



APLICAÇÃO DA TRANSFORMADA WAVELET NA REDUÇÃO DE RUÍDOS EM MEDIÇÕES DE DESCARGAS PARCIAIS

Caio Fleming Ferreira de Carvalho Cunha

Dissertação de Mestrado 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 Mestre em Engenharia Elétrica.

Orientadora: Mariane Rembold Petraglia

Rio de Janeiro
Dezembro de 2013

APLICAÇÃO DA TRANSFORMADA WAVELET NA REDUÇÃO DE RUÍDOS
EM MEDIÇÕES DE DESCARGAS PARCIAIS

Caio Fleming Ferreira de Carvalho Cunha

DISSERTAÇÃO 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 MESTRE EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. Mariane Rembold Petraglia, Ph.D.

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

Prof. Carlos Augusto Duque, D.Sc.

RIO DE JANEIRO, RJ – BRASIL
DEZEMBRO DE 2013

Cunha, Caio Fleming Ferreira de Carvalho

Aplicação da transformada wavelet na redução de ruídos em medições de descargas parciais/Caio Fleming Ferreira de Carvalho Cunha. – Rio de Janeiro: UFRJ/COPPE, 2013.

XXIII, 215 p.: il.; 29, 7cm.

Orientadora: Mariane Rembold Petraglia

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2013.

Referências Bibliográficas: p. 195 – 205.

1. Descargas Parciais.
 2. Transformada Wavelet.
 3. Otimização.
 4. Algoritmo Genético.
 5. Redução de Ruídos.
- I. Petraglia, Mariane Rembold.
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 a meus pais
Carlos Roberto da Cunha e
Rosemira Ferreira de Carvalho
Cunha e a meus amigos.*

Agradecimentos

Por meio deste trabalho, que simboliza um grande desafio em minha vida pessoal e profissional, gostaria de agradecer aos meus pais, Cunha e Rosemira, que sempre fizeram o possível para me propiciar uma boa educação, independente das dificuldades.

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

A conclusão deste mestrado não teria sido possível sem o incentivo, as discussões e os conselhos providos pelos amigos André Tomaz de Carvalho e Hélio Amorim, ambos primordiais na execução do mesmo, demonstro aqui minha gratidão.

Obrigado, também, a todos os professores da COPPE/UFRJ, que sempre me estimularam intelectualmente e com os quais tive a oportunidade de aprender muitos dos assuntos abordados neste trabalho.

Por último, porém não menos importante, agradeço muitíssimo a minha orientadora, Mariane Rembold Petraglia, quem me auxiliou no desenvolvimento e conclusão deste trabalho; e aos demais membros da banca. Declaro-me honrado pela participação no meu trabalho.

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

APLICAÇÃO DA TRANSFORMADA WAVELET NA REDUÇÃO DE RUÍDOS EM MEDIÇÕES DE DESCARGAS PARCIAIS

Caio Fleming Ferreira de Carvalho Cunha

Dezembro/2013

Orientadora: Mariane Rembold Petraglia

Programa: Engenharia Elétrica

A detecção de Descargas Parciais (DP) tem se mostrado uma eficiente ferramenta para diagnosticar a integridade do isolamento de equipamentos de alta tensão. Entretanto, a medição de tais sinais é frequentemente acompanhada de ruídos de diferentes fontes, o que pode comprometer a análise dos dados de interesse. A Transformada Wavelet tem sido aplicada no processo de filtragem destes sinais de DP fornecendo resultados superiores aos das demais técnicas de filtragem em malha aberta, devido à capacidade de prover informações relacionadas a mudanças no tempo e na frequência com diferentes resoluções.

Na literatura têm sido expostos diferentes métodos para seleção dos parâmetros que influenciam diretamente nos resultados da filtragem por Transformada Wavelet, como o número de níveis de decomposição, a função wavelet mãe, o valor de limiar, o fator de reescala deste valor e a função de limiarização aplicada na atenuação dos coeficientes. Nesta dissertação mostraremos que alguns destes métodos apresentam problemas, os quais serão evidenciados e discutidos, com base nos conceitos teóricos da Transformada Wavelet. Também serão propostas novas técnicas a fim de corrigir alguns destes problemas. Por fim, será proposto um método de otimização baseado em algoritmos genéticos para busca de todos parâmetros que influenciam o processo de filtragem por Transformada Wavelet.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

APPLICATION OF WAVELET TRANSFORM IN PARTIAL DISCHARGES
MEASUREMENTS DENOISING

Caio Fleming Ferreira de Carvalho Cunha

December/2013

Advisor: Mariane Rembold Petraglia

Department: Electrical Engineering

The detection of partial discharge (PD) signals has showed to be an efficient tool for verifying the integrity of the insulation in high voltage equipments. However, the measurement of such signals is often accompanied by noise from different sources, which might compromise the data analysis. The Wavelet Transform has been applied in the denoising process of these PD signals providing better results than other open loop filtering techniques due to the ability of providing information related to changes in time and in frequency with different resolutions.

In the literature, different methods have been proposed for selection of the parameters that influence directly the results of the denoising by Wavelet Transform, such as the number of decomposition levels, the mother wavelet function, the threshold value, the rescaling factor of this value and the thresholding function applied to the coefficients attenuation. In this dissertation we show that some of these methods present problems, which will become apparent and discussed. Based on the theoretical concepts of Wavelet Transform, new techniques are also proposed in order to correct some of these problems. Finally an optimization method based on genetic algorithms is proposed to search for all parameters that influence the filtering process by Wavelet Transform.

Sumário

Lista de Figuras	xiii
Lista de Tabelas	xix
Lista de Abreviaturas	xx
1 Introdução	1
1.1 Considerações Iniciais e Justificativas	1
1.2 Objetivos	3
1.3 Metodologia de Pesquisa	3
1.4 Estrutura da Dissertação	5
2 Descargas Parciais	7
2.1 Definição	7
2.2 Condições para Ocorrência de DP	8
2.3 Tipos de Descargas Parciais	9
2.3.1 Descargas Externas	9
2.3.2 Descargas Superficiais	10
2.3.3 Descargas Internas	10
2.4 Modelos para Descrição de DP	12
2.4.1 Modelo a-b-c	12
2.4.2 Modelo Qualitativo Baseado na Aproximação por Campo	13
2.5 Grandezas Derivadas e Relacionadas aos Pulsos de DP	15
2.5.1 Grandezas Derivadas dos Pulsos de DP	15
2.5.2 Grandezas Relacionadas à Tensão de Teste de DP	17
2.6 Calibração do Sistema de Medição	17
2.6.1 Principais Características dos Sinais de DP	19
2.7 Processamento Digital de Sinais de DP	21
2.7.1 Visualização das Informações de DP	22
2.8 Interferências em Medições de DP	24

3	Transformada Wavelet e sua Aplicação na Filtragem de Sinais de Descargas Parciais	28
3.1	Transformada Discreta de Fourier	28
3.1.1	Teorema de Parseval	31
3.1.2	Limitações da DFT com Sinais de DP	31
3.2	Transformada de Fourier de Tempo Curto	32
3.2.1	Limitações da STFT com Sinais de DP	33
3.3	Banco de Filtros	33
3.3.1	Subamostragem	34
3.3.2	Sobreamostragem	35
3.3.3	Bancos de Filtros de Reconstrução Perfeita de Dois Canais	35
3.3.4	Banco de Filtros QMF	38
3.4	Transformada Wavelet	40
3.4.1	Transformada Wavelet Contínua no Tempo	40
3.4.2	Amostragem Diádica da CWT	43
3.4.3	Análise Multirresolução	45
3.4.4	Transformada Wavelet Discreta e Banco de Filtros	51
3.4.5	Definição dos Filtros de Síntese e de Análise	54
3.4.6	Relação entre Filtros e Wavelet	55
3.4.7	Requerimentos para Encontrar os Coeficientes	56
3.4.8	Regularidade	57
3.4.9	Número de Momentos Nulos	58
3.4.10	Famílias Wavelet	59
3.5	Procedimento Wavelet de Filtragem Aplicado a Sinais de DP	60
3.5.1	Etapas da Filtragem Wavelet	61
3.5.2	Escolha da Transformada	65
3.5.3	Escolha do Número de Níveis de Decomposição	66
3.5.4	Seleção da Wavelet Mãe	68
3.5.5	Processo de Limiarização	69
4	Algoritmos Genéticos	79
4.1	Inspiração para Algoritmos Genéticos	79
4.2	Algoritmos Evolucionários	80
4.3	Componentes de um AE	82
4.4	Representação dos Indivíduos	82
4.5	Função de Aptidão	83
4.6	População	84
4.7	Seleção dos Pais	85
4.7.1	Seleção por Ranqueamento	85

4.7.2	Algoritmo de Seleção por Roleta (<i>Roulette Wheel</i>)	86
4.8	Recombinação	87
4.8.1	Recombinação para Representações Binárias	87
4.8.2	Recombinação para Representações Inteiras	88
4.8.3	Recombinação para Representações Reais ou Ponto Flutuante	88
4.9	Mutação	90
4.9.1	Mutação para Representações Binárias	91
4.9.2	Mutação para Representações Inteiras	91
4.9.3	Mutação para Representações Reais ou Ponto Flutuante	91
4.10	Seleção dos Sobreviventes	92
4.10.1	Substituição Baseada na Idade	92
4.10.2	Substituição Baseada na Aptidão	93
4.11	Inicialização	93
4.12	Condição de Terminação	94
4.13	Operação de um Algoritmo Genético	94
4.14	Hibridização: Algoritmos Meméticos	95

5 Método de Seleção da Wavelet Mãe Baseado na Relação Sinal

	Ruído e Método de Redução de Ruídos por Algoritmo Genético	99
5.1	Parâmetros de Avaliação de Filtragem	99
5.1.1	Erro Médio Absoluto	100
5.1.2	Erro Quadrático Médio	100
5.1.3	Raiz Quadrada do Erro Quadrático Médio	101
5.1.4	Coefficiente de Correlação	102
5.1.5	Diferença de Energia	103
5.1.6	Razão Sinal Ruído	103
5.1.7	Nível de Redução de Ruído	104
5.1.8	Erro de Amplitude	104
5.1.9	Coefficiente de Preservação de Informações	104
5.1.10	Variação do Tempo de Pico	105
5.1.11	Variação do Tempo de Subida	106
5.1.12	Diferença de Curtose	106
5.1.13	Tempo de processamento	107
5.2	Seleção do Número de Níveis Baseado no Espectro de Frequência	108
5.3	Métodos de Seleção da Wavelet Mãe	110
5.3.1	Método de Seleção da Wavelet Baseada na Correlação (CBWS)	111
5.3.2	Método de Seleção da Wavelet Baseada na Energia (EBWS)	114
5.3.3	Método de Seleção da Wavelet Baseada na Relação Sinal Ruído (SNRBWS)	117

5.3.4	Método Modificado de Seleção da Wavelet Baseada na Energia (MEBWS)	119
5.4	Otimização da Filtragem Wavelet Baseada em Algoritmos Genéticos	121
5.4.1	Função Custo para o Problema de Filtragem Wavelet	121
5.4.2	Considerações da Função Custo	124
5.4.3	Representação	126
5.4.4	Inicialização	127
5.4.5	Seleção dos Pais	128
5.4.6	Recombinação	128
5.4.7	Mutação	129
5.4.8	Seleção dos Sobreviventes	130
5.4.9	Condição de Terminação	131
5.4.10	Algoritmo de Busca	132
6	Comparação e Análise do Resultados	134
6.1	Sinais de DP Simulados	134
6.2	Ruídos Adicionados	137
6.3	Sinais de DP Medidos	141
6.4	Definição de Pesos para Função Custo	141
6.5	Comparação entre Métodos	145
6.5.1	Distribuição de Energia	148
6.6	Resultados e Discussões	163
6.6.1	Resultados Percentuais e Médios	174
6.6.2	Resultados de Tempo de Execução	180
6.6.3	Resultados dos Parâmetros de Limiarização	182
6.6.4	Avaliação do Algoritmo PSBLS com a Função de Aptidão	185
7	Conclusões e Sugestões	189
7.1	Sugestões	193
	Referências Bibliográficas	195
A	Circuitos de Medição de DP	206
A.1	Capacitor de Acoplamento e Impedância de Medição	208
A.2	Circuito para Medição de Transformadores	210
A.3	Circuito para Medição de Subestações Isoladas a Gás (GIS)	211
A.4	Circuito para medição de Transformadores de Corrente, Transformadores de Potência (TP) e Pararraio	212
A.5	Sistemas de Medição de DP	212
A.6	Instrumentos de Banda Larga	213

A.7 Instrumentos de Banda Estreita	214
A.8 Instrumentos de Banda Ultra Larga	215

Lista de Figuras

2.1	Descargas externas: (a) modelo; (b) real. Fonte: [13]	9
2.2	Descarga superficial.	10
2.3	Fotos de Descargas Internas:(a) DP guia em óleo; (b) arboreamento. Fonte: [13]	11
2.4	Modelo a-b-c.	12
2.5	Comportamento do modelo a-b-c.	13
2.6	Comportamento do modelo qualitativo de aproximação por campo: a onda senoidal representa a tensão aplicada, enquanto que a onda serrada representa o campo na cavidade. Quando ocorre a descarga o campo é reduzido (aproximadamente zero). Como a tensão muda após a descarga, o campo na cavidade muda de zero em proporção à mudança na tensão aplicada.	14
2.7	Circuito para calibração do objeto em teste C_a .	18
2.8	Circuito de medição.	18
2.9	Parâmetros de pulsos de DP: (a) DE; (b) DOE.	20
2.10	Circuito de processamento digital de Banda Ultra Larga (Ultra Wide Band - UWB).	21
2.11	Mapa PRPD Bipolar em: (a) 2D; (b)3D.	23
2.12	Diagrama 3PARD.	24
2.13	Diagrama 3PTRD para três pulsos de DP na Fase 1. Fonte: [35]	24
2.14	Diagrama 3CFRD.	25
2.15	Ruído Branco: (a) sinal; (b) histograma.	26
3.1	Células de resolução no plano tempo/frequência.	32
3.2	Decimação por um fator M .	34
3.3	Operação de decimação por um fator M , com filtro decimador.	34
3.4	Interpolação por um fator L .	35
3.5	Operação de interpolação por um fator L , com filtro interpolador.	35
3.6	Banco de filtros de dois canais.	36

3.7	Exemplo de função wavelet: (a) no domínio do tempo; (b) no domínio da frequência.	42
3.8	Células de resolução tempo x frequência para WT.	43
3.9	Amostragem diádica da WT.	44
3.10	Representação geométrica dos espaços multirresolução.	47
3.11	Árvore de análise wavelet formada por J estágios de dois canais. . .	52
3.12	Divisão do espectro de frequência da árvore de análise wavelet. . . .	53
3.13	Árvore de síntese wavelet formada por J estágios de dois canais. . .	54
3.14	Exemplo de wavelets Daubechies com diferentes regularidades: (a) regularidade = 0.91 (<i>db3</i>); (b) regularidade = 2.15 (<i>db7</i>).	58
3.15	Processo de remoção de ruídos pela transformada wavelet.	62
3.16	Sinal de pulso de DP com ruído branco.	62
3.17	Processo de filtragem wavelet em 3 níveis de um sinal DP.	63
3.18	Resposta ao impulso dos filtros de análise e síntese gerados pela wavelet Symlet de ordem 6 (<i>sym6</i>).	63
3.19	Coeficientes de aproximação final e coeficientes de detalhe gerados na decomposição do sinal de DP com o uso da wavelet Symlet de ordem 6 (<i>sym6</i>).	64
3.20	Coeficientes de detalhe gerados após o processo de limiarização. . . .	64
3.21	Resposta ao impulso dos filtros de análise e síntese gerados pela wavelet Symlet de ordem 6 (<i>sym6</i>).	65
3.22	Comparação dos resultados de filtragem de um pulso de DP para diferentes níveis de decomposição.	67
3.23	Função de limiarização: (a) suave ;(b) abrupta.	75
3.24	Função de limiarização Garrote.	75
3.25	Função de limiarização Nasiri.	76
3.26	Função de limiarização: (a) Zhang ₁ ;(b) Zhang ₂	77
4.1	Diagrama de fluxo de um AE.	81
4.2	Pseudocódigo para RWS.	87
4.3	Cruzamento de um ponto.	87
4.4	Cruzamento multiponto para $n = 3$	88
4.5	Cruzamento uniforme.	88
4.6	Recombinação simples para $k = 3$ e $\alpha = 1/2$	89
4.7	Recombinação aritmética única para $k = 4$ e $\alpha = 1/4$	90
4.8	Recombinação aritmética completa para $\alpha = 3/4$	90
4.9	Evolução de um AG quanto a distribuição da população.	95
4.10	Progresso no tempo de um AG para seu indivíduo mais apto.	95
4.11	Comparação das curvas de performance.	96

4.12	Associação da ideia de: (a) meme; (b)gene.	96
4.13	Possíveis locais para inserção de conhecimentos em um AG.	97
5.1	Comparação da diferença de curtose Dk para diferentes regras de seleção de limiar.	107
5.2	Divisão do espectro em bandas.	108
5.3	Algoritmo PSBLS.	109
5.4	Exemplo do procedimento de seleção do número de níveis de decom- posição: (a) Sinal de DP; (b) Espectro de potência do sinal.	110
5.5	Exemplo do procedimento CBWS: (a) pulso de DP e wavelet selecio- nados; (b) pulso de DP normalizado e wavelet reamostrada e norma- lizada; (c) pulso de DP reamostrado para igualar seu cruzamento por zero com o da wavelet; (d) wavelet preenchida com zeros e deslocada.	113
5.6	Gráfico Wavelet x Coeficiente de Correlação para o pulso DOE ana- lisado.	114
5.7	Gráfico de energia dos coeficientes de aproximação por nível para cada wavelet.	116
5.8	Distribuição de energia para os métodos EBWS e CBWS.	116
5.9	(a) Pulso de DP estimado; (b) Espectro de frequência com divisão das bandas de decomposição.	118
5.10	Distribuição de energia para os métodos EBWS, CBWS e SNRBWS.	120
5.11	Pseudocódigo da heurística incorporada ao AG.	130
5.12	Pseudocódigo da preservação elitista incorporada ao AG.	131
6.1	Sinais de DP simulados: (a) S_{PD1} ; (b) S_{PD2}	135
6.2	Sinais de DP simulados: (a) S_{PD3a} ; (b) S_{PD3b}	136
6.3	Sinais de DP simulados: (a) S_{PD4a} ; (b) S_{PD4b}	137
6.4	Sinais de DP simulados somados a um ruído branco de $SNR = 3$: (a) uniforme; (b) Gaussiano;	138
6.5	Ruído de espectro discreto: (a) ruído simulado; (b) FFT do ruído;	139
6.6	Sinal de DP S_{PD1} somado a um ruído AM.	139
6.7	Pseudocódigo para calculo do fator de ajuste ε para determinar o peso do parâmetro EQM.	145
6.8	Sinal de DP S_{23} : (a) sinal adquirido; (b) sinal filtrado com wavelet $db5$; (c) sinal estimado.	146
6.9	Energia dos coeficientes de aproximação por nível para cada wavelet: (a) permitindo a seleção da função $db1$; (b) excluindo $db1$ da seleção.	158
6.10	Resultados de filtragem do algoritmo EBWS: (a) permitindo a seleção da função $db1$; (b) excluindo $db1$ da seleção.	159

6.11	Resultado de redução de ruídos para S_{38} : formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.	160
6.12	Resultado de redução de ruídos para S_{57} : formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.	161
6.13	Resultado de redução de ruídos para $S_{63} + ng_{SNR=1}$: formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.	161
6.14	Resultado de redução de ruídos para $S_{71} + ng_{SNR=4}$: formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.	162
6.15	Resultado de redução de ruídos para $S_{3,SNR=4}$: formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.	162
6.16	Resultado de redução de ruídos para $S_{26,SNR=4}$: formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.	163
6.17	Resultado de redução de ruídos para $S_{48,SNR=4}$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.	164
6.18	Resultado de redução de ruídos para $S_{49,SNR=4}$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.	164
6.19	Resultado de redução de ruídos para $S_{52,SNR=4}$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.	165

6.20	Resultado de redução de ruídos para $S_{59,SNR=4}$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.	165
6.21	Resultado de redução de ruídos para $S_{71,SNR=4}$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.	166
6.22	Resultado de redução de ruídos para $S_{3,SNR=0,5}$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.	166
6.23	Resultado de redução de ruídos para $S_{7,SNR=0,5}$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.	167
6.24	Resultado de redução de ruídos para $S_{9,SNR=0,5}$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.	167
6.25	Comparação da função de aptidão para os pulsos de DP utilizando os métodos EBWS e CBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.	174
6.26	Comparação dos resultados das filtragens dos pulsos de DP utilizando os métodos EBWS e CBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.	175
6.27	Comparação da função de aptidão para os pulsos de DP utilizando os métodos SNRBWS e MEBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.	176
6.28	Comparação dos resultados das filtragens dos pulsos de DP utilizando os métodos SNRBWS e MEBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.	176
6.29	Comparação da função de aptidão para os pulsos de DP utilizando os métodos CBWS, EBWS, SNRBWS e MEBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.	177
6.30	Comparação dos resultados das filtragens dos pulsos de DP utilizando os métodos CBWS, EBWS, SNRBWS e MEBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.	178
6.31	Comparação da função de aptidão para os pulsos de DP utilizando os métodos CBWS, EBWS, SNRBWS, MEBWS e AG. O percentual indica o número de casos em que cada método obteve melhor resultado.	179
6.32	Comparação dos resultados das filtragens dos pulsos de DP utilizando os métodos CBWS, EBWS, SNRBWS e MEBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.	179

6.33	Comparação do tempo de processamento entre os métodos CBWS, EBWS, SNRBWS e MEBWS: (a) tempo de processamento; (b) tempo de processamento normalizado.	181
6.34	Comparação do tempo de processamento entre os métodos CBWS, EBWS, SNRBWS, MEBWS e AG: (a) tempo de processamento; (b) tempo de processamento normalizado.	181
6.35	Comparação dos melhores parâmetros de filtragem. O percentual indica o número de casos em que cada combinação de parâmetros aplicados na filtragem wavelet forneceu o maior valor de aptidão. . . .	183
6.36	Comparação dos melhores parâmetros de filtragem para cada método de seleção da wavelet e para o método AG. O percentual indica o número de casos em que cada combinação de parâmetros aplicados na filtragem wavelet forneceu o maior valor de aptidão.	184
6.37	Valor de aptidão em cada nível de decomposição: (a) sinal S_{38} ; (b) sinal S_{48} ; (c) sinal S_{57} ; (d) sinal S_{71} ; (e) sinal S_{74} ; (f) sinal $S_{10, SNR=4}$.	186
A.1	Circuito de medição de DP com impedância de medição Z_m em série com capacitor de acoplamento C_k	207
A.2	Circuito de medição DP com impedância de medição Z_m em série com o objeto de teste C_a	207
A.3	Circuito de medição de DP de ponte balanceada.	208
A.4	Circuito equivalente de acoplamento para medição de DP.	209
A.5	Circuito de medição de DP para transformadores.	210
A.6	Circuito de medição DP para GIS.	211
A.7	Tipos de sensores (capacitores de acoplamento C_k) aplicados na medição de DP em GIS.	211
A.8	Medição de DP em TC utilizando um transformador de corrente de alta frequência.	212
A.9	Princípio de quasi-integração de pulsos DP.	213

Lista de Tabelas

6.1	Parâmetros do pulso de DP mostrados na Fig. 6.2	136
6.2	Parâmetros do pulso de DP mostrados na Fig. 6.3.	137
6.3	Sinais de DP simulados com adição de ruído.	140
6.4	Sinais de DP medidos.	142
6.5	Valores de ajuste calculados para cada Sinal de DP.	144
6.6	Wavelet selecionada para obter o sinal de referência.	147
6.7	Wavelet selecionada em cada método para os sinais de DP simulados.	149
6.8	Wavelet selecionada em cada método para os sinais de DP medidos.	150
6.9	Wavelet selecionada em cada método para os sinais de DP medidos.	151
6.10	Wavelet selecionada em cada método para os sinais de DP medidos.	152
6.11	Wavelet selecionada em cada método para os sinais de DP medidos.	153
6.12	Wavelet selecionada em cada método para os sinais de DP medidos.	154
6.13	Porcentagem de energia dos coeficientes de aproximação e detalhe para cada método.	156
6.14	Porcentagem de energia dos coeficientes de aproximação e detalhe para cada método.	157
6.15	Comparação do EBWS e EBWS alterado.	158
6.16	Resultados de filtragem.	169
6.17	Resultados de filtragem.	170
6.18	Resultados de filtragem.	171
6.19	Resultados de filtragem.	172
6.20	Resultados de filtragem.	173
6.21	Valores médios dos parâmetros obtidos com cada algoritmo.	180
6.22	Contagem de melhores resultados para cada parâmetro de filtragem.	182
6.23	Contagem de melhores resultados isoladamente para cada parâmetro de filtragem.	184
6.24	Evolução da função custo por nível de decomposição.	187
6.25	Evolução da função custo por nível de decomposição.	188

Lista de Abreviaturas

DP	Descargas Parciais, p. 1
FFT	Fast Fourier Transform - Transformada de Fourier Rápida, p. 2
STFT	Short-Time Fourier Transform - Transformada de Fourier de Tempo Curto, p. 2
WVD	Wigner-Ville Distribution - Distribuição de Wigner-Ville, p. 2
WT	Wavelet Transform - Transformada Wavelet, p. 2
AG	Algoritmo Genético, p. 2
PSBLS	Power Spectrum Based Level Selection - Seleção de Nível Baseado na Densidade Espectral de Energia, p. 5
SNRBWS	Signal to Noise Ratio Based Wavelet Selection - Seleção Wavelet Baseada na Razão Sinal Ruído, p. 5
GIS	Gas Insulated Switchgear - Subestação Isolada a Gás, p. 11
AC	Alternated Current - Corrente Alternada, p. 12
DE	Damping Exponential - Exponencialmente Amortecida, p. 19
DOE	Damping Oscillatory Exponential - Oscilatório Exponencialmente Amortecida, p. 19
UWB	Ultra Wide Band - Banda Ultra Larga, p. 30
PRPD	Phase Resolved Partial Discharge - Descargas Parciais Discriminados por Fase, p. 21
3PARAD	3 Phase Amplitude Relation Diagram - Diagrama de Relação de Amplitude em 3 Fases, p. 22

3PTRD	3 Phase Time Relation Diagram - Diagrama de Relação de Tempo em 3 Fases, p. 23
3CFRD	3 Center Frequency Relation Diagram - Diagrama de Relação de Frequência em 3 Canais, p. 24
EMI	Eletromagnetic Interferences - Interferências Eletromagnéticas, p. 24
DSI	Discrete Spectrum Interferences - Interferências de Espectro Discreto, p. 25
FM	Frequência Modulada, p. 25
AM	Amplitude Modulada, p. 25
DFT	Discrete Fourier Transform - Transformada de Fourier Discreta, p. 28
DWT	Discrete Wavelet Transform - Transformada Wavelet Discreta, p. 28
FT	Fourier Transform - Transformada de Fourier, p. 29
IFT	Inverse Fourier Transform - Transformada de Fourier Inversa, p. 29
IDFT	Inverse Discrete Fourier Transform - Transformada de Fourier Inversa Discreta, p. 30
WDFT	Windowed Discrete Fourier Transform - Transformada de Fourier Inversa em Janela, p. 33
FIR	Finite Impulse Response - Resposta ao impulso Finita, p. 37
QMF	Quadrature Mirror Filter - Filtro com Espelhamento em Quadratura, p. 38
CWT	Continuous Wavelet Transform - Transformada Wavelet Contínua, p. 41
ICWT	Inverse Continuous Wavelet Transform - Transformada Wavelet Contínua Inversa, p. 41
WPT	Wavelet Packet Transform - Transformada Wavelet em Pacotes, p. 65

SWT	Stationary Wavelet Transform - Transformada Wavelet Estacionária, p. 65
DTCWT	Dual-Tree Complex Wavelet Transform - Transformada Wavelet Complexa de Árvore Dupla, p. 65
SGWT	Second Generation Wavelet Transform - Transformada Wavelet de Segunda Geração, p. 65
CBWS	Correlation Based Wavelet Selection - Seleção da Wavelet Baseada na Correlação, p. 69
EBWS	Energy Based Wavelet Selection - Seleção da Wavelet Baseada na Energia, p. 69
EQM	Erro Quadrático Médio, p. 70
SURE	Stein Unbiased Risk Error, p. 72
LMS	Least Mean Square - Mínima Média Quadrática, p. 72
MA	Memetic Algorithm - Algoritmo Memético, p. 79
AE	Algoritmo Evolucionário, p. 79
RWS	Roulette Wheel Selection - Seleção por Roleta, p. 85
CPU	Center Unit Processement - Unidade Central de Processamento, p. 94
SA	Simulated Annealing - Recozimento Simulado, p. 98
EMA	Erro Médio Absoluto, p. 100
REQM	Raíz do Erro Quadrático Médio, p. 101
CC	Coefficiente de Correlação, p. 102
NCC	Coefficiente de Correlação Normalizado, p. 102
DEn	Diferença de Energia, p. 103
SNR	Signal to Noise Ratio - Razão Sinal Ruído, p. 103
NRR	Nível de Redução de Ruído, p. 104
EA	Erro de Amplitude, p. 104
CPI	Coefficiente de Preservação de Informações, p. 105

VTP	Variação do Tempo de Pico, p. 105
VTs	Variação do Tempo de Subida, p. 106
Dk	Diferença de Curtose, p. 106
TPr	Tempo de Processamento, p. 107
MEBWS	Modified Energy Based Wavelet Selection - Seleção Modificada da Wavelet Baseada na Energia, p. 119
DSNR	Difference of Signal to Noise Ratio - Diferença da Razão Sinal Ruído, p. 122
CEPEL	Centro de Pesquisas de Energia Elétrica, p. 141
TC	Transformador de Corrente, p. 141
PR	Pararraio, p. 141
UHF	Ultra High Frequency - Frequência Ultra Alta, p. 211
TP	Transformador de Potência, p. 212

Capítulo 1

Introdução

1.1 Considerações Iniciais e Justificativas

No setor elétrico, com o crescimento dos grupos consumidores, se torna essencial dispor de um sistema elétrico com equipamentos capazes de suprir essa demanda de forma confiável. Para tanto, se faz necessário aplicar técnicas voltadas para o monitoramento, a manutenção e o diagnóstico preditivo dos equipamentos de alta tensão para melhorar sua performance e estender sua vida útil, contribuindo para a qualidade no fornecimento de energia e redução das faltas no sistema.

Uma variedade de problemas como falhas no processo de fabricação, desgaste térmico, ataque químico, além do envelhecimento natural do equipamento podem levar a falhas no isolamento, muitas das vezes irreversíveis, gerando grandes prejuízos tanto para os fornecedores quanto para os consumidores de energia.

Surge, portanto, a necessidade por uma técnica que contemple o monitoramento e a avaliação da degradação do isolamento dos equipamentos de alta tensão, permitindo tomar as decisões necessárias para evitar as falhas. A medição de Descargas Parciais (DP) é uma técnica eficaz, amplamente difundida e aceita pela sociedade científica para monitorar a degradação dos sistemas isolantes de equipamentos de alta tensão.

DP é uma descarga elétrica que ocorre numa parte do isolamento entre dois eletrodos, sem curto circuitar completamente os mesmos. DP podem se propagar no isolamento até que este seja tão enfraquecido que falhe completamente, causando um curto circuito com perda permanente do equipamento. Tais descargas podem ser detectadas e quantificadas eletricamente por meio de sensores instalados junto ao equipamento que se deseja monitorar. As medições de DP podem ser realizadas tanto

em campo quanto em laboratório; entretanto, em ambos casos existe a presença de ruídos no sinal adquirido, os quais muitas das vezes podem se sobrepor aos sinais de DP, limitando a precisão do diagnóstico de tais medições, podendo induzir a erros em sua análise. Com respeito a isso, a redução de ruídos é um passo crítico para detecção de DP.

Muitas técnicas de redução de ruídos têm sido empregadas [1, 2], dentre elas a Transformada Rápida de Fourier (*Fast Fourier Transform* - FFT), a Transformada de Fourier de Tempo Curto (*Short-Time Fourier Transform* - STFT), a Distribuição de Wigner-Ville (*Wigner-Ville Distribution* - WVD), os filtros notch, os filtros adaptativos [3–5] e os métodos baseados em Transformada Wavelet (*Wavelet Transform* - WT). As filtragens por WT têm sido aplicadas com maior frequência na extração de ruído branco e de espectro discreto, enquanto que na extração de ruídos pulsantes é preferível o uso de redes neurais ou um suporte de vetor de máquinas [6].

Uma das principais vantagens da WT é sua capacidade de prover informações relacionadas a mudanças no tempo e na frequência com diferentes resoluções [7], permitindo que ambas a característica global e os detalhes do sinal possam ser simultaneamente estudados [8], fato desejável na análise de sinais de DP.

A filtragem por WT apresenta parâmetros importantes que influenciam diretamente no resultado da redução de ruídos, como o número de níveis de decomposição, a função wavelet mãe, o valor de limiar, o fator de reescala deste valor e a função de limiarização aplicada na atenuação dos coeficientes. Muitos estudos têm focado na busca por métodos capazes de encontrar tais parâmetros para que forneçam o melhor resultado possível na filtragem dos sinais de DP.

Inicialmente apresentaremos um novo método para busca do número de níveis de decomposição e para busca da wavelet mãe, tentando suprir algumas das deficiências encontradas em outros métodos apresentados na literatura, com o objetivo de melhorar as medições de DP.

Pode-se tratar a filtragem por WT como um problema de otimização multi-variável. A otimização consiste basicamente em tentar várias soluções e utilizar as informações obtidas neste processo de forma a encontrar soluções cada vez melhores.

Aplicamos uma técnica de Algoritmo Genético (AG) para busca dos parâmetros utilizados no processo de filtragem. Tal método é aplicado na literatura em muitos problemas de otimização, sendo que recebe este nome por ser inspirado nos mecanismos de evolução de populações dos seres vivos. Esse algoritmo segue o princípio da seleção natural e sobrevivência do mais apto, declarado em 1859 por Charles Darwin em seu livro *A Origem das Espécies*.

Expomos no trabalho que o método PSBLS apesar de nem sempre fornecer o nível ótimo se mostrou uma alternativa mais atrativa em comparação as demais metodologias de seleção do número de níveis descritas na literatura. O SNRBWS obteve a melhor performance de filtragem em um menor tempo de processamento (importante para uma possível aplicação de medição em tempo real), mostrando que a ideia de concentrar o máximo valor absoluto dos coeficientes forneceu melhores resultados comparados aos demais métodos de seleção da WM. Com o uso do método AG foram obtidos os melhores resultados de filtragem dos sinais analisados. Ambos métodos apresentados contribuem para aprimorar o conhecimento existente na literatura a respeito da redução de ruídos de sinais de DP, o que nos permitiu levantar algumas propostas para desenvolvimentos futuros.

O trabalho nos possibilitou a publicação de um artigo na Conferência Internacional de Dielétricos Sólidos em Bolonha (*Internacional Conference of Solid Dielectrics in Bologna*) [9].

1.2 Objetivos

O objetivo desta dissertação é realizar o tratamento de sinais de Descargas Parciais, utilizando a técnica de processamento por Transformada Wavelet na redução de ruídos que acometem tais sinais, de modo a obter uma melhor qualidade na medição dos mesmos, possibilitando uma melhora na análise e diagnóstico do isolamento de equipamentos de alta tensão que compõem um sistema elétrico, o que proverá um acréscimo na qualidade do fornecimento de energia deste sistema.

Este estudo visa também aprimorar os métodos até então aplicados na literatura para definição dos parâmetros necessários na filtragem dos sinais de DP por meio da WT. Por fim, propomos um único método para busca de todos estes parâmetros de forma otimizada.

1.3 Metodologia de Pesquisa

Este trabalho se iniciou com a análise da literatura técnica voltada para o uso da Transformada Wavelet na filtragem de ruídos presentes em sinais de Descargas Parciais aquisitados de equipamentos de alta tensão por meio do método elétrico.

Com a análise dos métodos discutidos nessa literatura, devido à complexidade da aplicação da WT, constatou-se a existência de uma vasta área ainda por ser

explorada, pois muitas destas aplicam soluções de forma isolada tentando otimizar apenas um dos parâmetros que envolvem a filtragem por WT, sem apresentar uma solução ótima que englobe todo os parâmetros necessários a essa aplicação. Também foram constatadas dificuldades na aplicação de alguns métodos apresentados nessas publicações:

1. Definição do número de níveis não segue um critério adequado, sendo muitas vezes feita de forma aleatória, pelo uso do número máximo de níveis possível, o que acarreta desperdício de processamento sem garantias de obtenção de um bom resultado ou por uma busca incessante do melhor resultado, baseando-se em um único critério de avaliação;
2. O método de seleção da wavelet mãe baseado na correlação, é um método dispendioso no que diz respeito a sua programação e tempo de processamento;
3. O método de seleção da wavelet mãe baseado na concentração de energia seleciona a transformada cujos coeficientes de aproximação gerados a cada nível de decomposição apresentam a maior energia; entretanto, nem sempre este é um critério apropriado;
4. O uso de diferentes critérios usados para avaliação dos métodos de remoção de ruído propostos na literatura dificulta a comparação dos resultados;
5. A escolha da melhor função de limiarização a ser aplicada na filtragem de sinais de DP não é adequada, já que algumas publicações defendem o uso da função abrupta (*hard thresholding*) enquanto outras aplicam a função suave (*soft thresholding*);

O passo seguinte foi uma análise bibliográfica mais criteriosa, com a eleição de fontes de interesse com dados relevantes sobre a teoria de Transformada Wavelet e suas aplicações em remoção de ruídos além da análise bibliográfica de técnicas de otimização envolvendo, principalmente, Algoritmos Genéticos. Com base nos estudos bibliográficos foi possível levantar propostas para o desenvolvimento de novos métodos, de forma a tentar suprir as dificuldades e equívocos encontrados na literatura técnica.

1. Realizar a seleção do número de níveis decomposição através do cálculo da Densidade Espectral de Energia do sinal de DP, de forma a identificar as componentes de frequência mais relevantes para formação do sinal de DP e determinar o número de níveis necessário para prover uma boa representação destas frequências;
2. Estabelecer um novo método de seleção da wavelet mãe, tentando distribuir a

energia do sinal nos coeficientes de maior importância para formação do sinal de DP, sejam estes de aproximação ou de detalhe;

3. Realizar a análise dos resultados de filtragem com um número maior de parâmetros de avaliação;
4. Tratar o problema de redução de ruídos de sinais de DP por Transformada Wavelet como um problema de otimização multivariável, explorando em um único algoritmo todas as variáveis necessárias para a execução do processo de filtragem.

1.4 Estrutura da Dissertação

A presente dissertação está estruturada em sete capítulos. No Capítulo 1, expomos as considerações iniciais e as justificativas para os estudos que serão abordados, os objetivos deste trabalho, a metodologia de pesquisa aplicada e delimitamos sua estrutura.

No Capítulo 2 descrevemos o que vem a ser Descargas Parciais, quais as informações que podem ser extraídas na sua medição, bem como os circuitos aplicados para obtenção dos sinais de DP em cada tipo de equipamento e os tipos de ruídos que podem comprometer a análise destes sinais.

No Capítulo 3 abordamos os conceitos teóricos da Transformada Wavelet, descrevendo algumas de suas formas e suas aplicações, os parâmetros necessários para aplicação em filtragem de sinais de DP, bem como sua importância na redução de ruídos.

No Capítulo 4 apresentamos os Algoritmos Genéticos e descrevemos sua importância em problemas de otimização, abordando também conceitos de Algoritmos Meméticos. Apresentamos também algumas das técnicas que podem ser utilizadas no desenvolvimento de um AG.

O Capítulo 5 mostrará os métodos normalmente aplicados na seleção do número de níveis e da função wavelet mãe, expondo algumas das suas dificuldades e problemas, para então propor um novo método para seleção do número de níveis e um outro método para a seleção da wavelet mãe, denominados Seleção de Nível Baseada na Densidade Espectral de Energia (*Power Spectrum Based Level Selection* - PSBLS) e Seleção da Wavelet Baseada na Relação Sinal Ruído (*Signal to Noise Ratio Based Wavelet Selection* - SNRBWS), respectivamente. Também utilizamos o mesmo princípio do método SNRBWS e modificamos o método de Seleção da

Wavelet Baseado na Energia. Por fim descrevemos um novo método baseado em AG para otimização de todas as variáveis envolvidas no processo de filtragem por WT. Mostramos o desenvolvimento da função custo a ser aplicada no AG, a qual é essencial para determinar a qualidade da filtragem dos sinais de DP.

No Capítulo 6 comparamos os métodos desenvolvidos com alguns outros métodos descritos na literatura técnica. Em seguida, apresentamos os resultados de algumas simulações dos métodos abordados e realizar a discussão dos resultados obtidos. Mostrando que os métodos desenvolvidos forneceram excelentes resultados em comparação aos demais métodos já descritos na literatura.

Finalmente, no Capítulo 7 são expostas as conclusões obtidas com o trabalho desenvolvido, mostrando que os novos métodos conseguem fornecer resultados satisfatórios. Também expomos algumas sugestões para desenvolvimentos futuros.

Capítulo 2

Descargas Parciais

A avaliação de descargas parciais em equipamentos de alta tensão permite obter informações das condições do material isolante que os compõem, pois DP causam a deterioração progressiva do isolante, o que pode ocasionar falhas nesse equipamento gerando sérios prejuízos de cunho econômico e ambiental, afetando tanto fornecedores como consumidores de energia. Seu monitoramento tem se mostrado uma poderosa ferramenta na manutenção preventiva desses equipamento, salvaguardando os mesmos de falhas, o que permite o aumento de sua vida útil, de forma que gera grande economia. Portanto, é de suma importância para sistemas elétricos de alta tensão o monitoramento de DP.

2.1 Definição

A Descarga Parcial pode ser caracterizada como uma pequena descarga elétrica que ocorre em uma área imperfeita (cavidade, bolha ou inclusão) de um material dielétrico sujeita a um campo elétrico, no entanto o caminho percorrido por esta descarga não une completamente as extremidades do material [8].

Segundo a norma IEC 60270 [10], descargas parciais são descargas elétricas localizadas que simplesmente fazem a ligação parcial entre condutores através do isolamento e que podem ou não ocorrer adjacentes a um condutor. Tais DP são, em geral, a consequência de uma concentração de tensão elétrica local no isolamento ou sobre uma superfície do isolamento. Geralmente, descargas aparecem como pulsos com duração inferior a 1 ms.

