mais de um dado de descarga (*pixels* com valor maior que zero) presente na vizinhança abrangida pela “caixa”, e se houver o dado de descarga será mantido, caso contrário será igualado a zero (apaga o dado de DP do mapa PRPD).

Na Figura 7.11 é ilustrado o algoritmo de filtragem por caixa de *pixels*. Ao

final do algoritmo, os pontos de descargas muito esparsos serão eliminados e, assim, obtém-se um mapa mais limpo.

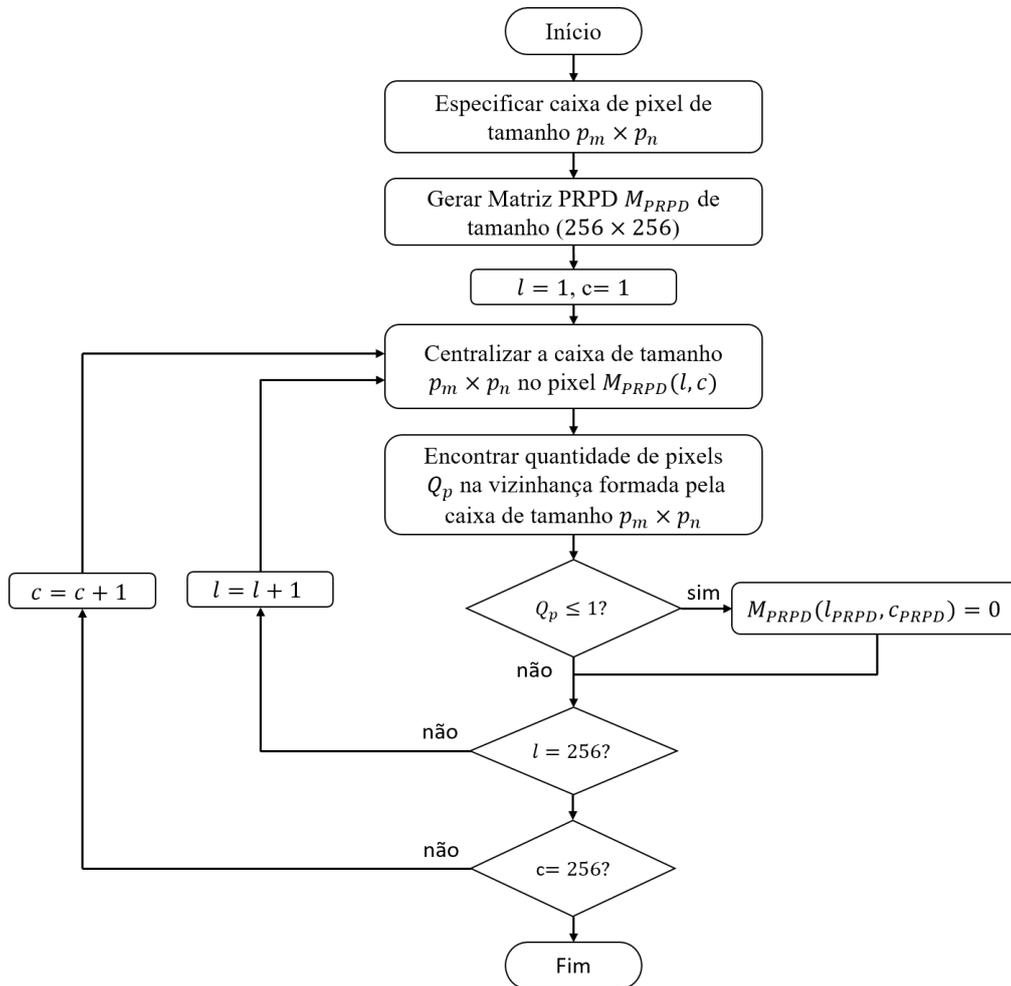


Figura 7.11: Fluxograma para algoritmo de filtragem por caixa de *pixels*.

Verifique o PRPD mostrado na Figura 7.12 que uma “caixa” com tamanho especificado pelos valores de p_m e p_n faz a varredura *pixel a pixel* da imagem do PRPD para verificar quais pulsos (pontos no mapa) podem ser eliminados.

Aplicando o algoritmo de filtragem por caixas de tamanhos variados no PRPD mostrado na Figura 7.11 pudemos obter os quatro mapas PRPD vistos na Figura 7.13. Nota-se que quanto menor a caixa, mais pontos poderão ser eliminados e mais claro se torna o mapa. Entretanto, é preciso ter cuidado, pois uma caixa muito pequena pode eliminar muitos pontos de pulsos. Portanto, indicamos não utilizar uma caixa com tamanho menor que 3×3 . A redução na quantidade de informação no PRPD proporcionada por este algoritmo poderia ser utilizada na implementação de um classificador por redes neurais, de modo a contribuir no aprendizado e no aumento da eficiência da rede.

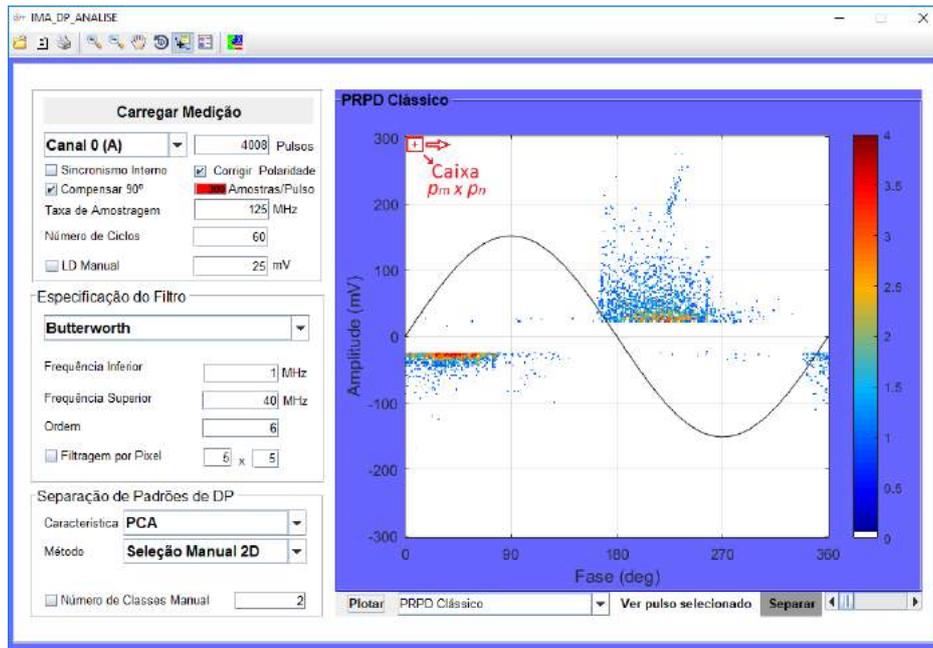


Figura 7.12: Ilustração do comportamento da filtragem por caixa de *pixel* em um PRPD Clássico obtido a partir de uma medição.

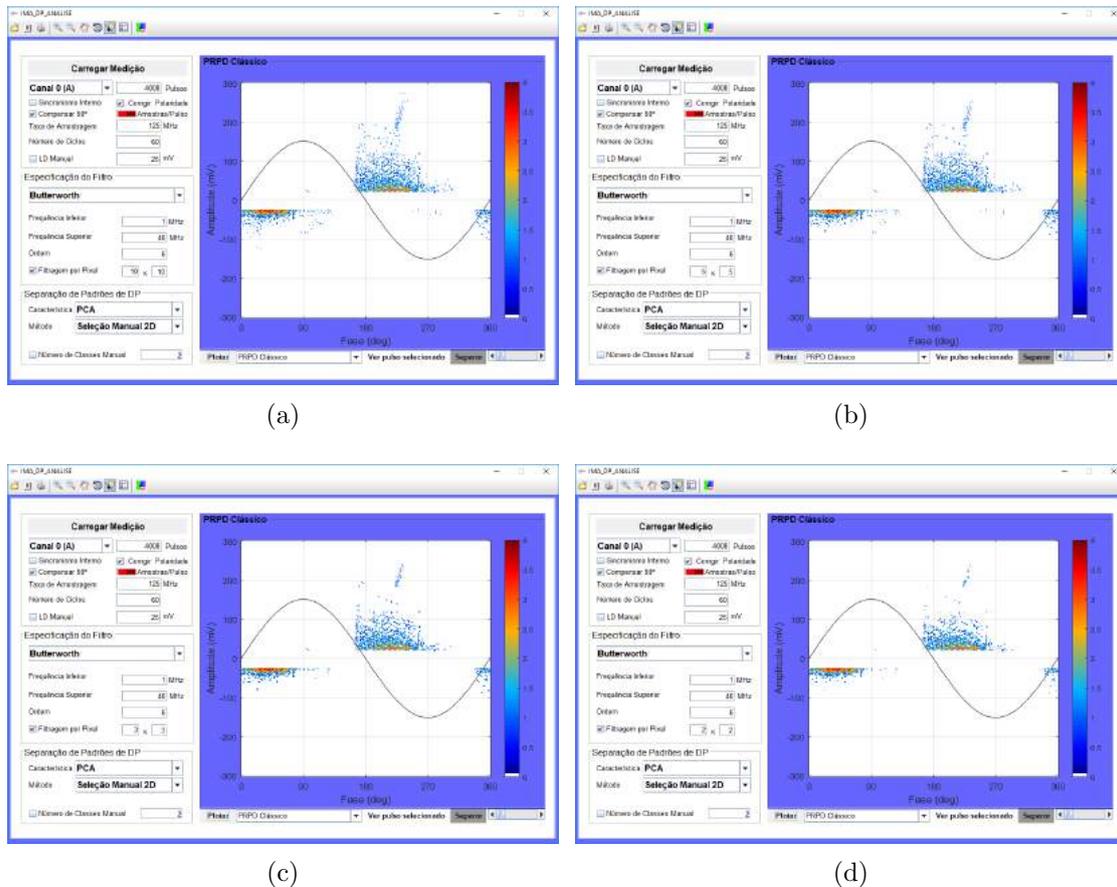


Figura 7.13: Mapas PRPD gerados após a filtragem por caixa de *pixels* com tamanho: (a) 10×10 ; (b) 5×5 ; (c) 3×3 ; (d) 2×2 .

Capítulo 8

Simulações e Avaliação dos Resultados

Neste capítulo inicialmente mostramos a etapa de criação de um banco de dados que inclui medições de DP feitas em diversos equipamentos de alta tensão diretamente no campo e em células de carga e barras estatóricas em laboratório, que simulam de forma controlada, algumas das fontes causadores do fenômeno em estudo. Conforme citado nos capítulos anteriores, dentre os equipamentos avaliados encontram-se disjuntores, geradores, geradores a diesel, Pararraios (PR), transformadores de potência, Transformadores de Corrente (TC), Transformadores de Potencial (TP) e GIS. Todas as medições foram realizadas seguindo as técnicas descritas em [35]. O banco obtido será importante para a avaliação das metodologias aqui propostas, bem como para pesquisas posteriores a este trabalho.

Em seguida, aplicaremos a função de limiarização Fleming e suas variações na redução do ruído presente em sinais de DP e, em complemento, avaliaremos diferentes combinações de funções Wavelet Mãe (WM) com a finalidade de identificar a mais apropriada no tratamento dos dados de DP (pulsos simulados e medidos dos equipamentos de alta tensão).

Mostraremos os resultados de performance obtidos com as modificações sugeridas para o método NACF usando as diferentes métricas de distância juntamente com o algoritmo de junção de classes por similaridade de seus pulsos centroides.

Finalizando, veremos os resultados gerados com o sistema de análise e separação de descargas parciais, dando maior ênfase no comparativo de performance dentre as diferentes combinações dos métodos de extração de características com os de agrupamento de dados e nas inovadoras técnicas de correção da polaridade atribuída aos pulsos na formação do histograma PRPD e de estimação da resposta em frequência

do sistema a partir dos pulsos identificados na medição do equipamento.

8.1 Banco de Dados Criado com Medições de Descargas Parciais

A formação de um banco de dados representativo dos defeitos típicos associados aos pulsos de DP de equipamentos de alta tensão é uma etapa necessária para a avaliação dos algoritmos de extração de características dos dados de DP, separação das diferentes fontes causadoras do fenômeno de DP, bem como do sistema de análise de DP desenvolvido neste trabalho.

O banco é composto por medições reais realizadas em campo, obtidas diretamente de equipamentos de alta tensão, como: hidrogeradores, geradores a diesel, turbo geradores, PR, TC, Disjuntores e GIS. Pelo fato das medições em campo serem esporádicas e demandarem muito tempo para formar um banco representativo, também tivemos de realizar medições em laboratório em células de carga construídas para simular os diferentes padrões de DP e barras estatísticas de geradores.

As células de carga, comumente descritas na literatura [42], [143], [156], [166], estão associadas fisicamente e quimicamente a uma ou mais partes de um equipamento, produzindo um padrão peculiar de pulsos de DP normalmente visto nas medições de DP em campo, dentre estes:

- descarga externa (Corona);
- descarga interna;
- descarga devido a partículas metálicas flutuantes;
- descarga em superfície;
- descarga no óleo isolante;
- descarga devido a partículas metálicas no terminal de terra;

Todas as células (confeccionadas no Cepel) foram construídas no formato cilíndrico com vidro, acrílico translúcido, fixadores de Policloreto de Vinila (PVC), anéis de vedação *O-ring* de borracha e terminais de cobre. As características construtivas básicas das células são mostradas no Apêndice C. Cada uma pode ser preenchida com óleo isolante ou gás SF_6 (que, por questões práticas, não foi utilizado neste trabalho). A distância entre o eletrodo de alta tensão e o de aterramento pode

ser ajustada, o que é útil para variarmos a tensão de injeção (valor de tensão em que as DP começam a ocorrer).

Experimentos também foram feitos utilizando as células de carga em configurações paralelas, conforme mostrado na Figura 8.1, o que produz padrões de PRPD contendo mais de uma fonte de DP simultaneamente. No entanto, cuidados foram tomados para que a tensão de injeção das células estivessem próximas umas das outras, de forma a não ocorrer curto circuito em nenhuma delas. Este dado nos permitirá avaliar, de maneira confiável, a performance dos métodos de separação e, futuramente, de classificação.



Figura 8.1: Todas as células de carga conectadas em paralelo.

Também utilizamos quatro barras estáticas de gerador, conforme mostrado na Figura 8.23, para avaliação de alguns padrões de DP que existem em barras. As medições foram realizadas em cada barra individualmente e com todas elas dispostas em paralelo, a fim de tentar recriar os diferentes padrões de defeitos em uma única medição.

Nas barras a tensão de ensaio foi aplicada diretamente nos terminais de cada uma e uma fita metálica foi utilizada para envolver parte do revestimento isolante, simulando uma descarga de ranhura. Fita esta que, ao ser aterrada, gera a diferença de potencial necessária para induzir as descargas parciais no interior do isolante.

O circuito de medição aplicado é o mesmo mostrado na Figura A.1. Aqui o objeto a ser testado é substituído pelas células ou barras. Como os ensaios são realizados em laboratório, é possível aplicar o filtro de alta tensão para eliminar

ruídos que possam advir da fonte de alta tensão. O capacitor de acoplamento utilizado possui valor de 473 pF (30 kV) e a impedância de medição de 2 K Ω . Além destes, também foi usado um filtro Passa Altas (PA) com frequência de corte de $F_c = 300$ KHz, aplicado em conjunto ou não com um circuito atenuador (resistivo-capacitivo) de relação 10:1; todos estes circuitos estão descritos no Apêndice A. O atenuador é requerido somente em níveis de tensão mais elevados, em que a senóide de sincronismo (60 Hz) ultrapassa o valor de 10 Vpp.



(a)



(b)



(c)



(d)

Figura 8.2: Componentes do circuito: (a) Controle da Fonte de AT; (b) Fonte de AT; (c) Filtro de AT; (d) Capacitor de acoplamento 473 pF e impedância de medição Z_m (caixa metálica).

Os componentes do circuito mais importantes para as medições no laboratório são mostrados na Figura 8.2, em que temos a fonte de AT da Phenix Technologies

de 100 kVA / 1A e seu respectivo painel de controle, o filtro T de AT da Power Diagnostix que suporta uma tensão de até 50 kV, o capacitor de acoplamento de 437 pF e a impedância confeccionada em uma caixa de alumínio.

Em alguns dos ensaios, além da impedância de medição Z_m , foram aplicados outros tipos de sensores bastante comuns em medições no campo, dentre eles: um Transformador de Corrente de Alta Frequência (*High Frequency Current Transform - HFCT*) Techimp envolvendo o cabo de aterramento e uma antena monopolo colocada a 2 m de distância do objeto sob ensaio. Na Figura 8.3, são mostrados os sensores mencionados.

Nos ensaios, para a aquisição dos dados, foi usado um osciloscópio digitalizador PicoScope de dois canais com 14 bits de resolução e frequência de amostragem de 125 MHz. As medidas foram feitas pelo tempo necessário para prover um PRPD com 60 ciclos e outro com 120 ciclos em cada nível de tensão aplicado ao objeto.



Figura 8.3: Sensores utilizados: (a) HFCT; (b) Antena Monopolo.

O nível de tensão máximo que pode ser aplicado em cada célula sem que ocorra curto circuito é impreciso. Assim, para assegurar a integridade dos equipamentos utilizados e do corpo técnico envolvido no ensaio, a tensão aplicada nos terminais de cada célula foi elevada gradativamente até a tensão de inepção. E para avaliar a influência de uma tensão mais elevada no padrão de descargas, realizamos testes numa tensão acima daquela de inepção.

A fim de estender o banco de dados, também foram feitas combinações em paralelo de células e barras estatóricas. Para conseguir ensaiar adequadamente algumas destas combinações foi preciso garantir que (ambas) as células tivessem tensão de inepção próximas e suportassem os diferentes níveis de tensão impostos durante o ensaio sem rompimento do isolante. Para tanto, as distâncias entre os eletrodos de

alta e de aterramento de cada células foram ajustadas uma a uma, até que todos os objetos ensaiados pudessem suportar uma tensão máxima de 18 kV. Com as barras estatóricas não houve problemas, pois todas tinham capacidade de suportar mais de 18 kV sem romper o isolamento.

Na Figura 8.4 são mostrados alguns dos circuitos montados no laboratório AT3 (localizado na instalações do Cepel) para ensaio das células de carga e das barras estatóricas.

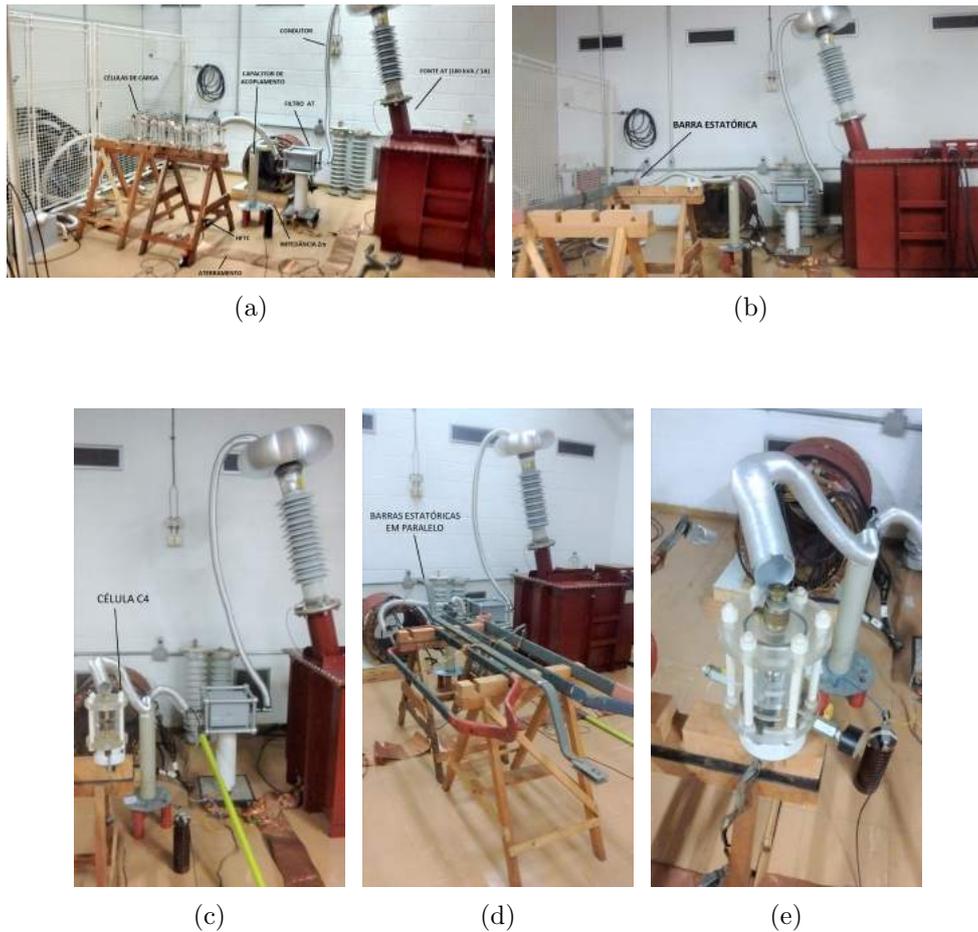


Figura 8.4: Circuitos ensaiados em laboratório: (a) todas as células em paralelo; (b) barra B1; (c) célula C4; (d) todas as barras em paralelo; (e) célula C6;

Conforme descrito no Capítulo 2, as DP também se manifestam visualmente com emissões de luz Ultra Violeta (UV). Durante alguns dos ensaios de células e barras tivemos a oportunidade de utilizar uma câmera UV (Deycor) capaz de capturar as emissões de luz ultra violeta na faixa de comprimento de onda de 100 nm – 280 nm (UV-C). A Figura 8.5 ilustra algumas das imagens obtidas pela câmera, em que os pontos em branco são as descargas que ocorreram no instante da captura.

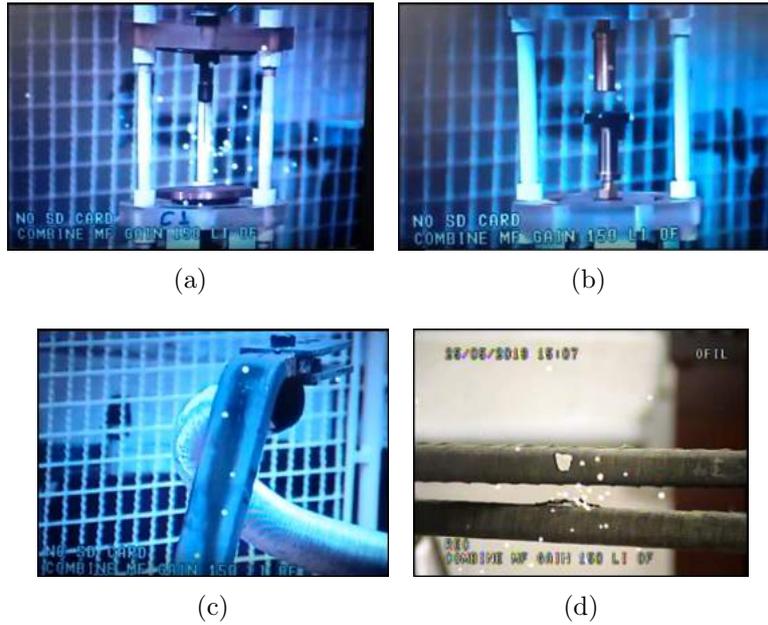


Figura 8.5: Detecção de DP usando câmera UV (Deycor): (a) descarga corona na célula C1 sob tensão de 18 kV; (b) descarga de superfície na célula C4 sob tensão de 17 kV; (c) descarga de superfície na barra B1 sob tensão de 18 kV (estimulada por contaminação com carbono); (d) descarga entre barras cruzadas do mesmo modelo da barra B1 sob tensão de 8 kV (barra superior em alta tensão e barra inferior aterrada pelos terminais de conexão e não pela malha que envolve o revestimento isolante)

8.2 Avaliação da Função de Limiarização Fleming no Processo Wavelet de Redução de Ruído

Em vista de realizar a avaliação da função de limiarização Fleming, bem como as suas quatro variantes (convenientemente denominadas Fleming 2, Fleming 3, Fleming 2 LMS e Fleming 3 LMS) apresentadas no Capítulo 5, fizemos a redução de ruído wavelet de um total de 2064 pulsos DP, incluindo sinais medidos de equipamentos de alta tensão em campo e sinais simulados com diferentes níveis de ruído branco uniforme, branco Gaussiano e AM (a maneira como estes foram obtidos foi a mesma descrita em [35]) e comparamos a performance destas funções com as clássicas funções de limiarização abrupta e suave e depois com mais outras 12 funções de limiarização mencionados no Capítulo 3.

Já sabemos que além da limiarização, o processo de wavelet *shrinkage* exige ainda a escolha da árvore de decomposição, da função wavelet, do número de níveis e do método de estimação de limiar. Como nosso objetivo é avaliar somente a função

de limiarização, alteraremos apenas esta e manteremos fixos os demais parâmetros necessários à filtragem. Optamos por utilizar a estrutura FWT, por facilidade de implementação e por ser bastante aplicada em tratamento de sinais de DP e, na seleção das wavelets mãe, utilizamos o método SNRBWS associado ao algoritmo para escolha do número de níveis de decomposição NWDLS. Na estimativa do valor de limiar a ser aplicado na função de limiarização, optamos pelo método *scaledep* [33], [35], [67]. Como a função Fleming e suas variantes dependem de uma constante de inclinação que controla a forma como os coeficientes wavelet decompostos serão eliminados ou atenuados, também compararemos os resultados para valores variados desta constante (excetuando-se as duas variantes que fazem a busca automática da constante com minimização LMS do risco SURE).

8.2.1 Comparação entre as Funções de Limiarização Fleming

Antes de realizarmos a comparação com outras funções (usando os parâmetros de avaliação descritos no Capítulo 5), analisaremos a performance apenas das funções Fleming de que dispomos.

Executamos cada método para todos os sinais disponíveis e fizemos a média dos valores de cada parâmetro de avaliação para, então, verificarmos qual dos métodos apresentava os melhores resultados. Realizamos a filtragem com diversos valores de inclinação (5, 10, 30, 50, 100, 200, 300, 500 e 1000) e tomamos o melhor resultado para cada um dos sinais, para só então calcularmos a média. Apesar das alternativas Fleming 2 LMS e Fleming 3 LMS realizarem a busca automática da constante, estas precisam de uma condição inicial para a busca e, portanto, nestes casos os mesmos valores de constante especificados para as demais funções foram usados como condição inicial.

Os resultados são mostrados na Tabela 8.1, em que os melhores resultados estão destacados em negrito. Observe que os valores médios para a função Fleming são superiores na maioria dos parâmetros avaliados incluindo o critério de aptidão J_{Apt} , o qual podemos considerar como o mais importante na identificação do melhor resultado de filtragem [35],[91]. A função Fleming 3 LMS obteve os melhores resultados para o Erro Médio Aritmético (EMA), o EQM e a Raiz Quadrada do Erro Médio Quadrático ($REQM$), algo esperado pois ao tentar minimizar o risco SURE espera-se minimizar o EQM . Para a SNR , a $DSNR$, o Nível de Redução de Ruído (NRR) e a ΔT_s , destacam-se os resultados da função Fleming 3. Já a função Fleming 2 LMS, se apresenta como a pior alternativa entre todas as variantes, conseguindo

melhor resultado apenas para o Deslocamento de Máxima amplitude (DM) Quanto ao tempo de execução (t_{exec}), os algoritmos das funções que não utilizam a técnica de minimização LMS são os mais rápidos, pois não precisam perder tempo com a busca da constante de inclinação. Assim sendo, vemos que o método Fleming se sai melhor, mas a proposta Fleming 3 e Fleming 3 LMS também mostram resultados interessantes.

Tabela 8.1: Valores Médios dos Parâmetros de Avaliação para cada Função de Limiarização Considerando os Melhores Resultados para cada Sinal em Diversos Valores de Constante de Inclinação.

Parâmetro	Função de Limiarização				
	Fleming	Fleming 2	Fleming 3	Fleming 2 LMS	Fleming 3 LMS
EMA	0,0208	0,0206	0,0201	0,0207	0,0201
EQM	0,0203	0,0203	0,0188	0,0202	0,0187
$REQM$	0,0286	0,0287	0,0281	0,0286	0,0280
CC	0,7907	0,7837	0,7850	0,7801	0,7804
NCC	0,7897	0,7826	0,7841	0,7790	0,7794
DE	0,2585	0,2786	0,2904	0,2796	0,2832
SNR	6,9282	6,8350	6,9296	6,6388	6,7165
$DSNR$	3,5087	3,4155	3,5100	3,2192	3,2969
NRR	-37,7130	-37,5343	-37,5334	-37,4907	-37,5363
EA_{max}	12,4550	14,2301	13,2563	14,8134	13,9728
EA_{min}	12,6776	15,8575	13,9187	16,3444	14,5851
ΔP_{max}	9,3150	15,3752	10,5974	15,5042	10,5964
ΔP_{min}	14,9126	22,0646	17,7159	22,1241	17,1044
DM	4536,25	4536,20	4536,24	4536,19	4536,24
ΔT_s	10,9540	10,9951	10,6161	11,4603	10,6662
p_g	8,1258	5,0982	5,6649	5,3250	5,8010
p_L	2,4512	2,8184	2,5576	2,8745	2,5869
Dk	16,4246	22,1328	21,1800	21,2159	20,3948
J_{Apt}	5,6746	2,2798	3,1073	2,4505	3,2141
t_{exec}	0,4777	0,4723	0,7256	3,9420	3,7512

Vale observar que estamos considerando os valores médios tomando os melhores resultados para cada sinal dentre as diversas constantes de inclinação, algo que na prática seria inadequado de se investigar. Os métodos que fazem a busca automática saem em vantagem nesse quesito, pois apenas necessitam de uma condição inicial

e por si só fazem a busca por um valor melhor. Portanto, é necessário investigar qual seria o valor apropriado para ser usado como ponto de partida nos métodos que usam a minimização por LMS. Outra desvantagem dos métodos que usam o LMS é que estes foram limitados para um número máximo de 250 iterações e, conforme visto na Seção 5.3, isso pode fazer com que os mesmos não tenham tempo suficiente para encontrar o valor ótimo, comprometendo sua performance dependendo dos coeficientes wavelet que lhes são apresentados.

Na Tabela 8.2 apresentamos a quantidade percentual de melhores resultados obtidos para cada sinal levando em conta os diferentes valores de constante de inclinação para as Funções de Limiarização Fleming. Observe que novamente as melhores funções são a Fleming, a Fleming 3 e a Fleming 3 LMS, conforme indicado pelos valores médios da Tabela 8.1, mas a quantidade de melhores resultados é percentualmente maior para o método Fleming 3 e não para o método Fleming, mesmo este tendo se mostrado superior em valores médios. Ou seja, quando a função Fleming consegue ser melhor acaba por atingir parâmetros um pouco superiores aos fornecidos pelo Fleming 3. Para o critério de aptidão a função Fleming 3 detém 30.67% dos melhores resultados, o que é bem superior à Fleming com 23.55% e às demais. Para o tempo de processamento temos que a Fleming e a Fleming 2 são as alternativas mais rápidas, mas em termos médios (Tabela 8.1) a função Fleming 3 também pode ser considerada relativamente rápida.

Quantitativamente conclui-se que, quando considerado todos os valores de inclinação, a Função Fleming 3 é a melhor. Isto mostra que a combinação das técnicas de busca dos coeficientes de maior importância para restaurar o pulso de DP e de atribuição de valores de limiares diferentes para os coeficientes positivos e negativos, é uma estratégia eficaz na filtragem de sinais de DP.

Tabela 8.2: Percentual de Melhores Resultados para cada Sinal em Diversos Valores de Constante de Inclinação definidos para as Funções de Limiarização Fleming.

Parâmetro	Função de Limiarização				
	Fleming	Fleming 2	Fleming 3	Fleming 2 LMS	Fleming 3 LMS
<i>EMA</i>	22,09	23,79	31,83	10,42	11,87
<i>EQM</i>	25,34	16,72	32,75	11,72	13,47
<i>REQM</i>	25,34	16,72	32,75	11,72	13,47
<i>CC</i>	25,68	15,46	35,17	10,66	13,03
<i>NCC</i>	25,92	15,46	34,88	10,42	13,32
<i>DE</i>	19,86	12,21	18,99	19,91	29,02
<i>SNR</i>	21,17	13,66	38,18	11,53	15,46
<i>DSNR</i>	21,17	13,66	38,18	11,53	15,46
<i>NRR</i>	59,35	3,25	15,02	8,43	13,95
<i>EA_{max}</i>	25,53	13,03	19,72	18,65	23,06
<i>EA_{min}</i>	26,89	12,89	17,10	22,00	21,12
ΔP_{max}	11,19	2,42	7,51	12,16	66,72
ΔP_{min}	10,8	3,78	6,73	15,21	63,47
<i>DM</i>	11,82	2,76	6,64	16,57	62,21
ΔT_s	12,4	8,91	13,23	17,15	48,3
<i>p_g</i>	24,66	15,94	32,46	11,82	15,12
<i>p_L</i>	28,59	12,84	20,78	16,33	21,46
<i>Dk</i>	23,84	15,99	16,76	20,78	22,63
<i>J_{Apt}</i>	26,99	15,26	31,25	11,24	15,26
<i>t_{exec}</i>	45,16	43,99	9,98	0,73	0,15

A Tabela 8.3 informa qual o valor de inclinação c produz a maior quantidade de melhores resultados por função de limiarização. Todos os métodos se dão melhor com um valor mais baixo de constante de inclinação, no caso $c = 5$. Nas funções Fleming 2 LMS e Fleming 3 LMS temos uma distribuição mais equilibrada dos resultados por c , pois o método faz a busca automática deste valor.

Tabela 8.3: Comparação Percentual de Melhores Resultados entre Funções Fleming por Constante de Inclinação.

Função	Constante de Inclinação								
	5	10	30	50	100	200	300	500	1000
Fleming	47,09	25,00	8,96	4,12	3,63	1,50	1,07	1,16	7,46
Fleming 2	65,16	11,82	5,52	2,37	1,79	1,55	0,78	1,16	9,84
Fleming 3	66,18	11,58	4,60	2,62	1,89	0,97	0,78	1,02	10,37
Fleming 2 LMS	25,97	10,85	8,04	7,80	8,43	10,47	6,59	6,06	15,79
Fleming 3 LMS	27,66	10,66	8,53	7,41	9,06	12,11	2,03	7,61	14,92

Já na Tabela 8.4 temos os resultados médios de aptidão J_{Apt} para as funções com cada constante e inclinação. Verifica-se que o melhor resultado médio é obtido com $c = 5$ nos casos das funções Fleming 2, Fleming 3 e Fleming 3 LMS e com $c = 10$ para as funções Fleming e Fleming 2 LMS. A medida que c aumenta ocorre uma piora nos resultados para todos os métodos. A função que se mostrou mais eficiente pela aptidão média foi a função Fleming tanto para $c = 5$ quanto para $c = 10$.

Tabela 8.4: Comparação do Valor Médio de J_{Apt} entre Funções Fleming por Constante de Inclinação.

Função	Constante de Inclinação								
	5	10	30	50	100	200	300	500	1000
Fleming	2,711	3,117	1,023	0,086	-0,725	-0,486	0,072	0,929	0,963
Fleming 2	1,335	1,060	0,917	0,895	0,881	0,878	0,884	0,887	0,881
Fleming 3	2,243	1,958	1,828	1,820	1,797	1,781	1,777	1,776	1,777
Fleming 2 LMS	0,371	0,479	0,167	0,216	-0,159	-0,379	-0,355	-0,741	-1,005
Fleming 3 LMS	1,529	1,196	1,118	0,808	0,672	0,540	0,209	0,108	0,184

Portanto, os resultados indicam que para elevar as chances de aplicar as novas funções de forma bem sucedida, o ideal é usar um valor de c entre 5 e 10, até mesmo como condição inicial dos métodos que combinam a busca por minimização LMS.

Na Figura 8.6 é mostrada uma comparação dos resultados de melhor filtragem dos sinais avaliados entre as funções Fleming para uma constante $c = 5$. Considerando apenas o parâmetro de aptidão, a função Fleming 3 foi a que proporcionou um

maior percentual de melhores resultados, preservando melhor os parâmetros globais (EMA , EQM , $REQM$, CC , NCC , SNR , $DSNR$) do que os parâmetros locais (EA_{min} , EA_{max} , ΔP_{min} , ΔP_{max} , DM , ΔT_s). Já a função Fleming 3 LMS tem uma boa performance na preservação dos parâmetros locais. Quanto ao tempo de processamento a Fleming é a que processa os sinais de DP mais rapidamente.

Atente que a comparação é feita apenas entre as variações da função Fleming, o que ainda não nos fornece um panorama da sua eficiência em relação às outras funções de limiarização. Portanto, para verificar se nossas propostas são válidas, analisaremos, nas Subseções seguintes, tanto em termos quantitativos (número de melhores resultados) quanto qualitativos (média de resultados), como cada uma se comporta em relação às conhecidas funções *hard* e *soft*. Em seguida, vamos comparar a performance média de todas as funções de limiarização comentadas no Capítulo 3, para verificar se a função consegue ser superior às demais.

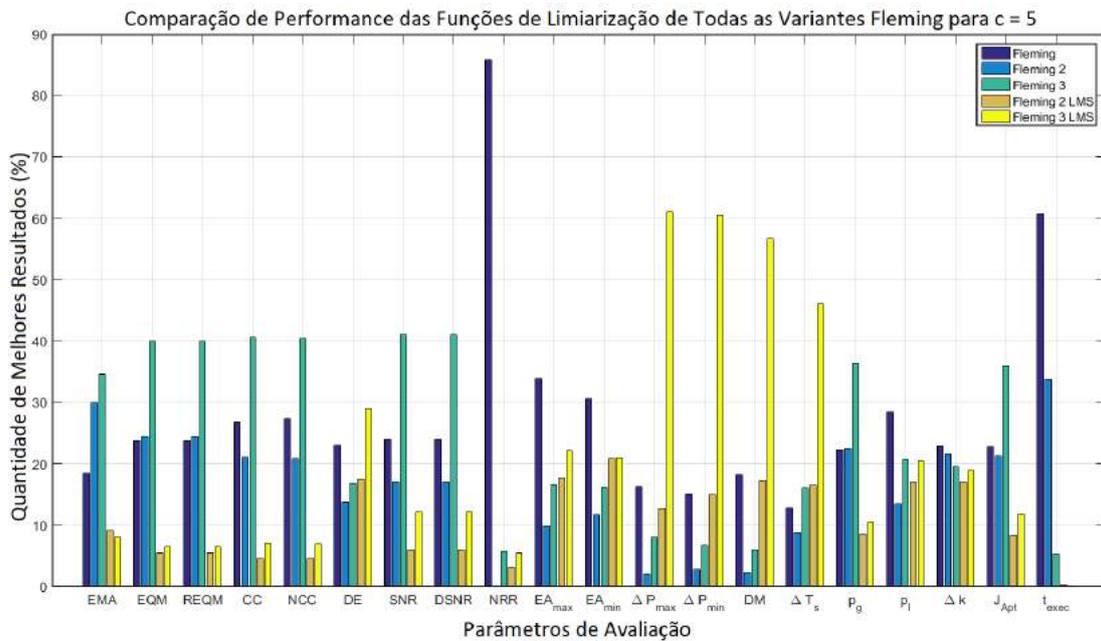


Figura 8.6: Resultados de melhor filtragem obtida entre as funções Fleming com constante de inclinação $c = 5$.

8.2.2 Comparação entre as Funções de Limiarização Fleming, *Hard* e *Soft*

O objetivo principal de se construir uma nova função de limiarização é fazer com que esta consiga produzir resultados superiores aos das funções convencionais. Como vimos no Capítulo 3 as funções mais aplicadas em filtragem de coeficientes wavelet são a *hard* e a *soft*, não apenas para sinais de DP, como também para processamento

de imagens, sinais de áudio, etc.

Primeiro mostramos na Figura 8.7 os resultados de comparação de todas as alternativas propostas usando inclinação $c = 5$ contra as funções *hard* e *soft*. De acordo com o critério de aptidão, constatamos que todas as funções propostas conseguem uma maior percentagem de melhores resultados que a *hard* e, também, as funções Fleming, Fleming 2 e Fleming 3 conseguem superar todas as demais. Conforme esperado, por sua simplicidade, a função *soft* é a mais rápida. Além do mais, as funções Fleming 3 e Fleming 3 LMS se destacam na maioria dos parâmetros de avaliação.

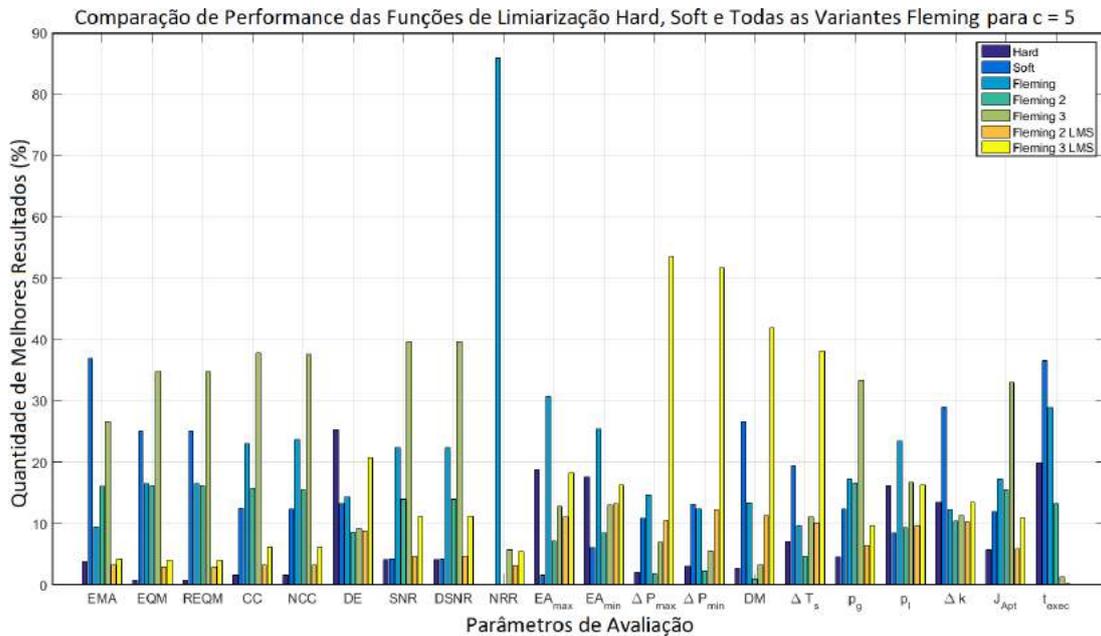


Figura 8.7: Comparação de resultados de melhor filtragem obtida entre as funções Fleming, *hard* e *soft*.

Repetindo a comparação, desta vez para $c = 10$, obtivemos resultados percentuais ainda melhores para nossas propostas, conforme mostrado na Figura 8.8. Novamente a função Fleming 3 se mostrou a melhor dentre todas ao fornecer o maior valor percentual de quantidade de melhores resultados de aptidão e a função Fleming 3 LMS também exibe resultados excelentes.

Para uma melhor noção comparativa, tomamos cada método desenvolvido de forma isolada. De acordo com os resultados expostos nas Figuras 8.9, 8.10, 8.11, 8.12 e 8.13 é evidenciada a superioridade de todas as alternativas que propusemos em relação à quantidade de melhores resultados obtidos em comparação com as usuais metodologias *hard* e *soft*. O único inconveniente é que nossos métodos precisam de um pouco mais de tempo para serem processados; entretanto, é um preço relativamente baixo a ser pago para atingir melhores resultados na redução de componentes

de ruído dos sinais de DP. Note ainda que a função *hard*, quando comparada com a *soft*, tende a fornecer uma melhor preservação das amplitudes dos pulsos de DP e melhor SNR, o que confirma as afirmações feitas na literatura [15], [83].

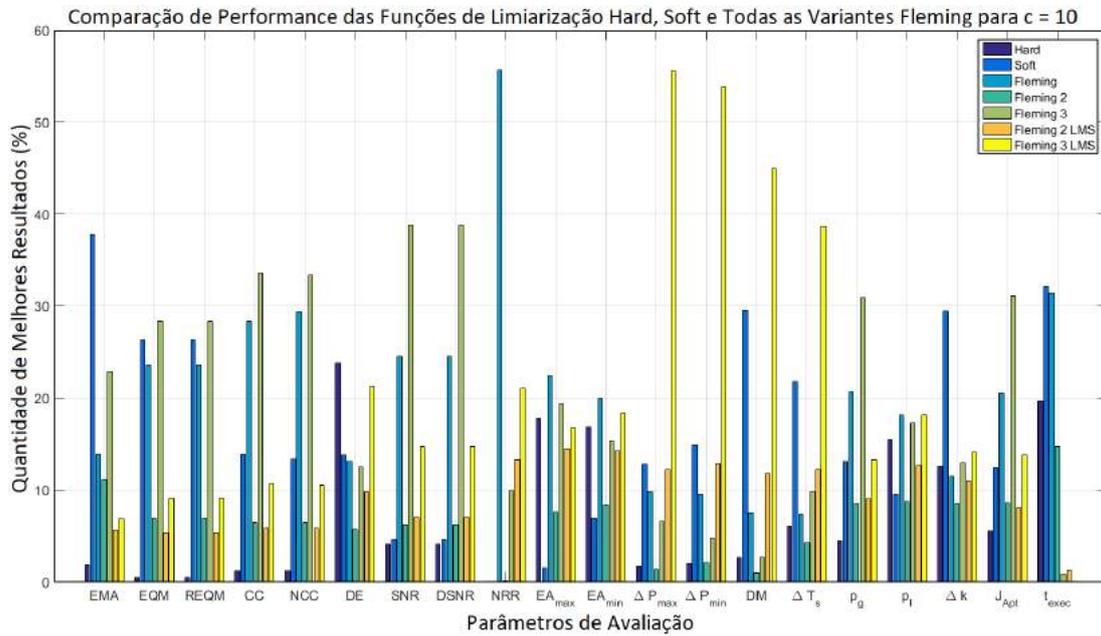


Figura 8.8: Comparação de resultados de melhor filtragem obtida entre as todas as funções Fleming, a *hard* e a *soft*.

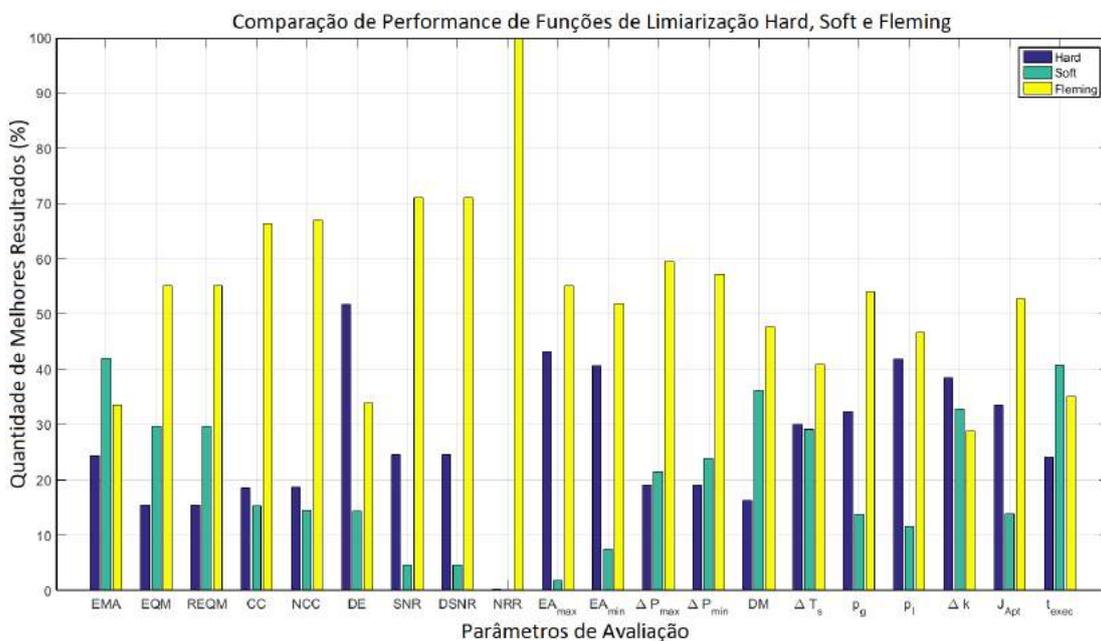


Figura 8.9: Comparação de resultados de melhor filtragem obtida entre a função Fleming, a *hard* e a *soft*.

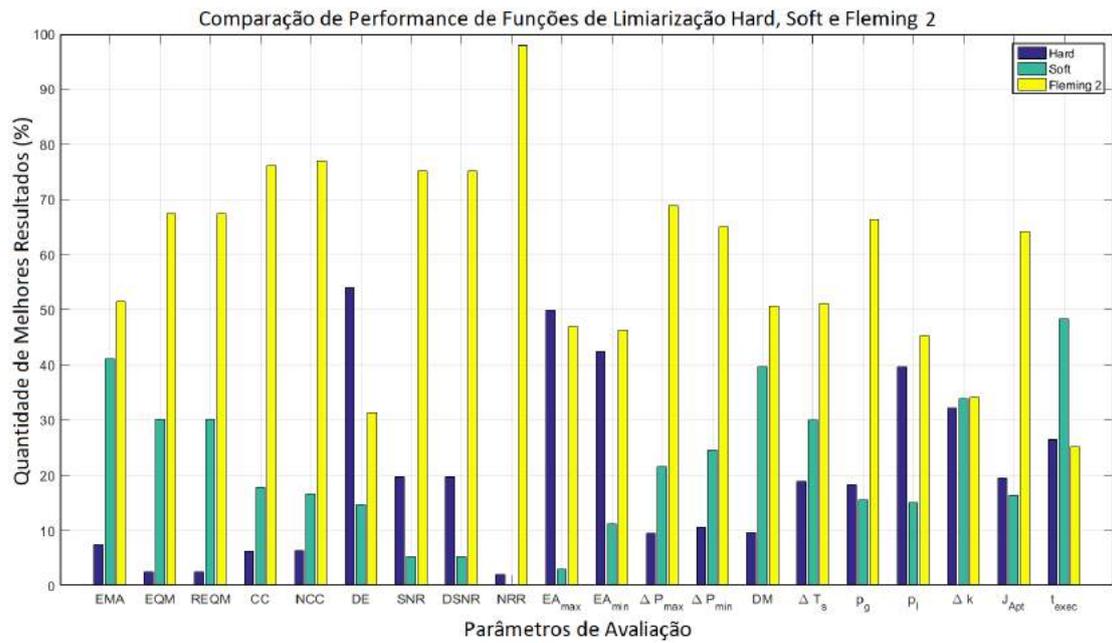


Figura 8.10: Comparação de resultados de melhor filtragem obtida entre a função Fleming 2, a *hard* e a *soft*.

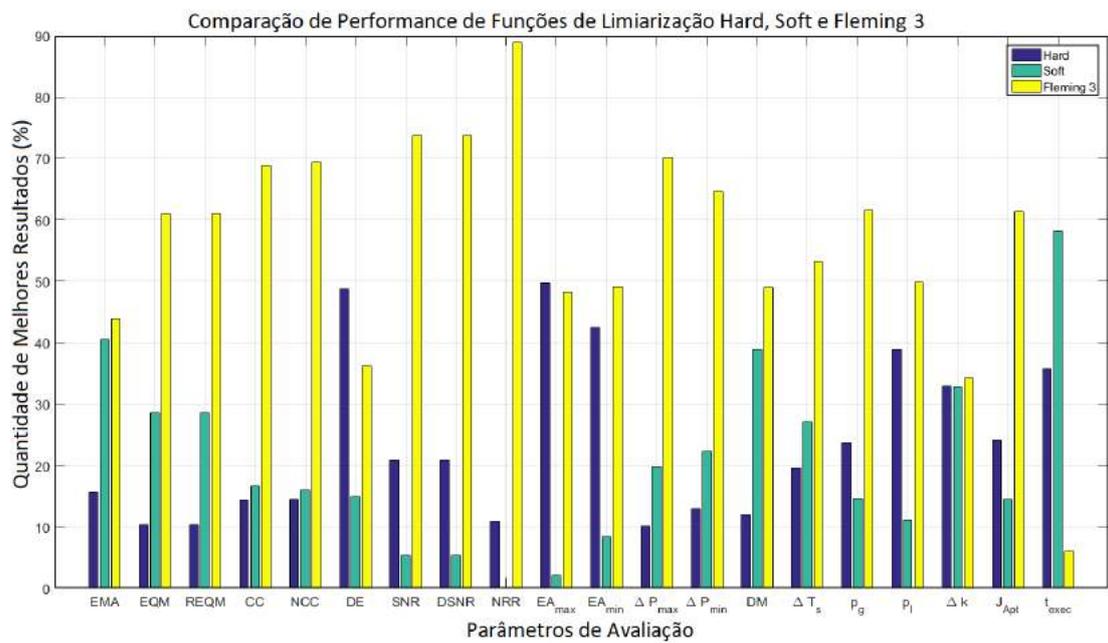


Figura 8.11: Comparação de resultados de melhor filtragem obtida entre a função Fleming 3, a *hard* e a *soft*.

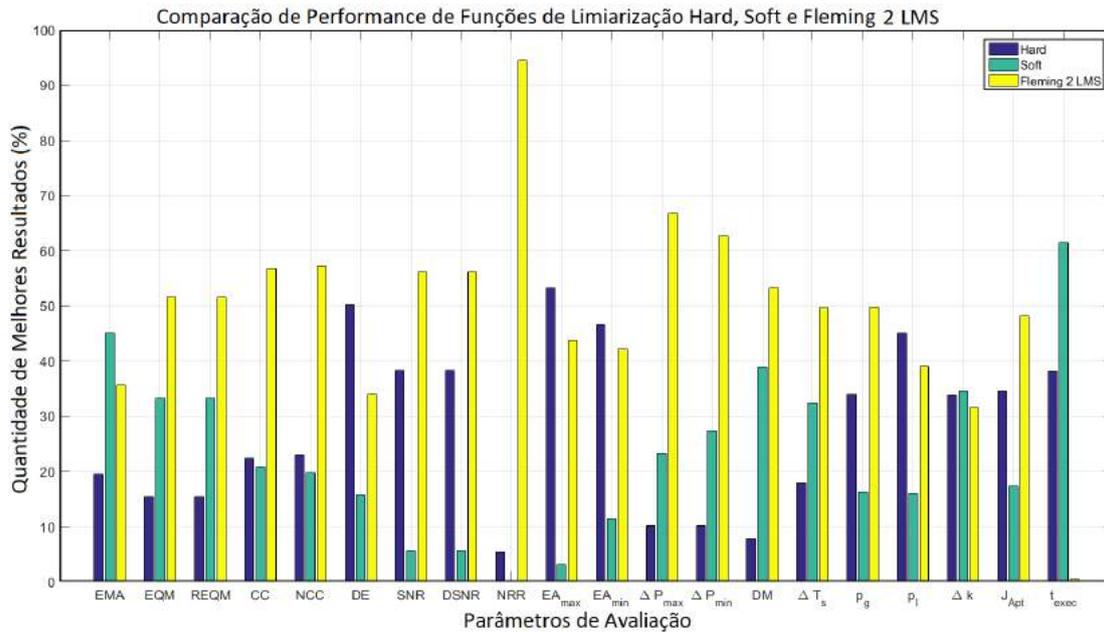


Figura 8.12: Comparação de resultados de melhor filtragem obtida entre a função Fleming 2 LMS, a *hard* e a *soft*.