O uso do termo Descarga Parcial pode ser aplicado a vários tipos de descargas, sendo estas interna, superficial ou externa, esta última denominada *corona*. A norma

IEC 60270 também descreve *corona* como uma forma de DP que ocorre em meio gasoso, em torno de condutores sem isolamento sólido ou líquido.

A ocorrência de DP é normalmente acompanhada pela emissão de onda acústica, luz, calor e reações químicas. Todas estas manifestações podem ser detectadas por diferentes métodos de medição; no entanto, na prática é preferível aplicar o método elétrico [11]. Este método faz uso de circuitos de medição para detectar e avaliar os pulsos de tensão ou corrente resultantes das DP. Na Seção 2.6 descreveremos os tipos de circuitos aplicados pela norma IEC 60270.

2.2 Condições para Ocorrência de DP

A DP ocorre devido à presença de cargas livres (elétrons e/ou íons positivos) em certa área e um campo elétrico que excede a intensidade do campo de gás contido nesta mesma área, acelerando as cargas livres de forma que se inicia um processo de avalanche. Esse fenômeno pode provocar a degradação gradual do material isolante, o que por fim pode ocasionar uma descarga completa entre os condutores, levando à destruição do sistema isolante e, portanto, perda do equipamento.

A menor tensão que deve ser aplicada para o surgimento de DP acima de uma magnitude específica é denominada tensão de inepção de descarga e a tensão na qual a magnitude da DP cai abaixo de um valor específico é denominada tensão de extinção de descarga. Tais valores são dependentes dos seguintes elementos [12]:

- geometria e espaçamento entre condutores e tipo de homogeneidade do isolamento;
- forma, localização e natureza das partículas no isolamento;
- forma, localização e dimensão das inclusões gasosas e do tipo de gás incluso;
- presença e tipo de contaminação sobre a superfície do isolamento;
- condições ambientes (temperatura, pressão, umidade);
- forma de onda, taxa de subida e tempo de aplicação da tensão;
- se o objeto foi exposto anteriormente a condicionamento térmico ou elétrico, ou envelhecimento;

2.3 Tipos de Descargas Parciais

Para identificar o tipo de DP é necessário averiguar os pontos do isolante em que as descargas podem ocorrer. Já que fisicamente, avalanches de elétrons auto sustentadas só podem ocorrer em meios gasosos [13], então podem existir descargas na área externa do isolante (corona), na área interna ou na superfície do isolante, em regiões de inclusão gasosa, cavidades ou bolhas devido a imperfeições nos dielétricos sólidos ou líquidos.

2.3.1 Descargas Externas

Descarga externas que geralmente ocorrem em linhas de transmissão, terminais de entrada de equipamentos de alta tensão, entre outros condutores expostos a um meio gasoso (na maioria dos casos o ar ambiente), ou seja, sem a presença de dielétricos sólidos ou líquidos. Estas descargas são designadas como *corona* e tal fenômeno se manifesta em consequência da concentração do campo elétrico em regiões com pequenos raios de curvatura de um condutor, acelerando os elétrons livres até o ponto em que estes começam a produzir novos elétrons por choque com outros átomos, de modo que ionizam as partículas do gás a sua volta (ar) até que se exceda o valor crítico de tensão (determinado pela geometria dos condutores, pressão e da natureza do gás [14]. Isso possibilita a passagem de corrente entre um eletrodo e outro, gerando uma sucessão de descargas parciais [12]. A Fig. 2.1 ilustra a descarga externa.




Figura 2.1: Descargas externas: (a) modelo; (b) real. Fonte: [13]

O processo de recombinação dos íons e elétrons libera energia em forma de calor, luz, som e radiação eletromagnética. Quando as descargas ocorrem no ar ambiente, processos químicos criam subprodutos que se incorporam ao ar a sua volta; assim,

as descargas no ar podem ser consideradas reversíveis. Entretanto, o ozônio gerado pode causar o fissuramento do isolamento de forma irreversível. Óxidos de nitrogênio junto com o vapor de água podem corroer metais e formar depósitos condutivos sobre o isolamento promovendo o fenômeno de trilhamento (*tracking*) do material [12].

2.3.2 Descargas Superficiais

Descargas superficiais ocorrem em gases ou líquidos, na superfície de um material dielétrico, normalmente partindo do eletrodo para superfície não coberta por este eletrodo (para superfície não coberta por este eletrodo). Assim que o campo elétrico que tangência a superfície excede um certo valor crítico, o processo de descarga superficial é iniciado [11]. Tais descargas ocasionam alterações na superfície do dielétrico, iniciando caminhos condutores (trilhamento) que se propagam ao longo da direção do campo elétrico, o que pode levar à ruptura completa da isolação [12].

A menos que se tome precauções para reduzir a concentração de campo na borda de condutores adjacentes ao isolamento, descargas de superfície no ar são prováveis de ocorrer em mais baixa tensão do que descargas internas [12]. Fontes comuns de descargas superficiais são terminações de cabos ou terminais de enrolamentos de estatores [15].




Figura 2.2: Descarga superficial.

2.3.3 Descargas Internas

Descargas Internas ocorrem devido a imperfeições no dielétrico presentes tanto em materiais sólidos e líquidos, bem como em gás comprimido. Como descargas só ocorrem em meio gasoso, as descargas em isolantes sólidos podem surgir em cavidades preenchidas com gás, tais como vazios, trincas, delaminações ou mesmo defeitos de estrutura molecular. Nos isolantes líquidos, podem aparecer em bolhas

de gás devido a fenômenos térmicos e elétricos e em vapores de água que podem ser criados em regiões de alto campo elétrico.

Algumas causas comuns para formação de cavidades em isolantes, além das citadas na Seção 2.2, são mostradas por [16]. No caso de materiais termoplásticos, e.g. polietileno, a falha pode ocorrer no processo de injeção do polímero por infiltração de ar ambiente, em polímeros termofixos, e.g. epóxi, a formação de vazios pode acontecer no processo de cura do material, também por infiltração de ar ou formação de gases residuais oriundos de reações químicas.

Algumas descargas internas podem surgir como arborescências (*treeing*) elétricas, Fig. 2.3(b), que têm sua origem devido a ocorrência de um grande número de DP numa certa região ou por uma falha no eletrodo [17], levando à deterioração do sistema isolante. Tal deterioração pode ocorrer de forma bastante rápida ou extremamente lenta. Portanto, um colapso pode ocorrer em pouco tempo ou levar anos até que finalmente ocorra.




Figura 2.3: Fotos de Descargas Internas:(a) DP guia em óleo; (b) arboreamento. Fonte: [13]

Descargas internas em Subestações Isoladas a Gás (GIS), que ocorrem em função da presença de partículas fixas ou móveis, podem dissociar o gás SF₆ em sub-produtos que podem deteriorar os isolantes sólidos ou resultar na formação de substâncias venenosas, levando a um colapso do sistema elétrico devido a transientes de sobretensão.

Pelo fato de descargas internas causarem o envelhecimento e degradação progressiva do isolamento, elas podem ser vistas como irreversíveis.

2.4 Modelos para Descrição de DP

Quando descargas parciais ocorrem em cavidades de isolantes, ocorre uma transferência de carga que reduz a tensão através da cavidade, causando uma diminuição proporcional da tensão nos terminais condutores do equipamento de alta tensão sob análise. Portanto, pulsos de DP não podem ser medidos diretamente já que a fonte de DP não está acessível.

Para avaliação do comportamento das descargas parciais em cavidades, pode ser aplicado o modelo de circuito equivalente, referido como modelo a-b-c, e o modelo baseado na aproximação por campo elétrico.

2.4.1 Modelo a-b-c

Foi o primeiro modelo de circuito equivalente, publicado por Gemant e Philipoff [18], em que a cavidade gasosa é associada a um elemento capacitivo C_c e a descarga é vista como o processo de descarga desse elemento que está envolto pela capacitância do isolamento em paralelo e do isolamento em série, representados por C_a e C_b , respectivamente, conforme ilustrado na Fig. 2.4. Pode-se dizer que a capacitância da cavidade será bem menor em relação às demais capacitâncias que a envolvem, já que ocupa uma área menor que a do isolamento.




Figura 2.4: Modelo a-b-c.

Analisando o comportamento do modelo a-b-c, ilustrado na Fig. 2.5, a tensão em Corrente Alternada (Alternated Current - AC) aplicada nos terminais do equipamento, designada como V_1 , produz uma tensão V_2 através da cavidade gasosa devido ao divisor capacitivo formado por C_b e C_c . Quando V_1 está acima da tensão de inepção, de forma que a tensão V_2 alcança um valor crítico, e, havendo carga livre o suficiente, ocorre o processo de descarga, representada pelo curto nos terminais de C_c . Desta maneira a tensão V_2 sofre um salto e assim que a descarga se

extingue volta a subir até que ultrapasse novamente o valor crítico, gerando outra descarga; o efeito repete-se gerando uma sequência de descargas. O processo tende a ocorrer próximo da tensão de pico para o primeiro pulso, mas, subsequentemente, a DP ocorre logo após a tensão zero e próximo dos picos [12]. Quanto maior o valor da tensão V_1 aplicada ao equipamento, maior tende a ser a frequência de ocorrência de pulsos, com sua magnitude permanecendo mais ou menos constante [13].

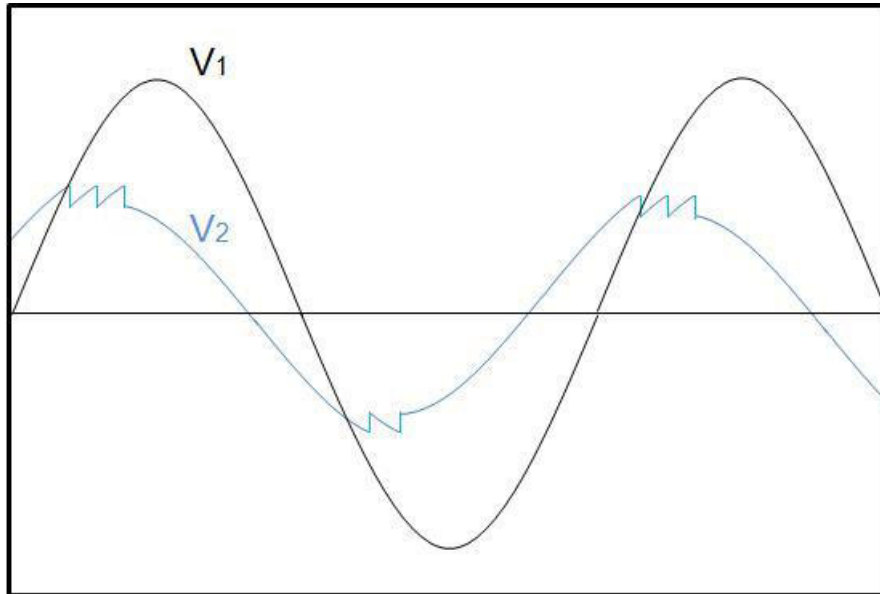


Figura 2.5: Comportamento do modelo a-b-c.

Por muito tempo se discutiu sobre a validade do modelo a-b-c na literatura, mas em [19] foi demonstrado que tal modelo, apesar de não corresponder aos processos físicos que acontecem em sistemas reais [20], representa corretamente os transientes associados às DP.

2.4.2 Modelo Qualitativo Baseado na Aproximação por Campo

Com base no argumento de que o modelo a-b-c não corresponde aos processos físicos que envolvem o fenômeno de DP e não permite o cálculo das capacitâncias presentes, outros modelos têm sido sugeridos [21]. Um modelo qualitativo proposto em [16] se baseia na aproximação por campo.

Considerando uma cavidade esférica entre os eletrodos de um dielétrico sólido, ao aplicar tensão alternada e levando em conta que inicialmente não existe carga na superfície ou interior da mesma, é possível assumir que o campo elétrico na cavidade será aproximadamente constante e irá variar proporcionalmente à tensão entre os

eletrodos (campo Laplaciano). Mesmo que o aumento de tensão provoque a elevação do campo no interior da cavidade acima do ponto de ruptura, não necessariamente ocorrerá uma descarga, pois pode haver demora até que surjam elétrons para iniciar o processo de descarga, principalmente em cavidades muito pequenas.

Para uma cavidade larga, se um elétron ocorre num volume crítico dentro da cavidade, o mesmo é acelerado pelo campo elétrico e ao se colidir com outras moléculas, produz um aumento exponencial no número de elétrons, resultando no surgimento de um canal (*streamer*) em um período de nanosegundos. A condutividade do canal reduz o campo elétrico na cavidade até que o canal acaba por desaparecer, mas em tal processo há uma grande quantidade de cargas positivas e negativas que se dirigem para o pequeno campo elétrico remanescente nas paredes da cavidade (Campo Poissoniano). Assim, com o fim da DP o campo é reduzido a quase zero, levando a uma redução da tensão através da amostra. Entretanto, como a tensão nos eletrodos varia, o campo dentro da cavidade mudará, já que a carga nas paredes não são móveis e causam um deslocamento entre o campo na cavidade e a tensão entre os eletrodos, como ilustrado na Fig. 2.6. Descargas consecutivas seguem o campo total dentro da cavidade e irão ocorrer quando o campo ultrapassar novamente o valor crítico. Tal processo permite verificar que as descargas podem ocorrer mesmo quando a tensão aplicada é zero, já que o campo Poissoniano se soma ao campo Laplaciano e pode ser alto o bastante para desencadear a descarga. Pode-se dizer que o processo de descarga segue o campo elétrico e não a tensão aplicada [15].




Figura 2.6: Comportamento do modelo qualitativo de aproximação por campo: a onda senoidal representa a tensão aplicada, enquanto que a onda serrada representa o campo na cavidade. Quando ocorre a descarga o campo é reduzido (aproximadamente zero). Como a tensão muda após a descarga, o campo na cavidade muda de zero em proporção à mudança na tensão aplicada.

A carga que flui sobre os eletrodos devido à mudança na configuração do campo elétrico é denominada DP de magnitude aparente, a qual se relaciona com a geometria, o tamanho, a forma, e a posição da cavidade dentro do equipamento. A variação de carga nos terminais do equipamento, assumindo que não haja mudança da constante dielétrica ou da distância entre os eletrodos, dependerá da mudança equivalente na capacitância e da tensão no equipamento em que ocorreu a última DP, não dependendo da área dos eletrodos. Já a variação de tensão depende da carga sobre os eletrodos e conseqüentemente da área destes.

2.5 Grandezas Derivadas e Relacionadas aos Pulsos de DP

Para que possamos realizar a análise dos dados de descargas parciais obtidos de um equipamento de alta tensão da maneira mais adequada possível, a norma IEC 60270 [10] define algumas grandezas importantes a serem obtidas durante um teste de DP.

2.5.1 Grandezas Derivadas dos Pulsos de DP

- A carga aparente q de um pulso DP é a carga que, se injetada dentro de um período muito curto de tempo entre os terminais do objeto em um circuito de teste específico, resultaria na mesma leitura no instrumento de medição que o próprio pulso de corrente DP. Seu valor é expresso em pC . Tal grandeza recebe o nome de aparente por não ser igual à quantidade de carga envolvida no local da descarga, sendo esta impossível de ser medida diretamente.
- Taxa de repetição do pulso n corresponde à razão entre o número total de pulsos de DP, N , ocorrendo dentro de um intervalo de tempo escolhido como referência, T_i . Para medi-la, é recomendado o uso de um circuito contador de pulsos na saída do circuito de medição do sinal de DP. Caso os instrumentos de medição tenham resposta oscilatória ou bi-direcional, é preciso utilizar um circuito para definir a forma do pulso, obtendo somente uma contagem por pulso. Para identificar a máxima taxa de repetição do pulso, o contador aplicado deve ter uma curta resolução de tempo do pulso, ou seja,

$$n = \frac{N}{T_i} \quad (2.1)$$

- Frequência de repetição do pulso, N_c , é o número total de pulsos de calibração equidistantes ocorrendo dentro de um intervalo de tempo T_{ref} pré-determinado, ou seja,

$$n = \frac{N_c}{T_{ref}} \quad (2.2)$$

- Ângulo de fase ϕ_i de um pulso DP é o ângulo de fase do sinal de tensão no instante em que ocorre o pulso. Pode ser encontrado pela diferença de tempo Δt_i entre o cruzamento de negativo para positivo do sinal AC aplicado e o pulso DP considerado, multiplicado por 360° e dividido pelo período T_c de um ciclo da tensão AC de teste, sendo portanto expressa em graus.

$$\phi_i = 360 \times \frac{\Delta t_i}{T_c} \quad (2.3)$$

- Corrente de descarga média I é o somatório dos valores absolutos das cargas aparentes de cada pulso de magnitude q_i durante um intervalo de tempo T_{ref} , dividido por este intervalo. É uma grandeza expressa em Coulombs por segundo (C/s) ou em Amperes (A).

$$I = \frac{1}{T_{ref}} (|q_1| + |q_2| + \dots + |q_3|) \quad (2.4)$$

- Potência média de descargas é a potência média dos pulsos DP introduzida nos terminais do objeto de teste devido à carga aparente, que é dada pelo produto entre os valores instantâneos da tensão de teste u_i no momento de ocorrência t_i de uma carga aparente de magnitude q_i durante um intervalo de tempo T_{ref} escolhido. A potência de descarga é expressa em Watts (W).

$$P = \frac{1}{T_{ref}} (q_1 u_1 + q_2 u_2 + \dots + q_i u_i) \quad (2.5)$$

Fisicamente a potência de descarga se mostra mais interessante do que a carga aparente para a avaliação da severidade da DP. No entanto, sua medição em uma precisão adequada requer uma faixa dinâmica muito ampla, já que pulsos com carga aparente de baixa magnitude mas com alta taxa de repetição de pulsos podem se portar de maneira similar a pulsos de carga muito alta mas com baixa taxa de repetição.

- Taxa quadrática D corresponde ao somatório dos quadrados das cargas aparentes individuais de magnitude q_i durante um intervalo de tempo T_{ref} dividido

por este intervalo. É expressa em (Coulombs)² por segundo (C²/s).

$$D = [(q_1)^2 + (q_2)^2 + \dots + (q_i)^2] / T_{ref} \quad (2.6)$$

Também podem ocorrer erros na medição devido à faixa dinâmica de medição.

2.5.2 Grandezas Relacionadas à Tensão de Teste de DP

Os seguintes níveis de tensão são de particular interesse:

- Tensão de injeção de DP U_i é a mais baixa tensão AC aplicada para a qual pulsos de DP ocorrem repetitivamente se igualando ou excedendo uma certa magnitude de carga aparente especificada, quando a tensão aplicada ao objeto sob teste é gradualmente aumentada de um valor onde nenhuma descarga parcial ocorre.
- Tensão de extinção de DP U_e é a mais baixa tensão AC aplicada na qual a magnitude dos pulsos de DP torna-se menor ou igual à uma carga aparente especificada, quando a tensão aplicada é gradualmente reduzida de um nível no qual os eventos de DP ocorrem.
- Tensão de teste de DP é uma tensão AC específica aplicada para um procedimento de teste de DP, durante o qual o objeto testado não deve apresentar pulsos DP excedendo uma magnitude de descarga parcial especificada.

No Apêndice A mostramos alguns dos circuitos utilizados nas medições de DP em equipamentos de alta tensão.

2.6 Calibração do Sistema de Medição

Sabendo que um pulso de DP gerado no interior do objeto irá provocar a leitura proporcional de uma carga aparente q_a no sistema de medição, é preciso determinar o fator de escala k para que esta carga possa ser medida em termos de pC.

Para obter k é preciso injetar pulsos de corrente de carga conhecida q_c nos terminais de objeto a ser testado C_a por meio de um calibrador, conforme mostrado na Fig. 2.7, sendo com isso possível simular um pulso de DP ocorrendo no interior deste objeto [22]. Esta carga irá gerar a leitura de uma carga proporcional q_l , assim o fator de escala pode ser calculado por:

$$k = \frac{q_c}{q_l} \quad (2.7)$$

Para uma boa precisão na medição, a norma IEC 60270 [10] recomenda aplicar pulsos para diversas faixas de magnitude em relação à magnitude de DP especificada.




Figura 2.7: Circuito para calibração do objeto em teste C_a .

O circuito de calibração pode ser montado como indicado na Fig. 2.8, onde um gerador produz pulsos equidistantes em degrau de magnitude U_g , que, ao passar pelo filtro formado pelo capacitor de baixa tensão C_c e pela resistência R_m do circuito de medição, é diferenciada, gerando um pulso semelhante ao pulso DP. É indicado que C_c não seja maior que 10% da capacitância C_a somada com a capacitância C_k , de modo que C_a e C_k não influenciem de forma significativa a carga injetada e esta pode ser obtida por:

$$q_c = U_g \times C_c \quad (2.8)$$




Figura 2.8: Circuito de medição.

Substituindo a Eq. (2.8) na Eq. (2.7) obtém-se o fator de escala k , assim para pulsos de DP medidos em um teste real a carga aparente medida q_a é dada pela Eq. (2.9) em que q_{DP} corresponde a carga lida para o pulso de DP real.

$$q_a = q_{DP} \times k \quad (2.9)$$

2.6.1 Principais Características dos Sinais de DP

Em [23] encontrou-se que a forma do pulso depende do tamanho da cavidade e da quantidade pela qual a tensão sobre a cavidade excede seu valor de ruptura. Ao passo que a amplitude do pulso aumenta com a sobretensão através da cavidade, o comprimento do pulso amplia com a separação do diâmetro da cavidade, pois os elétrons leva mais tempo para atravessar a distância entre os eletrodos. Denvins também classificou os pulsos em cavidades em duas categorias:

- Descargas *Townsend*: caracterizadas por pulsos de mais baixa intensidade e mais longos, resultantes de pulso de cauda prolongada devido a corrente de íon;
- Descargas *Streamer-like*: pulsos mais curtos (com tempos de subida mais rápidos) e de alta amplitude, prevalecendo níveis elevados de sobretensão sobre a cavidade.

Portanto, o tempo de subida dos pulsos de DP podem variar de alguns ns até us. Isso caracteriza pulsos de DP como pulsos de alta frequência.

A forma do pulso e seus tempos de subida também dependerão dos fatores expostos na Seção 2.2, já que dependem da sobretensão na cavidade. Além disso, o tempo de subida e a forma dos pulsos podem tornar-se bem degradados quando percorrem cabos ou bobinas de transformadores e máquinas, até chegar à impedância de medição Z_m [24].

A impedância utilizada na detecção dos pulsos de DP até o sistema de medição também altera as características do pulso de DP. Conforme discutido na Seção 2.6, as impedâncias de medição podem ser circuitos RC ou RLC, transformadores de corrente de alta frequência ou bobinas de Rogowski. Geralmente o formato dos pulsos adquiridos no sistema de medição são do tipo Exponencial Amortecido (*Damping Exponential* - DE) ou Oscilatórios Exponencialmente Amortecidos (*Damping Oscillatory Exponential* - DOE), tanto que tais tipos de formas de onda são bastante empregados na literatura para simular sinais de DP [25–32]. A Fig. 2.9 ilustra os típicos sinais de DP e seus parâmetros.

Pela Fig. 2.9(a) vemos alguns parâmetros importantes empregados na análise da forma de pulso de DP para um sinal exponencialmente amortecido:

- Valor de pico do pulso;
- Tempo de subida, calculado pelo tempo entre os instantes em que a amplitude corresponde a 10% e a 90% do seu valor de pico;

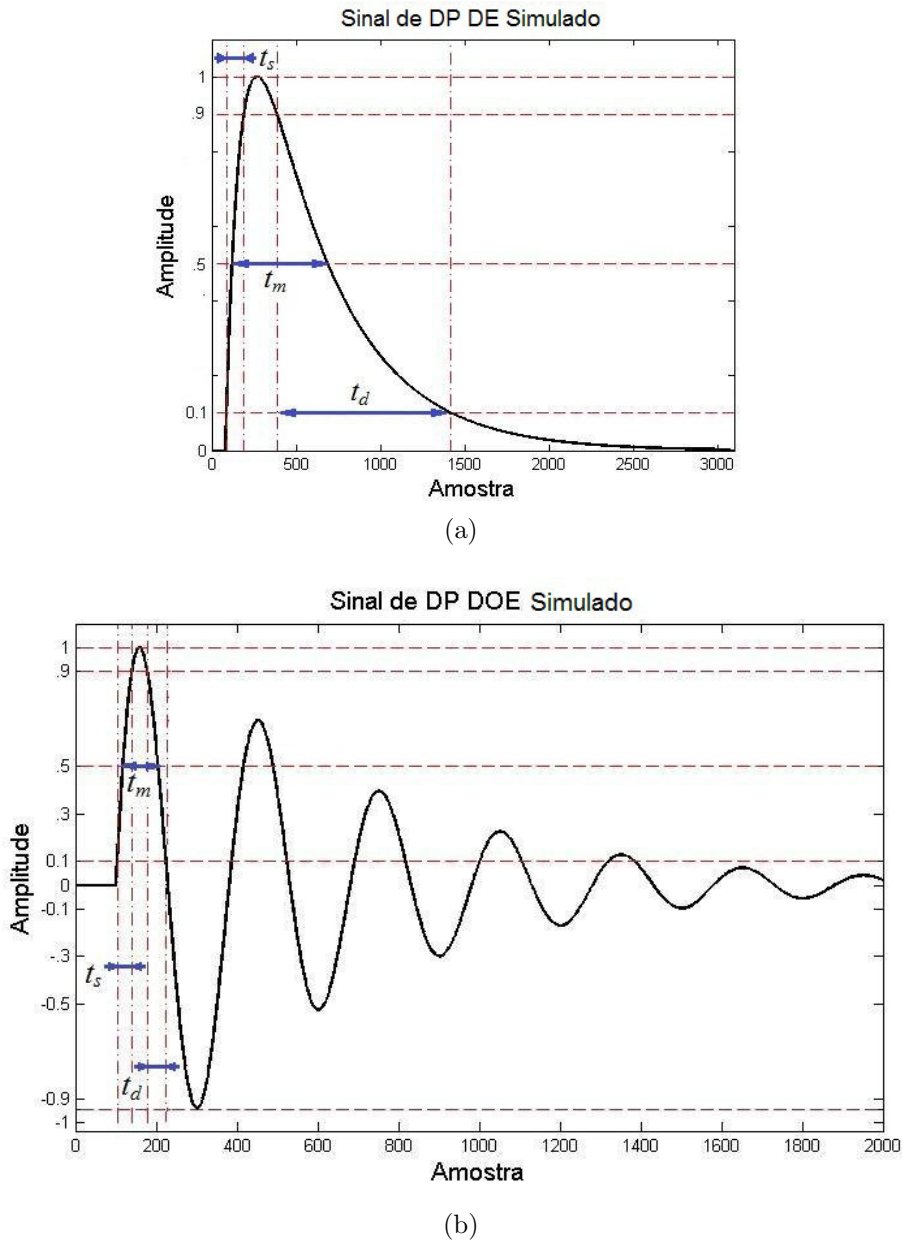


Figura 2.9: Parâmetros de pulsos de DP: (a) DE; (b) DOE.

- Tempo de descida, calculado pelo tempo entre os instantes em que a amplitude corresponde a 90% e a 10% do seu valor de pico;
- Duração do pulso, dada pelo intervalo de tempo em que o pulso está acima de 50% do seu valor de pico.

Para pulso DOE, os cálculos devem ser efetuados com relação ao primeiro pico e ainda é interessante verificar o valor do menor pico do pulso, conforme ilustrado na Fig. 2.9(b), servindo como uma informação a mais a respeito do formato do pulso.

2.7 Processamento Digital de Sinais de DP

Para digitalização dos sinais de DP, duas vertentes são aplicáveis. Na primeira se faz um pré-processamento analógico dos sinais de DP com um circuito de quasi-integração e de detecção de pico para obter a carga aparente dos pulsos. Em seguida os sinais DP e de sincronismo analógico são convertidos para digital por meio de um conversor A/D e ambos dados são repassados para o computador, no qual é feito todo o processamento digital para: cálculo dos parâmetros relevantes para análise de descarga parcial, exibição dos dados ao usuário e armazenamento dos dados na memória.

Na segunda vertente, não ocorre o pré-processamento analógico dos sinais DP, sendo estes encaminhados, juntamente com o sinal de sincronismo, a partir do circuito de medição para os conversores A/D. Após digitalizados, os sinais são submetidos à filtragem digital para obtenção da carga aparente e remoção de ruídos. Em seguida os dados podem ser submetidos ao processamento digital de interesse.

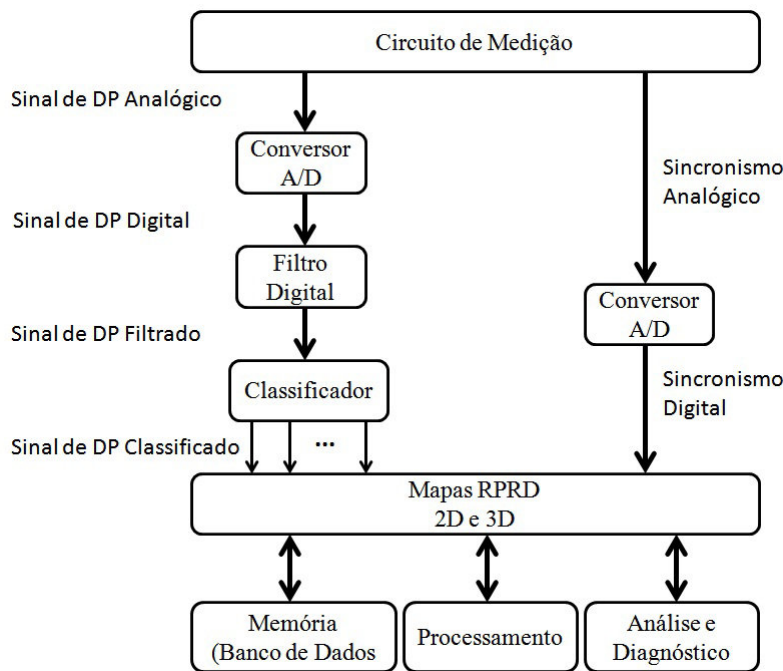


Figura 2.10: Circuito de processamento digital de Banda Ultra Larga (Ultra Wide Band - UWB).

Na Fig. 2.10 é mostrado como o processamento pode ser feito. Após a filtragem os dados de DP passam por um classificador, que permite a discriminação dos eventos entre DP e interferências que não puderam ser eliminadas na etapa de filtragem digital e permite ao sistema distinguir as diversas fontes causadoras de DP e até mesmo encontrar a localização destas falhas no objeto em teste. Com os dados classificados, são gerados mapas de Descargas Parciais Discriminados por Fase (*Phase*

Resolved Partial Discharge - PRPD) tanto em 2D quanto em 3D. Sobre esses mapas serão realizados todo o armazenamento, o processamento, a análise e o diagnóstico do equipamento em avaliação.

Portanto, a digitalização dos dados estende a capacidade de análise das formas de onda dos pulsos analisados, permitindo uma distinção de diferentes fontes de DP e uma melhor extração de ruídos dos sinais de DP.

Sistemas de processamento digital mais avançados possibilitam velocidades de processamento de dados em tempo real de DP contínuas e síncronas em canais múltiplos [33–35]

2.7.1 Visualização das Informações de DP

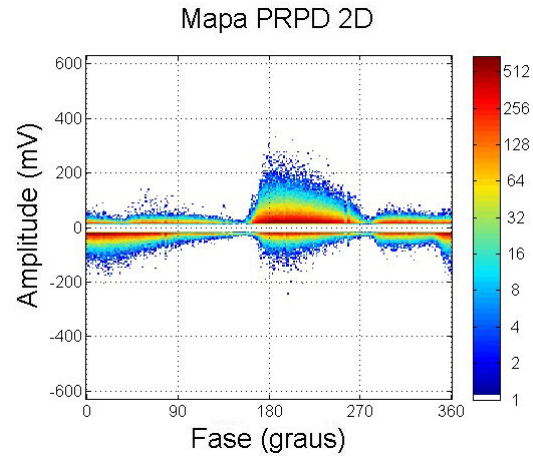
Sistemas de medição digital melhoraram a capacidade de visualização dos dados de DP, o que facilita o diagnóstico e interpretação destes dados.

A Fig. 2.11 mostra um mapa de PRPD, o qual condensa o número de pulsos ocorridos em uma dada amplitude e fase da tensão de corrente alternada aplicada no objeto analisado. O mapa pode ser exposto num formato 2D, conforme mostrado na Fig. 2.11(a), com eixo das abscissas indicando a fase de ocorrência do pulso de corrente de DP e o eixo das ordenadas indicando a amplitude do sinal DP. Os dados obtidos em cada ciclo são sobrepostos ao longo do intervalo de medição, gerando diferentes níveis de cor conforme a densidade de pulsos com mesma amplitude aumenta. Um modo mais agradável de visualização é o formato 3D, ilustrado na Fig. 2.11(b), em que o eixo das cotas informa o número de pulsos.

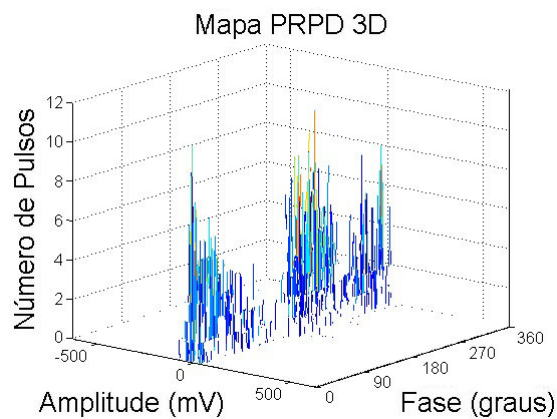
A análise e diagnóstico das condições em que se encontra o isolamento dos equipamentos de alta tensão por meio de DP requer experiência por parte do operador; por isso se faz necessário provê-lo com o maior número de informações possível, sendo a análise feita com base na evolução dos mapas de PRPD, de curva de tendência das grandezas relacionadas às DP e verificação de dados estatísticos [36, 37].

Para 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:

- Diagrama de Relação de Amplitude em 3 Fases (*3 Phase Amplitude Relation Diagram* - 3PARAD) [35, 38–40], que se baseia no fato de que, quando ocorre



(a)



(b)

Figura 2.11: Mapa PRPD Bipolar em: (a) 2D; (b)3D.

um pulso no isolamento, ele se propagará para cada fase, sendo medido com diferentes níveis de amplitude e capturado aproximadamente no mesmo instante. Em seguida, se faz o cálculo do logaritmo do valor absoluto dos pulsos para cada fase, sendo cada pulso transformado em um fasor relacionado à sua fase de origem, por fim é feita a soma vetorial destes fasores e o pulso DP é mostrado em um diagrama em 3D, conforme ilustrado na Fig. 2.12.

- Diagrama de Relação de Tempo em 3 Fases (*3 Phase Time Relation Diagram* - 3PTRD) [35], mostrado na Fig. 2.13, usa a mesma ideia do 3PARD, mas verificando o atraso entre cada um dos pulsos aquisitados num certo intervalo de tempo, o qual fornecerá informações a respeito da distância de propagação do pulso, já que esta se relaciona ao tempo de chegada de cada pulso (i.e., quanto mais distante o pulso DP mais tempo ele demora a chegar). Assim é possível estimar a localização da DP.
- Diagrama de Relação de Frequências em 3 Canais (*3 Center Frequency Relation*

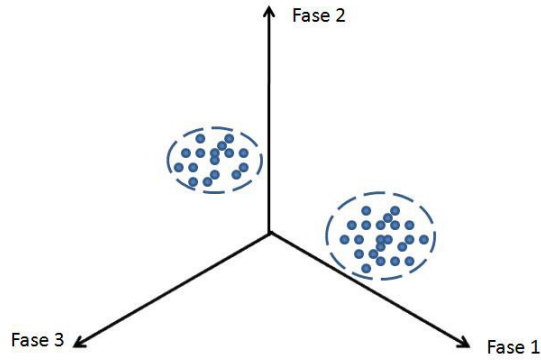


Figura 2.12: Diagrama 3PARD.

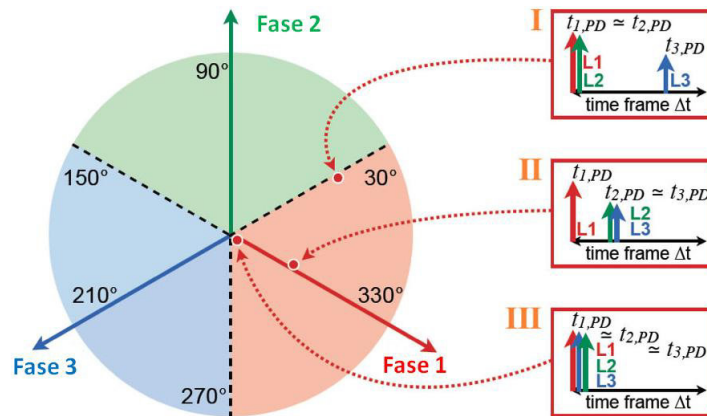


Figura 2.13: Diagrama 3PTRD para três pulsos de DP na Fase 1. Fonte: [35]

Diagram - 3CFRD), não necessita de três unidades independentes, podendo ser realizada através de apenas uma unidade de aquisição, a qual deve ser processada por três filtros, sendo um sintonizado em baixa frequência para atender a norma IEC 60270 [10] e os outros dois sintonizados em frequências mais elevadas de escolha do usuário, em que a propagação do pulso causa respostas espectrais distintas. Com isso, é possível realizar a separação dos sinais individuais em grupos (*clusters*), eliminando parte do ruído sobreposto.

2.8 Interferências em Medições de DP

A medição de DP é frequentemente acometida por ruídos de diferentes fontes, principalmente em medições realizadas em campo, onde os níveis de Interferências Eletromagnéticas (*Electromagnetic Interferences - EMI*) podem sobrepor totalmente os sinais de DP. Portanto, é importante ter conhecimento dos tipos de interferências e suas características para aperfeiçoar as técnicas de redução das mesmas [41, 42].

Os seguintes efeitos podem causar interferências nos sensores de medição de DP

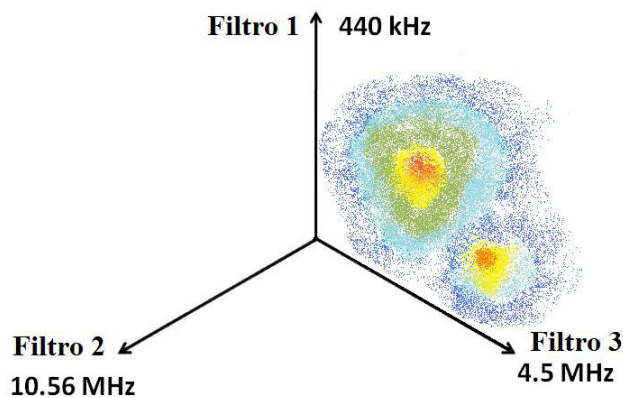


Figura 2.14: Diagrama 3CFRD.

on-line [41, 43]:

- Interferência de Espectro Discreto (*Discrete Spectrum Interferences* - DSI);
- Pulsos repetitivos;
- Pulsos aleatórios;
- Outras fontes como ruídos ambientes e do amplificador.

No que diz respeito à sua natureza, ruídos são classificados como [26, 32, 44, 45]:

- Senoidais contínuos e de espectro discreto;
- Pulsantes periódicos;
- Pulsantes estocásticos;
- Estocásticos contínuos.

Ruídos senoidais (DSI) são ruídos de banda estreita provenientes de sistemas de comunicações, como sinais de rádio de Amplitude Modulada (AM) e de Frequência Modulada (FM) e sinais de telefonia celular. Na maioria das medições apenas ruídos de rádio AM exercem influência considerável na medição de DP, pois a sua banda de operação (144 - 30000 kHz) coincide com a banda passante dos sistemas de medição [26]. Entretanto, com os avanços obtidos nas medições de UWB, os sinais de FM e de celular podem também causar interferências na medição.

Ruídos pulsantes periódicos advêm de dispositivos de eletrônica de potência como ruídos de disparos de tiristores, entre outros chaveamentos periódicos. Por ter o formato de um pulso, tendem a cobrir uma banda mais larga do espectro de potência do que os ruídos senoidais.

São exemplos de ruídos pulsantes estocásticos ruídos originados por descargas

atmosféricas, operações de chaveamentos infrequentes, *corona* emitidos por equipamentos de alta tensão, arco elétrico entre contatos adjacentes, ruídos do próprio circuito de medição, centelhamentos, arcos em máquinas rotativas, etc. Estes são as fontes mais comuns de interferência e que apresentam maior dificuldade para serem discriminados dos sinais de DP [29, 44], pois suas características são similares a dos pulsos de DP, necessitando de técnicas mais avançadas para sua extração, como redes neurais artificiais, lógica Fuzzy, etc [30, 46–48]

Ruídos estocásticos contínuos são representados por ruído branco. Podem ter origem nos amplificadores ou conversores A/D utilizados no sistema de medição, ou serem ruídos térmicos existentes na fonte de alimentação, na linha de transmissão, nos próprios equipamentos de alta tensão sob teste, etc. Seu espectro se distribui aleatoriamente ao longo de toda faixa de frequência, com uma densidade espectral de energia constante (mesma potência em uma banda de frequência com comprimento fixo). Seu nome se deve a uma analogia com a luz branca que é produzida a partir da combinação de todas as frequências cromáticas com potência similar.

Devido à sua potência média infinita, um ruído branco perfeito não existe na natureza. Este, entretanto, pode ser aproximado através de algoritmos de geração pseudo aleatórios (comandos *rand* e *randn* do Matlab)[6], conforme ilustrado na Fig. 2.15, onde foi gerado um sinal de ruído branco com distribuição gaussiana de média zero e variância finita.

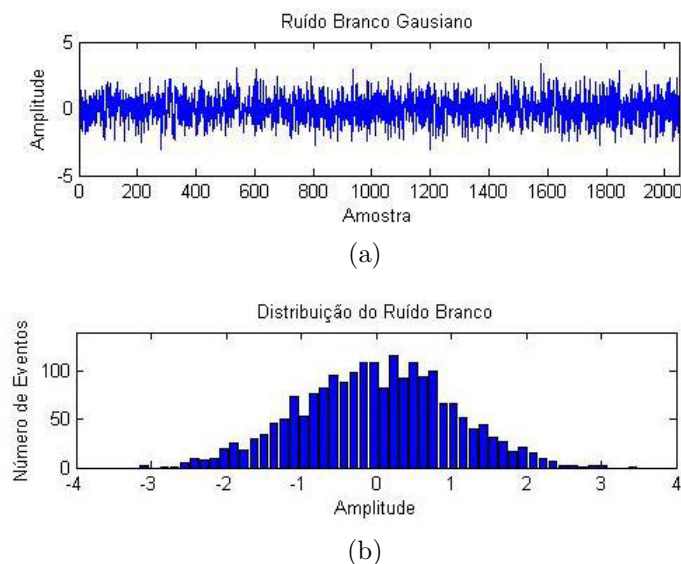


Figura 2.15: Ruído Branco: (a) sinal; (b) histograma.