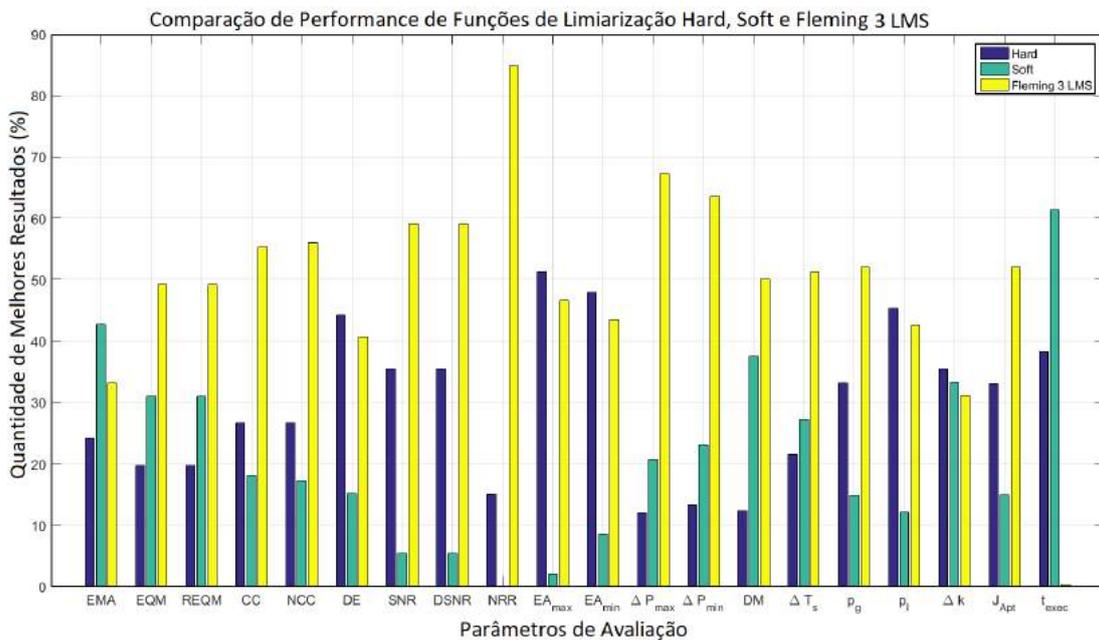


Figura 8.13: Comparação de resultados de melhor filtragem obtida entre a função Fleming 3 LMS, a *hard* e a *soft*.

8.2.3 Comparação entre Todas as Funções de Limiarização

Com os resultados descritos na Subseção anterior temos uma ideia quantitativa da capacidade de cada método empregado, mas somente com os resultados médios podemos ter real noção da qualidade de cada um. Implementamos todos os demais

métodos de truncamento dos coeficientes wavelet mencionados no Capítulo 3, incluindo as funções: *Adapt Shrink*, Garrote, Hui, Liu, Non Negative Garrote, *Semi Soft*, Stein, Zhang 1, Zhang 2, Zhang 3, Zhang 4 e Zhang 5. As variáveis necessárias à cada uma destas funções foram designadas de acordo com os dados fornecidos pelos respectivos autores nos trabalhos que as descrevem.

De forma similar ao mostrado na Tabela 8.4, fizemos uma avaliação dos resultados médios do parâmetro de aptidão e comparamos com os demais métodos, conforme as Tabelas 8.5 e 8.6. Note que a aptidão de 2,711 da função Fleming ($c = 5$) é a maior dentre todas as demais, sendo seguida pelas variações Fleming 3 ($c = 5$), Fleming 3 LMS ($c = 5$) e Fleming 2 ($c = 5$) e depois vêm as funções Garrote e a *hard* para só então vir a Fleming 2 LMS ($c = 5$). Os resultados indicam que as alternativas desenvolvidas atingiram o objetivo de superar outras funções anteriormente propostas, fornecendo também um melhor resultado qualitativo no tratamento de sinais de DP.

Realizamos, ainda, uma avaliação percentual da quantidade de melhores resultados considerando todas as funções de limiarização. Pela Tabela 8.7 as funções Fleming têm excelente performance quando comparadas às demais. No quesito aptidão, a que obteve uma maior quantidade de melhores resultados de filtragem foi a Fleming 3 com 28,73 % de todos os sinais. A função Zhang 5 também tem seu mérito quanto a preservação das características locais dos pulsos analisados como o de tempo de subida, os tempos de pico máximo e de pico mínimo e a amplitude máxima. Quanto critério de tempo de execução a função Stein se sobressai em relação às demais. A função *soft* acaba por perder espaço para as demais em praticamente todos os critérios avaliados, confirmando que a mesma não é indicada para tratar sinais de DP.

As Figuras 8.14 e 8.15 ilustram alguns resultados do uso da filtragem wavelet em sinais de DP simulados e medidos para as diferentes funções de limiarização comparadas nesta Seção. Percebe-se que as funções de limiarização Fleming têm boa performance e em sua maioria conseguem apresentar um maior valor de aptidão, ou seja, uma performance de filtragem superior, em concordância com os resultados demonstrados nas Tabelas 8.6, 8.5 e 8.7.

Tabela 8.5: Resultado Médio dos Parâmetros de Avaliação para todas as Funções de Limiarização.

Parâmetro	Função de Limiarização										
	<i>Hard</i>	<i>Soft</i>	Fleming	F. 2	F. 3	F. 2 LMS	F. 3 LMS	<i>A. Shrink</i>	Garrote	Hui	
<i>EMA</i>	0,0211	0,0202	0,0213	0,0206	0,0201	0,0209	0,0204	0,0210	0,0227	0,0235	
<i>EQM</i>	0,0204	0,0168	0,0203	0,0203	0,0188	0,0202	0,0187	0,0172	0,0210	0,0254	
<i>REQM</i>	0,0294	0,0309	0,0289	0,0286	0,0280	0,0289	0,0283	0,0304	0,0299	0,0382	
<i>CC</i>	0,7704	0,7365	0,7873	0,7870	0,7877	0,7738	0,7746	0,7611	0,7735	0,7134	
<i>NCC</i>	0,7693	0,7329	0,7865	0,7859	0,7867	0,7727	0,7736	0,7587	0,7727	0,7058	
<i>DE</i>	0,3018	0,5254	0,2989	0,2833	0,2928	0,2939	0,3047	0,4717	0,3639	0,5712	
<i>SNR</i>	6,4680	1,2200	6,8845	6,8330	6,9244	6,4952	6,5817	2,5653	6,5142	-0,0039	
<i>DSNR</i>	3,0484	-2,1995	3,4650	3,4135	3,5048	3,0756	3,1622	-0,8543	3,0947	-3,4235	
<i>NRR</i>	-37,3316	-36,5733	-38,0186	-37,5191	-37,5688	-37,4986	-37,5435	-36,8616	-38,2639	-36,3983	
<i>EAmax</i>	14,1321	39,7542	12,3669	14,7690	13,8375	15,6969	14,9120	35,0809	13,7813	43,7753	
<i>EAmín</i>	16,1110	35,5709	13,3229	16,2432	14,2777	17,0552	15,3055	30,0906	14,0323	40,1962	
ΔP_{max}	15,7103	11,4379	13,3003	16,2801	10,9872	16,2879	11,0657	13,9713	13,2891	12,4536	
$\Delta P_{mín}$	23,0556	20,1352	20,9179	23,9310	18,8678	24,2925	20,2370	23,4540	22,0741	23,5802	
<i>DM</i>	4536,192	4536,233	4536,207	4536,188	4536,236	4536,189	4536,240	4536,217	4536,216	4536,227	
ΔT_s	11,3144	9,8738	14,1361	11,6378	11,0286	11,9063	11,0794	13,9420	15,1128	10,7760	
<i>pg</i>	3,8089	-5,2684	5,7551	4,3065	4,9107	3,4496	4,3148	-0,6287	4,2715	-6,9717	
<i>PL</i>	2,9249	3,5891	3,0447	2,9715	2,6679	3,0787	2,7858	3,8804	3,1947	3,8608	
<i>Dk</i>	23,6691	30,7889	20,9416	23,7841	22,7397	24,5443	22,9617	24,7083	22,7964	31,2065	
<i>JApt</i>	0,8840	-8,8575	2,711	1,3350	2,2428	0,3709	1,5290	-4,5092	1,0768	-10,8325	
<i>tesec</i>	0,4590	0,4550	0,4571	0,4606	0,7111	3,0822	3,5602	0,4563	0,4562	0,4578	

Tabela 8.6: Resultado Médio dos Parâmetros de Avaliação para todas as Funções de Limiarização (continuação).

Parâmetro	Função de Limiarização									
	Liu	N. Garrote	S. Soft	Stein	Zhang 1	Z. 2	Z. 3	Z. 4	Z. 5	
<i>EMA</i>	0,0194	0,0193	0,0202	0,0193	0,0216	0,0198	0,0111	0,0358	0,0724	
<i>EQM</i>	0,0165	0,0159	0,0168	0,0159	0,0168	0,0163	0,0021	0,1715	0,2473	
<i>REQM</i>	0,0276	0,0282	0,0309	0,0282	0,0321	0,0295	0,0175	0,0585	0,0923	
<i>CC</i>	0,7753	0,7615	0,7365	0,7615	0,6242	0,7675	0,7534	0,1220	0,5751	
<i>NCC</i>	0,7734	0,7591	0,7329	0,7591	0,6231	0,7643	0,7513	0,1167	0,5751	
<i>DE</i>	0,2941	0,3573	0,5249	0,3573	3,2690	0,4770	0,3593	0,9775	10,5273	
<i>SNR</i>	5,4032	4,1780	1,2289	4,1780	2,8441	2,5163	-78,1502	-16,7955	4,0939	
<i>DSNR</i>	1,9836	0,7584	-2,1906	0,7584	-0,5755	-0,9032	-81,5697	-20,2150	0,6743	
<i>NRR</i>	-37,1571	-36,9693	-36,5749	-36,9693	-43,4754	-36,8029	45,3063	-34,2005	-47,9196	
<i>E_{max}</i>	20,5297	26,4084	39,7152	26,4084	27,2555	35,1136	98,3888	89,0223	39,0077	
<i>E_{min}</i>	17,3705	22,4973	35,5309	22,4973	30,8836	30,6644	95,6896	87,5289	61,4756	
ΔP_{max}	9,0812	9,9165	11,4379	9,9165	18,9885	11,2362	10,6441	132,8945	20,6252	
ΔP_{min}	16,4859	17,3405	19,8012	17,3405	23,7583	18,8655	18,1220	174,2407	28,2638	
<i>DM</i>	4536,236	4536,237	4536,233	4536,237	4536,195	4536,231	4536,246	4536,136	4536,172	
ΔT_s	9,5330	9,5683	9,8684	9,5683	15,2266	11,5696	9,0684	14,3782	20,0962	
<i>P_g</i>	2,1458	-0,5817	-5,2600	-0,5817	-6,3010	-1,4412	-84,3882	-35,9597	-8,8932	
<i>P_L</i>	2,6943	2,8970	3,5791	2,8970	4,2557	3,4913	5,8570	12,3117	5,3256	
<i>D_k</i>	25,1089	27,8457	30,7909	27,8457	31,6175	26,3539	30,6094	43,7877	36,1685	
<i>J_{Apt}</i>	-0,5486	-3,4787	-8,8392	-3,4787	-10,5567	-4,9325	-90,2453	-48,2714	-14,2188	
<i>t_{ewec}</i>	0,4558	0,4568	0,4552	0,4551	0,4566	0,4642	0,4563	0,4559	0,4560	

Tabela 8.7: Resultado Percentual dos Parâmetros de Avaliação para Todas as Funções de Limiarização.

	Função de Limiarização																		
	<i>Hard</i>	<i>Soft</i>	Fleming	F.2	F.3	F.2 LMS	F.3 LMS	<i>A.Shrink</i>	Garrote	Hui	Liu	N. Garrote	<i>S.Soft</i>	Stein	Zhang 1	Z.2	Z.3	Z.4	Z.5
<i>EMA</i>	1,45	0,78	2,57	11,48	23,59	2,08	3,15	2,03	5,72	9,21	7,61	1,89	0,97	7,61	0,34	3,92	5,09	7,85	2,66
<i>EQM</i>	0,68	0,10	6,54	12,40	30,04	1,74	3,29	4,31	8,87	4,46	5,96	2,62	0,44	5,62	0,78	4,65	3,44	1,65	2,42
<i>REQM</i>	0,68	0,10	6,54	12,40	30,04	1,74	3,29	4,31	8,87	4,46	5,96	1,74	0,44	6,49	0,78	4,65	3,15	1,65	2,71
<i>CC</i>	1,31	0,00	9,93	12,89	34,06	1,99	4,80	1,70	11,43	3,88	4,07	2,03	0,34	4,31	0,97	1,70	1,94	0,00	2,66
<i>NCC</i>	1,31	0,00	10,9	12,84	33,96	1,99	4,70	1,60	11,48	3,88	3,83	1,94	0,24	4,31	0,97	1,31	1,99	0,00	2,76
<i>DE</i>	21,56	0,29	7,95	3,34	6,01	5,18	15,65	2,08	9,01	1,41	8,48	1,11	0,15	4,26	2,47	1,99	3,92	0,92	4,22
<i>SNR</i>	2,91	0,00	10,27	11,05	36,19	2,76	7,56	0,00	4,02	0,53	2,03	1,45	0,15	3,54	0,58	0,00	1,94	0,00	15,02
<i>DSNR</i>	2,91	0,00	10,27	11,05	36,19	2,76	7,56	0,00	4,02	0,53	2,03	1,45	0,15	3,54	0,58	0,00	1,94	0,00	15,02
<i>NRR</i>	0,00	0,00	0,000	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	25,39	0,00	0,00	0,00	74,61
<i>EA_{max}</i>	9,84	0,00	13,23	3,88	5,72	5,81	9,21	0,24	10,47	0,34	4,89	1,02	0,00	3,92	9,88	0,29	2,18	0,68	18,41
<i>EA_{min}</i>	10,56	0,19	12,45	4,80	6,35	6,49	8,38	1,16	9,4	0,82	5,62	1,99	0,19	5,67	7,12	2,18	4,02	1,50	11,09
ΔP_{max}	1,16	0,00	0,82	0,44	2,37	2,57	7,22	4,07	4,51	0,68	3,00	0,00	1,41	1,89	5,28	5,23	16,57	0,87	41,91
ΔP_{min}	1,50	0,00	0,73	0,68	1,31	3,88	8,04	3,63	5,33	0,73	2,81	0,00	1,11	2,52	5,52	6,3	15,75	1,31	38,86
<i>DM</i>	1,36	0,00	0,63	0,00	1,02	2,18	4,31	2,42	2,96	1,6	0,63	0,00	2,03	1,26	5,23	2,62	11,77	36,00	23,98
ΔT_s	2,86	0,00	1,11	2,23	4,80	3,59	9,54	2,28	4,07	2,47	4,36	0,00	2,03	3,39	2,71	3,54	11,72	18,07	21,22
<i>P_g</i>	3,83	0,00	9,21	12,11	29,46	4,75	8,19	0,44	5,14	2,28	5,52	3,34	1,16	5,04	0,19	0,68	4,60	0,05	4,02
<i>P_L</i>	10,90	0,05	12,26	6,44	11,43	5,96	11,92	0,63	8,87	0,58	5,81	1,16	0,48	4,07	4,22	0,97	3,59	0,48	10,17
<i>Dk</i>	9,40	0,73	5,18	6,44	6,64	7,22	8,87	3,49	5,96	6,59	7,17	3,10	4,51	5,91	2,28	4,07	7,61	1,21	3,63
<i>JA_{opt}</i>	4,31	0,00	9,16	10,8	28,73	4,41	9,11	0,44	4,89	2,28	6,06	3,39	1,36	5,18	0,24	0,78	5,62	0,00	3,25
<i>t_{exec}</i>	5,72	10,13	6,78	1,36	0,15	0,05	0,00	7,80	3,92	3,34	7,80	3,39	7,46	10,90	9,30	0,34	5,96	5,04	10,56

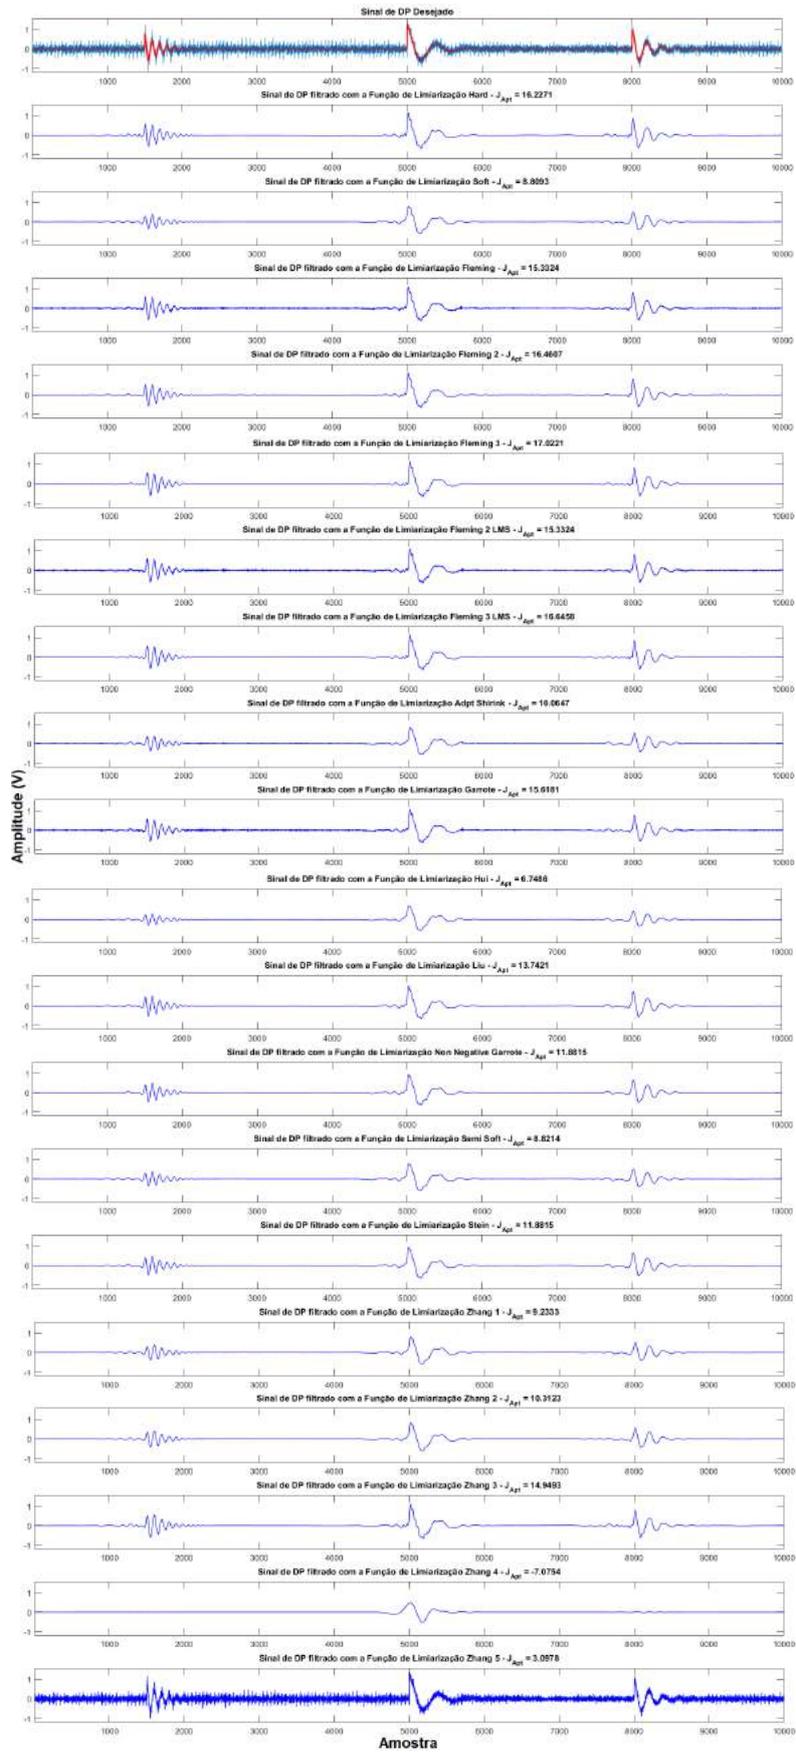


Figura 8.14: Exemplo 1 de filtragem wavelet para as diferentes funções de limiarização em um sinal de DP simulado.

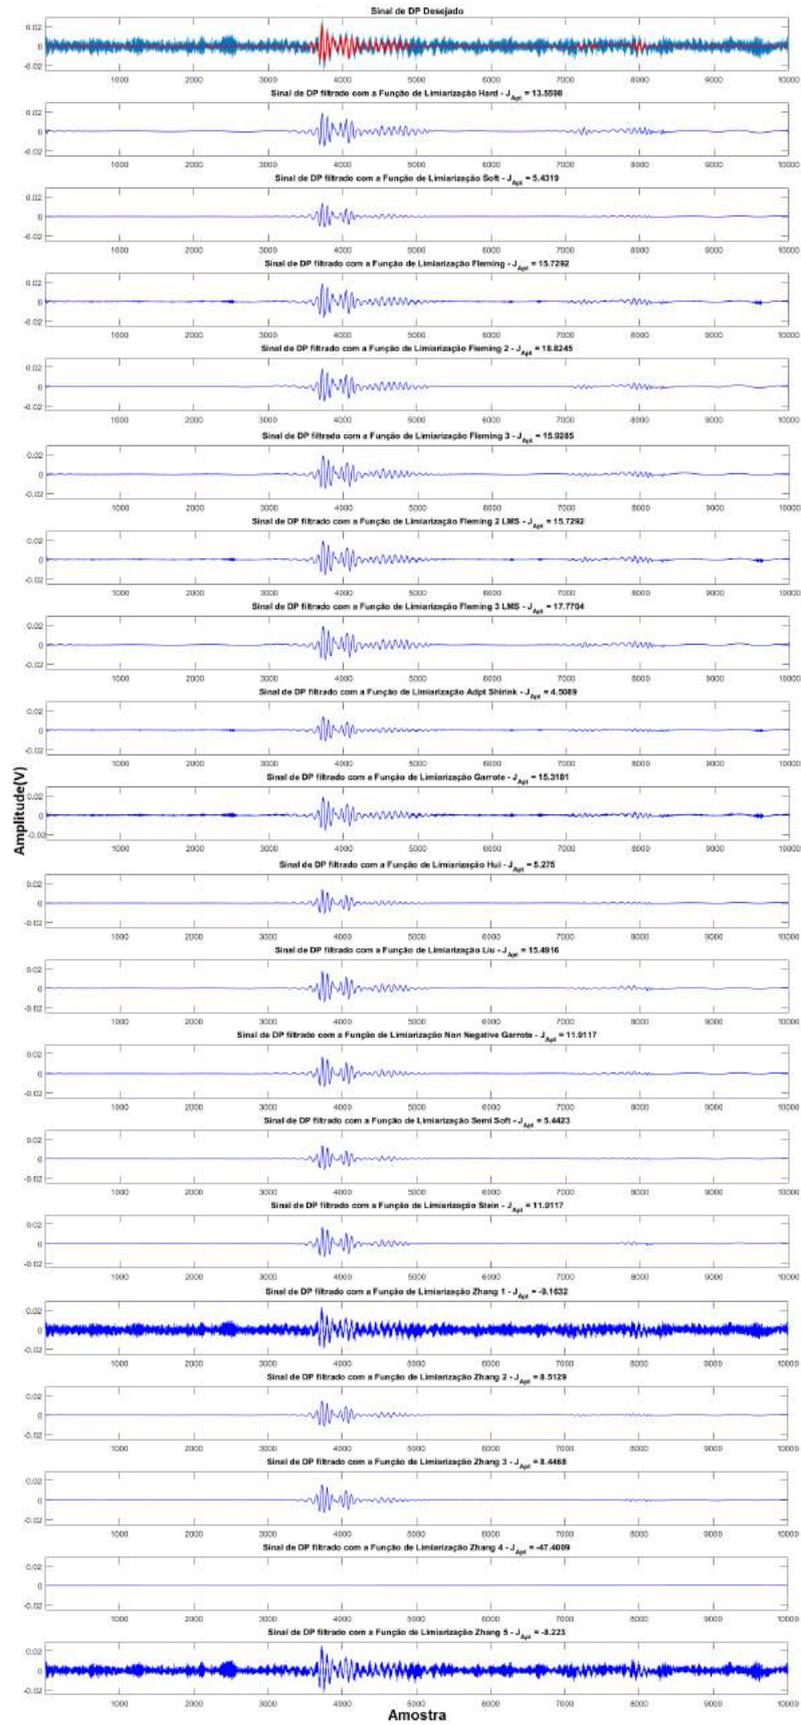


Figura 8.15: Exemplo 2 de filtragem wavelet para as diferentes funções de limiarização em um sinal de DP medido.

8.3 Avaliação das Funções Wavelet

Aproveitando o estudo feito com as funções de limiarização decidimos avaliar como a mudança das funções wavelet (wavelet mães) aplicadas na redução de coeficientes de ruído em sinais de DP poderia afetar os valores médios dos parâmetros de avaliação em cada um dos métodos de limiarização mostrados na Subseção 8.2.3. Desta forma, podemos complementar a análise do processamento wavelet e determinar qual é a melhor biblioteca de funções wavelet que devemos entregar ao método de seleção SNRBWS [33], [35], [67], [68].

No Capítulo 3, mostramos as WM que poderiam ser adotadas para tratar pulsos de DP, sendo estas pertencentes à família: *Daubechies* (ordem 1 a 45), *Symlets* (ordem 1 a 20), *Coiflets* (ordem 1 a 5), *Legendres* (ordem 1 a 9) e *Discrete Meyer* (sem ordem). Desse modo, optamos por formar as seguintes bibliotecas:

1. *Daubechies* - Db1 a Db45;
2. *Symlets* - Sym1 a Sym20;
3. *Coiflets* - Coif1 a Coif5;
4. *Legendre* - Legd1 a Legd9;
5. *Daubechies* e *Symlets* - Db1 até Db45 e Sym1 a Sym20;
6. *Daubechies*, *Symlets* e *Coiflets* - Db1 até Db45, Sym1 a Sym20 e Coif1 a Coif5;
7. *Daubechies*, *Symlets*, *Coiflets*, *Legendre* e *Discrete Meyer* - Db1 a Db45, Sym1 a Sym20, Coif1 a Coif5, Legd1 a Legd9 e Dmey;

Para uma apresentação mais compacta dos resultados consideramos apenas o critério de aptidão J_{Apt} . A Tabela 8.8 mostra que aplicar uma biblioteca contendo apenas as wavelets da família *Daubechies* produz os maiores valores de aptidão para várias das funções de limiarização, fornecendo uma média total de -6,6194. A família *Symlets* também mostra uma boa performance para filtragem com -6,9532 de média total. Na formação de uma biblioteca de funções wavelet podemos dizer que o mais adequado é empregar uma única família e não agrupar várias destas.

Vale destacar que todas as análises que realizamos na Seção 8.2 foram conduzidas com uma biblioteca formada pelas famílias *Daubechies*, *Symlets* e *Coiflets*. Para verificarmos o comportamento das diferentes bibliotecas com as funções de limiarização desenvolvidas decidimos analisar a quantidade de melhores resultados de aptidão (em percentual) obtidos para cada função usando as bibliotecas de WM descritas, conforme ilustra a Figura 8.16. No geral, apesar da mudança da biblioteca

Tabela 8.8: Comparação entre Diferentes Bibliotecas de Funções Wavelet Empregadas na Decomposição dos Sinais de DP.

Função de Limiarização	Biblioteca de Funções Wavelet						
	Db	Sym	Coif	Legd	Db e Sym	Db, Sym e Coif	Db, Sym, Coif, Legd e Dmey
Hard	2,1586	2,6712	-1,4999	-4,4407	0,7388	0,8840	-16,6978
Soft	-7,5352	-8,9580	-8,0497	-8,5640	-8,4590	-8,8575	-19,1807
Fleming	3,3764	3,2498	1,2758	1,6766	2,4867	2,7105	-6,1880
Fleming 2	2,5532	2,6768	-0,9675	-4,0601	1,1205	1,3350	-16,1569
Fleming 3	4,4523	3,3865	0,9153	0,3619	2,0875	2,2428	-10,0969
Fleming 2 LMS	2,1037	2,1993	-1,8727	-4,4362	0,4789	0,3709	-14,3903
Fleming 3 LMS	3,8468	-2,8356	-0,0735	-0,4013	1,3000	1,5290	-9,4529
Adapt Shrink	-4,2005	-5,0933	-5,2419	-5,2708	-5,2974	-4,5092	-12,1472
Garrote	1,6365	1,3317	0,0179	0,3295	0,8300	1,0768	-278,4640
Hui	-9,6913	-11,0717	-10,2824	-10,6652	-10,5279	-10,8325	-20,2150
Liu	1,0085	0,6545	-0,5685	-1,5342	-0,6957	-0,5486	-13,6523
N. Garrote	-2,1141	-2,7476	-2,7971	-3,9322	-3,3641	-3,4787	-15,0465
Semi Soft	-7,5240	-8,9453	-8,0391	-8,5546	-8,4470	-8,8392	-19,1733
Stein	-2,1141	-2,7476	-2,7971	-3,9322	-3,3641	-3,4787	-15,0465
Zhang 1	-10,5980	-10,7611	-10,8264	-10,9237	-10,9076	-10,5567	-17,0678
Zhang 2	-4,5614	-5,3996	-4,9366	-5,5169	-5,3289	-4,9325	-14,8469
Zhang 3	-37,2457	-28,9272	-55,4605	-45,1315	-90,1322	-90,2453	-72,7951
Zhang 4	-47,1905	-46,5539	-46,3572	-47,2289	-47,6204	-48,2714	-51,6086
Zhang 5	-14,1306	-14,2397	-14,4022	-14,3785	-14,1774	-14,2188	-17,8593
MÉDIA TOTAL	-6,6194	-6,9532	-9,0507	-9,2949	-10,4884	-10,4537	-33,6887

wavelet produzir resultados de melhor filtragem relativamente equilibrados para os métodos de limiarização, é possível afirmar que a família de wavelets *Daubechies* são as mais adequadas para as funções Fleming. Observação esta que se mostra de acordo com a avaliação mostrada na Tabela 8.8.

Diversas publicações a respeito de tratamento de ruído por WT já têm usado as wavelets da Família *Daubechies* e *Symlets* [10], [12], [41], [67], [68], mas até então não havia sido demonstrado experimentalmente a superioridade destas em relação às demais alternativas. Com esta avaliação confirmamos a hipótese de que elas são as mais indicadas para tratar sinais de DP, devido as suas propriedades e formatos similares aos de um pulso.

Outra vantagem de utilizar bibliotecas com uma única família é que estas são processadas mais rapidamente pelos métodos de seleção das funções wavelet para cada sub-banda decomposta, como é o caso do método SNRBWS que empregamos.

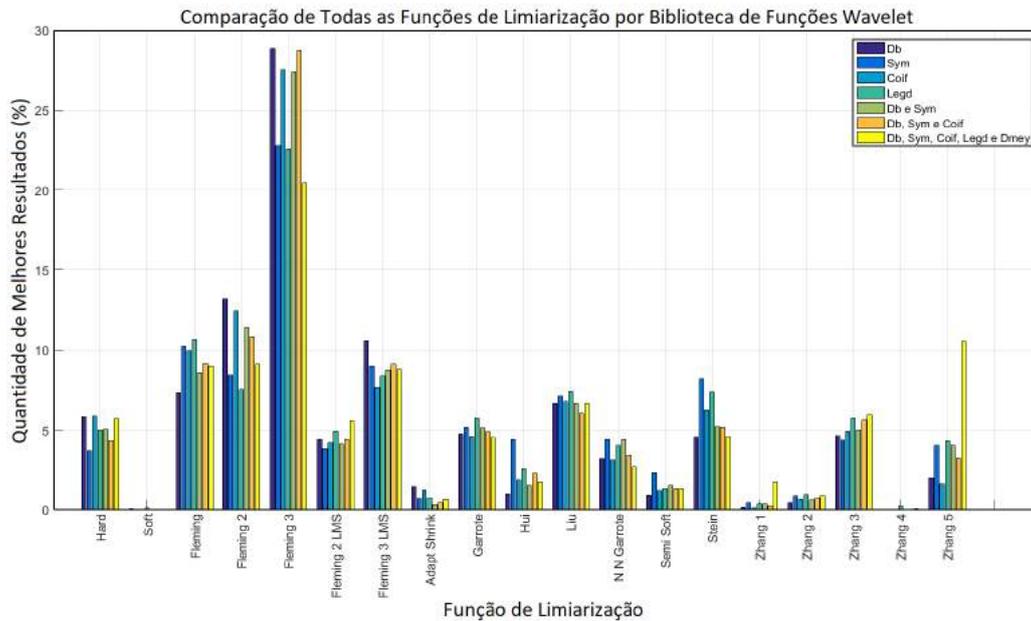


Figura 8.16: Comparação de resultados de melhor filtragem obtida para diferentes bibliotecas wavelet com cada função de limiarização.

8.4 Resultados da Nova Técnica de Identificação de Polaridade de Pulsos

No Capítulo 6 desenvolvemos um novo algoritmo para obter uma melhor identificação da real polaridade dos pulsos de DP. Para determinar a capacidade deste método em gerar mapas PRPD mais fidedignos e, conseqüentemente, possibilitar a melhora no diagnóstico do equipamento de alta tensão sob teste, mostraremos alguns exemplos comparando os mapas construídos a partir do método usual de primeiro cruzamento de LD com os construídos utilizando a técnica proposta. Ademais, mostraremos alguns pulsos pontuais dos mapas para averiguar se o método realmente consegue corrigir algum pulso que tenha sido erroneamente designado com o método tradicional.

De início, considere o caso de uma medição feita em um gerador. Na Figura 8.17(a) ilustramos o PRPD formado com o uso do método tradicional de medição, veja que tanto no semiciclo positivo quanto negativo, temos muitos pulsos identificados como positivos e negativos. Ao aplicar nosso algoritmo de identificação obtivemos o mapa na Figura 8.17(b). Repare que houve uma modificação significativa no dado apresentado, o qual parece ser bem mais condizente com um padrão de medição esperado. Confirmamos que os pulsos realmente tiveram sua polaridade corrigida avaliando diversos dos pontos medidos e verificando as respectivas formas

de onda. A título de exemplo exibimos na Figura 8.18(a) um ponto aparentemente negativo selecionado no PRPD tradicional, mas vê-se que a forma de onda correspondente a este é, na verdade, a de um pulso positivo, o qual foi devidamente corrigido após aplicarmos o novo algoritmo, conforme já visto na Figura 8.17(b). Na Figura 8.18(c) é selecionado um pulso negativo no mapa corrigido e verifica-se que sua forma de onda é realmente a de um pulso negativo, portanto, o método proporcionou uma melhora efetiva na apresentação dos dados.

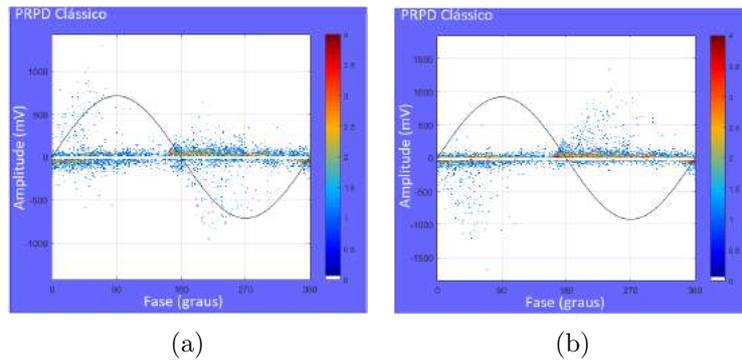


Figura 8.17: Comparação entre mapas PRPD obtidos na medição de um gerador: (a) gerado pelo método tradicional de identificação de polaridade; (b) gerado pelo novo método de identificação de polaridade.

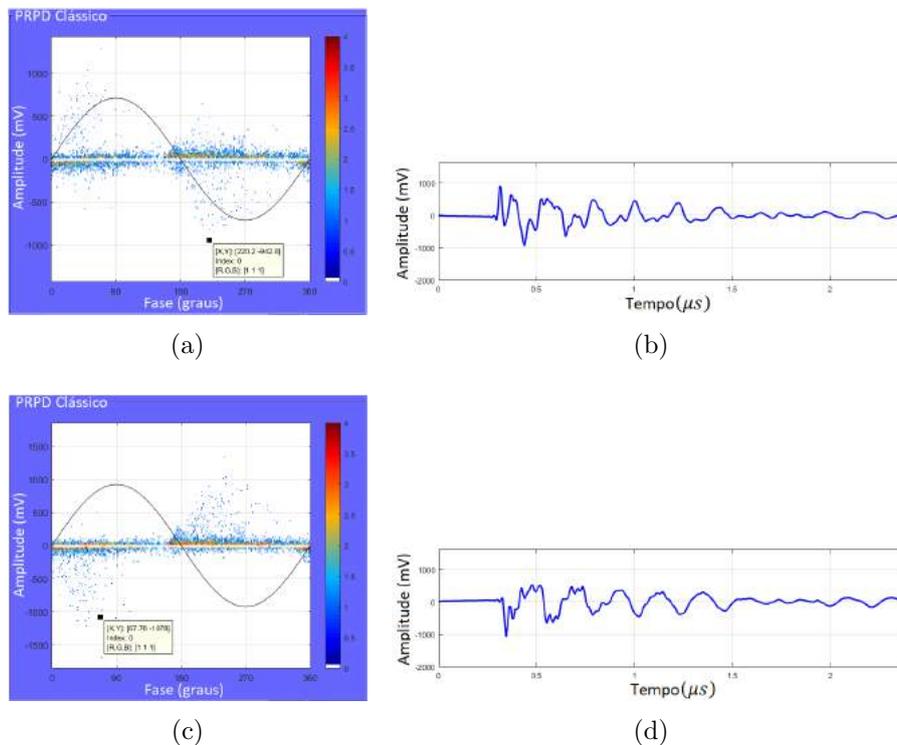


Figura 8.18: Verificação de pulsos: (a) pulso selecionado no PRPD usando o método tradicional; (b) pulso negativo erroneamente atribuído como positivo pelo método tradicional; (c) pulso selecionado no PRPD gerado pelo novo método; (d) pulso negativo corretamente atribuído como negativo pelo novo método.

A Figura 8.19 mostra a comparação no mapa PRPD resultante aplicando o método tradicional e o novo método de identificação, os quais foram obtidos de uma medição de DP realizada num gerador. Na Figura 8.19(a) é mostrado o PRPD gerado pela técnica usual de identificação. Veja que no semiciclo positivo alguns pulsos foram mostrados como pontos positivos, enquanto que a grande maioria dos pulsos neste semiciclo aparecem como pontos negativos; uma observação análoga pode ser feita também para o semiciclo negativo. Ao usar a nova técnica de identificação de polaridade, foi gerado o PRPD mostrado na Figura 8.19(b) e, apesar de não ter havido uma mudança tão expressiva, note no semiciclo positivo que pulsos anteriormente identificados como positivos agora foram designados como negativos e que o mapa se mostra mais bem definido. Para mostrar que houve uma melhoria, veja a Figura 8.20(a), onde selecionamos um dos pontos inicialmente identificado como pulso positivo e mostramos sua forma de onda na Figura 8.20(b), percebe-se que na verdade se trata de um pulso negativo, i.e., foi erroneamente identificado com o uso da metodologia clássica e, portanto, o mapa mostrado na Figura 8.19(b) realmente trouxe alguma melhora pois corrigiu a polaridade deste pulso. No entanto, infelizmente o novo método também está sujeito a erros de identificação, ainda que em menor quantidade se comparado ao tradicional, conforme mostra a Figura 8.20(c), na qual selecionamos um pulso atribuído como positivo no novo mapa e ao verificar sua forma de onda na Figura 8.20(d) temos, na verdade, um pulso negativo.

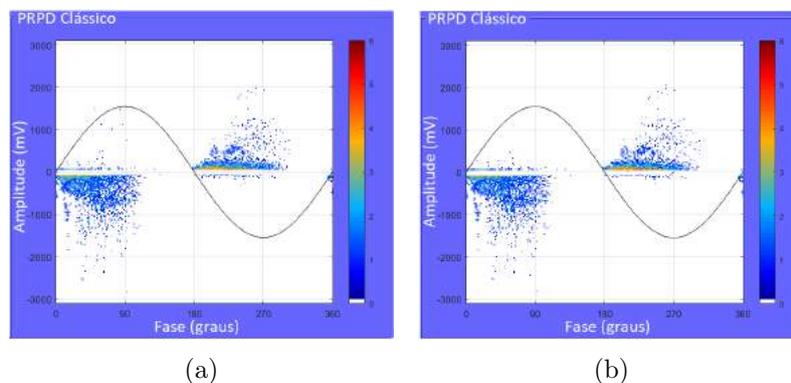
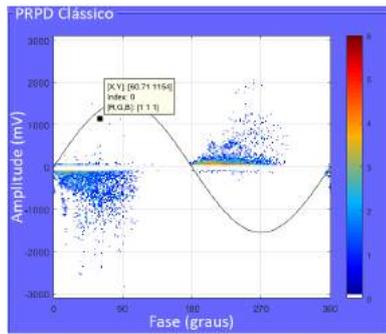
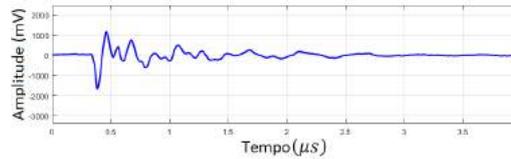


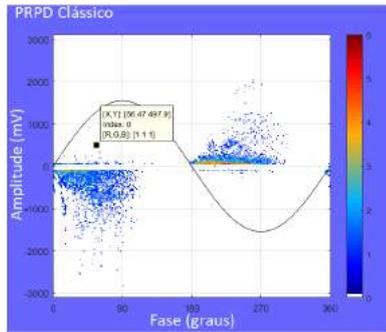
Figura 8.19: Comparação entre mapas PRPD obtidos na medição de um gerador: (a) gerado pelo método tradicional de identificação de polaridade; (b) gerado pelo novo método de identificação de polaridade.



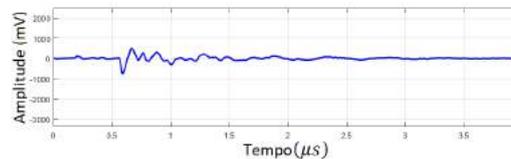
(a)



(b)



(c)



(d)

Figura 8.20: Verificação de pulsos: (a) pulso selecionado no PRPD usando o método tradicional; (b) pulso negativo erroneamente atribuído como positivo pelo método tradicional; (c) pulso selecionado no PRPD gerado pelo novo método; (d) pulso negativo erroneamente atribuído como positivo pelo novo método .

Para uma medição de DP feita numa UHE vista na Figura 8.21(a), observe que nos semiciclos positivo e negativo do PRPD tradicional temos pulsos com polaridade tanto positiva quanto negativa e, ao que parece, podem haver erros na identificação destes. Após aplicar a nova técnica obtivemos o mapa mostrado na Figura 8.21(b), o qual novamente se mostra muito mais coerente e bem definido. Para confirmar a correção da polaridade dos pulsos verificamos na Figura 8.22(a) que o pulso aparentemente positivo selecionado no PRPD usual possui forma de onda com polaridade negativa, conforme ilustrado na Figura 8.22(b). E após a correção, selecionamos no mapa um ponto negativo, o qual realmente corresponde a uma forma de onda com polaridade negativa. Portanto, o algoritmo consegue melhorar o dado apresentado e permitir um diagnóstico mais adequado do equipamento.

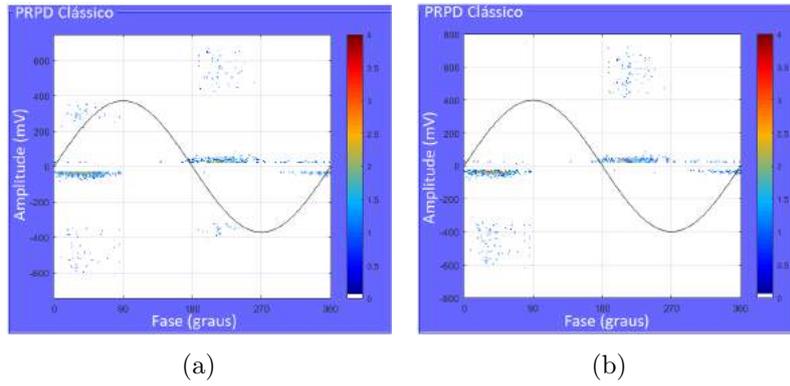


Figura 8.21: Comparação entre mapas PRPD obtido na medição de um gerador: (a) gerado pelo método tradicional de identificação de polaridade; (b) gerado pelo novo método de identificação de polaridade.

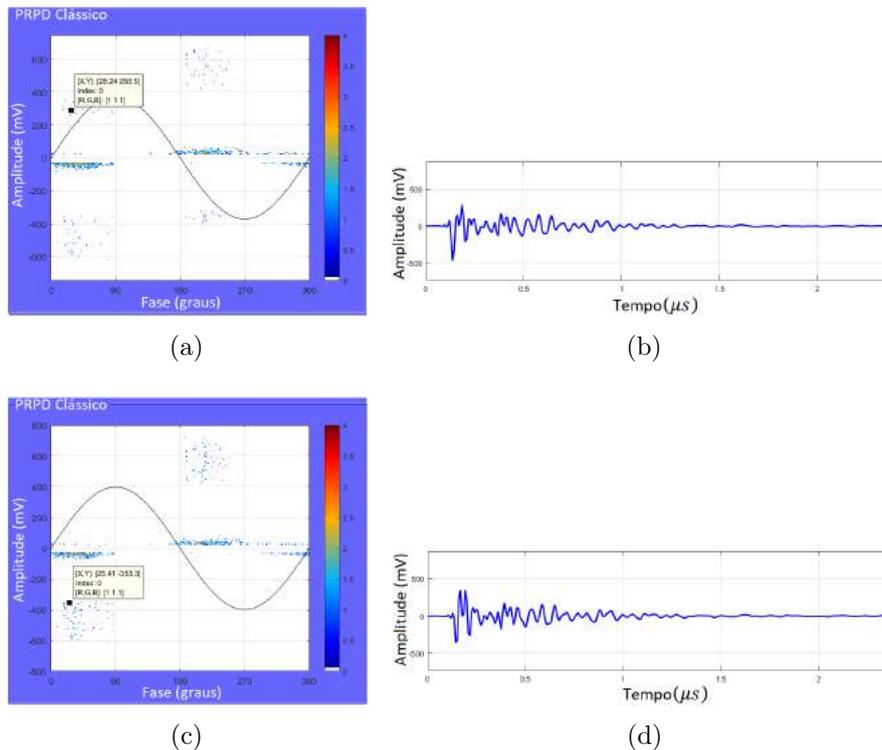


Figura 8.22: Verificação de pulsos: (a) pulso selecionado no PRPD usando o método tradicional; (b) pulso negativo erroneamente atribuído como positivo pelo método tradicional; (c) pulso selecionado no PRPD gerado pelo novo método; (d) pulso negativo corretamente atribuído como negativo pelo novo método.

Fica, então, demonstrada a capacidade de correção do novo método de identificação de polaridade, ainda que este não seja perfeito e possa identificar erroneamente alguns poucos pulsos, em comparação com o método que normalmente é aplicado na literatura conhecida temos uma melhora considerável na apresentação

de dados de algumas medições que, devido ao formato do pulso, acabam por provocar erros consideráveis no PRPD tradicional. Também existirão casos em que ao aplicar o método de correção de polaridade não haverá alterações tão importantes, como ocorreu para a medição mostrada na Figura 8.19, pois os pulsos podem possuir um formato que facilita a correta identificação de sua polaridade, produzindo um PRPD com características bem definidas.

8.5 Validação do Método de Estimativa da Resposta em Frequência do Sistema Medido

A validação do método de estimativa da resposta em frequência do sistema sob medição dependeria de conhecermos a função de transferência desse mesmo sistema para que pudéssemos compará-la com a resposta em frequência fornecida através da metodologia desenvolvida na Seção B.4.8. Devido à impossibilidade de se determinar tal função de transferência em medições realizadas em campo, a solução encontrada foi fazer um ensaio em laboratório onde pudemos medir a resposta em frequência desde o objeto ensaiado até a entrada do *hardware* de aquisição usado, no caso um osciloscópio de 2 canais.

Como objeto de ensaio utilizou-se uma barra estatórica (tensão nominal 13,8 kV), conforme a Figura 8.23. O circuito de medição empregado é o mesmo mostrado no Apêndice A, contendo filtro na saída da fonte de alta tensão um capacitor de acoplamento impedância resistiva ($2\text{ k}\Omega$) e cabo coaxial de 4.60 m de comprimento que conduz o sinal até um filtro PA (opcional) que por sua vez está ligado em um dos canais do osciloscópio por um cabo de 1.05 m.



Figura 8.23: Barra estatórica ensaiada em laboratório.

Inicialmente simulamos o circuito no *software* Multisim. Para tanto, considerou-se o cálculo aproximado de parâmetros distribuídos (por metro) do cabo

coaxial por meio de um programa desenvolvido no LabVIEW com as equações necessárias extraídas de [190], como mostra a Figura 8.24.

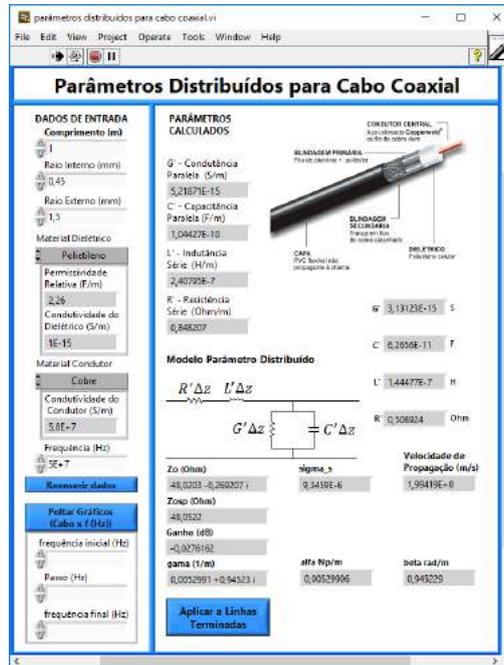


Figura 8.24: Programa em LabVIEW para cálculo a parâmetros distribuídos em cabos coaxiais.

O circuito completo simulado é mostrado na Figura 8.25 tanto com uso de filtro PA ($F_c = 300$ kHz) quanto sem o mesmo, e observe que também consideramos a impedância de entrada dos canais do osciloscópio, de acordo com a especificação do equipamento.

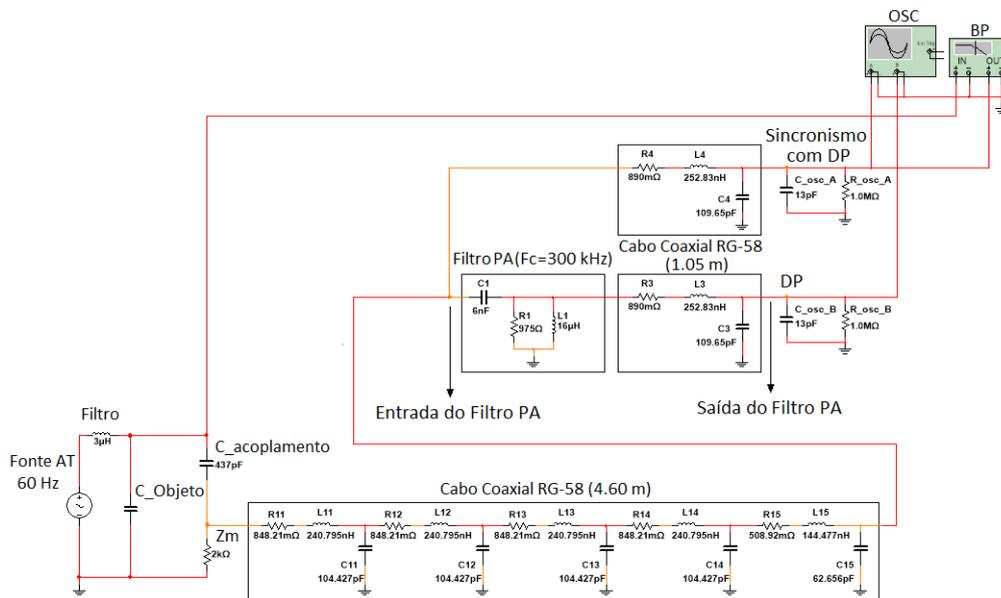


Figura 8.25: Circuito de medição de DP aplicado em laboratório.

Ao simular ambos os circuitos obtivemos as respostas em frequência correspondentes a cada canal, conforme as Figura 8.26(a) e (c). Note a existência de pontos de ressonância e antirressonância nas frequências mais altas, as quais são geradas pelos cabos coaxiais necessários para a medição dos pulsos. Na Figura 8.26(c) atente ao efeito de uma antirressonância na frequência de 512 kHz: a mesma só ocorre devido ao Filtro PA acoplado ao circuito. Tal efeito na RF pode ser evitado se a medição for feita usando apenas a impedância (com o Filtro PA retirado do circuito), como mostra o resultado da simulação ilustrado na Figura 8.27. Uma informação à parte que podemos extrair do diagrama de fase na Figura 8.26(d) é que, para frequências mais baixas, o sinal de referência AC 60 Hz é defasado aproximadamente de 90° pelo circuito de medição, e se fosse tomado depois do filtro seria defasado em -90° (270°). Por isso implementamos a opção de defasagem no sistema de análise e separação de DP descrito no Capítulo 7. Portanto, ao aplicarmos a técnica de estimativa da RF, esperamos encontrar algo similar ao que se vê nas Figuras 8.26(a) e (c) e Figuras 8.27 para cada caso considerado.