Nesta dissertação exploraremos a técnica de redução de ruído por meio da transformada wavelet para suprir interferências externas, como ruído branco, DSI e qualquer combinação destes presentes simultaneamente e sobrepostos com sinais de

DP. Esta etapa de filtragem possibilitará uma maior sensibilidade e confiabilidade no processamento, análise e diagnóstico dos sinais de DP.

Como ruídos pulsantes estocásticos são muito difíceis de serem eliminados na etapa de filtragem digital, estes têm de ser tratados na etapa de classificação, conforme ilustrado na Fig. 2.10, não sendo esta etapa o foco de nosso trabalho.

Capítulo 3

Transformada Wavelet e sua Aplicação na Filtragem de Sinais de Descargas Parciais

Este capítulo proverá uma revisão dos conceitos, finalidades e propriedades para possibilitar um melhor entendimento da aplicação da transformada wavelet em processamento de sinais, mais especificamente na redução de ruídos.

Inicialmente faremos uma breve introdução dos conceitos de Transformada Discreta de Fourier (*Discrete Fourier Transform* - DFT), seguida por uma análise de Transformada de Fourier de Tempo Curto (*Short-Time Fourier Transform* - STFT) e suas limitações. Em seguida, enfatizaremos a relação entre wavelets e bancos de filtro, e mostraremos alguns dos tipos de WT, dando especial atenção a Transformada Wavelet Discreta (*Discrete Wavelet Transform* - DWT). Conceitos mais básicos de processamento digital de sinais, necessários a um melhor entendimento dos assuntos aqui abordados não serão discutidos nesta dissertação; entretanto, podem ser encontrados em [6, 49, 50].

3.1 Transformada Discreta de Fourier

A transformada de Fourier de uma sequência $x(n)$, que contém amostras uniformemente espaçadas de um sinal $x(t)$ contínuo no tempo de $-\infty$ a $+\infty$, é dada por:

$$X(e^{j\omega}) = \sum_{n=-\infty}^{\infty} x(n)e^{-j\omega n} \quad (3.1)$$

No entanto, sua representação no domínio da frequência depende da variável contínua ω . Sendo $X(e^{j\omega})$ periódica, com período 2π . Para que seja possível obter a DFT, cuja variável independente k é inteira, é necessário amostrar uniformemente a transformada de Fourier (*Fourier Transform* - FT) sobre o eixo da frequência ω para $0 \leq \omega \leq 2\pi$, i.e., $\omega_k = (2\pi k/N)$, $0 \leq k \leq N - 1$, assim:

$$X'(e^{j\omega}) = X(e^{j\omega}) \sum_{k=-\infty}^{\infty} \delta\left(\omega - \frac{2\pi}{N}k\right) \quad (3.2)$$

A partir da Eq. (3.2) e com o auxílio do teorema da convolução [6], é possível demonstrar que:

$$x'(n) = x(n) * \frac{N}{2\pi} \sum_{p=-\infty}^{\infty} \delta(n - Np) = \frac{N}{2\pi} \sum_{p=-\infty}^{\infty} x(n - Np) \quad (3.3)$$

Caso o número de amostras de $x(n)$ seja maior que o da FT, o sinal original não poderá ser recuperado, mas se for menor $x'(n)$ será uma repetição periódica precisa de $x(n)$ e, portanto $x(n)$ pode ser obtido de um período completo de N amostras de $x'(n)$, conforme:

$$x(n) = \frac{2\pi}{N} x'(n), \text{ para } 0 \leq n \leq N - 1 \quad (3.4)$$

Portanto, é importante notar que as amostras da FT podem prover uma representação adequada de um sinal discreto no tempo de comprimento finito, somente se o número de amostras da DFT em um período é maior ou igual ao número de amostras do sinal original [6].

A fim de prevenir erros devido a *aliasing*, a taxa de amostragem do sinal analógico $x(t)$ deve ser pelo menos duas vezes maior do que a maior frequência de interesse no sinal analógico, i.e., deve estar em conformidade com o critério de Nyquist [6, 51]. Desta forma, frequências acima deste valor devem ser descartadas, já que sofrem o fenômeno de *aliasing*.

Para representar $x(n)$ como uma função das amostras de $X(e^{j\omega})$, basta aplicar a Transformada Inversa de Fourier (*Inverse Fourier Transform* - IFT) [6] na Eq. (3.2):

$$x'(n) = \frac{1}{2\pi} \int_0^{2\pi} X(e^{j\omega}) e^{j\omega n} d\omega \quad (3.5)$$

$$x'(n) = \frac{1}{2\pi} \sum_{k=0}^{N-1} X(e^{j(2\pi/N)k}) e^{j(2\pi/N)kn} \quad (3.6)$$

Substituindo a Eq. (3.6) na Eq. (3.4), obtemos:

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(e^{j(2\pi/N)k}) e^{j(2\pi/N)kn}, \text{ para } 0 \leq n \leq N-1 \quad (3.7)$$

A Eq. (3.7) mostra que um sinal discreto no tempo $x(n)$ pode ser recuperado de sua transformada discreta no tempo; tal definição corresponde a Transformada Discreta de Fourier Inversa (IDFT).

Para representar a DFT do sinal $x(n)$ basta reescrever a Eq. (3.1) da seguinte maneira:

$$X(e^{j(2\pi/N)k}) = \sum_{n=0}^{N-1} x(n) e^{-j(2\pi/N)kn}, \text{ para } 0 \leq k \leq N-1 \quad (3.8)$$

Aplicando a notação $W_N = e^{-\frac{j2\pi}{N}}$ e utilizando $X(k)$ ao invés de $X(e^{j(2\pi/N)k})$, podemos representar a DFT e sua inversa na forma mais conhecida

$$X(k) = \sum_{n=0}^{N-1} x(n) W_N^{kn}, \text{ para } 0 \leq k \leq N-1 \quad (3.9)$$

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) W_N^{-kn}, \text{ para } 0 \leq n \leq N-1 \quad (3.10)$$

Observando as Eqs. (3.9) e (3.10), o cálculo da DFT e IDFT requer aproximadamente N^2 multiplicações complexas e $N(N-1)$ adições complexas. Vemos, que a complexidade da DFT aumenta com o quadrado do comprimento do sinal, limitando sua aplicação prática. No entanto, um método mais eficiente de implementação da DFT que reduz a complexidade computacional para $N(\log_2 N)$ foi desenvolvido em [52]. Esta técnica é aplicada em diferentes algoritmos, conhecidos como algoritmos de Transformada Rápida de Fourier (FFT), os quais são amplamente aplicados em processamento de sinais.

3.1.1 Teorema de Parseval

Uma propriedade interessante da DFT conforme definido no item 3.1 é o teorema de Parseval que diz que a energia de um sinal discreto no domínio do tempo $x(n)$ é igual a energia de um sinal discreto no domínio da frequência, sobre um fator de escala N . O teorema pode ser equacionado como se segue:

$$\sum_{n=0}^{N-1} |x(n)|^2 = \frac{1}{N} \sum_{K=0}^{N-1} |X(k)|^2 \quad (3.11)$$

O termo $|X(k)|^2$ pode ser definido como densidade espectral de energia, por representar a energia do sinal em cada uma de suas componentes de frequência.

3.1.2 Limitações da DFT com Sinais de DP

Como evidenciado na Eq. (3.8), a derivação da DFT requer que o sinal de entrada $x(n)$ seja periódico, i.e., o sinal deve se repetir a cada N amostras. Assim, a representação do sinal pela DFT é melhor preservada para sinais verdadeiramente periódicos.

A informação de frequência calculada pela DFT é uma média sobre a duração total do sinal. Portanto, se existe um sinal transitório local sobre algum intervalo de tempo pequeno, este contribuirá para a DFT, mas sua localização no eixo do tempo será perdida.

A DFT baseada em análise espectral se mostra muito boa para métodos de filtragem no domínio da frequência. Entretanto, a DFT só provê informações das frequências contidas em um sinal e não fornece informações a respeito do tempo em que as alterações na frequência ocorrem [44]. Como resultado, na análise de um pulso de DP, a forma deste não pode ser determinada via FT e sua localização não pode ser obtida. Além do mais, pulsos de DP são de natureza transiente, irregular e não periódica [53], o que dificulta seu processamento por meio da DFT.

Quando é necessário que haja localização no tempo da componente espectral, para determinar como a componente de frequência do sinal varia no tempo, é preciso uma representação tempo-frequência [6]. A STFT pode ser empregada para atender esta necessidade.

3.2 Transformada de Fourier de Tempo Curto

Quando se deseja extrair informações a respeito da frequência de um sinal em torno de um certo local no tempo podemos aplicar a STFT [54], a qual mapeia o sinal em uma função de duas dimensões o tempo τ e a frequência ω [7].

A ideia por trás da STFT consiste em calcular a FT de um sinal $x(t)$ multiplicado por uma função janela $w(t - \tau)$, de forma a isolar o sinal em torno de $t = \tau$ antes de se calcular FT. Assim, para cada valor de τ , é obtido o espectro de $x(t)$ ao redor de $t = \tau$, ou seja,

$$STFT(\tau, \omega) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j\omega t} dt \quad (3.12)$$

A $STFT(\tau, \omega)$ é linear no sinal $x(t)$ e depende da escolha da função janela $w(t)$. Uma escolha comum para função janela $w(t)$ é a função Gaussiana, por estar concentrada em torno de $t = 0$ e $\omega = 0$ [6], seu comprimento pode ser estimado em ambos domínios por meio de seus respectivos desvios padrão σ_τ e σ_ω . Observando a Fig. 3.1 nota-se que a STFT analisa pedaços do sinal, com duração $2\sigma_\tau$, por meio de filtros de banda passante constante, igual a $2\sigma_\omega$.




Figura 3.1: Células de resolução no plano tempo/frequência.

Na STFT, a resolução no tempo e na frequência depende somente da escolha da função $w(t)$ [7]. Desta forma, uma janela de menor comprimento melhora a resolução no tempo ao custo de uma piora na resolução da frequência.

Tomando o princípio da incerteza [6], sempre que $w(t)$ cair mais rápido do que $1/\sqrt{t}$ para $t \rightarrow \pm\infty$, então

$$\sigma_\omega^2 \sigma_\tau^2 \geq \frac{1}{4} \quad (3.13)$$

A Eq. (3.13) mostra que existe um limite máximo de resolução que pode ser alcançado no eixo da frequência e do tempo.

A STFT possui uma versão para sinais de entrada discretos, denominada Transformada Discreta de Fourier em Janela (Windowed Discrete Fourier Transform - WDFT) e definida como [51]:

$$WDFT(k, m) = \sum_n x(n)w(n - m)e^{-j\frac{2\pi kn}{N}} dt, \text{ para } 0 \leq k \leq N - 1 \quad (3.14)$$

3.2.1 Limitações da STFT com Sinais de DP

O maior problema da STFT é que, apesar de mapear o sinal na frequência e no tempo, esta provê informações com uma resolução fixa, já que a função $w(t)$ tem que ser fixa. Tal comportamento se mostra indesejável com sinais altamente não estacionários, como ocorre com sinais de DP, que possuem características de tamanhos muito diferentes, necessitando de graus de resolução distintos. Desta maneira, para tratar sinais de DP, necessitamos de maior precisão no tempo para sinais de alta frequência com curta duração, bem como maior precisão na frequência para sinais de baixa frequência com longa duração [51].

Para superar estas limitações da STFT, é necessário uma transformada com diferentes tamanhos de janelas, de forma que se adapte às características do sinal a ser estudado. Esta necessidade pode ser atendida pela WT [55, 56].

3.3 Banco de Filtros

O processo de filtragem digital de sinais consiste na convolução das amostras do sinal de entrada $x(n)$ com as amostras da resposta ao impulso $h(n)$, de modo a obter um novo sinal $y(n)$ contendo os dados que se deseja analisar. Então, podemos escrever a saída de um filtro como:

$$y(n) = \sum_{k=0}^{n-1} h(k)x(n - k) \quad (3.15)$$

O grande desafio da aplicação de um filtro é determinar a resposta ao impulso para se obter o resultado esperado, de forma que remova interferências do sinal $x(n)$ [49].

Para aplicação de filtros digitais multi-taxas, são necessárias operações básicas como subamostragem (decimador) e sobreamostragem (interpolador).

3.3.1 Subamostragem

Subamostrar um sinal $x(n)$ por um fator M significa reduzir sua taxa de amostragem em M vezes. Portanto, a operação de decimação, representada na Fig. 3.2, pode ser escrita como

$$x_d(n) = x(nM) \quad (3.16)$$




Figura 3.2: Decimação por um fator M .

No domínio da frequência o espectro de $x_d(n)$ é composto de cópias do espectro de $x(k)$, expandidas por M e repetidas com período 2π . Este efeito resulta em perda de informação, sendo chamado de *aliasing*. Para evitar que isto ocorra devemos inserir um filtro passa-baixas antes do decimador, de forma a limitar o espectro ao intervalo de $[-\pi/M, \pi/M]$. Com o filtro, a operação de decimação, ilustrada na Fig. 3.3, é feita pela retenção das M -ésimas amostras da convolução do sinal com a resposta ao impulso $h_d(n)$ deste filtro, ou seja,

$$x_d(n) = \sum_{k=-\infty}^{\infty} x(k)h_d(nM - k) \quad (3.17)$$




Figura 3.3: Operação de decimação por um fator M , com filtro decimador.

3.3.2 Sobreamostragem

Sobreamostrar um sinal $x(n)$ por um fator L significa adicionar $L - 1$ zeros entre as suas amostras. Portanto, a relação de interpolação, representada na Fig. 3.4, pode ser escrita, conforme:

$$x'_i(n) = \begin{cases} x(n/L), & \text{se } n/L \in \mathbb{Z} \\ 0, & \text{caso contrário} \end{cases} \quad (3.18)$$




Figura 3.4: Interpolação por um fator L .

No domínio da frequência, o espectro de $x'_i(n)$ é composto de cópias comprimidas do espectro de $x(k)$ e repetidas com período $2\pi/L$. Para que o sinal $x'_i(n)$ não possua repetições em seu espectro, é necessário realizar a filtragem do espectro de $x'_i(n)$ fora do intervalo de $[-\pi/L, \pi/L]$, bastando inserir um filtro passa-baixas na saída do interpolador. Desta maneira, a operação de interpolação, mostrada na Fig. 3.5, pode ser expressa como

$$x_i(n) = \sum_{k=-\infty}^{\infty} x'_i(k)h(n - kL), \quad (3.19)$$




Figura 3.5: Operação de interpolação por um fator L , com filtro interpolador.

3.3.3 Bancos de Filtros de Reconstrução Perfeita de Dois Canais

Um banco de filtros de dois canais pode ser estruturado conforme mostrado na Fig. 3.6. Neste os filtros $H_0(z)$, $H_1(z)$, $G_0(z)$ e $G_1(z)$ devem ser projetados

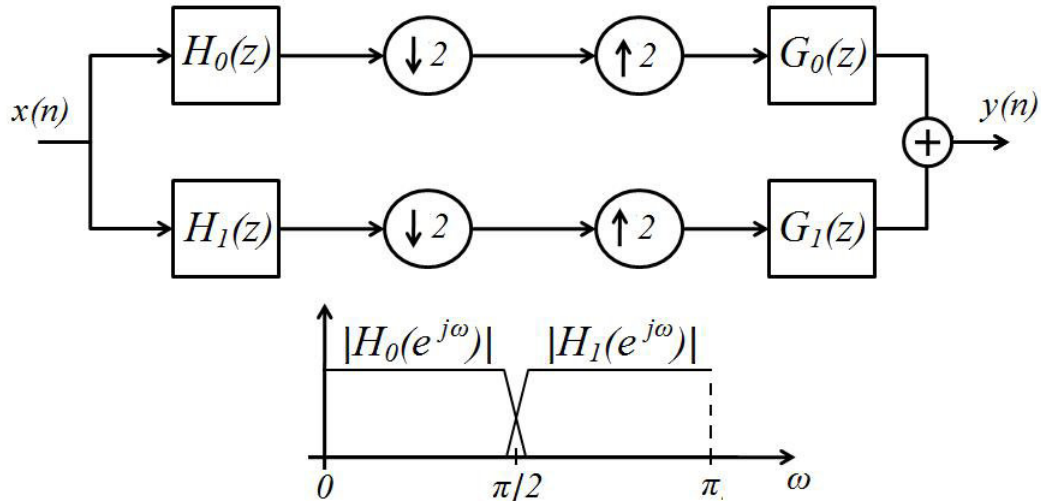


Figura 3.6: Banco de filtros de dois canais.

de modo que possam cancelar o efeito de sobreposição de seus espectros, fato que ocorre por não se tratarem de filtros ideais, gerando *aliasing*.

O banco exposto na Fig. 3.6 é comumente referido como maximamente (ou criticamente) decimado, pois o fator de decimação e de interpolação L , é igual ao número de subbandas M . O termo maximamente se deve ao fato de que este é o limite máximo para evitar perda de informação devido a *aliasing*. Portanto, uma das condições para que o banco de filtros possa ser dito de reconstrução perfeita é que $L \leq M$.

O banco de filtros pode ser expresso em termos de seus componentes polifásicos [6, 57, 58], usando:

$$H_k(z) = \sum_{j=0}^{M-1} z^{-j} E_{kj}(z^M) \quad (3.20)$$

$$G_k(z) = \sum_{j=0}^{M-1} z^{-(M-1-j)} R_{kj}(z^M) \quad (3.21)$$

Então, para o banco de dois canais maximamente decimado, temos

$$H_0(z) = E_{00}(z^2) + z^{-1}E_{01}(z^2) \quad (3.22)$$

$$H_1(z) = E_{10}(z^2) + z^{-1}E_{11}(z^2) \quad (3.23)$$

$$G_0(z) = z^{-1}R_{00}(z^2) + R_{10}(z^2) \quad (3.24)$$

$$G_0(z) = z^{-1}R_{01}(z^2) + R_{11}(z^2) \quad (3.25)$$

Tomando as Eqs. (3.22)a(3.25), podemos obter as matrizes $\mathbf{R}(z)$ e $\mathbf{E}(z)$ com se segue:

$$\mathbf{R}(z) = \begin{bmatrix} R_{00}(z) & R_{01}(z) \\ R_{10}(z) & R_{11}(z) \end{bmatrix} \quad (3.26)$$

$$\mathbf{E}(z) = \begin{bmatrix} E_{00}(z) & E_{01}(z) \\ E_{10}(z) & E_{11}(z) \end{bmatrix} \quad (3.27)$$

Generalizando para mais canais, a condição $\mathbf{R}(z)\mathbf{E}(z) = \mathbf{I}$, onde \mathbf{I} é a matriz identidade, garante perfeita reconstrução para um banco de filtros de M -canais [6, 57]. Como o sinal de saída tem de ser igual ao sinal de entrada atrasado, então:

$$\mathbf{R}(z)\mathbf{E}(z) = \mathbf{I}z^{-\Delta} \quad (3.28)$$

ainda é uma condição que garante a reconstrução perfeita, com um atraso total igual a $M\Delta + (M - 1)$.

Substituindo as Eqs. (3.26) e (3.27) em (3.28), e isolando a matriz $\mathbf{R}(z)$ temos:

$$\begin{bmatrix} R_{00}(z) & R_{01}(z) \\ R_{10}(z) & R_{11}(z) \end{bmatrix} = \frac{z^{-\Delta}}{E_{00}(z)E_{11}(z) - E_{10}(z)E_{01}(z)} \begin{bmatrix} E_{00}(z) & -E_{01}(z) \\ -E_{10}(z) & E_{11}(z) \end{bmatrix} \quad (3.29)$$

Para implementação de filtros de Resposta ao Impulso Finita (Finite Impulse Response - FIR), que será aplicado em WT, o denominador deve ser proporcional a um atraso l puro, assim:

$$E_{00}(z)E_{11}(z) - E_{10}(z)E_{01}(z) = cz^{-l} \quad (3.30)$$

A partir das Eqs. (3.26) e (3.27) é possível reescrever a Eq. (3.30) em termo de seus filtros:

$$H_0(-z)H_1(z) - H_0(z)H_1(-z) = 2cz^{-(2l+1)} \quad (3.31)$$

Substituindo a Eq. (3.30) na Eq. (3.29), e calculando $G_0(z)$ e $G_1(z)$ com as Eqs. (3.24) e (3.25), temos que:

$$G_0(z) = -\frac{z^{2(l+\Delta)}}{c}H_1(-z) \quad (3.32)$$

$$G_1(z) = -\frac{z^{2(l+\Delta)}}{c}H_{10}(-z) \quad (3.33)$$

Assumindo um polinomial $P(z) = H_0(z)H_1(-z)$, o projeto de um filtro de reconstrução perfeita de dois canais deve seguir [Vertelli and kovacevic, 1995]:

1. Determinar $P(z)$ tal que $P(-z) - P(z) = 2cz^{-2l-1}$;
2. Fatorar $P(z)$ para obter $H_0(z)$ e $H_1(-z)$, garantindo que estes sejam filtros passa-baixas;
3. Encontrar $G_0(z)$ e $G_1(z)$ usando as Eqs. (3.32) e (3.33).

É interessante verificar que a resposta em magnitude $|G_0(e^{j\omega})|$ e $|H_1(e^{j\omega})|$ são imagens espelhadas uma da outra em torno de $\omega = \pi/2$. O mesmo ocorre com $|H_0(e^{j\omega})|$ e $|G_1(e^{j\omega})|$. Além do mais, para o caso em que o banco de filtro seja composto por filtros FIR de fase linear, basta encontrar um filtro de fase linear $P(z)$ e realizar sua fatorização em função de fase linear. Neste caso $P(z) - P(-z) = 2cz^{-2l-1}$.

Uma técnica amplamente aplicada é um banco de filtros FIR de dois canais denominado Filtro com Espelhamento em Quadratura (Quadrature Mirror Filter - QMF), discutido a seguir.

3.3.4 Banco de Filtros QMF

Considerando o banco de filtros de dois canais da Fig. 3.6, é possível determinar a relação entre a entrada e a saída do filtro no domínio z , dada por

$$Y(z) = \frac{1}{2}[H_0(z)G_0(z) + H_1(z)G_1(z)]X(z) + \frac{1}{2}[H_0(-z)G_0(z) + H_1(-z)G_1(z)]X(-z) \quad (3.34)$$

O efeito de *aliasing* ocorre em função de $X(-z)$. Conforme discutido na Seção 3.3.3, para obter reconstrução perfeita, o sinal de saída deve ser uma versão atrasada da entrada e a componente de *aliasing* deve ser anulada, o que implica em:

$$H_0(z)G_0(z) + H_1(z)G_1(z) = 2z^{-l} \quad (3.35)$$

$$H_0(-z)G_0(z) + H_1(-z)G_1(z) = 0 \quad (3.36)$$

No banco de filtros QMF, o filtro passa-altas de análise $H_1(z)$ é projetado para alternar os sinais das amostras da resposta ao impulso do filtro passa-baixas, o qual é escolhido como um filtro de fase linear de N -ésima ordem. Desta forma,

$$H_1(z) = H_0(-z) \quad (3.37)$$

A Eq. 3.37 implica em dizer que a resposta em magnitude do filtro passa-altas $|H_1(e^{j\omega})|$ é a imagem espelhada da resposta em magnitude do filtro passa-baixas $|H_0(e^{j\omega})|$ com relação à frequência de quadratura $\pi/2$. Tal propriedade explica o nome dado a este tipo de banco de filtros.

Para atender a Eq. (3.36), os filtros de síntese são escolhidos de acordo com:

$$G_0(z) = H_0(-z) = H_1(-z) \quad (3.38)$$

$$G_1(z) = -H_0(-z) = -H_1(z) \quad (3.39)$$

Portanto, substituindo as Eqs. (3.35) e (3.36) na Eq. (3.34), a função de transferência geral será dada por

$$H(z) = \frac{1}{2}[H_0(z)G_0(z) + H_1(z)G_1(z)] = \frac{1}{2}[H_0(z)H_1(-z) - H_1(z)H_0(-z)] \quad (3.40)$$

$$H(z) = \frac{1}{2}[H_0^2(z) - H_0^2(-z)] \quad (3.41)$$

Aplicando a decomposição polifásica do filtro passa-baixas $H_0(z) = E_{00}(z) + z^{-1}E_{01}(z^2)$, podemos escrever:

$$H(z) = 2z^{-1}E_{00}(z^2)E_{01}(z^2) \quad (3.42)$$

A Eq. (3.42) evidencia que a reconstrução perfeita é alcançada se os componentes polifásicos do filtro passa-baixas são simples atrasos, limitando a seletividade dos filtros gerados. Por isso no projeto de filtros QMF geralmente se usa uma solução aproximada, em que $H_0(z)$ é escolhido como um filtro de fase linear, eliminando distorções de fase sobre a função de transferência $H(z)$ [6].

Outra propriedade do banco QMF é sua implementação eficiente por causa de sua estrutura modulada, onde os filtros passa-altas e passa-baixas estão relacionados [58].

3.4 Transformada Wavelet

Uma função wavelet é uma “pequena onda” em formato oscilante, que possui sua energia finita concentrada num ponto, para proporcionar uma ferramenta de análise de fenômenos transientes, não estacionários ou variantes no tempo, como é o caso de sinais de DP. Ela detém a habilidade de permitir a avaliação simultânea das componentes do sinal em intervalos não-uniformes de tempo e frequência [49].

3.4.1 Transformada Wavelet Contínua no Tempo

A WT de uma função contínua no tempo e pertencente ao espaço das funções de quadrado integrável $\mathcal{L}^2(\mathbb{R})$, isto é, com média zero, duração limitada e energia finita, é sua decomposição em uma base formada por expansões (compressões e dilatações) e translações de uma única função chamada wavelet mãe $\psi(t)$. As funções da base são definidas como [6, 58]

$$\psi_{b,a}(t) = \frac{1}{\sqrt{|a|}}\psi\left(\frac{t-b}{a}\right) \quad (3.43)$$

Sendo a CWT de uma função $x(t)$ dada por [58]:

$$W_\psi(b, a) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t)\psi^*\left(\frac{t-b}{a}\right) dt, \quad a, b \in \mathbb{R}, \quad a \neq 0 \quad (3.44)$$

A função $\psi(t)$ no domínio da frequência $\Psi(\omega)$ deve ser uma função passa-banda,

para garantir que possua energia finita e média zero, conforme citado em [58] e demonstrado a seguir [59]:

Assumindo que as wavelets sejam reais, pelo teorema de Parseval, a integral da Eq. (3.44), pode ser obtida no domínio FT:

$$W_\psi(b, a) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(\omega) \Psi_{b,a}^*(\omega) d\omega \quad (3.45)$$

O sinal $x(t)$ pode ser recuperado pela sua Transformada Wavelet Contínua Inversa (*Inverse Continuous Wavelet Transform* - ICWT), dada por:

$$x(t) = C_\psi^{-1} \int_0^\infty \int_{-\infty}^{\infty} W_\psi(b, a) \psi_{b,a}(t) \frac{da db}{a^2} \quad (3.46)$$

Para assegurar que o sinal seja perfeitamente reconstruído a partir de sua representação na WT é preciso que se atenda à condição de admissibilidade

$$C_\psi^{-1} = 2\pi \int_0^\infty \frac{|\Psi(\omega)|^2}{|\omega|} d\omega = 2\pi \int_{-\infty}^0 \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (3.47)$$

Para que a Eq. (3.47) seja satisfeita,

$$\Psi(0) = \int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (3.48)$$

Portanto, a resposta ao impulso da wavelet deve ser do tipo passa-banda, com $|\Psi(\omega)|$ decaindo rapidamente quando $|\omega| \rightarrow 0$ e quando $|\omega| \rightarrow \infty$. Tal resposta em frequência advém de uma pequena onda no domínio do tempo, como ilustrada na Fig. 3.7, o que justifica o nome de transformada wavelet.

A partir da Eq. (3.44) percebemos que, ao se variar o parâmetro a (fator de escala), a forma de onda da wavelet se altera proporcionalmente no domínio do tempo, o que gera uma variação inversamente proporcional no domínio da frequência. O parâmetro b (operador de translação) realiza o deslocamento (translação) da wavelet no tempo. Desta maneira, a CWT pode ser reescrita como

$$W_\psi(b, a) = \frac{1}{\sqrt{|a|}} x(t) * \psi^* \left(\frac{-t}{a} \right) \quad (3.49)$$

O termo $|a|^{-1/2}$ é inserido para assegurar que todas as funções escaladas tenham

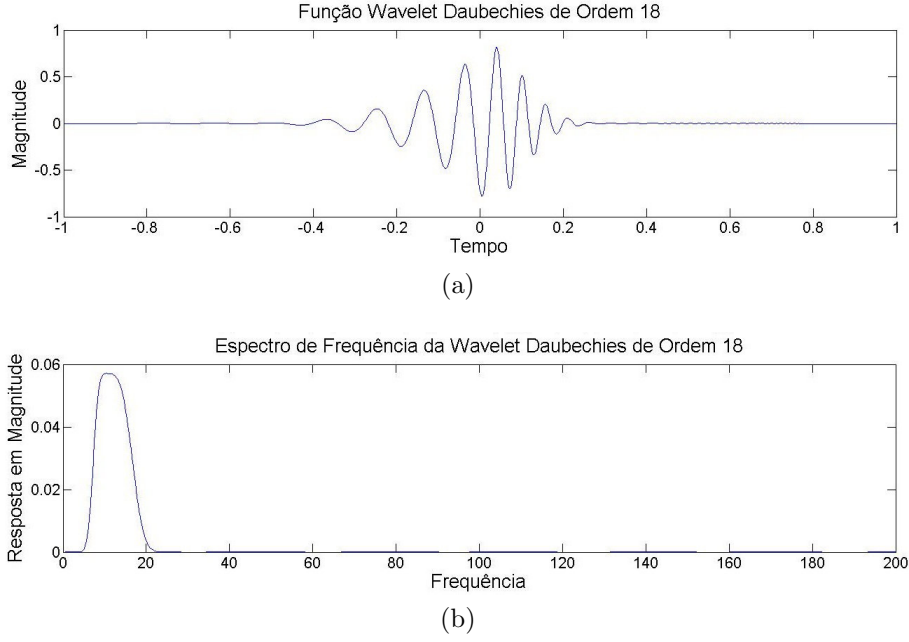


Figura 3.7: Exemplo de função wavelet: (a) no domínio do tempo; (b) no domínio da frequência.

a mesma energia [58].

Resolução Tempo x Frequência

Como foi feito para a STFT, também é possível determinar para a CWT as variâncias de $\psi(t)$ e das frequências positivas de $\Psi(\omega)$ [60].

$$\sigma_b^2 = \frac{\int_{-\infty}^{\infty} (t - t_0)^2 |\psi(t)|^2 dt}{\int_{-\infty}^{\infty} |\psi(t)|^2 dt} \quad (3.50)$$

$$\sigma_\omega^2 = \frac{\int_{-\infty}^{\infty} (\omega - \omega_0)^2 |\Psi(\omega)|^2 d\omega}{\int_{-\infty}^{\infty} |\Psi(\omega)|^2 d\omega} \quad (3.51)$$

Concluimos que o desvio padrão de $\psi_{b,a}(t)$ e sua TF são, respectivamente, $a\sigma_b$ e σ_ω/a e que a frequência central e a banda passante de $\Psi_{b,a}(\omega)$ são iguais a ω_0/a e $2\sigma_\omega/a$. Isso mostra que a WT provê informações sobre o sinal $x(t)$ versus seu espectro $X(\omega)$ dentro de um intervalo de tempo e frequência

$$[b + a.t_0 - a.\sigma_b, b + a.t_0 + a.\sigma_b] \times \left[\frac{\omega_0}{a} - \frac{\sigma_\omega}{a}, \frac{\omega_0}{a} + \frac{\sigma_\omega}{a} \right] \quad (3.52)$$

Da Eq. (3.52) percebemos que quanto maior o valor de a menor será a resolução no tempo e maior a resolução na frequência. A Fig. 3.8 ilustra as células de resolução da WT. Portanto, a wavelet é desejável para análise de sinais com características

de frequência de durações distintas, para as quais existe um valor ótimo de fator de escala que as represente.




Figura 3.8: Células de resolução tempo x frequência para WT.

3.4.2 Amostragem Diádica da CWT

Como citado na seção anterior, à medida que o fator de escala aumenta a resolução na frequência diminui, necessitando de uma maior quantidade de células para suprir a região do plano $\omega \times b$, verificar Eq. (3.52). Podemos, então, discretizar tal fator como $a = a_0^m$, para $a_0 > 1$, $m \in \mathbb{Z}$. Já a discretização do operador de translação pode ser feita considerando $b = nb_0 a_0^m$, e substituindo os valores amostrados nas Eqs. (3.43) e (3.44), ou seja

$$\psi_{m,n}(t) = \frac{1}{\sqrt{|a_0^m|}} \psi\left(\frac{t - nb_0 a_0^m}{a_0^m}\right) = a_0^{-m/2} \psi(a_0^{-m} t - nb_0) \quad (3.53)$$

$$W_\psi(m, n) = a_0^{-m/2} \int_{-\infty}^{\infty} \psi_{m,n}^*(t) x(t) dt \quad (3.54)$$

Restringindo os pontos amostrados ao caso diádico, ou seja, fazendo $a_0 = 2$ e $b_0 = 1$, algumas funções $\psi_{m,n}(t)$, $m, n \in \mathbb{Z}$ permitem a reconstrução de todos os sinais $x(t)$ pertencentes ao $\mathcal{L}^2(\mathbb{R})$. Podemos, então, expressar qualquer função $x(t) \in \mathcal{L}^2(\mathbb{R})$ como

$$x(t) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} c_{m,n} \psi_{m,n}(t), \quad (3.55)$$

$$c_{m,n} = \int_{-\infty}^{\infty} \psi_{m,n}^*(t) x(t) dt \quad (3.56)$$

onde $c_{m,n}$ representa os coeficientes da WT do sinal $x(t)$. A Fig. 3.9 mostra a amostragem diádica da WT, onde é notável que para cada incremento de m o valor a dobra, ou seja, dobra-se o comprimento no domínio do tempo e divide-se pela metade (uma oitava) o comprimento na frequência.




Figura 3.9: Amostragem diádica da WT.

Ortonormalidade e Biortogonalidade da DWT

Para $x(t) = \psi_{k,l}(t)$, temos que:

$$\psi_{k,l}(t) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} c_{m,n} \psi_{m,n}(t). \quad (3.57)$$

A igualdade acima só será verdadeira se $c_{m,n} = \delta(m - k)\delta(n - l)$, de modo que:

$$\int_{-\infty}^{\infty} \psi_{m,n}^*(t) \psi_{k,l}(t) dt = \delta(m - k)\delta(n - l). \quad (3.58)$$

Portanto, $\psi_{m,n}(t)$, $m, n \in \mathbb{Z}$ será uma wavelet ortonormal de $\mathcal{L}^2(\mathbb{R})$, podendo ser aplicada em ambas etapas de análise e de síntese. A Eq. (3.58) representa a condição de ortonormalidade e é normalmente expressa pelo produto interno [6, 58]

$$\langle \psi_{k,l}(t), \psi_{m,n}(t) \rangle = \delta(m-k)\delta(n-l). \quad (3.59)$$

Não se pode assumir que qualquer conjunto de $\psi_{m,n}(t)$, $m, n \in \mathbb{Z}$ permita a reconstrução de todos os sinais $x(t) \in \mathcal{L}^2(\mathbb{R})$ [58]. Para que isso ocorra, um conjunto dual $\bar{\psi}_{m,n}(t)$, $m, n \in \mathbb{Z}$ deve existir, e tanto $\psi_{m,n}(t)$ quanto $\bar{\psi}_{m,n}(t)$ devem ocupar o espaço $\mathcal{L}^2(\mathbb{R})$. Os conjuntos podem ser expressos por suas wavelets de análise $\psi_{m,n}(t)$ e síntese $\bar{\psi}_{m,n}(t)$, como se segue

$$\psi_{m,n}(t) = a_0^{-m/2} \psi(2^{-m}t - n) \quad (3.60)$$

$$\bar{\psi}_{m,n}(t) = a_0^{-m/2} \bar{\psi}(2^{-m}t - n) \quad (3.61)$$

Neste caso, qualquer $x(t) \in \mathcal{L}^2(\mathbb{R})$ poderá ser escrito como,

$$x(t) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} c_{m,n} \bar{\psi}_{m,n}(t), \quad (3.62)$$

Apesar de nenhuma das funções serem ortogonais, as funções $\psi_{m,n}(t)$ são ortogonais a $\bar{\psi}_{m,n}(t)$, ou seja,

$$\langle \psi_{m,n}(t), \bar{\psi}_{k,l}(t) \rangle = \delta(m-k)\delta(n-l). \quad (3.63)$$

Wavelets que atendem a Eq. (3.63) são ditas biortogonais.

3.4.3 Análise Multirresolução

A análise multirresolução da transformada wavelet, desenvolvida por Daubechies [60, 61], busca fazer a avaliação do sinal em diferentes níveis de resolução, obtidos de um sistema de banco de filtros, que separa o sinal em espaços contendo informações aproximadas e detalhadas do mesmo.

Considerando uma função escala $\phi(t)$, mostrada na Eq. (3.64), com um conjunto $\phi(t-n)$, $n \in \mathbb{Z}$ ortonormal, gera um espaço definido como V_0 . De modo

similar, $2^{-m/2}\phi(2^{-m}t - n)$ gera um espaço V_m .

$$\phi(t) = \sum_{n=-\infty}^{\infty} c(n)\sqrt{2}\phi(2t - n) \quad (3.64)$$

onde $\sqrt{2}\phi(2t - n)$ também será ortonormal e $c(n)$ é dado por:

$$c(n) = \int_{-\infty}^{\infty} \phi(t)\sqrt{2}\phi^*(2t - n)dt \quad (3.65)$$

Então, se considerarmos $i, j \in \mathbb{Z}$ para $i > j$, existirão constantes $\alpha^{ij}(n)$ tal que

$$\phi(2^{-i}t) = \sum_{n=-\infty}^{\infty} \alpha^{ij}(n)\phi(2^{-j}t - n) \quad (3.66)$$

Podemos concluir que as funções que geram o espaço V_i estão contidas em V_j , ou seja, em cada nível o processo de decomposição cria um espaço que conterà os espaços gerados na próxima decomposição, assim:

$$\cdots \supset V_{-2} \supset V_{-1} \supset V_0 \supset V_1 \supset \cdots \quad (3.67)$$

Quanto maior o espaço gerado maior será sua resolução. Portanto, um aumento do índice do espaço implicará em uma redução da resolução. A função também deve atender a seguinte relação:

$$\bigcup_{j=-\infty}^{\infty} V_j = \mathcal{L}_2(\mathbb{R}) \quad (3.68)$$

$$\bigcap_{j=-\infty}^{\infty} V_j = \{0\} \quad (3.69)$$

Seja a variável W_j designada como o espaço formado pelo complemento ortogonal de V_j em V_{j-1} , i.e., a quantidade de detalhe adicionado quando aumentamos a resolução indo do espaço V_j para V_{j-1} , temos que

$$V_j \perp W_j \quad (3.70)$$

$$V_{j-1} = V_j \oplus W_j \quad (3.71)$$

A Eq. (3.70) mostra que todos os membros de V_j serão ortogonais a W_j . Já a Eq. (3.71) indica que a soma ortogonal dos espaços V_j e W_j dará origem a um espaço V_{j-1} com maior resolução, ou seja, com maior largura de banda. A Fig. 3.10 ilustra uma representação geométrica dos espaços multirresolução, o que facilita a compreensão do processo de análise multirresolução.




Figura 3.10: Representação geométrica dos espaços multirresolução.

Como ilustrado na Fig. 3.10, qualquer função $d(t) \in W_j$ também pertence a V_{j-1} . Assim, a função pode ser representada por:

$$g(t) = \sum_{n=-\infty}^{\infty} d(n) \sqrt{2} \phi(2t - n) \quad (3.72)$$

Já que a wavelet reside no espaço V_{j-1} , é possível representar a wavelet como

$$\psi(t) = \sum_{n=-\infty}^{\infty} (-1)^n c(1-n) \sqrt{2} \phi(2t - n) \quad (3.73)$$

Analisando a Fig. 3.10 podemos notar que o espaço $\mathcal{L}_2(\mathbb{R})$ é formado pela soma ortogonal dos espaços W_j , ou seja,

$$\mathcal{L}_2(\mathbb{R}) = \dots W_{-2} \oplus W_{-1} \oplus W_0 \oplus W_1 \oplus \dots \quad (3.74)$$

Podemos dizer que o espaço $\mathcal{L}_2(\mathbb{R})$ é formado pela soma ortogonal do espaço V_j e os demais espaços de detalhe $W_j, W_{j-1}, W_{j-2}, \dots$:

$$\mathcal{L}_2(\mathbb{R}) = V_j \oplus W_j \oplus W_{j-1} \oplus W_{j-2} \oplus \dots \quad (3.75)$$

Segundo Daubechies [62] $\psi_{m,n}(t) = 2^{-m/2}\phi(2^{-m}t - n)$, para todo $m, n \in \mathbb{Z}$ forma uma base ortonormal para W_m , conseqüentemente as funções $\psi(t - n)$ serão ortogonais às funções $\phi(t - m)$. Levando em consideração a Eq. (3.74), verificamos que $\psi_{m,n}(t)$ também constitui uma base ortonormal de $\mathcal{L}_2(\mathbb{R})$.

Portanto, qualquer função que pertença ao $\mathcal{L}_2(\mathbb{R})$ pode ser escrita da maneira indicada nas Eqs. (3.55) e (3.56), as quais representam a DWT de $f(t)$ com wavelet mãe $\psi(t)$. Os coeficientes da WT $d_m(n)$ correspondem à projeção da função sobre um espaço detalhe W_m de resolução m . Desta forma, podemos dizer que a WT faz a decomposição de um sinal em espaços de diferentes resoluções, justificando o nome de decomposição multirresolução.

$$f(t) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} d_m(n)\psi_{m,n}(t) \quad (3.76)$$

$$d_m(n) = \int_{-\infty}^{\infty} \psi_{m,n}^*(t) x(t) dt \quad (3.77)$$

A transformada wavelet discreta ortogonal possui a desvantagem de não apresentar fase linear [63]. Para atingir a linearidade na fase é necessário utilizar a transformada wavelet biortogonal.

Representação Biortogonal

São definidas wavelets de análise $\psi(t)$ e de síntese $\bar{\psi}(t)$ distintas, com suas funções de escala definidas como $\phi(t)$ e $\bar{\phi}(t)$, respectivamente. De maneira análoga ao caso ortogonal, definimos:

$$\phi(t) = \sum_{n=-\infty}^{\infty} c(n)\sqrt{2}\phi(2t - n) \quad (3.78)$$

$$\bar{\phi}(t) = \sum_{n=-\infty}^{\infty} c(n)\sqrt{2}\bar{\phi}(2t - n) \quad (3.79)$$

Supondo que

$$\langle 2^{-m/2}\phi(2^{-m}t - n), 2^{-m/2}\bar{\phi}(2^{-m}t - k) \rangle = \delta(n - k) \quad (3.80)$$

temos

$$c(n) = \int_{-\infty}^{\infty} \phi(t)\sqrt{2}\bar{\phi}^*(2t - n)dt \quad (3.81)$$

$$\bar{c}(n) = \int_{-\infty}^{\infty} \bar{\phi}(t)\sqrt{2}\phi^*(2t - n)dt \quad (3.82)$$

As funções $\phi(t)$ e $\bar{\phi}(t)$ geram dois subespaços como o gerado na Eq. (3.67). Analogamente a Eqs. (3.70) e (3.71), podemos definir:

$$V_j \perp \bar{W}_j \text{ e } \bar{V}_j \perp W_j \quad (3.83)$$

$$\bar{V}_{j-1} = \bar{V}_j + \bar{W}_j \quad (3.84)$$

$$V_{j-1} = V_j + W_j \quad (3.85)$$

Como os subespaços $W_j \in V_{j-1}$ e $\bar{W}_j \in \bar{V}_{j-1}$, $\psi(t)$ e $\bar{\psi}(t)$ podem ser escritas como

$$\psi(t) = \sum_{n=-\infty}^{\infty} \left(\int_{-\infty}^{\infty} \psi(t)\sqrt{2}\bar{\phi}^*(2t - n)dt \right) \sqrt{2}\phi(2t - n) \quad (3.86)$$

$$\bar{\psi}(t) = \sum_{n=-\infty}^{\infty} \left(\int_{-\infty}^{\infty} \bar{\psi}(t)\sqrt{2}\phi^*(2t - n)dt \right) \sqrt{2}\bar{\phi}(2t - n) \quad (3.87)$$

De forma análoga a Eq. (3.60), temos que

$$\mathcal{L}_2(\mathbb{R}) = \dots \bar{W}_{-2} \oplus \bar{W}_{-1} \oplus \bar{W}_0 \oplus \bar{W}_1 \oplus \dots \oplus \bar{W}_j \oplus \dots \quad (3.88)$$

A Eq. (3.88) acima mostra que uma WT biortogonal envolve a projeção de uma função sobre os espaços detalhe \bar{W}_j [62].

Decomposição do Sinal

Com base na relação exposta na Eq. (3.75), qualquer função $x(t) \in \mathcal{L}_2(\mathbb{R})$ pode ser expandida em termos de seus coeficientes gerados pela função escala $\phi(t)$

e pela função wavelet mãe $\psi(t)$:

$$x(t) = \sum_n c_{m_j}(n) \phi_{m_j,n}(t) + \sum_{m=m_j}^{\infty} \sum_n d_m(n) \psi_{m,n}(t) \quad (3.89)$$

A escolha da escala m_j determina uma escala grosseira de aproximação final, cujo espaço V_j é gerado por $\phi_{m_j,n}(t)$. Já o restante do espaço $\mathcal{L}_2(\mathbb{R})$ é gerado pelas wavelets, $\psi_{m,n}(t)$ que provêm detalhes de alta resolução do sinal $x(t)$.

Os coeficientes gerados na expansão wavelet podem descrever completamente o sinal original e ser utilizados para análise, descrição, aproximação e filtragem. Se a wavelet é ortogonal, os coeficientes são dados por:

$$c_m(n) = \langle x(t), \phi_{m,n}(t) \rangle = \int x(t) \phi_{m,n}(t) dt \quad (3.90)$$

$$d_m(n) = \langle x(t), \psi_{m,n}(t) \rangle = \int x(t) \psi_{m,n}(t) dt \quad (3.91)$$

A Eq. (3.89) corresponde à decomposição do sinal numa sucessiva filtragem passa-baixas acompanhada pela separação de sinais passa-banda [58].

Teorema de Parseval

A energia de um sinal $x(t)$ corresponde a energia existente em cada um dos seus coeficientes wavelet quando a função escala forma uma base ortonormal com a wavelet mãe aplicada no processo de decomposição. Isto mostra que a ortonormalidade é uma característica importante.

Transcrevendo a definição anterior temos [58]:

$$\int |x(t)|^2 dt = \sum_{l=-\infty}^{\infty} |c(l)|^2 + \sum_{m=0}^{\infty} \sum_{n=-\infty}^{\infty} |d_m(n)|^2 \quad (3.92)$$

com a energia sendo particionada no tempo por n e em escala por m entre os coeficientes de aproximação e de detalhe.

Também é importante notarmos que tal igualdade não se mantém quando a wavelet utilizada é biortogonal.

3.4.4 Transformada Wavelet Discreta e Banco de Filtros

Os coeficientes obtidos em um nível mais alto de escala estão relacionados a seus coeficientes em uma escala mais baixa. Considerando que o espaço V_j é gerado pelas funções $2^{-j/2}\phi(2^{-j}t - n)$ com um tempo de amostragem $t_a = 2^j n$ e sendo $\phi(t) = \sum_{n=-\infty}^{\infty} h(n)\sqrt{2}\phi(2t - n)$, temos que

$$2^{-j/2}\phi(2^{-j}t - k) = \sum_{n=-\infty}^{\infty} h(n)\sqrt{2}\phi(2^{1-j}t - 2k - n) \quad (3.93)$$

Tomando a função $x_1(t) \in V_j$ e os coeficientes de aproximação $c_j(k)$ gerados pela filtragem de um sinal $x(t)$, podemos escrever

$$x_{1j}(t) = \sum_{k=-\infty}^{\infty} c_j(k)2^{-j/2}\phi(2^{-j}t - k) \quad (3.94)$$

Com base na Eq. (3.65),

$$c_j(k) = \sum_{n=-\infty}^{\infty} h^*(n) \int_{-\infty}^{\infty} x(t)2^{(1-j)/2}\phi^*(2^{1-j}t - 2k - n) dt \quad (3.95)$$

Portanto, os coeficientes de aproximação $c_j(k)$ em resolução 2^{-j} são gerados a partir da filtragem e subamostragem por um fator 2 (decimação com $M = 2$) de seus coeficientes de aproximação anteriores, ou seja, em uma resolução mais alta 2^{1-j} . Portanto, ao definir o filtro $h_0(n) = h^*(-n)$, podemos reescrever a Eq. (3.95), como

$$c_j(k) = \sum_{n=-\infty}^{\infty} h_0(n)c_{j-1}(2k - n) \quad (3.96)$$

Para definir os coeficientes de detalhe $d_j(k)$, é necessário analisar o espaço W_j gerado pelas funções $2^{-j/2}\psi(2^{-j}t - n)$, onde a função wavelet $\psi(t) = 2^{-j/2}\psi(2^{-j}t - n)$. Analogamente ao processo desenvolvido para encontrar os coeficientes de aproximação, podemos definir a função $x_{2j}(t) \in W_j$ e os coeficientes $d_j(k)$, como

$$x_{2j}(t) = \sum_{k=-\infty}^{\infty} d_j(k)2^{-j/2}\psi(2^{-j}t - k) \quad (3.97)$$

$$d_j(k) = \sum_{n=-\infty}^{\infty} h_1(n)c_{j-1}(2k-n) \quad (3.98)$$

Ao recorrer à Seção 3.3, percebemos que as Eqs. (3.96) e (3.98) implementam tanto a etapa de subamostragem quanto a etapa de filtragem, onde $h_1(n) = h^*(-n)$, corresponde a um filtro digital FIR. Da mesma forma os coeficientes de detalhe $d_j(k)$ também são determinados a partir da filtragem por $h_1(n)$ e subamostragem por um fator de 2 dos coeficientes de aproximação anteriores $c_{j-1}(k)$. Isso nos mostra que a DWT de um sinal $x(t)$ pode ser obtida de forma recursiva pelas Eqs. (3.96) e (3.98). É notável que os coeficientes $c_j(k)$ e $d_j(k)$ possuirão a metade da taxa de amostragem do coeficiente $c_{j-1}(k)$.

A Fig. 3.11 ilustra a árvore de análise wavelet formada por J estágios de banco de filtros de dois canais, discutidos anteriormente na Seção 3.3. O primeiro estágio, divide igualmente o espectro de frequência de $c_{j-1}(k)$ em uma banda passa-baixas e em uma passa-altas, resultando nos coeficientes escala e nos coeficientes wavelet em uma escala menor $c_j(k)$ e $d_j(k)$. No segundo estágio o espectro é dividido em uma banda passa-baixas e uma passa-faixa, para níveis maiores de decomposição o processo de divisão continuaria. A Fig. 3.12 mostra a divisão do espectro do sinal de entrada, onde para cada escala j o sinal tem seu espectro de frequência dividido ao meio, mantendo constante a relação entre o comprimento da banda passante e a frequência central, ou seja, o fator de qualidade Q se mantém constante durante toda a decomposição. Observe que também ocorre a sobreposição do espectro nas extremidades da banda passante dos filtros (*aliasing*), já que estes nunca serão ideais.

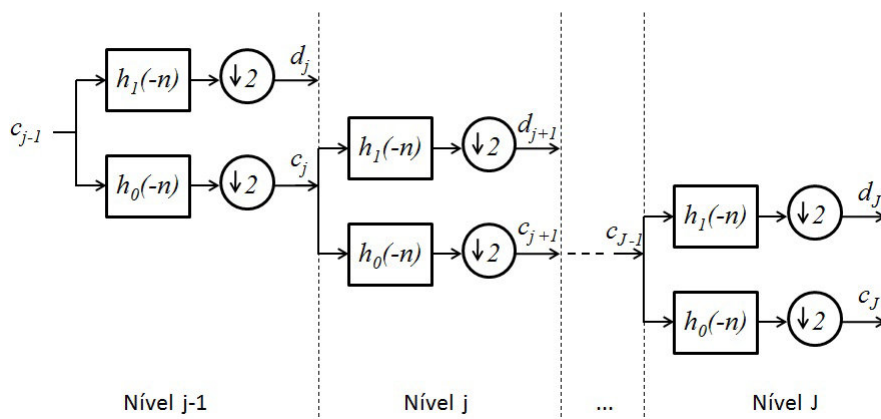


Figura 3.11: Árvore de análise wavelet formada por J estágios de dois canais.

O processo de decomposição wavelet também é denominado decomposição em oitavas, por reduzir pela metade a banda passante do espectro a cada escala.

A reconstrução do sinal original a partir dos coeficientes gerados durante o




Figura 3.12: Divisão do espectro de frequência da árvore de análise wavelet.

processo de análise de um sinal $x(t)$ pode ser feita a partir de uma combinação da função escala e da wavelet mãe. Já que o espaço $V_{j-1} = V_j \oplus W_j$, podemos descrever a projeção $c_{j-1}(k)$ do sinal $x(t)$ sobre V_{j-1} como

$$c_{j-1}(t) = \sum_{k=-\infty}^{\infty} c_{j-1}(k) 2^{(1-j)/2} \phi(2^{1-j}t - k) \quad (3.99)$$

$$c_{j-1}(t) = x_{1_j}(t) + x_{2_j}(t) \quad (3.100)$$

ou em termos da próxima escala, como

$$c_{j-1}(t) = \sum_{k=-\infty}^{\infty} c_j(k) 2^{-j/2} \phi(2^{-j}t - k) + \sum_{k=-\infty}^{\infty} d_j(k) 2^{-j/2} \psi(2^{-j}t - k) \quad (3.101)$$

Substituindo as Eqs. (3.64) e (3.73) na Eq. (3.101), obtemos

$$\begin{aligned} c_{j-1}(k) &= \sum_{k=-\infty}^{\infty} c_j(k) \sum_{l=-\infty}^{\infty} h(n) 2^{(1-j)/2} \phi(2^{1-j}t - 2k - n) \\ &+ \sum_{k=-\infty}^{\infty} d_j(k) \sum_{l=-\infty}^{\infty} h_1(n) 2^{(1-j)/2} \phi(2^{1-j}t - 2k - n) \end{aligned} \quad (3.102)$$

Admitindo que as funções sejam ortonormais e multiplicando as Eqs. (3.99) e (3.102) por $\phi(2^{1-j}t - 2k - n)$ e definindo $g_0(n) = h(n)$ e $g_1(n) = h_1(n)$, temos que:

$$c_{j-1}(l) = \sum_{k=-\infty}^{\infty} c_j(k) g_0(l - 2k) + \sum_{k=-\infty}^{\infty} d_j(k) g_1(l - 2k) \quad (3.103)$$

A Eq. (3.103) mostra que o sinal em uma escala superior pode ser recuperado

pela sobreamostragem por um fator 2 (interpolação por $L = 2$) dos coeficientes de aproximação $c_j(k)$ seguidos por um filtro com resposta ao impulso $g_0(n)$, o mesmo é feito para o coeficiente de detalhe usando um filtro com resposta ao impulso $g_1(n)$. Ambos resultados são somados produzindo o sinal em uma resolução mais alta 2^{1-j} .

A Fig. 3.13 ilustra a árvore de síntese wavelet para J estágios de banco de filtros de dois canais. Novamente, ao referenciarmos a Seção 3.3, concluímos que a Eq. (3.103) consegue recuperar plenamente o sinal decomposto na análise wavelet sem perda de qualquer informação, pois o *aliasing* gerado na decomposição é anulado quando aplicamos a sobreamostragem, dobrando o tamanho dos coeficientes de aproximação e de detalhe pela inserção de zeros. Em seguida realizamos a convolução destes sinais com seus respectivos filtros $g_0(n)$ e $g_1(n)$, somando as saídas dos filtros, o que equivale a soma das projeções dos sinais de cada espaço gerado na decomposição, atendendo a Eq. (3.75).

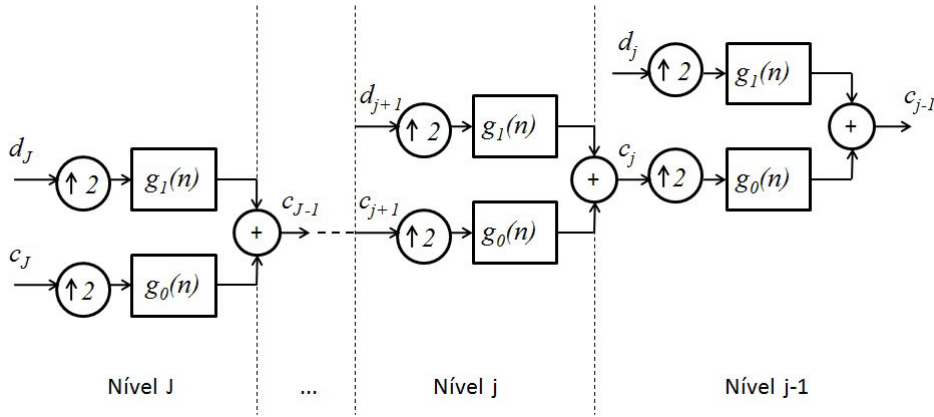


Figura 3.13: Árvore de síntese wavelet formada por J estágios de dois canais.

3.4.5 Definição dos Filtros de Síntese e de Análise

Os coeficientes dos filtros de análise, $h_0(n)$ e $h_1(n)$, e de síntese, $g_0(n)$ e $g_1(n)$, podem ser obtidos das funções wavelets $\psi(t)$ e escala $\phi(t)$. Por meio das Eqs. (3.81), (3.82), (3.86) e (3.87) é possível defini-los como

$$h_0(n) = \int_{-\infty}^{\infty} \phi^*(t) \sqrt{2} \bar{\phi}(2t+n) dt \quad (3.104)$$

$$g_0(n) = \int_{-\infty}^{\infty} \bar{\phi}(t) \sqrt{2} \phi^*(2t-n) dt \quad (3.105)$$

$$h_1(n) = \int_{-\infty}^{\infty} \psi^*(t) \sqrt{2} \bar{\phi}(2t+n) dt \quad (3.106)$$

$$g_1(n) = \int_{-\infty}^{\infty} \bar{\psi}(t) \sqrt{2} \phi^*(2t - n) dt \quad (3.107)$$

Aplicando a transformada de Fourier às funções wavelets, funções escala e filtros, temos [58]

$$\bar{\phi}(\omega) = \prod_{n=2}^{\infty} \frac{1}{\sqrt{2}} H_0^*(e^{j\omega/2^n}) \quad (3.108)$$

$$\phi(\omega) = \prod_{n=2}^{\infty} \frac{1}{\sqrt{2}} G_0(e^{j\omega/2^n}) \quad (3.109)$$

$$\bar{\psi}(\omega) = \frac{1}{\sqrt{2}} H_1^*(e^{j\omega/2}) \prod_{n=2}^{\infty} \frac{1}{\sqrt{2}} H_0^*(e^{j\omega/2^n}) \quad (3.110)$$

$$\psi(\omega) = \frac{1}{\sqrt{2}} G_1(e^{j\omega/2}) \prod_{n=2}^{\infty} \frac{1}{\sqrt{2}} G_0(e^{j\omega/2^n}) \quad (3.111)$$

onde $\phi(\omega)$, $\psi(\omega)$, $\bar{\phi}(\omega)$ e $\bar{\psi}(\omega)$ são, respectivamente, as funções escala e wavelet de análise, as funções escala e wavelet de síntese. No caso ortogonal, quando $\phi(\omega) = \bar{\phi}(\omega)$ e $\psi(\omega) = \bar{\psi}(\omega)$, temos que $h_0(n) = g_0^*(-n)$ e $h_1(n) = g_1^*(-n)$. Portanto, a resposta ao impulso dos filtros de análise constituem versões espelhadas dos filtros de síntese (filtros QMF).

3.4.6 Relação entre Filtros e Wavelet

Quando as wavelets são biortogonais, as funções $\phi(\omega)$, $\psi(\omega)$, $\bar{\phi}(\omega)$ e $\bar{\psi}(\omega)$ satisfazem as seguintes condições:

$$\langle \phi(t), \phi(t - m) \rangle = \delta(m) \quad (3.112)$$

$$\langle \psi(t), \bar{\psi}(t - m) \rangle = \delta(m) \quad (3.113)$$

$$\langle \phi(t), \bar{\psi}(t - m) \rangle = 0 \quad (3.114)$$

$$\langle \psi(t), \bar{\phi}(t-m) \rangle = 0 \quad (3.115)$$

Substituindo as Eqs. (3.81), (3.82), (3.86) e (3.87) nas Eqs. (3.112) a (3.115), encontramos que

$$G_0(z) H_0(z) + G_0(-z) H_0(-z) = 2 \quad (3.116)$$

$$G_1(z) H_1(z) + G_1(-z) H_1(-z) = 2 \quad (3.117)$$

$$G_0(z) H_1(z) + G_0(-z) H_1(-z) = 0 \quad (3.118)$$

$$G_1(z) H_0(z) + G_1(-z) H_0(-z) = 0 \quad (3.119)$$

Para o caso em que as wavelets são ortogonais, como $h_0(n) = g_0^*(-n)$ e $h_1(n) = g_1^*(-n)$, então $H_0(z) = G_0^*(z)$ e $H_1(z) = G_1^*(z)$, portanto,

$$G_0(z) G_0^*(z) + G_0(-z) G_0^*(-z) = 2 \quad (3.120)$$

$$G_1(z) G_1^*(z) + G_1(-z) G_1^*(-z) = 2 \quad (3.121)$$

$$G_0(z) G_1^*(z) + G_0(-z) G_1^*(-z) = 0 \quad (3.122)$$

$$G_1(z) G_0^*(z) + G_1(-z) G_0^*(-z) = 0 \quad (3.123)$$

As Eqs. (3.120) a (3.123) também obedecem às condições para reconstrução perfeita expostas para filtros de dois canais na Seção 3.3.

3.4.7 Requerimentos para Encontrar os Coeficientes

Para que seja possível formar funções escala e wavelets biortogonais e ortonormais, é necessário aplicar o banco de filtros de dois canais com reconstrução perfeita.

Entretanto, os filtros $H_0(z)$, $H_1(z)$, $G_0(z)$ e $G_1(z)$ devem ser apropriadamente normalizados para gerar a WT.

O filtro passa-baixas normalizado pode ser obtido pela integração da Eq. (3.78) (assumindo $c(n) = g_0(n)$):

$$\int_{-\infty}^{\infty} \phi(t) dt = \frac{1}{\sqrt{2}} \sum_{n=-\infty}^{\infty} g_0(n) \int_{-\infty}^{\infty} \phi(2t - n) d(2t) N \quad (3.124)$$

Como $\int_{-\infty}^{\infty} \phi(t) dt = 1$, temos

$$\sum_{n=-\infty}^{\infty} g_0(n) = \sqrt{2} \quad (3.125)$$

Para determinar o filtro passa-altas normalizado, basta integrar a Eq. 3.73, designando $h_1(n) = g_1(n)$:

$$\int_{-\infty}^{\infty} \psi(t) dt = \frac{1}{\sqrt{2}} \sum_{n=-\infty}^{\infty} g_1(n) \int_{-\infty}^{\infty} \phi(2t - n) d(2t) \quad (3.126)$$

como $\int_{-\infty}^{\infty} \psi(t) dt = 0$, então

$$\sum_{n=-\infty}^{\infty} g_1(n) = 0 \quad (3.127)$$

A Eq. (3.127) mostra que os filtros passa-altas precisam ter média zero para permitir a construção das wavelets.

3.4.8 Regularidade

A regularidade de uma função wavelet ou função escala está relacionada à quantidade de derivadas contínuas que estas possuem.

Em [64] Daubechies verificou a regularidade da função wavelet e da função escala (de análise e de síntese), i.e., a convergência dos produto infinitos nas Eqs. (3.108) a (3.111). Supondo que o filtro $G_0(z)$ tenha N zeros em $z = -1$, este pode ser descrito como

$$G_0(z) = \sqrt{2} \left(\frac{1+z^{-1}}{2} \right)^N S(z) \quad (3.128)$$

A convergência de uma função $\phi(t)$ ocorre se

$$\sup |S(e^{j\omega})| < 2^{N-1} \quad (3.129)$$

Portanto, se $G_0(z)$ não possuir zeros em $z = -1$, a Eq. (3.129) não poderá ser atendida, já que $S(1) = 1$.

Caso N seja superior ao número mínimo requerido para satisfazer a condição acima, a função continuará tendo derivadas contínuas. Neste caso, quanto maior o valor da regularidade, mais suave será a forma da wavelet, como indicado na Fig. 3.14. Vale ressaltar que a regularidade esta associada somente com os filtros passa-baixas $g_0(n)$ e $h_0(n)$.




Figura 3.14: Exemplo de wavelets Daubechies com diferentes regularidades: (a) regularidade = 0.91 (*db3*); (b) regularidade = 2.15 (*db7*).

3.4.9 Número de Momentos Nulos

As propriedades de aproximação de uma decomposição multirresolução estão ligadas à quantidade de momentos nulos (*vanishing moments*) da wavelet mãe.

O k -ésimo momento da wavelet pode ser calculado por

$$m_k = (-j)^{-k} \left. \frac{d^k \Psi(\omega)}{d\omega^k} \right|_{\omega=0} \quad (3.130)$$

Se a wavelet possui N zeros presentes em $\omega = 0$, então podemos dizer que a wavelet possui N momentos nulos, tal que

$$\int_{-\infty}^{\infty} t^k \psi(t) dt = 0 \quad \text{para } k = 0, 1, \dots, N-1 \quad (3.131)$$

Isto significa que os coeficientes de detalhe gerados pela convolução de uma wavelet de N momentos com uma função polinomial de grau menor ou igual a N serão todos nulos. Portanto, a função será representada apenas pelos seus coeficientes de aproximação.

Se a função é analítica, então ela pode ser expandida em uma série de Taylor como [6]

$$x(t) = \sum_{k=0}^{\infty} \frac{1}{k!} \left. \frac{d^k x(t)}{dt^k} \right|_{t=t_0} (t-t_0)^k$$

Assim, para uma wavelet com N momentos nulos, somente os termos em que $k > N$ não irão gerar coeficientes de detalhe nulos.

O número de momentos pode ser controlado no processo de construção das wavelets a partir do banco de filtros. Observando as Eqs. (3.108) a (3.111), percebemos que os coeficientes wavelet de análise $\psi(\omega)$ e de síntese $\bar{\psi}(\omega)$ dependem, respectivamente, dos filtros passa-altas de síntese $G_1(e^{j\omega})$ e passa-baixas de análise $H_0(e^{j\omega})$. Com isso o número de momentos nulos da wavelet de análise é dado pelo número de zeros de $H_0(z)$ em $z = -1$ e da wavelet de síntese pelo número de zeros de $G_1(z)$ em $z = 1$.

3.4.10 Famílias Wavelet

Muitos tipos de famílias wavelets são discutidas na literatura [59, 65–67]. As principais famílias com características e aplicações distintas, são [68]:

- Haar - designada como *haar* ou *db1*. São wavelets simétricas com número de momentos igual a 1;
- Daubechies - designadas como *dbN*, onde N indica a ordem e também o número de momentos. Além disso, são filtros FIR assimétricos.
- Symlets - designadas como *symN*, em que N indica a ordem. São aproximadamente simétricas;

- Coiflets - designadas como $coifN$, onde N indica a ordem e a função ψ tem $2N$ momentos. São mais simétricas que as wavelets dbN ;
- Biortogonal - designadas como $biorNr.Nd$, onde Nr e Nd indicam as ordens dos filtros de síntese e análise respectivamente. Possuem número de momentos igual a Nr e são filtros biortogonais de fase linear, podendo ser simétricos;
- Biortogonal Reversa - designadas como $rbiorNd.Nr$, em que Nr e Nd indicam as ordens dos filtros de síntese e análise respectivamente. Possuem número de momentos igual a Nd e são filtros biortogonais de fase linear, podendo ser simétricos.

Diversas outras famílias wavelets podem ser encontradas na literatura. No entanto, no trabalho desenvolvido nesta dissertação faremos uso apenas das wavelets das famílias Daubechies, Symlets e Coiflets, por serem amplamente aplicadas na filtragem de sinais de descargas parciais [69]. Estas wavelets apresentam propriedades interessantes no tratamento de pulsos irregulares e de rápido transiente como os pulsos de DP. Dentre estas propriedades podemos destacar [9, 25, 30, 44]:

- ortogonalidade;
- duração limitada;
- algoritmo rápido;
- assimetria.

3.5 Procedimento Wavelet de Filtragem Aplicado a Sinais de DP

Como já discutido, a aplicação da filtragem por meio da FFT e STFT não é tão eficaz no tratamento de sinais não estacionários, transientes e de natureza estocástica como os de DP [27], já que estas transformadas não permitem uma localização no domínio do tempo e da frequência da mesma forma que a transformada wavelet o faz [9, 28] (com melhor resolução na frequência e pior resolução no tempo nas componentes de baixa frequência do sinal; e pior resolução na frequência e melhor resolução no tempo para as componentes de alta frequência do sinal). Portanto, a eficácia destes métodos se torna limitada em comparação com a filtragem wavelet, que apresenta uma capacidade de auto adaptação ao sinal.

A maior parte das aplicações da transformada wavelet é destinada à eliminação

de ruído branco, pois ao analisarmos a distribuição dos coeficientes no domínio wavelet observamos que a densidade média dos coeficientes é inversamente proporcional à escala diádica $1/2^j$ (j indica o nível de decomposição), ou, metade do número dos coeficientes locais extremos não se propagam 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 wavelet do sinal de DP difere do ruído, já que tende a ter sua energia concentrada em poucos níveis de decomposição, torna-se fácil identificar e separar os sinais de DP do ruído presente [25, 44, 70].

A filtragem de sinais no domínio da DWT utiliza bancos de filtros de análise e de síntese. A etapa de análise é aplicada para decompor o sinal original em suas constituintes subbandas ou níveis, em geral logaritmicamente espaçados. Isso permite a separação do ruído existente e do sinal de interesse, este ocorrendo em um instante de tempo particular e em uma frequência particular. Ao identificar nestas subbandas os coeficientes que concentram a maior parte da energia do sinal e aplicar um valor de limiar nestes coeficientes é possível eliminar, de maneira significativa, grande parte do ruído presente, permitindo obtermos uma boa estimativa do sinal desejado, que pode ser recuperado por meio do banco de filtros de síntese (IDWT) [69].

Não só o ruído branco poderá ser suprimido do sinal, mas também componentes com ruído de espectro discreto, desde que as frequências destes sinais não coincidam com as componentes de frequência dos sinais de DP.

3.5.1 Etapas da Filtragem Wavelet

A filtragem de um sinal pela DWT envolve os três passos que se seguem [9, 70]:

1. Determinar o número de níveis de decomposição J e escolher a wavelet para cada nível j , onde $j = 1, 2, \dots, J$, e então, realizar a decomposição dos coeficientes DWT;
2. Encontrar os valores de limiar pela aplicação de uma regra de seleção e usar estes valores em uma função de limiarização aplicada aos coeficientes de detalhe em cada nível;
3. Reconstruir o sinal pela aplicação da IDWT aos coeficientes de aproximação final e de detalhe limiarizados, obtendo o sinal filtrado.

Cada uma destas etapas é melhor descrita na Fig. 3.15, que evidencia os parâmetros que necessitam ser determinados para que se possa concluir o processo de redução

de ruídos do sinal bruto. São eles:

- A transformada wavelet a ser utilizada;
- O número de níveis de decomposição;
- A Wavelet Mãe aplicada na decomposição;
- A forma de se calcular os valores de limiar;
- A função a ser utilizada na limiarização dos coeficientes.

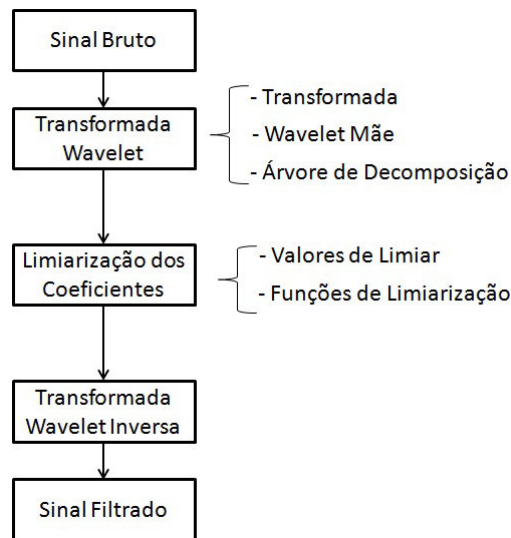


Figura 3.15: Processo de remoção de ruídos pela transformada wavelet.

Portanto, a performance da filtragem dependerá de cada um destes parâmetros, sendo que alguns destes têm maior impacto na variação do resultado final. Dentre eles temos a seleção do número de níveis de decomposição e da wavelet mãe, e o cálculo dos valores de limiar em cada nível, que melhor representarão o sinal de DP. A obtenção destes parâmetros se mostra um desafio de otimização [27].




Figura 3.16: Sinal de pulso de DP com ruído branco.

Para demonstrar melhor o processo de filtragem DWT, tomemos como exemplo a decomposição de um sinal bruto de DP, ilustrado na Fig. 3.16, para 3 níveis de decomposição ($J = 3$), conforme o diagrama mostrado na Fig. 3.17. O sinal bruto é decomposto em seus coeficientes de detalhe d_1 e coeficientes de aproximação c_1 ao

passar pelo filtro de dois canais e ser decimado por um fator 2, como discutido na Seção 3.3. As respostas ao impulso $h_1(-n)$ e $g_1(-n)$ representam, respectivamente, os filtros passa-altas formados pela função wavelet mãe ψ_1 , e filtros passa-baixas, formados pela função escala ϕ_1 , para o primeiro nível de decomposição. É importante notar que os filtros passa-altas e passa-baixas não são independentes, mas relacionados por [51]:

$$h_j(N - 1 - n) = (-1)^n g_j(n) \quad (3.132)$$

onde N é o comprimento do filtro. Observe que os dois filtros são versões alternadas reversas em índice ímpar um do outro e a conversão de passa-baixas para passa-altas é provida pelo termo $(-1)^n$, como ilustrado na Fig. 3.18, que mostra a resposta ao impulsos dos filtros de análise e de síntese para a wavelet *sym6*; filtros que satisfazem tal condição são conhecidos como QMF, conforme descrito na Seção 3.3.




Figura 3.17: Processo de filtragem wavelet em 3 níveis de um sinal DP.

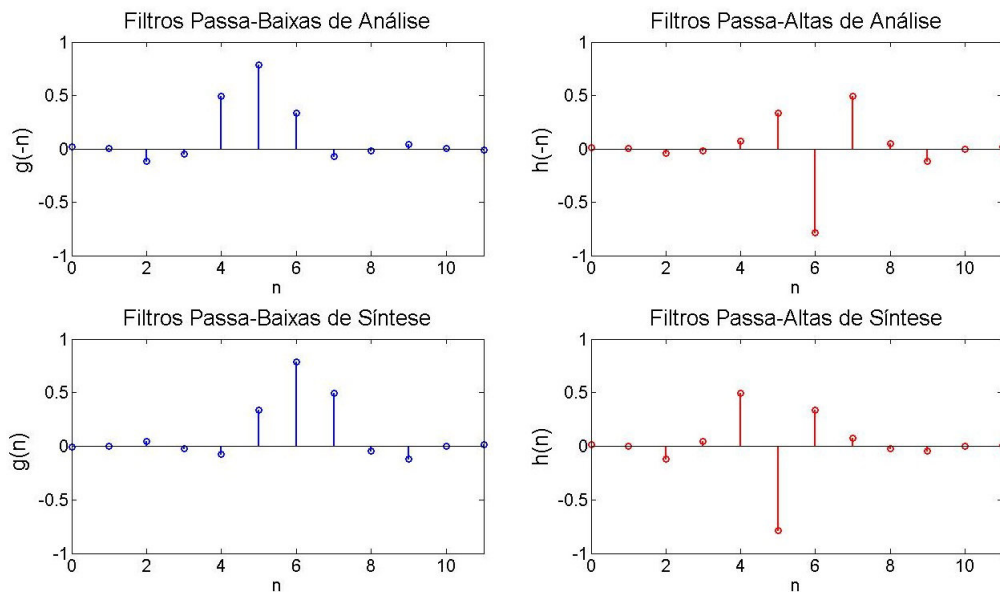


Figura 3.18: Resposta ao impulso dos filtros de análise e síntese gerados pela wavelet Symlet de ordem 6 (*sym6*).

De forma recursiva, os coeficientes de aproximação gerados são novamente decompostos até que atinjam seu nível máximo. Como resultado, no último nível do processo de análise do sinal obtemos todos os coeficientes de detalhe d_1 , d_2 , d_3 e os coeficientes da aproximação final c_3 , mostrados na Fig. 3.19. Observe que a cada nível o número de coeficientes é reduzido pela metade. Estes coeficientes passam pelo processo de limiarização, que em grande parte da literatura é realizada pela aplicação de uma função abrupta (*hard*) ou a suave (*soft*) [25, 26, 28, 30, 44, 45, 71] aos coeficientes, sendo o valor de limiar calculado com base em uma regra de seleção que estima qual o nível de ruído existente em cada coeficiente.

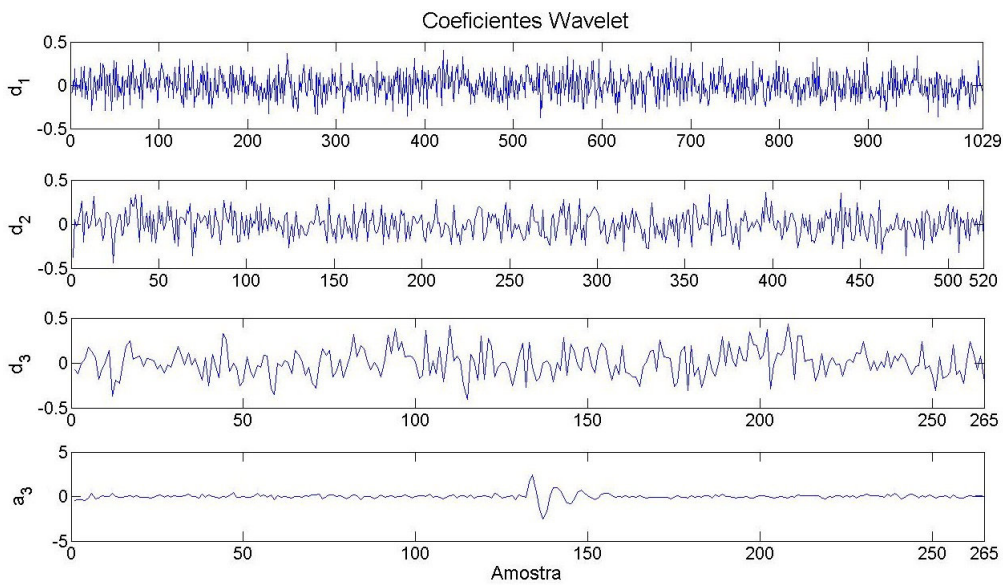


Figura 3.19: Coeficientes de aproximação final e coeficientes de detalhe gerados na decomposição do sinal de DP com o uso da wavelet Symlet de ordem 6 (*sym6*).




Figura 3.20: Coeficientes de detalhe gerados após o processo de limiarização.

Após a limiarização, com valores de limiar dados por $\lambda_{d_1} = 0.5773$, $\lambda_{d_2} = 0.5322$ e $\lambda_{d_3} = 0.4891$, são gerados os novos coeficientes, d'_1 , d'_2 , d'_3 e c'_3 , vistos na Fig. 3.20, livres de ruído nos níveis de detalhe, restando apenas uma pequena quantidade de ruído no coeficiente de aproximação final. Como etapa final o sinal de DP filtrado, mostrado na Fig. 3.21, será recuperado pelo banco de filtros de síntese com interpoladores por um fator 2. Estes filtros correspondem aos filtros aplicados na decomposição com resposta ao impulso “espelhada” (QMF), conforme ilustrado na Fig. 3.18.




Figura 3.21: Resposta ao impulso dos filtros de análise e síntese gerados pela wavelet Symlet de ordem 6 (*sym6*).

Discutiremos as dificuldades observadas na escolha de cada um dos parâmetros aplicados na filtragem de um sinal de DP nas seções que se seguem.

3.5.2 Escolha da Transformada

Nesta dissertação nos limitaremos apenas à avaliação da DWT por ser amplamente aplicada na literatura aqui estudada [25–32, 44, 45, 71], devido a algumas vantagens quanto a facilidade de implementação e a alta velocidade de processamento, em função de decompor recursivamente somente os coeficientes de aproximação gerados a cada nível e reduzir o número de amostras de ambos coeficientes para cada escala com o uso de decimadores.

No entanto, existem algumas aplicações voltadas ao estudo de DP que utilizam outros tipos de transformada wavelet, como a Transformada Wavelet em Pacotes (*Wavelet Packet Transform* - WPT), a Transformada Wavelet Estacionária (*Stationary Wavelet Transform* - SWT), a Transformada Wavelet Complexa de Árvore Dupla (*Dual-Tree Complex Wavelet Transform* - DTCWT) e Transformada Wavelet de Segunda Geração (*Second Generation Wavelet Transform* - SGWT) [26, 53, 68, 72, 73].

Apesar de em geral serem transformadas compostas por uma estrutura mais complexa e exigirem um maior tempo de processamento, possuem algumas propriedades que podem ser interessantes para filtragem de sinais. Não descreveremos em

maiores detalhes estas transformadas, já que não serão aplicadas em nosso desenvolvimento.

3.5.3 Escolha do Número de Níveis de Decomposição

Definir o número de níveis de resolução a serem empregados na reconstrução de um sinal de DP envolto em ruído tem se mostrado um desafio para aplicações em análise wavelet, já que nas inúmeras publicações analisadas ainda não se definiu de forma clara um critério adequado para seleção do mesmo.

Na literatura podemos encontrar a descrição de alguns procedimentos que têm sido adotados para a seleção do número de níveis empregados na decomposição wavelet. Na maioria dos casos [1, 7, 9, 27, 28, 30, 44] a seleção é feita de forma empírica, verificando que, para um dado sinal de DP, um certo número de níveis J é o bastante para prover um bom resultado na atenuação do ruído.

Em [41] os autores especificam um certo número de níveis de decomposição J sem qualquer esclarecimento da razão para utilizá-lo. Em [71] os autores observam que o nível de resolução muito baixo produz um resultado de filtragem ruim, pois o sinal de DP e os componentes de interferência de baixa frequência podem ser agrupados nos mesmos níveis, dificultando a separação [45], no entanto, se J for muito grande pode não haver melhora significativa na qualidade do sinal obtido, além de haver uma elevação no tempo de processamento; em geral, um nível de resolução de 4 ou 5 é considerado suficiente para uma boa filtragem.

Zhou *et al.* em [32] propõem um estudo a priori do espectro de frequência do pulso de DP, a fim de investigar a distribuição de energia em cada nível, identificando aqueles que possuem maior importância na composição do sinal de DP, e assim melhorar a performance de reconstrução do sinal. É recomendado neste processo o uso do limite superior do número de níveis com o qual um sinal de comprimento N pode ser decomposto:

$$J_{max} = \text{fix}(\log_2 N) \quad (3.133)$$

onde *fix* arredonda o elemento entre parênteses para o inteiro mais próximo de zero. No entanto, para aplicação junto ao Matlab Wavelet Toolbox, o comprimento do sinal no nível mais alto de decomposição não pode ser menor do que o comprimento N_w do filtro de decomposição associado à wavelet mãe, obtendo-se então:

$$J_{max_M} = \text{fix} \left(\log_2 \left(\frac{N}{N_w - 1} \right) \right) \quad (3.134)$$

De acordo com [32], não seria apropriado utilizar um número de níveis maior que J_{max_M} além de aumentar o tempo de processamento. Isto pode ser corroborado ao analisarmos a Fig. 3.22, em que temos o resultado da filtragem de um pulso de DP (com comprimento $N = 10000$) decomposto para cinco valores distintos de níveis de decomposição $J = 3$, $J = 5$, $J = J_{max_M} = 9$, $J = 11$ e $J = J_{max} = 13$ usando uma wavelet Daubechies de ordem 6 ($N_w = 12$). É visível que para níveis de decomposição até J_{max_M} ocorre uma melhora significativa na qualidade do sinal obtido, enquanto que para valores superiores a melhora no resultado em relação a J_{max_M} é praticamente imperceptível com o custo de um aumento no tempo de processamento.