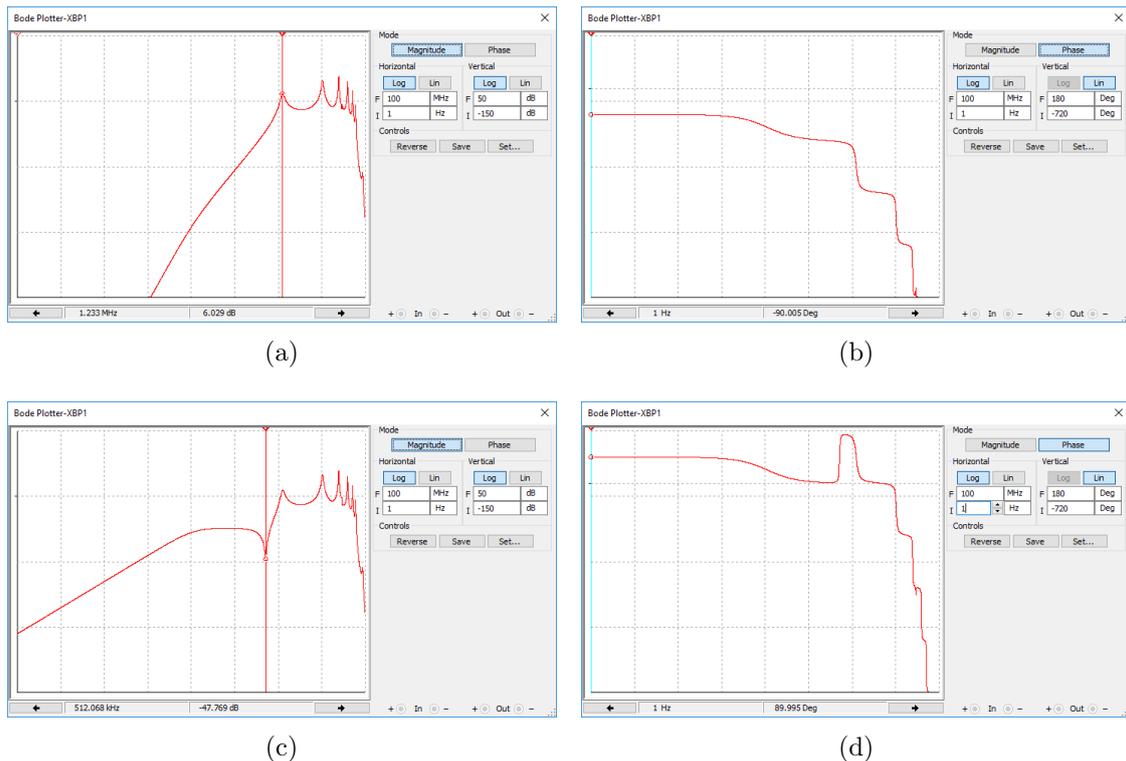


Figura 8.26: Circuito de medição de DP com impedância e filtro PA: (a) Bode de módulo saída DP; (b) Bode de fase saída DP; (c) Bode de módulo saída sincronismo com DP ; (d) Bode de fase saída sincronismo com DP.

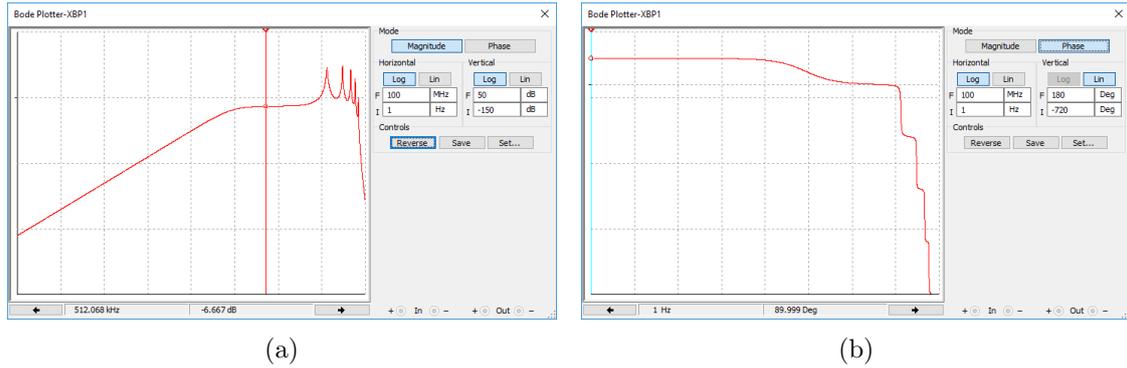


Figura 8.27: Circuito de medição de DP com impedância (filtro PA foi retirado do circuito mostrado na Figura 8.25) e cabo coaxial com 4.60 m de comprimento: (a) Bode de módulo; (b) Bode de fase.

Além da simulação, também verificou-se a RF real do circuito, que pode diferir um pouco do circuito simulado, já que não conseguimos levar em conta todas as possíveis alterações que podem ser ocasionadas por variações dos componentes aplicados, conexões, precisão nas medidas dos cabos, entre outras variáveis não computadas. Esta medição pode ser feita de dois modos: aplicando um sinal conhecido de tensão senoidal na entrada (terminais de alta e de terra da barra medida), medir a tensão de saída e calcular a relação entre as mesmas; ou com o uso do mesmo princípio da técnica de estimativa, em que são aplicados impulsos diversos que abrangem uma determinada faixa de frequência e utilizar a função *hold* FFT disponível no próprio *software* do osciloscópio para determinar a RF do sistema. No experimento, estes impulsos foram aplicados usando um gerador de formas de onda arbitrárias (integrado ao osciloscópio) e um calibrador de DP.

Optamos pela última alternativa, em que inserimos os impulsos na barra de duas maneiras: uma com o calibrador que é usado nas medições de DP e emite pulsos que simulam descargas, podendo ser variado em amplitude e polaridade (entretanto, com a desvantagem de atuar em uma faixa de frequência não muito ampla); então, decidimos usar o gerador de sinais existente no *hardware* de medição para injetar impulsos que podem ser facilmente controlados para atingir uma banda de frequência mais extensa. Esta alternativa também serve como uma comprovação direta da possibilidade de se obter a RF do circuito apenas usando impulsos que simulam sinais de DP.

O pulso criado usando o gerador de formas de onda arbitrário é mostrado na Figura 8.28, o mesmo pode ser repetido com a frequência desejada (limitada em no máximo 20 MHz). A Figura 8.29 mostra os pulsos medidos pelos canais do osciloscópio, que recebem os sinais de entrada e de saída do Filtro PA. Constatamos

se a presença de dois padrões de pulsos, um de maior amplitude proveniente do calibrador (numa frequência de repetição de 60 Hz) e outro de menor amplitude que vem do gerador de formas de onda arbitrário do *hardware* de aquisição.

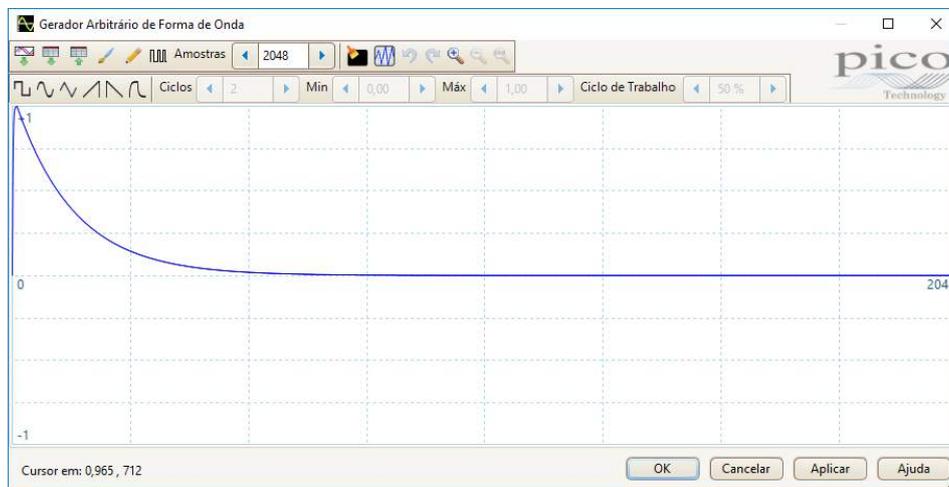


Figura 8.28: Pulso de DP simulado no gerador de formas de onda arbitrárias.

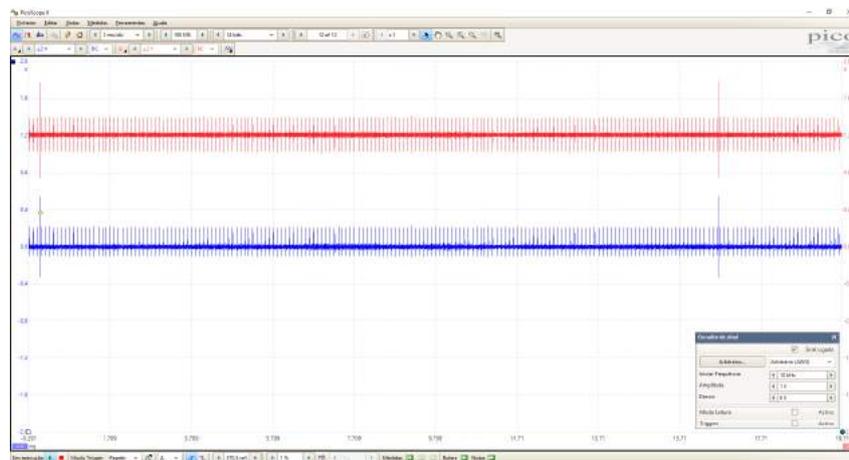


Figura 8.29: Pulsos medidos no canais A (azul) e B (vermelho) do osciloscópio.

Usando o analisador de espectro do próprio *software* do osciloscópio, fizemos a medição da RF do sistema para os dois canais na banda de 1 kHz até 62.5 MHz, conforme a Figura 8.30. Se compararmos a resposta da Figura 8.30(a) e (b) com as respostas da Figura 8.26(b) e (c), que mostram o comportamento na saída do filtro e na saída da impedância de medição, respectivamente, quando consideramos uma escala de ganho normalizada é possível identificar uma grande semelhança no formato das RF simuladas com as medidas, principalmente nas ressonâncias proporcionadas pelo filtro combinado com a impedância em 1.25 MHz também existe o mesmo efeito de antirressonância em torno de 512 kHz para a RF na entrada do filtro PA (saída da impedância).

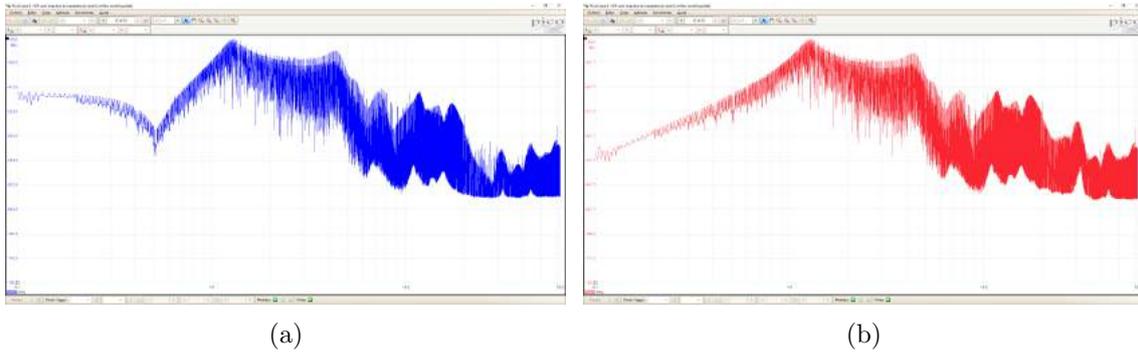


Figura 8.30: Resposta em frequência real do circuito: (a) para a saída da impedância; (b) para a saída do filtro PA.

Já a Figura 8.31 exibe a RF obtida para o circuito sem considerar o uso do Filtro de PA e, novamente, se compararmos este resultado com o mostrado na Figura 8.27 percebemos que a antirressonância em 512 kHz desaparece. Já nas frequências mais altas, verificam-se algumas diferenças nos pontos exatos de ocorrência das ressonâncias e antirressonâncias. Isso acontece porque é difícil prever todas as variáveis envolvidas no processo, por exemplo, como simular a estrutura de uma barra de gerador ou como considerar a configuração dos parâmetros distribuídos, que no caso do cabo optamos por considerar cada metro (de cabo) como um elemento concentrado para não estendermos o tamanho do circuito mostrado na Figura 8.25. Além disso, não podemos garantir que a amplitude do pulso criado pelo gerador de sinais do Picoscope se manterá linear sem quaisquer perdas nas frequências mais altas.

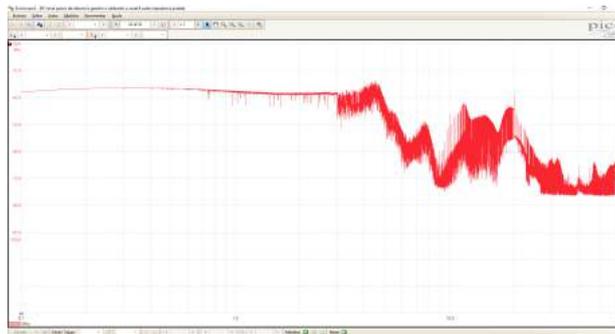
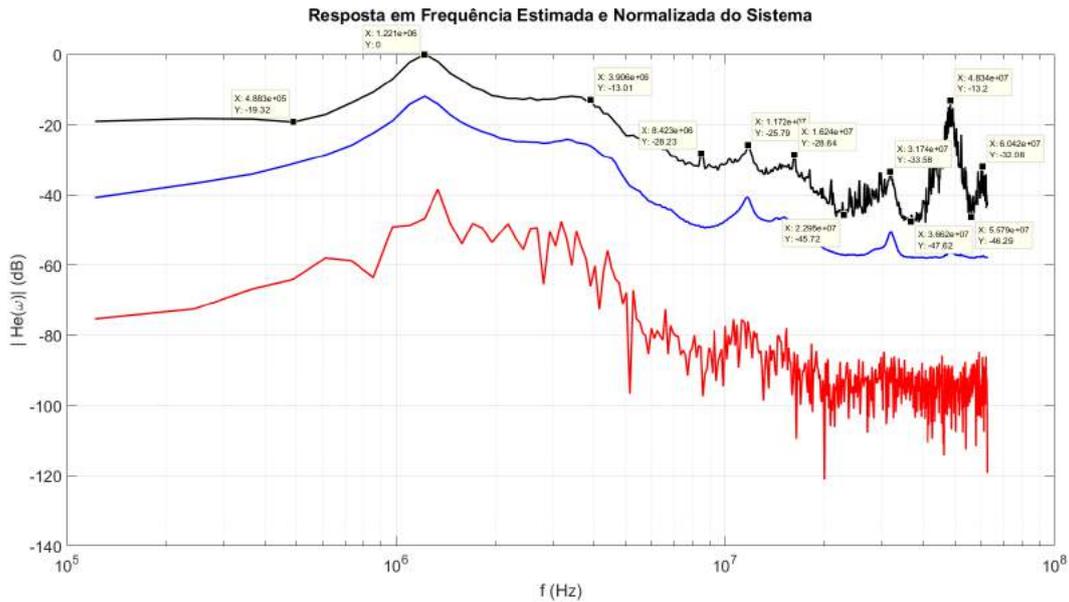


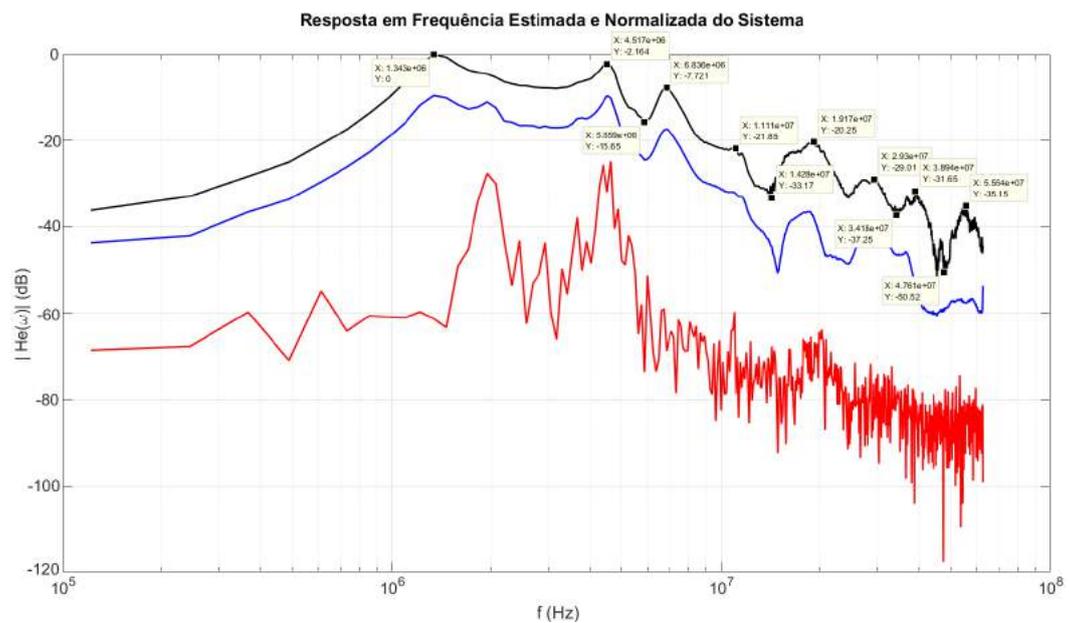
Figura 8.31: Resposta em frequência real do circuito para a saída da impedância sem ter o filtro PA acoplado.

Por último, usando o novo método proposto, analisamos a RF estimada e normalizada para pulsos de DP aquisitados numa medição feita na mesma barra estatórica submetida a uma tensão de 18 kV durante 120 ciclos. Primeiro mostramos na Figura 8.33(a) e (b) os resultados para a entrada e saída do filtro PA, respectivamente. Observe que temos três linhas, sendo que a preta representa a RF estimada

pela retenção dos valores de máximo, a azul representa a média e a vermelha a retenção de valores mínimos de cada pulso detectado durante a medição. Ao comparar as RF estimadas com as RF medidas diretamente, vide na Figura 8.30(a) e (b), percebemos as similaridades entre o formato das RF, principalmente nos pontos de frequência de ressonância e antirressonância. Também avaliamos o caso em que a medida é tomada sem ter o filtro PA acoplado ao circuito, conforme exibido na Figura 8.33. Comparando com o resultado da Figura 8.31, novamente nota-se a semelhança entre as RF obtidas.



(a)



(b)

Figura 8.32: Resposta em frequência real do circuito: (a) saída da impedância com o filtro PA acoplado; (b) saída do filtro PA.

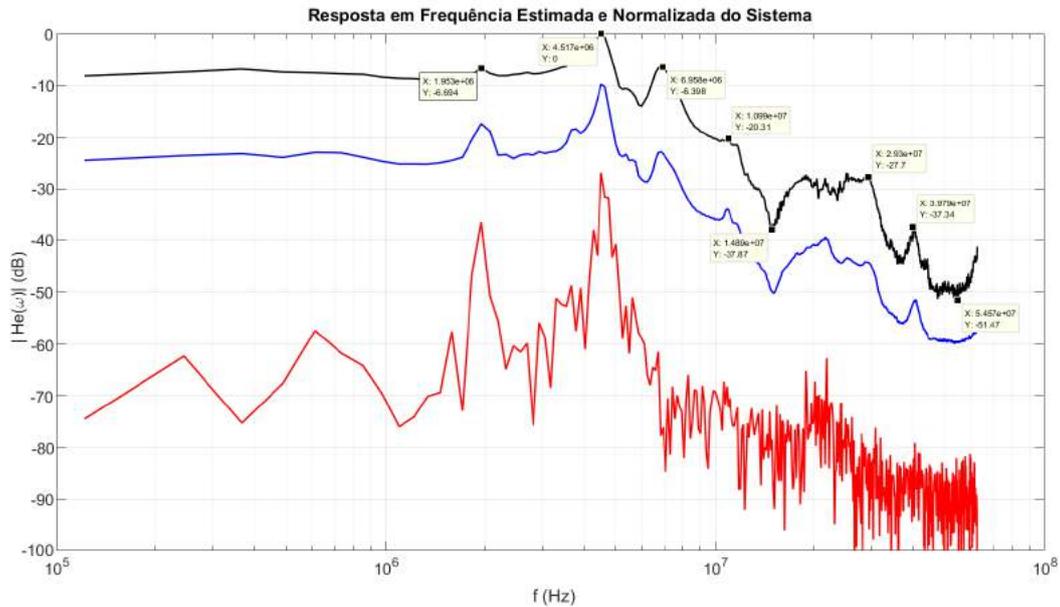


Figura 8.33: Resposta em frequência real do circuito para a saída da impedância sem ter o filtro PA acoplado.

Portanto, com base nos resultados mostrados, conclui-se que é possível utilizar os próprios pulsos de DP para encontrar uma boa estimativa do formato da RF do sistema sob análise. Esta estimativa da RF pode ser útil para: identificar a banda de frequência de maior ocorrência dos pulsos medidos, podendo auxiliar na medição do equipamento avaliado; estimar os pulsos originais ocorrendo dentro do isolante do equipamento como foi mostrado no Capítulo 7, o que possibilita uma melhor estimativa da carga real (em picocoulombs) de cada pulso; para verificar se os padrões separados pelo sistema de análise e separação de dados pertencem a classes diferentes. No entanto, é importante considerar que é necessária que uma quantidade expressiva de pulsos sejam detectados durante a medição para que a estimativa obtida represente com boa fidelidade a RF real do sistema medido.

8.6 Avaliação do Sistema de Análise e Separação de Dados de Descargas Parciais

O sistema de análise e separação de dados de DP foi criado com intuito de auxiliar num diagnóstico mais preciso das condições do isolante de um equipamento de alta tensão. Para isso, o sistema engloba um conjunto de ferramentas destinadas ao processamento e tratamento dos dados obtidos numa medição para sua adequada exibição ao usuário. Vamos demonstrar como essas ferramentas podem ser aplicadas para a correta análise dos sinais de DP (retirados do banco de dados descrito na Seção

8.1). Por questões práticas seria inadequado avaliar todos os dados de que dispomos no banco criado, assim sendo focaremos em alguns exemplos mais relevantes para a compreensão da utilidade do sistema proposto neste trabalho.

Como primeira abordagem, utilizamos o sistema criado para avaliar o tempo de processamento de cada um dos métodos de extração de características para 20 medições distintas com 60 ciclos, contemplando avaliações em laboratório e em campo. Dividimos a avaliação em dois grupos com 10 medições, sendo um contendo menos de 1000 pulsos detectados e outro entre 1000 e 10000 pulsos.

Os resultados para o primeiro grupo de medições são mostrados na Tabela 8.9. Constata-se que a maioria dos métodos de extração são bem rápidos, levando menos de 3 segundos para serem executados. O mais rápido foi o método Tempo x Frequência, levando apenas 0,068 s para extrair a característica. No entanto, alguns métodos se mostraram bem lentos, como é o caso da extração por PCA Exponencial, PCA Probabilística, PCA da FFT Exponencial, PCA da FFT Probabilística, Power Ratio, MDS Análise Fatorial, MDS Sammon Mapping e MDS SPE, em que o mais lento destes foi a PCA Exponencial em 3D com tempo de processamento de 207,433 s. Se desejássemos avaliar cada uma das características para medições contendo poucos pulsos detectados, o tempo total médio de execução de todos os métodos seria 662,882 s, aproximadamente 11 min.

Tabela 8.9: Tempo Médio dos Métodos de Extração de Características para Medições com Menos de 1000 Pulsos Detectados.

Método	Tempo de Extração (s)	Método	Tempo de Extração (s)
Tempo x Frequência	0,068	Power Ratio	74,420
Parâmetros Weibull	1,728	t-SNE 2D	0,236
NACF	0,327	t-SNE 3D	0,177
PCA 2D Simples	1,136	MDS 2D - Diffusion Map	0,513
PCA 2D Kernel (Clássica)	1,707	MDS 2D - Análise Fatorial	21,913
PCA 2D Kernel (Gaussiana)	1,698	MDS 2D - GDA	1,457
PCA 2D Exponencial	107,022	MDS 2D - Landmark Isomap	2,682
PCA 2D Probabilística	13,735	MDS 2D - LDA Algorithm	1,124
PCA 3D (Clássica)	0,773	MDS 2D - LPP	0,471
PCA 3D Kernel (Clássica)	2,392	MDS 2D - NPE	0,746
PCA 3D Kernel (Gaussiana)	2,395	MDS 2D - Sammon Mapping	22,708
PCA 3D Exponencial	207,433	MDS 2D - SPE	3,902
PCA 3D Probabilística	27,963	MDS 3D - Diffusion Map	0,446
PCA FFT 2D (Clássica)	0,557	MDS 3D - Análise Fatorial	18,502
PCA FFT 2D Kernel (Clássica)	1,5302	MDS 3D - GDA	1,359
PCA FFT 2D Kernel (Gaussiana)	1,592	MDS 3D - Landmark Isomap	2,897
PCA FFT 2D Exponencial	42,34	MDS 3D - LDA Algorithm	1,040
PCA FFT 2D Probabilística	8,500	MDS 3D - LPP	0,381
PCA FFT 3D (Clássica)	0,471	MDS 3D - NPE	0,637
PCA FFT 3D Kernel (Clássica)	1,375	MDS 3D - Sammon Mapping	25,889
PCA FFT 3D Kernel (Gaussiana)	1,440	MDS 3D - SPE	4,242
PCA FFT 3D Exponencial	42,387	Tempo Total	662,882
PCA FFT 3D Probabilística	8,571		

Na Tabela 8.10 são informados os tempos médios dos algoritmos de extração de características para medições com um grande número de pulsos detectados. Veja que, novamente, o algoritmo de Tempo x Frequência foi o mais rápido e o PCA 3D Exponencial o mais lento, mas neste caso os tempos de processamento de todos os métodos são bem maiores que os tempos mostrados na Tabela 8.9. Além disso, a diferença dos tempos de um método para outro são bem maiores, tanto que desta vez somente 6 métodos levam menos de 3 s para serem executados (Tempo x Frequência, NACF, PCA 2D Clássica, PCA da FFT 2D Clássica, PCA 3D Clássica e PCA da FFT 3D Clássica, MDS LDA e MDS LPP), ou seja, o tempo de processamento para medições com muitos pulsos se eleva de forma não linear, podendo

levar tempo demais para gerar o resultado sem a garantia de que este seja superior aos demais. O tempo médio total para extrair todas as características foi de 3137,571 s, algo próximo de 52 min o que é quase 5 vezes o tempo médio gasto com as medições contendo menos de 1000 pulsos. Portanto, em se tratando de medições com muitos pulsos, devemos dar preferência pelos métodos mais rápidos (e.g, Tempo x Frequência, PCA clássica e suas variantes, MDS LDA e MDS LPP) e caso o resultado não seja satisfatório, podemos investigar os outros que têm um maior custo de processamento.

Tabela 8.10: Tempo Médio dos Métodos de Extração de Características para Medições com Mais de 1000 Pulsos Detectados.

Método	Tempo de Extração (s)	Método	Tempo de Extração (s)
Tempo x Frequência	0,138	Power Ratio	57,424
Parâmetros Weibull	3,946	t-SNE 2D	208,805
NACF	1,397	t-SNE 3D	215,344
PCA 2D Clássica	1,394	MDS 2D - Diffusion Map	11,167
PCA 2D Kernel (Clássica)	26,129	MDS 2D - Análise Fatorial	12,906
PCA 2D Kernel (Gaussiana)	24,193	MDS 2D - GDA	26,631
PCA 2D Exponencial	356,658	MDS 2D - Landmark Isomap	54,775
PCA 2D Probabilística	23,375	MDS 2D - LDA Algorithm	1,239
PCA 3D (Clássica)	1,718	MDS 2D - LPP	1,910
PCA 3D Kernel (Clássica)	50,750	MDS 2D - NPE	5,787
PCA 3D Kernel (Gaussiana)	47,230	MDS 2D - Sammon Mapping	270,132
PCA 3D Exponencial	656,400	MDS 2D - SPE	65,718
PCA 3D Probabilística	45,649	MDS 3D - Diffusion Map	13,759
PCA FFT 2D (Clássica)	1,008	MDS 3D - Análise Fatorial	13,398
PCA FFT 2D Kernel (Clássica)	24,734	MDS 3D - GDA	27,595
PCA FFT 2D Kernel (Gaussiana)	25,505	MDS 3D - Landmark Isomap	53,395
PCA FFT 2D Exponencial	169,638	MDS 3D - LDA Algorithm	1,194
PCA FFT 2D Probabilística	19,238	MDS 3D - LPP	1,902
PCA FFT 3D (Clássica)	1,081	MDS 3D - NPE	5,580
PCA FFT 3D Kernel (Clássica)	24,174	MDS 3D - Sammon Mapping	299,473
PCA FFT 3D Kernel (Gaussiana)	24,278	MDS 3D - SPE	67,838
PCA FFT 3D Exponencial	172,809	Tempo Total	3137,571
PCA FFT 3D Probabilística	20,157		

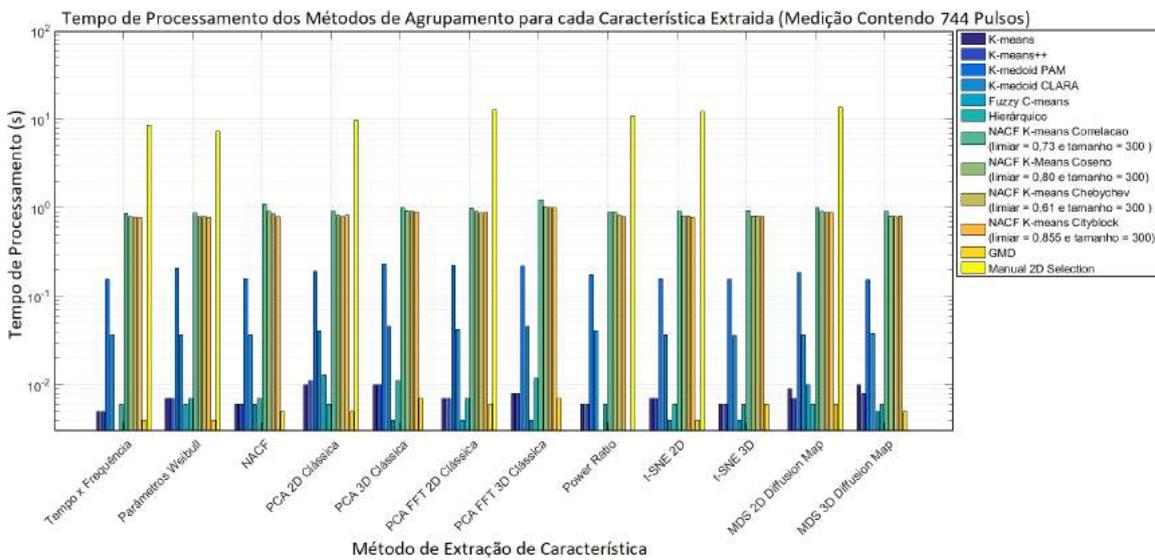
Em seguida, avaliamos o tempo de execução do método de clusterização para as

diversas combinações de extração de características. Neste caso, a fim de não levar muito tempo avaliando as 20 medições usadas para gerar os resultados vistos nas Tabelas 8.9 e 8.10, selecionamos aleatoriamente apenas duas medições, uma com menos de 1000 pulsos e outra com mais de 1000 pulsos. Além disso, utilizamos o Índice de Dunn (ID) [172] que mede a compacidade (distância máxima entre os pontos de dados dos *clusters*) e a separação dos *clusters* (distância mínima entre os *clusters*). Essa medida serve como um indicativo da qualidade da separação realizada, podendo também ser usado para encontrar o número certo de *clusters* em um conjunto de dados, no qual o valor máximo do índice representa o particionamento correto (partição com maior separação entre *clusters* e menos dados dispersos entre estes). No entanto, é importante entender que um índice alto nem sempre significa uma correta separação dos diferentes padrões de dados, portanto, o usaremos apenas como uma referência complementar.

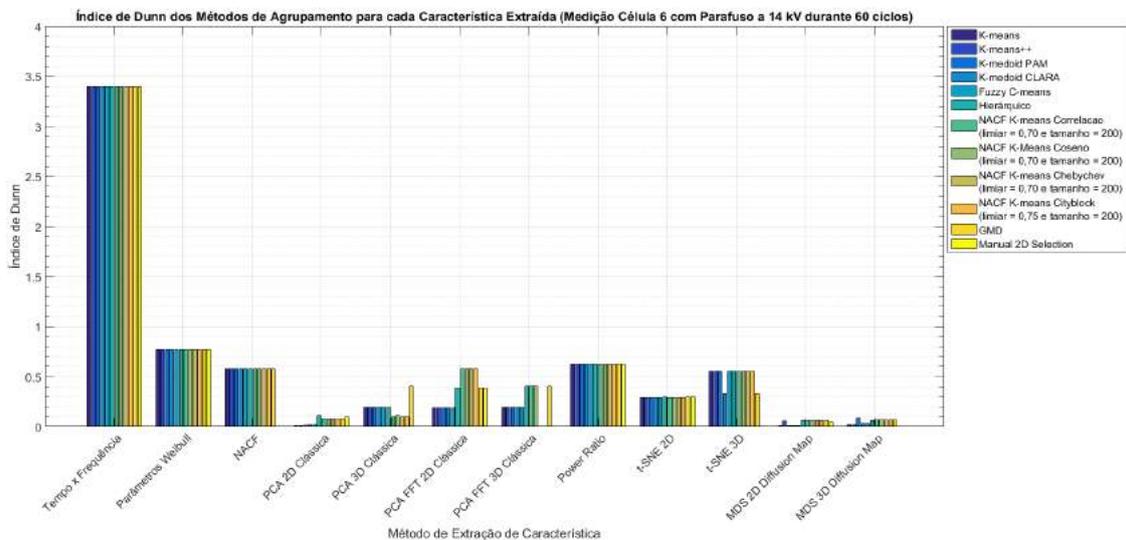
Na Figura 8.34 são mostrados os resultados de tempo médio e do índice de Dunn para cada método de agrupamento de todas as características de que dispomos no sistema. No caso temos como exemplo uma medição com 744 pulsos adquiridos de uma célula de carga ensaiada em laboratório sob uma tensão de 14 kV por um período de 60 ciclos. Pela Figura 8.34(a) percebe-se que para todos os diferentes algoritmos de extração o tempo de processamento do método de agrupamento permanece praticamente igual por serem automáticos, exceto para o método manual (aplicável somente para características em 2D) por este depender da rapidez com que o usuário avalia cada gráfico de característica projetado. Os métodos K-means, K-means ++, K-medoid CLARA, Fuzzy C-means, Hierárquico e GMD são bastante rápidos em sua execução com valores de tempo inferiores a 0,25 s; o método K-medoid PAM necessita de um tempo maior (mas não superior a 4 s) para processar os dados; quanto as variações dos métodos NACF K-means necessita-se de um tempo relativamente elevado devido as suas diferentes etapas de busca envolvidas no seu algoritmo. Outra observação importante, é que o uso de diferentes métricas de distância teve efeito positivo quanto a redução no tempo de processamento, decrescendo para as métricas Coseno, *Chebyshev* e *City block* com uma melhora de até 9,4%, 15,4% e 21,4%, respectivamente. Ademais, são especificados os valores de limiar e de tamanho mínimo usados para cada métrica, os quais foram escolhidos de forma a produzirem resultados similares de separação e, em conformidade com o que discutimos no Capítulo 6, é preciso ajustar o valor de limiar de acordo com cada métrica.

A Figura 8.34(b) traz os resultados de ID. Neste exemplo em particular temos um padrão de descarga que é muito bem discriminado nas diferentes extrações de características, o que nos permite obter resultados de separação dos dados muito

similares para os diferentes métodos de agrupamento, o que se reflete em valores de ID iguais ou bastante próximos um dos outros dentro de cada método. Como informamos anteriormente o ID não pode ser usado para comparações entre metodologias diferentes, mas somente para comparações dentro de uma mesma metodologia, portanto, apenas com o valor deste índice não podemos tirar conclusões a cerca de qual método forneceu a melhor separação dos diferentes padrões de DP presentes nesta medição. Por exemplo, pela Figura 8.34(b) os maiores valores de ID são fornecidos pelo método Tempo x Frequência e se considerarmos o método por Parâmetros Weibull temos valores menores de ID, mas ambos fornecem o mesmo resultado de separação, conforme ilustra a Figura 8.35.

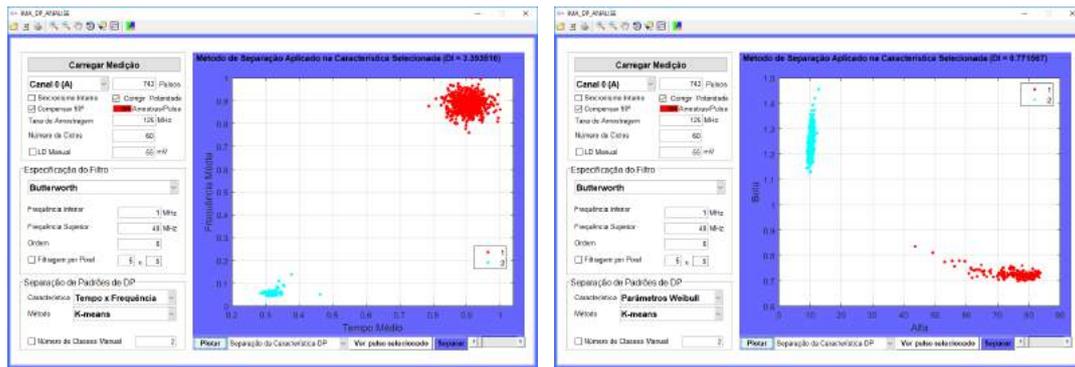


(a)



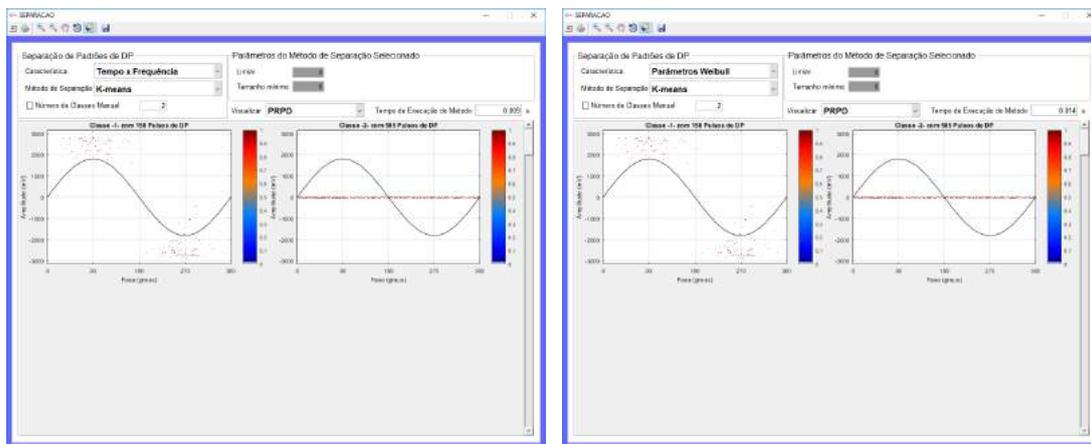
(b)

Figura 8.34: Resultados para medição com 744 pulsos: (a) tempo médio; (b) índice de Dunn.



(a)

(b)



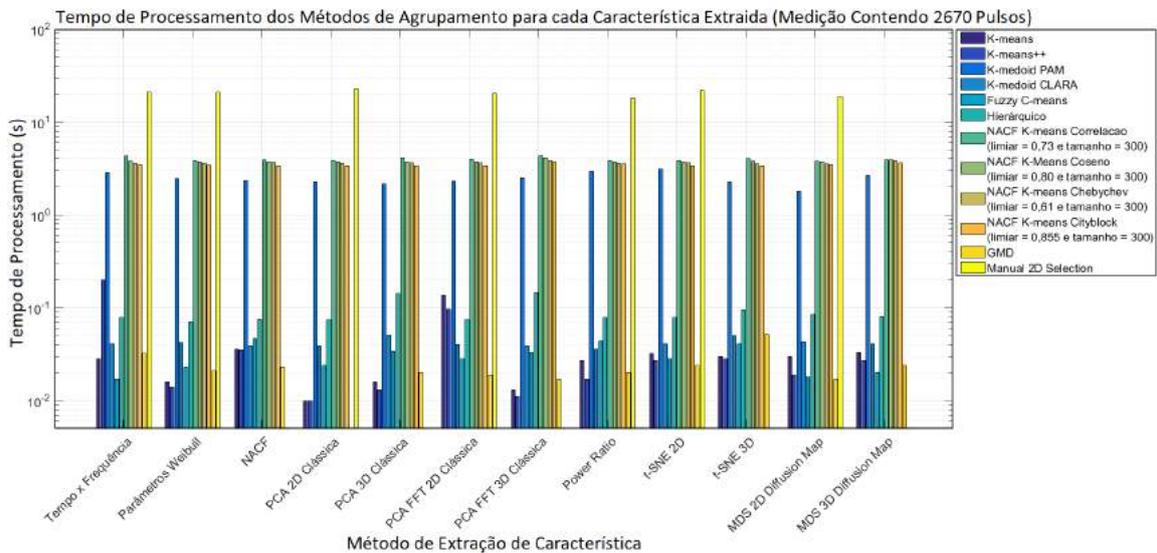
(c)

(d)

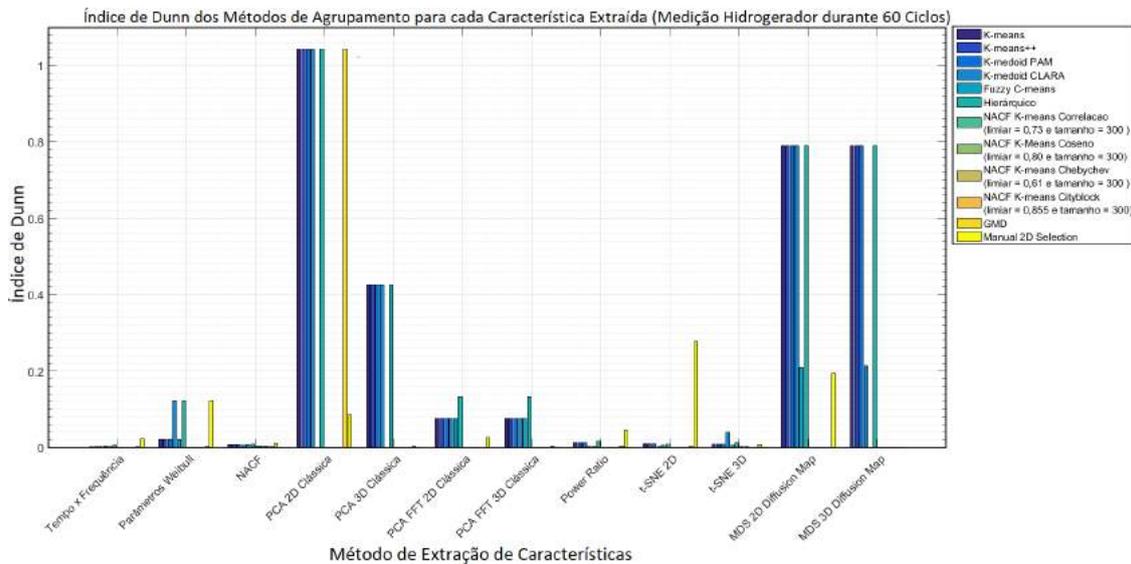
Figura 8.35: Resultados de separação para medição de célula de carga usando método K-means na característica extraída: (a) Tempo x Frequência; (b) Parâmetro Weibull; (c) PRPD separado pelo método Tempo x Frequência; (d) PRPD separado pelo método Parâmetro Weibull.

No segundo exemplo, visto na Figura 8.36, temos os resultados de uma medição com 2670 pulsos obtidos de um hidrogerador. Quanto ao tempo de processamento dos métodos mostrados na Figura 8.36(a) temos um comportamento similar ao descrito no primeiro exemplo, só que neste caso o tempo para processar mais pulsos se torna bem maior, principalmente para o método de seleção manual dos *clusters*. O método NACF K-means e suas alternativas possuem o mesmo comportamento com uma melhora de até 13,1%, 18,5% e 21,3% nas respectivas métricas Coseno, *Chebychev* e *City block*. Para o ID resultante o método PCA 2D Clássica forneceu os maiores valores e o Tempo x Frequência os menores valores, resultados bem diferente do comportamento visto no primeiro exemplo, isso porque estamos lidando com dados de características distintas das células de carga. Portanto, não se pode afirmar que um método consegue sempre a melhor representação dos dados e/ou a melhor separação, pois a performance de cada um depende do tipo de pulso que é

aquisitado, o qual por sua vez está atrelado ao tipo de equipamento, aos elementos que compõem o circuito de medição (sensores, cabos, conectores, dimensões do equipamento, filtros, *hardware* de aquisição, entre outros). Outra observação a ser feita é que o ID não é um índice muito representativo para o método NACF K-means, já que este avalia a similaridade entre a NACF dos pulsos e tem a capacidade de identificar pontos sobrepostos, conforme ilustra a Figura 8.37, em que são comparados os resultados de separação para a característica Weibull com agrupamento pelo método Hierárquico contra o agrupamento pelo método NACF



(a)



(b)

Figura 8.36: Resultados para medição com 2670 pulsos: (a) tempo médio; (b) índice de Dunn.

K-means (Correlação). Note que o método NACF K-means encontra pontos sobre-

postos e bem afastados, o que faz com que o valor de ID seja baixo (0,000054) em relação a outros métodos (e.g., Hierárquico com ID de 0,123180), como pode ser visto nas Figuras 8.37(a) e (b), mas sua performance de separação é superior, como se verifica ao comparar os padrões separados nas Figuras 8.37(c) e (d). Outro fator a se considerar é a alta sensibilidade no resultado deste método perante os parâmetros de limiar e de tamanho mínimo da classe (número mínimo de pulsos para formar uma classe) especificados.

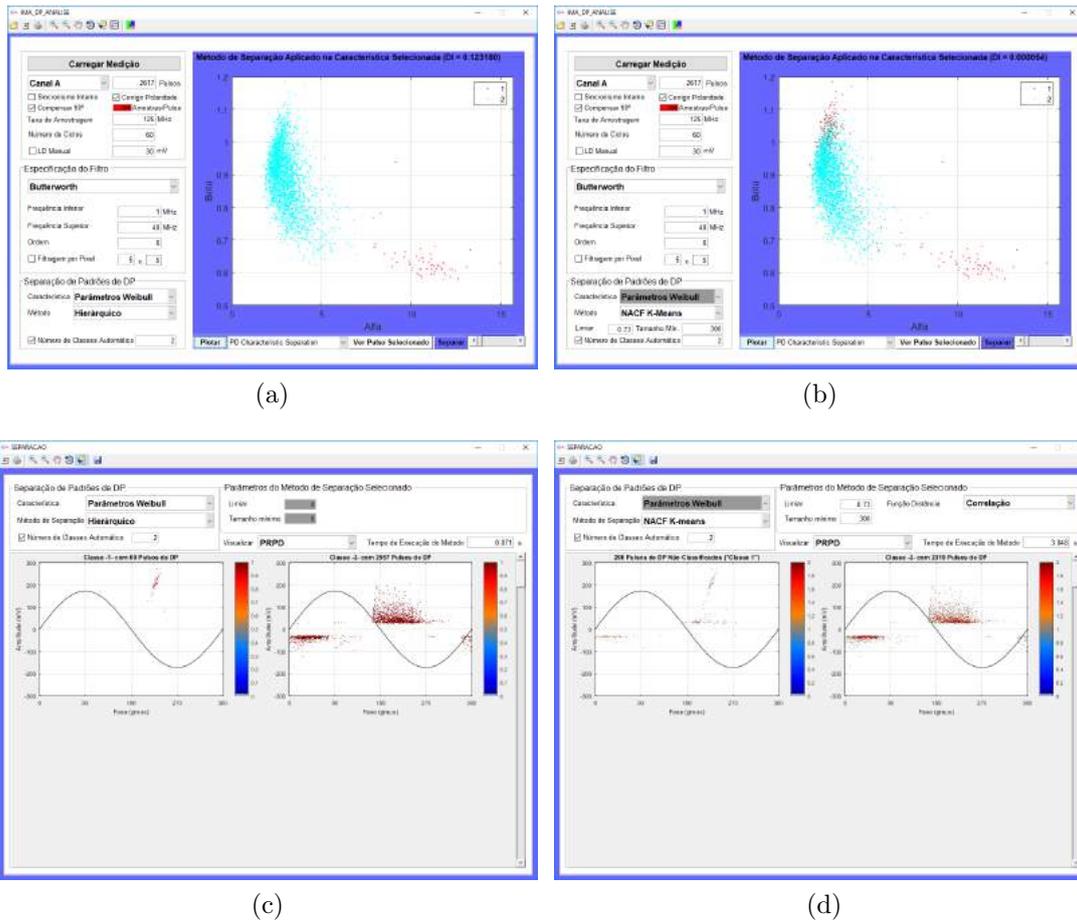
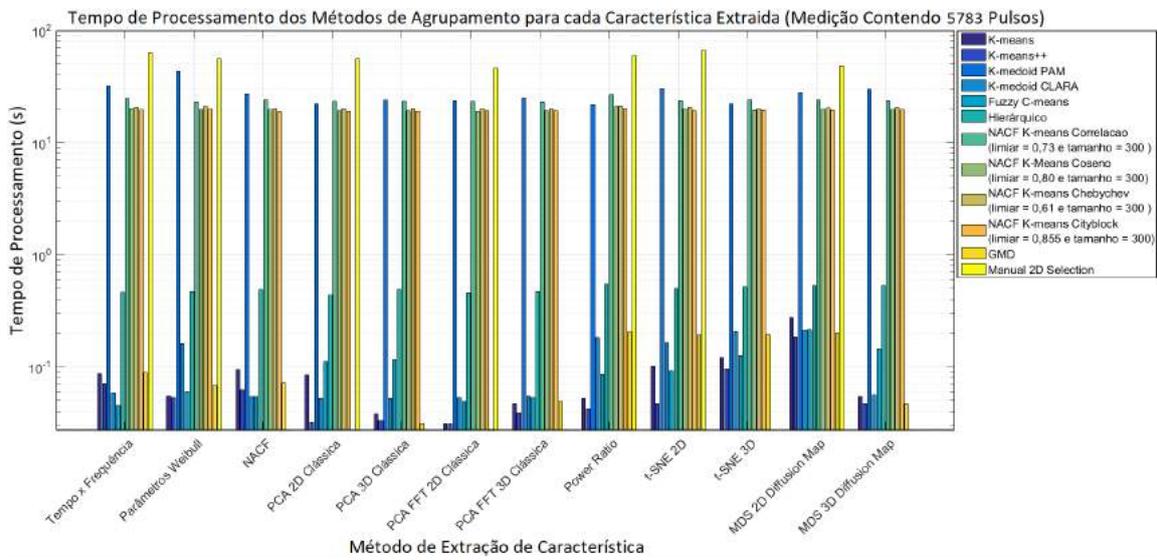


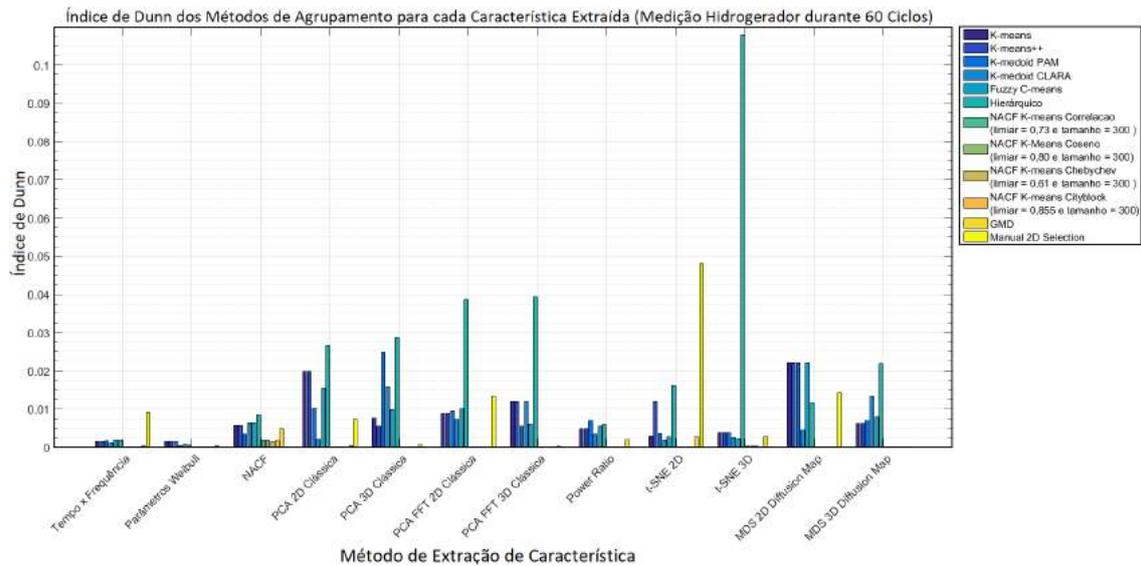
Figura 8.37: Resultados de separação para medição de um hidrogerador com o uso do método K-means na característica extraída: (a) Tempo x Frequência; (b) Parâmetro Weibull; (c) PRPD separado pelo método Tempo x Frequência; (d) PRPD separado pelo método Parâmetro Weibull.

Um último exemplo é mostrado na Figura 8.38 para uma medição contendo 5783 pulsos detectados em outro hidrogerador. Novamente com o aumento no número de amostras houve uma elevação expressiva no tempo de processamento dos métodos de agrupamento, principalmente para o K-medoid PAM, o NACF K-means e o de Seleção Manual 2D, conforme mostrado na Figura 8.38(a). Observe que para uma maior quantidade de pulsos a diferença no tempo de execução das alternativas do método NACF K-means se tornam mais evidentes, chegando até

21,3%, 20,3% e 24,4% para as respectivas métricas Coseno, *Chebychev* e *City block*. Já o ID demonstra uma redução no seu valor para todos os métodos. É certo que estes resultados dependem da medição, mas há uma maior probabilidade destes reduzirem, pois existe uma quantidade superior de pulsos que geralmente ocasionam uma maior dispersão nas características extraídas. Neste exemplo, o método Hierárquico produziu os maiores ID dentre os diferentes algoritmos de caracterização dos pulsos. Considerando todos os métodos de agrupamento, a extração de característica que obteve os melhores índices foi a MDS Diffusion Map,



(a)



(b)

Figura 8.38: Resultados para medição com 5783 pulsos: (a) tempo médio; (b) índice de Dunn.

diferentemente do primeiro e segundo exemplos, nos quais se sobressaíram, respectivamente, as técnicas Tempo x Frequência e PCA 2D Clássica.