Figura 3.22: Comparação dos resultados de filtragem de um pulso de DP para diferentes níveis de decomposição.

Shetty *et al.* [72] sugerem que o número de decomposições seja definido *a priori*, dependendo da frequência de amostragem F_s e da frequência de corte F_d do circuito detector utilizado na medição do sinal de DP, de acordo com a Eq. (3.135).

$$J = \text{fix} \left(\frac{\log_2(F_s) - \log_2(F_d)}{\log(2)} - 1 \right) \quad (3.135)$$

No Capítulo 5, utilizaremos os conceitos aqui abordados para a criação de um método, baseado na resposta em frequência do pulso de DP, para a seleção do número de níveis.

3.5.4 Seleção da Wavelet Mãe

Na Seção 3.4.10 apresentamos várias famílias de funções wavelet, que podem ser utilizadas para a filtragem do sinal. A seleção da wavelet mais adequada se mostra uma etapa crítica, pois terá grande influência nos resultados finais, sendo responsável por gerar os pares de filtros de análise ($h_j(-n)$ e $g_j(-n)$) e de síntese ($h_j(n)$, $g_j(n)$) da escala j em que é aplicada.

Em [29] Wang *et al.* sugerem que a função wavelet seja selecionada de acordo com o sinal processado, e que a seleção da wavelet apropriada afetará consideravelmente o resultado da redução de ruídos.

Em grande parte da literatura verificada [7, 45, 62, 74, 75], os autores selecionam a wavelet mãe de forma aleatória ou levando em conta apenas a semelhança visual entre a forma de onda do sinal e da wavelet mãe, sem propor uma forma mais criteriosa para esta escolha. Em [45] o autor realiza a escolha se baseando apenas em tentativa e erro.

H. Zang *et al.* [41] afirmam que quanto maior a similaridade entre a forma do sinal original e da função wavelet básica, maior serão os coeficientes produzidos. Para considerações de reconstrução e filtragem, a wavelet ótima para um sinal é aquela que é capaz de gerar em uma dada escala coeficientes com valores tão altos quanto possível através do domínio tempo escala. Em [28] é utilizada a mesma justificativa para a seleção da wavelet.

Em [76] o autor seleciona entre muitos tipos as wavelets da família *Daubechies* por terem características de assimetria e serem ortogonalmente compactas, conforme discutido na Seção 3.4.10. É utilizada a função *Daubechies* com ordem que gera uma forma de onda que mais se assemelha à forma de seu pulso de DP simulado.

Gaouda *et al.* [27] selecionam a wavelet com base no fato que o espectro de frequência da função mãe mostra uma separação mais precisa dos componentes do sinal quando possui máximo número de momentos nulos. Com o aumento do número de momentos nulos, mais suavidade pode ser alcançada e seu espectro se mostra mais próximo do ideal nos entornos de zero e π . Desta forma, a região de sobreposição do espectro de frequência entre os dois filtros é pequena e um mínimo vazamento espectral é esperado na análise multirresolução wavelet do sinal. Entretanto, também haverá uma elevação no custo computacional de processamento para tratamento do sinal.

Verificamos que a escolha da melhor wavelet mãe é uma questão importante, mas soluções generalizadas ainda parecem elusivas. Portanto, se mostra um pro-

blema que necessita ser melhor estudado. Esta é a principal motivação para o desenvolvimento do método de Seleção da Wavelet Mãe Baseado na Relação Sinal Ruído (SNRBWS) que será desenvolvido nesta dissertação.

Alguns autores têm sugerido algoritmos de seleção da wavelet mãe que se mostram um pouco mais elaborados e eficientes. Dentre estes algoritmos podemos destacar:

- o método de Seleção da Wavelet Mãe Baseado na Correlação (CBWS), descrito em [9, 26, 27, 30, 44], que basicamente busca a wavelet que apresenta uma maior correlação com o pulso de DP analisado e a aplica na filtragem do sinal medido;
- o método de Seleção da Wavelet Mãe Baseado na Energia (EBWS) [30], que faz a busca da wavelet para cada escala baseando-se na maximização da quantidade de energia nos coeficientes de aproximação.

Discutiremos detalhadamente os métodos supracitados no Capítulo 5 os quais serão comparados aos métodos propostos neste trabalho.

3.5.5 Processo de Limiarização

O processo de filtragem wavelet recai sobre a ideia básica de que a energia de uma função frequentemente se concentrará em poucos coeficientes no domínio wavelet enquanto que a energia do ruído se espalha ao longo de todos os coeficientes no domínio wavelet. Desta forma, a função de limiarização tenderá a manter os coeficientes de maior energia que representam o sinal de interesse, enquanto tende a reduzir a zero os coeficientes de ruído.

Pode-se dizer que o processo de limiarização compreende a essência da filtragem wavelet, tanto que existe uma extensa literatura para cálculo de valores de limiar e descrição de funções de limiarização.

Ao lado da função de limiarização, a seleção do valor ótimo de limiar também constitui uma importante regra no processo de redução de ruídos. Os métodos de seleção de limiar podem ser divididos em três grupos principais:

1. O primeiro faz uso do limiar universal (*universal-threshold*), onde o valor de limiar é escolhido uma única vez e aplicado a todos os coeficientes de ruído. O método mais conhecido (Visu Shrink) é descrito por D. L. Donoho *et al.* em [77] como a primeira técnica prática em filtragem de sinais;

2. O segundo, denominado limiares em subbandas adaptativos, o valor de limiar é selecionado diferentemente para cada cada subbanda de detalhe [77, 78];
3. No terceiro, grupos de seleção de limiares espacialmente adaptativos são selecionados para cada coeficiente wavelet ou para algum grupo deles [79].

Limiarização de Coeficientes Wavelets Ruidosos

Considere que um sinal contaminado por ruído é dado por [77, 80, 81]:

$$x_i = \mu_i + n_i, \quad i = 0, 1, \dots, N - 1 \quad (3.136)$$

onde μ_i são os i -ésimos coeficientes wavelet de um sinal livre de ruído e n_i são os i -ésimos coeficientes de ruído branco Gaussiano com distribuição idêntica independente (*independent identical distribution* - i.i.d.) $N(0, \sigma)$. A proposta da filtragem é estimar a função wavelet $\hat{\mu}_i$ com o menor Erro Quadrático Médio (EQM), i.e., minimizar o risco l^2 para um dado sinal ruidoso. Em outras palavras, a diferença entre o sinal livre de ruído e o sinal reconstruído deve ser aceitavelmente pequena. O EQM entre μ_i e $\hat{\mu}_i$ é definido como:

$$EQM(\hat{\mu}_i, \mu_i) = \frac{1}{N} \|\hat{\boldsymbol{\mu}} - \boldsymbol{\mu}\|^2 = \frac{1}{N} \sum_{i=0}^{N-1} (\hat{\mu}_i - \mu_i)^2 \quad (3.137)$$

A ortogonalidade da DWT tem uma fundamental consequência estatística que transforma um ruído branco em outro ruído branco. Portanto, se a DWT é ortogonal, podemos recorrer à relação de Parseval e expressar a função risco dada na Eq. (3.137) como:

$$EQM(\hat{\mu}_i, \mu_i) = \frac{1}{N} \sum_{i=0}^{N-1} (\hat{\mu}_i - \mu_i)^2 = \frac{1}{N} \sum_{j,k} (\hat{\omega}_{j,k} - \omega_{j,k})^2 \quad (3.138)$$

onde $\omega_{j,k}$ e $\hat{\omega}_{j,k}$ são os k -ésimo coeficientes wavelet de d e \hat{d} , respectivamente, na j -ésima escala.

Limiar Universal

Donoho *et al.* [82] descrevem o método com um estimador fixo do nível de ruído, onde o valor de limiar universal λ_u é dado por

$$\lambda_u = \sigma \sqrt{2 \log(N)} \quad (3.139)$$

onde N é o comprimento do sinal e σ é o desvio padrão (fator de reescala), que caso não seja conhecido pode ser estimado por meio dos coeficientes wavelet da menor escala. Então podemos dizer que:

$$\sigma = \frac{\text{mediana}(|\omega_{j,k}| \mid j, k \in W_1)}{q} \quad (3.140)$$

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

Uma importante característica deste método é que o sinal reconstruído é quase “livre de ruído”. Isto pode ser explicado, já que o estimador fixo $\sqrt{2 \log(N)}$ evita que espúrios de coeficientes ruidosos apareçam no sinal, pois quando n_i é uma sequência de ruído Gaussiano, então a probabilidade de que os maiores coeficientes do ruído sejam superiores ao valor do estimador tenderá a zero quando N for muito grande, i.e.,

$$p \left\{ \max |n_i| > \sqrt{2 \log(N)} \right\} \rightarrow 0, \text{ quando } N \rightarrow \infty \quad (3.141)$$

Um procedimento mais robusto de estimação do limiar com base no limiar universal discutido em [81], faz uso da estimativa do desvio padrão dependente de cada escala dos coeficientes wavelets e não mais apenas para os coeficientes da primeira escala de decomposição, ou seja,

$$\sigma_j = \frac{\text{mediana}(|\omega_{j,k}| \mid j, k \in W_j)}{q} \quad (3.142)$$

substituindo na Eq. (3.139), obtemos

$$\lambda_{u_j} = \sigma_j \sqrt{2 \log(N)} \quad (3.143)$$

Apesar de a Eq. (3.143) ser um estimador robusto do nível de ruído em cada escala, este ainda elimina uma boa parte da energia do sinal desejado [44]. Então Donoho [82] propôs uma modificação, adotando um esquema de estimação do limiar totalmente dependente da escala, como se segue:

$$\lambda_{d_j} = \sigma_j \sqrt{2 \log(N_j)} \quad (3.144)$$

em que N_j é o comprimento do vetor do coeficiente de detalhe na escala j e o desvio

padrão σ_j é o mesmo da Eq. (3.142).

Tal equação vem sendo muito utilizada no tratamento de sinais de DP [25, 26, 44, 83].

Stein Unbiased Risk Estimator

SURE constitui uma das mais práticas estimações de EQM [84]. Para problemas de estimação da função de limiar, como na Eq. (3.136), temos:

$$\mathbf{g}(\mathbf{x}) = \hat{\boldsymbol{\mu}}(\mathbf{x}) - \mathbf{x} \quad (3.145)$$

onde $\mathbf{g}(\mathbf{x}) = [g_0, g_1, \dots, g_{N-1}]^T$ é uma função de \mathcal{R}^N para \mathcal{R}^N e $\hat{\boldsymbol{\mu}}(\mathbf{x})$ é um estimador particular de um vetor $\boldsymbol{\mu}$. Em [85] Stein mostrou que quando $\mathbf{g}(\mathbf{x})$ é fracamente diferenciável, então

$$E_{\mu} \|\hat{\boldsymbol{\mu}}(\mathbf{x}) - \boldsymbol{\mu}\|^2 = N + E_{\mu} \{ \|\mathbf{g}(\mathbf{x})\|^2 + 2\nabla_x \cdot \mathbf{g}(\mathbf{x}) \}, \quad (3.146)$$

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

$$R_s(\lambda) = N + \|\mathbf{g}(\mathbf{x})\|^2 + 2\nabla_x \cdot \mathbf{g}(\mathbf{x}) \quad (3.147)$$

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

$$\frac{\partial R_s(\lambda)}{\partial \lambda} = 2 \sum_{i=0}^{N-1} g_i \frac{\partial g_i}{\partial x_i} + 2 \sum_{i=0}^{N-1} \frac{\partial^2 g_i}{\partial x_i \partial \lambda} \quad (3.148)$$

A Eq. (3.148) é muito aplicada em algoritmos adaptativos de busca de limiar baseado no gradiente [86, 87]. Um dos algoritmos mais utilizados em aprendizagem de redes neurais é o método iterativo de Mínima Média Quadrática (*Least Mean Square* - LMS). 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, o limiar pode ser ajustado para a solução ótima em cada escala como se segue [86]:

$$\lambda_j(i+1) = \lambda_j(i) - \Delta \lambda_j, \quad j = 1, 2, \dots, J \quad (3.149)$$

onde o ajuste do limiar no passo i é dado por

$$\Delta\lambda_j = \alpha_j(i) \cdot \left. \frac{\partial R_s^{(j)}(\lambda)}{\partial \lambda_j} \right|_{t_j=t_j(i)} \quad (3.150)$$

A cada passo o valor de $\alpha_j(i)$ (taxa de aprendizagem) deve ser selecionado de modo que $\lambda_j(i+1) \geq 0$.

A solução ótima do risco SURE, ou seja, seu argumento mínimo corresponderá a uma estimativa da solução ótima do risco na Eq. (3.137).

Em seguida, é preciso tomar uma função de limiarização η , que será discutida posteriormente, para realizar a busca pelo valor de limiar ótimo. Para tanto, é necessário que esta função seja diferenciável, ou seja, que tenha ao menos uma derivada. Com isso, podemos tomar o estimador da Eq. (3.145) como a função de limiarização, obtendo então g_i , o que nos habilita para calcular o risco SURE e buscar o valor ótimo de limiar para cada escala por meio da Eq. (3.149).

Donoho *et al.* em [77] consideraram a Eq. (3.147) para definir o risco SURE do estimador de limiar suave. Sendo este fracamente diferenciável no sentido Stein [85], então temos que a quantidade

$$SURE(\lambda; \mathbf{x}) = N - 2 \cdot \#\{i : |x_i| \leq \lambda\} + \sum_{i=0}^{N-1} (|x_i| \wedge \lambda)^2 \quad (3.151)$$

é uma estimativa imparcial do risco: $E_\mu \|\hat{\mu}^{(\lambda)}(\mathbf{x}) - \boldsymbol{\mu}\|^2 = E_\mu SURE(\lambda; \mathbf{x})$. Usando este risco para selecionar o limiar, temos

$$\lambda_{S_j} = \arg \min_{\lambda \geq 0} SURE(\lambda; \mathbf{x}) \quad (3.152)$$

Limiar Híbrido

O princípio SURE não é adequado em situações em que os coeficientes wavelet são muito esparsos, pois nestas situações as muitas coordenadas em que o sinal é zero fazem com que a raiz do EQM não tenda a zero linearmente quando a esparsidade tende a zero. Tal comportamento é inaceitável.

Em contrapartida, o estimador de limiar fixo $\lambda_F = \sqrt{2 \log(N)}$ independe do dado. Quando aplicado a coeficientes muito esparsos apresenta resultados mais satisfatórios do que os obtidos por meio do método SURE. Já para situações onde

o sinal é mais denso, i.e., sem tantos coeficientes nulos, o método SURE tende a ser melhor do que o estimador fixo.

Donoho *et al.* [77] propuseram um algoritmo híbrido dado pela combinação dos dois métodos, em que o valor de limiar é calculado pelo limiar fixo quando se tratar de uma situação em que o sinal é esparsos e pelo método SURE considerando o estimador de limiar suave (soft) λ_{S_j} quando o sinal é mais denso, i.e.,

$$\lambda_{H_j} = \begin{cases} \lambda_F, & N^{-1} \sum_{i=0}^{N-1} (x_i^2 - 1) \leq \frac{\sqrt[3]{\log_2(N)}}{\sqrt{N}} \\ \lambda_{S_j}, & N^{-1} \sum_{i=0}^{N-1} (x_i^2 - 1) > \frac{\sqrt[3]{\log_2(N)}}{\sqrt{N}} \end{cases} \quad (3.153)$$

Funções de Limiarização

Na literatura voltada à filtragem de sinais no domínio wavelet, as duas funções de limiarização dos coeficientes wavelets mais aplicadas são: a limiarização suave (*soft thresholding*) e a limiarização abrupta (*hard thresholding*), ambas apresentadas em [77] e mostradas na Fig. 3.23.

A função de limiarização suave é descrita por:

$$\eta_{soft}(\omega_{j,k}, \lambda) = \begin{cases} \text{sign}(\omega_{j,k}) \cdot (|\omega_{j,k} - \lambda|), & |\omega_{j,k}| > \lambda \\ 0, & |\omega_{j,k}| \leq \lambda \end{cases} \quad (3.154)$$

A função de limiarização abrupta é dada por:

$$\eta_{hard}(\omega_{j,k}, \lambda) = \begin{cases} \omega_{j,k}, & |\omega_{j,k}| > \lambda \\ 0, & |\omega_{j,k}| \leq \lambda \end{cases} \quad (3.155)$$

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. Perceba que a limiarização abrupta preserva melhor as características de amplitude dos coeficientes do que a limiarização suave, por não reduzir os coeficientes acima com valores do limiar. Segundo Xiaorong *et al.* [29] isto permite que sinais impulsivos como os de DP sejam reconstruídos de uma melhor forma promovendo uma melhor relação sinal ruído [7, 87].

Em [83] Jian Li *et al.* propuseram um método de busca baseado em algoritmos genéticos, para busca do valor ótimo de uma função custo que faz uso do risco SURE dado na Eq. (3.148), o qual por sua vez está associado a uma função de limiarização




Figura 3.23: Função de limiarização: (a) suave ;(b) abrupta.

descrita por M. Nasiri *et al.* [88] como função de limiarização Garrote (Garrote *thresholding*):

$$\eta_{garrote}(\omega_{j,k}, \lambda) = \begin{cases} \omega_{j,k} - 0.5 \frac{\lambda^2}{\omega_{j,k}}, & |\omega_{j,k}| > \lambda \\ 0.5 \frac{\omega_{j,k}^3}{\lambda}, & |\omega_{j,k}| \leq \lambda \end{cases} \quad (3.156)$$

Tal função, ilustrada na Fig. 3.24, é utilizada por possuir derivadas contínuas, característica desejável e necessária para aplicação em algoritmos de busca baseados no risco SURE. Já a função abrupta não é adequada para ser aplicada em algoritmos de busca envolvendo a minimização do risco SURE, uma vez que não é uma função contínua. A função suave pode ser aplicada, mas esta é fracamente diferenciável.




Figura 3.24: Função de limiarização Garrote.

M. Nasiri *et al.* propõem ainda uma outra função de limiarização, uma função diferenciável não linear com dois parâmetros de ajuste de forma, $k \in (0, 1]$ e m . Ajustando o parâmetro k , uma função intermediária próxima de um ótimo, entre a função abrupta e a suave, é obtida. E ajustando m a função é aproximada de um ótimo por meio de pequenas alterações. Em outras palavras, otimizar k funciona

como uma busca global e otimizar m funciona como uma busca local para encontrar o melhor valor de limiar. A função de limiarização Nasiri é dada por:

$$\eta_{nasiri}(\omega_{j,k}, \lambda, m, k) = \begin{cases} \omega_{j,k} + (k-1)\lambda - 0.5 \frac{k \times \lambda^m}{\omega_{j,k}^{m-1}}, & \omega_{j,k} > \lambda \\ 0.5 \frac{k \times |\omega_{j,k}|^{m + [(2-k)/k]}}{\lambda^{m + [(2-k)/k]}} \text{sign}(\omega_{j,k}), & |\omega_{j,k}| \leq \lambda \\ \omega_{j,k} - (k-1)\lambda + 0.5 \frac{k \times (-\lambda)^m}{\omega_{j,k}^{m-1}}, & \omega_{j,k} < -\lambda \end{cases} \quad (3.157)$$

A Fig. 3.25 mostra esta Função para $m = 2$ e k variando de 0 a 1. É possível notar que a função Nasiri para k próximo de zero porta-se como a função suave.




Figura 3.25: Função de limiarização Nasiri.

Em [86, 89] Zhang descreve outras duas funções de limiarização contínuas e diferenciáveis desejáveis para aplicações em algoritmos de busca de valor ótimo. As funções são definidas por:

$$\eta_{Zhang_1}(\omega_{j,k}, \lambda, k) = \begin{cases} \omega_{j,k} + \lambda - \frac{\lambda}{2k+1}, & \omega_{j,k} < -\lambda \\ \frac{1}{(2k+1)\lambda^{2k}} \cdot \omega_{j,k}^{2k+1}, & |\omega_{j,k}| \leq \lambda \\ \omega_{j,k} - \lambda + \frac{\lambda}{2k+1}, & \omega_{j,k} > \lambda \end{cases} \quad (3.158)$$

$$\eta_{Zhang_2}(\omega_{j,k}, \lambda, \alpha) = \omega_{j,k} + 0.5 \left(\sqrt{(\omega_{j,k} - \lambda)^2 + \alpha} - \sqrt{(\omega_{j,k} + \lambda)^2 + \alpha} \right) \quad (3.159)$$

Na Eq. (3.158) o parâmetro $k \geq 0$ faz o ajuste da forma de limiarização. Para $k = 0$ não haverá limiarização, já quando $k \rightarrow \infty$ a função converge para a limiarização suave, como mostrado na Fig. 3.26(a). A Fig.3.26(b) ilustra a função de limiarização Zhang₂. Em [87] esta função foi aplicada num algoritmo de busca

LMS com base no cálculo do gradiente do risco SURE, obtendo melhores resultados de EQM nos sinais de DP filtrados.




Figura 3.26: Função de limiarização: (a) Zhang₁ ;(b) Zhang₂

Associação do Valor de Limiar e da Função de Limiarização

Em resumo o procedimento de redução dos coeficientes wavelet pode ser dividido em três passos:

1. Determinar o modo de cálculo do valor de limiar, o qual pode ser realizado através dos seguintes métodos [68]:

sqtwolog - emprega o limiar universal $\sqrt{2 \log(N)}$;

rigrsure - seleção adaptativa utilizando o princípio SURE com o valor de limiar dado pela Eq. (3.152);

heursure - realiza a seleção com base na combinação dos dois métodos anteriores, descrito pela Eq. (3.153);

minimaxi - faz a seleção do limiar usando o princípio minimax descrito por Donoho *et al.* em [82];

scaledep - faz a seleção de limiar dependente do nível de decomposição j , conforme a Eq. (3.144).¹

2. Após o cálculo do valor de limiar, é possível aplicar um método multiplicativo para reescalar este valor, por meio de um dos seguintes métodos [68]:

one - não aplica nenhum tipo de reescala;

¹O método *scaledep* não está implementado no Matlab Wavelet Toolbox, mas como este vem sendo bastante utilizado na filtragem de sinais de DP, o implementamos e o incorporamos ao Wavelet Toolbox para uso em nossas simulações.

sln - estima o nível de ruído baseado no primeiro coeficiente de detalhe, usando para isso o valor do desvio padrão σ exposto na Eq. (3.140); A combinação da regra de seleção *sqtwolog* com o fator de reescala *sln* gera o efeito mostrado na Eq. (3.139).

mln - estima o nível de ruído para os coeficientes de cada escala de decomposição, usando o desvio padrão σ_j descrito na Eq. (3.142); A junção da regra de seleção *sqtwolog* com o fator de reescala *mln*, mostrada na Eq. (3.143), é mais empregada já que tende a eliminar uma menor quantidade de energia do sinal de DP quando comparado ao resultado obtido com a Eq. (3.139).

3. Por último é necessário aplicar a função de limiarização nos coeficientes de detalhe obtidos na decomposição wavelet com base nos valores de limiar obtidos para cada nível j . Esta etapa irá determinar como os coeficientes serão atenuados ou zerados para reduzir ou eliminar o ruído distribuído entre eles. Como já discutido, as funções mais empregadas na filtragem de sinais de DP são as funções suave e abrupta, mas como a função abrupta tende a preservar melhor as características de amplitude, provendo melhor relação sinal ruído [9], esta é aplicada com maior frequência. Portanto, aplicaremos a função abrupta em nossas comparações e análises no Capítulo 6.

Capítulo 4

Algoritmos Genéticos

Neste capítulo abordaremos os conceitos básicos de computação evolucionária, mais precisamente a metodologia de otimização por meio da aplicação de algoritmos genéticos, a qual encontra inspiração a partir dos mecanismos de evolução natural descritos na teoria da evolução de Darwin [90]. Dentre estes conceitos, descreveremos sucintamente os princípios de evolução natural pela sobrevivência do mais forte. Em seguida, exploraremos os componentes necessários para o desenvolvimento de um algoritmo genético. Por fim, voltaremos um pouco da nossa atenção para Algoritmos Meméticos (MA), que incorporam aproximações baseadas em algoritmos de busca local ou informações específicas do problema, com intuito de adicionar algum conhecimento à estrutura dos Algoritmos Evolucionários (AE), incluindo AG, de modo que aumente a performance do método que será desenvolvido em nosso trabalho.

4.1 Inspiração para Algoritmos Genéticos

O teorema da evolução de Darwin trata da evolução de acordo com os princípios de seleção natural. Em um meio ambiente cada indivíduo deve competir por recursos para que possa sobreviver, e aqueles indivíduos que se mostram mais adaptados a este meio têm uma probabilidade maior de sucesso. Tomando o instinto básico de reprodução, estes indivíduos com maior aptidão possuem grandes chances de se reproduzirem e gerarem descendentes cada vez mais preparados para lidar com o ambiente que os cerca. Tal padrão é conhecido como **sobrevivência do mais forte** [85].

Outro processo que está associado a evolução natural, diz respeito aos traços fenotípicos, como características físicas e de comportamento exclusivas de cada in-

divíduo, as quais afetam a forma como ele lida com o ambiente e, portanto, sua aptidão. As informações contidas no **fenótipo** estão codificadas dentro de cada **gene** que constitui o **genótipo** (cromossomo). Na fase de reprodução, os genes são aleatoriamente alterados, em processos de **recombinação** ou de **mutação**, gerando um ou mais descendentes que conterão parte das características de cada pai. É através destas alterações nos genes que os traços fenotípicos variam. Os indivíduos mais aptos irão continuar a se reproduzir, gerando novos descendentes, de forma que a evolução progride para populações cada vez mais adaptadas.

É importante notar que todas as variações, sejam estas mutações ou recombinações, ocorrem num nível genotípico, i.e., com base nos genes de cada indivíduo. Já a seleção de cada ser da população será feita com base em sua aptidão, ou seja, no nível fenotípico.

Baseado em todo este processo evolutivo, John Holland começou a pesquisar sobre algoritmos que realizavam a evolução simulada de populações, resolvendo de forma eficiente o problema de encontrar bons cromossomos [91, 92]. A estes algoritmos, Holland designou de **algoritmos genéticos**.

A otimização consiste em melhorar a performance de um processo para alcançar um ou mais pontos ótimos. Os AG funcionam da mesma maneira, combinando a sobrevivência dos mais fortes com troca de genes (informações) que levem a população a atingir um melhor resultado.

4.2 Algoritmos Evolucionários

O algoritmo evolucionário forma uma base comum a suas diversas variantes. Dentre estas variantes, está o AG, que é o mais aplicado na literatura. Portanto, abordaremos as ideias principais dos AE.

Para que possamos determinar o quão apto ou forte é um indivíduo, é preciso determinar uma **função custo** das variáveis envolvidas no problema, permitindo uma medição abstrata de sua aptidão, onde quanto maior o valor desta melhor será o indivíduo. Assim, é possível selecionar um grupo composto pelos melhores candidatos para formar a próxima geração através de um processo de recombinação de dois ou mais destes candidatos (também denominado cruzamento) e/ou de mutação, a qual é aplicada a um único candidato. Consequentemente, surgem grupos de descendentes (filhos), que por sua vez são avaliados através da função custo e competem com a população anterior para formar a próxima geração. Com a nova população todo o processo pode ser repetido, até que se atinja uma solução (indivíduo) com

qualidade suficiente ou até que o algoritmo alcance um certo número de repetições (definido *a priori*). O diagrama de fluxo mostrado na Fig. 4.1 possibilita uma melhor associação das etapas fundamentais de um AE.

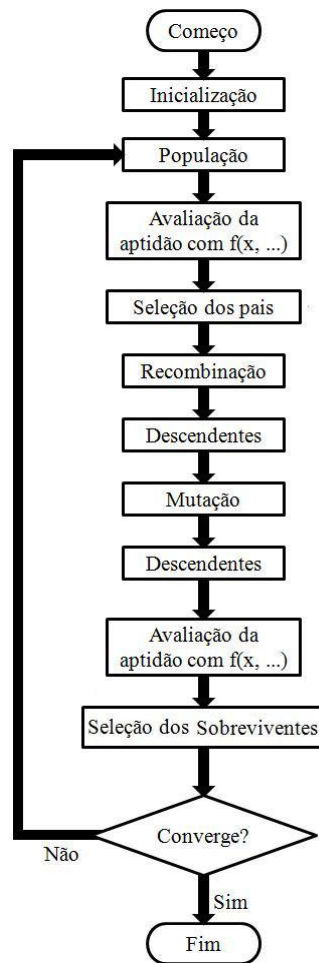


Figura 4.1: Diagrama de fluxo de um AE.

A cada nova iteração é selecionada uma nova população melhor adaptada, i.e., que apresenta melhores soluções para o problema em questão, resultando na sua convergência para um ótimo. Entretanto, são necessários cuidados para que a variação dos operadores de recombinação e mutação mantenham a diversidade dentro da população, para que se evite a convergência da população para valores ótimos locais ao invés da convergência para um ótimo global.

Vale ressaltar que as etapas de seleção, recombinação e mutação de um AE são processos estocásticos. Durante a seleção, mesmo que as chances de um candidato mais apto ser selecionado seja maior, ainda existirá a possibilidade de que um indivíduo mais fraco seja escolhido e possa vir a ser um dos pais. Na recombinação a escolha dos genes de cada pai que serão cruzados se faz de maneira aleatória. O mesmo ocorre no processo de mutação, onde os genes a serem alterados são escolhidos aleatoriamente.

4.3 Componentes de um AE

Observando a Fig. 4.1 podemos destacar os componentes mais relevantes de um AE, que também englobam as componentes de um AG:

- Representação;
- Função de aptidão;
- População;
- Seleção dos pais;
- Recombinação;
- Mutação;
- Seleção dos sobreviventes.

Estudaremos a seguir cada um destes componentes, além do modo de inicialização e da condição de finalização dos algoritmos.

4.4 Representação dos Indivíduos

A representação diz respeito a forma como vamos interpretar um possível candidato à solução no espaço onde ocorre o processo evolucionário (espaço genótipo), i.e., como mapear o fenótipo em um genótipo que o represente. Isto é importante, pois a busca evolucionária (recombinação e mutação) ocorre totalmente em nível genotípico, com a manipulação dos genes ou alelos que constituem o genótipo.

É necessário que esta representação seja reversiva, i.e., que além de permitir o mapeamento do fenótipo em genótipo (codificação), também permita o mapeamento do genótipo em fenótipo (decodificação), já que as etapas de avaliação da função custo, seleção dos pais e dos sobreviventes ocorrem no espaço fenótipo.

A codificação é uma etapa importante do problema por ser uma severa limitação da janela de informação que é observada a partir do sistema [93].

Em AG os tipos de representação normalmente aplicada são:

- binária - a representação mais clássica usada em GA, devido à sua simplicidade. Nesta, o genótipo é composto por um conjunto de dígitos binários (*bit-string*) de tamanho finito, que deve codificar uma solução de um dado problema. Ao representarmos números inteiros ou valores reais temos de tomar o cuidado de

aplicar a codificação *Grey*, que garante que dois inteiros consecutivos tenham distância Hamming igual a um [94]. Como exemplo a representação do número inteiro 7 em binário equivaleria a um genótipo igual a $\{1\ 0\ 0\}$ (código *Grey*);

- inteira - apesar de a representação binária ser a mais aplicada em AG, nem sempre esta se mostra a opção mais adequada. Podem ocorrer casos onde a representação por números inteiros seja a mais indicada. Por exemplo, se desejamos identificar qual o método de cálculo de limiar mais adequado para aplicar na transformada wavelet, verificando a teoria de WT anteriormente descrita, temos um conjunto de possíveis métodos $\{heursure, minimaxi, rigrsure, sqtwolog, scaledep\}$ que pode ser representado como $\{1, 2, 3, 4, 5\}$;
- valor real ou ponto flutuante - geralmente a maneira mais sensível de se representar um problema é usar a representação de valores reais, referidas como ponto flutuante do ponto de vista computacional. O genótipo é representado por um vetor como $X = [x_1, x_2, \dots, x_D]$ onde D é a dimensão do número de espaços de busca [95];
- permutação - quando há necessidade de se saber a ordem em que uma sequência de eventos ocorreu, é recomendado representar este como uma permutação de um conjunto de inteiros. Devemos cuidar para que cada valor de alelo (gene) ocorra somente uma vez na solução, conservando a propriedade de permutação. Uma das possibilidades, é fazer com que o i -ésimo elemento da representação se refira ao evento que ocorreu naquele local na sequência. Desta forma, para $[A, B, C]$ com permutação $[2, 3, 1]$, a representação é dada como $[B, C, A]$.

4.5 Função de Aptidão

A função de aptidão (ou função custo) funcionará como indicativo da força de cada candidato à solução, portanto é primordial na etapa de classificação e seleção dos indivíduos mais aptos em uma população. Podemos dizer que encontrar a função aptidão que descreve o problema é a tarefa mais importante dentro do desenvolvimento de qualquer AE, assim como o AG.

Seu objetivo é servir como uma medida da qualidade dentro de um espaço fenótipo, que por sua vez também indicará o estado de cada gene dentro do espaço genótipo. Portanto, é esta função que permitirá uma ligação entre o sistema e o processo evolutivo do AG.

Basicamente a função custo é uma representação de todas as variáveis que

desejamos otimizar num problema. E na grande maioria dos casos sua definição não é nada trivial, por isso devemos buscar defini-la com o devido cuidado e conhecimento das grandezas envolvidas no processo. No Capítulo 5 iremos mostrar passo a passo o modo como criamos nossa função custo.

4.6 População

A população em um AG define um multiconjunto de candidatos à solução no espaço genótipo. É na população que todo processo evolutivo ocorrerá, já que um único indivíduo não é capaz de evoluir por conta própria. Dada uma representação, temos de definir o tamanho da população μ e representar cada indivíduo com seu genótipo.

É por meio do cálculo da aptidão de cada genótipo que constitui uma dada população, que os operadores de seleção (seleção dos pais e seleção dos sobreviventes) definem os melhores e piores indivíduos desta população portanto aqueles que serão recombinados e aqueles que farão parte da próxima população. Em geral, o tamanho da população não se altera durante a execução do AG, mas há casos em que o tamanho da população pode diminuir com a busca evolucionária.

Uma característica na população é sua diversidade, ou seja, a medida do número de diferentes soluções presentes. Pode ser referida ao número de diferentes valores de aptidão, neste caso um único valor de aptidão não implica que exista somente um fenótipo, já que fenótipos distintos podem ter a mesma aptidão; também podemos aplicar a medida dos diferentes números de fenótipos na população e caso haja apenas um fenótipo não há garantia de que exista um único genótipo; por fim, se considerarmos a medida do número de genótipos distintos, teremos para um único genótipo somente um fenótipo e um valor de aptidão presentes.

É desejável e importante que a população tenha uma boa diversidade, principalmente em sua inicialização, pois quanto maior esta o for, maior será a região explorada, o que aumenta as chances de encontrarmos melhores indivíduos. Apesar, da diversidade tender a diminuir com a evolução da população para uma região de convergência, necessitamos de meios para tentar preservar esta diversidade dentro da população, para evitar que fiquemos presos em um ótimo local. Uma boa forma de se fazer isso é aumentar a taxa de indivíduos que sofrerão mutação e aplicar métodos de seleção probabilísticos.

Na literatura são descritos dois tipos de modelos populacionais de AG [85]:

- modelo geracional - começamos com uma população de tamanho μ , os pais selecionados para cruzamento também terão tamanho μ . Após a aplicação dos operadores de variação gerar-se-ão β descendentes com o mesmo tamanho da população inicial, estes por sua vez constituirão a próxima geração que tomará o lugar de toda a população inicial;
- modelo de estado estacionário - nem toda a população é alterada de uma única vez. Somente $\beta (< \mu)$ indivíduos antigos serão substituídos por β novos descendentes. Isto promove um salto geracional igual a β/μ .

4.7 Seleção dos Pais

É o mecanismo responsável pela seleção dos genótipos que se tornarão os pais da próxima linha de descendentes, levando em conta a qualidade de cada indivíduo. É o que a torna, juntamente com a etapa de seleção de sobreviventes, responsável por melhorar a qualidade da população. Normalmente, a seleção é feita de maneira probabilística, o que dá chances, ainda que menores, a candidatos com aptidão inferior de se tornarem pais, melhorando a diversidade na população.

Diversos tipos de métodos de seleção são descritos na literatura, incluindo seleção por truncamento, proporcional a aptidão, torneio, ranqueamento, roleta (*roulette wheel*), entre outros [96–98], mas o ponto chave é dar preferência a indivíduos mais aptos.

Nesta dissertação voltaremos nossa atenção para o método de seleção por ranqueamento e o de Seleção por *Roulette Wheel* (*Roulette Wheel Selection* - RWS), um dos métodos mais empregados em AG [85].

4.7.1 Seleção por Ranqueamento

É um método estatístico especificamente desenvolvido para selecionar a maior parte dos melhores sistemas em uma população, onde todos os indivíduos estão competindo. Este mantém uma pressão de seleção constante ao classificar a população com base na função custo, e designando as probabilidades a cada candidato de acordo com sua classificação, ao invés de classificá-los diretamente pelo seu valor de aptidão. Duas das formas clássicas apresentadas em [85] são:

- linearmente decrescente - é parametrizada para um valor s ($1.0 < s \leq 2.0$). Para AG onde o número de descendentes β gerados é igual ao tamanho da

população μ ; o melhor indivíduo recebe classificação $\mu - 1$, e o pior a classificação 0; assim a probabilidade de seleção para um candidato de classificação i será:

$$P_{rank-linear}(i) = \frac{(2-s)}{\mu} + \frac{2i(s-1)}{\mu(\mu-1)} \quad (4.1)$$

- exponencialmente decrescente - como na seleção linear, a quantidade de pressão aplicada é limitada ($s = 2$). Para uma maior pressão em selecionar indivíduos acima de uma aptidão média, o ranqueamento exponencial pode ser aplicado por meio da Eq. (4.2), onde c é um fator de normalização escolhido de modo que o somatório das probabilidades seja unitário, o que dependerá do tamanho da população.

$$P_{rank-exponencial}(i) = \frac{1 - e^{-i}}{c} \quad (4.2)$$

4.7.2 Algoritmo de Seleção por Roleta (*Roulette Wheel*)

O nome dado ao algoritmo faz referência ao ato de girar uma roleta, em que cada repartição reflete a probabilidade de seleção de um indivíduo, a qual está relacionada à sua aptidão. Portanto, o grupo de pais selecionados reflete de forma aproximada a distribuição de probabilidade da seleção. Para o caso em que o número de membros selecionados é igual ao tamanho da população, o RWS inicialmente calcula a proporção $pr(i)$ do valor de aptidão de cada indivíduo $f(x_i)$ em relação ao valor total de aptidão de toda população. A proporção é normalmente obtida por:

$$pr(i) = \frac{f(x_i)}{\sum_{i=0}^{\mu} f(x_i)} \quad (4.3)$$

Então, o operador repete μ vezes, selecionando um indivíduo da população corrente para gerar a nova população. A cada vez, um número real r , uniformemente selecionado na faixa de $[0, 1)$, é gerado, e o indivíduo x_k , onde k satisfaz a Eq. (4.4), é selecionado, dando maior chance de seleção para o indivíduo mais adaptado. Um pseudocódigo do RWS é mostrado na Fig. 4.2.

$$k = \min \left\{ \mu \mid \sum_{i=1}^{\mu-1} pr(i) \leq r, \mu = 1, 2, \dots, \mu \right\} \quad (4.4)$$

```

INICIO
  PARA i=1:μ
    pr(i)=f(x(i))/ somatorio(f(x(i)));
  FIM
  definir individuo=1;
  ENQUANTO (individuo ≤ μ)
    gerar um valor uniforme [0,1): r=rand(1);
    definir índice: i=1;
    ENQUANTO (somatorio(pr(i)) < r)
      definir i=i+1;
    FIM
    definir grupo_pais(individuo)= populacao(i);
    definir individuo = individuo+1;
  FIM
FIM

```

Figura 4.2: Pseudocódigo para RWS.

4.8 Recombinação

A recombinação ou cruzamento é um operador de variação estocástico que combina partes de dois cromossomos pais, a fim de produzir um ou dois descendentes com partes do material genético de ambos pais. Assim, esperamos que a maior parte dos filhos gerados tenham traços genéticos com melhor aptidão. Obviamente, como o processo é estocástico, não se pode garantir que todos os descendentes terão características desejáveis.

O tipo de recombinação aplicada variará com o modo como o genótipo foi representado. Portanto, variações de recombinação são propostas na literatura para representação binária, número inteiro, em valor real ou ponto flutuante e permutação [96, 99]. Nos limitaremos a apenas algumas delas.

4.8.1 Recombinação para Representações Binárias

Cruzamento de um ponto

A partir de dois genótipos (pais) de comprimento g , é escolhido aleatoriamente um ponto q no intervalo $[1, g - 1]$, e as porções dos dois cromossomos além deste ponto são trocadas para formar os descendentes, como na Fig. 4.3.




Figura 4.3: Cruzamento de um ponto.

Cruzamento multiponto

É similar ao anterior, exceto que n pontos de cruzamento são aleatoriamente escolhidos sem duplicação, dividindo o cromossomo em diversos segmentos que são trocados para gerar os descendentes, conforme ilustrado na Fig. 4.4.




Figura 4.4: Cruzamento multiponto para $n = 3$.

Cruzamento uniforme

Generaliza a ideia de tomar cada gene como um ponto em potencial de cruzamento. Para tanto, é criada uma série de variáveis aleatórias com distribuição uniforme entre $[0, 1]$, que informarão qual pai irá contribuir com o *bit*. Em cada posição, o correspondente gene dos pais são trocados caso a variável aleatória possua seu valor acima de um parâmetro α , caso contrário não ocorre a troca. Um exemplo é mostrado na Fig. 4.5.




Figura 4.5: Cruzamento uniforme.

4.8.2 Recombinação para Representações Inteiras

Na representação inteira é possível aplicar os mesmos tipos de cruzamentos vistos para o caso binário, só que agora os alelos serão números inteiros ao invés de um *bit*.