Pelos exemplos discutidos conclui-se que quando estamos lidando com dados contendo poucos pulsos (menos de 1000), todos os métodos, tanto de extração de características quanto os de agrupamento, são muito rápidos em separar os padrões de DP existentes na medição. Desta forma, se torna interessante investigar mais de uma combinação de técnicas para encontrar um melhor resultado, exceto quando a separação dos dados está bem definida e não deixa dúvidas quanto à correta divisão dos grupos. Em casos em que o volume de informações é alto, é aconselhável primeiramente lidar com combinações de metodologias de extração/agrupamento mais rápidas e, caso não se obtenha um resultado dentro do esperado, aplicar as opções mais lentas. Também não é possível precisar uma melhor combinação entre as técnicas, pois irão depender dos dados adquiridos que podem diferir bastante de um equipamento para outro, além de outras variáveis que interferem no formato dos pulsos em cada nova medição. Tal fato demonstra a importância de se ter uma variedade de métodos ao invés de adotar um único para compor um sistema de separação de dados de descargas parciais e, conseqüentemente, de classificação dos mesmos.

Todas as novas métricas propostas para o método NACF K-means atingiram o objetivo de melhoria na sua performance de processamento dos sinais de DP, obtendo reduções significativas em comparação com a métrica de correlação, principalmente para grandes quantidades de pulsos. No entanto, ainda assim tal método tende a levar bem mais tempo para ser processado. Assim, seu uso é mais indicado quando há poucos pulsos detectados ou quando a separação dos padrões se torna complicada para os demais métodos. Também são necessários cuidados quanto à especificação dos parâmetros de limiar e do tamanho mínimo de pulsos para formar uma classe, pois o método é bastante sensível a mudança dos mesmos.

Para demonstrar o efeito desta sensibilidade em todas as suas variações foram obtidos os tempos de processamento, ID e número de classes geradas (sem aplicar a metodologia de agrupamento das classes com padrões similares proposta no Capítulo 6) que se vê nas Figuras 8.39, 8.40 e 8.41. Verifique que, para pequenas alterações no valor de limiar, a variação no tempo e nos valores de ID é considerável. Na Figura 8.39 temos os tempos de processamento para cada métrica de distância alguns valores de limiar usando tamanho mínimo de 100 e 300 pulsos, no caso desta medição nota-se que para valores de limiar abaixo de 0,800 a variação no tempo é sutil, mas acima deste a variação usando a função correlação de Pearson e a técnica *Chebyshev* começam a ser bastante afetadas; e acima de um limiar de 0,950 os métodos

City block e *Chebychev* demoram em sua execução e acabam por não conseguirem separar os dados, agrupando todos em uma única Classe, conforme a Figura 8.40(b) e 8.41(b). Esse efeito nos mostra que cada métrica para produzir resultados similares ou iguais aos fornecidos pela correlação de Pearson precisa ter o valor de limiar ajustado. De acordo com os resultados verificados a métrica Coseno pode trabalhar com limiar próximo do usado para a correlação; já a *Chebychev* precisa de valores menores, como mostra a Figura 8.40, e a *City block* necessita de valores um pouco superiores. Limiares muito altos não são indicados para a maioria das análises, pois acarretam lentidão na execução do algoritmo e tendem a não separar os padrões, gerando apenas uma classe (denominada como não classe), principalmente para um valor de tamanho mínimo elevado, conforme a Figura 8.41(b).

De forma geral, as alternativas propostas são mais rápidas que o método tradicional e, também, produzem resultados equivalentes ou similares de separação quando usado o valor de limiar adequado. O tamanho mínimo especificado pode afetar a quantidade de classes geradas, sendo que valores muito pequenos tendem a gerar diversas classes e valores muito altos podem impedir a separação dos diferentes padrões de descargas que possam existir.

Na Subseção seguinte mostraremos alguns exemplos adicionais das funcionalidades do sistema de análise e como estes afetam o PRPD gerado e as separação dos padrões.

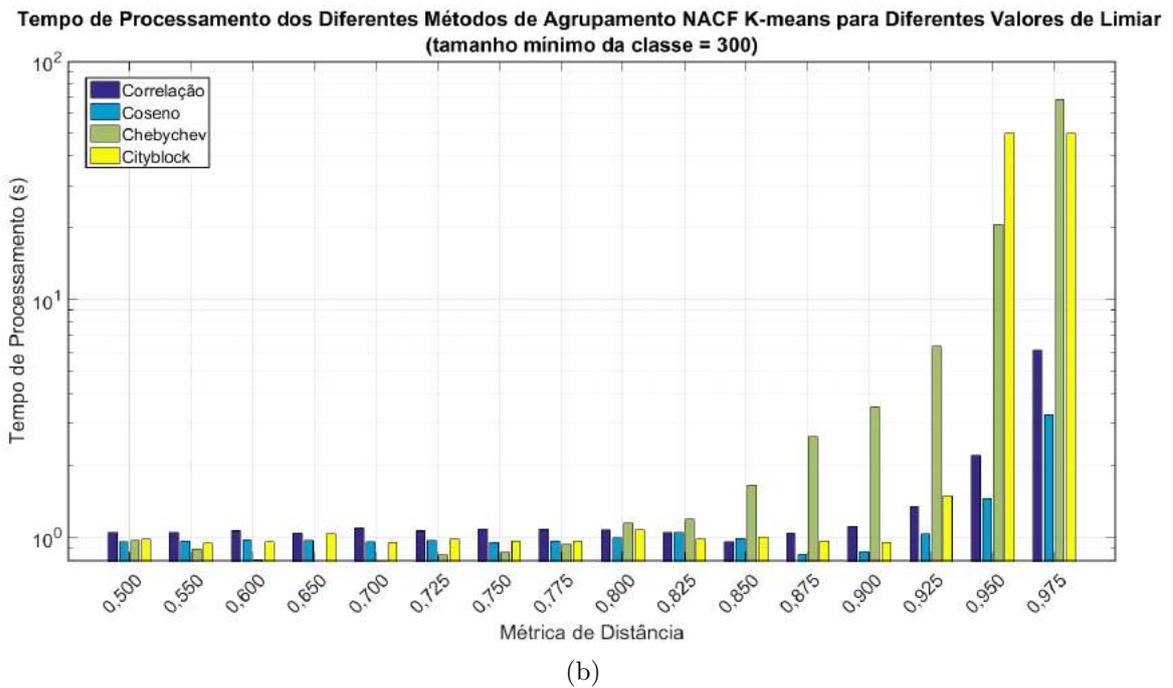
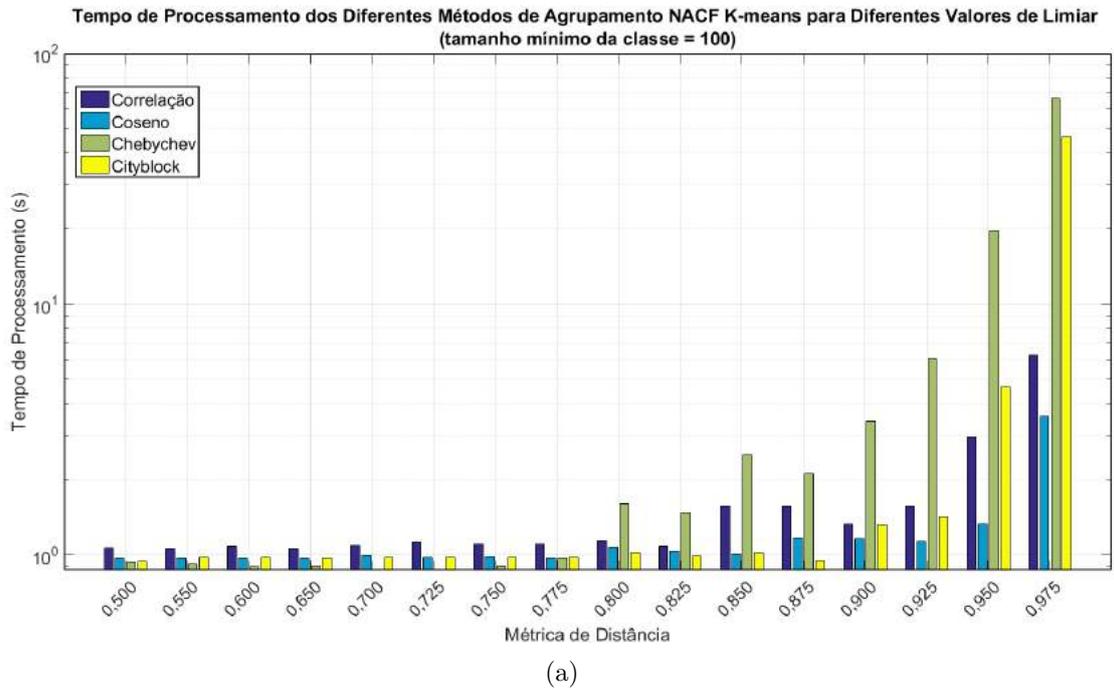
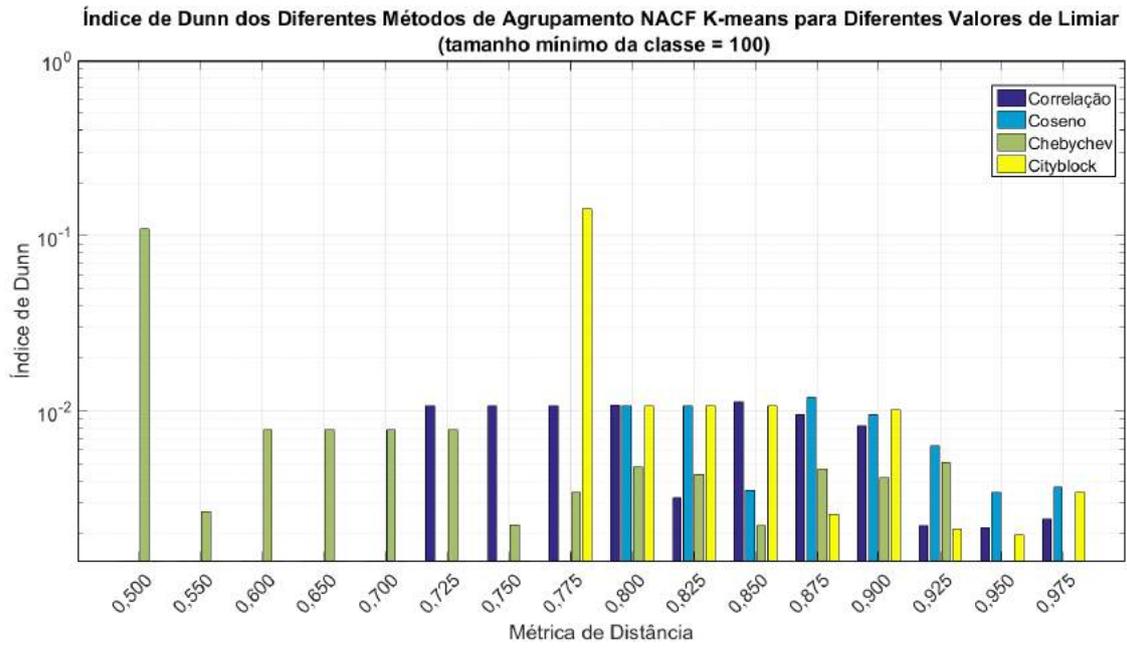
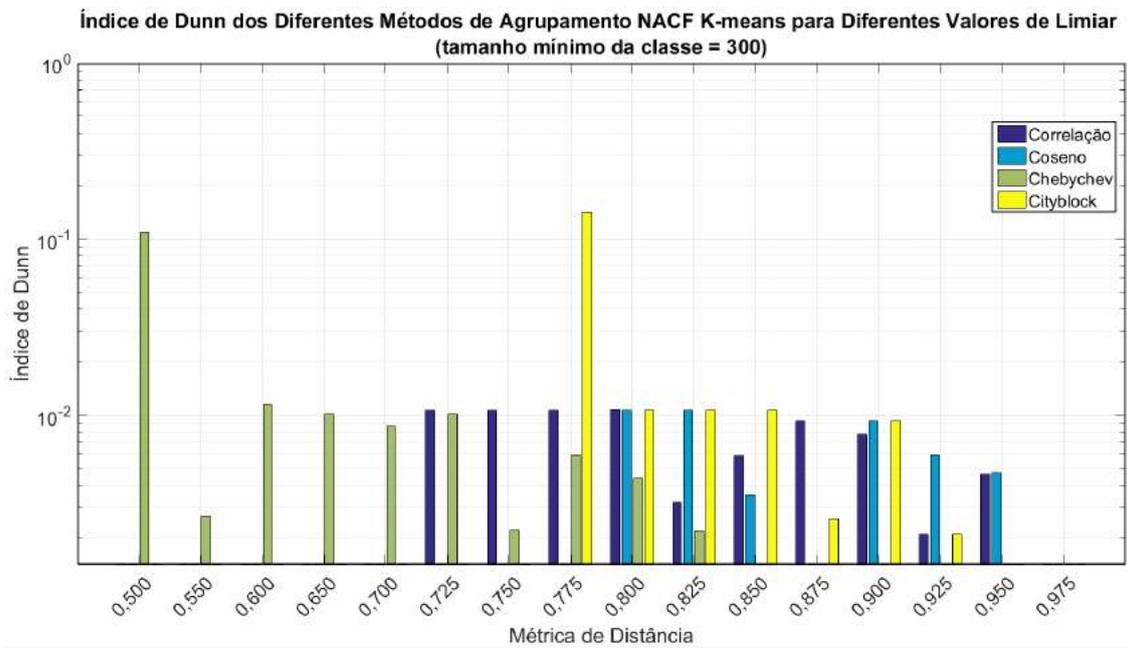


Figura 8.39: Resultados para diferentes valores de limiar: tempo de processamento para tamanho mínimo igual a (a) 100 e (b) 300.



(a)



(b)

Figura 8.40: Resultados para diferentes valores de limiar: índice de Dunn para tamanho mínimo igual a (c) 100 e (d) 300.

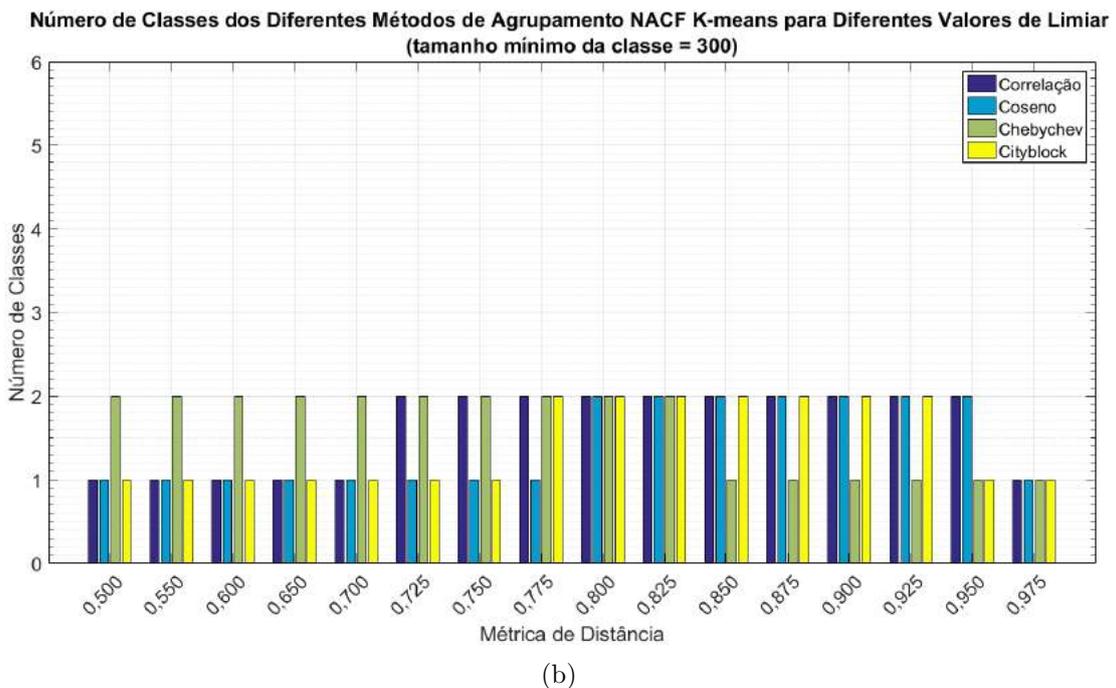
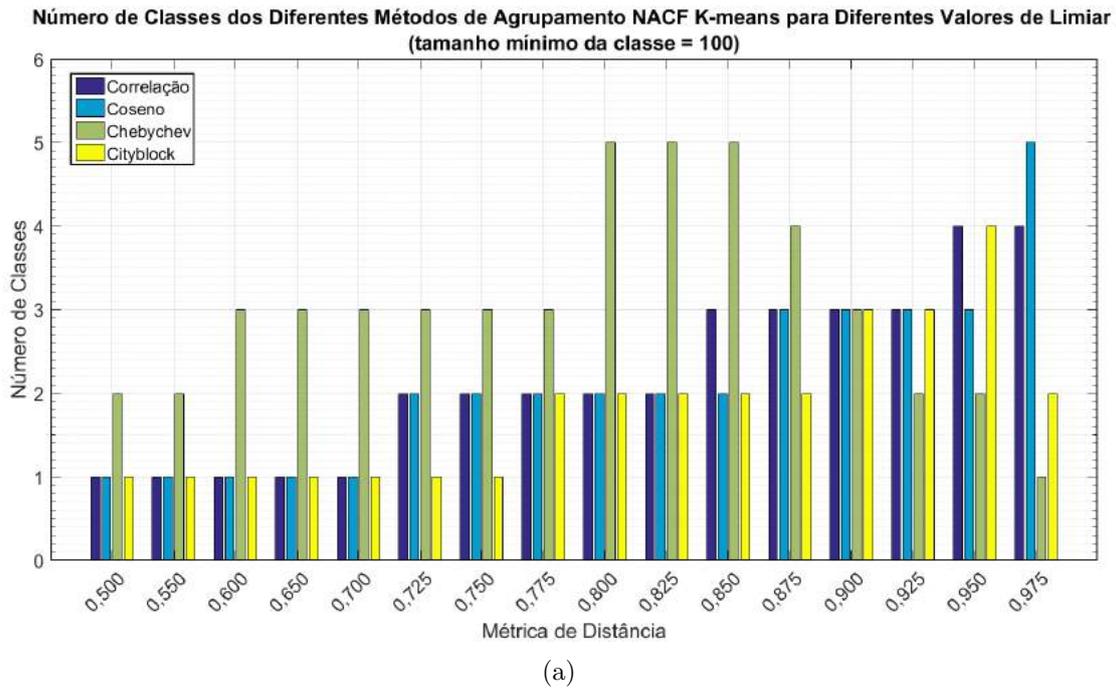


Figura 8.41: Resultados para diferentes valores de limiar: número de classes para tamanho mínimo igual a (a) 100 e (b) 300.

8.6.1 Avaliação das Funcionalidades do Sistema de Análise

Apesar de já termos mostrado como funciona o método de correção de polaridade na Seção 8.4, ilustramos na Figura 8.42 mais alguns exemplos diretamente no sistema desenvolvido. Temos três medições realizadas em equipamentos diferentes, uma na célula de testes C6 em laboratório, uma num gerador a diesel e outra num

hidrogerador. Nas Figuras 8.42(a) e (b) são mostrados os mapas PRPD gerados para a medição da célula C6 através do método convencional de identificação de polaridade dos pulsos e do método proposto, respectivamente. É notável a diferença

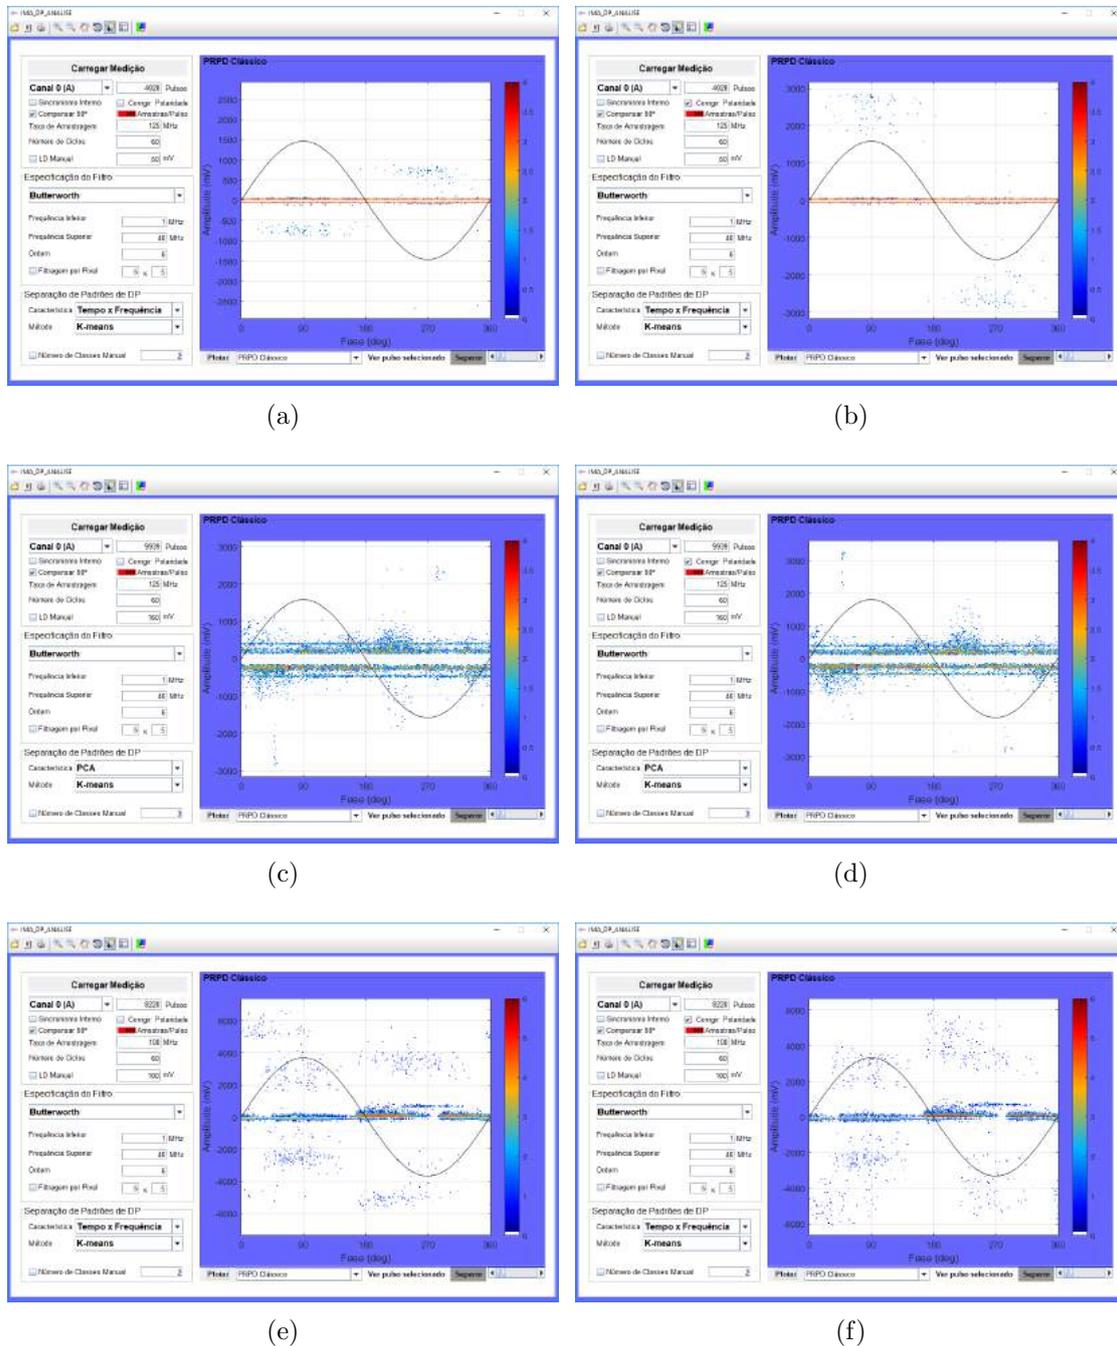
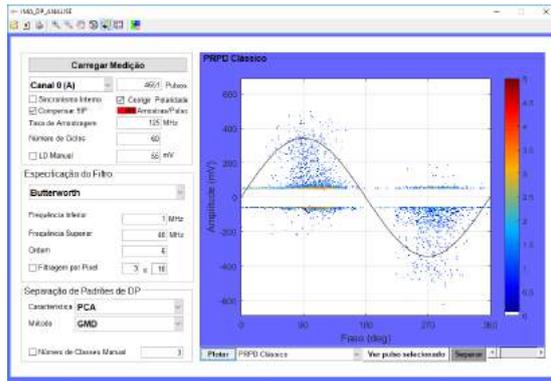


Figura 8.42: Exemplos de correção de polaridade dos pulsos no mapa PRPD: (a) Medição da célula C6 usando o método convencional; (b) Medição da célula C6 usando o método proposto; (c) Medição de gerador a diesel usando o método convencional; (d) Medição de gerador a diesel usando o método proposto; (e) Medição de hidrogerador usando o método convencional; (f) Medição de hidrogerador usando o método proposto.

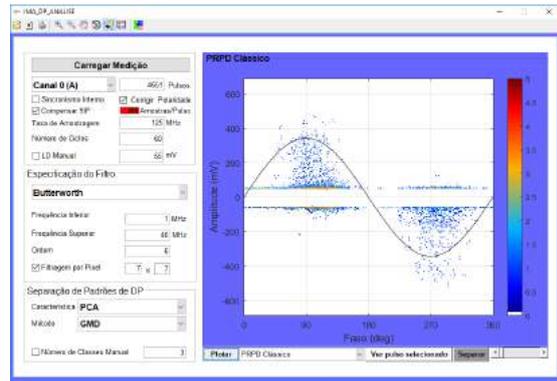
entre os mapas, ocorrendo uma mudança que pode afetar diretamente o diagnóstico, principalmente quanto a amplitude máxima das descargas. Nas Figuras 8.42(c) e (d) temos os mapas sem e com correção para a medição de um gerador a diesel, e novamente há uma diferença considerável entre os resultados, formando um mapa melhor definido após aplicar a correção de polaridade. Por último, as Figuras 8.42(e) e (f) trazem o exemplo do hidrogerador, também com alterações significativas e com um mapa mais coerente após a correção.

Como uma filtragem a parte, podemos aplicar ao PRPD a filtragem por *pixel* que trata a imagem do mapa e não os sinais propriamente ditos. Esta técnica permite gerar um mapa mais limpo eliminando pontos de descargas ou de ruído isolados ao longo do mapa, os quais podem atrapalhar na identificação dos padrões. O método pode ser aplicada ao mapa clássico e aos mapas separados. Um exemplo do uso da filtragem por *pixel* no PRPD clássico é mostrado na Figura 8.43, em 8.43 (a) vemos o mapa original enquanto que em 8.43(b), (c) e (d) temos os mapas filtrados com uma caixa de *pixel* de tamanho 7x7, 5x5 e 3x3, respectivamente. Constata-se um redução efetiva do número de pontos de descargas conforme decrescemos o tamanho da caixa de *pixel*, promovendo uma limpeza do mapa sem comprometer o formato característico da medição. Após realizarmos a separação dos padrões usando o algoritmo MDS LPP de 2D com seleção manual dos *clusters*, foi possível obter os mapas mostrados na Figura 8.44, seguindo a lógica anterior temos em 8.44(a) a separação sem o uso da filtragem por caixa de *pixels* e em 8.44(b), (c) e (d) os resultados aplicando a filtragem com caixas de tamanho 7x7, 5x5 e 3x3, respectivamente. Mais uma vez, o número de pontos de cada mapa é gradualmente reduzido. Os mapas mostrados referem-se a dois padrões de defeitos comuns em geradores: descarga entre barras e descarga interna.

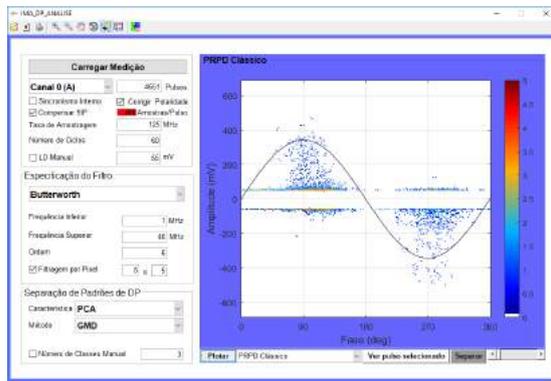
O procedimento demonstrado pode vir a ser bastante útil para uma futura implementação de um classificador supervisionado, pois serve como uma ferramenta de limpeza dos dados que poderá facilitar o processo de identificação automática dos diversos padrões de defeitos [191].



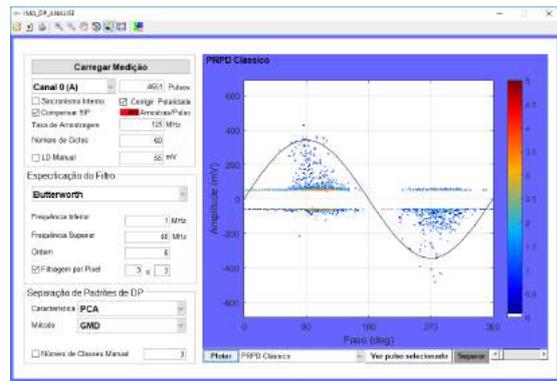
(a)



(b)



(c)



(d)

Figura 8.43: Medição de barra estática 3: (a) sem filtragem por pixel; (b) com filtragem por pixel para caixa de tamanho 3x3; (c) com filtragem por pixel para caixa de tamanho 5x5; com filtragem por pixel para caixa de tamanho 7x7;.

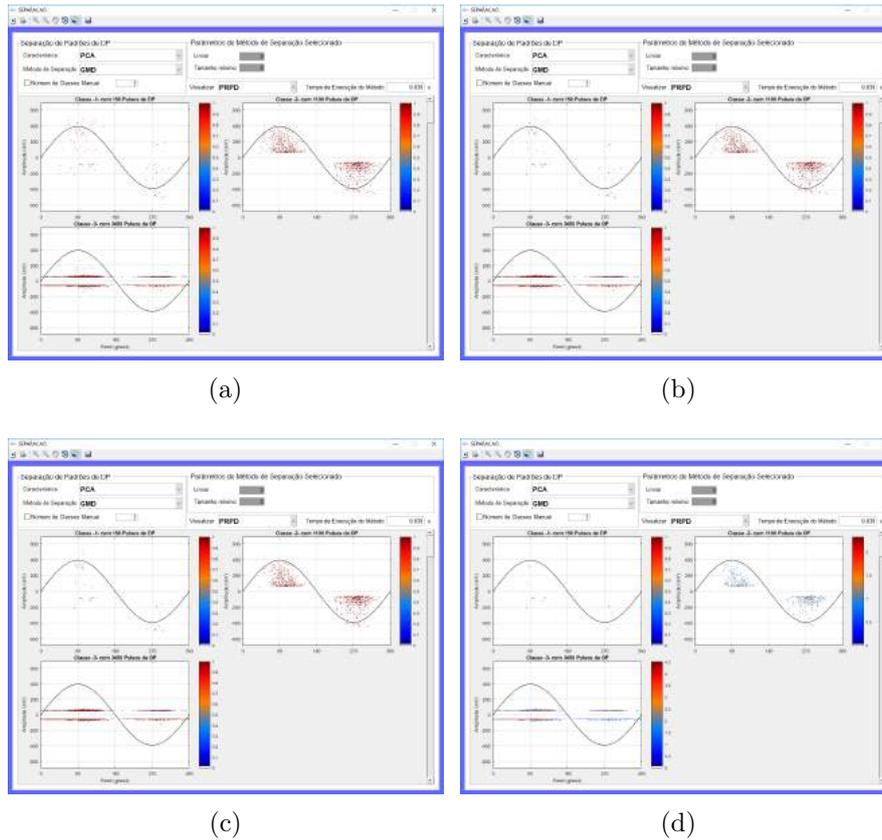


Figura 8.44: Separação da medição de barra estática 3: (a) sem filtragem por pixel; (b) com filtragem por pixel para caixa de tamanho 3x3; (c) com filtragem por pixel para caixa de tamanho 5x5; com filtragem por pixel para caixa de tamanho 7x7.

A seguir, em complemento aos exemplos de estimativa da RF através dos pulsos medidos, também mostraremos alguns casos de estimativa da resposta em frequência do equipamento avaliado (incluindo o circuito usado na medição). Veja na Figura 8.45 os histogramas PRPD e as RF extraídas da medição da célula C6 em 14 kV o canal A recebe o sinal de DP vindo do filtro PA e o canal B o sinal na saída da impedância Z_m (sincronismo com DP). Na Figura 8.45(b) é mostrada a RF estimada com os pulsos detectados em 8.45(a) sem aplicar o filtro digital Butterworth e sem realizarmos a separação dos padrões. Recorrendo à Seção 8.5, veremos que temos um resultados similar ao simulado em 8.26(a) (atentar para a diferença nas escalas), com a ressonâncias em torno de 1.25 MHz, 10 MHz, 25 MHz, 30 MHz, 50 MHz, sendo até mais preciso do que para a barra estática avaliada anteriormente (provavelmente por não termos modelamos a estrutura da barra). Feita a separação do PRPD em seus padrões, conforme a Figura 8.45(c) extraímos as RF correspondentes vistas em 8.45(d) e desta vez obtivemos uma resposta para os pulsos de DP coerente com a RF antes da separação e outra resposta de formato bem plano que se espalha ao longo de todo espectro de frequência. Ou seja, neste caso temos o padrão de um

ruído branco. Nas Figura 8.45(e) e 8.45(f) verificamos o comportamento das RF após aplicar o filtro digital PB Butterworth (frequência de corte inferior em 1 MHz e frequência de corte superior de 40 MHz), e percebe-se que ambas RF são afetadas pelo filtro digital e sofrem atenuação fora da banda especificada.

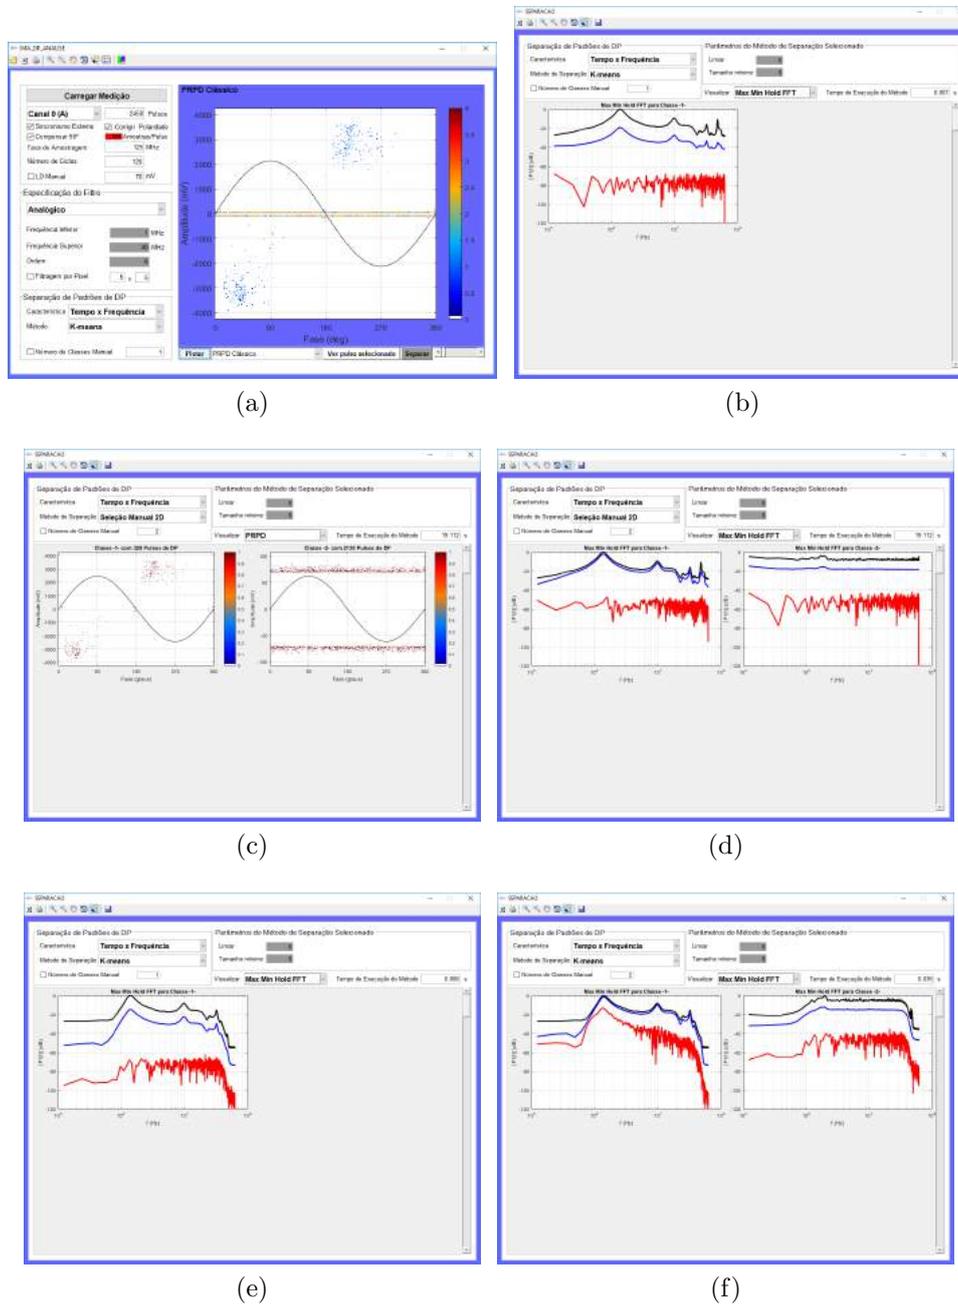


Figura 8.45: Respostas em frequência estimadas para a célula C6 avaliada em laboratório: (a) PRPD clássico; (b) RF estimada sem a separação dos pulsos; (c) PRPD dos padrões de pulsos separados; (d) RF estimadas após a separação dos pulsos; (e) RF estimada sem a separação dos pulsos com o uso do filtro digital PB Butterworth; (f) RF estimada após a separação dos pulsos com o uso do filtro digital PB Butterworth.

Também fizemos a estimativa da RF pelo canal B (com filtro PA acoplado

no canal A) usando o filtro digital Butterworth. Na Figura 8.46 a RF estimada a partir dos pulsos aquisitando sem a separação dos padrões. O resultado é similar ao mostrado na Figura 8.26(c) exceto pela antirressonância em 500 kHz, pois aqui foi aplicado um filtro digital PB com frequência de corte inferior de 1 MHz, que acaba por atenuar as componentes abaixo desta frequência. Ainda assim, após separar os padrões de pulsos, conforme a Figura 8.46(c), a RF estimada vista na Figura 8.46(d) para o padrão de DP demonstra resquícios de uma antirressonância em 500 KHz e a outra RF estimada para o segundo padrão confirma que este é ruído branco.

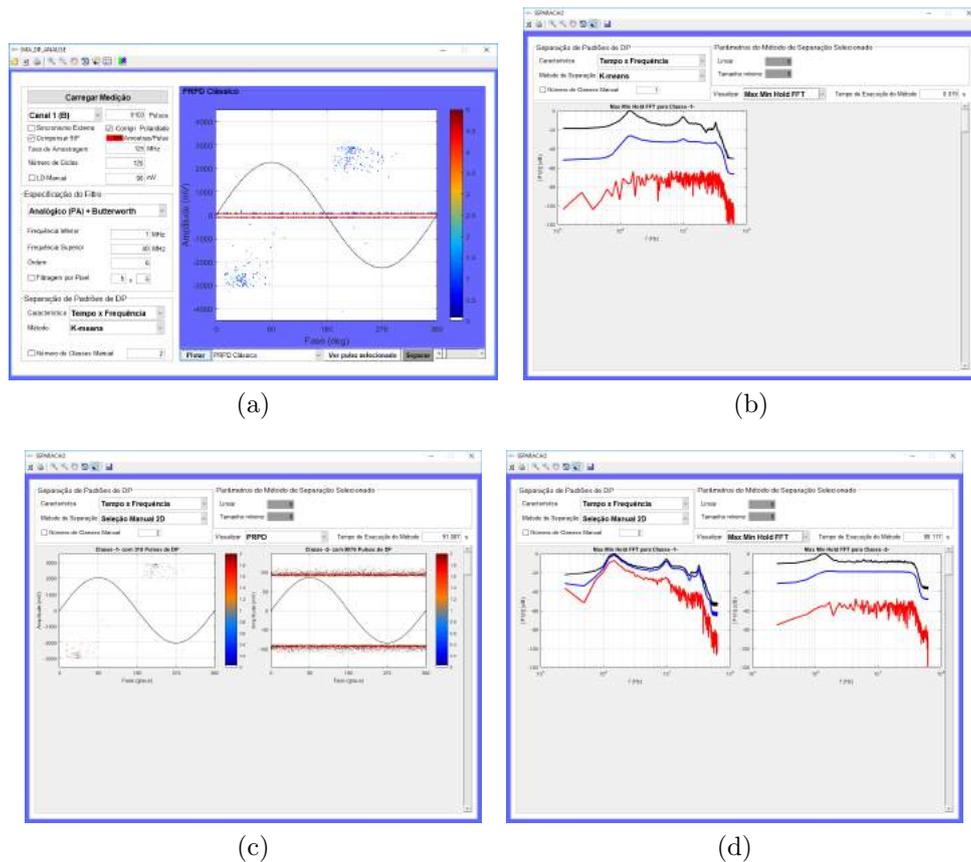


Figura 8.46: Respostas em frequência estimadas para a célula C6 avaliada em laboratório através do canal B que recebe o sinal proveniente da impedância de medição: (a) PRPD clássico; (b) RF estimada sem a separação dos pulsos; (c) PRPD dos padrões de pulsos separados; (d) RF estimadas após a separação dos pulsos; (e) RF estimada sem a separação dos pulsos com o uso do filtro digital PB Butterworth; (f) RF estimada após a separação dos pulsos com o uso do filtro digital PB Butterworth.

Apesar de não implementado ao sistema de forma definitiva, usamos em algumas análises o filtro digital Butterworth combinado com a técnica de redução de ruído branco por transformada wavelet. Para a filtragem wavelet aplicamos a função de limiarização Fleming (proposta no Capítulo 5) com constante de inclinação igual a 5, função wavelet *Daubechies* de ordem 8 (*Db8*) com $J = 10$ níveis de decomposição. Na

Figura 8.47 são ilustrados o PRPD e a característica Tempo x Frequência extraídos considerando apenas a filtragem Butterworth e a filtragem por WT combinada com a Butterworth da medição da célula C4 em laboratório. Comparando as Figuras 8.47(a) e (b) notamos que o ruído presente na medição usual desaparece do PRPD quando também faz-se a filtragem wavelet, o que acarretou na redução da quantidade de pulsos detectados, já que a maioria destes era ruído branco. Além disso, ocorre uma mudança significativa nas características Tempo x Frequência, sendo mais fácil separar os padrões presentes, pois além de reduzir a quantidade de dados, os pulsos de descargas também têm parte do ruído indesejável eliminado de sua forma de onda.

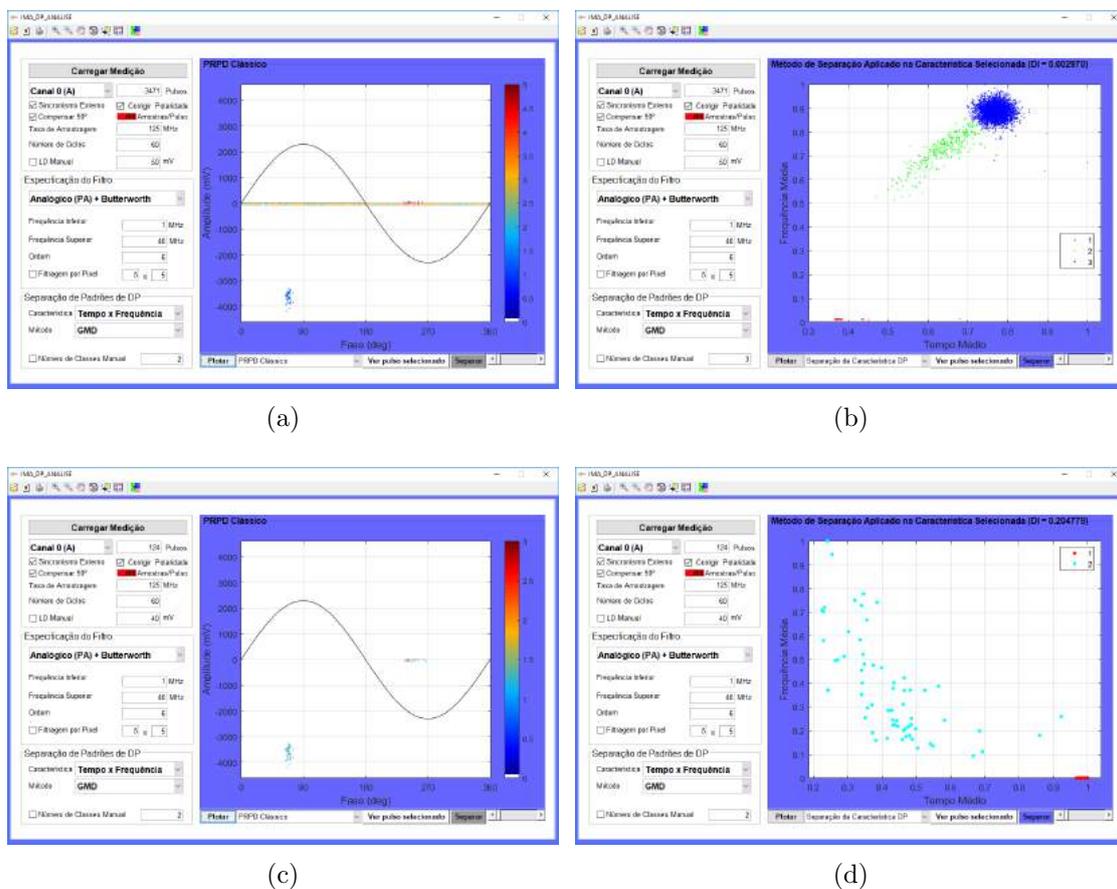


Figura 8.47: Filtragem PRPD para medição da célula C4: PRPD clássico filtrado com Butterworth; (b) Característica Tempo x Frequência separada pelo método GMD; (c) PRPD clássico filtrado com Butterworth e WT; (d) Característica Tempo x Frequência separada pelo método GMD.

Considerando uma medição em campo feita num hidrogerador, temos os resultados vistos na Figura 8.48. Desta vez, por não termos uma medição com grande quantidade de ruído acima do LD de 30 mV estipulado para gerar os mapas PRPD, não existem grandes diferenças entre os mapas das Figuras 8.48(a) e (c), mas há uma

redução significativa na quantidade de pulsos detectados na característica Tempo x Frequência extraída, ver Figuras 8.48(b) e (d). Este problema ocorre devido à extração de ruído por WT acarretar alteração no formato dos pulsos reconstruídos, o que afeta a amplitude de pico dos pulsos após ser executada. Pode-se notar tal efeito na Figura 8.49, na qual comparamos as diferenças entre o sinal adquirido (contendo a componente AC sem filtragem digital), o sinal após a filtragem digital por Butterworth e o sinal após a filtragem wavelet. Portanto, o filtro Butterworth tem como principal objetivo eliminar as componentes de baixa frequência (AC, tiristores, entre outros) e a filtragem wavelet é recomendada para atenuar o ruído branco que geralmente atrapalha a medição.

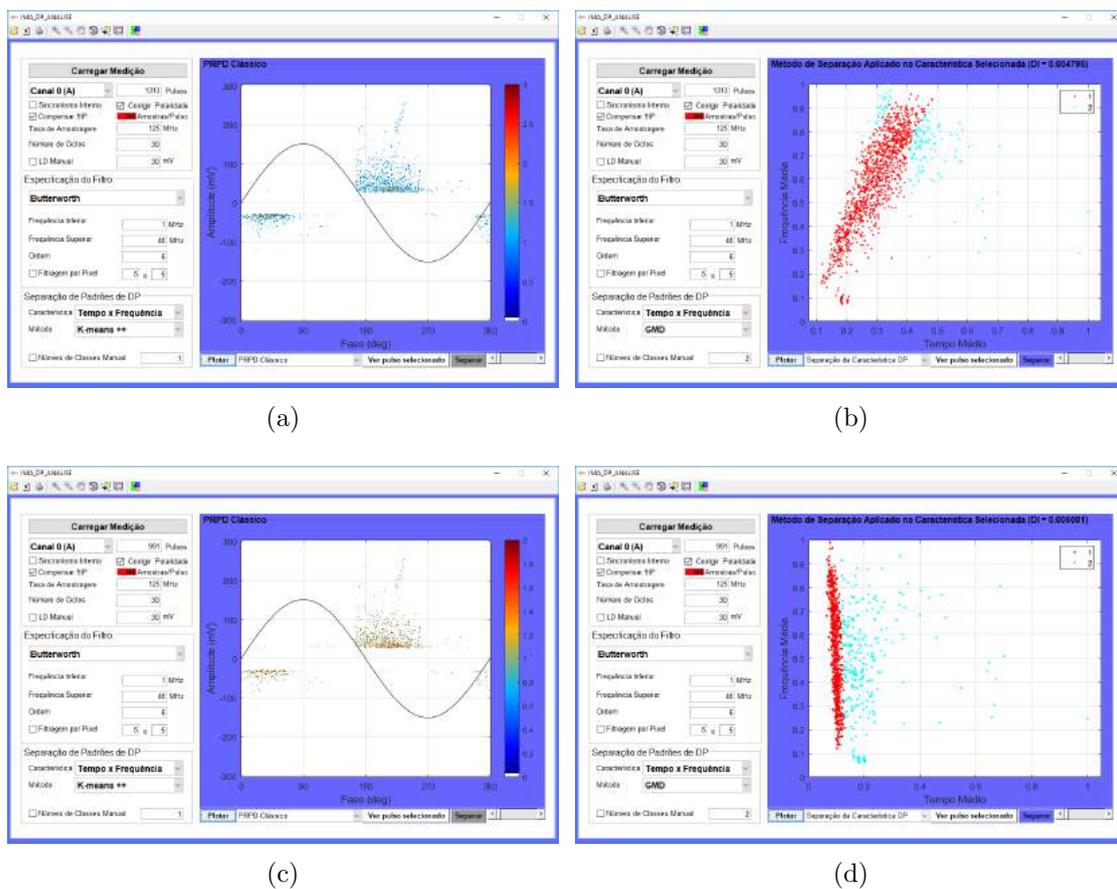


Figura 8.48: Filtragem PRPD para medição de um hidrogerador: (a) PRPD clássico filtrado com Butterworth; (b) Característica Tempo x Frequência separada pelo método GMD; (c) PRPD clássico filtrado com Butterworth e WT; (d) Característica Tempo x Frequência separada pelo método GMD.

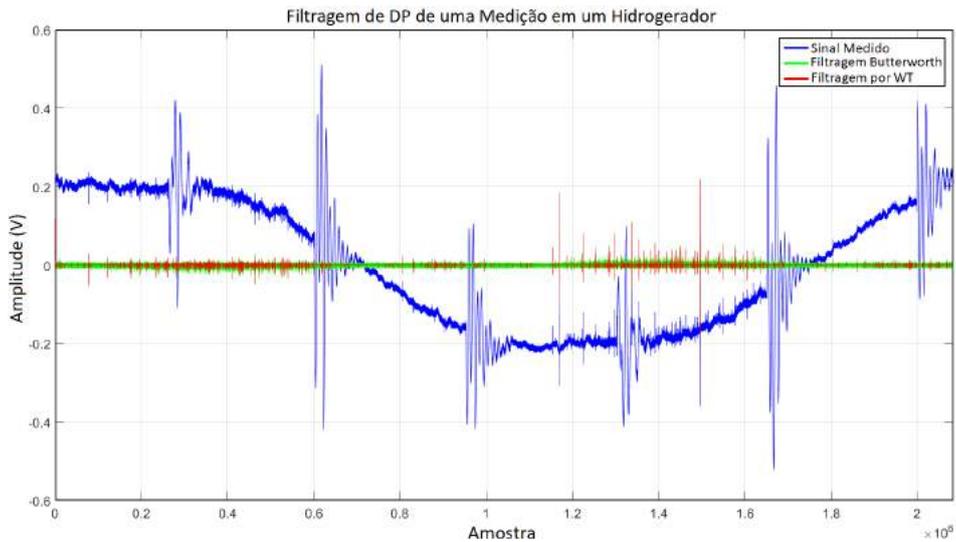


Figura 8.49: Exemplo de um ciclo medido (azul) submetido a filtragem digital Butterworth (verde) e a filtragem wavelet (vermelho).

Uma última constatação, é que ao aplicar a WT na redução de ruído pode-se utilizar um LD muito menor sem que seja detectada uma grande quantidade de pulsos, diminuindo o tempo de execução das diferentes ferramentas de análise que o programa disponibiliza. Para a mesma medição mostrada nas Figura 8.48(a) e (c) (feitas com LD igual a 30 mV) têm-se, respectivamente, 1313 e 991 pulsos identificados. Avaliamos a quantidade de pulsos que seriam detectados para um LD igual a 10 mV, verificar a Figura 8.50. Constate em (a) que sem a filtragem wavelet teríamos 25930 pulsos detectados e com a filtragem wavelet vista em (b), detectamos apenas 5734 pulsos (i.e., uma redução de 77,87% no número de pulsos), os quais são realmente relevantes para compor o mapa.

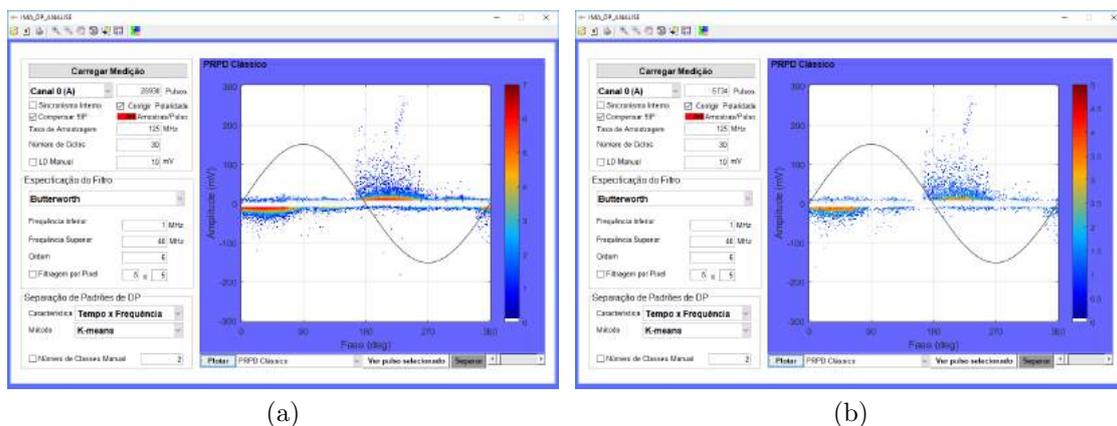


Figura 8.50: PRPD gerado para LD igual a 10 mV: (a) sem filtragem wavelet; (b) com filtragem wavelet.

Outras funcionalidades mais triviais, como defasagem em 90° , LD automático,

visualização pulso a pulso, histogramas de amplitude ou de fase, salvar os pulsos ou mapas PRPD separados em pastas organizadas por tipo de equipamento, opção de idioma inglês/português, já puderam ser compreendidas com as descrições e exemplos dados no Apêndice B. Assim sendo, a seguir, passaremos para os exemplos de caracterização e separação das DP.

8.6.2 Exemplos de Caracterização e Separação dos Padrões de Descargas Parciais

A seguir apresentaremos e discutiremos exemplos para comprovar a capacidade do sistema de caracterização e separação desenvolvido em conseguir discriminar com eficácia os diferentes tipos de DP e até mesmo o ruído que eventualmente pode acometer uma medição.

A Figura 8.51 traz os resultados de separação de dados aqusitados na fase C de um hidrogerador. Na Figura 8.51(a) é exibido o PRPD padrão, no qual é perceptível a provável existência de mais de um padrão de descargas, uma suposição que vem a ser confirmada com a extração da característica PCA da FFT dos pulsos detectados mostrada na Figura 8.51(b). Note que dois *clusters* puderam ser separados pelo método K-means ++, fornecendo os submapas mostrados na Figura 8.51(c). Se recorrermos a [192], podemos identificar mais facilmente que os mesmos correspondem, respectivamente, à atividade de descargas internas (caracterizadas pela simetria na máxima amplitude e na distribuição de pulsos, quando as descargas ocorrendo em ambos semiciclos são comparadas) e de descargas entre barras (ocorre nos terminais do enrolamento entre duas barras quando o espaçamento é muito pequeno para suportar o estresse elétrico, podendo causar a degradação do isolante; produz descargas com amplitude relativamente constante, normalmente superior à amplitude de descargas internas, e são registradas em ambos os semiciclos). A confirmação de que realmente se tratam de padrões diferentes pode ser feita através dos pulso centroide e da FFT centroide ilustrados nas Figuras 8.51(d) e (e), pois ambos apresentam um formato singular.

No segundo caso ilustrado na Figura 8.52 temos a medição do mesmo equipamento só que desta vez através da fase B. Novamente, pela Figura 8.52(a), constatamos dois padrões distintos de descargas, os quais foram separados usando a extração por PCA da FFT dos pulsos e o método K-means, conforme a Figura 8.52(b). Os mapas separados mostrados na Figura 8.52(c) trazem os mesmos padrões (em menor amplitude) descritos para a Figura 8.51, o que é esperado já que se trata do mesmo equipamento. No entanto, percebe-se que o padrão referente à descarga interna está

deslocado em função da defasagem existente entre as fases, mas as descargas entre barras no centro do PRPD (ver Figura 8.52(a)) não surgem deslocadas, isso porque estas têm origem na Fase B (onde têm maior amplitude) e estão se propagando para a Fase C, sobrepondo-se às descargas que ali ocorrem. O pulsos e FFT centroides mostradas nas Figura 8.52(d) e (e) também indicam que são padrões diferentes e parecidos com os obtidos para a fase B.

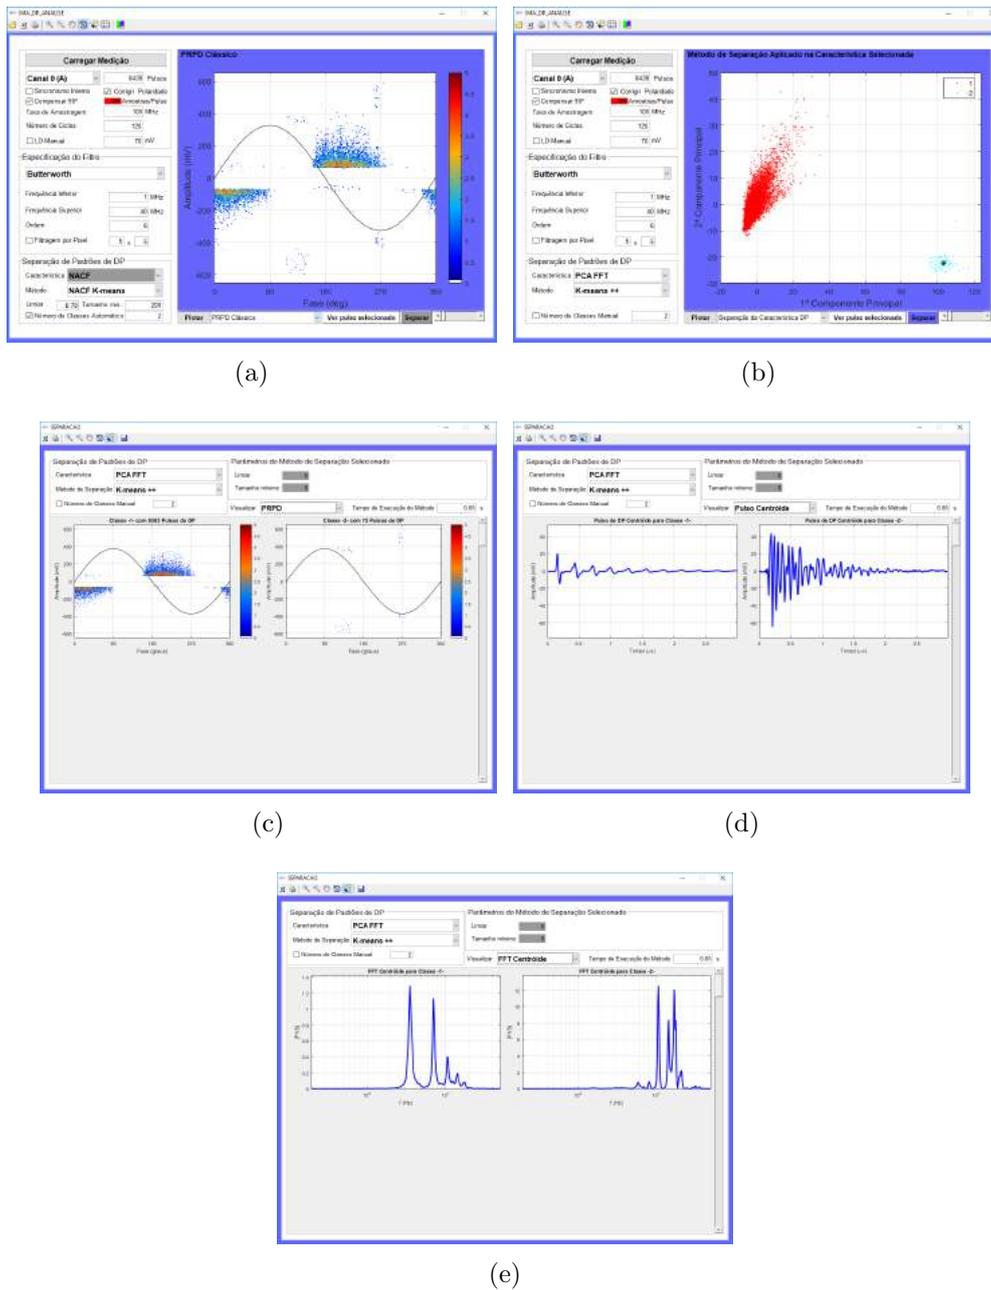
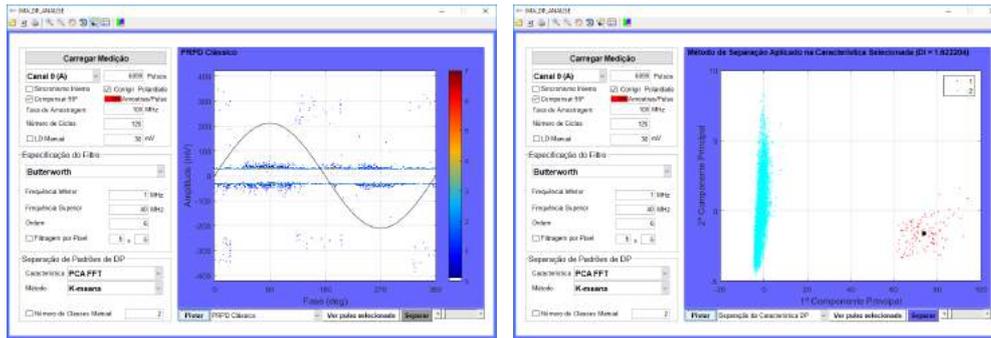
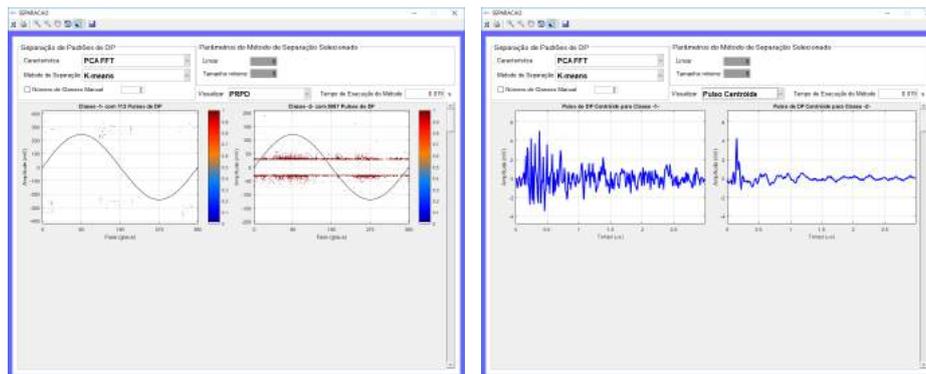


Figura 8.51: Resultado de separação de medição na fase B do hidrogenador: (a) PRPD clássico; (b) Característica PCA da FFT 2D separada; (c) PRPD separado em classes; (d) Pulso centroeide de cada classe; (e) FFT centroeide de cada classe.



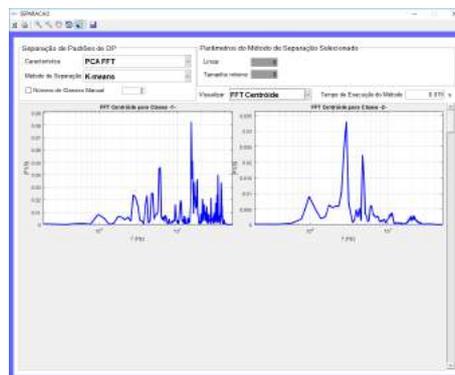
(a)

(b)



(c)

(d)



(e)

Figura 8.52: Resultado de separação de medição na fase C do hidrogerador:(a) PRPD clássico; (b) Característica PCA da FFT 2D separada; (c) PRPD separado em classes; (d) Pulso centróide de cada classe; (e) FFT centróide de cada classe.

Num terceiro exemplo temos os dados aquisitados na fase B de um gerador a diesel. O PRPD obtido é mostrado na Figura 8.53(a), na qual verificam-se diversos padrões de descargas. A separação foi feita utilizando a extração da característica Tempo x Frequência combinada com o método de Seleção Manual 2D, fornecendo três padrões diferentes, como ilustra a Figura 8.53(b). Os mapas separados na Figura 8.53(c) indicam a típica descarga interna com um pouco de sobreposição de descargas das demais fases; a descarga entre barras com maior amplitude e ruído

pulsante, difícil de ser eliminado seja pela filtragem analógica ou digital (Butterworth ou WT). Pelas Figuras 8.53(d) e (e) verifica-se que os padrões foram bem separados, representando pulsos com forma de onda e FFT bem diferentes entre si. Veja que o pulso médio do terceiro padrão não apresenta um formato característico de uma descarga parcial e provavelmente se trata de ruído.

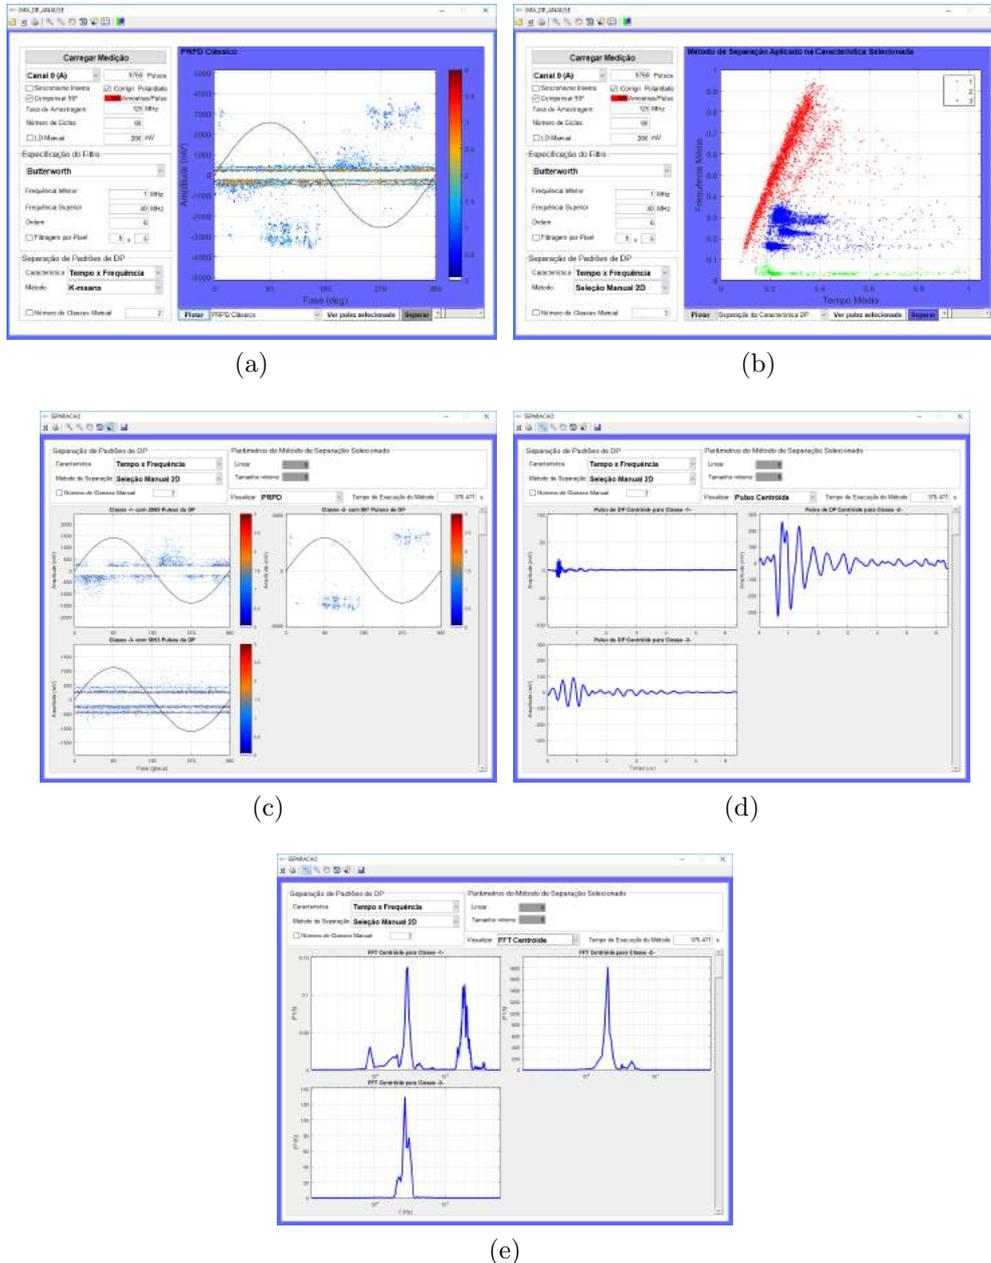


Figura 8.53: Resultado de separação de medição na fase B de um gerador a diesel: (a) PRPD clássico; (b) Característica Tempo x Frequência separada; (c) PRPD separado em classes; (d) Pulso centroide de cada classe; (e) FFT centroide de cada classe.

Como último exemplo de sinal medido em campo, expomos o caso de uma medição em TC avaliado em uma subestação. A Figura 8.54(a) mostra o PRPD

resultante, em que parece haver mais de um padrão de pulsos, o que é confirmado pela separação da característica t-SNE em 2D através do método Hierárquico visto na Figura 8.54(c). Ao avaliar as Figura 8.54(d) e (e), constata-se que existe uma grande semelhança no formato da FFT dos dois primeiros padrões na faixa entre 1 MHz e 2 MHz, e ainda que de forma atenuada também está presente na FFT do último padrão. Tal observação leva a considerarmos a possibilidade de haver um ruído de espectro discreto comum a todos os padrões, sendo este predominante no segundo PRPD separado. Após recorrer a uma pesquisa rápida percebemos que na região onde foi realizada a medição existe uma rádio AM (denominada “Rádio Floresta”), que opera na frequência de 1500 kHz. Esta é exatamente a mesma frequência da componente de maior energia vista nas FFT, ou seja, temos a interferência de um sinal AM, o qual é mais evidente na forma de onda do segundo mapa (Figura 8.54(d)). O terceiro padrão realmente apresenta características de DP. A dúvida que permanece é quanto ao primeiro padrão mostrado na Figura 8.54(c), já que este está bastante contaminado com o ruído AM.

Uma maneira simples de sanar o problema do ruído AM presente na medição do TC é usar um filtro digital com frequência de corte inferior acima de 1.5 MHz. Assim sendo, optamos por reavaliar usando um filtro acima de 2 MHz. O resultado pode ser verificado na Figura 8.55, desta vez conseguimos eliminar o padrão de ruído AM que interferia em todos os demais pulsos. Portanto nos resta concluir que o TC é acometido por dois tipos de sinais de descargas parciais diferentes. Outro ponto desta medição no TC foi a necessidade de se utilizar um número de amostras por pulso igual a 5000, o que é muito maior ao usualmente designado (300). Entretanto, foi essa quantidade que nos permitiu visualizar a existência do ruído AM no gráfico do pulso centroide.

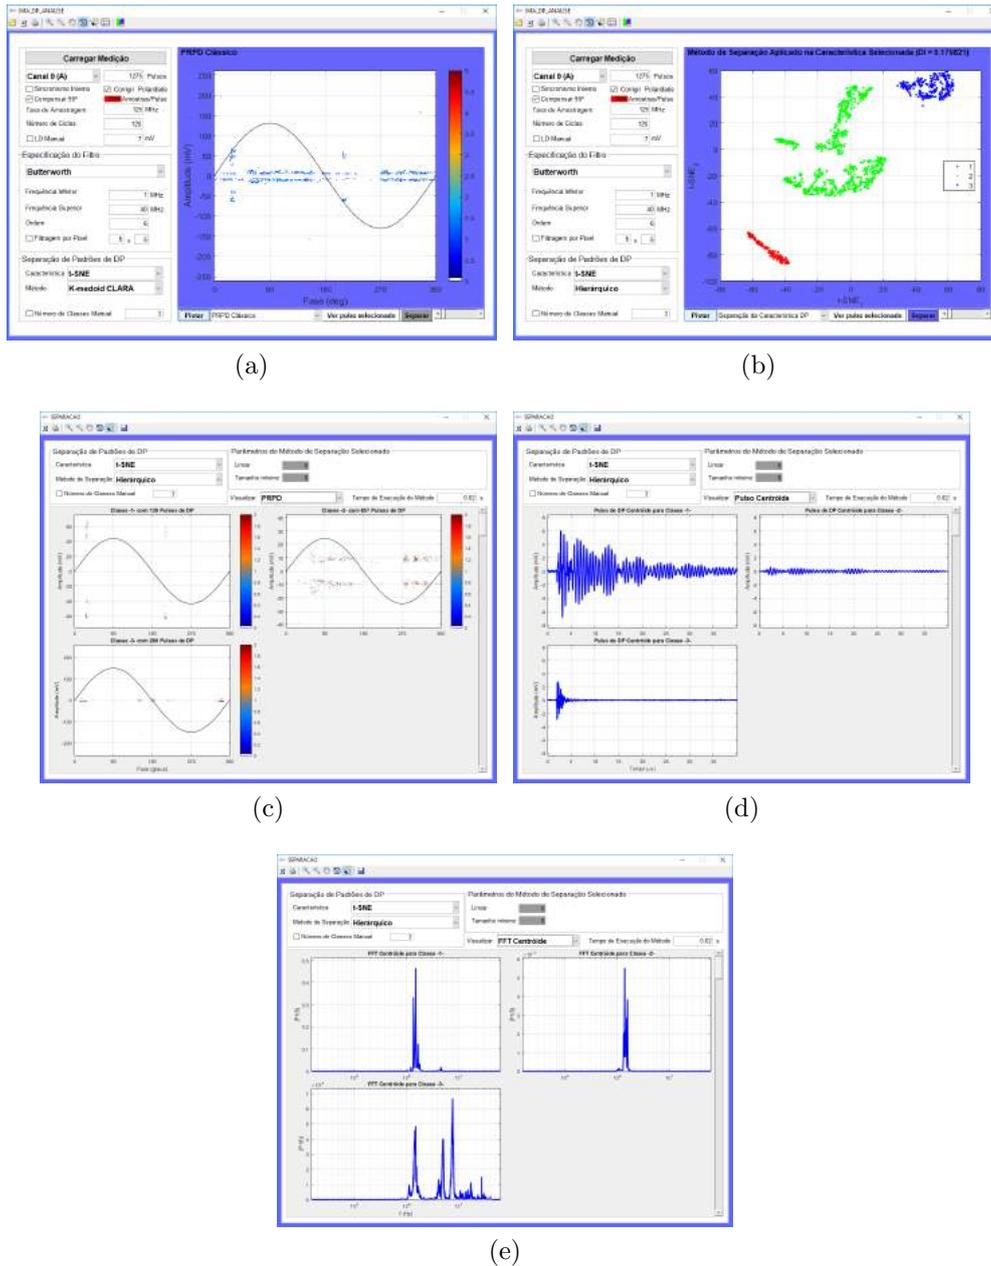
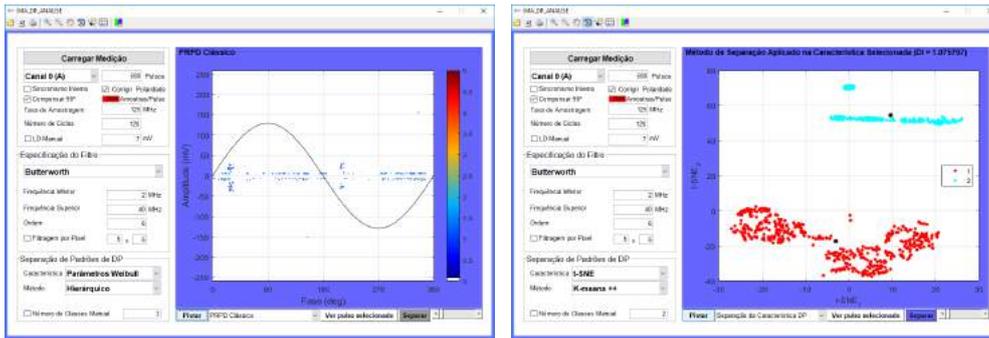


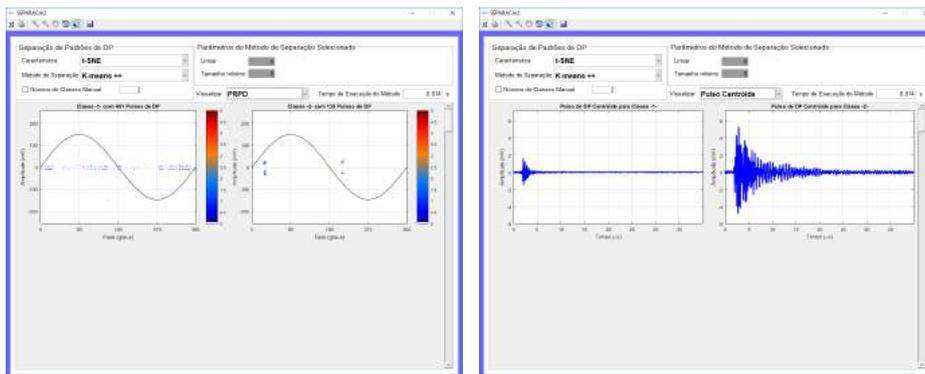
Figura 8.54: Resultado de separação de medição de um TC em uma subestação:(a) PRPD clássico; (b) Característica t-SNE 2D separada; (c) PRPD separado em classes; (d) Pulso centroide de cada classe; (e) FFT centroide de cada classe.

Também avaliamos uma medição feita em laboratório usando as célula C3 e C5 em paralelo sob uma tensão de 18 kV. O mapa obtido é mostrado na Figura 8.56(a), após a separação efetuada com a técnica de extração de características Tempo x Frequência e o método de agrupamento GMD, percebe-se a existência três grupos de pulsos. A Figura 8.56(c) ilustra os padrões de descarga separados, sendo o primeiro gerado pela célula C3, o segundo pela célula C5 e o terceiro padrão é ruído branco que atua com baixa amplitude e em toda a banda de frequência medida, verificar Figuras 8.56(d) e (e).



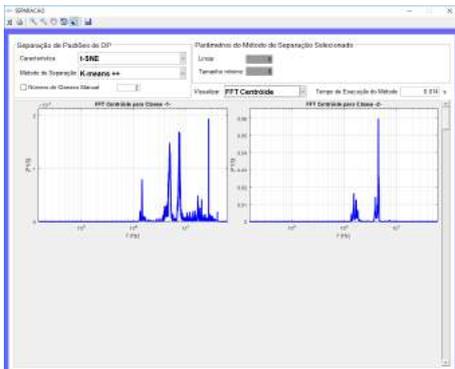
(a)

(b)



(c)

(d)



(e)

Figura 8.55: Resultado de separação de medição de um TC em uma subestação (sem ruído AM):(a) PRPD clássico; (b) Característica t-SNE 2D separada; (c) PRPD separado em classes; (d) Pulso centroide de cada classe; (e) FFT centroide de cada classe.

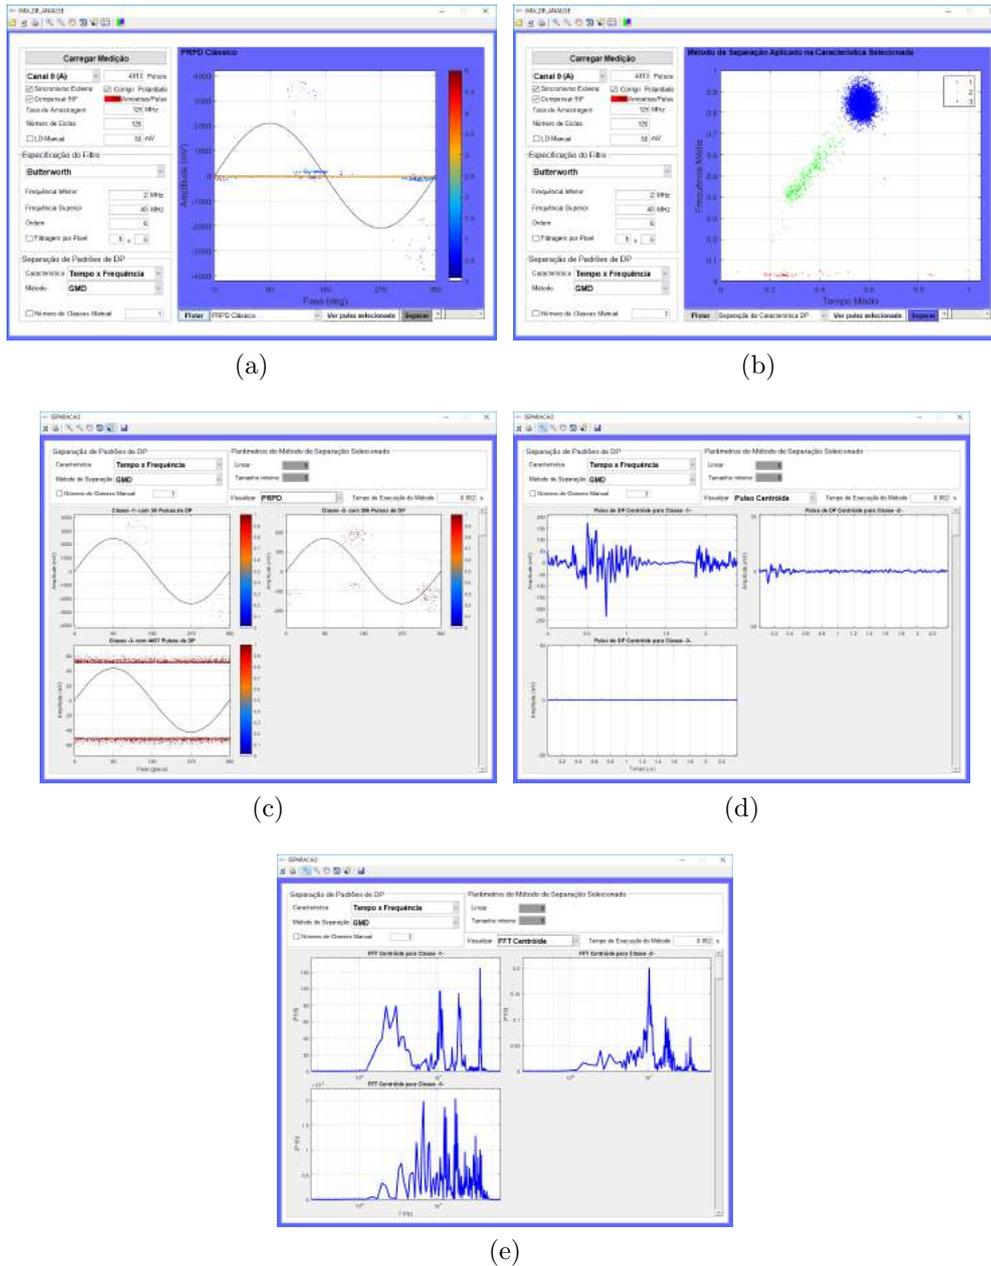


Figura 8.56: Resultado de separação de medição das células C3 e C5 em paralelo: (a) PRPD clássico; (b) Característica Tempo x Frequência separada; (c) PRPD separado em classes; (d) Pulso centroide de cada classe; (e) FFT centroide de cada classe.

Portanto, com os exemplos descritos acima fica demonstrada a capacidade do sistema de análise em atingir os objetivos esperados, especialmente em permitir um melhor diagnóstico do equipamento em avaliação. Deve-se notar que não existe um único método de caracterização e agrupamento que será sempre superior aos demais, pois o resultado de uma boa discriminação dos padrões de descargas ou ruído dependerá do equipamento, de suas características construtivas, de suas condições operacionais no instante da medição, do circuito usado na medição (impedância,

conectores, cabos, filtros, atenuadores, *hardware* de aquisição), do tipo de ruído existente, entre outros, ou seja, uma grande quantidade de variáveis difíceis de serem previstas. Por este motivo é que o sistema de análise e separação de dados de DP proposto neste trabalho traz uma quantidade significativa de ferramentas para garantir ao usuário que ele consiga atingir um diagnóstico mais assertivo ao que teria com o uso de um sistema que forneça apenas as informações clássicas dos histogramas PRPD, de Fase e de Amplitude ou com um único algoritmo de separação de classes.

Além do mais, ao separar cada padrão de pulsos obtido e permitir sua organização por tipo de equipamento e tipo de defeito associado, o sistema é um passo importante para o desenvolvimento de uma metodologia de identificação automática destes padrões, sem depender da expertise de um especialista em sinais de DP.

Capítulo 9

Conclusões e Sugestões de Trabalhos Futuros

Para o setor elétrico, é um grande desafio garantir a continuidade no fornecimento de energia elétrica sem qualquer tipo de interrupção devido a falhas em importantes equipamentos de alta tensão nas etapas de geração, transmissão e distribuição de energia elétrica. Assim, é necessário atestar as condições de trabalho desses equipamentos, principalmente no que se refere ao isolamento, que nos casos de falha pode causar graves danos pessoais e materiais.

Um dos passos mais importantes antes de podermos prosseguir com o desenvolvimento, assim como os testes, dos métodos de processamento, extração de características e separação dos sinais de DP tratados neste trabalho, foi a criação de um banco de dados representativo dos defeitos típicos associados aos pulsos de DP que ocorrem em equipamentos de alta tensão. A forma que consideramos apropriada para iniciar a criação deste banco foi obter dados de equipamentos de campo, tais como: geradores hidrelétricos, geradores a diesel, turbo geradores, PR, TC, TP, disjuntores e GIS. No entanto, como as medições em campo são esporádicas e exigem muito tempo para formar um banco representativo, também tivemos que realizar medições em laboratório. Para isso, utilizamos quatro barras de estator de geradores e seis células de carga construídas para simular os diferentes defeitos que causam DP. As células de carga foram construídas com base na literatura [42], [144], [149], [156]. Cada célula está fisicamente e quimicamente associada a uma ou mais partes de um equipamento, produzindo um padrão peculiar de pulsos de DP normalmente encontrados em medições de campo.

Nos ensaios em laboratório e medições de campo, o circuito foi aplicado de acordo com a norma IEC 60270. Todas as medições foram feitas com o *software*

IMA-DP (Cepel) pelo tempo necessário para fornecer um PRPD de 60 ciclos e outro com 120 ciclos em cada nível diferente de tensão aplicado ao objeto. No final, formamos um banco contendo 144 arquivos de medições de campo e 315 arquivos de testes de laboratório (85 medidos em barras estatóricas e 230 em células de carga). O banco de dados criado foi suficiente para o desenvolvimento do nosso trabalho.

Em sequência, desenvolvemos uma nova função de limiarização, denominada Fleming, unindo a ideia de uma função fortemente diferenciável e uma alternativa mais flexível, possibilitando sua otimização para fornecer um melhor resultado no tratamento do pulso de DP e preservar suas características importantes da descarga. A proposta foi inspirada na conhecida função logística [185], dependente de um parâmetro que controla a declividade da curva no valor de limiar (calculado a priori). Também foram criadas algumas variantes desta mesma função, usando três ideias simples, porém pouco investigadas na literatura: identificar os coeficientes decompostos com maior contribuição na recuperação do sinal de interesse; determinar níveis de limiar diferentes para os coeficientes wavelet positivos e negativos, ao invés de aplicar um único valor para ambos; realizar a busca automática do parâmetro ótimo necessário à nova função usando o conceito de minimização LMS do risco SURE [149], o qual fornece uma estimativa do EQM do sinal após sua filtragem [83].

Com os resultados descritos na Seção 8.3 ficou comprovada a capacidade da função Fleming e de suas variantes (exceto a função Fleming 2 LMS) de superar as funções mais usuais como a abrupta (*hard*) e a suave (*soft*), além de outras doze alternativas desenvolvidas em algumas publicações [70], [83], [153]. Mesmo tendo apresentado bons resultados na atenuação de ruído, esperávamos que as variações que realizam a busca automática da variável de inclinação conseguissem os melhores resultados médios, mas por termos de limitar o número de iterações para não estendermos o tempo de processamento, o método nem sempre conseguiu atingir o valor ótimo de inclinação para a função, o que acarretou em perda de performance. A função Fleming aplicada com valores de inclinação entre 5 e 10 foi capaz de fornecer os melhores resultados em um tempo menor.

A alternativa Fleming 3 apresentou o maior percentual de melhores resultados e a Fleming o maior valor médio em termos de aptidão. Assim, se o objetivo é conseguir uma maior quantidade de resultados superiores, o indicado é limiarizar usando a Fleming 3, mas se o objetivo é conseguir melhores resultados médios deve-se usar a função Fleming. Quanto ao tempo médio de processamento, tais funções são relativamente rápidas comparadas às demais funções, não ficando muito atrás das clássicas abrupta e suave.

Em conjunto com a análise feita para as novas funções verificamos como a mudança das funções WM aplicadas na redução dos coeficientes de ruído em sinais de DP poderia afetar os valores médios dos parâmetros de avaliação em cada um dos métodos de limiarização. Os testes foram feitos usando o método SNRBWS para selecionar as WM em cada nível de decomposição, em que o número máximo de níveis (J) foi definido pelo método NDWLS. As bibliotecas de WM foram avaliadas para cada família mostrada na Subseção 8.2.3, tanto de forma isolada quanto conjunta. Os resultados médios de aptidão J_{Apt} obtidos com a filtragem de todos os 2064 pulsos mostraram que o uso de uma biblioteca contendo apenas wavelets da família *Daubechies* ou wavelets da família *Symlets* são as mais apropriadas para tratar os sinais de DP. Já as demais famílias investigadas como a *Coiflets*, *Legendre* e *Discrete Approximation Meyer* ou quaisquer combinações não conseguiram resultados interessantes. Portanto, na formação de uma biblioteca de funções wavelet podemos dizer que o mais adequado é empregar uma única família e não agrupar várias destas, o que é conveniente até mesmo para acelerar o processo de busca das wavelets por parte de qualquer método de seleção da WM que venha a ser aplicado.

Tal constatação corrobora a afirmação feita em muitos trabalhos publicados [29], [41], [68] de que, devido a suas propriedades e formatos similares aos de pulsos de descarga, as wavelets *Daubechies* e *Symlets* são preferidas para tratar dados de DP.

Outra etapa que conseguimos desenvolver neste trabalho foi a de implementação de técnicas de extração de características e de separação dos pulsos detectados durante a medição de DP. Inicialmente foi dada especial atenção ao aperfeiçoamento da metodologia de separação de pulsos NACF K-means descrita em [51], pois, apesar de conseguir realizar a distinção entre os diferentes tipos de defeitos associados às descargas parciais, levava muito tempo para conseguir efetuar esta tarefa. Em vista desta desvantagem e percebendo que o mesmo poderia ser otimizado, decidimos modificar alguns passos do algoritmo para acelerar seu processamento sem comprometer a sua eficácia.

A primeira mudança foi alterar as equações de ACF e de limiar para serem calculadas mais rapidamente. Tal modificação contribui para a redução do tempo de execução, mas de forma pouco significativa.

A segunda alteração proposta foi substituir a correlação de Pearson p_c como métrica de distância do algoritmo K-means por outras métricas, tais como: o coeficiente de correlação de postos de Spearman, o coeficiente de correlação tau de Kendall, a similaridade Coseno, a métrica *City block* e a distância *Chebychev* (diferença de coordenada máxima). As métricas Spearman e tau de Kendall mostraram-se

inapropriadas para substituir a correlação de Pearson, entretanto, as demais foram adequadas e bem mais rápidas pelos resultados obtidos na avaliação de medições de DP, necessitando apenas do ajuste adequado no valor de limiar usado para cada uma. Todas as novas métricas propostas para o método NACF K-means atingiram o objetivo de melhoria na performance de processamento dos sinais de DP, obtendo reduções importantes em comparação com a métrica de correlação, principalmente para grandes quantidades de pulsos (variando de 10% a 25%). Também vimos que independentemente da métrica aplicada, o método é bastante sensível à variação dos parâmetros de limiar e do número mínimo de pulsos para formar uma classe, necessitando de cuidados na especificação dos mesmos. Limiares muito altos não são indicados para a maioria das medições, pois podem demorar demais quando têm que lidar com muitos pulsos e tendem a não separar os padrões, gerando apenas uma classe (denominada como não classe) principalmente para um valor de número mínimo de pulsos elevado.

Por último, verificamos que ao invés de usar o demorado e equivocado teste χ^2 seria mais eficaz usar a correlação de Pearson entre os pulsos centroides dos padrões de PRPD gerados para poder avaliar a similaridade entre os mapas PRPD produzidos, e assim decidir quais deles devem ser agrupados. Essa alteração contribuiu bastante para acelerar o método NACF K-means para todas as métricas sem afetar a performance de separação.

Ao gerar um mapa PRPD, uma tarefa crucial é identificar a polaridade dos pulsos e esta nem sempre é simples, podendo apresentar erros que geram confusão no diagnóstico do equipamento avaliado, principalmente quando a medição é afetada por ruído que distorce a forma de onda do pulso que chega ao *hardware* de aquisição. Assim sendo, apresentamos uma nova técnica visando reduzir a quantidade de erros de atribuição de polaridade que acontecem com os métodos tradicionais normalmente empregados em diversos dos sistemas de avaliação de equipamentos de alta tensão por diagnóstico de DP. O novo algoritmo realiza uma combinação dos métodos usuais para obter uma maior precisão na identificação da polaridade dos pulsos. Além disso, usamos o conceito de correlação para ajudar a determinar a polaridade do pulso avaliado (seja este proveniente de DP ou não).

Foram mostrados alguns exemplos comparando os histogramas PRPD gerados pelo método de primeiro cruzamento de LD com o que propusemos. Os resultados evidenciaram a capacidade de correção da nossa técnica em comparação com a que é tradicionalmente utilizada. Ainda que nossa proposta não seja perfeita e possa identificar erroneamente alguns poucos pulsos, temos uma melhora considerável na apresentação dos dados para a maioria das medições. Ademais, também existirão

casos em que os pulsos medidos possuem um formato tal que facilita a correta identificação de sua polaridade por ambos métodos, produzindo um PRPD com características bem definidas.

Em seguida, apresentamos uma nova metodologia para obter uma estimativa da resposta em frequência do sistema que está sendo avaliado. Inclui-se no sistema a região onde a descarga se origina dentro do equipamento até o hardware de aquisição, i.e., a estimativa representará a RF do objeto testado, da impedância de medição, dos cabos, dos conectores e de quaisquer outros componentes acoplados ao circuito de medição, como filtros e atenuadores. A ideia apresentada foi a de usar os pulsos detectados na medição de DP para estimar a RF do sistema. Tal proposta advém da técnica que faz uso de impulsos para encontrar a RF de um circuito, mas neste caso é necessário conhecer o impulso na entrada e saída deste circuito. No entanto, em se tratando de impulsos de descargas parciais é impossível saber exatamente o formato do sinal na entrada do circuito (descarga ocorrendo na imperfeição no interior do isolante), pois a mesma não é fisicamente acessível. É por esta razão que enfatizamos que o nosso método fornece apenas uma estimativa da RF do circuito sob teste.

A estimativa é feita iterativamente a partir da DFT de cada pulso detectado, onde é armazenado o ganho máximo em dB para cada componente de frequência. Após percorrer todos os pulsos teremos a DFT estimada, que depois de ser normalizada para um ganho máximo igual a 0 dB nos fornecerá a RF estimada. Este processo busca reproduzir a retenção de máximo de um analisador de espectro.

Para demonstrar a capacidade de estimar a RF em frequência de um sistema fizemos simulações em uma barra e em uma célula de carga em laboratório. Verificamos que a RF simulada, a RF medida por impulsos gerados diretamente num gerador de sinais e a RF medida a partir da avaliação de DP deste mesmo objeto eram bastante similares, e que até mesmo possuíam frequências de ressonância e antirressonância em pontos similares. No caso da barra estatórica, foi vista uma pequena diferença em relação a RF simulada, pois não conseguimos modelar a impedância (predominantemente capacitiva) entre o condutor da barra e a malha de terra que a envolvia, mas para a célula de carga em que este efeito foi desprezível verificamos que a RF obtida foi muito próxima à simulada em seu formato (considerando a normalização de ganho). Portanto, estes resultados indicam a capacidade do método em fornecer uma boa aproximação da RF real do sistema usando apenas os pulsos detectados durante a medição.

Podemos concluir que a estimativa da RF é útil para: identificarmos a banda de frequência de maior ocorrência dos pulsos medidos, podendo auxiliar na medição

do equipamento avaliado; estimar os pulsos originais ocorrendo dentro do isolante do equipamento como foi mostrado no Capítulo 7, o que possibilita uma melhor estimativa da carga real (em picocoulombs) de cada pulso; verificar se os padrões discriminados pelo programa de análise e separação de dados pertencem a classes diferentes. No entanto, é importante considerar a necessidade de que uma quantidade expressiva de pulsos seja detectada durante a medição para que a estimativa obtida represente com boa fidelidade a RF real do sistema medido.

Na Seção 8.6, utilizando-se de alguns dos sinais existentes no banco de dados que criamos, foram mostrados os resultados médios de performance quanto ao tempo de processamento e qualidade da separação realizada para alguns dos diferentes métodos de extração de características e de agrupamento. Quanto ao tempo de processamento dos métodos de extração de características, verificamos que todos são bastante rápidos quando têm de lidar com medições contendo menos de 1000 pulsos, levando em média menos de 3 segundos para serem executados. No entanto, quando a quantidade de pulsos da medição é maior do que 1000 pulsos alguns dos métodos se tornam bastante lentos, por exemplo, extração por: PCA Exponencial, PCA Probabilística, PCA da FFT Exponencial, PCA da FFT Probabilística, Power Ratio, MDS Análise Fatorial, MDS Sammon Mapping e MDS SPE. Portanto, não se indica o seu uso exceto quando os mais rápidos não conseguirem boa performance na separação dos diferentes padrões de pulsos. A atribuição de método mais rápido e mais lento ficam, respectivamente, com os métodos Tempo x Frequência e PCA Exponencial em 3D.

Em seguida, foram apresentados os resultados de tempo de processamento e Índice de Dunn dos métodos de agrupamento combinados com algumas das técnicas de extração e características. Quando tratando dados com menos de 1000 pulsos, percebe-se que para todos os diferentes algoritmos de extração o tempo de processamento do método de agrupamento permanece praticamente igual, exceto para o método manual (aplicável somente para características em 2D) por depender da rapidez com que o usuário avalia cada gráfico de característica projetado. Mais especificamente, os métodos K-means, K-means ++, K-medoid CLARA, Fuzzy C-means, Hierárquico e GMD são bastante rápidos em sua execução; o método K-medoid PAM necessita de um pouco mais de tempo (não superior a 4 s), e as variantes dos métodos NACF K-means precisam de um tempo relativamente elevado, devido às diferentes etapas de busca envolvidas em seu algoritmo. Para dados com uma quantidade grande de pulsos, a diferença no tempo de processamento entre os métodos torna-se mais expressiva. Portanto, assim como ocorre para as técnicas de extração, é indicado que primeiro apliquem-se as técnicas mais rápidas e, caso estas não gerem resultados satisfatórios de separação dos padrões, se deve recorrer aos métodos

mais custosos, como o NACF K-means ou o de seleção manual em 2D. Quanto à qualidade da separação indicada pelo ID atingido em cada alternativa, não se pode precisar qual a melhor combinação entre as técnicas, pois irão depender dos dados adquiridos que podem diferir bastante de um equipamento para outro, além de outras variáveis que interferem no formato dos pulsos em cada nova medição. Esta observação demonstra a importância de se ter uma variedade de métodos, ao invés de adotar um único para compor um sistema de separação e/ou classificação de dados de DP.

Também mostramos uma nova alternativa de filtragem dos dados de DP, esta é aplicada diretamente na imagem do PRPD, realizando uma varredura *pixel a pixel* do mapa gerado em uma medição para eliminar pontos dispersos que podem ser adquiridos. Com esta alternativa de filtragem por caixa de *pixel* é possível obter um mapa PRPD bem definido, facilitando a identificação dos diferentes padrões de descargas que possam estar presentes.

Por fim, apresentamos o sistema de análise e separação de dados de DP, o qual agrega todos os estudos descritos acima, além de outras funcionalidades, tais como: filtragem digital Butterworth; defasagem em 90° ; *LD* automático; visualização pulso a pulso; histogramas de amplitude ou de fase; armazenamento dos pulsos ou mapas PRPD separados em pastas organizadas por tipo de equipamento; opção de idioma inglês/português; criação automática de relatório. Uma avaliação extra demonstrada, apesar de ainda não incorporada ao sistema, foi o uso da filtragem por WT (combinada aos métodos de escolha dos parâmetros wavelet que desenvolvemos, e.g., SNRBWS e Limiarização Fleming) para redução de ruído branco presente nos sinais adquiridos. Esta opção de filtragem se mostrou muito eficiente em limpar os dados, diminuindo a quantidade de informações de ruído desnecessárias sem afetar as características de amplitude e fase dos pulsos de descarga, o que contribui para acelerar o processamento e facilitar a separação dos tipos diferentes de pulsos.

Com os exemplos das diferentes funcionalidades do sistema vistos na Seção 8.6, conclui-se que o mesmo é uma ferramenta útil, com capacidade de auxiliar na análise dos dados obtidos nas medições de DP e possibilitar a sua separação em padrões de defeitos, o que também abre caminho para a posterior identificação automática dos mesmos com técnicas de classificação por redes neurais supervisionadas.

Portanto, o sistema de análise e separação de dados de DP desenvolvido neste trabalho auxilia especialistas na localização e na identificação das fontes causadoras de defeitos no isolante do equipamento sob ensaio. Com isso, é possível obter um diagnóstico mais preciso das condições operacionais e, conseqüentemente, facilitar a manutenção preditiva e/ou corretiva deste equipamento.

De modo geral, todos os estudos apresentados foram capazes de atingir seus objetivos de maneira satisfatória. Obviamente, é possível dar continuidade ao processo de análise de dados de DP para aperfeiçoar o diagnóstico dos diversos equipamentos de um sistema elétrico de potência. A seguir apresentaremos algumas propostas de trabalhos futuros.

9.1 Sugestões de Trabalhos Futuros

Conforme verificamos, embora os métodos e o sistema de análise aqui apresentados tenham atingido seus objetivos, o próximo passo é implementar a opção de filtragem por WT, incorporando as modificações que propusemos de seleção das funções wavelet pelo método SNRBWS, a seleção do número de níveis de decomposição pelo algoritmo NDWLS e a limiarização através da função Fleming. Ao aplicar tal ferramenta teremos um ganho considerável de performance por diminuir o volume de informações com que o sistema terá de lidar.

Ainda dentro do campo da WT, poderia ser investigado o uso de outras estruturas de decomposição wavelet que não a clássica FWT, como a SWT, WPT e DTCWT. Sabendo da existência destas variações, acreditamos que adaptar e avaliar a performance dos métodos de seleção dos parâmetros wavelet que desenvolvemos ampliaria o seu entendimento e, por sua vez, a aplicabilidade de cada um.

A estimativa da RF de um sistema sob medição usando os pulsos de DP foi validado apenas em laboratório. Seria adequado avaliar esta nova metodologia em um equipamento real de RF conhecida, como é o caso de transformadores de potência que são submetidos a avaliações periódicas de RF usando o método tradicional de varredura (*offline*). Desta forma seria possível realizar uma comparação entre a RF estimada e a RF real do equipamento avaliado.

Outra etapa a ser implementada é a introdução de um algoritmo de classificação automática dos tipos de pulsos separados pelo sistema de análise usando redes neurais com treinamento supervisionado para a identificação de defeitos específicos em certos equipamentos. No entanto, essa não é uma tarefa simples, pois é preciso considerar que os defeitos típicos que ocasionam as descargas parciais são em sua maioria diferentes para os equipamentos de alta tensão existentes, sejam geradores, GIS, TC, TP, disjuntores, cabos, PR, transformadores. Então, é importante ter uma quantidade considerável de amostras de DP de cada tipo de defeito associado a cada tipo de equipamento. Por isso neste trabalho foi destacada a importância da criação do banco de dados, o qual deve ser expandido para que se tenha um número

representativo de pulsos de cada classe de defeito. O algoritmo de classificação pode seguir por dois caminhos distintos, sendo que em um deles uma rede neural seria treinada diretamente com os dados dos pulsos aquisitados e, no outro, a rede seria treinada com dados de imagem do histograma PRPD (caso em que a filtragem por pixel pode ser bastante útil).

Atualmente os dados processados pelo sistema proposto são obtidos por meio de outro programa, o IMA-DP, o qual foi desenvolvido usando o *software* LabVIEW. Portanto, outra possibilidade seria adicionar ao sistema projetado as etapas de leitura, aquisição e gravação direta dos sinais de DP a partir do *hardware* de aquisição de dados. Ou então, seguir o caminho contrário e programar nosso sistema ao produto Cepel na plataforma de desenvolvimento do LabVIEW, a qual costuma apresentar excelente performance quanto ao tempo de processamento por utilizar 100% da capacidade do processador de uma máquina, enquanto que o Matlab está limitado a 1/3 desta capacidade.

Referências Bibliográficas

- [1] HONGXIA, L., XUEFENG, Z. “A Method of Second Wavelet Transform Automated Threshold for Partial Discharge Signal Extraction”. In: *Digital Manufacturing and Automation (ICDMA), 2011 Second International Conference on*, pp. 42–45, Aug. 2011. doi: 10.1109/ICDMA.2011.19.
- [2] LALITHA, E., SATISH, L. “Wavelet Analysis For Classification of Multi-source PD Patterns”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 7, n. 1, pp. 40–47, Feb. 2000. ISSN: 1070-9878. doi: 10.1109/94.839339.
- [3] MEIJER, S., AGORIS, P. D., SEITZ, P. P., et al. “Condition assessment of power cable accessories using advanced VHF/UHF PD detection”. In: *Conference Record of the 2006 IEEE International Symposium on Electrical Insulation*, pp. 482–485, June 2006. doi: 10.1109/ELINSL.2006.1665361.
- [4] *IEC 60270 - High-voltage Test Techniques: Partial Discharge Measurements, Third Edition (2000)*, 3 ed., 2000.
- [5] HADDAD, A., WARNE, D. F. *Advances in High Voltage Engineering*. IET Power and Energy Series, London, UK, 2007. ISBN: 978-1-84919-038-1.
- [6] TIAN, Y., LEWIN, P. L., DAVIES, A. E. “Comparison of on-line partial discharge detection methods for HV cable joints”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 9, n. 4, pp. 604–615, Aug 2002. ISSN: 1070-9878. doi: 10.1109/TDEI.2002.1024439.
- [7] WANG, X., LI, B., ROMAN, H. T., et al. “Acousto-optical PD detection for transformers”, *IEEE Transactions on Power Delivery*, v. 21, n. 3, pp. 1068–1073, July 2006. ISSN: 0885-8977. doi: 10.1109/TPWRD.2005.861242.
- [8] WANG, L., FANG, N., WU, C., et al. “A Fiber Optic PD Sensor Using a Balanced Sagnac Interferometer and an EDFA-Based DOP Tunable Fi-

- ber Ring Laser”, *Sensors*, v. 14, n. 5, pp. 83–98, 2014. ISSN: 1424-8220. doi: 10.3390/s140508398. Disponível em: <<http://www.mdpi.com/1424-8220/14/5/8398>>.
- [9] POSADA-ROMAN, J., GARCIA-SOUTO, J. A., RUBIO-SERRANO, J. “Fiber Optic Sensor for Acoustic Detection of Partial Discharges in Oil-Paper Insulated Electrical Systems”, *Sensors*, v. 12, n. 4, pp. 4793, 2012. ISSN: 1424-8220. doi: 10.3390/s120404793. Disponível em: <<http://www.mdpi.com/1424-8220/12/4/4793>>.
- [10] MORTAZAVI, S. H., SHAHRTASH, S. M. “Comparing Denoising Performance of DWT, WPT, SWT and DT-CWT for Partial Discharge Signals”, *Universities Power Engineering Conference, 2008. UPEC 2008. 43rd International*, pp. 1–6, Sep. 2008. doi: 10.1109/UPEC.2008.4651625.
- [11] SATISH, L., NAZNEEN, B. “Wavelet Denoising of PD Signals Buried in Excessive Noise and Interference”, *IEEE Trans. Dielect. Elect. Insul.*, v. 10, n. 2, pp. 354–367, Apr. 2003.
- [12] YOU, F., ZHANG, Y. “An Improved Wavelet Threshold Denoising Method for Transformer Partial Discharge Signal”. In: *Green Power, Materials and Manufacturing Technology and Applications II*, v. 214, *Applied Mechanics and Materials*, pp. 148–153. Trans Tech Publications, 11 2012. doi: 10.4028/www.scientific.net/AMM.214.148.
- [13] KONIG, G., FESER, K. “A New Digital Filter to Reduce Periodic Noise in Partial Discharge Measurements”, *6th International Sympos. HV Engineering*, pp. 1–4, 1989.
- [14] MALLAT, S., HWANG, W. L. “Singularity detection and processing with wavelets”, *IEEE Transactions on Information Theory*, v. 38, n. 2, pp. 617–643, March 1992. ISSN: 0018-9448. doi: 10.1109/18.119727.
- [15] SHIM, I., SORAGHAN, J., SIEW, W. “Detection of PD Utilizing Digital Signal Processing Methods. Part 3: Open-loop Noise Reduction”, *Electrical Insulation Magazine, IEEE*, v. 17, n. 1, pp. 6–13, Jan./Feb. 2001.
- [16] SHIM, I., SORAGHAN, J., SIEW, W. “Digital Signal Processing Applied to the Detection of Partial Discharge: an Overview”, *Electrical Insulation Magazine, IEEE*, v. 16, n. 3, pp. 6–12, may-june 2000. ISSN: 0883-7554. doi: 10.1109/57.845021.