4.8.3 Recombinação para Representações Reais ou Ponto Flutuante

Podemos seguir dois caminhos no cruzamento de cromossomos em ponto flutuante:

- recombinação discreta é realizada conforme o cruzamento aplicado na representação binária, entretanto os genes agora serão valores em ponto flutuante.

O empecilho desta tática é que não serão gerados filhos com novos valores de ponto flutuante, havendo apenas uma alteração das posições dos valores existentes.

- recombinação aritmética se utiliza da Eq. (4.5) (para α em $[0, 1]$) para permitir a criação de um novo material genético nos descendentes d_i , a partir dos genótipos de cada pai p_i e m_i . No entanto, por se tratar de um processo médio, a variação dos valores do alelo fica reduzida.

$$d_i = \alpha p_i + (1 - \alpha) m_i \quad (4.5)$$

Mostraremos alguns tipos de recombinações aritméticas nos parágrafos que se seguem.

Recombinação Simples

Inicialmente é definido um ponto k aleatório, como no cruzamento binário de um ponto. Em seguida, os alelos antepostos a este ponto são copiados para o cromossomo do descendente, enquanto que os alelos pospostos são gerados por meio de uma média aritmética dos pais, conforme a Fig. 4.6. As Eqs. (4.6) e (4.7) mostram os descendentes gerados com por meio desta recombinação.

$$\text{Descendente 1} : [p_1, \dots, p_k, \alpha \cdot m_{k+1} + (1 - \alpha) p_k, \dots, \alpha \cdot m_g + (1 - \alpha) p_g] \quad (4.6)$$

$$\text{Descendente 2} : [m_1, \dots, m_k, \alpha \cdot p_{k+1} + (1 - \alpha) m_k, \dots, \alpha \cdot p_g + (1 - \alpha) m_g] \quad (4.7)$$




Figura 4.6: Recombinação simples para $k = 3$ e $\alpha = 1/2$.

Recombinação Aritmética Única

É semelhante à recombinação simples, só que a média é realizada apenas no ponto k . Portanto, os descendentes podem ser definidos como se segue:

$$\text{Descendente 1} : [p_1, \dots, p_k, \alpha \cdot m_{k+1} + (1 - \alpha) p_k, p_{k+1}, \dots, x_g] \quad (4.8)$$

$$\text{Descendente 2} : [m_1, \dots, m_k, \alpha \cdot p_{k+1} + (1 - \alpha) m_k, m_{k+1}, \dots, m_g] \quad (4.9)$$

A Fig. 4.7 mostra um exemplo com o valor de $k = 4$ e $\alpha = 1/4$.



Figura 4.7: Recombinação aritmética única para $k = 4$ e $\alpha = 1/4$.

Recombinação Aritmética Completa

Realiza o somatório dos alelos de ambos pais para cada gene, como ilustra a Fig. 4.8. Analisando as Eqs. (4.10) e (4.11) vemos que para o caso em que $\alpha = 1/2$, os descendentes serão gêmeos.

$$\text{Descendente 1} = \alpha \cdot p + (1 - \alpha) m \quad (4.10)$$

$$\text{Descendente 2} = \alpha \cdot m + (1 - \alpha) p \quad (4.11)$$



Figura 4.8: Recombinação aritmética completa para $\alpha = 3/4$.

4.9 Mutaç o

  um operador que insere varia es nos alelos de um cromossomo para gerar um filho, na maioria das vezes muito semelhante ao pai. Esta varia o pode ser local ou global, i.e., aplicada em um  nico ou em todos genes. A opera o   feita ocasionalmente (normalmente com uma probabilidade ρ_m), mas altera aleatoriamente o valor de uma posi o na s rie gen tica. Conseq entemente, o processo de muta o sempre ser  estoc stico.

A muta o pode ser importante para suprir a popula o com alguma diversidade, pois pode alcan ar qualquer ponto (dado tempo o bastante), propiciando a conex o desta com o espa o de busca. De certo modo cada gen tipo que comp e uma solu o pode ser atingido pelos operadores de varia o [100].

A muta o aplicada tamb m depender  do tipo de representa o associada ao problema. Algumas t cnicas utilizadas ser o discutidas nas pr ximas se es.

4.9.1 Mutação para Representações Binárias

A mutação é feita para cada gene do cromossomo (de tamanho g) pela inversão do *bit* com uma probabilidade p_m . Assim, cerca de $g \cdot p_m$ valores do genótipo mudarão de valor.

A escolha do valor de probabilidade dependerá do resultado desejado. No entanto, é comum a aplicação de um valor baixo de forma que na média cerca de um gene por geração seja alterado

4.9.2 Mutação para Representações Inteiras

Em [85] são descritas duas formas principais de mutação para números inteiros, as quais mudam cada gene separadamente com probabilidade p_m .

Reajuste Aleatório

Com probabilidade p_m , um novo valor de alelo é escolhido aleatoriamente de um conjunto de valores possíveis em cada posição. É indicado para situações onde o gene codifica atributos cardinais;

Mutação Arrastada

Soma pequenos valores a cada gene com probabilidade p_m . Estes valores são amostrados para cada posição, a partir de uma distribuição simétrica em torno do zero. Se faz necessária, a presença de parâmetros para controle dos saltos que a mutação toma no espaço de busca, os quais nem sempre são fáceis de se definir. Também é possível aplicar o reajuste aleatório juntamente com a mutação arrastada (*creep mutation*), o que tende a ocasionar pequenas mudanças no gene, de modo que não gera tantos genes distantes no espaço de busca.

4.9.3 Mutação para Representações Reais ou Ponto Flutuante

O valor do gene é alterado aleatoriamente dentro de seu domínio, entre um limite inferior L_i e um limite superior U_i , conforme uma probabilidade de mutação. Com base na distribuição de probabilidade podemos destacar dois tipos operadores, de mutação uniforme e de mutação não uniforme com distribuição fixa.

Mutação Uniforme

Os novos valores de alelos são retirados dos limites $[L_i, U_i]$ de maneira uniforme e aleatória. Normalmente é aplicada com alguma probabilidade de mutação.

Mutação não Uniforme com Distribuição Fixa

Geralmente causa pequenas alterações no valor do gene adicionando uma quantidade retirada aleatoriamente de uma distribuição Gaussiana de média zero e desvio padrão especificado, ajustando o valor para os limites $[L_i, U_i]$ (caso seja necessário). Como na distribuição Gaussiana a maior parte das amostras se concentra dentro do desvio padrão, a maioria das alterações dos genes será pequena. Ainda assim, pode acontecer (com baixa probabilidade) que valores elevados sejam gerados devido ao prolongamento da distribuição, que nunca chega a ser nula. Alguns trabalhos têm aplicado a distribuição de Cauchy, a qual tem uma probabilidade um pouco maior de gerar valores altos.

4.10 Seleção dos Sobreviventes

A etapa de seleção dos sobreviventes, também denominada substituição, se encarrega de identificar quais os indivíduos (dentre uma população de μ pais e de β descendentes) que irão compor a próxima geração de μ candidatos à solução.

O processo de escolha é feito com base na qualidade (valor de aptidão) que cada indivíduo possui, assim como ocorre na seleção dos pais, só que envolvendo um estágio diferente. Como consequência, os candidatos com maior aptidão tendem a ser mais favorecidos que outros, por isso na grande parte das implementações em AG a seleção é determinística, diferindo da seleção de pais que quase sempre é estocástica.

As variações dos tipos de estratégias de substituição vistas na literatura geralmente se baseiam na aptidão ou na idade dos indivíduos.

4.10.1 Substituição Baseada na Idade

A substituição se baseia na idade do indivíduo, sendo que cada indivíduo existe na população por um número limitado de gerações. Assim a sobrevivência dos indivíduos mais aptos é decidida no estágio de recombinação e mutação.

Quando ocorre de o número de descendentes ser igual ao dos pais ($\beta = \mu$), cada

indivíduo existe por uma única geração, e os pais serão substituídos por todos os filhos. Se o número de descendentes for menor que o número de pais ($\beta < \mu$), basta descartar β pais e substituí-los pelos filhos.

De forma alternativa a seleção dos pais a serem substituídos pode ser feita aleatoriamente [101], entretanto tal estratégia tende a ocasionar a perda do melhor membro dentro da população. Por isso não é considerada uma alternativa adequada.

4.10.2 Substituição Baseada na Aptidão

Aplicada para escolher μ candidatos dos $\beta + \mu$ descendentes e pais que irão avançar no AG, a decisão é feita verificando a aptidão de cada candidato.

Nesta etapa, também podemos aplicar os esquemas discutidos para seleção de pais. Com isso, comentaremos apenas alguns mecanismos.

Substituição do Pior

São selecionados os β piores membros da população para que sejam substituídos. Em geral ocasiona uma rápida melhora da população, o que pode ser indesejável, já que leva a uma convergência prematura para o membro mais adaptado desta população. É mais indicado para algoritmos que contenham uma população muito grande ou que gastem muito tempo para execução de um ciclo.

Elitismo

Sempre mantém o membro mais apto da população, de maneira que, se este membro for selecionado para ser substituído por um descendente com menor aptidão, o mesmo não será excluído, permanecendo na população. Também pode ser utilizado em conjunto com a estratégia baseada na idade, e de substituição estocástica baseada na aptidão.

4.11 Inicialização

A inicialização é o passo que gera (semeia) de modo aleatório os indivíduos que irão compor a população inicial. Qualquer heurística pode ser aplicada para gerar esta população com alta aptidão. Tal aprimoramento inicial da população pode ser obtido através de estratégias para inserção de algum conhecimento denominado meme, conforme discutiremos na seção de algoritmos meméticos.

4.12 Condição de Terminação

Caso seja conhecido qual o nível ótimo de aptidão, podemos fazer com que o AG pare sua execução após encontrar tal ótimo. Em contrapartida, pode ocorrer (em uma situação real) que este ótimo não seja alcançável, para tanto podemos interromper o algoritmo após este atingir um valor aceitável em comparação ao ótimo com uma dada precisão $\varepsilon > 0$.

Ainda assim, pode ser que o AG não consiga atingir tal critério de parada. Então, é preciso aplicar uma condição que garantirá a parada da busca. Em [85] são propostas as seguintes opções:

1. estipular um tempo máximo gasto pela Unidade Central de Processamento (Center Processing Unit - CPU) no processamento do AG;
2. o número total de avaliações de aptidão alcançar um certo limite;
3. o valor de aptidão permanecer sob um mesmo valor limiar por um dado período de tempo;
4. a diversidade da população cair abaixo de um limiar estipulado.

Também é aceitável aplicar dois ou mais critérios de parada ao mesmo tempo, ou outras regras de parada que melhor se adaptem ao problema em questão. A ideia fundamental a ser seguida é que devemos garantir que o algoritmo pare em algum momento.

4.13 Operação de um Algoritmo Genético

O modo como um AE, incluindo o AG, opera pode ser explicado através da Fig. 4.9, que mostra três estágios de uma busca evolucionária. Na esquerda vemos a etapa após a inicialização, em que a maioria dos indivíduos estão aleatoriamente distribuídos por todo o espaço de busca. No centro da Fig. 4.9 observamos que depois de algumas iterações os operadores de variação e seleção fazem com que os membros da população comecem a se deslocar para as regiões de maior aptidão. Próximo do fim da busca, todos os indivíduos começam a se concentrar nas regiões em torno dos picos da função, i.e., em regiões que definem o ótimo local e global (como mostrado na direita da Fig. 4.9). Esta etapa final é delicada, pois os indivíduos podem ficar todos presos em um único ponto de ótimo local. Este processo evolutivo pode ser classificado em fase de exploração, onde os membros da população estão espalhados

no espaço de busca; e em fase de exploração, quando os valores se concentram em torno de pontos com boas soluções.




Figura 4.9: Evolução de um AG quanto a distribuição da população.

AE possuem um comportamento temporal como o observado na Fig. 4.10, que mostra como o melhor indivíduo da população evolui seu valor de aptidão com o passar do tempo (ciclos), melhorando iterativamente e rapidamente a aptidão da solução inicial. Este gráfico recebe o nome de comportamento de qualquer instante, remetendo a ideia de que o algoritmo pode parar sua execução a qualquer instante, fornecendo uma solução, mesmo que local.

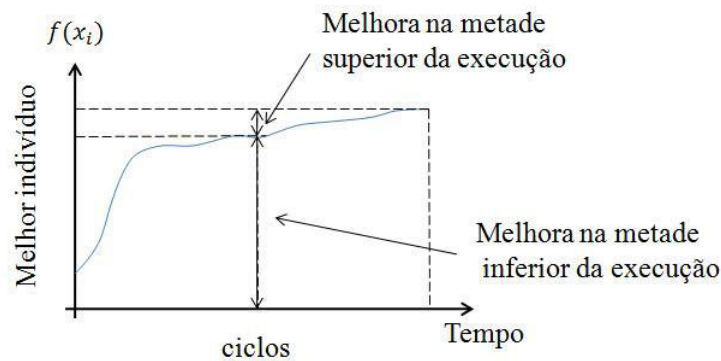


Figura 4.10: Progresso no tempo de um AG para seu indivíduo mais apto.

A curva da Fig. 4.10 evidencia que após algumas iterações a melhora obtida é muito pequena, por isso serve como ferramenta para nos ajudar a ajustar as condições de parada do algoritmo. Fica claro que executar o algoritmo por uma quantidade muito grande de ciclos pode não ser tão interessante, já que perderíamos muito tempo para obter melhoras não tão significativas.

4.14 Hibridização: Algoritmos Meméticos

O método de busca por AE tem uma boa eficiência para uma ampla faixa de problemas; ainda assim é possível elevar a sua taxa de sucesso e a sua eficiência. Ao alterar ligeiramente um AE puro com outras metodologias de busca já conhecidas ou com heurísticas que agreguem informações relevantes a respeito do problema em

questão, a curva de performance global do algoritmo se altera da performance de um AE puro para a de um método desenvolvido especificamente para o problema, como pode ser visto na Fig. 4.11.




Figura 4.11: Comparação das curvas de performance.

AE não são bons em encontrar a solução final, pois evoluem lentamente devido à natureza estocástica dos operadores. Uma maneira eficiente de se incorporar conhecimento a um AE, incluindo um AG, é agregar uma busca sistemática da vizinhança de boas soluções encontradas no processo evolucionário. Isso pode ser empregado pela adição de um algoritmo ou heurística de busca local ao ciclo do AG empregado no problema.

Dawkin em [102] inseri o conceito de “memes”. Um meme pode ser entendido como uma unidade de transmissão cultural, do mesmo modo que um gene forma uma unidade de transmissão biológica, conforme sugere a Fig. 4.12. A adição de uma fase de aprendizagem (desenvolvimento) ao ciclo evolucionário pode ser vista como uma interação meme-gene.




Figura 4.12: Associação da ideia de: (a) meme; (b) gene.

Moscato em [103] criou a nomenclatura de algoritmo memético para designar uma gama de técnicas de busca evolucionária baseadas na adição de uma ou mais fases de busca local ou de informações específicas a respeito do problema.

A busca local é um processo iterativo, que vasculha um conjunto de pontos numa dada vizinhança de um bom candidato à solução e o substitui pelo vizinho caso este apresente uma melhor qualidade. Muitas formas de busca local podem ser implementadas em um problema envolvendo AG. Não entraremos em detalhes a respeito destas metodologias de busca, mas aqueles que desejam maiores informações podem recorrer a [85]

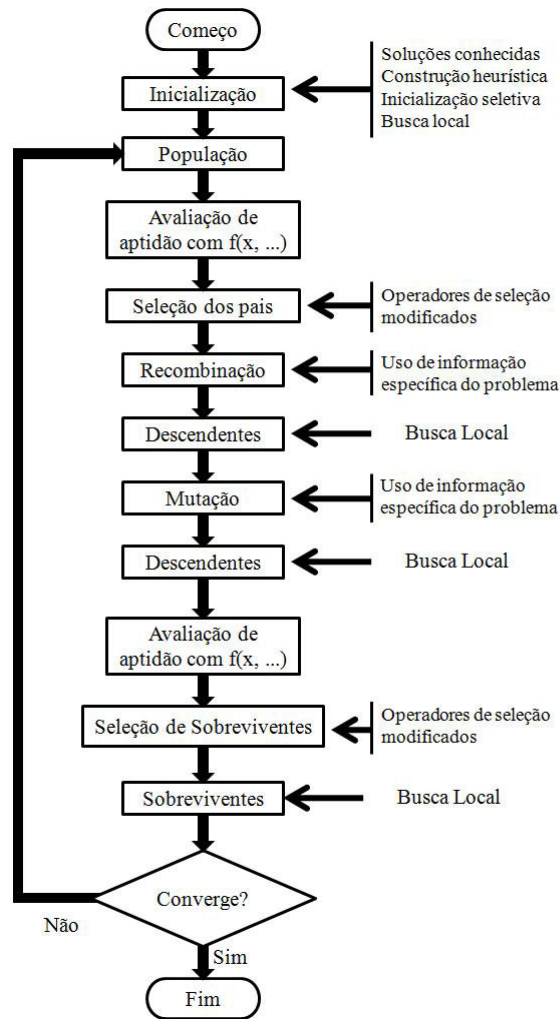


Figura 4.13: Possíveis locais para inserção de conhecimentos em um AG.

Portanto, um MA surge como uma ferramenta de melhora ou desenvolvimento da fase de aprendizagem no ciclo evolucionário. E a forma na qual um AG pode ser utilizado junto com a busca local e/ou com um conhecimento específico é ilustrada na Fig. 4.13.

Analisando a Fig. 4.13, vemos que a busca local pode ser realizada junto da etapa de inicialização, para fornecer uma população de partida formada por um conjunto de pontos que são localmente ótimos com respeito a algum operador de movimento. Também é possível inserir na população alguma boa solução conhecida, ou ainda criar alguma heurística que melhore os indivíduos iniciais. Outro recurso

comum é fazer uma inicialização seletiva, em que um amplo número de soluções aleatórias são criadas e as melhores selecionadas por meio de um torneio.

Entretanto, a busca local é mais aplicada na exploração dos descendentes gerados na fase de recombinação ou na fase de mutação [85]. Apesar de não mostrado na Fig. 4.13, a busca é feita alterando sutilmente o genótipo dos indivíduos mais bem adaptados e avaliando estes novos candidatos no espaço fenótipo, para decidir se serão inseridos na população.

Outra alternativa, é aplicarmos operadores de seleção modificados no processo de seleção dos pais ou dos descendentes. Em [104] os autores sugerem a aplicação de um algoritmo de Cozimento Simulado (*Simulated Annealing* - SA) para fazer a seleção dos indivíduos.

Podemos ainda, inserir alguma informação específica de um dado problema para tentar melhorar a aptidão da população tanto na fase de recombinação quanto na de mutação.

Capítulo 5

Método de Seleção da Wavelet Mãe Baseado na Relação Sinal Ruído e Método de Redução de Ruídos por Algoritmo Genético

Munidos de todas informações apresentadas nos capítulos anteriores, nos tornamos aptos à vislumbrar áreas ainda não exploradas e propor novos métodos com o intuito de aperfeiçoar as atuais técnicas de redução de ruídos por meio da transformada wavelet.

Portanto, neste capítulo, aplicaremos o conhecimento adquirido para o desenvolvimento de uma metodologia de Seleção do Número de Níveis de Decomposição com Base na Densidade Espectral de Potência (*Power Spectrum Based Level Selection* - PSBLS) do dado de DP obtido, e um novo método de Seleção da Wavelet Mãe Baseado na Relação Sinal Ruído (SNRBWS) dos coeficientes gerados na decomposição multirresolução do sinal estimado. Por último, apresentaremos uma alternativa para a otimização simultânea de todos os parâmetros envolvidos na filtragem wavelet como consequência dos estudos de AG.

5.1 Parâmetros de Avaliação de Filtragem

Antes de voltarmos nossa atenção para a descrição dos métodos mencionados anteriormente, é importante detalharmos parâmetros que têm sido aplicados na avaliação da eficiência da redução de ruídos pela WT, os quais serão necessários

para o entendimento dos métodos que virão a ser discutidos neste capítulo, além de exercerem um papel fundamental no desenvolvimento do Capítulo 6, onde faremos a comparação e a análise dos resultados de filtragem para cada um dos algoritmos aqui estudados.

Inevitavelmente, em qualquer processo de eliminação de ruídos por wavelet ocorrerá alguma distorção no sinal obtido, em consequência da atenuação de componentes significativas que compõem o sinal desejado durante a fase de limiarização.

Vários critérios podem ser aplicados para estimar o nível de distorção que ocorreu durante a filtragem. Denominamos $x_1(t)$ o sinal que desejamos obter (ideal) e $x_2(t)$ o sinal resultante do processo (estimado), ambos contendo N amostras.

5.1.1 Erro Médio Absoluto

O Erro Médio Absoluto (EMA) é uma medida estatística de quão distante o valor estimado de um dado está do seu valor ideal. A distância é dada pelo valor absoluto da diferença, entre estes valores, ou seja,

$$EMA = \frac{1}{N} \sum_{i=1}^N |x_1(i) - x_2(i)| \quad (5.1)$$

Em [28] os autores utilizaram este parâmetro para verificar a qualidade dos sinais filtrados.

5.1.2 Erro Quadrático Médio

Em estatística o Erro Quadrático Médio (EQM) é um critério, alternativa derivada do EMA, destinado a avaliar a diferença entre um estimador e o verdadeiro valor da quantidade estimada. Em termos práticos, o EQM corresponde à soma da variância e da tendenciosidade, conforme a Eq. (5.2).

Este parâmetro pode ser usado para dar uma indicação de qual o melhor estimador (em nosso caso, as variáveis aplicadas na filtragem wavelet), ou seja, um EQM pequeno frequentemente indica uma variação mínima entre o resultado esperado e o resultado obtido, portanto, um bom estimador.

$$EQM = \frac{1}{N} \sum_{i=1}^N |x_1(i) - x_2(i)|^2 \quad (5.2)$$

Se o EQM é zero, indica que o estimador produz um resultado perfeito, mas tal situação raramente ocorre.

O EQM tem sido um dos critérios mais aplicado em publicações destinadas ao tratamento de sinais de DP [26, 30, 32, 71, 83] caracterizaram diversos métodos de filtragem com base no EQM; no entanto, em [1] os autores utilizaram uma variável a mais, como se segue

$$EQM_{\sigma} = \frac{1}{N\sigma_n^2} \sum_{i=1}^N |x_1(i) - x_2(i)|^2 \quad (5.3)$$

onde σ_n^2 corresponde à potência total do ruído. Neste caso, se o método rejeitar todos os componentes de ruído, o EQM_{σ} será unitário. Em outras palavras quanto mais próximo de 1 for o valor de EQM_{σ} , melhor o método será em extrair o ruído.

Apesar de ser um bom parâmetro de avaliação, o EMQ tende a dar um peso maior para grandes erros do que para pequenos, enfatizando dados discrepantes através da mediana dos dados de amostra.

5.1.3 Raiz Quadrada do Erro Quadrático Médio

Como o nome sugere, a Raiz Quadrada do Erro Quadrático Médio (REQM) é definida pela a raiz quadrada do EQM, como indicado na Eq. (5.4). Serve como uma medida das diferenças individuais (resíduos) entre o valor esperado e o valor estimado, compactando-as em um único valor de previsão.

$$REQM = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_1(i) - x_2(i)|^2} \quad (5.4)$$

Luo Hongxia *et al.* [28] aplicaram o REQM como um dos parâmetros de análise de performance de filtragem.

O REQM também pode ser calculado em sua forma normalizada, onde o resultado da Eq. (5.4) é dividido pela diferença entre os valores de máximo e mínimo do dado aproximado, ou seja,

$$NREQM = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N |x_1(i) - x_2(i)|^2}}{(max(x_1) - min(x_1))} \quad (5.5)$$

5.1.4 Coeficiente de Correlação

O Coeficiente de Correlação (CC) mede o grau de semelhança (correlação) global entre duas variáveis, bem como a direção dessa semelhança (se positiva ou negativa). O resultado deste parâmetro sempre se encontra entre -1 e $+1$. O sinal serve como indicativo da direção, onde:

- $CC = -1$ indica que ambos os sinais são iguais, mas reversos (colineares em sentido oposto, i.e., um giro de 180° na forma de onda);
- $CC = 0$ significa que os sinais são ortogonais;
- $CC = +1$ significa que os sinais são idênticos, ou seja, estão perfeitamente correlacionados.

Portanto, quanto mais próximo da unidade este parâmetro for, melhor será a extração de ruídos. O CC pode ser calculado através da seguinte equação:

$$CC = \frac{\sum_{i=1}^N (x_1(i) - \bar{x}_1) (x_2(i) - \bar{x}_2)}{\sqrt{\sum_{i=1}^N (x_1(i) - \bar{x}_1)^2 \sum_{i=1}^N (x_2(i) - \bar{x}_2)^2}} \quad (5.6)$$

onde as variáveis \bar{x}_1 e \bar{x}_2 correspondem, respectivamente, às médias aritméticas do sinal desejado e do sinal obtido na filtragem. Assim sendo,

$$\bar{x}_1 = \frac{\sum_{i=1}^N x_1(i)}{N} \quad (5.7)$$

e

$$\bar{x}_2 = \frac{\sum_{i=1}^N x_2(i)}{N}. \quad (5.8)$$

A Eq. (5.6) foi utilizada em [25, 26, 44] como critério de avaliação e também forma a base para o método de seleção da wavelet mãe baseado na correlação (CBWS), citado em [9, 30, 44].

Xu Zhongrong [76] e Luo Hongxia *et al.* [28] recorreram ao coeficiente de correlação normalizado, dado por:

$$NCC = \frac{\sum_{i=1}^N x_1(i) x_2(i)}{\sqrt{\sum_{i=1}^N x_1^2(i) \sum_{i=1}^N x_2^2(i)}} \quad (5.9)$$

5.1.5 Diferença de Energia

A Diferença de Energia (DEn) indica o valor absoluto da perda de energia entre o estimador e o valor obtido durante o processamento wavelet, sendo calculado por:

$$DEn = \left| \sum_{i=1}^N x_1^2(i) - \sum_{i=1}^N x_2^2(i) \right| \quad (5.10)$$

Luo Hongxia *et al.* [28] também usaram este parâmetro em suas comparações.

5.1.6 Razão Sinal Ruído

A Razão Sinal Ruído (*Signal to Noise Ratio* - SNR) estabelece a razão entre a energia do sinal desejado e do ruído, Em outras palavras, a SNR é dada pela relação entre as energia do sinal e a potencia do ruído, i.e.,

$$SNR = \frac{E_{sinal}}{E_{ruído}} = \left(\frac{A_{sinal}}{A_{ruído}} \right)^2 \quad (5.11)$$

onde A_{sinal} e $A_{ruído}$ são, respectivamente, a máxima amplitude do sinal e a máxima amplitude do ruído.

Normalmente a medição é realizada em escala logarítmica, em decibéis dB, por meio de [26, 32, 73]:

$$SNR_{dB_1} = 10 \log \left(\frac{E_{sinal}}{E_{ruído}} \right) = 10 \log \left(\left(\frac{A_{sinal}}{A_{ruído}} \right)^2 \right) \quad (5.12)$$

Algumas publicações [27, 41, 75] aplicam outro tipo de SNR, levando em conta o sinal desejado e o sinal resultante:

$$SNR_{dB_2} = 10 \log \left(\frac{\sum_{i=1}^N x_2^2(i)}{\sum_{i=1}^N (x_1(i) - x_2(i))^2} \right) \quad (5.13)$$

Genericamente a SNR é definida como na Eq. (5.14), que avalia a razão do valor da amostra de máxima amplitude do sinal e o valor da amostra de máxima amplitude do ruído. Este critério foi usada em [25, 41, 76].

$$SNR_{dB} = 10 \log \left(\frac{\max(\text{signal})}{\max(\text{ruído})} \right) \quad (5.14)$$

A Eq. (5.14) também será aplicada no desenvolvimento de nossa proposta de seleção da wavelet mãe baseada na relação sinal ruído (SNRBWS).

5.1.7 Nível de Redução de Ruído

Satish and Banu [45] propõem o uso do Nível de Redução de Ruído (NRR) como uma alternativa para avaliação prática, pois em muitos casos não se sabe qual é o sinal que desejamos obter na filtragem, ou seja, não conhecemos o sinal de referência $x_1(i)$. O NRR é calculado por:

$$NRR = 10 \log \frac{1}{N} \sum_{i=1}^N |x_n(i) - x_2(i)|^2 \quad (5.15)$$

onde $x_n(i)$ é o sinal ruidoso adquirido na medição.

5.1.8 Erro de Amplitude

O Erro de Amplitude (EA) fornece uma medida da variação percentual entre a amplitude do sinal ideal A_1 e a amplitude do sinal resultante A_2 , ou seja,

$$EA = \left| \frac{A_1 - A_2}{A_1} \right| \times 100\% \quad (5.16)$$

Este critério surge em [26, 30, 45, 83] como modo de avaliação juntamente com algum parâmetro de cunho estatístico como EQM, SNR ou CC. Pode ser utilizado tanto para amplitude máxima quanto mínima.

5.1.9 Coeficiente de Preservação de Informações

Para estimar o efeito da redução de ruídos por WT, Zhao *et al.* [31] propõem um novo conceito de coeficiente de avaliação da perda de informação, o qual apresenta um critério mais amplo quanto ao efeito da filtragem wavelet sobre diferentes bases, refletindo similaridades holísticas e intuitivas de um ponto de vista estatístico, bem como características locais do sinal filtrado.

Os autores sugerem o uso de um Coeficiente de Preservação de Informações (CPI), dado por:

$$CPI = \frac{1}{n} \sum_{i=1}^n K_i \left| \frac{A_i - B_i}{A_i} \right| \times 100\% \quad (5.17)$$

onde A_i é a i -ésima parâmetro considerado do sinal estimado, B_i é o i -ésima parâmetro correspondente do sinal filtrado, o parâmetro K_i é o peso dado à i -ésima informação e n é a quantidade de informações avaliadas. Os pesos devem ser distribuídos às informações de forma que $\sum_{i=1}^n K_i = 1$.

Em [31] os autores fizeram uso do parâmetro de SNR e CC para prover informações de cunho estatístico (global) do sinal e indicaram o uso da variação no tempo de subida, no instante de ocorrência do pico de amplitude do pulso e na amplitude do pulso (EA) para fornecer a degradação das características locais no sinal.

Com o CPI é possível ter uma ideia mais ampla do real efeito da redução de ruídos no sinal obtido, o que fornece um critério mais robusto para nos direcionar na escolha dos melhores parâmetros utilizados para realizar a filtragem, i.e., nos permite identificar o estimador que mais nos aproxima do sinal desejado.

5.1.10 Variação do Tempo de Pico

A Variação do Tempo de Pico (VTP) é a percentagem da diferença absoluta entre o instante em que ocorre o pico de amplitude do sinal ideal e o instante em que ocorre o pico do sinal resultante. Portanto, podemos designar dois pontos de variação:

- Variação do Tempo de Pico máximo ΔT_{pmax} , onde são considerados os instantes em que ocorre o valor máximo de amplitude do pulso de DP aproximado T_{pmax_1} e do pulso DP obtido T_{pmax_2} , i.e.,

$$\Delta T_{pmax} = \left| \frac{T_{pmax_1} - T_{pmax_2}}{T_{pmax_1}} \right| \times 100\% \quad (5.18)$$

- Variação do Tempo de Pico mínimo, ΔT_{pmin} , indicado para situações onde o pulso de DP tem o formato DOE, mostrado na Fig. 2.18(b), onde considera-se os instantes em que ocorrem o valor mínimo de amplitude do pulso de DP aproximado T_{pmin_1} e do pulso de DP obtido T_{pmin_2} , i.e.,

$$\Delta T_{pmin} = \left| \frac{T_{pmin_1} - T_{pmin_2}}{T_{pmin_1}} \right| \times 100\% \quad (5.19)$$

5.1.11 Variação do Tempo de Subida

A Variação do Tempo de Subida (VTS), ΔT_s , é a análoga a VTP, só que leva em conta a diferença absoluta entre o tempo de subida (verificar Seção 2.9) do sinal ideal T_{s_1} e o tempo de subida do sinal obtido T_{s_2} , ou seja,

$$\Delta T_s = \left| \frac{T_{s_1} - T_{s_2}}{T_{s_1}} \right| \times 100\% \quad (5.20)$$

Ambos parâmetros, VTP e VTS, fornecem informações de características locais da preservação da forma de onda do pulso de DP.

5.1.12 Diferença de Curtose

A Diferença de Curtose (Dk), é um parâmetro baseado na diferença absoluta da curtose do sinal aproximado k_1 e do sinal filtrado k_2 , i.e.,

$$Dk = |k_1 - k_2| \quad (5.21)$$

A medida estatística de Curtose indica o grau de “achatamento” da distribuição, i.e., o quanto uma curva de frequência será achatada em relação a uma curva normal de referência, servindo como uma medida de dispersão que caracteriza o formato da curva da função de distribuição. A curtose de uma distribuição normal será 3; para as distribuições que são mais altas (afuniladas) e concentradas que a distribuição normal, a curtose será maior do que 3; e as funções de distribuição mais “achatadas” que a distribuição normal têm curtose menor do que 3.

A curtose de uma distribuição é definida como

$$k = \frac{E(x - \bar{x})^4}{\sigma^4} \quad (5.22)$$

onde \bar{x} é a média de x (sinal), σ é o desvio padrão de x , e $E(v)$ representa o valor esperado da variável aleatória v .

Tal parâmetro se mostra importante para identificar curtos intervalos de ruído presentes no sinal após ser filtrado. Para exemplificar, tomemos um sinal de DP adquirido de um equipamento de alta tensão. Aplicamos a este a técnica de redução de ruídos por WT (com wavelet mãe *db3*, fator de reescala *mln*, função de limiarização abrupta), variando apenas a forma de cálculo do valor de limiar entre *heursure*, *minimaxi* e *sqtwolog*. Os resultados de filtragem com seus respectivos valores de Dk estão mostrados na Fig. 5.1. Observe que quanto maior o valor deste critério de avaliação, maior a presença de pequenos intervalos contendo ruídos que não foram eliminados no processo de limiarização.




Figura 5.1: Comparação da diferença de curtose Dk para diferentes regras de seleção de limiar.

5.1.13 Tempo de processamento

O Tempo de Processamento (TP_r) surge em algumas publicações quando há a intenção de fazer a comparação entre diferentes metodologias de filtragem [30, 83]. Como o nome indica, este parâmetro mede o tempo gasto pelo processador do computador utilizado para executar o algoritmo (em [68] é calculado por meio dos comandos *tic* e *toc*, mas é indicado que se faça algumas execuções do mesmo algoritmo para obter uma média do tempo de processamento).

5.2 Seleção do Número de Níveis Baseado no Espectro de Frequência

Com base em uma das sugestões dadas em [105], descreveremos um método para seleção do número de níveis a ser aplicado na decomposição wavelet de um sinal de DP.

Sabemos que cada sinal de DP possui um espectro de frequência exclusivo, o qual representa todas as frequências presentes neste. Em uma situação onde a presença de ruído não se sobrepõe ao pulso de DP, as frequências que detêm uma contribuição maior para a formação do sinal desejado produzirão um espectro de maior potência concentrado em torno de uma certa faixa de frequência. Com o processo de decomposição multirresolução, o sinal terá suas componentes de frequência divididas em bandas não uniformes. A Fig. 5.2 ilustra tal divisão (considerando filtros ideais e ortogonais), onde F_s corresponde à frequência de amostragem empregada na aquisição do sinal de DP. Observe que, para J níveis de decomposição, a largura da banda passante dos coeficientes de detalhe se reduz com o nível do índice j de decomposição, por um fator $F_s/2^j$, enquanto as componentes do coeficiente de aproximação se encontram na banda entre 0 e $F_s/2^{J+1}$.




Figura 5.2: Divisão do espectro em bandas.

Portanto, para obter uma boa qualidade na filtragem wavelet, propomos fazer com que o número de níveis seja suficiente para representar com uma boa resolução a componente de menor frequência que possui uma potência significativa. Tal nível de potência pode ser estipulado pelo usuário, através um parâmetro ρ que indica o percentual da potência total do sinal onde devemos procurar a frequência mínima F_{min} . Este parâmetro é usado com o propósito de descartar componentes que, embora presentes, não contêm energia significativa.

A partir da propriedade de divisão do espectro em $J + 1$ subbandas e da frequência mínima que desejamos representar, propomos determinar o número de níveis por meio do espectro de energia do sinal considerado através da expressão

$$J = \text{fix} \left(\log_2 \left(\frac{F_s}{F_{\min}} \right) \right) \quad (5.23)$$

onde fix representa a mesma função descrita para Eq. (3.133). O algoritmo de seleção do número de níveis baseado no espectro de potência, mostrado no fluxograma da Fig. 5.3, calcula a quantidade de níveis no qual pelo menos $(100 - p)\%$ da energia do sinal é decomposta em subespaços de detalhe, prevenindo-nos do custo computacional de se decompor o sinal em subespaços que não contêm informações relevantes. Note que o algoritmo converge em no máximo 100 iterações.

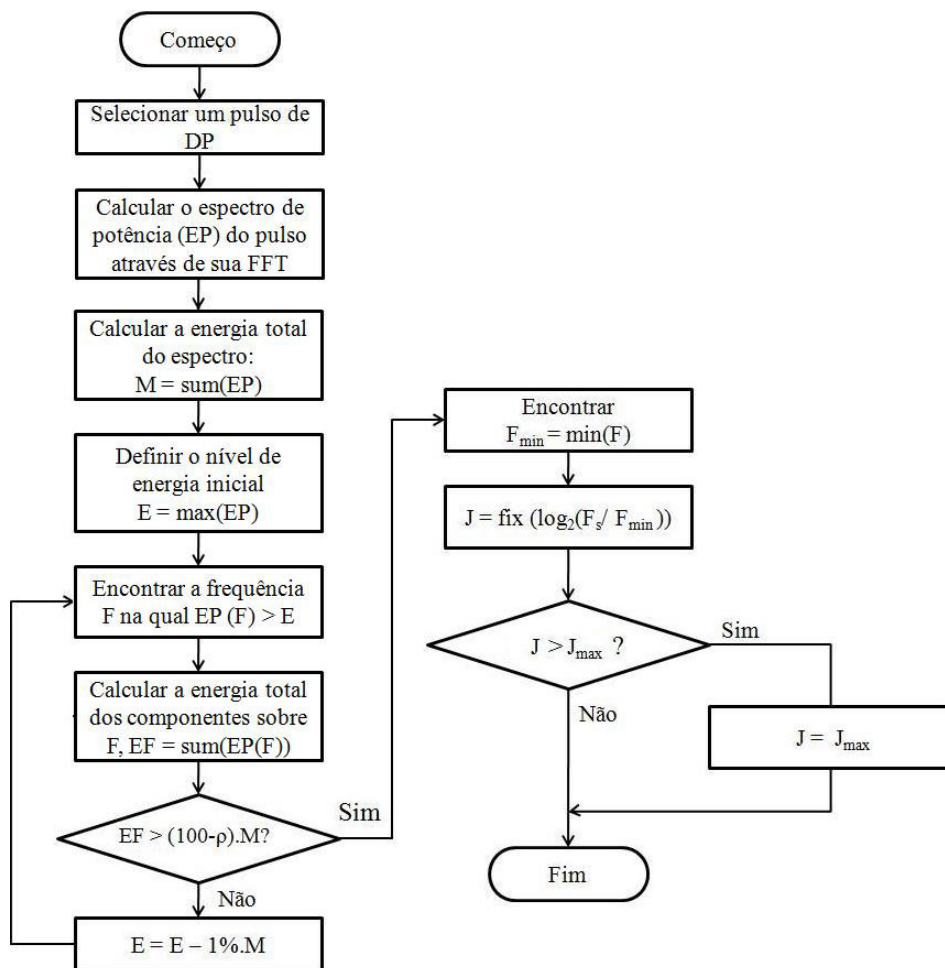


Figura 5.3: Algoritmo PSBLS.

Considere, por exemplo, o sinal de DP de tamanho $N = 10000$ amostras, ilustrado na Fig. 5.4(a), amostrado com $F_s = 1$ GHz, cujo espectro de potência é mostrado na Fig. 5.4(b). A linha horizontal pontilhada indica o ponto onde a potência p corresponde a 10% da energia total do sinal e a linha vertical pontilhada indica a frequência com a menor potência imediatamente maior do que a indicada pela linha horizontal, a qual neste caso foi $F_{\min} = 1,099$ MHz, substituindo este valor na Eq. (5.23) nos encontramos $J = 9$ níveis de decomposição. Este valor foi

suficiente para permitir separar as componentes de frequência presentes no sinal de DP, provendo um excelente resultado de filtragem, sem a necessidade de decompor o sinal para seu máximo número de níveis, que pela Eq. (3.133) seria igual a 13, resultando em uma economia de tempo no processo de redução de ruídos.

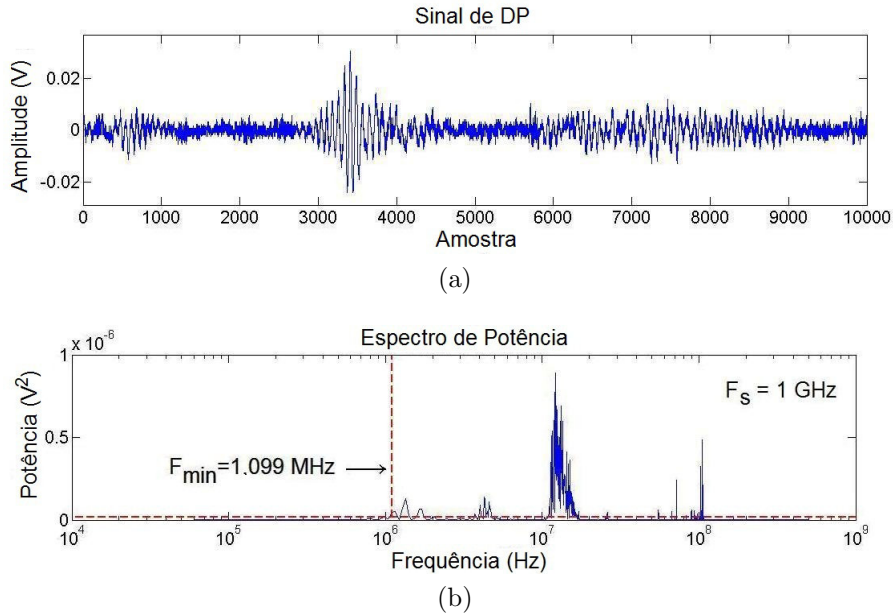


Figura 5.4: Exemplo do procedimento de seleção do número de níveis de decomposição: (a) Sinal de DP; (b) Espectro de potência do sinal.