- [17] SRIRAM, S., NITIN, S., PRABHU, K. M. M., et al. “Signal denoising techniques for partial discharge measurements”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 12, n. 6, pp. 1182–1191, Dec. 2005. ISSN: 1070-9878. doi: 10.1109/TDEI.2005.1561798.
- [18] NETTO, P. S. R., SILVA, S. L., EDUARDO, A. B. D. *Digital Signal Processing System Analysis and Design*. 2 ed. New York, Cambridge, 2001.
- [19] MA, X. D., ZHOU, C., KEMP, I. J. “DSP based partial discharge characterisation by wavelet analysis”. In: *Discharges and Electrical Insulation in Vacuum, 2000. Proceedings. ISDEIV. XIXth International Symposium on*, v. 2, pp. 780–783 vol.2, 2000. doi: 10.1109/DEIV.2000.879104.
- [20] MA, X., ZHOU, C., KEMP, I. “Interpretation of wavelet analysis and its application in partial discharge detections”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 9, n. 3, pp. 446–457, Jun. 2002. ISSN: 1070-9878. doi: 10.1109/TDEI.2002.1007709.
- [21] ZHONGRONG, X., JU, T., CAIXIN, S. “Application of Complex Wavelet Transform to Suppress White Noise in GIS UHF PD Signals”, *Power Delivery, IEEE Transactions on*, v. 22, n. 3, pp. 1498–1504, Jul. 2007. ISSN: 0885-8977. doi: 10.1109/TPWRD.2007.899767.
- [22] DAUBECHIES, I. “Ten Lectures on Wavelet”, *Society for Industrial and Applied Mathematics*, 1992.
- [23] CHANG, C., JIN, J., KUMAR, S., et al. “Denoising of Partial Discharge Signals in Wavelet Packets Domain”, *Science, Measurement and Technology, IEEE Proceedings*, v. 152, n. 3, pp. 129–140, May. 2005. ISSN: 1350-2344. doi: 10.1049/ip-smt:20041315.
- [24] TANG, M., LI, H., LIU, X., et al. “Medium voltage cable partial discharge signals denoising by Second Generation Wavelet Packet Transform”. In: *Information and Automation (ICIA), 2013 IEEE International Conference on*, pp. 1097–1102, Aug 2013. doi: 10.1109/ICInfA.2013.6720459.
- [25] W. GAO, S., ZHANG, M., H. YUAN, C., et al. “Wavelet Packet Analyzing of Power Transformer Partial Discharge Signals”. In: *Control, Automation and Systems Engineering (CASE), 2011 International Conference on*, pp. 1–4, July 2011. doi: 10.1109/ICCASE.2011.5997569.
- [26] KYPRIANOU, A., GEORGHIOU, G. “Wavelet Packet Denoising for On-Line Partial Discharge Detection in High Voltage Systems”. In: *Proceedings of*

the 2005 IEEE International Symposium on, Mediterrean Conference on Control and Automation Intelligent Control, 2005., pp. 1184–1189, June 2005. doi: 10.1109/.2005.1467183.

- [27] PETRARCA, C., LUPO, G. “Wavelet Packet Denoising of Partial Discharge Data”. In: *2006 IEEE Conference on Electrical Insulation and Dielectric Phenomena*, pp. 644–647, Oct 2006. doi: 10.1109/CEIDP.2006.312014.
- [28] MALLAT, S. G. “A Theory For Multiresolution Signal Decomposition: the Wavelet Representation”, *IEEE Transaction Pattern Anal*, v. 11, pp. 674–693, 1989.
- [29] MA, X., ZHOU, C., KEMP, I. “Automated Wavelet Selection and Thresholding For PD Detection”, *Electrical Insulation Magazine, IEEE*, v. 18, n. 2, pp. 37–45, Mar./Apr. 2002. ISSN: 0883-7554. doi: 10.1109/57.995398.
- [30] DONOHO, D. L., JOHNSTONE, I. M. “Adapting to Unknown Smoothness via Wavelet Shrinkage”, *J. Amer. Stat. Assoc*, v. 90, pp. 1200–1224, 1995.
- [31] LI, J., SUN, C., YANG, J. “Adaptive De-noising For PD Online Monitoring based on Wavelet Transform”, *IEEE Southeast Conf., Memphis, USA*, pp. 71–74, 2006.
- [32] AGORIS, P. D., MEIJER, S., GULSKI, E., et al. “Threshold selection for wavelet denoising of partial discharge data”. In: *Electrical Insulation, 2004. Conference Record of the 2004 IEEE International Symposium on*, pp. 62–65, Sept 2004. doi: 10.1109/ELINSL.2004.1380450.
- [33] CUNHA, C. F., CARVALHO, A. T., PETRAGLIA, M. R., et al. “A new wavelet selection method for partial discharge denoising”, *Electric Power Systems Research*, v. 125, pp. 184 – 195, 2015. ISSN: 0378-7796. doi: <http://dx.doi.org/10.1016/j.epsr.2015.04.005>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S037877961500111X>>.
- [34] SARDY, S. “Minimax threshold for denoising complex signals with Waveshrink”, *IEEE Transactions on Signal Processing*, v. 48, n. 4, pp. 1023–1028, Apr 2000. ISSN: 1053-587X. doi: 10.1109/78.827536.
- [35] CUNHA, C. F. F. D. C. *Aplicação da Transformada Wavelet na Redução de Ruídos em Medições de Descargas Parciais*. Ms.C. dissertation, Federal University of Rio de Janeiro (UFRJ), Rio de Janeiro, Rio de Janeiro, Brazil, Dec. 2013.

- [36] RAY, P., MAITRA, A. K., BASURAY, A. “A new threshold function for de-noising partial discharge signal based on wavelet transform”. In: *Signal Processing Image Processing Pattern Recognition (ICSIPR), 2013 International Conference on*, pp. 185–189, Feb 2013. doi: 10.1109/ICSIPR.2013.6497985.
- [37] COIFMAN, R. R., DONOHO, D. L. *Translation-invariant De-noising, Wavelets and Statistics*. Springer Yale University, Stanford University, USA, 1995.
- [38] BUI, T. D., CHEN, G. “Translation-invariant denoising using multiwavelets”, *IEEE Transactions on Signal Processing*, v. 46, n. 12, pp. 3414–3420, Dec 1998. ISSN: 1053-587X. doi: 10.1109/78.735315.
- [39] LI, J., CHENG, C., JIANG, T., et al. “Wavelet de-noising of partial discharge signals based on genetic adaptive threshold estimation”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 19, n. 2, pp. 543–549, April 2012. ISSN: 1070-9878. doi: 10.1109/TDEI.2012.6180248.
- [40] CARVALHO, A. T. D. *Seleção de Bases Wavelet para a Redução de Ruído de Banda Larga em Medições de Descargas Parciais em Máquinas Síncronas*. Ds.C. thesis, Federal University of Rio de Janeiro (UFRJ), Rio de Janeiro, Rio de Janeiro, Brazil, February 2014.
- [41] LI, J., JIANG, T., GRZYBOWSKI, S., et al. “Scale dependent wavelet selection for de-noising of partial discharge detection”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 17, n. 6, pp. 1705–1714, dec. 2010. ISSN: 1070-9878. doi: 10.1109/TDEI.2010.5658220.
- [42] EVAGOROU, D., KYPRIANOU, A., LEWIN, P., et al. “Feature extraction of partial discharge signals using the wavelet packet transform and classification with a probabilistic neural network”. v. 4, pp. 177–192, April 2010. Disponível em: <<http://eprints.soton.ac.uk/370429/>>.
- [43] ZHAOHENG, D., SHANGHE, L., LEI, W. “Selection of the optimal wavelet bases for wavelet de-noising of partial discharge signal”. In: *Signal Processing Systems (ICSPS), 2010 2nd International Conference on*, v. 3, pp. V3–400–V3–404, July 2010. doi: 10.1109/ICSPS.2010.5555675.
- [44] HAO, L., LEWIN, P., HUNTER, J., et al. “Discrimination of multiple PD sources using wavelet decomposition and principal component analysis”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 18, n. 5,

pp. 1702–1711, october 2011. ISSN: 1070-9878. doi: 10.1109/TDEI.2011.6032842.

- [45] XIAORONG, W., ZONGJUN, G., YONG, S., et al. “Extraction of partial discharge pulse via wavelet shrinkage”. In: *Properties and Applications of Dielectric Materials, 2000. Proceedings of the 6th International Conference on*, v. 2, pp. 685–688 vol.2, 2000. doi: 10.1109/ICPADM.2000.876113.
- [46] ZHOU, X., ZHOU, C., KEMP, I. J. “An improved methodology for application of wavelet transform to partial discharge measurement denoising”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 12, n. 3, pp. 586–594, June 2005. ISSN: 1070-9878. doi: 10.1109/TDEI.2005.1453464.
- [47] KARTHIKEYAN, B., GOPAL, S., VENKATESH, S. “{ART} 2—an unsupervised neural network for {PD} pattern recognition and classification”, *Expert Systems with Applications*, v. 31, n. 2, pp. 345–350, 2006. ISSN: 0957-4174. doi: <http://dx.doi.org/10.1016/j.eswa.2005.09.029>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0957417405002216>.
- [48] BARTNIKAS, R., NOVAK, J. P. “On the character of different forms of partial discharge and their related terminologies”, *IEEE Transactions on Electrical Insulation*, v. 28, n. 6, pp. 956–968, Dec 1993. ISSN: 0018-9367. doi: 10.1109/14.249369.
- [49] STONE, G. C., SEDDING, H. G., FUJIMOTO, N., et al. “Practical implementation of ultrawideband partial discharge detectors”, *IEEE Transactions on Electrical Insulation*, v. 27, n. 1, pp. 70–81, Feb 1992. ISSN: 0018-9367. doi: 10.1109/14.123442.
- [50] MORSHUIS, P. H. F. “Partial discharge mechanisms in voids related to dielectric degradation”, *IEE Proceedings - Science, Measurement and Technology*, v. 142, n. 1, pp. 62–68, Jan 1995. ISSN: 1350-2344. doi: 10.1049/ip-smt:19951562.
- [51] CONTIN, A., PASTORE, S. “Classification and separation of partial discharge signals by means of their auto-correlation function evaluation”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 16, n. 6, pp. 1609–1622, December 2009. ISSN: 1070-9878. doi: 10.1109/TDEI.2009.5361581.
- [52] RAYMOND, W. J. K., ILLIAS, H. A., BAKAR, A. H. A., et al. “Partial discharge classifications: Review of recent progress”, *Measurement*, v. 68, pp. 164–181, 2015. ISSN: 0263-2241. doi: <http://dx.doi.org/>

org/10.1016/j.measurement.2015.02.032. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0263224115000901>>.

- [53] VENKATESH, S., GOPAL, S. “Robust Heteroscedastic Probabilistic Neural Network for multiple source partial discharge pattern recognition – Significance of outliers on classification capability”, *Expert Systems with Applications*, v. 38, n. 9, pp. 11501 – 11514, 2011. ISSN: 0957-4174. doi: <http://dx.doi.org/10.1016/j.eswa.2011.03.026>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417411004349>>.
- [54] HOOFF, M., FREISLEBEN, B., PATSCH, R. “PD source identification with novel discharge parameters using counterpropagation neural networks”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 4, n. 1, pp. 17–32, Feb 1997. ISSN: 1070-9878. doi: 10.1109/94.590861.
- [55] HAN, Y., SONG, Y. H. “Using improved self-organizing map for partial discharge diagnosis of large turbogenerators”, *IEEE Transactions on Energy Conversion*, v. 18, n. 3, pp. 392–399, Sept 2003. ISSN: 0885-8969. doi: 10.1109/TEC.2003.815834.
- [56] GULSKI, E. “Computer-aided measurement of partial discharges in HV equipment”, *IEEE Transactions on Electrical Insulation*, v. 28, n. 6, pp. 969–983, Dec 1993. ISSN: 0018-9367. doi: 10.1109/14.249370.
- [57] CONTIN, A., CAVALLINI, A., MONTANARI, G. C., et al. “Digital detection and fuzzy classification of partial discharge signals”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 9, n. 3, pp. 335–348, Jun 2002. ISSN: 1070-9878. doi: 10.1109/TDEI.2002.1007695.
- [58] S. BISWAS, D. DEY, B. C., CHAKRAVORTI, S. “An approach based on rough set theory for identification of single and multiple partial discharge source”, *International Journal of Electrical Power and Energy Systems*, v. 46, n. 3, pp. 163–174, 2013. ISSN: 0142-0615.
- [59] CARMINATI, E., CRISTALDI, L., LAZZARONI, M., et al. “A neuro-fuzzy approach for the detection of partial discharge”, *IEEE Transactions on Instrumentation and Measurement*, v. 50, n. 5, pp. 1413–1417, Oct 2001. ISSN: 0018-9456. doi: 10.1109/19.963218.
- [60] LALITHA, E. M., SATISH, L. “Fractal image compression for classification of PD sources”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 5, n. 4, pp. 550–557, Aug 1998. ISSN: 1070-9878. doi: 10.1109/94.708272.

- [61] C. CHEN, H. “Fractal features-based pattern recognition of partial discharge in XLPE power cables using extension method”, *IET Generation, Transmission Distribution*, v. 6, n. 11, pp. 1096–1103, November 2012. ISSN: 1751-8687. doi: 10.1049/iet-gtd.2012.0080.
- [62] CONTIN, A., MONTANARI, G. C., FERRARO, C. “PD source recognition by Weibull processing of pulse height distributions”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 7, n. 1, pp. 48–58, Feb 2000. ISSN: 1070-9878. doi: 10.1109/94.839341.
- [63] ZHANG, X., XIAO, S., SHU, N., et al. “GIS partial discharge pattern recognition based on the chaos theory”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 21, n. 2, pp. 783–790, April 2014. ISSN: 1070-9878. doi: 10.1109/TDEI.2013.004020.
- [64] DEY, D., CHATTERJEE, B., CHAKRAVORTI, S., et al. “Cross-wavelet transform as a new paradigm for feature extraction from noisy partial discharge pulses”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 17, n. 1, pp. 157–166, February 2010. ISSN: 1070-9878. doi: 10.1109/TDEI.2010.5412014.
- [65] LIAO, R., TAYLOR, G. A., TAVERNIER, K., et al. “Comparative study of feature extraction methods applied to partial discharge signals”. In: *2012 47th International Universities Power Engineering Conference (UPEC)*, pp. 1–6, Sept 2012. doi: 10.1109/UPEC.2012.6398585.
- [66] PATTANADECH, N., NIMSANONG, P. “Partial discharge classification using principal component analysis combined with self-organizing map”. In: *TENCON 2014 - 2014 IEEE Region 10 Conference*, pp. 1–5, Oct 2014. doi: 10.1109/TENCON.2014.7022348.
- [67] CUNHA, C. F. F. D. C., CARVALHO, A. T. D., PETRAGLIA, M. R., et al. “An Improved Scale Dependent Wavelet Selection for Data Denoising of Partial Discharge Measurement”, *Solid Dielectrics (ICSD), 2013 IEEE International Conference on*, pp. 100–104, Jun./Jul. 2013. ISSN: 2159-1687.
- [68] CARVALHO, A. T., LIMA, A. C., CUNHA, C. F., et al. “Identification of partial discharges immersed in noise in large hydro-generators based on improved wavelet selection methods”, *Measurement*, v. 75, pp. 122 – 133, 2015. ISSN: 0263-2241. doi: <http://dx.doi.org/>

10.1016/j.measurement.2015.07.050. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S026322411500398X>>.

- [69] HUSSEIN, R., SHABAN, K. B., EL-HAG, A. H. “Wavelet Transform With Histogram-Based Threshold Estimation for Online Partial Discharge Signal Denoising”, *IEEE Transactions on Instrumentation and Measurement*, v. 64, n. 12, pp. 3601–3614, Dec 2015. ISSN: 0018-9456. doi: 10.1109/TIM.2015.2454651.
- [70] RAY, P., MAITRA, A. K., BASURAY, A. “A new threshold function for denoising partial discharge signal based on wavelet transform”. In: *Signal Processing Image Processing Pattern Recognition (ICSIPR), 2013 International Conference on*, pp. 185–189, Feb 2013. doi: 10.1109/ICSIPR.2013.6497985.
- [71] RAY, P., MAITRA, A. K., BASURAY, A. “Extract Partial Discharge signal using wavelet for on-line measurement”. In: *Communications and Signal Processing (ICCSP), 2013 International Conference on*, pp. 888–892, April 2013. doi: 10.1109/iccsp.2013.6577184.
- [72] ZHANG, X.-P., DESAI, M. D. “Adaptive denoising based on SURE risk”, *IEEE Signal Processing Letters*, v. 5, n. 10, pp. 265–267, Oct 1998. ISSN: 1070-9908. doi: 10.1109/97.720560.
- [73] ZANG, H., WANG, Z., ZHENG, Y. “Analysis of signal de-noising method based on an improved wavelet thresholding”. In: *Electronic Measurement Instruments, 2009. ICEMI '09. 9th International Conference on*, pp. 1–987–1–990, Aug 2009. doi: 10.1109/ICEMI.2009.5274493.
- [74] DONOHO, D. L., JOHNSTONE, I. M. “Threshold selection for wavelet shrinkage of noisy data”. In: *Engineering in Medicine and Biology Society, 1994. Engineering Advances: New Opportunities for Biomedical Engineers. Proceedings of the 16th Annual International Conference of the IEEE*, pp. A24–A25 vol.1, Nov 1994. doi: 10.1109/IEMBS.1994.412133.
- [75] VISHWAKARMA, D. K., KAPOOR, R., DHIMAN, A., et al. “De-noising of Audio Signal using Heavy Tailed Distribution and comparison of wavelets and thresholding techniques”. In: *Computing for Sustainable Global Development (INDIACom), 2015 2nd International Conference on*, pp. 755–760, March 2015.
- [76] TULSANI, H., GUPTA, R. “1-D signal denoising using wavelets based optimization of polynomial threshold function”. In: *Reliability, Infocom*

Technologies and Optimization (ICRITO) (Trends and Future Directions), 2014 3rd International Conference on, pp. 1–5, Oct 2014. doi: 10.1109/ICRITO.2014.7014720.

- [77] ZHANG, W.-Q., SONG, G.-X. “A translation-invariant wavelet de-noising method based on a new thresholding function”. In: *Machine Learning and Cybernetics, 2003 International Conference on*, v. 4, pp. 2341–2345 Vol.4, Nov 2003. doi: 10.1109/ICMLC.2003.1259900.
- [78] DONG, X., YUE, Y., QIN, X., et al. “Signal denoising based on improved wavelet packet thresholding function”. In: *2010 International Conference on Computer, Mechatronics, Control and Electronic Engineering*, v. 6, pp. 382–385, Aug 2010. doi: 10.1109/CMCE.2010.5609809.
- [79] GUO, Q., YU, S., LENG, M., et al. “Signal Denoising Using Simplified SURE-Based Linear Expansion of Thresholds in the Wavelet Domain”. In: *Image and Signal Processing, 2008. CISP '08. Congress on*, v. 3, pp. 592–596, May 2008. doi: 10.1109/CISP.2008.538.
- [80] A, S. L., A, Y. L., C, X. H., et al. “A Novel Thresholding Method in Removing Noises of Electrocardiogram Based on Wavelet Transform”. 2013.
- [81] HE, H., WANG, Z., TAN, Y. “Noise reduction of ECG signals through genetic optimized wavelet threshold filtering”. In: *2015 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*, pp. 1–6, June 2015. doi: 10.1109/CIVEMSA.2015.7158597.
- [82] TULSANI, H., GUPTA, R. “Wavelet based optimized polynomial threshold function for ECG signal denoising”. In: *Computing for Sustainable Global Development (INDIACom), 2015 2nd International Conference on*, pp. 1563–1566, March 2015.
- [83] NASRI, M., NEZAMABADI-POUR, H. “Image denoising in the wavelet domain using a new adaptive thresholding function”, *Neurocomputing*, v. 72, n. 46, pp. 1012 – 1025, 2009. ISSN: 0925-2312. doi: <http://dx.doi.org/10.1016/j.neucom.2008.04.016>.
- [84] JANGRA, S., KUMAR, S. “A New Threshold Function for Image Denoising based on Wavelet Transform”, pp. 60–65, Jun 2012. doi: 10.1109/ICSIPR.2013.6497985.

- [85] MOHIDEEN, S. K., PERUMAL, S. A., KRISHNAN, N., et al. “A novel approach for image denoising using dynamic tracking with new threshold technique”. In: *Computational Intelligence and Computing Research (ICCIC), 2010 IEEE International Conference on*, pp. 1–4, Dec 2010. doi: 10.1109/ICCIC.2010.5705917.
- [86] NOROUZZADEH, Y., RASHIDI, M. “Image denoising in wavelet domain using a new thresholding function”. In: *International Conference on Information Science and Technology*, pp. 721–724, March 2011. doi: 10.1109/ICIST.2011.5765347.
- [87] CHANG, S. G., YU, B., VETTERLI, M. “Adaptive wavelet thresholding for image denoising and compression”, *IEEE Transactions on Image Processing*, v. 9, n. 9, pp. 1532–1546, Sep 2000. ISSN: 1057-7149. doi: 10.1109/83.862633.
- [88] BISWAS, M., OM, H. “An adaptive wavelet thresholding image denoising method”. In: *Communications (NCC), 2013 National Conference on*, pp. 1–5, Feb 2013. doi: 10.1109/NCC.2013.6488014.
- [89] ZAHOOR, A. S., POORNACHANDRA, S. “Image de-noising using ex-trim shrinkage”, p. 33–40, Feb 2011.
- [90] C., A. T., C., C. F. C., M., F., et al. “A New Methodology for the Evaluation of the Influence of Discrete Spectral Interference on Partial Discharge Measurements in the Field”, *Electrical Insulation Conference (EIC), 2016 IEEE*, Jun. 2016.
- [91] CUNHA, C. F. “Proposal of a novel fitness function for evaluation of wavelet shrinkage parameters on partial discharge denoising”, *IET Science, Measurement and Technology*, v. 12, pp. 283–289(6), March 2018. ISSN: 1751-8822.
- [92] OMARI, T., BEREKSI-REGUIG, F. “An automatic wavelet denoising scheme for heart sounds”, *International Journal of Wavelets, Multiresolution and Information Processing*, v. 13, n. 03, pp. 1550016, 2015. doi: 10.1142/S0219691315500162.
- [93] ZHOU, Y., LI, S., ZHOU, Y., et al. “An Improvement Algorithm Based on Wavelet Shrinkage De-noising”, *Journal of Information and Computational Science*, v. 12, n. 17, pp. 6613–6620, Nov 2015. doi: 10.12733/jics20107097.

- [94] HUSSEIN, R., SHABAN, K. B., EL-HAG, A. H. “Energy Conservation-based Thresholding for Effective Wavelet Denoising of Partial Discharge Signals”, *IET Science, Measurement and Technology*, May 2016.
- [95] XIE, Y., HUANG, Q., CHANG, J., et al. “Period analysis of hydrologic series through moving-window correlation analysis method”, *Journal of Hydrology*, v. 538, pp. 278 – 292, 2016. ISSN: 0022-1694. doi: <http://dx.doi.org/10.1016/j.jhydrol.2016.04.024>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0022169416302050>>.
- [96] YANG, D., LI, H., HU, Y., et al. “Vibration condition monitoring system for wind turbine bearings based on noise suppression with multi-point data fusion”, *Renewable Energy*, v. 92, pp. 104 – 116, 2016. ISSN: 0960-1481. doi: <http://dx.doi.org/10.1016/j.renene.2016.01.099>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0960148116300994>>.
- [97] GUILLEN, D., IDARRAGA-OSPINA, G., MOMBELLO, E., et al. “Partial discharges location in transformer winding using wavelets and Kullback–Leibler divergence”, *Electric Power Systems Research*, v. 136, pp. 398 – 405, 2016. ISSN: 0378-7796. doi: <http://dx.doi.org/10.1016/j.epsr.2016.03.020>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378779616300670>>.
- [98] KREUGER, F. H. *Partial Discharge Detection in High-Voltage Equipment.*, 1 ed., 1989.
- [99] LEMKE, E. *WG D1.33 Guide for Partial Discharge Measurements in Compliance to IEC 60270*, 1 ed., 2008.
- [100] GEMANT, A., PHILIPPOFF, W. “Die Funkenstrecke mit Vonkondensator, Zeitschrift für Technische Physik”, *IET Science, Measurement and Technology*, v. 13, n. 9, pp. 425–430, 1932.
- [101] BOGGS, S. A. “Partial discharge. III. Cavity-induced PD in solid dielectrics”, *IEEE Electrical Insulation Magazine*, v. 6, n. 6, pp. 11–16, Nov 1990. ISSN: 0883-7554. doi: 10.1109/57.63094.
- [102] GULSKI, E. “Analysis of Partial Discharges”, *IEEE TDEI*, v. 2, n. 5, pp. 822–837, Oct 1995.
- [103] JUNIOR, J. T. *Medição de Descargas Parciais*, 1 ed., 2003.

- [104] MASON, J. H. “Enhancing the significance of PD measurements”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 2, n. 5, pp. 876–888, Oct 1995. ISSN: 1070-9878. doi: 10.1109/94.469982.
- [105] PEDERSEN, A., CRICHTON, G. C., MCALLISTER, I. W. “The theory and measurement of partial discharge transients”, *IEEE Transactions on Electrical Insulation*, v. 26, n. 3, pp. 487–497, Jun 1991. ISSN: 0018-9367. doi: 10.1109/14.85121.
- [106] “IEEE Guide for the Measurement of Partial Discharges in AC Electric Machinery”, *IEEE Std 1434-2014 (Revision of IEEE Std 1434-2000)*, pp. 1–89, Dec 2014. doi: 10.1109/IEEESTD.2014.6973042.
- [107] KURRER, R., FESER, K. “The application of ultra-high-frequency partial discharge measurements to gas-insulated substations”, *IEEE Transactions on Power Delivery*, v. 13, n. 3, pp. 777–782, Jul 1998. ISSN: 0885-8977. doi: 10.1109/61.686974.
- [108] KOCK, N. D., CORIC, B., PIETSCH, R. “UHF PD detection in gas-insulated switchgear-suitability and sensitivity of the UHF method in comparison with the IEC 270 method”, *IEEE Electrical Insulation Magazine*, v. 12, n. 6, pp. 20–26, Nov 1996. ISSN: 0883-7554. doi: 10.1109/57.546277.
- [109] BAUMGARTNER, R., FRUTH, B., LANZ, W., et al. “Partial discharge. X. PD in gas-insulated substations-measurement and practical considerations”, *IEEE Electrical Insulation Magazine*, v. 8, n. 1, pp. 16–27, Jan 1992. ISSN: 0883-7554. doi: 10.1109/57.120634.
- [110] CLEARY, G. P., JUDD, M. D. “UHF and current pulse measurements of partial discharge activity in mineral oil”, *IEE Proceedings - Science, Measurement and Technology*, v. 153, n. 2, pp. 47–54, March 2006. ISSN: 1350-2344. doi: 10.1049/ip-smt:20050103.
- [111] JUDD, M. D., YANG, L., HUNTER, I. B. B. “Partial discharge monitoring for power transformer using UHF sensors. Part 2: field experience”, *IEEE Electrical Insulation Magazine*, v. 21, n. 3, pp. 5–13, May 2005. ISSN: 0883-7554. doi: 10.1109/MEI.2005.1437603.
- [112] ÁLVAREZ, F., GARNACHO, F., ORTEGO, J., et al. “Application of HFCT and UHF Sensors in On-Line Partial Discharge Measurements for Insulation Diagnosis of High Voltage Equipment”, *Sensors*, v. 15, n. 4, April 2015.

- [113] KREUGER, F. H., GULSKI, E. “Automatisiertes Messsystem zur Erfassung von Teilentladungs-Kenngrößen für die Beurteilung Elektrischer Isolierungen”, *Technisches Messen*, pp. 124–129, 1989.
- [114] GULSKI, E. “Computer-aided Measurement of Partial Discharges in HV Equipment”, December 1993.
- [115] PAULINO, M. E. C. “Estado da Arte da Medição com Múltiplos Canais Sincronizados para Avaliação de Descargas Parciais”, *Proc. IEEE Power Engineering Society Transmission and Distribution Conf.*, 2010.
- [116] PLATH, K. D., PLATH, R., EMANUEL. “Synchrone Dreiphasige Teilentladungsmessung an Leistungs Transformatoren vor Ort und im Labor”, 2002.
- [117] WEISSENBERG, F., PLATH, KALKNER. “On-Site PD Detection at Cross-Bonding Links of HV Cables”, *Cigrè*, 2004.
- [118] KALKNER, R., OBRALIC, F., PLATH. “Synchronous 3-Phase Partial Discharge Detection on Rotating Machines”, *Cigrè*, 2006.
- [119] MAS’UD, A. A., STEWART, B., MCMEEKIN, S. “Application of an ensemble neural network for classifying partial discharge patterns”, *Electric Power Systems Research*, v. 110, pp. 154–162, April 2014. ISSN: 0378-7796. doi: 10.1016/j.epsr.2014.01.010.
- [120] ZHANG, H., BLACKBURN, T. R., T. PHUNG, B., et al. “A novel wavelet transform technique for on-line partial discharge measurements. 1. WT de-noising algorithm”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 14, n. 1, pp. 3–14, Feb 2007. ISSN: 1070-9878. doi: 10.1109/TDEI.2007.302864.
- [121] NAGESH, V., GURURAJ, B. I. “Evaluation of digital filters for rejecting discrete spectral interference in on-site PD measurements”, *IEEE Transactions on Electrical Insulation*, v. 28, n. 1, pp. 73–85, Feb 1993. ISSN: 0018-9367. doi: 10.1109/14.192242.
- [122] HARTJE, H. B. M. “New methods to reduce the disturbance influence on the in situ-partial-discharge (PD) - measurement and monitoring”, *Sixth ISH*, pp. 73–85, Oct 1989.
- [123] NAGESH, V., GURURAJ, B. I. “Evaluation of digital filters for rejecting discrete spectral interference in on-site PD measurements”, *IEEE Tran-*

sactions on Electrical Insulation, v. 28, n. 1, pp. 73–85, Feb 1993. ISSN: 0018-9367. doi: 10.1109/14.192242.

- [124] GAOUDA, A. M., EL-HAG, A., ABDEL-GALIL, T. K., et al. “On-line detection and measurement of partial discharge signals in a noisy environment”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 15, n. 4, pp. 1162–1173, Aug 2008. ISSN: 1070-9878. doi: 10.1109/TDEI.2008.4591239.
- [125] SONG, X., ZHOU, C., HEPBURN, D. M., et al. “Second generation wavelet transform for data denoising in PD measurement”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 14, n. 6, pp. 1531–1537, December 2007. ISSN: 1070-9878. doi: 10.1109/TDEI.2007.4401237.
- [126] M. MISITI, Y. MISITI, G. O. E. A. *Wavelet Toolbox Users Guide*. The MathWorks, 2012.
- [127] SHETTY, P. K., RAMU, T. S. “An undecimated wavelet transform based enhancement, statistical feature extraction and detection-classification of PD signals [partial discharges]”. In: *Acoustics, Speech, and Signal Processing, 2004. Proceedings. (ICASSP '04). IEEE International Conference on*, v. 5, pp. V-401–4 vol.5, May 2004. doi: 10.1109/ICASSP.2004.1327132.
- [128] COIFMAN, R. R., WICKERHAUSER, M. V. “Entropy-based algorithms for best basis selection”, *IEEE Transactions on Information Theory*, v. 38, n. 2, pp. 713–718, March 1992. ISSN: 0018-9448. doi: 10.1109/18.119732.
- [129] “Preface to the second edition”. In: Mallat, S. (Ed.), *A Wavelet Tour of Signal Processing (Second Edition)*, second edition ed., Academic Press, San Diego, 1999. ISBN: 978-0-12-466606-1. doi: <http://dx.doi.org/10.1016/B978-012466606-1/50001-5>.
- [130] DU, L., XU, R., XU, F., et al. “Research on key parameters of speech denoising algorithm based on wavelet packet transform”. In: *Computer Science and Information Technology (ICCSIT), 2010 3rd IEEE International Conference on*, v. 6, pp. 551–556, July 2010. doi: 10.1109/ICCSIT.2010.5564729.
- [131] EVAGOROU, D., KYPRIANOU, A., LEWIN, P. L., et al. “Evaluation of Partial Discharge Denoising using the Wavelet Packets Transform as a Preprocessing Step for Classification”. In: *2008 Annual Report Conference*

on *Electrical Insulation and Dielectric Phenomena*, pp. 387–390, Oct 2008.
doi: 10.1109/CEIDP.2008.4772794.

- [132] SHENSA, M. J. “The discrete wavelet transform: wedding the a trous and Mallat algorithms”, *IEEE Transactions on Signal Processing*, v. 40, n. 10, pp. 2464–2482, Oct 1992. ISSN: 1053-587X. doi: 10.1109/78.157290.
- [133] KINGSBURY, N. “The dual-tree complex wavelet transform: A new efficient tool for image restoration and enhancement”. In: *Signal Processing Conference (EUSIPCO 1998), 9th European*, pp. 1–4, Sept 1998.
- [134] SELESNICK, I. W., BARANIUK, R. G., KINGSBURY, N. G. “The dual-tree complex wavelet transform”. In: *Electrical and Computer Engineering*, v. 6, pp. 123–151, Nov. 2005.
- [135] DAUBECHIES, I. *Ten Lectures on Wavelets*. Society for I and Applied Mathematics, 1992.
- [136] VETTERLI, KOVAEEVIC, J. *Wavelets and Subband Coding*. Englewood Cliffs, NJ, Prentice-Hall, 1995.
- [137] ABRY, P. *Ondelettes et Turbulence. Multirésolutions, Algorithmes de Décomposition, Invariance D'échelles*. Paris, Diderot Arts, 1997.
- [138] COHEN, A. *Ondelettes, Analyses Multirésolution et Traitement Numérique du Signal*. Tese de Doutorado, University of Paris IX, Dauphine, 1992.
- [139] ZHANG, H., BLACKBURN, T. R., PHUNG, B. T., et al. “Signal processing of on-line partial discharge measurements in HV power cables”. In: *Australasian Universities Power Engineering Conf., Brisbane, Australia*, p. Paper ID 161, 2004.
- [140] ZHANG, H., BLACKBURN, T. R., PHUNG, B. T., et al. “Application of signal processing techniques to on-line partial discharge detection in cables”. In: *Power System Technology, 2004. PowerCon 2004. 2004 International Conference on*, v. 2, pp. 1780–1785 Vol.2, Nov 2004. doi: 10.1109/ICPST.2004.1460291.
- [141] KIM, C. H., AGGARWAL, R. “Wavelet Transforms in Power Systems. Part I. General Introduction to the Wavelet Transformers”, *Power Engineering Journal*, v. 14, n. 2, pp. 81–87, Apr. 2000. ISSN: 0950-3366. doi: 10.1049/pe:20010404.

- [142] ZHANG, H., BLACKBURN, T. R., PHUNG, B. T., et al. “A Novel Wavelet Transform Technique For On-line Partial Discharge Measurements. 1. WT De-noising Algorithm”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 14, n. 1, pp. 3–14, Feb. 2007. ISSN: 1070-9878. doi: 10.1109/TDEI.2007.302864.
- [143] UMAMAHESWARI, R., SARATHI, R. “Feature extraction of UHF PD signals by wavelet packet based MRSD analysis For defect identification in Gas Insulated Systems”. In: *2012 Annual IEEE India Conference (INDICON)*, pp. 1218–1222, Dec 2012. doi: 10.1109/INDICON.2012.6420804.
- [144] SEO, J., MA, H., SAHA, T. “Probabilistic wavelet transform for partial discharge measurement of transformer”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 22, n. 2, pp. 1105–1117, April 2015. ISSN: 1070-9878. doi: 10.1109/TDEI.2015.7076812.
- [145] SHETTY, P., RAMU, T. “An Undecimated Wavelet Transform Based Enhancement, Statistical Feature Extraction and Detection-Classification of PD Signals”. In: *Acoustics, Speech, and Signal Processing, 2004. Proceedings. (ICASSP '04). IEEE International Conference on*, v. 5, pp. 401–404, may 2004. doi: 10.1109/ICASSP.2004.1327132.
- [146] CROUSE, M. S., NOWAK, R. D., BARANIUK, R. G. “Wavelet-based statistical signal processing using hidden Markov models”, *IEEE Transactions on Signal Processing*, v. 46, n. 4, pp. 886–902, Apr 1998. ISSN: 1053-587X. doi: 10.1109/78.668544.
- [147] MIHCAK, M. K., KOZINTSEV, I., RAMCHANDRAN, K., et al. “Low-complexity image denoising based on statistical modeling of wavelet coefficients”, *IEEE Signal Processing Letters*, v. 6, n. 12, pp. 300–303, Dec 1999. ISSN: 1070-9908. doi: 10.1109/97.803428.
- [148] GAO, H.-Y. “Wavelet Shrinkage Denoising Using the Non-Negative Garrote”, *Journal of Computational and Graphical Statistics*, v. 7, n. 4, pp. 469–488, Dec 1998. ISSN: 1070-9908. doi: 10.2307/1390677.
- [149] STEIN, C. M. “Estimation of the Mean of a Multivariate Normal Distribution”, *The Annals of Statistics*, v. 9, n. 6, pp. 1135–1151, Feb 1981.
- [150] DONOHO, D. L., JOHNSTONE, I. M. “Ideal Spatial Adaptation by Wavelet Shrinkage”, *Biometrika Trust*, v. 81, n. 3, pp. 1135–1151, Feb 1981. doi: 10.2307/2337118.

- [151] RAY, P., MAITRA, A. K., BASURAY, A. “Extract Partial Discharge signal using wavelet for on-line measurement”. In: *Communications and Signal Processing (ICCSP), 2013 International Conference on*, pp. 888–892, April 2013. doi: 10.1109/iccsp.2013.6577184.
- [152] HUIMIN, C., RUIMEI, Z., YANLI, H. “Improved Threshold Denoising Method Based on Wavelet Transform”, *Physics Procedia*, v. 33, pp. 1354 – 1359, 2012. ISSN: 1875-3892. doi: <https://doi.org/10.1016/j.phpro.2012.05.222>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1875389212015350>>. 2012 International Conference on Medical Physics and Biomedical Engineering (ICMPBE2012).
- [153] ZHANG, X.-P. “Thresholding neural network for adaptive noise reduction”, *IEEE Transactions on Neural Networks*, v. 12, n. 3, pp. 567–584, May 2001. ISSN: 1045-9227. doi: 10.1109/72.925559.
- [154] SATISH, L., ZAENGL, W. S. “Artificial neural networks for recognition of 3-d partial discharge patterns”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 1, n. 2, pp. 265–275, Apr 1994. ISSN: 1070-9878. doi: 10.1109/94.300259.
- [155] WANG, K., LI, J., ZHANG, S., et al. “A hybrid algorithm based on s transform and affinity propagation clustering for separation of two simultaneously artificial partial discharge sources”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 22, n. 2, pp. 1042–1060, April 2015. ISSN: 1070-9878. doi: 10.1109/TDEI.2015.7076806.
- [156] MA, H., CHAN, J. C., SAHA, T. K., et al. “Pattern recognition techniques and their applications for automatic classification of artificial partial discharge sources”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 20, n. 2, pp. 468–478, April 2013. ISSN: 1070-9878. doi: 10.1109/TDEI.2013.6508749.
- [157] CHANG, W. Y. “Partial discharge pattern recognition for cast-resin current transformer”. In: *2009 IEEE 9th International Conference on the Properties and Applications of Dielectric Materials*, pp. 461–464, July 2009. doi: 10.1109/ICPADM.2009.5252390.
- [158] JAMES, R. E., PHUNG, B. T. “Development of computer-based measurements and their application to PD pattern analysis”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 2, n. 5, pp. 838–856, Oct 1995. ISSN: 1070-9878. doi: 10.1109/94.469978.

- [159] GULSKI, E., KRIVDA, A. “Neural networks as a tool for recognition of partial discharges”, *IEEE Transactions on Electrical Insulation*, v. 28, n. 6, pp. 984–1001, Dec 1993. ISSN: 0018-9367. doi: 10.1109/14.249372.
- [160] PATTANADECH, N., NIMSANONG, P. “Partial discharge classification using learning vector quantization network model”. In: *TENCON 2014 - 2014 IEEE Region 10 Conference*, pp. 1–5, Oct 2014. doi: 10.1109/TENCON.2014.7022349.
- [161] SU, M. S., CHEN, J. F., CHEN, C. Y., et al. “Classification of partial discharge events in GILBS using discrete wavelet transform and probabilistic neural networks”. In: *Condition Monitoring and Diagnosis (CMD), 2012 International Conference on*, pp. 963–967, Sept 2012. doi: 10.1109/CMD.2012.6416314.
- [162] ARDILA-REY, J. A., ROJAS-MORENO, M. V., MARTÍNEZ-TARIFA, J. M., et al. “Inductive Sensor Performance in Partial Discharges and Noise Separation by Means of Spectral Power Ratios”, *Sensors*, v. 14, n. 2, pp. 3408–3427, 2014. ISSN: 1424-8220. doi: 10.3390/s140203408.
- [163] T. HASTIE, R. T., FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference and Prediction*. Springer, 2009.
- [164] DING, C., HE, X. “K-means clustering via principal component analysis”. pp. 225–232. ACM Press, 2004.
- [165] LIAO, R., FERNANDESS, Y., TAVERNIER, K., et al. “Recognition of partial discharge patterns”. In: *2012 IEEE Power and Energy Society General Meeting*, pp. 1–8, July 2012. doi: 10.1109/PESGM.2012.6344929.
- [166] PATTANADECH, N., NIMSANONG, P. “Effect of training methods on the accuracy of PCA-KNN partial discharge classification model”. In: *TENCON 2014 - 2014 IEEE Region 10 Conference*, pp. 1–5, Oct 2014. doi: 10.1109/TENCON.2014.7022350.
- [167] DEMSAR, J. *Pattern Recognition and Machine Learning*. Springer, 2006.
- [168] LAWRENCE, N. “Probabilistic Non-linear Principal Component Analysis with Gaussian Process Latent Variable Models”, *J. Mach. Learn. Res.*, v. 6, pp. 1783–1816, dez. 2005. ISSN: 1532-4435. Disponível em: <<http://dl.acm.org/citation.cfm?id=1046920.1194904>>.
- [169] HINTON, G., ROWEIS, S. “Stochastic Neighbor Embedding”. pp. 225–232. Department of Computer Science, 2004.

- [170] BISHOP, C. M. *Neural Network for Pattern Recognition*. Oxford University Press, 1995.
- [171] VAN DER MAATEN, L., HINTON, G. “Visualizing Data using t-SNE”, *Journal of Machine Learning Research*, v. 9, pp. 2579–2605, 2008. Disponível em: <<http://www.jmlr.org/papers/v9/vandermaaten08a.html>>.
- [172] “Matlab Toolbox for Dimensionality Reduction”. 2018. Disponível em: <<https://lvdmaaten.github.io/drtoolbox/>>.
- [173] MAZROUA, A. A., SALAMA, M. M. A., BARTNIKAS, R. “PD pattern recognition with neural networks using the multilayer perceptron technique”, *IEEE Transactions on Electrical Insulation*, v. 28, n. 6, pp. 1082–1089, Dec 1993. ISSN: 0018-9367. doi: 10.1109/14.249382.
- [174] SU, M.-S., CHEN, J.-F., LIN, Y.-H. “Phase determination of partial discharge source in three-phase transmission lines using discrete wavelet transform and probabilistic neural networks”, *International Journal of Electrical Power and Energy Systems*, v. 51, pp. 27–34, 2013. ISSN: 0142-0615. doi: <http://dx.doi.org/10.1016/j.ijepes.2013.03.004>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0142061513001014>>.
- [175] SATISH, L., ZAENGL, W. S. “Can fractal features be used for recognizing 3-d partial discharge patterns”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 2, n. 3, pp. 352–359, Jun 1995. ISSN: 1070-9878. doi: 10.1109/94.395421.
- [176] COATES, A., NG, A. Y. “Learning Feature Representations with K-Means”. In: Montavon, G., Orr, G. B., Müller, K.-R. (Eds.), *Neural Networks: Tricks of the Trade: Second Edition*, pp. 561–580, Berlin, Heidelberg, Springer Berlin Heidelberg, 2012. ISBN: 978-3-642-35289-8. doi: 10.1007/978-3-642-35289-8_30. Disponível em: <http://dx.doi.org/10.1007/978-3-642-35289-8_30>.
- [177] ARTHUR, D., VASSILVITSKII, S. “K-means++: the advantages of careful seeding”. In: *In Proceedings of the 18th Annual ACM-SIAM Symposium on Discrete Algorithms*, 2007.
- [178] JAIN, A. K., DUBES, R. C. *Algorithms for Clustering Data*. Prentice-Hall, 1988.

- [179] PARK, H.-S., JUN, C.-H. “A simple and fast algorithm for K-medoids clustering”, *Expert Systems with Applications*, v. 36, n. 2, pp. 3336–3341, mar. 2009. ISSN: 09574174. doi: 10.1016/j.eswa.2008.01.039. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2008.01.039>>.
- [180] KAUFMAN, L., ROUSSEEUW, P. *Clustering by Means of Medoids*. Reports of the Faculty of Mathematics and Informatics. Faculty of Mathematics and Informatics, 1987. Disponível em: <<https://books.google.com.br/books?id=HK-4GwAACAAJ>>.
- [181] BEZDEK, J. C. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Norwell, MA, USA, Kluwer Academic Publishers, 1981. ISBN: 0306406713.
- [182] HAMERLY, G., ELKAN, C. “Learning the K in K-Means”. In: *In Neural Information Processing Systems*, p. 2003. MIT Press, 2003.
- [183] ESTER, M., KRIEGEL, H.-P., SANDER, J., et al. “A density-based algorithm for discovering clusters in large spatial databases with noise”. pp. 226–231. AAAI Press, 1996.
- [184] “What is Hierarchical Clustering?” 2018. Disponível em: <<https://www.displayr.com/what-is-hierarchical-clustering/>>.
- [185] TAKENS, F. “Detecting strange attractors in turbulence”. In: Rand, D., Young, L.-S. (Eds.), *Dynamical Systems and Turbulence, Warwick 1980: Proceedings of a Symposium Held at the University of Warwick 1979/80*, pp. 366–381, Berlin, Heidelberg, Springer Berlin Heidelberg, 1981. ISBN: 978-3-540-38945-3. doi: 10.1007/BFb0091924.
- [186] CELSO GREBOGI, STEVEN W. MCDONALD, E. O. J. A. Y. “Final state sensitivity: An obstruction to predictability”, *Physics Letters A*, v. 99, n. 9, pp. 415–418, Sept 1983. doi: 10.1016/0375-9601(83)90945-3.
- [187] ERTÖZ, L., STEINBACH, M., KUMAR, V. “Finding clusters of different sizes, shapes, and densities in noisy, high dimensional data”. In: *The National Conference SPCTS*, 2003.
- [188] “Tracing Filter/Oscillator Frequency Response Using Spectrum Analyzer and Signal Generator”. 2018. Disponível em: <<http://www.kerrywong.com/2015/12/21/>>.

- [189] *IEC TS 60034-27-2 - Rotating electrical machines - Part 27-2: On-line partial discharge measurements on the stator winding insulation of rotating electrical machines*, 1 ed., 2012.
- [190] WENTWORTH, S., SILVEIRA, F. *Eletromagnetismo aplicado: Abordagem antecipada das linhas de transmissão*. BOOKMAN COMPANHIA ED. ISBN: 9788577802906.
- [191] R. OLIVEIRA, R. ARAÚJO, F. B. A. S. R. Z. W. F. V. D., BRASIL, F. “A System Based on Artificial Neural Networks for Automatic Classification of Hydro-generator Stator Windings Partial Discharges”, *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, v. 16, n. 3, pp. 628–645, September 2017. ISSN: 2179-1074. doi: 10.1590/2179-10742017v16i3854.
- [192] HUDON, C., BELEC, M. “Partial discharge signal interpretation for generator diagnostics”, *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 12, n. 2, pp. 297–319, April 2005. ISSN: 1070-9878. doi: 10.1109/TDEI.2005.1430399.
- [193] JR., A., A. T. D. CARVALHO, E. A. “Medições de Descargas Parciais no Campo - Aspectos Práticos em Geradores e Motores”, *Cigrè*, v. 13, May 2009.
- [194] AMORIM, H. P., CARVALHO, A. T. D., RODRIGUES, T. B., et al. “Experience with on-line insulation diagnostics of surge arresters by PD measurement in the field”. In: *2016 IEEE International Conference on Dielectrics (ICD)*, v. 1, pp. 472–475, July 2016. doi: 10.1109/ICD.2016.7547645.
- [195] AMORIM, H. P., CARVALHO, A. T. D., RODRIGUES, T. B., et al. “On-site measurements of Partial Discharges through tap of the bushings — Brazilian experience in power transformers”. In: *2013 IEEE International Conference on Solid Dielectrics (ICSD)*, pp. 1020–1023, June 2013. doi: 10.1109/ICSD.2013.6619767.
- [196] FLORKOWSKI, M., FLORKOWSKA, B. “Phase-resolved rise-time-based discrimination of partial discharges”, *IET Generation, Transmission Distribution*, v. 3, n. 1, pp. 115–124, January 2009. ISSN: 1751-8687. doi: 10.1049/iet-gtd:20080171.
- [197] JUDD, M. D., YANG, L., HUNTER, I. B. B. “Partial discharge monitoring of power transformers using UHF sensors. Part I: sensors and signal in-

terpretation”, *IEEE Electrical Insulation Magazine*, v. 21, n. 2, pp. 5–14, March 2005. ISSN: 0883-7554. doi: 10.1109/MEI.2005.1412214.

- [198] ROUSSEEUW, P. J. “Silhouettes: A graphical aid to the interpretation and validation of cluster analysis”, *Journal of Computational and Applied Mathematics*, v. 20, pp. 53 – 65, 1987. ISSN: 0377-0427. doi: [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7).

Apêndice A

Circuitos Aplicados nas Medições de Descargas Parciais

Neste apêndice apresentamos os circuitos que podem ser aplicados na medição de DP. Junto a estes, também, são mostrados os circuitos periféricos que aplicamos em nossas medições em laboratório e em campo.

A.1 Circuito de Medição Padrão para DP

A norma IEC 60270 [4] faz menção a três circuitos que se diferenciam basicamente pelo arranjo da impedância de medição Z_m . A Figura A.1 ilustra um dos circuitos mais aplicados nas medições de DP, em que o objeto sob ensaio C_a é posicionado em paralelo com um capacitor de acoplamento C_k . O capacitor de acoplamento propicia um caminho de baixa impedância para componentes de alta frequência, em série com a impedância de medição Z_m , pela qual os sinais de DP serão transmitidos através de um cabo apropriado (coaxial ou fibra óptica) até o sistema de aquisição. Nota-se ainda a presença de um filtro, no caso um indutor, que tem a finalidade de atenuar ruído eletromagnético de alta frequência oriundo da fonte de alta tensão que alimenta o equipamento em teste e prevenir um curto circuito para o sinal de DP através da fonte. A utilização deste filtro é mais frequente em ensaios feitos em laboratório, não sendo aplicado em medições *on-line* ou em campo devido a questões práticas e de segurança que envolveriam sua instalação na rede de alimentação. O sinal de sincronismo é obtido de um divisor de tensão capacitivo formado pelos capacitores C_1 e C_2 , de forma que o sistema consegue identificar o ângulo de fase em que cada pulso de DP ocorre (possibilitando a construção do mapa PRPD). Em alguns casos, quando da inexistência ou impossibilidade de se ter o divisor, o sinal pode

ser adquirido diretamente de uma fonte 110 V ou 220 V da própria alimentação do sistema de medição, desde que respeitados os limites de segurança dos equipamentos e das pessoas. É possível, ainda, utilizando ferramentas de processamento de sinais, obter o sincronismo diretamente do sinal adquirido pela impedância Z_m , pois este ainda conserva a componente de frequência da rede de alimentação [193].

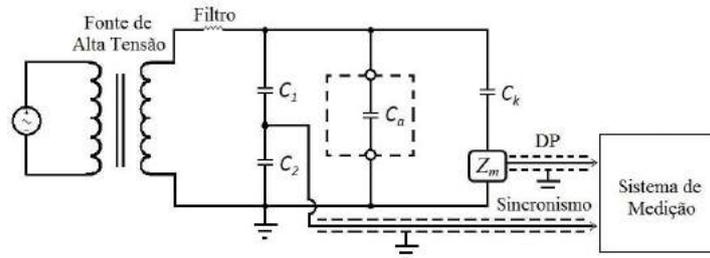


Figura A.1: Circuito de medição de DP com impedância de medição Z_m em série com capacitor de acoplamento C_k .

Outra opção de circuito é mostrada na Figura A.2, onde Z_m é colocado em série com o condutor de aterramento do objeto em teste. O uso deste circuito pode ser indicado em situações em que a capacitância é muito alta. Em contrapartida, pode haver a necessidade de interrupção da conexão de aterramento do equipamento, o que nem sempre é possível. Existe, também, o risco do objeto de teste entrar em curto circuito, o que poderia acarretar danos ao sistema de medição e por em risco a vida daqueles que o operam.

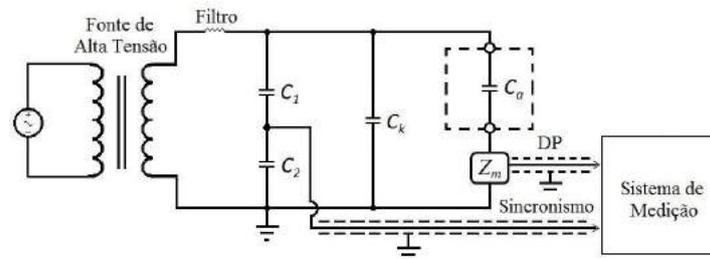


Figura A.2: Circuito de medição de DP com impedância de medição Z_m em série com o objeto de teste C_a .

Um último circuito de medição de DP, que não aplicado em nossas avaliações, é o de ponte balanceada também descrito na IEC 60270 [4].

O capacitor de acoplamento é útil para atenuar a amplitude da tensão de teste e permitir a transferência das componentes de alta frequência dos sinais de DP que surgem nos terminais do objeto ensaiado até Z_m .

A seguir são mostrados os circuitos periféricos que são aplicáveis nas medições. Todos eles são montados em uma caixa de alumínio para garantir a blindagem contra interferências eletromagnéticas.

A.2 Impedância de Medição

A impedância Z_m (quadripolo) faz a conversão do pulso de corrente DP em um pulso de tensão equivalente, para que possa ser processado no sistema de medição. A impedância pode ser confeccionada como um circuito ressonante RLC, o qual é utilizado em sistemas de banda estreita tendo maior imunidade a ruído, mas pode causar erros de integração em pulsos que ocorram quase simultaneamente. Outra opção é o uso de circuitos RC, usado em sistemas de banda larga. Também é possível empregar uma impedância puramente resistiva, entretanto, são necessários cuidados com sobretensões que podem danificar o sistema de medição.

Nas medições em laboratório e em geradores empregamos como impedância o circuito resistivo da Figura A.3, o qual contém apenas quatro resistores de precisão (1%) de 8.06 k Ω (1/4 W) e um Tubo protetor de Surto à Gás (*Gas Discharge Tube* - GDT) de 90 V, o qual tem a função de garantir algum nível de proteção para o hardware de medição. Todos os componentes são dispostos em paralelo, o que forma uma resistência equivalente próxima de 2 k Ω .

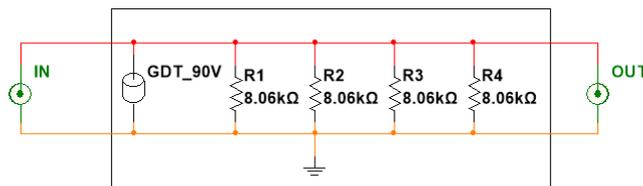


Figura A.3: Circuito da impedância de medição Z_m aplicada nas medições em laboratório e em geradores.

Em outros equipamentos de AT como PR, TC, TP são usados HFCT fabricados pela Techimp. Em buchas de transformadores a medição é feita pelo TAP da mesma, por onde é acoplada a impedância. Já para GIS é preciso utilizar uma cinta capacitiva, a qual seve como uma antena capaz de captar as perturbações eletromagnéticas ocasionadas pelas descargas que venham a ocorrer no interior do equipamento. Mais detalhes sobre estes sensores podem ser encontrados em [35].

Por vezes, após a impedância Z_m , é necessário aplicar um filtro passa altas e/ou atenuador. A seguir descrevemos ambos os circuitos.

A.3 Filtro Passa Altas

O filtro passa altas é usado para diminuir interferências de baixa frequência como ruído de tiristor, entre outros. No entanto, seu uso implica na redução do sinal de sincronismo AC (60 Hz), e portanto, é necessário fazer a medição usando mais um canal do *hardware* de aquisição, para que não se perca a sincronia com a tensão aplicada sobre o objeto ensaiado. O sinal de sincronismo poderá vir diretamente da entrada do filtro ou de outro ponto qualquer da rede que esteja em fase com a tensão de alimentação do equipamento medido.

O circuito que compõe o filtro é mostrado na figura A.4. Verifique que é um simples filtro de 2º Ordem, o qual foi projetado para uma ter frequência de corte de 300 kHz.

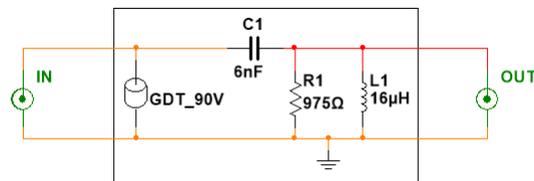


Figura A.4: Circuito do Filtro PA com frequência e corte em 300 kHz.

As respostas em frequência simulada e medida são mostradas na Figura A.5. Na simulação, também foram considerados os parâmetros distribuídos (calculados de maneira aproximada) dos dois cabos coaxiais RG-58 de 1.00 m de comprimento usados para medir a RF real do circuito. Note na Figura A.5 (b) que a frequência de corte está em torno de 310 kHz com ressonância em 500 kHz, bem próxima da simulada, mas a partir de 21.2 MHz começa a ocorrer uma atenuação seguida por uma antirressonância (zero complexo) em 30 MHz e por uma ressonância em 37 MHz. Este problema surge devido a presença dos cabos coaxiais usados para avaliar o filtro, além da impedância de entrada do osciloscópio usado na medição. Para frequências muito altas, os cabos começam a se comportar como uma linha de transmissão, gerando alterações na RF.

A.4 Atenuador

Determinadas medições podem fornecer um sinal de sincronismo com nível de tensão superior ao limite suportado pelo *hardware* de aquisição (± 10 VAC), necessitando que seja aplicado um circuito atenuador.

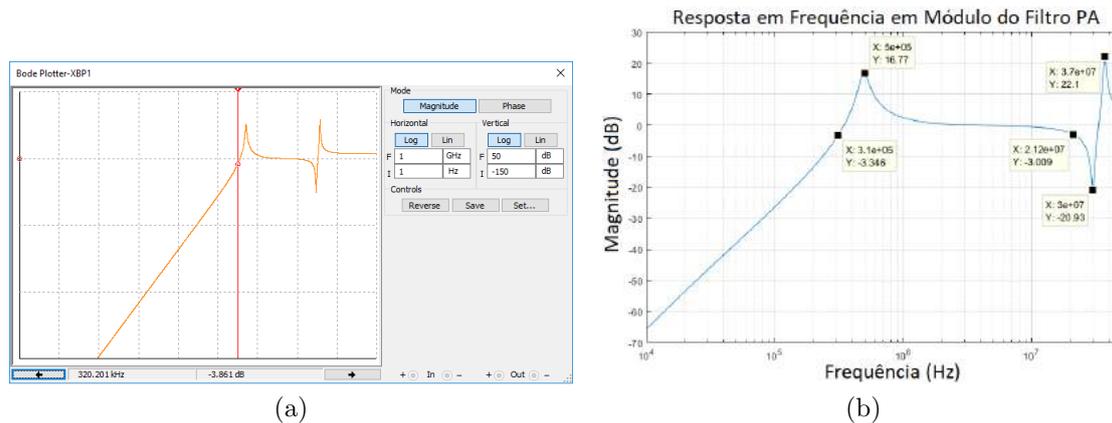


Figura A.5: Resposta em frequência para o Filtro PA: (a) simulada; (b) medida.

Em algumas de nossas medições foi necessário usar um atenuador (resistivo capacitivo), conforme a Figura A.6, com uma relação 10:1 (atenuação de 20 dB). Se utilizado em conjunto com o filtro PA, ele deve sempre ficar posposto a este, pois é projetado para fazer casamento com a impedância de entrada do osciloscópio (1 MΩ em paralelo com um capacitor de 10 pF a 20 pF).

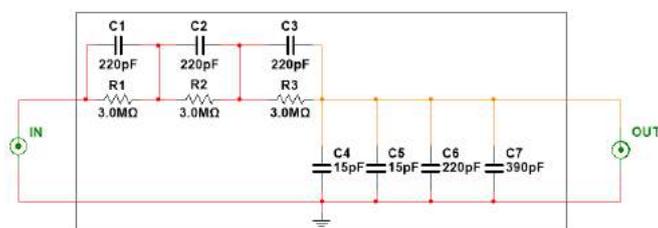
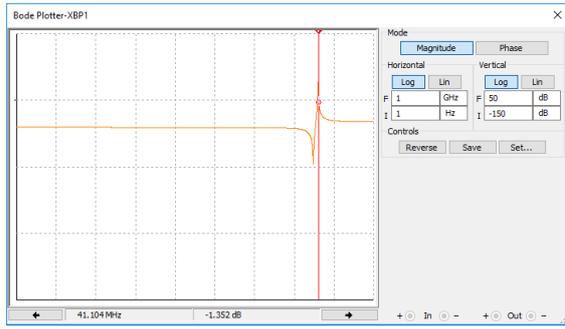
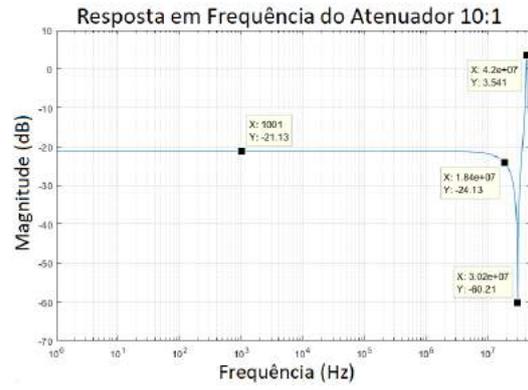


Figura A.6: Circuito atenuador com relação 10:1.

As RF simulada (considerando parâmetros distribuídos de cabos coaxiais e a impedância de entrada do osciloscópio) e medida são mostradas na Figura A.7. Repare que a RF do atenuador provoca a atenuação de 20 dB (10 vezes) para a qual foi projetado, entretanto, sofre os efeitos provocados pelos cabos coaxiais, formando uma região de antirressonância em 30 MHz e de ressonância em 42 MHz, onde ocorrem alterações no ganho e na defasagem que sai de 0° para 180°. Ao comparar a RF simulada com a medida vemos que são bastante similares, demonstrando a influência que os cabos coaxiais podem ter nas medições de DP.



(a)



(b)

Figura A.7: Resposta em frequência para o atenuador: (a) simulada; (b) medida.

Apêndice B

Estrutura de Processamento do Sistema de Análise e Separação de Descargas Parciais

A seguir explicamos as etapas que contemplam o sistema de análise e separação de dados (verificar a Figura 7.10) desenvolvido a partir dos estudos que desenvolvemos, servindo de forma eficiente como uma ferramenta de avaliação métodos propostos.

B.1 Leitura de Dados

Para ler os dados de DP o sistema permite a busca do diretório onde o dado medido poderá ser selecionado. A extensão do arquivo é *.hws (*Hierarchical Waveform Storage Data File*) que se baseia numa Formatação Hierárquica dos Dados (*Hierarchical Data Format Version 5 - HDF5*), a qual possibilita o gerenciamento de dados extremamente grandes. A escolha dessa formatação para o nosso sistema se deve ao fato de o *software* de medição usado (IMA-DP [194],[195]) gravar os dados com essa extensão.

A leitura do arquivo é feita com base no canal especificado pelo usuário e com o tipo de sincronismo que será utilizado. O sistema disponibiliza para escolha até quatro canais, que é o padrão da maioria dos osciloscópios, denominados canais A, B, C ou D. Se a medição usou apenas um canal do *hardware* de aquisição (tensão de referência AC e DP no mesmo canal), deve-se escolher a opção de Sincronismo Interno e selecionar o canal em que a captura dos dados foi realizada. Caso a medição tenha sido feita usando dois canais do osciloscópio quando a DP encontra-

se em um canal e tensão AC de referência em outro canal, deve-se escolher a opção de Sincronismo Externo e selecionar o canal onde o sinal de DP foi capturado, pois o canal adjacente será automaticamente escolhido pelo sistema como o que contém o sinal de referência AC (e.g., se canal A contém o sinal de DP, logo o canal B deverá conter o sinal de referência).

No Sincronismo Externo o sinal de referência AC é usado apenas para sincronizar a fase das DP, e o outro é usado na etapa de identificação dos pulsos por cruzamento de LD , que necessita somente do sinal de DP.

B.1.1 Sincronização

Conforme mencionado na Seção anterior, se o tipo de sincronismo selecionado for o Interno, o sinal adquirido deverá conter, além dos sinais de descarga, a componente atenuada da tensão aplicada sobre o objeto avaliado. Este artifício, elimina a necessidade de aquisição do sinal de sincronismo por meio de outro canal, reduzindo o custo do *hardware* quando se fala em uma medição de diversos pontos. Neste caso, a tensão aplicada pode ser extraída do sinal adquirido por um processo de subtração espectral. Este procedimento consiste em calcular a DFT do sinal, de modo a obter o ângulo de fase e a amplitude da componente harmônica na frequência principal da rede. Os demais harmônicos podem ser igualados a zero e a DFT inversa dará o sinal sem componentes harmônicas. A tensão aplicada pode ser obtida subtraindo-se do sinal original o sinal sem harmônicos. Os sinais são finalmente sincronizados e escalados de acordo com a função de transferência do circuito de medição. A desvantagem dessa forma de sincronização é o tempo de processamento, já que exige a filtragem do sinal para a etapa de identificação do pulso.

Outra possibilidade é optar pelo sincronismo externo e fazer a medição do sinal de DP em um canal e o de referência por outro canal. A sincronização passa a ser feita pelo canal que recebe o sinal de referência AC, e assim que calculado o ângulo de fase, os sinais de DP (medidos em outro canal) seguem para a etapa de detecção de pulsos. Neste caso, presume-se que tenha sido aplicado um filtro passa altas analógico no sinal de DP, o que nos possibilita eliminar a etapa de filtragem digital, acelerando o processamento dos dados.

O sincronismo correto depende do circuito de medição utilizado na avaliação do equipamento de alta tensão. É comum o uso de um circuito resistivo capacitivo, o qual deslocará a componente de frequência principal da rede (60 Hz) em cerca de 90° na saída da impedância de medição (verificar o Apêndice A). E, se inserido um filtro Passa Altas (PA) após a impedância Z_m , esse deslocamento será alterado de

acordo com a resposta em frequência deste filtro. Em nossas medições (tanto em campo como em laboratório) utilizamos um filtro PA de segunda ordem que defasa a tensão AC em mais 180° , o que gera um deslocamento de fase total de -90° ($90^\circ + 180^\circ = 270^\circ = -90^\circ$). Em função disso, projetamos o sistema de maneira que o usuário possa decidir entre deslocar ou não a fase calculada em 90° .

Se a escolha for deslocar, existem duas possibilidades que dependeram da forma como a medição foi realizada:

1. Se selecionado Sincronismo Interno e no circuito de medição foi aplicado um filtro analógico PA (que ainda que sutil permita a passagem da componente AC) o deslocamento do ângulo calculado será de -90° ;
2. Caso contrário o deslocamento será de $+90^\circ$.

O ideal é permitir que o usuário insira o valor de deslocamento de acordo com sua preferência, para adaptar a medição a qualquer tipo de circuito que for utilizado, mesmo aqueles com deslocamento diferente de 90° ; entretanto, o sistema ainda não foi adaptado para esta funcionalidade.

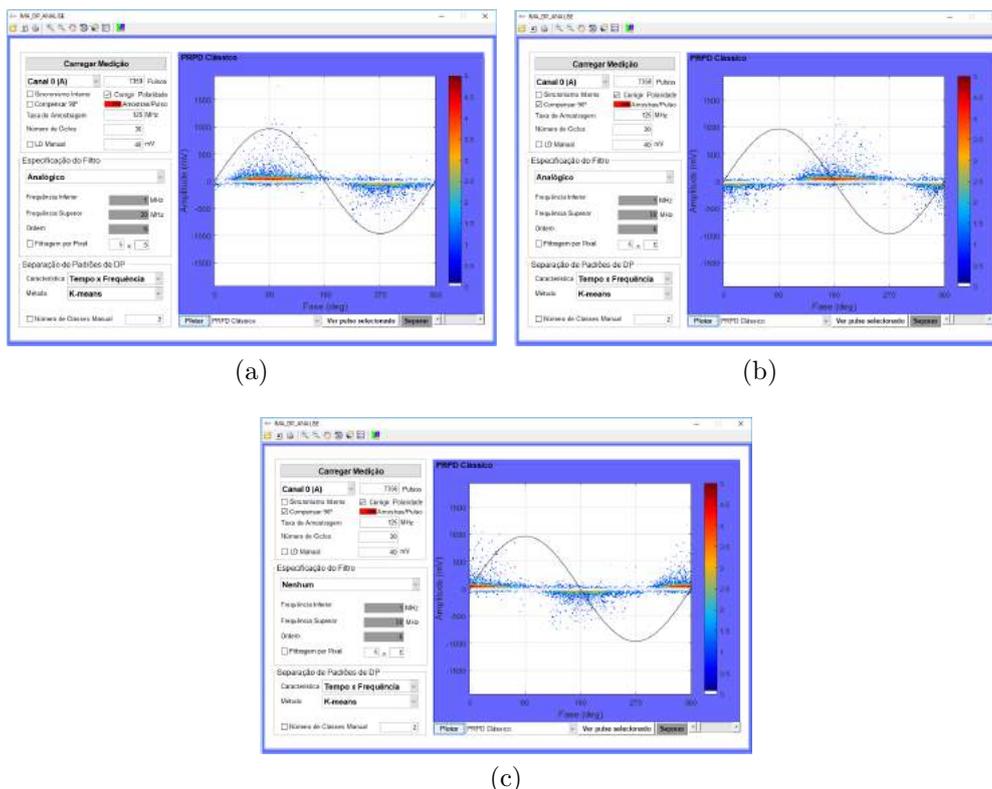


Figura B.1: Mapas PRPD obtidos para diferentes defasagens de sincronismo: (a) 0° ; (b) -90° ; (c) $+90^\circ$.

Na Figura B.1 é ilustrado o efeito no mapa PRPD em cada tipo de compensação

permitida pelo sistema. No sistema de análise foi escolhido o Sincronismo Interno direto pelo canal A (assume-se que alguma componente da tensão de referência AC esteja presente no sinal adquirido). Para a Figura B.1(a) não foi feita nenhuma compensação, com isso obteve-se 0° de defasagem. No caso da Figura B.1(b) foi selecionada a compensação 90° e por ter informado ao sistema o uso de filtro analógico (passa altas) o mapa foi corrigido em -90° (270°). Na Figura B.1(c) o usuário informou que nenhum filtro foi usado, assim o sistema assume que a defasagem existente no sinal medido deve-se apenas ao capacitor de acoplamento em conjunto com a impedância Z_m , ou seja, $+90^\circ$. Portanto, o sistema pode se adaptar a algumas das possíveis configurações do circuito usadas durante uma medição.

B.2 Filtragem Digital

A filtragem de componentes de frequência de sinais de DP fora da banda de HF reduz o ruído presente na medição, especialmente aqueles em Baixa Frequência (*LowFrequency* - LF). A definição da banda de frequência adequada numa medição irá depender principalmente do tipo de equipamento avaliado. Para geradores uma banda que tenha frequência de corte inferior de 3 MHz já é suficiente para atenuar grande parte da energia de ruído pulsante periódico originário, por exemplo, de chaveamentos de tiristores em circuitos retificadores. A Figura B.2 mostra um pulso de DP e um ruído pulsante acompanhados de seus respectivos espectros de potência. Neste exemplo, o pulso apresenta componentes em frequências bem maiores do que as vistas no outro pulso, o qual se encontra em torno de 1.6 MHz.

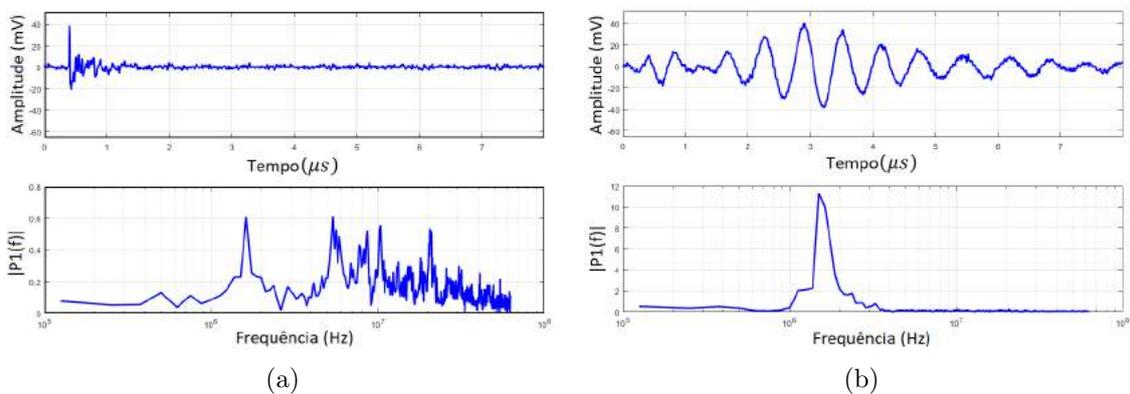


Figura B.2: Pulsos e seus respectivos espectro de potência: (a) DP; (b) ruído pulsante.

Existem inúmeras técnicas de filtragem digital que poderiam ser empregadas [16], entretanto, é preciso ter em mente que algumas destas podem produzir dis-

torções de amplitude e fase no sinal tratado, as quais não podem ser ignoradas na análise de sinais de DP. Para tentar contornar estes problemas preferimos aplicar o filtro duplo Butterworth com cancelamento de Fase [196], o qual consiste em usar duas vezes o mesmo filtro do tipo Butterworth com alguma manipulação, como se segue [40] :

1. Filtrar o sinal;
2. Inverter o sinal filtrado;
3. Filtrar novamente o sinal invertido;
4. Reinverter o sinal resultante.

Quando o sinal filtrado é revertido no tempo e depois filtrado novamente, a desfasagem sobre cada frequência é cancelada pelo segundo filtro, tal qual as distorções no sinal filtrado são reduzidas. Adicionalmente, a seletividade do filtro é melhorada. O resultado da filtragem de um pulso de DP pode se visto na Figura B.3(b). A distorção do pulso foi substancialmente reduzida em comparação com o resultado filtro Butterworth normal, verificar Figura B.3(a), o que é comprovado pela correlação de 0.9916 entre o sinal original e o sinal filtrado.

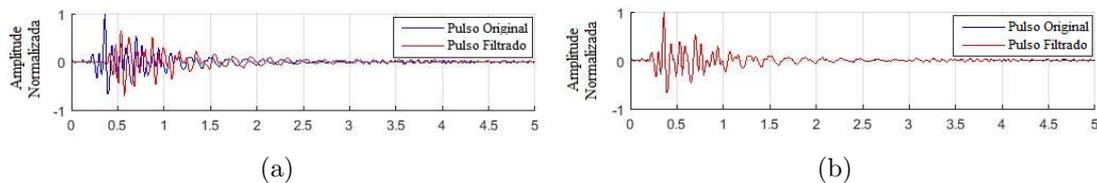


Figura B.3: Pulsos de DP filtrados com filtro passa banda para suprimir ruído: (a) Butterworth de 6^a ordem; (b) Butterworth de 6^a ordem com cancelamento de Fase.

No sistema de análise de DP, a especificação do filtro passa banda Butterworth permite que a ordem e as frequências de corte inferior e de corte superior sejam determinadas pelo usuário, de acordo com seu julgamento da melhor banda para avaliar o seus dados de DP. Pode-se assumir um filtro de 6^a ordem, com uma faixa de frequência de 1 MHz até 30 MHz, mas nada impede a escolha de outras faixas, desde que respeitada a regra de Nyquist, não operando em frequências acima da metade da frequência de amostragem. Na seleção da etapa de filtragem dispomos de quatro opções, conforme se segue:

- Analógico (PA) + Butterworth - refere-se a uma medição com uso de filtro analógico PA após a impedância de medição e, ainda assim, deseja-se aplicar o filtro Butterworth com cancelamento de fase. Também, indica que o sinal de

DP é recebido depois de ter passado por um filtro analógico. Se o sincronismo interno estiver selecionado significa que por esse mesmo canal será feito o sincronismo, mesmo que com a filtragem das baixas frequências, neste caso o sistema de análise é setado para realizar o sincronismo em -90° ;

- Butterworth - Aplica a filtragem Butterworth com cancelamento de fase, como no primeiro caso, mas nesta opção o usuário indica que não foi utilizado um filtro analógico PA. Como efeito, o sistema de análise será setado automaticamente para fazer um deslocamento de $+90^\circ$ na etapa de sincronismo;
- Nenhum - indica ao sistema que nenhum tipo de filtro analógico foi utilizado e que não se deseja aplicar a filtragem digital;
- Analógico - neste caso, apenas é indicado o uso de um filtro analógico PA, ou seja, um canal do *hardware* de aquisição será usado para captura do sinal de DP filtrado analógicamente e o outro para captura do sinal de referência da rede (60 Hz). Portanto, espera-se que seja usado em conjunto com o sincronismo externo.

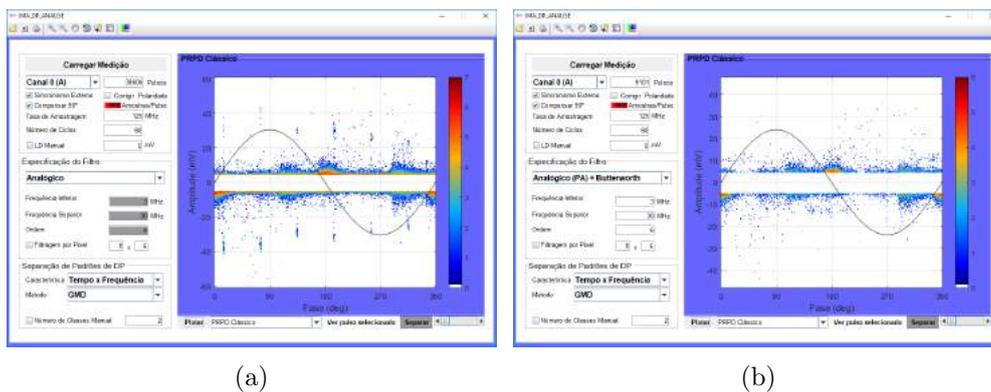


Figura B.4: Pulsos de DP filtrados com filtro passa banda para suprimir ruído: (a) sem filtrar; (b) filtrado.

Na Figura B.4(a) temos o PRPD (sem o uso do filtro passa banda digital) de onde extraímos ambos os pulsos mostrados na Figura B.3, note a presença marcante de pulsos de tiristor em pontos bem definidos com defasagem por volta de 60° entre si. Após aplicar o filtro PB de HF com frequências de corte inferior e superior dadas por 3 MHz e 30 MHz, respectivamente, o mapa resultante, visto na Figura B.4(b), já não indica a presença dos pulsos de tiristor. Logo justifica-se a importância da etapa de filtragem digital. Um outro detalhe a considerar-se é que há uma redução expressiva na quantidade de pulsos capturados, pois aqueles que estejam em frequências inferiores a 3 MHz também serão atenuados e, conseqüentemente,

podem não ser identificados pelo algoritmo de detecção de pulsos por cruzamento de LD . Então, ao especificar a banda de atuação do filtro digital, é preciso que o usuário entenda que existe um compromisso entre eliminação de ruído e detecção de DP.

Também considerou-se a possibilidade de se realizar a filtragem de ruído de espectro discreto. No entanto, em [90], onde foi feita uma análise sobre a efetividade da filtragem de espectro discreto em sinais de DP, concluiu-se que, ao contrário do que atestam muitas publicações [10], [11], os ruídos de espectro discreto não necessariamente prejudicam a medição de DP. Sendo assim, não vimos qualquer comprometimento em não adicionar esta etapa de filtragem ao nosso sistema.

B.3 Identificação de Pulsos por cruzamento de limiar

Pode-se dizer que está é a etapa crucial na análise de DP, pois será a responsável pela identificação dos pulsos de DP no sinal de obtido na medição. A forma mais simples de identificar os pulsos é através da detecção do cruzamento de um certo nível pré-estabelecido, o limiar de descarga (LD). Em [40] foi descrito o método de identificação de pulsos pelo cruzamento do LD , o qual foi usado no desenvolvimento do nosso sistema, acrescido da possibilidade de escolha do novo método de detecção de polaridade proposto. Ambos foram descritos na Seção 7.1.

O ruído de fundo pode ser eliminado da medição de DP através de um processo de limiarização, conforme a Figura B.5. O nível de limiar pode ser selecionado visualmente ou pode ser estimado automaticamente com base em alguma inferência estatística do ruído, no caso, o desvio padrão σ_S de todo o sinal filtrado em cada ciclo. Para cada caso, o nível de LD deve ser ajustado com um valor acima da amplitude máxima (em módulo) do ruído de fundo presente. Se algum modelo estocástico for assumido para o ruído, o LD pode ser calculado de forma a minimizar a probabilidade do ruído exceder seu nível durante o tempo de aquisição. Por exemplo, assumindo um ruído branco Gaussiano (média zero) presente na medição de DP e tomando um ciclo, onde o número de amostras é N (para uma frequência de amostragem F_s), o valor abaixo do qual uma amostra aleatória deste ruído cai $p = 1 - N^{-1}$ por cento do tempo é dado pela função quantil de p . Calculando para $F_s = 100$ MHz ($N = 1666666$), é possível encontrar um $LD \geq 4.8556 \times \sigma_S$, o que faz a probabilidade de um ruído presente em uma amplitude maior do que este valor inferior a N^{-1} . Em outras palavras, o valor de limiar torna improvável a detecção

de pulsos falsos criados pelo ruído branco Gaussiano com um certo desvio padrão.

Após avaliar diversos sinais de medição de descargas (mesmo que tenham sido medidos com uma F_s de 125 MHz), definimos $LD = 7 \times \sigma_S$ como um valor ideal para o nosso sistema.

No entanto, antes de realizar a busca pelos pulsos de DP em cada ciclo de dados é necessário definir uma janela de tempo de um certo comprimento para a detecção do cruzamento do LD . No sistema de análise é permitido ao usuário definir este valor em número de amostras, mas para permitir a correta análise dos dados é preciso obedecer uma regra que será explicada na Subseção a seguir.

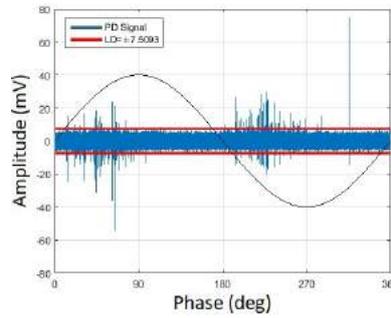


Figura B.5: Sinal processado e limiar de ruído (LD) para a detecção dos pulsos de DP, definido automaticamente. Fonte: [44]

B.3.1 Comprimento do Pulso Janelado

Depois do processo de filtragem, é necessário trigar cada pulso presente no dado medido, e para tanto é importante definir o comprimento de cada pulso trigado. Este comprimento dependerá da frequência de amostragem F_S usada na medição e da menor componente de frequência $F_{inferior}$ que o usuário deseja representar na sua análise. A questão a ser respondida é: qual será o número mínimo de amostras para representar com resolução satisfatória um pulso na menor componente de frequência. Logo, o mínimo valor para detectar adequadamente um pulso de DP será:

$$Pulso_{comprimento} = \frac{2 \times F_S}{F_{inferior}}. \quad (B.1)$$

Na maioria dos casos de avaliação de DP usa-se a banda de HF, uma escolha satisfatória é determinar $F_{inferior}$ igual a 1 MHz o que corresponde à frequência de corte inferior do filtro digital. Uma frequência de amostragem de 100 MHz pode ser considerada suficiente para a maioria dos casos de análise de DP de equipamentos de alta tensão, exceto em avaliações de cabos e GIS, onde as DP ocorrem na banda de

UHF 300 MHz até 3 GHz [197], [110], [111]. Em nosso caso, o *hardware* de aquisição tem uma frequência de amostragem de 125 MHz, assim o mínimo comprimento de pulso deverá ser 250 amostras, mas como padrão preferimos a escolha de 300 amostras. Como o sistema de separação permite avaliar a forma de onda de cada pulso de DP detectado, em alguns casos pode ser necessário aumentar o número de amostras para uma melhor avaliação dos pulsos, com intuito de identificar se estes realmente são provenientes de descargas parciais no interior do equipamento ou apenas ruído. No entanto, é preciso entender que uma janela com um número muito grande de amostras pode fazer com que mais de um pulso esteja presente, logo, interfira na quantidade de pulsos detectada no mapa PRPD resultante e na separação dos padrões de pulsos.

Na Figura B.6 exemplificamos uma leitura de dados de uma medição feita com 300 amostras ($2.392 \mu s$) e outra feita com 1000 amostras ($7.992 \mu s$). Para cada caso temos um pulso de tiristor e um pulso de DP. Perceba na Figura B.6(a) que o pulso de DP pôde ser bem representado neste caso. Já o pulso de tiristor (mais lento) necessita de uma quantidade maior de amostras para ser melhor avaliado, o que se conseguiu usando 1000 amostras, conforme ilustra a Figura B.6(b). Portanto, cabe ao usuário avaliar qual a quantidade de amostras que melhor irá representar seus dados sem desprezar a quantidade mínima dada pela Equação B.1. No sistema é permitida a alteração desta janela especificando o número de amostras considerado para identificar o pulso.

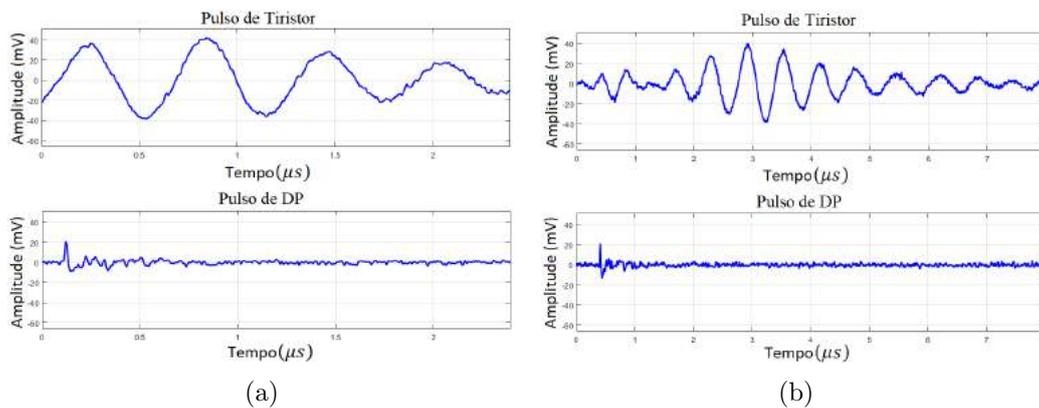


Figura B.6: Pulsos de tiristor e de DP janelados com: (a) 300 amostras; (b) 1000 amostras.

B.3.2 Matriz de Dados

Ao fim do algoritmo de detecção de pulsos será gerada uma matriz de dados M , a qual deve conter o vetor do pulso janelado, a amplitude de pico deste pulso (se

positivo será a amplitude máxima, caso contrário será a mínima), o seu instante de ocorrência (será usado para identificar a fase de ocorrência no mapa PRPD) e, em caráter informativo, o ciclo onde o pulso foi detectado. Logo, temos a matriz

$$M_{m \times n} = [\text{pulso}(1:\text{número de amostras do pulso}), \text{Amplitude}, \text{Fase}, \text{ciclo}], \quad (\text{B.2})$$

de tamanho $m \times n$, onde $m = \text{número de pulsos detectados}$ e $n = \text{número de amostras do pulso} + 3$. Será por meio desta matriz que todas as análises sobre a medição efetuada poderão ser realizadas, por exemplo: plotar o PRPD, avaliar os histogramas de amplitude e de fase, extrair características, separar padrões por agrupamento de dados, visualizar pulsos, entre outros.

B.4 Apresentação de Dados

Devido a grande quantidade de informação na matriz de dados adquirida a partir da medição de DP, é preciso comprimi-la para que possa ser convenientemente processada, apresentada e armazenada. Uma maneira conveniente para fazer isso é compactar os dados em forma de histogramas estatísticos ou extrair atributos representativos destes dados, ou seja, características que representam eventos de DP categorizadas em componentes no domínio do tempo e/ou da frequência.

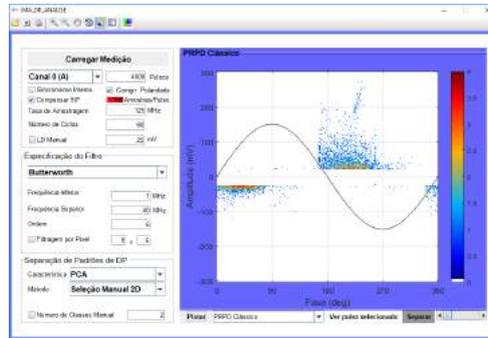
No Capítulo 2 descrevemos as formas convencionais de apresentação dos dados de DP, como o mapa PRPD e os espectrogramas de amplitude e fase extraídos deste mapa (*fingerprints*).

Já no Capítulo 4 apresentamos as principais formas de extração de características, algumas destas já utilizadas para representação de dados de DP e outras ainda não apresentadas na literatura ligada às DP. Devido ao potencial de cada técnica de extração em conseguir fornecer uma boa representação para os pulsos detectados, todas serão acrescentadas ao sistema de análise aqui desenvolvido. Com esta variedade, facilitamos o emprego de métodos de agrupamento para conseguir a separação das características extraídas e, conseqüentemente, dos padrões de DP em seus submapas PRPD.

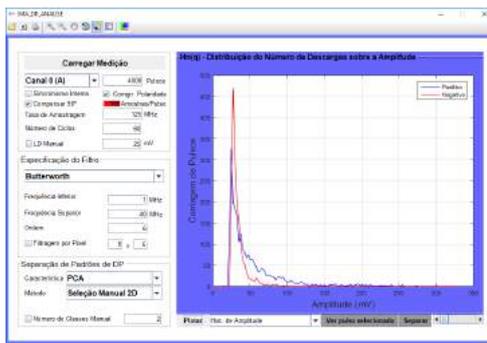
No sistema de análise proposto, dispomos de algumas opções para visualizar (plotar) os dados, as quais serão citadas e exemplificadas nas Subseções a seguir. Tomaremos como exemplo uma medição com duração de 60 ciclos feita num hidrogênador de uma UHE, na qual foi utilizado um *hardware* ($F_S = 125$ MHz com 14 *bits* de resolução) para aquisição dos dados em apenas um canal.

B.4.1 PRPD Clássico e *Fingerprints*

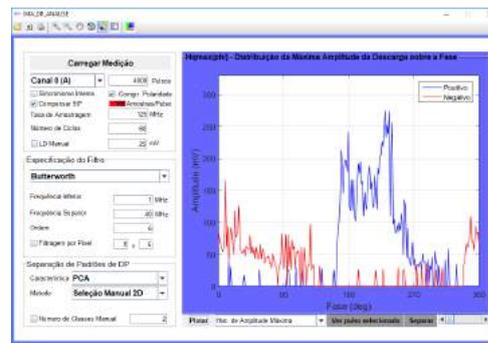
Estas são as formas mais comuns de se compactar os dados de DP. Como já foram discutidos anteriormente, não entraremos em mais detalhes de como são obtidas, mas para criar uma sequência lógica de apresentação do sistema de análise mostramos na Figura B.6 os resultados para a medição mencionada.



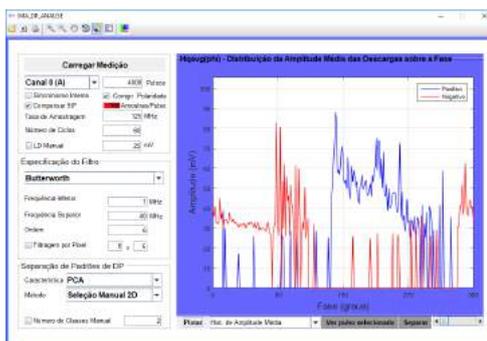
(a)



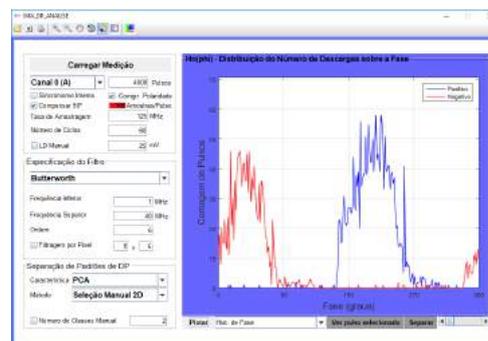
(b)



(c)



(d)



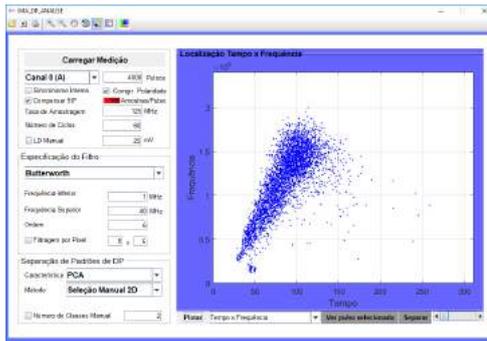
(e)

Figura B.7: Apresentação de dados de DP: (a) PRPD Clássico; (b) Histograma de Amplitude - Distribuição do número de descargas sobre a amplitude; (c) Histograma de Máxima Amplitude - Distribuição da máxima amplitude das descargas sobre a fase; (d) Histograma de Amplitude Média - Distribuição da amplitude média das descargas sobre a fase; (e) Histograma de Fase - Distribuição do número de descargas sobre a fase.

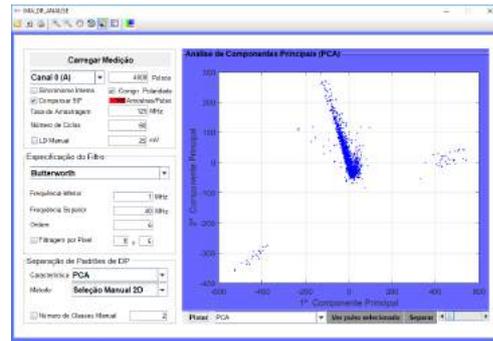
B.4.2 Visualização da Extração de Características

O objetivo principal do sistema de análise é a separação dos diferentes padrões de DP e do ruído. No entanto, antes de aplicar o método de agrupamento de dados para a separação, é preciso escolher qual técnica de extração de características será aplicada. Por esta razão, permitimos a visualização de algumas destas técnicas de extração, dentre elas:

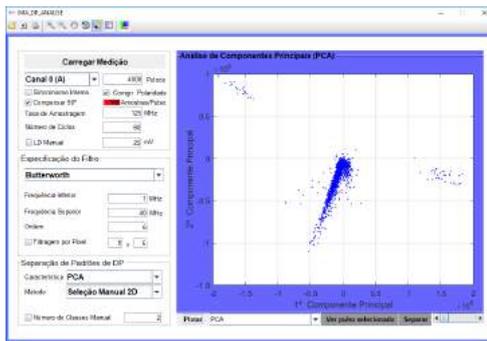
- Tempo x Frequência;
- PCA dos pulsos (em 2D ou 3D) - podendo ser feita a escolha entre a PCA Clássica, PCA Kernel (simples), PCA Kernel (Gaussiana), PCA Exponencial (E-PCA) e PCA Probabilística (PPCA);
- PCA da FFT dos pulsos (em 2D ou 3D) - podendo ser feita a escolha entre a PCA Clássica, PCA Kernel (simples), PCA Kernel (Gaussiana), E-PCA e PPCA;
- *Power Ratio*.



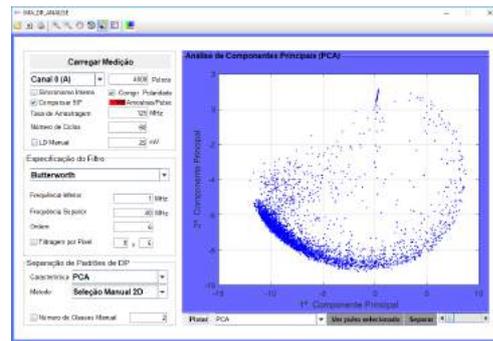
(a)



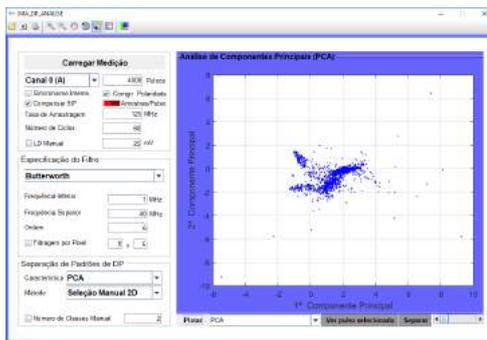
(b)



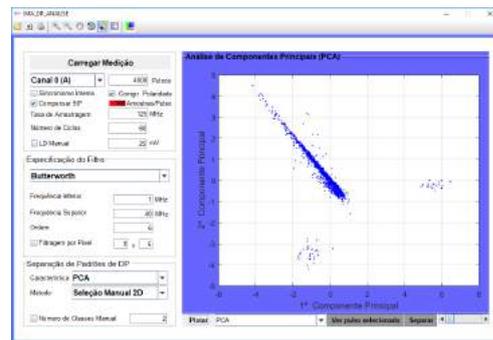
(c)



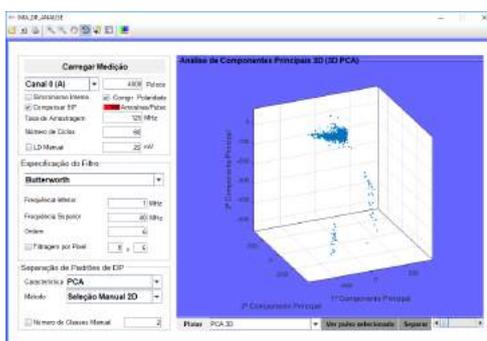
(d)



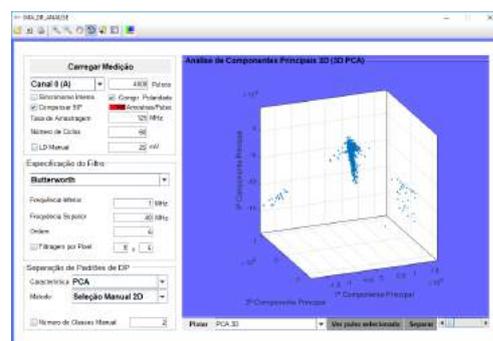
(e)



(f)

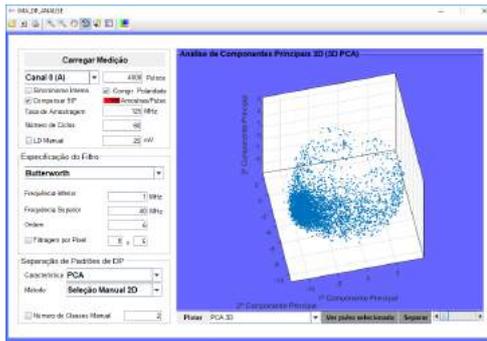


(g)

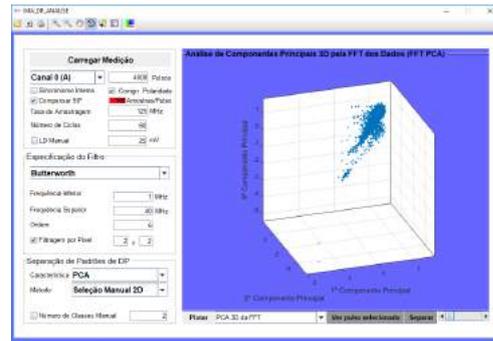


(h)

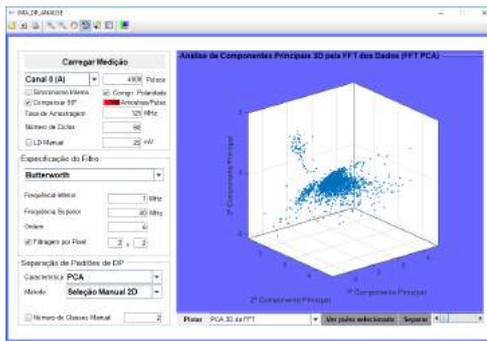
Figura B.8: Visualização de características extraídas: (a) Tempo x Frequência; (b) PCA 2D; (c) PCA Kernel 2D; (d) PCA Kernel Gaussiana 2D; (e) E-PCA 2D; (f) PPCA 2D; (g) PCA 3D; (h) PCA Kernel 3D.



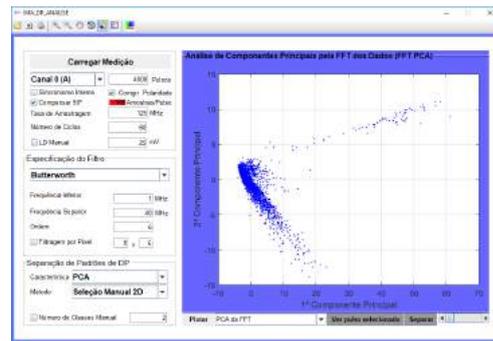
(a)



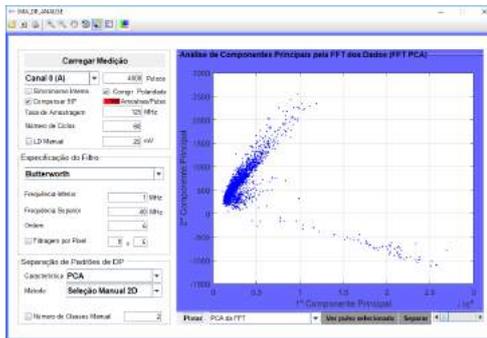
(b)



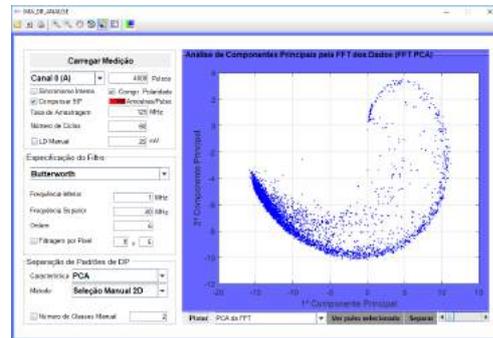
(c)



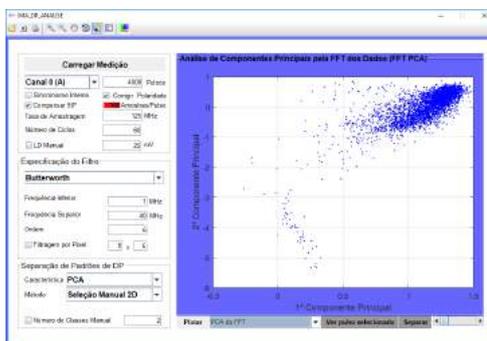
(d)



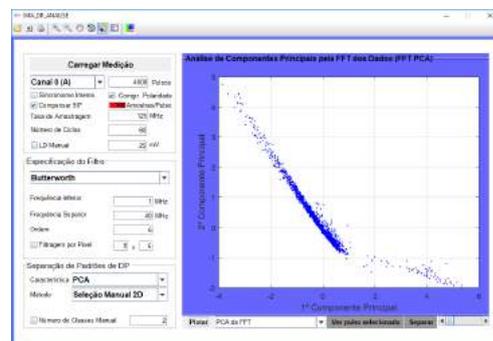
(e)



(f)



(g)



(h)

Figura B.9: Visualização de características extraídas: (a) PCA Kernel Gaussiana 3D; (b) E-PCA 3D; (c) PPCA 3D; (d) PCA da FFT 2D; (e) PCA Kernel da FFT 2D; (f) PCA Kernel Gaussiana da FFT 2D; (g) E-PCA da FFT 2D; (h) PPCA da FFT 2D.

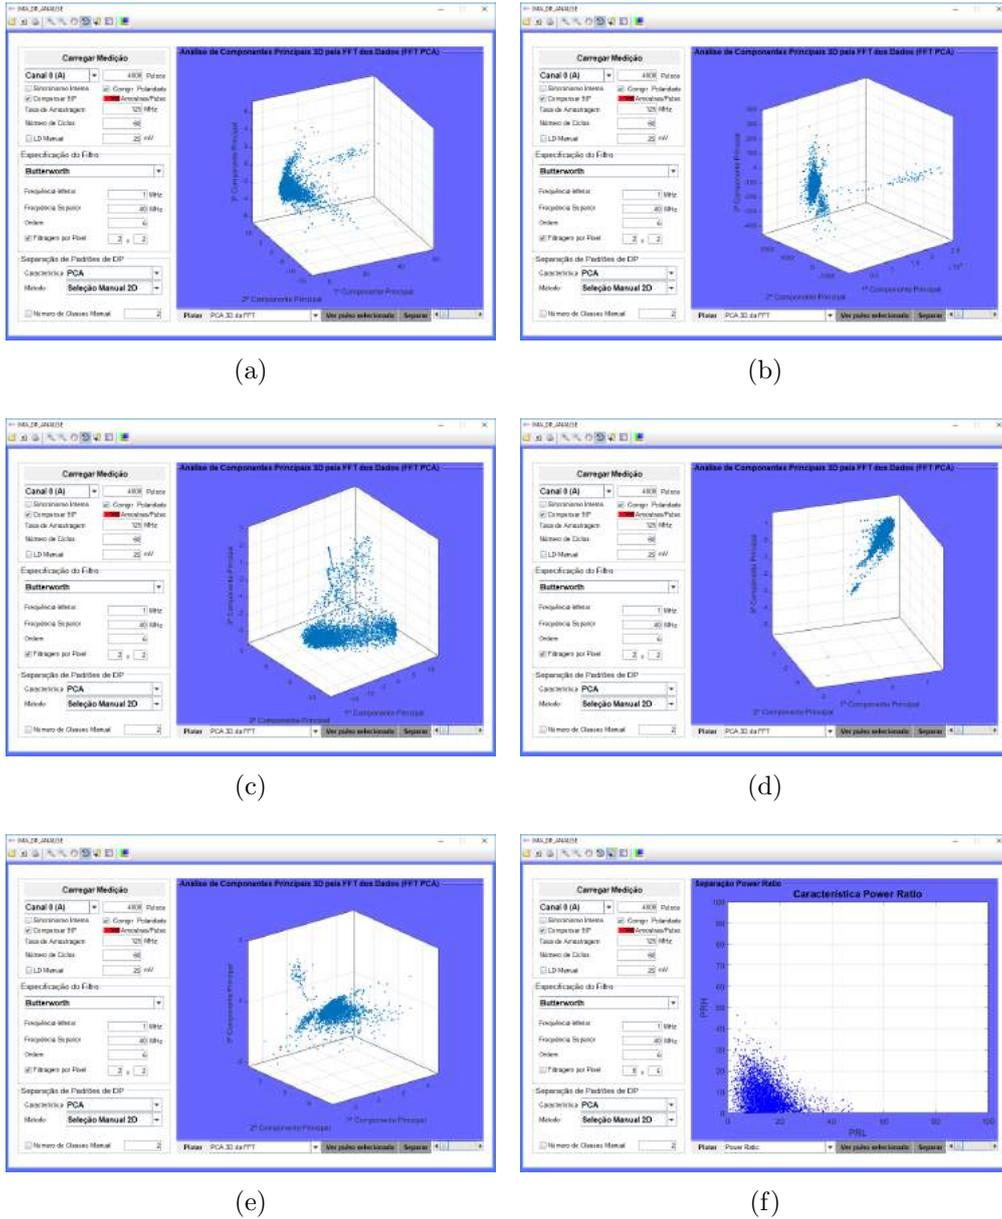


Figura B.10: Visualização de características extraídas: (a) PCA da FFT 3D; (b) PCA Kernel da FFT 3D; (c) PCA Kernel Gaussiana da FFT 3D; (d) E-PCA da FFT 3D; (e) PPCA da FFT 3D; (f) *Power Ratio*.