Como o algoritmo proposto 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 máximo de níveis dado pela Eq. (3.133). Nesse caso, o número máximo J_{max} deve ser adotado.

5.3 Métodos de Seleção da Wavelet Mãe

Como discutimos na Seção 3.5.4, na literatura foram propostos alguns métodos automáticos de seleção da wavelet mãe, os quais propõem diferentes critérios para a seleção da wavelet mãe a partir de uma biblioteca de funções candidatas.

A seguir discutiremos estes métodos, mostrando alguns dos problemas da aplicação dos mesmos então, apresentaremos uma nova proposta que busca sanar alguns destes problemas.

5.3.1 Método de Seleção da Wavelet Baseada na Correlação (CBWS)

O método CBWS foi proposto por X. Ma *et al.* [44] com a finalidade de suprir as tentativas de filtragem de sinais de DP no domínio wavelet que se baseavam na ideia de que a semelhança visual entre a forma de onda do pulso de DP e a função wavelet utilizada implicariam numa melhor representação do sinal de DP original. Ou seja, quanto maior a semelhança maior o produto interno entre o sinal e a wavelet, o que maximiza os coeficientes no domínio tempo-escala (frequência). Em outras palavras, a wavelet selecionada deve ser capaz de gerar o mais alto máximo local do sinal de interesse no padrão wavelet, caracterizando melhor o conteúdo de frequência dos coeficientes ao longo dos níveis de decomposição.

Em [44] os autores utilizam o coeficiente de correlação, entre o pulso de DP de interesse X e a wavelet mãe Y . A wavelet ótima será aquela que maximizar o coeficiente de correlação [106].

A fórmula para o cálculo do coeficiente de correlação, dada na Eq. (5.6), pode ser reescrita como se segue

$$CC_{X,Y} = \frac{\sum_{i=1}^N (X(i) - \bar{X})(Y(i) - \bar{Y})}{\sqrt{\sum_{i=1}^N (X(i) - \bar{X})^2 \sum_{i=1}^N (Y(i) - \bar{Y})^2}} \quad (5.24)$$

Ainda em [44] é sugerido que a seleção seja feita usando os seguintes passos:

1. Analisar a forma de onda do pulso de DP esperado para produzir um pulso de DP “típico”;
2. Selecionar uma forma de onda de uma biblioteca de funções wavelet;
3. Calcular o coeficiente de correlação cruzada, dado na Eq. (5.24), entre a forma de onda da DP e cada wavelet da biblioteca;
4. Determinar a wavelet ótima, i.e., aquela que maximiza $CC_{X,Y}$.

Segundo os autores em [25], reescalando a wavelet mãe em duração e amplitude para cada nível, maiores coeficientes serão gerados se a wavelet adequada tiver sido selecionada. Consequentemente, se produzirá um melhor resultado de filtragem. Também concluem que wavelets com ordem mais baixa são mais apropriadas para medição de pulsos de DP adquiridos a partir de circuitos de detecção RC, enquanto que as wavelets de ordem elevada são mais apropriadas para pulsos adquiridos através de circuitos RLC.

Apesar de descreverem a metodologia de busca pelo coeficiente de correlação nos artigos [25, 44], os autores ainda deixam em aberto algumas questões:

1. Qual deve ser a escala selecionada para se realizar o cálculo do coeficiente de correlação?
2. Considerando que não só a escala mas também o deslocamento influenciará no resultado, qual deve ser o deslocamento selecionado para se calcular o coeficiente?

Para tentar responder estas questões, em [30] Li *et al.* sugerem que os sinais de DP e da wavelet analisada sejam reamostrados e deslocados circularmente até que coincidam no mesmo instante em seu pico de amplitude e no primeiro cruzamentos por zero após este pico.

O algoritmo de seleção da wavelet pelo método CBWS sugerido por Li *et al.* é descrito a seguir:

1. Criar uma biblioteca de funções $\psi_{t,i}$, para cada tipo de família wavelet (tipo: $t = 1, 2, \dots, p$) e selecionar a ordem da wavelet (ordem: $i = 1, 2, \dots, N$);
2. Gerar a wavelet mãe $\psi_{t,i}$ com razoável resolução;
3. Reamostrar o sinal de DP e/ou a função wavelet, tal que eles tenham o mesmo número de amostras;
4. Normalizar a magnitude do sinal de DP e da wavelet tal que ambos tenham valor de pico igual a 1;
5. Calcular a diferença entre o pico e o ponto de cruzamento por zero do sinal de DP (Δt_s) e da wavelet (Δt_w);
6. Se $\Delta t_s > \Delta t_w$, a wavelet é reamostrada por um fator $\Delta t_s / \Delta t_w$, caso contrário o sinal de DP é reamostrado por um fator $\Delta t_w / \Delta t_s$;
7. Se os comprimentos do sinal de DP e da wavelet são diferentes, completar com zeros o mais curto;
8. Deslocar o pico da wavelet até que esteja no mesmo instante do pico do sinal de DP;
9. Determinar o coeficiente de correlação entre o sinal e a wavelet de acordo com a Eq. (5.24);
10. Repita os passos de 2 a 9, armazenando a informação wavelet se o coeficiente de correlação obtido for maior do que o anterior, até que todas as funções

wavelet tenham sido testadas;

11. Escolher a wavelet mãe que possuir a máxima correlação como a wavelet ótima.

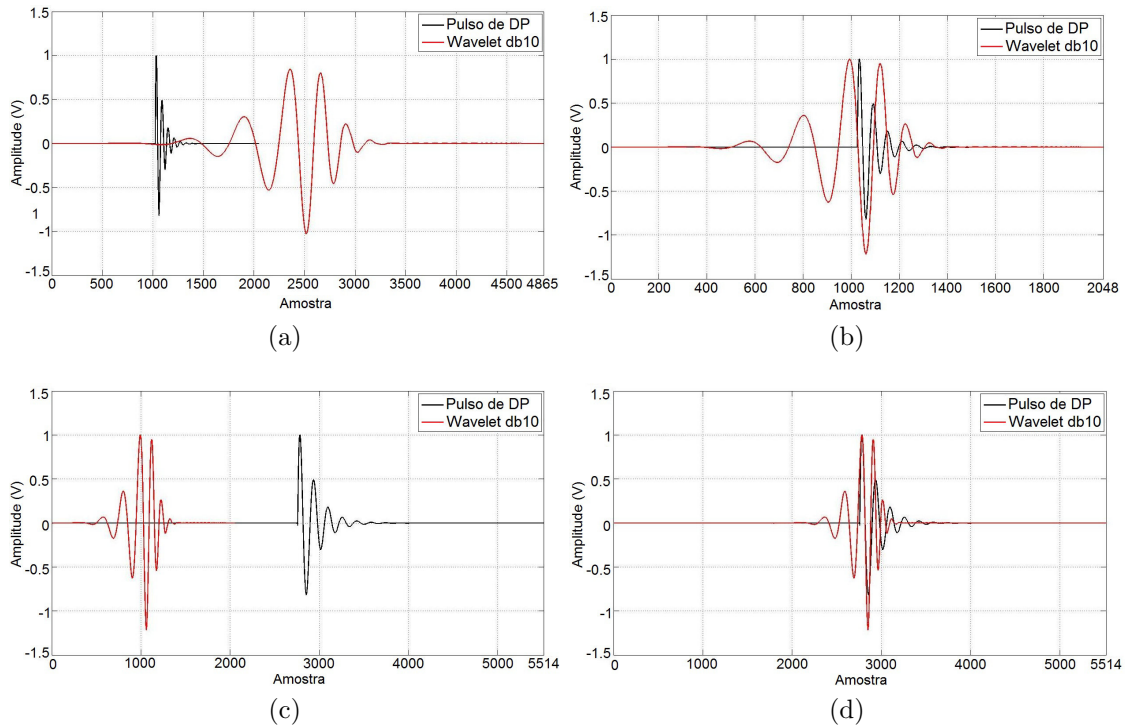


Figura 5.5: Exemplo do procedimento CBWS: (a) pulso de DP e wavelet selecionados; (b) pulso de DP normalizado e wavelet reamostrada e normalizada; (c) pulso de DP reamostrado para igualar seu cruzamento por zero com o da wavelet; (d) wavelet preenchida com zeros e deslocada.

Para exemplificarmos o processo, utilizamos um pulso de DP do tipo DOE e aplicamos o algoritmo CBWS para buscar a wavelet com maior coeficiente de correlação. Na Fig. 5.5 são mostramos as etapas do processo de análise do pulso de DP para a função wavelet *db10*. Inicialmente temos o pulso de DP e a wavelet criada na Fig. 5.5(a). O sinal de DP e a wavelet são reamostrados e/ou normalizados, de forma que possuam o mesmo número de amostras e a mesma amplitude, como ilustra a Fig. 5.5(b). Em seguida, para ajustar os pontos de cruzamento por zero após o pico, o sinal de DP foi reamostrado, como mostrado na Fig. 5.5(c); Por fim, a forma de onda da wavelet foi preenchida com zeros para ficar com o mesmo número de amostras do pulso de DP e deslocada circularmente até que seus picos coincidisse, como mostra a Fig. 5.5 (d). Após executarmos o método para uma biblioteca de wavelets (composta pelas funções *db2* a *db25*, *sym2* a *sym15* e *coif1* a *coif5*), obtivemos como melhor resultado a wavelet *sym7*, com um valor de $CC_{X,Y} = 0.9122$, conforme ilustrado na Fig. 5.6.

Este algoritmo também foi aplicado por Mortazavi *et al.* em [26].




Figura 5.6: Gráfico Wavelet x Coeficiente de Correlação para o pulso DOE analisado.

5.3.2 Método de Seleção da Wavelet Baseada na Energia (EBWS)

Li *et al.* [30] propuseram uma maneira de selecionar uma wavelet para cada escala j baseando-se na distribuição de energia entre as subbandas de decomposição.

Em cada nível é feita uma decomposição do sinal desejado s para cada wavelet de um conjunto de funções candidatas (biblioteca wavelet), e a wavelet base que produzir coeficiente de aproximação c_j contendo o maior percentual de energia será a wavelet selecionada para a escala em questão. Para as escalas sucessivas os coeficientes de aproximação do nível anterior $j - 1$ serão tomado como sinal s a ser decomposto, e o processo se repete até que o número de níveis desejado J seja atingido. A energia percentual dos coeficientes de aproximação na escala j ($j = 1, 2, \dots, J$) é definido como:

$$E_c = \frac{\sum_k (c_{J,k})^2}{\sum_k (c_{J,k})^2 + \sum_{j=1}^J \sum_k (d_{j,k})^2} \times 100 \quad (5.25)$$

A ideia por trás do algoritmo EBWS se sustenta no fato de que quando os coeficientes de detalhe d_1 são atenuados (na maioria dos casos anulados) na etapa de limiarização, o sinal de DP filtrado perderá energia e sofrerá distorções. Se a wavelet base ótima gerar aproximações do sinal de DP com maior percentagem de energia do que as demais wavelets, o sinal filtrado perderá menos energia e manterá uma menor distorção da forma de onda, quando os coeficientes de detalhe d_1 passar em pelo processo de limiarização.

A seleção da wavelet ótima é executada para cada nível e, portanto, é dita dependente da escala.

O algoritmo de seleção da wavelet baseado na energia (EBWS) é descrito a seguir

1. Criar uma biblioteca de funções wavelet $\psi_{t,i}$, para cada tipo de família wavelet (tipo: $t = 1, 2, \dots, p$) e selecionar as ordens da wavelet (ordem: $i = 1, 2, \dots, N$);
2. Definir o número total de níveis de decomposição J ;
3. Selecionar uma wavelet base da biblioteca e executar um nível de decomposição do sinal de DP estimado s . Este é considerado no primeiro nível de decomposição wavelet. A aproximação e detalhe $c_1^{(j)}$ e $d_1^{(j)}$ são obtidos;
4. Calcular $E_{c_1}^{(t,i)}$ a percentagem de energia de $c_1^{(j)}$ definida como na Eq. (5.25), para cada wavelet da biblioteca;
5. Se $E_{c_1}^{(T,I)}$ é o máximo de $E_{c_1}^{(t,i)}$, a wavelet base $\psi_{T,I}$ é a wavelet ótima para o primeiro nível de decomposição;
6. Para o j -ésimo nível, fazer $s = c_{j-1}^{(T,I)}$, onde $c_{j-1}^{(T,I)}$ é a aproximação gerada pela wavelet base ótima na escala $j - 1$. Selecionar uma wavelet base e executar a decomposição wavelet de um único nível para o novo valor de s ;
7. Calcular $E_{c_j}^{(t,i)}$, a percentagem de energia de $c_j^{(i)}$ para todas as funções wavelets da biblioteca;
8. Encontrar o máximo de $E_{c_j}^{(t,i)}$. Tomar a wavelet correspondente como a wavelet base ótima para o j -ésimo nível de decomposição;
9. Repetir os passos de 3 a 8, até $j = J$, obtendo a wavelet ótima em todas as escalas.

Segundo os autores, este método apresentou melhores resultados de redução de ruídos dos sinais de DP do que o método CBWS, no que diz respeito aos parâmetros de avaliação EQM e EA. Além disso, o método apresentou uma performance superior em termos de tempo de processamento na busca das wavelets ótimas.

Para exemplificar, iremos tomar o pulso de DP utilizado no exemplo com o método CBWS, para um número total de níveis $J = 11$. Ao executarmos o algoritmo EBWS obtivemos as wavelets que forneceram o maior valor de percentagem de energia nos coeficientes de aproximação para cada nível. A Fig. 5.7, mostra a energia dos coeficientes de aproximação para cada wavelet da biblioteca em cada nível de

decomposição j (onde $j = 1, 2, \dots, J$). Os pontos em destaque (cor verde) indicam as wavelets que forneceram a maior energia de aproximação para cada escala, sendo estas $db2$, $db2$, $db2$, $db2$, $db4$, $db2$, $db15$, $db19$, $db21$, $db23$ e $db23$.




Figura 5.7: Gráfico de energia dos coeficientes de aproximação por nível para cada wavelet.

Para mostrar o efeito do método, foi realizada a filtragem do sinal de DP acrescido de um ruído branco com 1/4 da amplitude de pico do sinal de DP estimado. Para fins de comparação, foram utilizadas as wavelets selecionadas tanto pelo método EBWS quanto pelo CBWS ($sym7$), com o valor de limiar calculado pelo método *scaledep* e a limiarização feita pela função abrupta. Observe na Fig. 5.8 que a energia dos coeficientes da aproximação final gerada pelo método EBWS é maior que a proporcionada pelo método CBWS, o que sustenta o fato afirmado pelos autores de que o algoritmo eleva a percentagem de energia no coeficiente de aproximação.




Figura 5.8: Distribuição de energia para os métodos EBWS e CBWS.

Embora o objetivo do método EBWS seja maximizar a concentração de ener-


gia do sinal sobre os coeficientes de aproximação, comparado a outros métodos de seleção, isto nem sempre ocorrerá. Tal fato pode ser explicado observando que o algoritmo EBWS seleciona a wavelet que provê a maior E_c em um dado nível, mas esta função pode não ser aquela que, no próximo nível, produziria uma aproximação com maior percentagem de energia [9]. Nas comparações apresentados no Capítulo 6, mostraremos este efeito. Portanto, não é possível afirmar que o método EBWS produz a maior concentração de energia nos coeficientes de aproximação e sim que ele tende a produzir coeficientes de aproximação com maior energia.

5.3.3 Método de Seleção da Wavelet Baseada na Relação Sinal Ruído (SNRBWS)

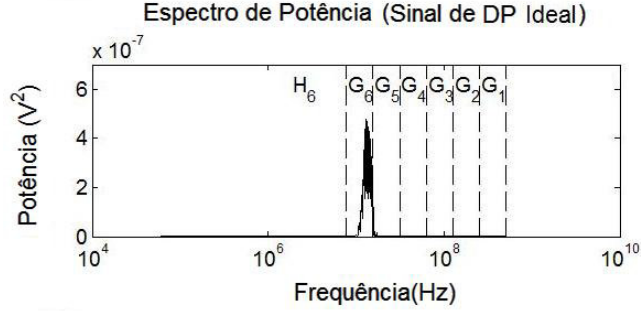
O objetivo desta seção é descrever um novo método de seleção dependente da escala, o qual busca melhorar a performance de filtragem de sinais de DP. Para tanto, notamos que o método EBWS assume que a energia do pulso de DP sempre irá se concentrar sobre a subbanda de aproximação. De um certo nível de decomposição em diante, tal suposição não será necessariamente verdadeira. Nestes casos, deste nível em diante, o EBWS operará no sentido oposto a maximização dos coeficientes do pulso de DP.

Recorrendo ao teorema de Parseval, podemos afirmar que para uma decomposição por wavelet ortogonal a energia existente nos coeficientes de decomposição corresponderá a energia do sinal, portanto quanto mais a distribuição de energia nos coeficientes se aproximar do espectro do sinal estimado, melhor será a qualidade da redução de ruídos. A Fig. 5.9 ilustra um sinal de DP estimado e o seu espectro de potência, onde as barras verticais delimitam a divisão do espectro em suas subbandas. Podemos perceber que a maior parte da energia do sinal ideal (estimado) se concentra nas subbandas de detalhe G_5 e G_6 e não na subbanda de aproximação H_6 . Portanto, neste caso, em um processo de busca da wavelet ótima o mais adequado seria maximizar os coeficientes nas bandas de detalhe G_5 e G_6 .

Para contornar este problema proporemos um algoritmo para identificar em cada nível de decomposição a subbanda na qual o pulso de PD deverá se concentra. Podemos assumir que para cada nível de decomposição, a subbanda correspondente ao pulso de DP será aquela que possuir o mais amplo valor de amplitude absoluto. Para identificar quais dos coeficientes gerados a cada decomposição contêm tal sinal, iremos utilizar o parâmetro de relação sinal ruído, já descrito na Seção 5.1 e calculado por meio da Eq. (5.14). Em [9], o método utiliza o valor de SNR_{dB} medido em dB ; posteriormente percebemos que ao aplicar a SNR sem o logaritmo obteríamos



(a)



(b)

Figura 5.9: (a) Pulso de DP estimado; (b) Espectro de frequência com divisão das bandas de decomposição.

o mesmo resultado a um menor custo de processamento. Então, assim o faremos nessa dissertação, reescrevendo a Eq. (5.14) como

$$SNR = \frac{\max(sinal)}{\max(ruído)} \quad (5.26)$$

Consideremos então que no j -ésimo estágio, a decomposição do sinal é realizada para cada wavelet candidata, gerando os coeficientes de aproximação c_j e de detalhe d_j . Os coeficientes correspondentes ao sinal de DP serão identificados como c_j ou d_j , que possuírem o coeficiente de maior magnitude, i.e.,

$$\begin{aligned} sinal &= c_j \text{ e } ruído = d_j & \text{se } \max(|c_j|) \geq \max(|d_j|) \\ sinal &= d_j \text{ e } ruído = c_j & \text{caso contrário} \end{aligned} \quad (5.27)$$

Assim, a relação sinal ruído pode ser calculada pela Eq. (5.26). A wavelet que resultar no mais alto valor de SNR é selecionada para este estágio. Quando isto é feito, existe uma tendência de que o sinal de DP reconstruído apresente menor distorção com melhores resultados de filtragem quando comparado a outros métodos, já que a função wavelet selecionada tende a concentrar componentes com maior amplitude nas bandas de frequência que contêm mais informação do sinal de DP

desejado.

Em resumo o processo de seleção da wavelet baseado na relação sinal ruído (SNRBWS) é composto dos seguintes passos:

1. Criar uma biblioteca de funções wavelet $\psi_{t,i}$, para cada tipo de família wavelet (tipo: $t = 1, 2, \dots, p$) e selecionar as ordens da wavelet (ordem: $i = 1, 2, \dots, N$);
2. Definir o número total de níveis de decomposição J ;
3. Para cada candidata wavelet, realizar a decomposição do sinal de DP estimado s em um único nível, gerando os coeficientes de aproximação c_1 e detalhe d_1 ;
4. Comparar os valores de pico de c_1 e d_1 , atribuindo os coeficientes com maior valor de pico como *signal* e os outros como *ruído*, e calcular a $SNR^{(t,i)}$ definida pela Eq. (5.26);
5. Se o $SNR^{(T,I)}$ é maior do que o $SNR^{(t,i)}$, para $t = 1, 2, \dots, p$ e $i = 1, 2, \dots, N$, guardar a wavelet $\psi_{T,I}$ como a melhor para este nível de decomposição;
6. Repetir os passos 2 a 5 até que o número máximo de níveis J seja alcançado, tomando os coeficientes de aproximação obtidos com a melhor wavelet $\psi_{T,I}$ no nível $j - 1$ como o sinal s para o j -ésimo nível.

Para demonstrar que o método SNRBWS tende a concentrar a energia nos coeficientes de maior importância, utilizamos o mesmo exemplo aplicado para a comparação entre os métodos EBWS e CBWS. Ao realizarmos a decomposição do sinal de DP, obtivemos as seguintes wavelets ótimas: *coif1*, *sym12*, *db13*, *db10*, *coif1*, *db2*, *sym5*, *db2*, *sym5*, *coif1* e *db3*. A distribuição de energia para os três algoritmos é mostrada na Fig. 5.10. Observe que a concentração da energia se eleva nos coeficientes de detalhe de maior importância d_5 , a um valor superior ao dos demais métodos.

5.3.4 Método Modificado de Seleção da Wavelet Baseada na Energia (MEBWS)

Nos questionamos se não poderíamos aplicar o raciocínio utilizado para desenvolver o método SNRBWS ao conceito utilizado no método EBWS, já que o algoritmo SNRBWS foi desenvolvido com o propósito de concentrar a energia nos coeficientes de maior importância.




Figura 5.10: Distribuição de energia para os métodos EBWS, CBWS e SNRBWS.

Em resposta a esta questão propomos identificar em cada nível de decomposição a sub-banda que concentra a maior parte da representação dos pulsos de DP. No entanto, ao invés de utilizarmos como parâmetro de identificação o valor absoluto de pico dos coeficientes, avaliamos os coeficientes que possuem a maior quantidade de energia e os tomamos como os coeficientes que contêm a energia do sinal E_{sinal} , i.e.,

$$\begin{aligned} E_{sinal} &= E_{c_j} & \text{se } E_{c_j} \geq E_{d_j} \\ E_{sinal} &= E_{d_j} & \text{caso contrário} \end{aligned} \quad (5.28)$$

onde E_{c_j} é a energia dos coeficientes de aproximação e E_{d_j} é a energia dos coeficientes de detalhe. Em cada estágio a wavelet candidata que produzir o mais alto valor de E_{sinal} será selecionada como ótima.

Em resumo o processo modificado de seleção da wavelet baseado na energia (MEBWS) é composto dos seguintes passos:

1. Criar uma biblioteca de funções wavelet $\psi_{t,i}$, para cada tipo de família wavelet (tipo: $t = 1, 2, \dots, p$) e selecionar as ordens da wavelet (ordem: $i = 1, 2, \dots, N$);
2. Definir o número total de níveis de decomposição J ;
3. Para cada wavelet candidata, realizar a decomposição do sinal de DP estimado s em um único nível, gerando os coeficientes de aproximação c_1 e o detalhe d_1 ;
4. Comparar os valores de energia de E_{c_1} e E_{d_1} , atribuindo a energia com maior valor como a energia do sinal $E_{sinal}^{(t,i)}$;
5. Se $E_{sinal}^{(T,I)}$ é maior do que o $E_{sinal}^{(t,i)}$, para $t = 1, 2, \dots, p$ e $i = 1, 2, \dots, N$, guardar a wavelet $\psi_{T,I}$ como a melhor para este nível de decomposição;

6. Repetir os passos 2 a 5 até que o número máximo de níveis J seja alcançado, tomando os coeficientes de aproximação obtidos com a melhor wavelet $\psi_{T,I}$ no nível $j - 1$ como o sinal s para o j -ésimo nível.

5.4 Otimização da Filtragem Wavelet Baseada em Algoritmos Genéticos

Problemas de otimização têm como objetivo encontrar a entrada que leva uma saída especificada ou a um resultado próximo desta saída. Portanto, a tarefa de otimização de um sinal de DP com base na filtragem wavelet pode ser descrita como a busca pelos parâmetros de entrada necessários ao processo de redução de ruídos no domínio wavelet, de forma que estes propiciem uma semelhança maior entre o sinal de DP filtrado e o sinal de descarga estimado.

Assim sendo, para que se possa aplicar otimização a sinais de DP por meio da WT é necessário inserir algum conhecimento no processo, o qual permita ao sistema saber a saída que desejamos encontrar. Este conhecimento, será aqui provido por meio de um sinal estimado de DP.

Será com essa informação que o algoritmo de otimização buscará pelos parâmetros mais adequados para proceder a filtragem wavelet (estudados na Seção 3.5).

Como discutimos no Capítulo 4, uma forma de otimização muito difundida é a otimização por meio de AG, por sua eficácia e rapidez em encontrar bons resultados. Portanto, neste trabalho proporemos uma estratégia de busca com base em AG.

Em um AG, o maior problema se refere à criação de uma função custo, de modo que possamos avaliar a qualidade (aptidão) das variáveis envolvidas no problema (parâmetros de filtragem wavelet). A seguir mostraremos a abordagem tomada para desenvolver tal função.

5.4.1 Função Custo para o Problema de Filtragem Wavelet

Para o desenvolvimento de uma função custo que nos permita identificar bons fenótipos no processo de busca evolucionária, recorreremos aos parâmetros aplicados na avaliação da filtragem, descritos na Seção 5.1.

Zhao *et al.* [31] ao criarem o CPI, enfatizam a importância de não avaliarmos

a qualidade de nossa filtragem com base em um ou dois parâmetros de avaliação, como fazem a maioria dos autores [28, 30–32, 83, 84], mas utilizarmos uma quantidade significativa de critérios que reflitam tanto similaridades globais (critérios estatísticos) quanto similaridades locais. Isso nos permitirá portanto, ter uma visão mais ampla do efeito de redução de ruídos wavelet no sinal obtido, nos direcionando à uma escolha mais adequada. Baseado nesta ideia, criaremos a função aptidão a ser utilizada no AE.

Sabendo que a função deve ser formada tanto por parâmetros globais quanto locais, dividiremos a função em duas variáveis, ou seja,

$$f_{Apt} = p_g - p_l \quad (5.29)$$

onde f_{Apt} representa a função aptidão que desejamos, e p_g e p_l constituem os parâmetros globais e locais, respectivamente. Estes parâmetros são definidos a seguir.

Parâmetros Globais (p_g).

Recorrendo à Seção 5.1 verificamos que os critérios de avaliação que fornecem uma informação global ou estatística do sinal filtrado são o EMA, o EQM, a REQM, o CC, o NCC, a SNR_{dB2} , a NRR e a DEn. Diante destes critérios, escolhemos apenas os mais aplicados na literatura para representar a variável global, sendo estes o EQM, o NCC e por fim, a diferença da SNR_{dB2} (DSNR), calculada por:

$$DSNR = SNR_{dB2_{SF}} - SNR_{dB2_{SA}} \quad (5.30)$$

onde $SNR_{dB2_{SF}}$ indica a razão sinal ruído entre o sinal estimado $x_1(n)$ e o sinal filtrado $x_2(n)$, e $SNR_{dB2_{SI}}$ indica a razão sinal ruído entre o sinal estimado $x_1(n)$ e o sinal de entrada (sinal amostrado) $x_a(n)$. Este critério mostra o quanto a SNR do sinal filtrado melhorou em relação a SNR do sinal de entrada.

Observe que para alguns parâmetros, como o DSNR e o NCC, quanto mais alto o valor obtido melhor será o sistema em reduzir o ruído. Já para outros critérios é desejável obter o menor valor possível, como é o caso do EQM. Para formar a função de parâmetros globais basta somarmos cada critério, aplicando um peso α_i para $i = 1, 2, 3$, como se segue

$$p_g = \alpha_1 \cdot DSNR + \alpha_2 \cdot NCC + \alpha_3 \cdot \frac{1}{EQM} \quad (5.31)$$

Observe que o EQM está no denominador, isto se faz necessário para maximizar o critério em bons resultados, já que quanto menor seu valor melhor a filtragem. Então, na avaliação da aptidão desejamos que o valor de p_g seja o maior possível, i.e., seja maximizado.

Substituindo as Eqs. (5.2), (5.9) e (5.13) na Eq. (5.31), temos

$$p_g = \alpha_1 \left[\left(10 \log \frac{\sum_{i=1}^N x_2^2(i)}{\sum_{i=1}^N (x_1(i) - x_2(i))^2} \right) - \left(10 \log \frac{\sum_{i=1}^N x_a^2(i)}{\sum_{i=1}^N (x_1(i) - x_a(i))^2} \right) \right] + \alpha_2 \left(\frac{\sum_{i=1}^N x_1(i)x_2(i)}{\sqrt{\sum_{i=1}^N x_1^2(i) \sum_{i=1}^N x_2^2(i)}} \right) + \alpha_3 \left(\frac{1}{\frac{1}{N} \sum_{i=1}^N |x_1(i) - x_2(i)|^2} \right) \quad (5.32)$$

onde as constantes de peso servem para designar a importância que cada critério de avaliação terá na composição da função custo. Portanto, cabe ao usuário decidir o peso a ser designado a cada variável. Ao determinar o peso é importante tomarmos o cuidado de não dar muito valor a um só critério, pois “mascararíamos” o efeito dos demais.

Parâmetros Locais (p_l).

Como critérios que provêm informações locais a respeito do sinal obtido em relação ao sinal estimado podemos citar o EA máximo, o EA mínimo, a VTP máxima, a VTP mínima, a VTS e a Dk . Usaremos todos estes critérios para compor nossa função local. Como na função global, atribuiremos diferentes pesos β_i às variáveis locais, obtendo

$$p_l = \beta_1 \cdot EA_{max} + \beta_2 \cdot EA_{min} + \beta_3 \cdot \Delta T_{pmax} + \beta_4 \cdot \Delta T_{pmin} + \beta_5 \cdot VTS + \beta_6 \cdot Dk \quad (5.33)$$

Substituindo as Eqs. (5.16), (5.18), (5.19), (5.20) e (5.21) na Eq. (5.33), obtemos

$$p_l = \beta_1 \left| \frac{A_{max1} - A_{max2}}{A_{max1}} \right| + \beta_2 \left| \frac{A_{min1} - A_{min2}}{A_{min1}} \right| + \beta_3 \left| \frac{T_{pmax1} - T_{pmax2}}{T_{pmax1}} \right| + \beta_4 \left| \frac{T_{pmin1} - T_{pmin2}}{T_{pmin1}} \right| + \beta_5 \left| \frac{T_{s1} - T_{s2}}{T_{s1}} \right| + \beta_6 |k_1 - k_2| \quad (5.34)$$

onde o índice 1 nos critérios locais se refere ao sinal estimado e o índice 2 ao sinal filtrado. Em ambos os parâmetros mostrados na Eq. (5.33), um bom resultado se caracteriza por um menor erro ou variação possível. Novamente, é preciso tomar

cuidado com a escolha das constantes β_i , para não valorizarmos demais um único critério, o que poderia fornecer resultados não tão bons, ou até mesmo inadequados.

Ao verificar a Eq. (5.29) notamos que os parâmetros globais são subtraídos dos parâmetros locais, de modo que quanto maior a diferença entre os parâmetros globais (que devem ser maximizados) e os parâmetros locais (que devem ser minimizados), melhor será a aptidão do sinal filtrado. Aplicando as Eqs. (5.32) e (5.34) na Eq. (5.29), formamos nossa função custo, dada por:

$$\begin{aligned}
f_{Apt} = & \left[\alpha_1 \left(\left(10 \log_{10} \frac{\sum_{i=1}^N x_2^2(i)}{\sum_{i=1}^N (x_1(i) - x_2(i))^2} \right) - \left(10 \log_{10} \frac{\sum_{i=1}^N x_a^2(i)}{\sum_{i=1}^N (x_1(i) - x_a(i))^2} \right) \right) \right. \\
& + \alpha_2 \left(\frac{\sum_{i=1}^N x_1(i)x_2(i)}{\sqrt{\sum_{i=1}^N x_1^2(i) \sum_{i=1}^N x_2^2(i)}} \right) + \alpha_3 \left(\frac{1}{\frac{1}{N} \sum_{i=1}^N |x_1(i) - x_2(i)|^2} \right) \left. \right] \\
& - \left[\beta_1 \left| \frac{A_{max1} - A_{max2}}{A_{max1}} \right| + \beta_2 \left| \frac{A_{min1} - A_{min2}}{A_{min1}} \right| + \beta_3 \left| \frac{T_{pmax1} - T_{pmax2}}{T_{pmax1}} \right| \right. \\
& \left. + \beta_4 \left| \frac{T_{pmin1} - T_{pmin2}}{T_{pmin1}} \right| + \beta_5 \left| \frac{T_{s1} - T_{s2}}{T_{s1}} \right| + \beta_6 |k_1 - k_2| \right]
\end{aligned} \tag{5.35}$$

5.4.2 Considerações da Função Custo

No cálculo da Eq. (5.35) precisamos levar em conta algumas considerações com relação ao cálculo do EA máximo, do EA mínimo, da VTP mínima e da VTS.

No Capítulo 2 vimos que a forma do pulso de DP pode variar desde exponencialmente amortecido a oscilatório exponencialmente amortecido, e que o pulso pode ser positivo ou negativo. Portanto, é necessário comparar as magnitudes do maior valor de amplitude com a do menor valor do sinal ideal, para assim determinar qual dos valores é o maior e qual é o menor, designando-os como A_{max} e como A_{min} , respectivamente, conforme as Eqs. (5.36) e (5.37). O mesmo raciocínio pode ser usado para calcular o tempo de subida em torno do maior valor do pulso de DP, seja este positivo ou negativo.

$$A_{max_i} = \begin{cases} \max(x_i(n)) & \text{se } \max(x_i(n)) \geq \min(|x_i(n)|), \text{ para } i = 1, 2 \\ \min(x_i(n)) & \text{caso contrário} \end{cases} \tag{5.36}$$

$$A_{min_i} = \begin{cases} \min(x_i(n)) & \text{se } \max(x_i(n)) \geq \min |(x_i(n))|, \text{ para } i = 1, 2 \\ \max(x_i(n)) & \text{caso contrário} \end{cases} \quad (5.37)$$

No caso de o pulso de DP ser DE ou ser um pulso DOE com valor de amplitude mínima baixo, não faz sentido levar em consideração os critérios de avaliação relacionados ao valor mínimo, como é o caso do EA mínimo e do VTP mínimo. Assim, para garantir que estes não tenham influência no cálculo de f_{Apt} , atribuímos um valor nulo a cada um deles, por meio do teste a seguir:

$$EA_{min} = \begin{cases} \frac{A_{min_1} - A_{min_2}}{A_{min_1}} & \text{se } \min(x_i(n)) \leq \tau\% \times A_{max_i} \\ 0 & \text{caso contrário} \end{cases} \quad (5.38)$$

$$VTP_{min} = \begin{cases} \frac{T_{pmin_1} - T_{pmin_2}}{T_{pmin_1}} & \text{se } \min(x_i(n)) \leq \tau\% \times A_{max_i} \\ 0 & \text{caso contrário} \end{cases} \quad (5.39)$$

o que garante que não levaremos em consideração pulsos que possuam amplitude mínima menor ou igual a $\tau\%$ do valor de amplitude máxima. A percentagem considerada pode ser alterada pelo usuário da forma que considerar satisfatória; para nossos experimentos 5% se mostrou um bom valor.

Outra precaução que devemos ter é com relação ao parâmetro EQM, pois este em geral é um valor muito pequeno e, apesar de improvável, pode ser zero caso o sinal filtrado seja idêntico ao sinal estimado. Por isso, precisamos estipular um limite para que não ocorra erro no cálculo de $1/EQM$. Em nossa aplicação estipulamos um valor de 10^{-9} como limite, o que impede que o denominador seja nulo, mas assegura que o termo e contribui significativamente para a função de aptidão do sinal analisado, garantindo que este seja selecionado como ótimo. Determinado o valor de EQM, submetemos este a seguinte condição:

$$EQM = \begin{cases} 10^{-9} & \text{se } EQM = 0 \\ EQM & \text{caso contrário} \end{cases} \quad (5.40)$$

5.4.3 Representação

A representação do problema é importante para que possamos traduzi-lo em um genótipo que possa sofrer as alterações impostas pelo processo de busca evolucionária, sendo necessária principalmente nas etapas de recombinação e mutação. Para criar a representação devemos levar em consideração as variáveis envolvidas na redução de ruídos por transformada wavelet, as quais foram descritas na Seção 3.58. Então construímos para cada indivíduo na população um genótipo com a seguinte estrutura:

$$\text{genótipo} = [J \text{ Meth } Sohr \text{ Scal } WM] \quad (5.41)$$

onde

- J indica o número de níveis de decomposição, representado com números inteiros, os quais podem variar de 1 a J_{max} , descrito na Eq. (3.133).
- $Meth$ representa o método utilizado para encontrar o valor de limiar, podendo variar entre cinco tipos, que também representaremos como variáveis inteiras:

$$\begin{aligned} heursure &\leftrightarrow 1 \\ minimaxi &\leftrightarrow 2 \\ rigrsure &\leftrightarrow 3 \\ sqtwolog &\leftrightarrow 4 \\ scaledep &\leftrightarrow 5 \end{aligned}$$

- $Sohr$ corresponde à função de limiarização que será aplicada para atenuação dos coeficientes wavelet; nesta dissertação aplicamos apenas as funções abrupta (*hard*) e suave (*soft*), e as representaremos como se segue:

$$\begin{aligned} hard &\leftrightarrow 1 \\ soft &\leftrightarrow 2 \end{aligned}$$

- $Scal$ é o fator multiplicativo para reescala do valor de limiar, podendo ser *one*, *sln* ou *mln*:

$$\begin{aligned} one &\leftrightarrow 1 \\ sln &\leftrightarrow 2 \\ mln &\leftrightarrow 3 \end{aligned}$$

- WM contém as wavelets a serem aplicadas em cada nível, sendo necessário que a quantidade de wavelets seja limitada em relação ao valor de J escolhido. Para aplicar o genótipo é necessário que todos os indivíduos tenham o mesmo

tamanho. Então, geraremos as wavelets de acordo com o número máximo de níveis J_{max} permitido para o pulso de DP avaliado, e ao realizarmos a filtragem wavelet utilizaremos apenas a quantidade de wavelets correspondente ao valor indicado pelo alelo J . Como neste trabalho aplicaremos somente as wavelets da família Daubechies, Symlets e Coiflets, precisamos definir a ordem máxima com que trabalharemos em cada família. Feito isto, basta somarmos estas ordens máximas e representar as wavelets com números inteiros de 1 a (ordem máxima db + ordem máxima sym + ordem máxima $coif$). A representação descrita é dada a seguir

$$\begin{aligned}
db1 &\leftrightarrow 1 \\
&\vdots \leftrightarrow \vdots \\
dbN_1 &\leftrightarrow N_1 \\
sym1 &\leftrightarrow N_1 + 1 \\
&\vdots \leftrightarrow \vdots \\
symN_2 &\leftrightarrow N_2 + N_1 \\
coif1 &\leftrightarrow N_2 + N_1 + 1 \\
&\vdots \leftrightarrow \vdots \\
coifN_3 &\leftrightarrow N_3 + N_2 + N_1
\end{aligned}$$

Para exemplificar, considere que desejamos gerar um indivíduo com 10000 amostras ($J_{max} = 13$) a ser decomposto para $J = 7$, com o valor de limiar calculado por *sqtwolog* e reescalado com *mln* que usará a função *hard* para redução dos coeficientes gerados pelas das wavelets *db5*, *db9*, *sym6*, *db23*, *coif2*, *sym13*, *coif5*, sendo que limitamos a ordem das wavelets em $N_1 = 30$, $N_2 = 15$ e $N_3 = 5$. A representação deste candidato é dada por

$$genótipo = [7\ 4\ 1\ 3\ 5\ 9\ 36\ 23\ 47\ 43\ 50\ \#\ \#\ \#\ \#\ \#\ \#] \quad (5.42)$$

onde $\#$ pode ser qualquer valor de 1 a 50 ($30 + 15 + 5$), pois não serão utilizados na filtragem wavelet do sinal de DP.

5.4.4 Inicialização

Definidas a função custo e a forma de representação, o primeiro passo do algoritmo é gerar a população inicial. Para isso definimos o tamanho da população μ e geramos cada uma das variáveis wavelet descritas anteriormente de forma aleatória com uma distribuição uniforme, para mantermos a diversidade da população, o que

não ocorreria caso gerássemos os números com uma distribuição Gaussiana ou com uma distribuição de Cauchy.

No Capítulo 4 descrevemos os algoritmos Meméticos; nesta etapa também é possível inserir conhecimento externo para formar a população inicial. Um exemplo seria aplicar um dos métodos de seleção de wavelet já descritos para criarmos um candidato a compor nossa população inicial. Entretanto, para fins de comparação com os demais métodos, optamos por não tomar essa medida.

5.4.5 Seleção dos Pais

Para seleção dos pais é preciso calcular a aptidão de cada indivíduo. Para tanto, temos que tomar cada genótipo da população e converter a informação numérica contida nos genes para determinar os parâmetros (fenótipo) que serão usados na filtragem wavelet do sinal, de modo que possamos aplicar estes na função responsável pela redução de ruídos do pulso de DP em análise. Com isso, geramos o sinal filtrado que será aplicado na função de aptidão descrita pela Eq. (5.35) e, levando em conta as considerações descritas na Seção 5.4.2, obtemos o valor de aptidão para cada indivíduo.

Conhecendo o valor de aptidão de toda a população, a seleção dos pais da próxima geração é feita usando o, já descrito, algoritmo *Roulette Wheel*, com pseudocódigo ilustrado na Fig. 4.2.