As Figuras B.8, B.9 e B.10 nos permitem visualizar cada uma destas características extraídas a partir da matriz de dados gerada após a identificação dos pulsos. Vemos que cada método de extração possui sua performance, fornecendo diferentes resultados, os quais serão melhores ou piores dependendo do tipo de sinal presente nas medições. Por esta razão que fornecemos ao usuário do sistema de análise a opção de investigar entre os diversos algoritmos de extração de características aquela que propiciará a melhor separação dos diferentes padrões de pulsos. Entende-se como melhor caracterização de um conjunto de sinais, aquela

que consegue (do ponto de vista normalizado) o menor distanciamento entre sinais similares (maior densidade) e maior afastamento entre pulsos de características distintas. Para as extrações mostradas nas Figuras B.8, B.9 e B.10 poderíamos assumir, visualmente, que tanto a PCA clássica (2D e 3D) quanto a PCA Kernel simples (2D e 3D) são as melhores e poderiam ser mais facilmente distinguidas por quaisquer dos métodos de separação que fossem aplicados.

É, também, através da visualização das características que podemos estimar a quantidade de padrões (classes) diferentes que existem numa medição, para então podermos especificar, manualmente ou automaticamente, o número de classes que devemos definir antes de executar a separação. Para a classificação automática é usado o critério Silhouette que auxilia na interpretação e validação da consistência dentro de um *cluster* de dados, informando graficamente o quão bem cada um deles se encaixa no *cluster* ao qual foi designado [198]. Coeficientes Silhouette próximos de +1 indicam que as amostras estão distantes dos grupos vizinhos. Um valor 0 indica que as amostras estão sobre ou próximas da fronteira entre dois *clusters* e valores negativos indicam que as amostras podem ter sido atribuídas ao grupo errado. Na Figura B.11 exemplificamos a escolha automática para a característica por PCA simples, tomando o maior valor Silhouette como o critério que define o número de *clusters* ideal, neste caso para 3 *clusters* temos o maior valor e, portanto, os dados serão separados em 3 classes.

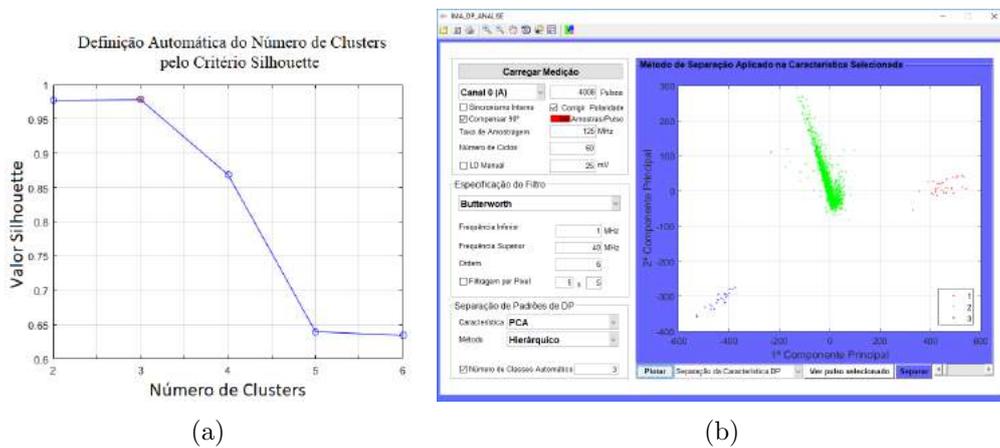


Figura B.11: Escolha automática do número de classes usando o critério Silhouette: (a) Valor Silhouette de 2 até 6 classes; (b) Característica PCA Simples dividida em 3 classes;

Outros métodos de extração podem ser visualizados somente após executar a separação dos pulsos com a escolha da opção de “Separação da Característica de DP”, que é o caso da:

- Extração de característica pela PCA da função NACF (somente em 3D);
- Extração de característica por estatística Weibull;
- Extração de característica por t-student SNE (t-SNE) em 2D ou 3D;
- Extração de característica por algoritmos MDS - podendo ser feita a escolha entre DMAP, análise fatorial, GDA, Landmark-Isomap, LDA, LPP, NPE, SM e SPE.

B.4.3 Separação de Padrões de DP em Classes

O principal esforço que envolve o processo de separação de cada tipo de defeito de DP é extrair uma característica que consiga condensar os sinais de origem similar e distanciar aqueles de fonte distinta o tanto quanto possível, juntamente com um método de agrupamento que consiga separar as diferentes classes com a melhor acurácia.

Dentre os vários métodos de extração de características e de agrupamento é difícil encontrar uma única combinação generalizada para as diferentes condições a que uma medição de DP está exposta (interferências, tensão aplicada, umidade, temperatura, circuitos de medição, etc.); para os diferentes tipos de defeitos que as geram; e para os diferentes tipos de equipamentos avaliados. Assim, optamos por projetar o sistema de maneira que seja possível investigar combinações diversas e definir aquela que melhor consegue separar os diversos pulsos detectados.

Com a separação é obtida uma nova matriz de dados, a qual denominamos de Matriz Classificada Mc , dada por:

$$Mc_{m \times n} = [\text{Pulso}(1:\text{número de amostras do pulso}), \text{Amplitude}, \text{Fase}, \text{Ciclo}, \text{Classe}], \quad (\text{B.3})$$

neste caso a dimensão $n = \text{número de amostras do pulso} + 4$. Portanto, Mc contém a matriz de dados M juntamente com os indicadores (numéricos) de qual classe pertence cada pulso contido nesta.

Todos os métodos de caracterização dos sinais de DP que usamos foram mencionados na Subseção B.4.2. Nos resta mostrar a seguir os métodos de agrupamento de dados (*clustering*) que aplicamos ao sistema:

- K-means;
- K-means ++;

- K-medoid PAM;
- K-medoid CLARA;
- Fuzzy C-means;
- Hierárquico;
- NACF K-means - podendo ser feita a escolha entre as funções distância usadas para identificar a similaridade entre cada pulso, sendo estas a função correlação e Pearson, a função Coseno, a função *Chebyshev* ou a função *City block*. Como calcula automaticamente o número de classes presente na medição, não necessita que este seja definido *a priori*;
- GMD.

Todos os métodos de agrupamento destacados acima têm sua utilidade em detectarem automaticamente os grupos presentes em uma medição de DP, mas por vezes a característica extraída pode claramente identificar cada fonte de DP, tal que uma seleção manual poderia perfeitamente separar estes grupos. Em vista desta necessidade, adicionamos ao sistema a opção de seleção manual (feita com o *mouse*) para o mapeamento gerado por quaisquer das técnicas de caracterização descritas (Subseção B.4.2).

A seleção manual é realizada diretamente sobre o gráfico 2D da característica extraída, onde devemos usar o *mouse* para selecionar os vértices de um polígono que irão englobar todos os pontos (pulsos medidos) que desejamos atribuir à classe a qual estimamos que estes pontos pertençam. O processo é repetido para a quantidade de classes que definimos *a priori*, logo, a seleção manual não é permitida caso a definição de classes esteja no modo automático. Na Figura B.12 demonstramos o processo de seleção manual. De acordo com a característica extraída na Figura B.12(a), intuitivamente podemos identificar 2 classes, logo iniciamos a escolha aleatória de vértices que englobem quaisquer das classes que identificamos e, em seguida, repetimos o processo até termos selecionado todas as classes, conforme ilustrado nas Figura B.12(b), (c) e (d). Como resultado temos a característica mapeada e o PRPD separados (verificar Figuras B.12(e) e (f)).

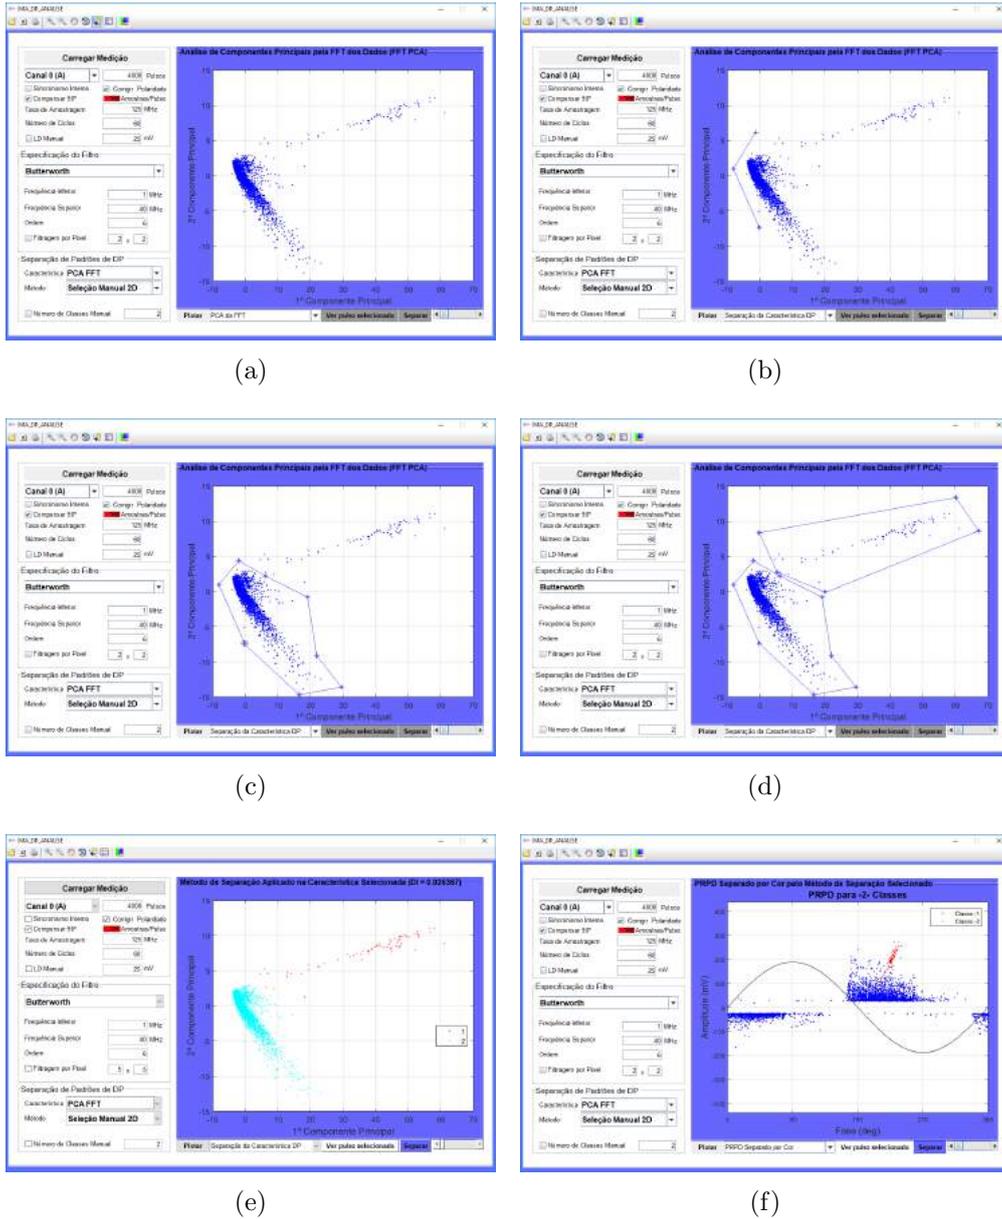


Figura B.12: Método de seleção manual de classes: (a) PCA da FFT 2D obtida; (b) Início da seleção poligonal da 1ª classe; (c) Seleção poligonal da 1ª classe; (c) Seleção poligonal da 2ª classe; (e) Característica PCA da FFT separada; (e) PRPD separado por cor.

Na figura B.13 expomos alguns exemplos de separação da característica de DP proporcionados pelo sistema de análise. Os resultados mostrados nas Figuras B.13 (a), (b), (c) e (d) são muito parecidos com 2 classes. Para o exemplo mostrado na Figura B.13(e) o método NACF consegue identificar uma classe a mais (sendo uma delas formadas por pulsos que não se enquadraram em termos de similaridade ao pulsos das outras duas classes). Na Figura B.13(f), o método GMD mostra uma performance um pouco distinta das vistas para os métodos K-Means ++, K-medoid

CLARA , Fuzzy C-means e Hierárquico, pois trabalha com base na distribuição Gaussiana dos componentes. No entanto, o que queremos destacar é que todos os métodos possuem a capacidade de identificar os diferentes padrões existentes e que tal capacidade dependerá de quão bem as características podem ser extraídas dos sinais obtidos na medição. Portanto, cada método tem seu valor, podendo se portar melhor ou pior de acordo com os dados aquisitados.

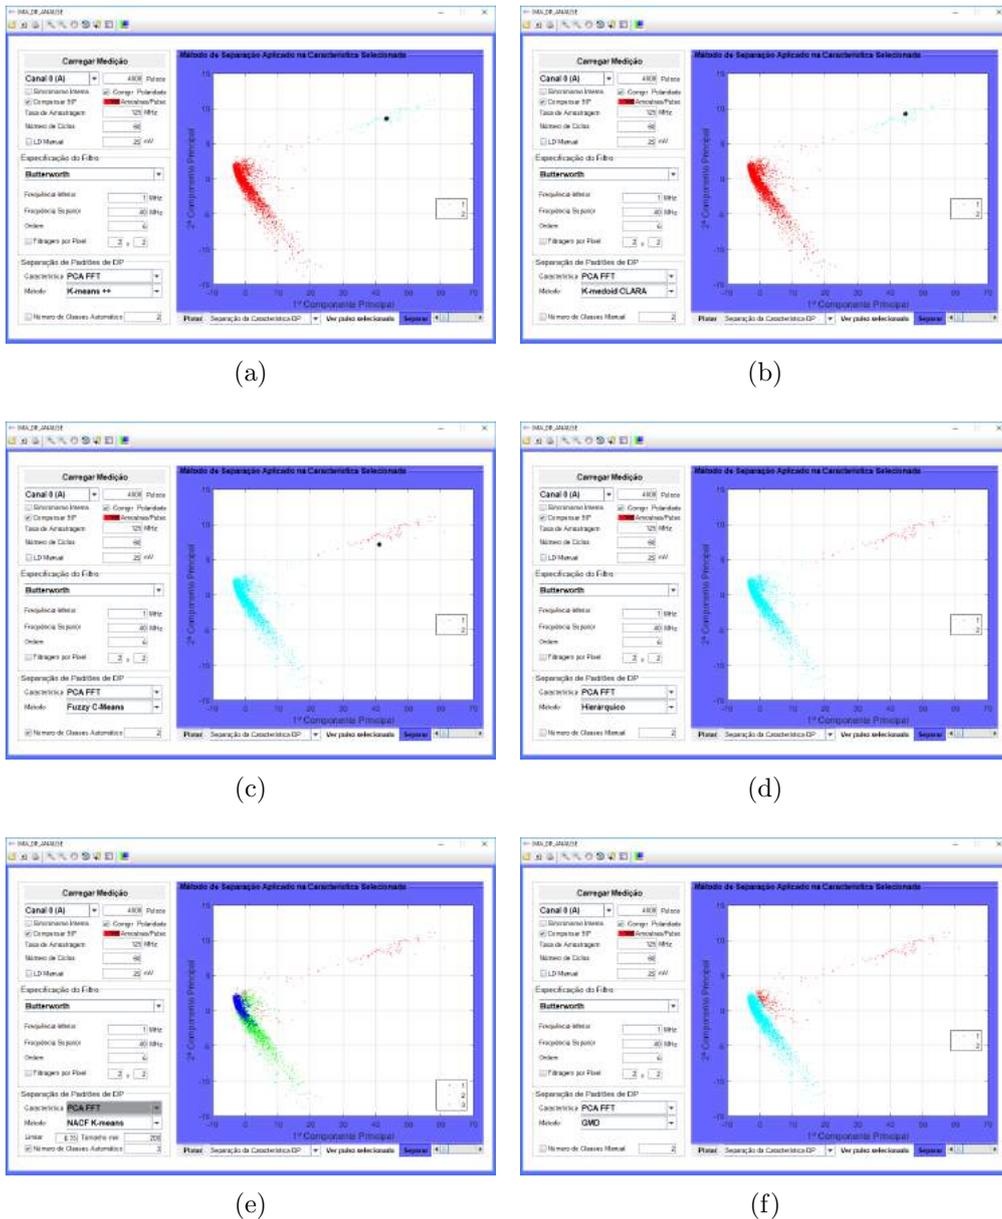


Figura B.13: Exemplos de separação da característica PCA simples da FFT dos sinais de DP: (a) K-means ++; (b) K-medoid CLARA; (c) Fuzzy C-means; (d) Hierárquico; NACF K-means; (f) GMD.

Após executar a etapa de separação dos dados especificando a técnica de extração e o método de agrupamento, que combinados permitem isolar os padrões de

pulsos de DP e mesmo ruído presentes, é possível separá-los em sub-mapas PRPD correspondentes às classes geradas. Após serem separados, ainda é possível visualizar o pulso médio, o espectro de potência médio e a resposta em frequência estimada do sistema medido para cada um destes mapas.

B.4.4 Análise Pulso a Pulso

Como a matriz de dados gerada contém a forma de onda de cada pulso detectado no cruzamento do valor de LD , é possível fazer a análise destes pulsos individualmente. Nesta análise podemos verificar a forma de onda no domínio do tempo para avaliar as amplitudes e a polaridade do pulso, além de extrair o espectro de potência correspondente para identificar as componentes de frequência existentes neste pulso. Para ter acesso a análise pulso a pulso na tela do programa basta selecionar um ponto correspondente ao pulso que se deseja visualizar e clicar em “Ver pulso selecionado”. A seleção deste ponto pode ser feita no mapa PRPD clássico, no gráfico com a característica de DP separada ou no PRPD distinguido por cores. Como exemplo, a Figura B.14 mostra o processo de seleção e visualização do pulso para o mapa PRPD.

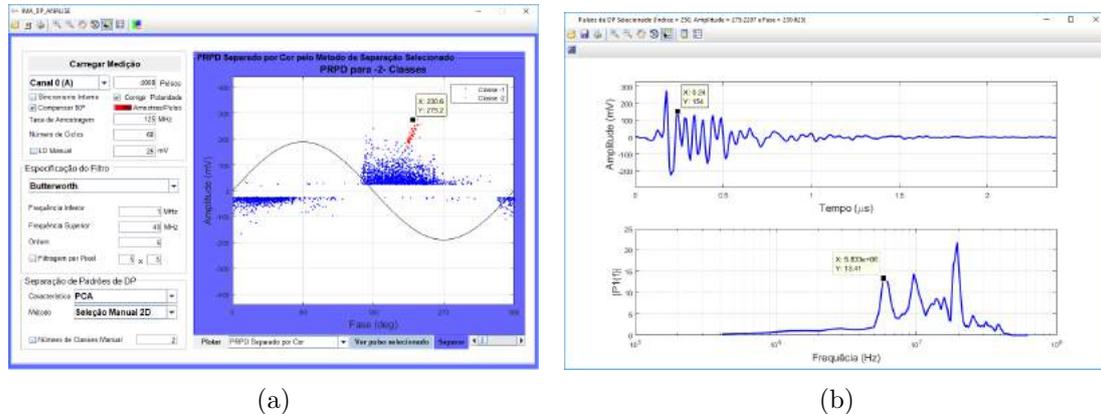
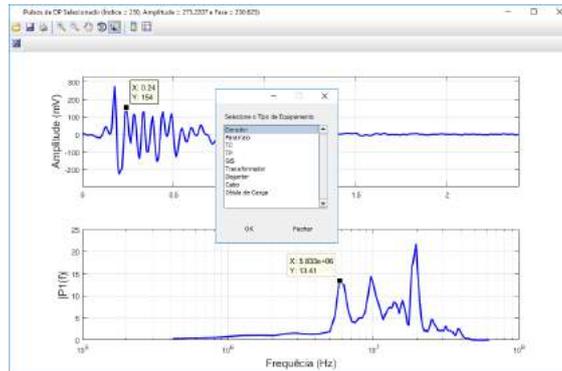


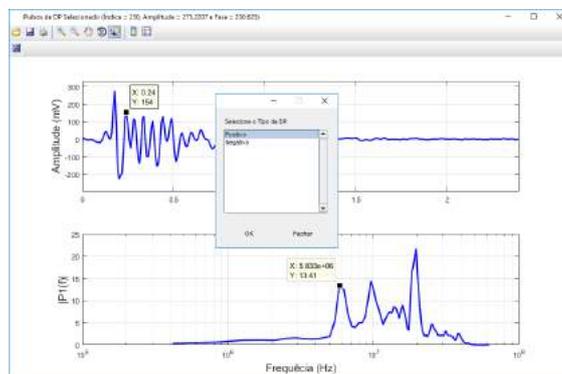
Figura B.14: Análise pulso a pulso: (a) seleção do pulso no mapa PRPD distinguido por cor; (b) visualização na janela de análise do pulso selecionado.

O sistema dispõe de ferramentas gráficas para facilitar a análise de cada figura gerada (*zoom in*, *zoom out*, *pan*, legenda, rotacionar, inserir cursor indicativo de dado), permite imprimir a tela e salvar as figuras. Adicionalmente, é possível salvar o pulso em análise num diretório organizado por tipo de equipamento de alta tensão (Gerador, Pararraio, TC, TP, GIS, Transformador, Disjuntor, Cabo ou Célula de Carga) e de acordo com a polaridade (positiva ou negativa). Esta função mostrada

na Figura B.15 é importante para organização dos dados que poderão ser usados posteriormente em outros estudos.



(a)



(b)

Figura B.15: Salvando pulso analisado em diretórios organizados por: (a) tipo de equipamento que foi medido; (b) polaridade do pulso visualizado.

B.4.5 Separação em Submapas PRPD

A partir da matriz Mc é possível identificar a qual classe pertence cada pulso e, conseqüentemente, separar o mapa PRPD clássico em submapas PRPD correspondentes a cada classe. Esta disjunção é muito importante para avaliarmos a eficácia dos métodos de extração de características e de agrupamento usados. Ademais, consegue-se analisar com maior clareza os tipos de defeitos existentes numa medição, algo que nem sempre é possível de ser feito com o mapa PRPD clássico. Como resultado prático, há uma contribuição significativa para o correto diagnóstico do objeto examinado.

Para demonstrar o quão importante essa separação pode ser para uma medição, veja o exemplo mostrado na Figura B.16, no qual o PRPD clássico (obtido a partir de um gerador a diesel) não nos permite observar os sinais típicos de DP, pois os

mesmos se encontram encobertos por ruídos de alta amplitude. Somente após aplicar a metodologia de agrupamento de classes e, por fim, dividir estas em seus respectivos submapas PRPD é que conseguimos visualizar claramente a existência de ruído e de um padrão típico de DP (descarga interna em gerador), conforme a Figura B.16(c).

No sistema de análise, os mapas podem ser divididos após clicar em “Separar”, com isso, os mapas separar-se-ão por classe (é permitido separar no máximo 10 classes), sendo exibidos numa nova tela, conforme já mostrado na Figura B.16. Esses mapas podem ser separados usando a mesma escala de amplitude do mapa clássico ou podem ser divididos usando amplitudes distintas. No último caso, gerar PRPD com escalas diferentes é muito útil para uma melhor resolução quando existem padrões de defeitos com relações de amplitude entre si muito grandes. A Figura B.17 evidencia a melhora na resolução quando comparamos o PRPD obtido usando a mesma escala (Figura B.17(a)) com o obtido usando escala distinta ((Figura B.17(b)).

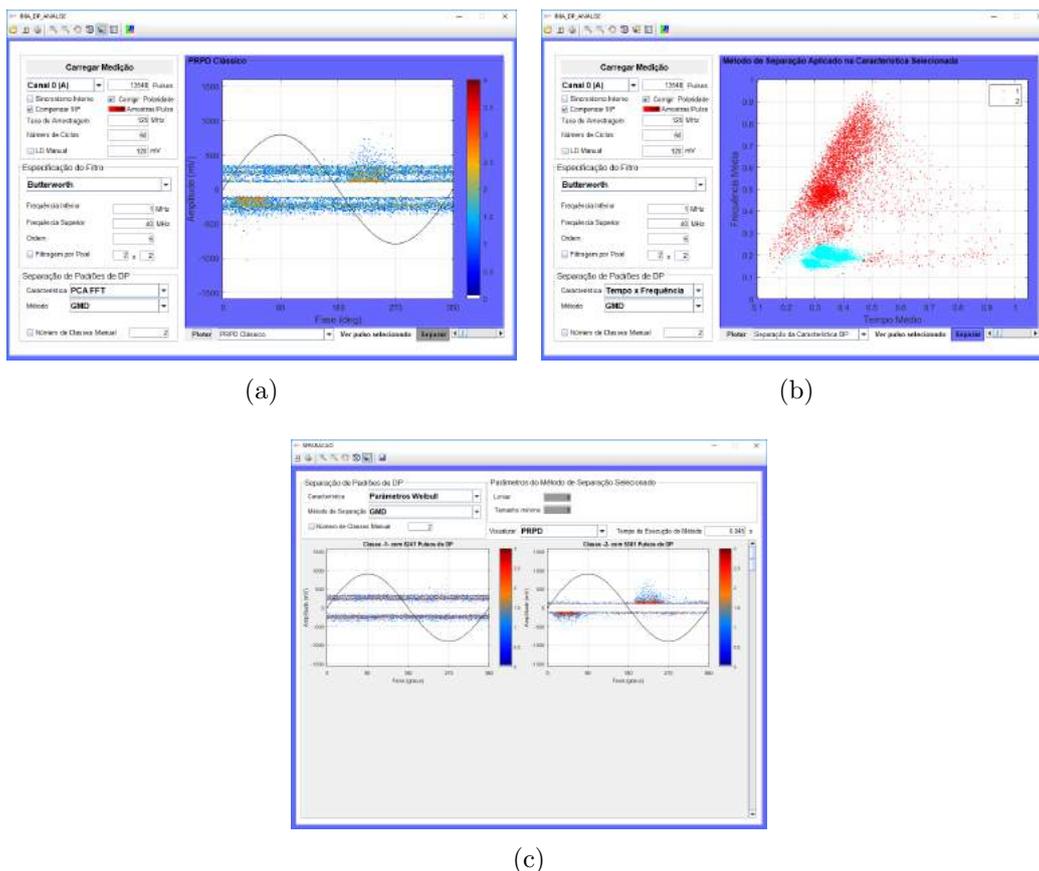
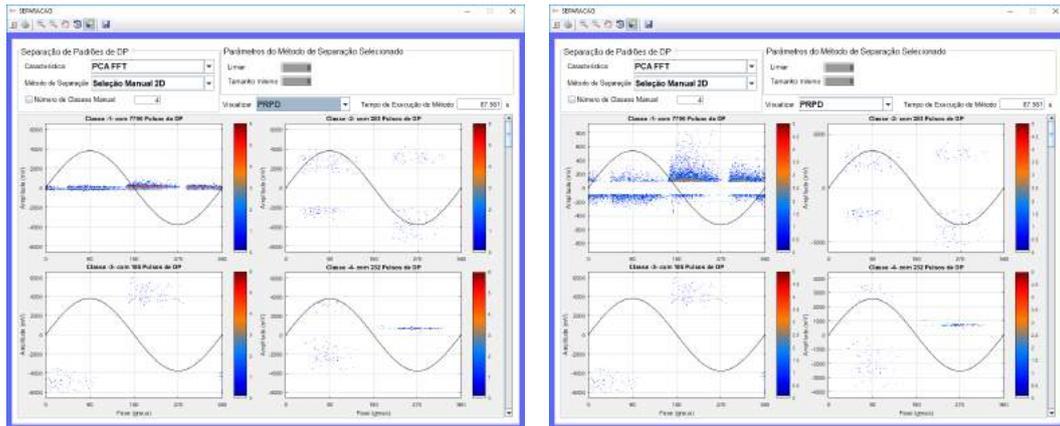


Figura B.16: Exemplo de separação de uma medição de DP: (a) PRPD clássico; (b) Característica Tempo x Frequência separada em cor pelo método GMD; (c) Tela de separação com submapas PRPD separados.



(a)

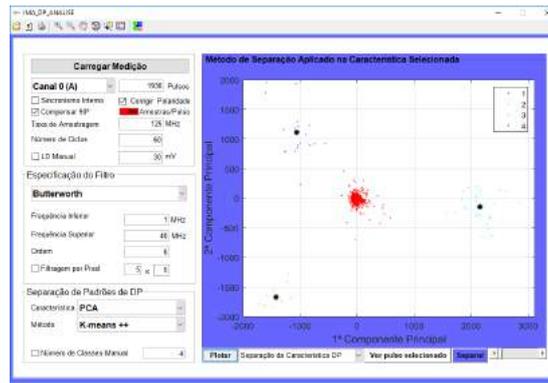
(b)

Figura B.17: PRPD separados com: (a) mesma escala; (b) escala distinta.

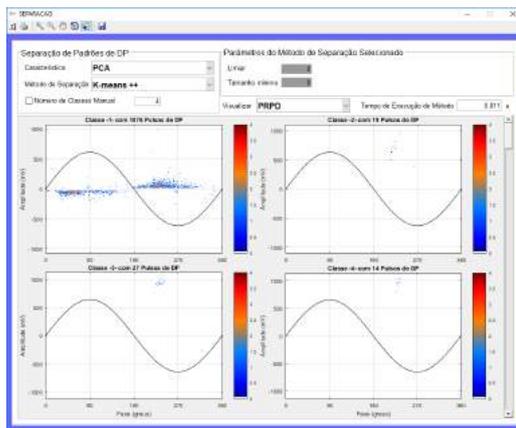
Assim como ocorre para o mapa PRPD clássico, também, é possível aplicar a filtragem por caixa de *pixels* ao mapas separados, bastando que esta opção de filtragem esteja selecionada.

B.4.6 Pulso Médio

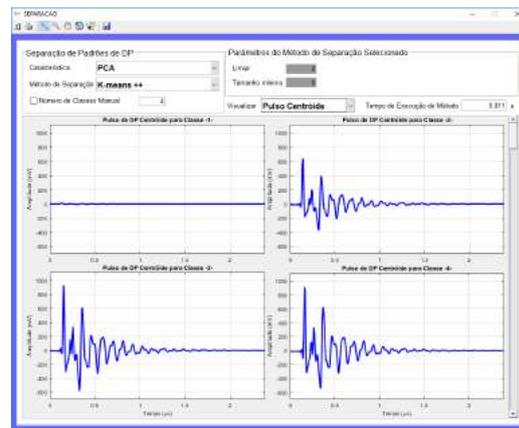
É esperado, ao final do processo de desmembramento dos padrões de pulsos em seus respectivos mapas PRPD, que cada um destes representem um único tipo de defeito causador da DP ou de interferência. No entanto, sabe-se que os processos de extração de características e de clusterização não são capazes de garantir a perfeita separação dos padrões por si sós. Daí surge a necessidade de avaliar se os mapas produzidos realmente retratam classes distintas. Uma maneira eficiente é verificar o pulso médio representante de sua respectiva classe. Logo, se a forma de onda do pulso médio (centroide) de uma classe se assemelha ao de qualquer outra classe gerada, é possível assumir com alta probabilidade que estes pulsos são oriundos de um único defeito.



(a)



(b)



(c)

Figura B.18: (a) Separação da característica extraída dos pulsos de DP; (b) mapas PRPD separados; (c) pulsos médios correspondentes aos mapas separados.

Como exemplo, podemos citar os casos onde pulsos com diferenças de amplitude consideráveis ou sutis alterações de forma acabam por afetar a extração de características e fazer com que sejam agrupados em classes distintas, mas ainda assim provém do mesmo tipo de defeito. A Figura B.18 ilustra tal efeito. Repare em B.18(b) e em B.18(c) que, apesar de separados como classes distintas, três dos padrões possuem pulsos médios muito similares, o que nos permite assumir que são originários do mesmo tipo de defeito no equipamento analisado. Já a classe 1 mostrada tem pulso médio bem distinto dos demais, ou seja, esta classe realmente provém de outra fonte de defeito, e portanto, a medição deveria ser dividida em 2 classes e não em 4 como achamos que fosse ao visualizar a PCA (simples em 2D) mostrada na Figura B.18(a).

Vale lembrar que esta propriedade já foi explorada na Seção 6.1, onde usamos a correlação entre os pulsos médios para avaliar a similaridades entre as classes geradas pelo método NACF e decidir se estas poderiam ser reagrupadas.

É importante destacar que alguns dos métodos de extração e de agrupamento

dos dados usados em nosso trabalho, até então, não foram explorados para o tratamento de sinais de DP na literatura vigente. Portanto, ao incorporarmos estas metodologias ao sistema de análise de descargas parciais, podemos aperfeiçoar os resultados de separação e classificação de dados, além de abrir caminho para novos estudos e contribuições nesta área.

B.4.7 Espectro de Potência Médio

Com o mesmo objetivo de ajudar na identificação de PRPD semelhantes, também estendemos a análise ao espectro de potência médio das classes obtidas. O espectro de potência médio é obtido diretamente a partir do pulso centroeide. Para o exemplo mostrado na Figura B.18, obtemos os espectros correspondentes expostos na Figura B.19, confirmando que as classes 2, 3 e 4 são referentes a pulsos de mesma classe, enquanto que a classe 1 é diferente, contendo componentes de mais baixas frequências.

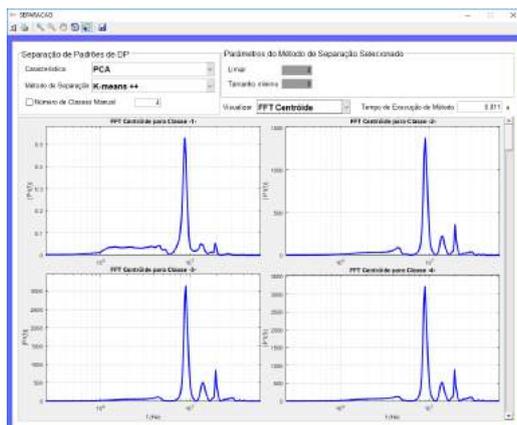


Figura B.19: Espectros de potência médios para os PRPD mostrados a Figura B.18(b).

B.4.8 Estimativa de Resposta em Frequência Normalizada (*Max Min Hold FFT*)

Este recurso faz a estimativa da resposta em frequência normalizada do sistema avaliado, a qual engloba todo o circuito de medição, desde a origem do pulso no interior do equipamento, terminais, impedância de medição Z_m , cabos coaxiais, filtros, amplificadores, atenuadores, entre outros dispositivos que podem ser acoplados, até mesmo o *hardware* usado para a aquisição dos dados. Também pode influenciar na RF os filtros digitais que por ventura venham a ser utilizados no processamento dos dados de DP. Para verificar o efeito do filtro digital na RF observe a diferença entre

a Figura B.20(a) com a RF estimada para a medição sem o uso de filtros digitais e a Figura B.20(b) com a RF estimada com o uso de um filtro passa banda Butterworth de 6ª ordem com frequências de corte inferior e superior de 1 MHz e 40 MHz.

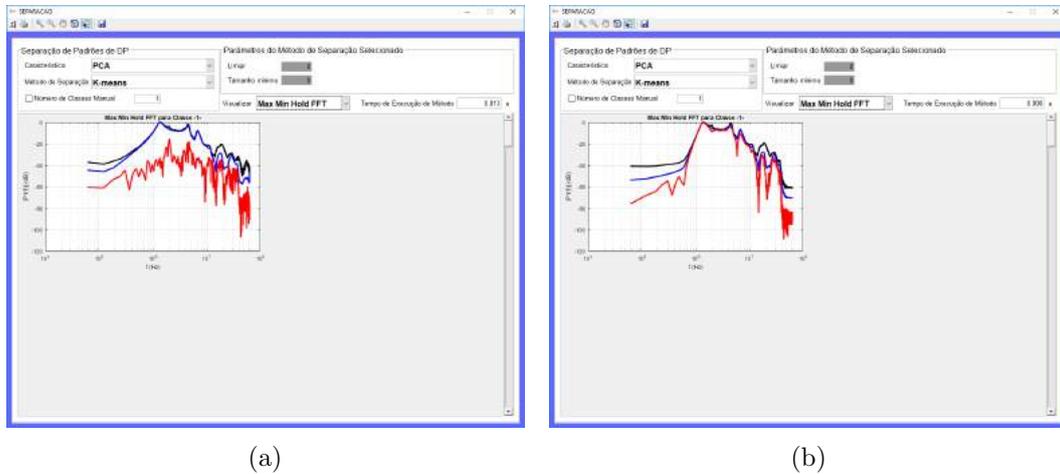


Figura B.20: Comparação entre RF estimada sem uso de filtro digital e com uso de filtro digital passa banda Butterworth (1 MHz - 40 MHz).

A técnica aplicada para estimar essa RF por retenção de valores de máximos (*Max Hold*), bem como sua variação de retenção de mínima (*Min Hold*) e média, já foram explicados na Seção 7.2. Conforme descrito, além de permitir uma análise do sistema medido, esta ferramenta também é útil na identificação de pulsos erroneamente agrupados em uma certa classe (verificar Figura 7.7).

B.5 Ferramentas Gráficas e Gerador de Relatórios

Como o sistema fornece diversas informações a respeito dos dados medidos em um formato gráfico, dispomos de um conjunto de ferramentas que facilitam a análise destas imagens, dentre estas:

- *Zoon in* - amplia a imagem;
- *Zoon out* - afasta (reduz) a imagem;
- *Pan* - desloca a imagem no sentido desejado;
- Rotacionar - rotaciona a imagem, sendo muito útil para as características extraídas em 3D;

- Cursor de Dados - insere um cursor indicativo das informações do dado selecionado no gráfico;
- legenda - insere legenda na imagem;
- impressão - permite imprimir a imagem mostrada na tela do programa;
- salvar imagem - permite salvar a imagem mostrada na tela do programa;

Gerador Relatório Pode-se dizer que uma das funcionalidade mais úteis do sistema é a capacidade que este tem de gerar um relatório (em extensão *.docx) com os dados produzidos ao final de todo o processamento, no qual incluem-se: a leitura dos sinais de DP; a filtragem; a geração do PRPD e dos demais histogramas; a caracterização dos dados; o agrupamento das características extraídas e os mapas PRPD separados por padrão com os seus respectivos pulsos médios. Ao condensar todas essas as informações em um único arquivo, este relatório facilita muito a avaliação e, conseqüentemente, o diagnóstico final do equipamento.

B.6 Interfaces do Sistema

Para compactar todas as funcionalidades do sistema em uma forma adequada para o usuário final, o programa desenvolvido conta com as três interfaces descritas a seguir.

B.6.1 Interface Principal

É na interface principal do programa que é possível carregar o dado armazenado em qualquer diretório (banco de dados). Antes de carregar uma medição, o usuário precisa definir: qual o canal do *hardware* de aquisição será avaliado, qual a taxa de amostragem de aquisição usada na medição dos dados, o número de ciclos a ser lido, o nível de *LD* (podendo optar pelo cálculo automático deste), se deseja aplicar o algoritmo de correção de polaridade e se deseja compensar a defasagem no mapa gerado em 90 °. Adicionalmente, é necessário especificar o tipo de filtragem, se será usado filtro digital e a configuração da frequência inferior e superior de corte, além da ordem deste. Também é possível optar pelo uso ou não da filtragem por caixa de *pixels*, bastando definir as dimensões da caixa.

Após carregar o dados será mostrada a quantidade de pulsos detectada e é possível “Plotar” os dados que se quer analisar, podendo escolher entre: “PRPD

Clássico”; “Histograma de Amplitude”; “Histograma de Amplitude Máxima”; “Histograma de Amplitude Média”; “Histograma de Fase”; característica “Tempo x Frequência”; característica “PCA”; característica “PCA 3D”; característica “PCA da FFT”; característica “PCA 3D da FFT”; característica “*Power Ratio*”; “Separação das Características DP” e “PRPD Separado por Cor”. Nos dois últimos casos é preciso definir, no quadro de separação de padrões de DP, qual a combinação dos métodos de extração de característica e de agrupamento de dados utilizada, podendo-se inserir manualmente o número de classes (baseado numa análise visual da característica extraída) ou selecionar a busca automática desta quantidade.

Exemplos da interface principal podem ser vistos nas Figuras B.10 e B.13.

B.6.2 Interface de Análise Pulso a Pulso

Para ter acesso à análise pulso a pulso é preciso ter plotado o gráfico “PRPD Clássico”, o gráfico “Separação das Características DP” ou o gráfico “PRPD Separado por Cor”. Em quaisquer destas imagens é possível selecionar pulso com a ferramenta “cursor de dados” e acionar a visualização em “Ver pulso selecionado”. Com isso será mostrada uma nova interface com o pulso selecionado e seu espectro de potência.

Esta funcionalidade ajuda o usuário na análise dos dados e para conferência se estes realmente referem-se a pulsos de descargas ou se são apenas sinais de ruído.

Nesta mesma interface é possível decidir se deseja salvar o pulso janelado, sendo o mesmo organizado em diretórios por tipo de equipamento e por polaridade (positivo ou negativo), conforme descrevemos na Seção B.4.4. Uma funcionalidade extremamente útil para estudos e desenvolvimentos futuros.

Exemplos da interface de análise pulso a pulso foram mostrados nas Figuras B.14 e B.15.

B.6.3 Interface de Separação

Depois de gerada a imagem de “Separação das Características DP” ou do “PRPD Separado por Cor” e acionar “Separar” é aberta a interface de separação. Nesta interface são apresentados o quadro com informações das técnicas de caracterização e separação usadas, o número de classes separadas e os mapas PRPD separados por classe, podendo ser apresentados até 10 padrões diferentes. Junto do título de cada mapa é mostrada a respectiva quantidade de pulsos. Também é mostrado o tempo

de execução necessário para realizar o processo de separação dos dados, o qual é útil para estudos comparativos entre os métodos aplicáveis.

Ademais, é possível Visualizar o pulso médio (“Pulso Centroide”) para cada PRPD gerado, o espectro de potência (“FFT Centroide”) e, por último, a RF estimada a partir dos pulsos separados (“*Max Min Hold FFT*”).

Exemplos da interface de separação podem ser vistos nas Figuras B.17, B.18, B.19 e B.20.

Apêndice C

Características Construtivas das Células de Carga

Conforme descrito na Subseção 8.1, construímos um total de 6 células de cargas no intuito de simular alguns dos tipos de DP que ocorrem em equipamentos de AT. Todas estas células possuem estrutura em bases de acrílico sustentadas por barras roscadas de plástico PVC e no centro das bases podem ser inseridos condutores de cobre, os quais servirão como terminais para receber o aterramento ou a tensão de alimentação proveniente de uma fonte de AT. Cilindros de vidro podem ser colocados entre as bases acrílicas com auxílio de anéis de vedação (*O-rings*), permitindo que sejam preenchidos com algum elemento isolante, como óleos ou gás SF₆ (usado em GIS).

Na Figura C.1 é mostrado o projeto estrutural das células, com exemplo de terminais condutores de AT e de aterramento feitos em cobre e fixados por arruelas de pressão, arruelas e roscas. Os terminais de cobre podem ser ajustados de forma a serem aproximados ou afastados, o que permite controlar a tensão de injeção em que as descargas começam a ocorrer. O terminal condutor de cobre superior (AT) possui uma furação que permite fixar extremidades com formatos diferentes, como agulha (célula C1), esfera (célula C6), espaçadores isolantes (células C2, C3 e C4), entre outros. Além disso, é possível substituir ou adaptar os terminais de acordo com o tipo de defeito que se deseja simular. Também existem entradas para injeção de gás na base de acrílico inferior, enquanto que na base superior existe uma abertura para que se possa colocar qualquer óleo isolante.

Portanto, pela maneira que as células foram projetadas, elas podem ser preenchidas com isolantes tanto no estado gasoso, quanto nos estados líquido ou sólido.

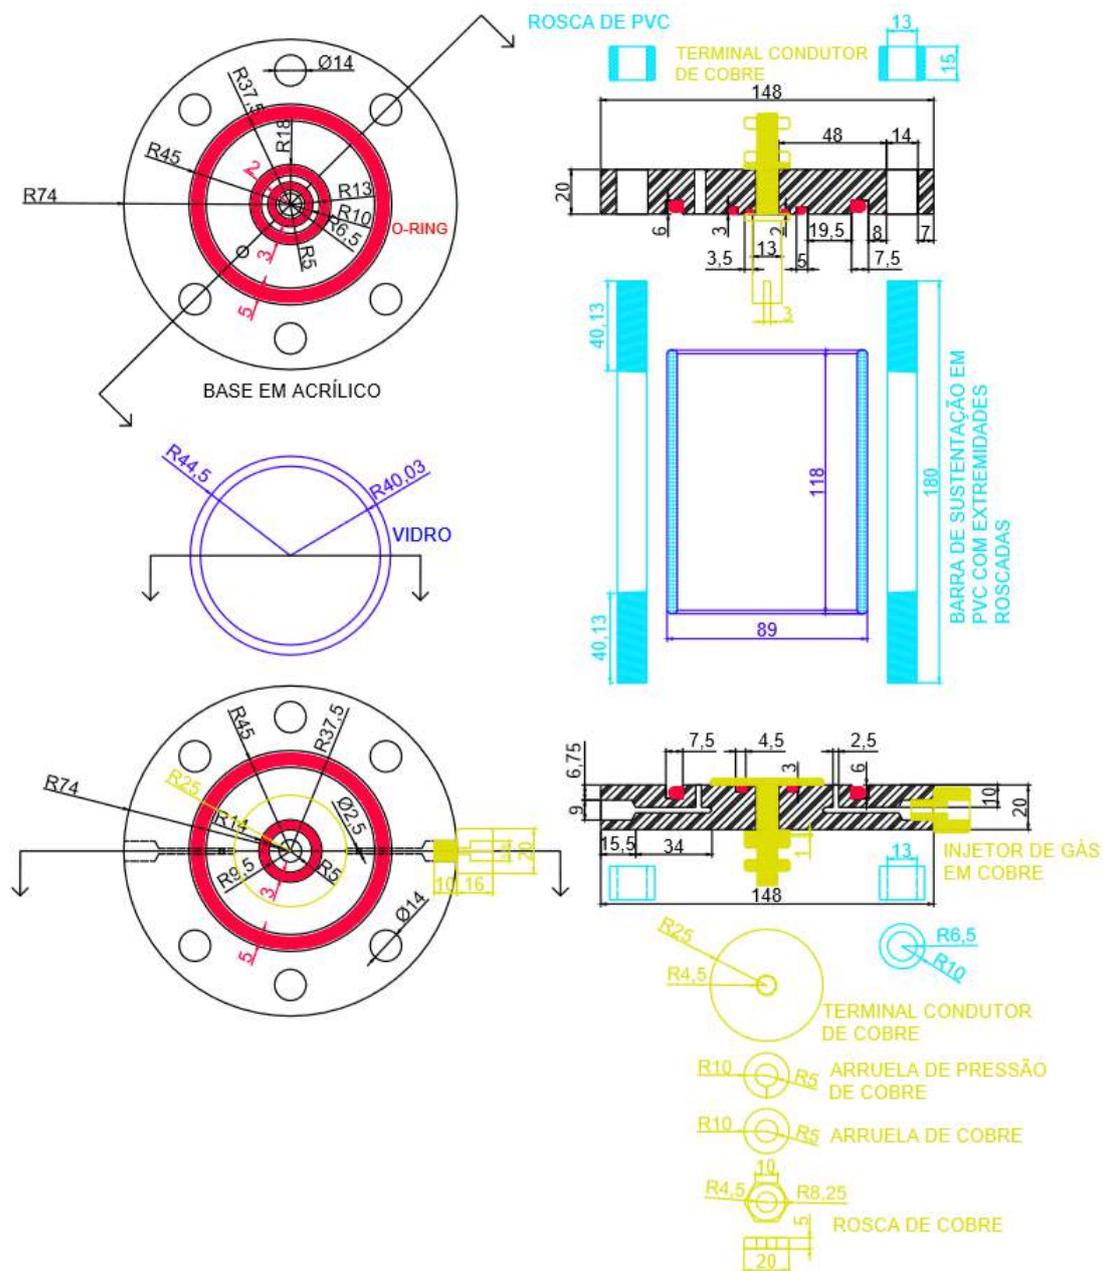


Figura C.1: Projeto estrutural padrão das células de carga.

Na Figura mostramos cada uma das células que foram utilizadas de forma a isolar os possíveis defeitos que possam ocorrer nos equipamentos de potência. Na célula da Figura C.2(a) há uma agulha de aço de 1 mm de diâmetro e curvatura de ponta de $50 \mu\text{m}$ que simula o efeito corona. A célula da Figura C.2(b) apresenta uma ponta no terminal de terra, podendo também gerar corona e simular problemas de fixação entre conectores. A célula da Figura C.2(c) possui uma ponta flutuante que pode simular descargas devido às partículas metálicas entre os terminais de alta tensão e de aterramento. Na Figura C.2(d) uma célula que simula descargas de superfície sobre uma borracha isolante (de dimensões 25.4 mm x 25.4 mm x 8 mm)

colocada entre os terminais de alta tensão e de aterramento. Na Figura C.2(e) é mostrada uma célula de ponta plana imersa em óleo isolante, que permite representar descargas envolvendo saídas de alta tensão, objeto flutuante no óleo ou mau contato entre conectores de alta tensão. Por último, a célula da Figura C.2(f), em que foi inserido um pequeno parafuso para simular uma partícula metálica livre no terminal de terra de um equipamento.

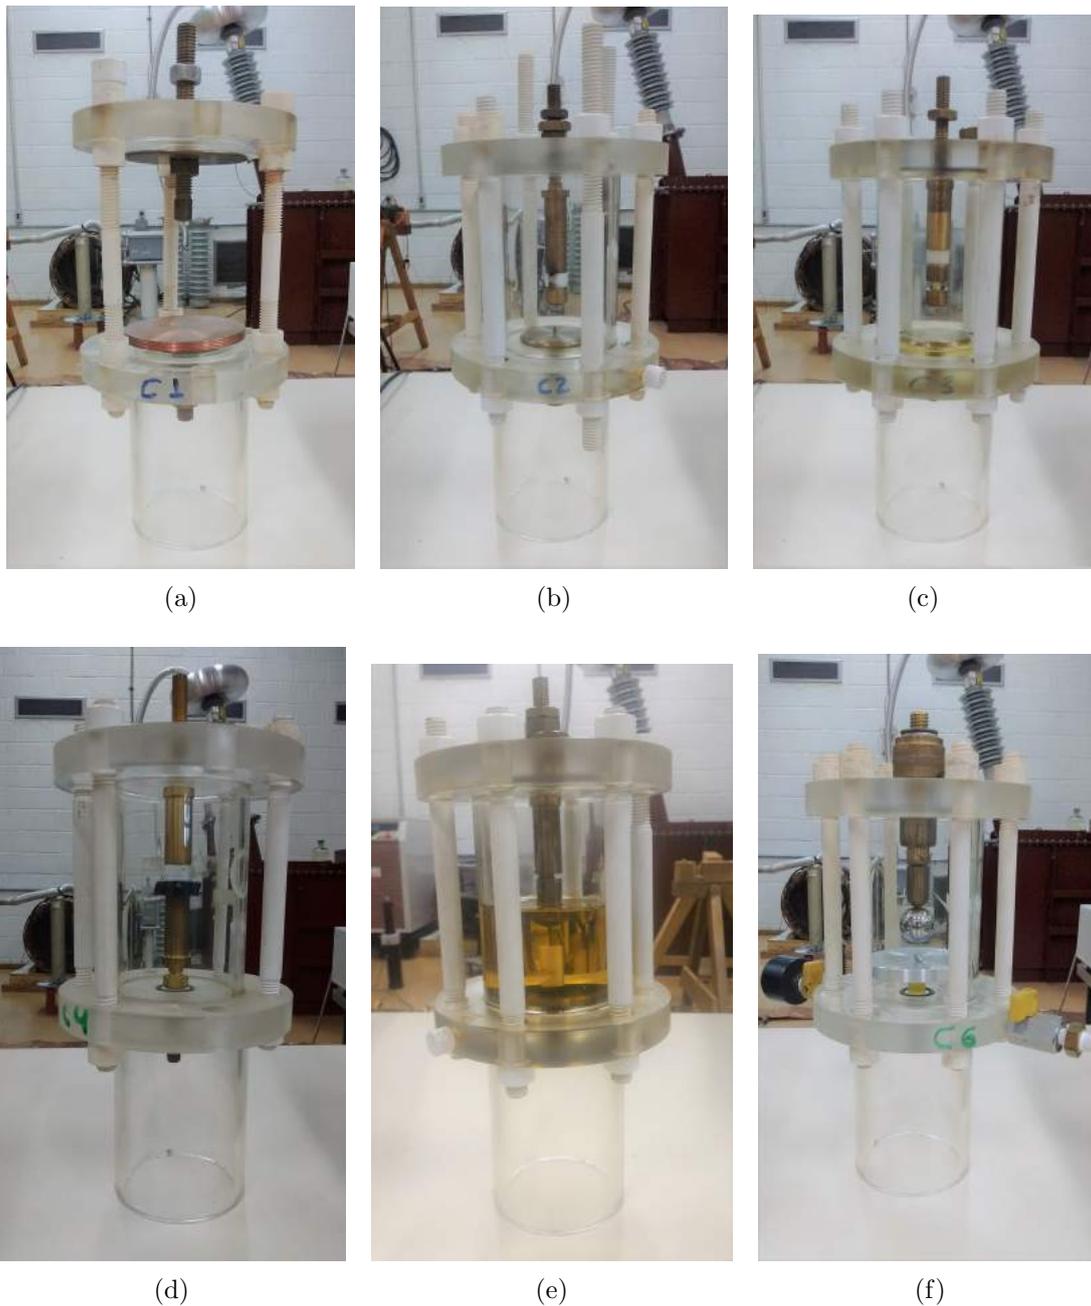


Figura C.2: Células de carga desenvolvidas para análise de defeitos ligados a DP: (a) C1; (b) C2; (c) C3; (d) C4; (e) C5; (f) C6.