5.4.6 Recombinação

A partir dos pais selecionados podemos aplicar a recombinação. No entanto, ao invés de utilizarmos uma recombinação destinada à representação inteira, optamos pela recombinação aritmética completa descrita para a representação em ponto flutuante, a qual foi escolhida por gerar novos genes em vez de simplesmente trocar os alelos de cada pai como sugerem as recombinação de um ponto, uniforme ou multiponto, o que não nos daria uma diversidade populacional muito grande. Outro motivo é o uso do parâmetro α na equação, o que permite controlar a semelhança entre os filhos gerados. As equações foram descritas no Capítulo 4, e serão repetidas aqui por comodidade, repare pelas Eqs. (5.43) e (5.44) que neste caso o termo *round* aproxima o valor obtido para o inteiro mais próximo.

$$Descendente\ 1 = round(\alpha \cdot p + (1 - \alpha) m) \quad (5.43)$$

$$Descendente 2 = round(\alpha \cdot m + (1 - \alpha) p) \quad (5.44)$$

Então, para recombinação pegamos dois pais p e m de forma ordenada e aplicamos as Eqs. (5.43) e (5.44) para gerar dois novos descendentes e o tamanho da população de descendentes, sendo o mesmo da população inicial, i.e., $\beta = \mu$. Vale lembrar que para o caso em que $\alpha = 1/2$ os filhos gerados serão idênticos, para obter indivíduos distintos aplicaremos $\alpha = 3/4$. Tal valor pode não ser interessante, pois restringe a diversidade da população.

5.4.7 Mutação

Na etapa de mutação optamos por aplicar o método de reajuste aleatório, descrito no Capítulo 4. Portanto, percorremos toda a população de descendentes gerados após a recombinação e selecionamos alguns deles com uma probabilidade $p_s = 5\%$. Em seguida, modificamos os genes destes candidatos com uma probabilidade de mutação $p_m = 2$. A modificação é feita substituindo o gene por uma variável aleatória inteira (uniformemente distribuída) dentro dos limites possíveis para cada gene.

Heurística de Mutação

Nesta fase também implementamos uma heurística, a qual não podemos determinar como mutação, pois não ocorre estocasticamente e sim de uma maneira forçada para uma certa quantidade $\gamma\%$ de indivíduos da população de descendentes geradas após os operadores de recombinação e mutação. Em nosso trabalho, estipulamos que $\gamma = 3\%$ desta população será alterada, de modo que definiremos aleatoriamente uma wavelet mãe (representada numericamente) e a atribuiremos a todos os genes correspondentes às wavelets (do 5º ao J_{max} -ésimo gene). Desta forma garantimos que o algoritmo explore regiões onde uma única wavelet é aplicada a todos os níveis de decomposição, áreas que dificilmente seriam alcançadas na fase de inicialização ou nas etapas de recombinação e mutação. O pseudo-código desta heurística é mostrado na Fig. 5.11, onde N_1 , N_2 e N_3 correspondem à ordem máxima de cada uma das três famílias aqui adotadas e μ é o tamanho da população de descendentes.

Esta heurística também pode ser vista como uma forma de inserir uma informação, a partir de um conhecimento prévio que possuímos a respeito de nosso problema, o que nos remete à ideia de MA, discutida na Seção 4.14.

```

INICIO
  definir i=1;
  ENQUANTO (i ≤ γ * μ)
    gerar um valor inteiro uniforme de [1,μ]: m = randi([1 μ],1);
    pegar o indivíduo entre descendentes: ind = descendentes(m, :);
    modificar genes da wavelet do indivíduo:
    ind_m = [ind(1:4) (randi([1 (N1 + N2 + N3)],1))*ones(1, Jmax)];
    reinserir o indivíduo na população: descendentes (m, :) = ind_m;
    i=i+1;
  FIM
FIM

```

Figura 5.11: Pseudocódigo da heurística incorporada ao AG.

5.4.8 Seleção dos Sobreviventes

Para selecionar os sobreviventes, primeiro montamos um grupo composto pela população antiga e pela população de descendentes gerados após a mutação. Depois ordenamos este grupo de acordo com sua aptidão e então selecionamos $a\%$ dos indivíduos mais aptos, $b\%$ dos indivíduos medianos (no caso, indivíduos que se encontram acima dos μ candidatos mais aptos) e $c\%$ dos piores candidatos.

Selecionando a nova população desta maneira, podemos controlar a diversidade da população, pois se selecionássemos 100% dos indivíduos mais aptos, poderíamos rapidamente ficar presos em um ótimo local, pois estaríamos restringindo o espaço de exploração do AG. Ao adicionar uma percentagem de candidatos medianos e até mesmo ruins, garantimos que a população não seja composta só de indivíduos ótimos, aumentando a diversidade desta. Ainda assim, é necessário cuidado na escolha das percentagens, obviamente devemos dar maior ênfase aos candidatos com melhor aptidão, designar uma percentagem pequena para genótipos medianos e uma ainda menor para os piores indivíduos. Neste trabalho, após algumas simulações, assumimos como aceitável uma proporção com $a = 90\%$, $b = 9\%$ e $c = 1\%$.

Busca Local (Algoritmo Memético)

Já mostramos no Capítulo 4 as etapas de um AG onde podemos inserir um procedimento de busca local para investigar a existência de indivíduos mais aptos na vizinhança dos melhores membros da população.

Neste trabalho, selecionamos o candidato mais forte da nossa nova população, gerada após a seleção dos sobreviventes e exploramos sua vizinhança para tentar encontrar resultados ainda melhores. Nesta busca alteramos dois genes, o primeiro correspondente ao número de níveis de decomposição J e o terceiro $Sohr$, que indica o tipo de função de limiarização usada para redução dos coeficientes.

Para o primeiro alelo simplesmente somamos 1 ao valor atual de J , mas caso este já se encontre em seu valor máximo J_{max} de escalas de decomposição, subtraímos 1.

Para o terceiro alelo investigamos a outra possibilidade, i.e., se a função utilizada for a abrupta trocamos pela suave e avaliamos o custo e se for suave, mudamos para abrupta.

Gerados os vizinhos, avaliamos a aptidão de cada um e a comparamos com a aptidão anterior, caso o vizinho mais apto seja melhor que o antigo candidato, o inserimos no lugar deste candidato. Com isso, aumentamos nossas chances de encontrar melhores candidatos de uma maneira mais rápida. Como aplicamos esta busca apenas ao candidato com melhor função custo, não precisamos nos preocupar em preservar a diversidade da população, o que seria feito criando uma probabilidade para aceitação de um vizinho mais apto.

Preservação do Melhor Indivíduo

Optamos por acrescentar uma etapa que preserva o melhor indivíduo da população. Para isso, verificamos se houve uma piora na aptidão do candidato mais apto na iteração atual em relação ao candidato da iteração anterior. Caso ocorra piora, o antigo genótipo é reinserido na população no lugar de um indivíduo escolhido aleatoriamente (distribuição uniforme). O pseudocódigo para implementação da preservação elitista é mostrado na Fig. 5.12.

```

INICIO
ordenar candidatos por aptidão: [C I] = sort(Aptidao,'descend');
achar e guardar a melhor aptidão na iteração k: apt_max(k) = C(1);
SE (k >1)
    SE (apt_max(k) < apt_max(k-1))
        escolher linha para reinserir o melhor: l = randi([1 μ],1);
        inserir na população: populacao(l,:) = individuo_m(k-1,:);
        designar sua aptidão: Aptidao(l,:) = apt_max(k-1);
        reordenar candidatos: [C I] = sort(Aptidao,'descend');
        guardar melhor aptidão: apt_max(k) = C(1);
    FIM
FIM
Guarda melhor genótipo: Individuo_m(k,:) = populacao(1,:);
FIM

```

Figura 5.12: Pseudocódigo da preservação elitista incorporada ao AG.

5.4.9 Condição de Terminação

Para finalizar o AG, simplesmente limitamos o número de execuções do algoritmo para $N_{ite} = 4$ iterações, pois não temos conhecimento do nível ótimo de aptidão.

5.4.10 Algoritmo de Busca

Para facilitar o entendimento do processo de busca genética implementado nesta dissertação, combinaremos todas as etapas anteriormente descritas para formar o algoritmo de otimização da filtragem wavelet baseada em AG, facilitando sua implementação junto ao Matlab, já que não faremos uso da caixa de ferramentas (*toolbox*) destinada a AG. Em resumo podemos descrevê-lo pelos seguintes passos:

1. Determinar o sinal de DP a ser filtrado e estabelecer uma estimativa do sinal que desejamos encontrar. Especificar ainda o tamanho da população μ , o número de execuções de busca N_{ite} , as famílias wavelets e seus respectivos valores máximos de ordem (aqui foram utilizadas wavelets da família Daubechies, Symlets e Coiflets com ordem máxima N_1 , N_2 e N_3 , respectivamente);
2. Conhecendo a forma como o sistema avaliado será representado (Eq. (5.41)), gerar μ genótipos de forma aleatória com distribuição uniforme (usamos aqui a função do Matlab *randi*), respeitando os limites de valores possíveis para cada gene. Com estes indivíduos formamos a população inicial;
3. Calcular a **aptidão da população inicial** convertendo o genótipo de cada membro para um fenótipo que possa ser submetido à filtragem wavelet (usamos a função *wden* adaptada para decompor cada nível com sua respectiva wavelet). Obtido o sinal filtrado o utilizamos, juntamente com o sinal estimado, para calcular a função custo descrita pela Eq. (5.35);
4. Aplicar o método de **seleção dos pais RWS**, discutido no Capítulo 4, para identificar os cromossomos que irão compor o grupo de cruzamento;
5. Executar a etapa de **recombinação** (descrita na Seção 5.4.6) dois a dois nos cromossomos que compõem o grupo de cruzamento selecionado, gerando um grupo formado por $\beta = \mu$ filhos;
6. Fazer a **mutação** dos filhos selecionando-os com uma probabilidade $p_s = 5\%$ e alterando seus genes de forma aleatória com uma probabilidade de mutação $p_m = 2\%$, conforme discutido na Seção 5.4.7;
7. Aplicar a **heurística** (MA), já discutida, para que possamos alterar cerca de 3% dos genótipos dos filhos, de modo que contenham apenas um tipo de wavelet mãe em todos os níveis de decomposição; isto é essencial para ampliar nosso espaço de busca;
8. Realizar a **seleção dos sobreviventes** avaliando tanto a população quanto os descendentes gerados pelos operadores de recombinação mutação e heurística,

conforme descrito na Seção 5.4.8 (numa proporção $a = 90\%$, $b = 9\%$ e $c = 1\%$);

9. Com a nova população composta pelos sobreviventes, fazer a **busca local** pela vizinhança do melhor candidato, investigando o número de níveis e a função de limiarização. Caso exista um vizinho com maior aptidão, inseri-lo no lugar do anterior.
10. Guardar a aptidão do candidato mais forte e avaliar se não diminuiu em relação à aptidão do candidato anterior (na primeira iteração esta etapa não será executada, por não haver uma população anterior de sobreviventes), caso tenha diminuído inseri-lo em uma posição aleatória na população de sobreviventes;
11. Guardar valores de aptidão média da nova população, do seu genótipo mais fraco e por fim do cromossomo do melhor indivíduo;
12. Repetir os passos 4 a 11 até que seja alcançado o número de iterações N_{ite} ;
13. Mostrar os parâmetros de filtragem obtidos para o melhor genótipo existente na população final de sobreviventes.

Capítulo 6

Comparação e Análise do Resultados

Neste capítulo utilizaremos os métodos de busca do número de níveis, de seleção da wavelet mãe e de busca dos parâmetros de filtragem wavelet baseado em AG, discutidos no capítulo anterior, para avaliar a eficiência de cada um na redução de ruídos de sinais de DP simulados e medidos a partir de equipamentos de alta tensão, seguindo as técnicas de medição descritas no Capítulo 1.

Inicialmente abordaremos os tipos de sinais e ruídos que serão simulados. Então, faremos uso destes sinais para realizar comparações entre os métodos com base nos resultados fornecidos por cada um destes. Por fim, discutiremos os resultados obtidos por cada método, destacando os que mostraram a melhor performance e as razões para tal.

6.1 Sinais de DP Simulados

Em uma medição real, não temos conhecimento da forma de onda do sinal *a priori*. Neste caso, o procedimento frequentemente adotado para avaliação de diferentes algoritmos de filtragem consiste em simular sinais com base em modelos matemáticos e adicionar ruídos simulados ou medidos, avaliando (pelos diferentes parâmetros descritos no Capítulo 5) a eficiência através da comparação entre o sinal original e o filtrado.

Os sinais de DP normalmente relatados na literatura são gerados empregando os modelos matemáticos aplicados em [30], um correspondendo a uma forma de onda DE (S_{PD1}) e o outro DOE (S_{PD2}), dados por


$$S_{PD1} = A (e^{-\alpha_1 t} - e^{-\alpha_2 t}) \quad (6.1)$$

$$S_{PD1} = A (e^{-\alpha_1 t} \cos(\omega t - \varphi) - e^{-\alpha_2 t} \cos(\varphi)) \quad (6.2)$$


onde A é o coeficiente de amplitude, α_1 e α_2 são constantes destinadas ao controle do tempo de decaimento do sinal, $\varphi = \tan^{-1}(\omega/\alpha_2)$, e a frequência da componente oscilatória é dada por $\omega = 2\pi \times f_d$. Em [30, 83] foram sugeridos os seguintes valores para estes parâmetros:

$$\begin{cases} A = 1 \\ \alpha_1 = 1 \times 10^6 s^{-1} \\ \alpha_2 = 1 \times 10^7 s^{-1} \\ f_d = 10 MHz \end{cases}$$

Os pulsos de DP simulados são mostrados na Fig. 6.1 (a) e (b), respectivamente, em função dos pontos amostrados com taxa de aquisição de 60 MHz.



(a)



(b)

Figura 6.1: Sinais de DP simulados: (a) S_{PD1} ; (b) S_{PD2} .

Em [26] Mortazavi *et al.* também simulam outro tipo de sinal DOE para representar pulsos de DP, dado por


$$S_{PD3} = \begin{cases} Ae^{\frac{t-t_0}{\tau}} \cos(2\pi f_0(t-t_0)), & t \geq t_0 \\ 0, & t < t_0 \end{cases} \quad (6.3)$$

onde t_0 é o instante de tempo de ocorrência do pulso, τ é o fator de oscilação e f_0 é a frequência de oscilação. Os sinais de DP simulados ilustrados na Fig. 6.2 (a) e


Tabela 6.1: Parâmetros do pulso de DP mostrados na Fig. 6.2

Sinal	Pulso	A	t_0 (μs)	τ (μs)	f_0 (kHz)
S_{PD3a}	1	0.8	150	2.0	1000
	2	1.2	480	2.5	250
	3	1.0	800	2.0	500
S_{PD3b}	1	0.8	150	2.0	1000
	2	1.2	500	2.5	250
	3	1.0	760	2.0	500

(b) são formados por uma composição de três pulsos obtidos pela Eq. (6.3) com os parâmetros dados na Tabela 6.1.



(a)




(b)

Figura 6.2: Sinais de DP simulados: (a) S_{PD3a} ; (b) S_{PD3b} .


Finalmente, inspirado por [27] iremos simular o sinal de DP dado por

$$S_{PD4} = e^{-\delta t} \begin{cases} -A_1 \text{sen}(2\pi f_1 t), & t_1 \leq t < t_2 \\ -A_2 \text{sen}(2\pi f_2 t) - A_3 \text{sen}(2\pi f_3 t), & t_2 \leq t < t_3 \\ 0, & t < t_1 \end{cases} \quad (6.4)$$

onde f_1 , f_2 e f_3 são valores da frequência de cada senoide, t_1 , t_2 e t_3 definem os intervalos de ocorrência dos pulsos que compõem o sinal, A_1 , A_2 e A_3 correspondem aos seus valores de amplitude e $\delta = 7 \times 10^6 s^{-1}$ é o tempo de decaimento. Os sinais simulados são ilustrados na Fig. 6.3, sendo ambos uma composição de dois pulsos dada pela Eq. (6.4), com parâmetros de amplitude e de tempo mostrados na Tabela 6.2.



(a)



(b)

Figura 6.3: Sinais de DP simulados: (a) S_{PD4a} ; (b) S_{PD4b} .

Tabela 6.2: Parâmetros do pulso de DP mostrados na Fig. 6.3.

Sinal	S_{PD4a}		S_{PD4b}	
	1	2	1	2
A_1	1.125	0.350	0.595	1.330
A_2	0.000	0.450	0.300	1.200
A_3	0.000	0.015	0.010	0.040
t_1 (ns)	90.7	630.8	121.6	600.8
t_2 (ns)	-	729.9	220.7	699.9
t_3 (ns)	-	930.0	420.8	900.0
f_1 (MHz)	30	20	20	20
f_2 (MHz)	-	15	15	15
f_3 (MHz)	-	10	10	10

Portanto, mostramos cada um dos sinais de DP simulados que usaremos em nossas comparações. No entanto, precisamos simular ruídos para incorporá-los aos nossos sinais de DP originais.

6.2 Ruídos Adicionados

Ruído pode ser definido como uma componente indesejável de um sinal medido, que não tem relação com o sinal de interesse.

Na Seção 2.11 apresentamos os tipos de ruídos que comprometem as medições de DP. E vimos que a transformada wavelet é indicada para eliminar ruído branco e ruídos de espectro discreto. Portanto, iremos simular em nosso trabalho sinais de

ruído branco e sinais de espectro discreto, mais especificamente ruído de amplitude modulada. Ambos, serão adicionados aos sinais de DP simulados, tanto de forma separada quanto simultânea.

Como explicamos no Capítulo 2, ruído branco pode ser facilmente simulado por um gerador aleatório de sinais, seja com distribuição uniforme n_{bu} ou Gaussiana n_{bg} tendo média nula e variância constante. Assim sendo, aplicaremos ruído branco com ambas distribuições, como ilustra a Fig. 6.4, em que adicionamos o ruído ao sinal de DP S_{PD3a} .





Figura 6.4: Sinais de DP simulados somados a um ruído branco de $SNR = 3$: (a) uniforme; (b) Gaussiano;


O ruído de espectro discreto inserido será um sinal de banda AM, pois estes são emitidos em uma faixa de frequência que coincide com a faixa de medição de grande parte dos equipamentos de medição de DP. Segundo Motarzavi *et al.* [26] o ruído AM pode ser simulado por:

$$n_{AM} = A \sum (c + m \times \text{sen}(2\pi f_m t)) \times \text{sen}(2\pi f_c t) \quad (6.5)$$

com amplitude da onda portadora $c = 1$, amplitude e frequência de modulação do sinal $m = 0.4$ e $f_m = 1$ kHz, respectivamente, e frequência da onda portadora $f_c = 600$ kHz, 800 kHz, 1000 kHz, 1200 kHz, 1400 kHz. A Fig. 6.5 mostra o ruído AM simulado e seu espectro de frequência. Podemos ver que o espectro possui os picos de amplitude nas frequências da portadora, como era de se esperar.



(a)



(b)

Figura 6.5: Ruído de espectro discreto: (a) ruído simulado; (b) FFT do ruído;

Na Fig. 6.5 é mostrado o sinal de DP S_{PD1} acrescido de um ruído AM com uma $SNR = 3$.




Figura 6.6: Sinal de DP S_{PD1} somado a um ruído AM.

Em nossos experimentos, para os sinais de DP mostrados na Seção 6.1, foram adicionados ruído branco uniforme, ruído branco gaussiano e ruídos de espectro discreto AM, separada e simultaneamente. Os sinais resultantes foram identificados na Tabela 6.3. Os ruídos foram adicionados com 5 diferentes níveis de razão sinal ruído ($SNR = 0.5, 1, 2, 3$ e 4), com isso possuímos um total de 180 sinais simulados adicionados a ruídos distintos. Para os sinais S_{PD4a} e S_{PD4b} o ruído AM foi adicionado com $f_c = 6000$ kHz, 8000 kHz, 10000 kHz, 12000 kHz, 14000 kHz.

Tabela 6.3: Sinais de DP simulados com adiço de rudo.

Designaço	Sinal + Rudo
S_1	$S_{PD1} + n_{bu}$
S_2	$S_{PD1} + n_{bg}$
S_3	$S_{PD1} + n_{AM}$
S_4	$S_{PD1} + n_{bu} + n_{AM}$
S_5	$S_{PD1} + n_{bg} + n_{AM}$
S_6	$S_{PD1} + n_{bu} + n_{bg} + n_{AM}$
S_7	$S_{PD2} + n_{bu}$
S_8	$S_{PD2} + n_{bg}$
S_9	$S_{PD2} + n_{AM}$
S_{10}	$S_{PD2} + n_{bu} + n_{AM}$
S_{11}	$S_{PD2} + n_{bg} + n_{AM}$
S_{12}	$S_{PD2} + n_{bu} + n_{bg} + n_{AM}$
S_{13}	$S_{PD3a} + n_{bu}$
S_{14}	$S_{PD3a} + n_{bg}$
S_{15}	$S_{PD3a} + n_{AM}$
S_{16}	$S_{PD3a} + n_{bu} + n_{AM}$
S_{17}	$S_{PD3a} + n_{bg} + n_{AM}$
S_{18}	$S_{PD3a} + n_{bu} + n_{bg} + n_{AM}$
S_{19}	$S_{PD3b} + n_{bu}$
S_{20}	$S_{PD3b} + n_{bg}$
S_{21}	$S_{PD3b} + n_{AM}$
S_{22}	$S_{PD3b} + n_{bu} + n_{AM}$
S_{23}	$S_{PD3b} + n_{bg} + n_{AM}$
S_{24}	$S_{PD3b} + n_{bu} + n_{bg} + n_{AM}$
S_{25}	$S_{PD4a} + n_{bu}$
S_{26}	$S_{PD4a} + n_{bg}$
S_{27}	$S_{PD4a} + n_{AM}$
S_{28}	$S_{PD4a} + n_{bu} + n_{AM}$
S_{29}	$S_{PD4a} + n_{bg} + n_{AM}$
S_{30}	$S_{PD4a} + n_{bu} + n_{bg} + n_{AM}$
S_{31}	$S_{PD4b} + n_{bu}$
S_{32}	$S_{PD4b} + n_{bg}$
S_{33}	$S_{PD4b} + n_{AM}$
S_{34}	$S_{PD4b} + n_{bu} + n_{AM}$
S_{35}	$S_{PD4b} + n_{bg} + n_{AM}$
S_{36}	$S_{PD4b} + n_{bu} + n_{bg} + n_{AM}$

6.3 Sinais de DP Medidos

Na Seção 2.6 descrevemos os diferentes tipos de circuitos utilizados em medições de DP. Foi por meio destes que fizemos a aquisição dos dados de DP que analisaremos nesta dissertação. Alguns sinais foram medidos nos laboratórios do Centro de Pesquisas de Energia Elétrica (CEPEL) utilizando o circuito mostrado na Fig. A.1, aplicando como objeto de teste C_a uma Barra de Estatórica ou um Disjuntor.

Os demais sinais avaliados neste trabalho advêm de medições em campo, como os sinais obtidos de GIS, transformadores, hidro geradores, Transformador de Corrente (TC) e Pararraio (PR). Os métodos de medição aplicados a estes equipamentos também foram apresentados no Apêndice A.

Os dados foram aquisitados com diferentes taxas de amostragem para os diversos equipamentos, conforme indicado na Tabela 6.4, os quais em sua maioria foram analisados com um comprimento de 10000 amostras.

Também adicionamos ruído branco Gaussiano com $SNR = 4$ aos sinais mostrados na Tabela 6.4; com isso formamos um grupo de 80 sinais distintos para serem utilizados na comparação dos algoritmos aqui descritos.

Somamos um total de 260 sinais de DP distintos, dentre pulsos de DP aquisitados e simulados.

6.4 Definição de Pesos para Função Custo

Para aplicarmos a função Custo f_{Apt} , definida na Eq. (5.34), no algoritmo genético e para usá-la como um parâmetro de avaliação dos demais métodos, precisamos definir os pesos α_i e β_i . Para encontrar tais pesos fomos obrigados a executar o AG algumas vezes para valores distintos de pesos e para vários sinais de DP distintos, de forma a determinar heurísticamente os pesos que permitissem identificar bons resultados de filtragem.

Por meio das simulações feitas verificamos que:

- O critério DSNR normalmente fornece valores em uma ordem de grandeza não muito elevada; com isso optamos por fazer $\alpha_1 = 1$;
- De antemão sabemos que o critério NCC não é maior do que 1; portanto, para dar a este uma importância aproximadamente igual à dada ao parâmetro

Tabela 6.4: Sinais de DP medidos.

Designação	Equipamento	F_s (MHz)
S_{37}	Barra estatórica 1	250
S_{38}	Barra estatórica 2	250
S_{39}	Disjuntor 1	500
S_{40}	Disjuntor 2	500
S_{41}	Pararraio 1	100
S_{42}	Pararraio 2	100
S_{43}	Pararraio 3	100
S_{44}	Pararraio 4	2500
S_{45}	Pararraio 5	2500
S_{46}	Pararraio 6	2500
S_{47}	Pararraio 7	2500
S_{48}	Pararraio 8	2500
S_{49}	GIS 1	1000
S_{50}	GIS 2	1000
S_{51}	GIS 3	1000
S_{52}	GIS 4	1000
S_{53}	GIS 5	2500
S_{54}	GIS 6	2500
S_{55}	GIS 7	2500
S_{56}	GIS 8	5000
S_{57}	TC 1	250
S_{58}	TC 2	250
S_{59}	TC 3	250
S_{60}	TC 4	1000
S_{61}	Transformador 1	500
S_{62}	Transformador 2	500
S_{63}	Transformador 3	500
S_{64}	Transformador 4	500
S_{65}	Transformador 5	500
S_{66}	Transformador 6	1000
S_{67}	Transformador 7	1000
S_{68}	Transformador 8	1000
S_{69}	HG 1	250
S_{70}	HG 2	500
S_{71}	HG 3	500
S_{72}	HG 4	500
S_{73}	HG 5	1000
S_{74}	HG 6	1000
S_{75}	HG 7	5000
S_{76}	HG 8	5000

DSNR, fizemos $\alpha_2 = 10$;

- O critério EQM tende a fornecer valores muito baixos (próximos de zero) diante de bons resultados de filtragem. Sabendo que o mesmo se encontra no denominador, obteríamos um valor muito alto, anulando o efeito dos demais termos. Percebemos que o valor de peso deveria ser adaptado a cada sinal que estivesse sendo analisado, o que nos levou a incluir junto ao algoritmo de avaliação de aptidão do AG uma rotina para buscar um valor de peso $10^{-\varepsilon}$. A rotina consiste em um *loop* que incrementa o valor de ajuste ε com um passo ℓ até que o resultado de α_3/EQM alcance um valor menor ou igual a 10, considerado aceitável para contribuir com o custo total, sem prejudicar o valor dos demais critérios. O pseudocódigo da rotina é mostrada na Fig. 6.7. Note que o valor de passo escolhido é igual 0.5; quanto menor este valor mais próximo de 10 será a contribuição do critério EQM. Encontrado o valor ε , o fixamos para todos os indivíduos avaliados, para que fossem analisados sob o mesmo peso. É importante que o indivíduo (candidato) analisado nesta primeira etapa, tenha um resultado razoável de filtragem; para isso basta executar o algoritmo para a população inicial e determinar qual o mais apto sob qualquer peso α_3 e em seguida reanalisá-lo com a rotina descrita anteriormente. Esta medida é suficiente para garantir que o AG tenha um bom desempenho ao determinar a aptidão de cada indivíduo da população. Para usar a função custo na avaliação dos demais métodos, primeiro executamos o algoritmo AG e determinamos o valor de α_3 para cada sinal analisado, sem a necessidade de fazê-lo para os sinais com adição do ruído simulado. Sendo $\alpha_3 = 10^{-\varepsilon}$, expomos na Tabela 6.5 os valores de ajuste ε encontrados.
- Os valores dos pesos β_1 a β_4 , correspondentes aos parâmetros locais, foram escolhidos como 0.02, visto que os critérios correspondentes à este peso são dados em porcentagem, raramente os valores de EAmáx, EAmin, VTPmáx e VTPmín ultrapassarão 100% de variação; entretanto o valor de VTS pode atingir valores muito altos. Tome como exemplo um sinal com tempo de subida (em amostras) igual a 5 amostras e ao ser filtrado seu valor passa a ser de 20 amostras, correspondendo a um VTS igual a 400%. Então limitamos este critério a apresentar um valor máximo de 200% e aplicamos $\beta_5 = 0.02$;
- O peso determinado para o critério Dk foi $\beta_6 = 1.5$. Este componente é essencial para permitir que a nossa função exclua sinais que, apesar de terem boas características globais e até mesmo locais, no que se refere aos critérios anteriores, contêm pequenos trechos de ruído de alta amplitude, como ilustrado na Fig. 5.1.

Tabela 6.5: Valores de ajuste calculados para cada Sinal de DP.

Sinal	ε	Sinal	ε
S_1	-2	S_{54}	-6.5
S_2	-2	S_{55}	-6.5
S_3	-2.5	S_{56}	-4.5
S_4	-2.5	S_{57}	-5
S_5	-3	S_{58}	-5
S_6	-3	S_{59}	-5
S_{37}	-6	S_{60}	-5
S_{38}	-6	S_{61}	-5.5
S_{39}	-5	S_{62}	-4.5
S_{40}	-3	S_{63}	-3
S_{41}	-6	S_{64}	-3
S_{42}	-6	S_{65}	-4
S_{43}	-6	S_{66}	-4
S_{44}	-8	S_{67}	-4
S_{45}	-6	S_{68}	-4
S_{46}	-1	S_{69}	-7.5
S_{47}	-8	S_{70}	-8
S_{48}	-8	S_{71}	-7.5
S_{49}	-5	S_{72}	-7
S_{50}	-5	S_{73}	-7
S_{51}	-5.5	S_{74}	-7.5
S_{52}	-6	S_{75}	-4
S_{53}	-5.5	S_{76}	-5

```

INICIO
  definir valor de passo:  $\ell=0,5$ ;
  definir valor de ajuste:  $\varepsilon=0$ ;
  ENQUANTO ( $c \geq 10$ )
    calcular  $c = \alpha_3/\text{MSE} = 10^{-\varepsilon}/\text{MSE}$ ;
     $\varepsilon = \varepsilon + \ell$ ;
  FIM
FIM

```

Figura 6.7: Pseudocódigo para cálculo do fator de ajuste ε para determinar o peso do parâmetro EQM.

6.5 Comparação entre Métodos

Os métodos aplicados aos vários sinais de DP disponíveis, os quais foram descritos nas Seções 6.1 a 6.3, serão comparados a seguir.

Na análise dos sinais de DP medidos, já que não conhecemos *a priori* a forma de onda dos pulsos de DP, estimamos o pulso ideal como se segue:

1. Primeiro, aplicamos o processo de filtragem wavelet utilizando uma determinada wavelet mãe em conjunto com a função de limiarização **abrupta**, sendo os valores de limiar obtidos por meio do método *scaledep* (sem levar em conta o fator de reescala, já que esse não é aplicado em conjunto com este método), para que possamos remover parte do ruído do sinal de DP amostrado;
2. Na sequência, as porções do sinal obtido correspondente à ruído, que não foram bem eliminadas na filtragem, são zeradas, permitindo obter um sinal estimado de DP que será utilizado no cálculo dos parâmetros de avaliação.

Neste trabalho, utilizamos também o mesmo sinal estimado para a busca das wavelets mãe em cada um dos métodos descritos no Capítulo 5; no entanto, este procedimento não seria muito indicado para uma medição de DP em tempo real no campo, por demandar tempo, já que é feito manualmente. Nestas situações, seria possível executar somente o primeiro passo para uso nos algoritmos de seleção da wavelet mãe. Ainda assim, para o método de seleção dos parâmetros baseado no AG o mais indicado é executar os dois passos descritos, caso contrário é muito provável que o método encontre os mesmos parâmetros aplicados no primeiro passo de estimativa do sinal. Portanto, não haveria sentido em se buscar por um ótimo que já conhecemos, fugindo ao propósito de encontrar parâmetros que resultem o mais próximo possível na eliminação de ruídos.

Todas as wavelets empregadas no processo de determinação do sinal de re-

ferência são mostradas na Tabela 6.6 para cada um dos sinais de DP medidos escolhemos as mesmas em um grupo contendo wavelets *db2* a *db30*, *sym2* a *sym15* e *coif1* a *coif5*.

Um exemplo do processo descrito é mostrado na Fig. 6.8 para o sinal S_{23} . Note que tal procedimento permitirá uma melhor comparação dos métodos de seleção wavelet aqui apresentados.




Figura 6.8: Sinal de DP S_{23} : (a) sinal adquirido; (b) sinal filtrado com wavelet *db5*; (c) sinal estimado.

Com os sinais ideais gerados para cada um dos pulsos de DP medidos e com os sinais simulados ideais, obtemos as wavelets ótimas para cada algoritmo de seleção discutido no Capítulo 5. Inicialmente executamos o algoritmo de seleção PSBLS para determinar o número de níveis a ser aplicado em cada um dos métodos, exceto no método AG que faz a busca de todos os parâmetros envolvidos no processo de redução de ruídos por wavelet. Os resultados de wavelet mãe obtidos para cada um dos sinais são mostrados nas Tabelas 6.7 a 6.12. Note que para os algoritmos EBWS, SNRBWS, MEBWS e AG uma wavelet diferente é selecionada para cada nível, enquanto que para o algoritmo CBWS uma única wavelet é selecionada para todos os níveis.

A seleção wavelet dos algoritmos CBWS, EBWS, SNRBWS e MEBWS é feita com base no sinal ideal (estimado) e os sinais resultantes da adição dos ruídos simulados são decompostos com a mesma wavelet mãe. No entanto, dependendo do nível de ruído adicionado, pode ocorrer que o número de níveis encontrado pelo

Tabela 6.6: Wavelet selecionada para obter o sinal de referência.

Sinal de DP Medido	Wavelet
S_{37}	db15
S_{38}	coif5
S_{39}	sym8
S_{40}	db5
S_{41}	coif5
S_{42}	sym5
S_{43}	db5
S_{44}	coif5
S_{45}	coif5
S_{46}	coif4
S_{47}	coif5
S_{48}	db5
S_{49}	db9
S_{50}	db9
S_{51}	db5
S_{52}	coif5
S_{53}	coif5
S_{54}	coif4
S_{55}	db20
S_{56}	sym5
S_{57}	db10
S_{58}	coif5
S_{59}	db5
S_{60}	coif5
S_{61}	db5
S_{62}	sym5
S_{63}	db7
S_{64}	sym5
S_{65}	db9
S_{66}	sym5
S_{67}	db5
S_{68}	db7
S_{69}	db20
S_{70}	coif4
S_{71}	db7
S_{72}	db7
S_{73}	db6
S_{74}	sym15
S_{75}	db5
S_{76}	db5

algoritmo PSBLS seja diferente, e nos casos em que encontramos um número menor o processo de filtragem utiliza as mesmas wavelets indicadas pelas tabelas, entretanto, são utilizadas apenas as wavelets correspondentes ao número de níveis calculado; nos casos em que o número calculado foi maior, foi preciso executar novamente cada algoritmo para encontrar as wavelets nos níveis superiores. Não podemos assumir o mesmo para o método de busca AG, pois este pode selecionar wavelets mãe distintas para cada um dos sinais. Optamos por não mostrar todas as wavelets resultantes por questões de praticidade, devido ao elevado número de sinais avaliados.

Analisando as Tabelas 6.7 a 6.11 vemos o número de níveis de decomposição J selecionados pelo algoritmo PSBLS para os métodos CBWS, EBWS, SNRBWS e MEBWS; já o número de níveis selecionado pelo AG é diferente, dado que este algoritmo busca pelo ótimo em todos os parâmetros aplicados na wavelet, o que inclui o número de níveis.

Se assumirmos de antemão que os parâmetros selecionados pelo AG proverão os melhores resultados de filtragem, então, por suposto, o J encontrado por este será o melhor. Podemos verificar que o método de seleção de níveis PSBLS, mesmo não fornecendo o mesmo valor, chega bem próximo do número encontrado pelo AG, o que é um indicativo de que o PSBLS tem um bom comportamento, apesar de não fornecer um número de níveis ótimo. Discutiremos melhor as particularidades do método PSBLS na Seção 6.6.4.

6.5.1 Distribuição de Energia

Para mostrarmos o efeito de distribuição de energia, dentre os coeficientes de detalhe e os coeficientes de aproximação, aplicamos a decomposição wavelet utilizando as wavelets selecionadas pelos diferentes métodos, combinada com os parâmetros de filtragem que geraram os melhores resultados em cada um dos métodos de seleção. E então, calculamos a energia de cada um dos coeficientes gerados. Os resultados são mostrados nas Tabelas 6.13 e 6.14 para 8 sinais de DP distintos, dentre eles os sinais S_{38} , S_{57} , S_{77} ($S_{37} + ng_{SNR=4}$), S_{79} ($S_{37} + ng_{SNR=4}$), S_{103} ($S_{39} + ng_{SNR=4}$), S_{111} ($S_{71} + ng_{SNR=4}$), S_{126} ($S_2, SNR=4$), S_{128} ($S_3, SNR=1$), S_{160} ($S_9, SNR=3$). É notável que a energia dos coeficientes do método SNRBWS tende a se concentrar nos níveis de maior importância que compõem o sinal de DP, resultando, em geral, em uma melhor qualidade na redução dos ruídos presentes no sinal, quando comparado ao EBWS e ao CBWS. Como o número de níveis selecionado pelo método AG é diferente do selecionado pelo PSBLS, estes são apresentados isoladamente. Observe, juntamente com as Tabelas 6.11 a 6.16, que por buscar todos os parâmetros que me-

Tabela 6.7: Wavelet selecionada em cada método para os sinais de DP simulados.

Sinal	J	Método	Wavelet Mãe
S_1	11	CBWS	sym16
		EBWS	db2/db2/db2/db2/db2/db22/db2/db2/db19/db11/db30/
		SNRBWS	coif1/db2/sym12/db4/sym5/sym11/coif1/db3/db3/db4/coif1/
		MEBWS	coif1/db2/db2/sym5/db4/sym5/coif1/db2/db30/db30/db30/
	6	AG	sym11/db10/sym3/sym5/db20/db25/
S_2	10	CBWS	sym7
		EBWS	db2/db2/db2/db2/db4/db2/db30/db30/db26/db27/db29/
		SNRBWS	coif1/sym12/db13/db10/coif1/db2/sym5/db2/sym5/db2/coif1/
		MEBWS	coif2/db9/sym4/sym9/sym5/db27/db2/db3/db4/db5/db4/
	7	AG	db14/sym6/db11/sym12/sym3/sym10/db14/
S_3	13	CBWS	sym7
		EBWS	db2/db2/db2/db2/db2/db2/db4/coif1/db24/db27/db30/db30/db30/
		SNRBWS	sym5/db27/db27/coif5/db22/sym12/db10/db5/sym4/sym4/coif1/sym4/db25/
		MEBWS	sym5/sym4/sym5/sym7/coif4/sym4/coif1/db2/db2/db3/db3/db2/db2/
	8	AG	sym14/sym14/sym14/sym14/sym14/sym14/sym14/sym14/
S_4	12	CBWS	sym7
		EBWS	db2/db2/db2/db2/db2/db2/db5/db2/db18/db4/db29/db4/db29/
		SNRBWS	sym5/db27/db27/db30/db28/sym8/db2/db4/db13/db5/sym5/db4/db24/
		MEBWS	sym5/sym4/sym5/db8/sym10/sym5/db26/db30/db4/db3/db3/sym4/db15/
	8	AG	sym13/sym13/sym13/sym13/sym13/sym13/sym13/sym13/
S_5	13	CBWS	sym10
		EBWS	db2/db2/db2/db2/db2/db28/db29/db2/db18/db14/db19/db27/
		SNRBWS	db23/db26/db24/coif3/coif2/db10/db27/db8/db9/db8/db24/db2/
		MEBWS	db3/sym7/db9/sym4/coif2/coif4/db2/db30/db30/db11/db4/db3/
	10	AG	db15/db3/db13/sym14/db13/sym8/sym15/sym6/coif2/db3/
S_6	13	CBWS	coif4
		EBWS	db2/db2/db2/db2/db2/db2/db25/db5/coif1/db27/db27/db29/
		SNRBWS	db23/db5/db26/db28/db22/db5/db7/db15/db3/coif3/db19/db5/
		MEBWS	db4/db2/sym5/db27/coif4/sym7/sym14/db27/db30/db30/sym13/db30/
	6	AG	db26/db19/db11/sym9/sym11/sym9/

Tabela 6.8: Wavelet selecionada em cada método para os sinais de DP medidos.

Sinal	J	Método	Wavelet Mãe
S_{37}	13	CBWS	sym4
		EBWS	db2/db2/db2/db2 /db8/db4/coif1/db4/coif1/db30/db28/db30/db19
		SNRBWS	db17/db29/sym5/db11/sym12/db3/coif5/sym9/db6/sym7/db3/db3/sym4
		MEBWS	db4/sym4/sym5/sym9/db14/ db2 /coif1/ db2/db2/db2/db2 /db7
	8	AG	db13/sym4/db26/db20/sym7/sym4/db28/sym3
S_{38}	13	CBWS	db2
		EBWS	db2/db2/db2 /db11/ db2 /db4/coif1/coif1/ db2 /db26/db30/db27/db30
		SNRBWS	db18/db15/db23/db13/sym13/db22/coif4/sym12/db5/coif1/db4/coif2/sym4
		MEBWS	db4/db5/db12/sym10/db11/coif1 db2/db2/db2/db2 /db3/sym4/db3/
	8	AG	db30/db21/db14/db27/db29/sym4/db24/sym13
S_{39}	7	CBWS	sym13
		EBWS	db2/db2/db2/db2/db2 /db9/ db2
		SNRBWS	sym8/db7/sym8/db19/db29/db17/db29
		MEBWS	db3/sym5/coif4/sym15/db29/sym15/coif1
	6	AG	db7/db7/db7/db7/db7/db7
S_{40}	7	CBWS	coif5
		EBWS	db2/db2/db2/db2/db2 /db29/ db2
		SNRBWS	db4/sym9/db5/db5/db10/db30/db19
		MEBWS	db5/db5/db5/db5/db5/ db2 /db29
	7	AG	db28/db19/db8/db29/db16/sym10/db14
S_{41}	6	CBWS	db4
		EBWS	db2/db2/db2 /db22/db4/db7
		SNRBWS	coif2/sym7/sym7/coif1/db8/sym5
		MEBWS	sym5/db4/sym13/db30/db4/db4
	8	AG	db29/db11/db16/db24/db13/db24/db25/sym11
S_{42}	10	CBWS	sym16
		EBWS	db2 /db4/db29/db30/db26/db29/db25/db29/db28/db28
		SNRBWS	db2/db10/db28/db9/coif1/coif1/db10/coif1/db14/coif1
		MEBWS	db14/ db2 /db30/db4/db3/db15/db8/db5/db3/db3
	8	AG	db4/db20/coif4/db25/db29/coif2/db6/coif4
S_{43}	6	CBWS	db4
		EBWS	db2/db2/db2 /db17/db4/db3
		SNRBWS	sym5/db5/db8/db10/db4/db3
		MEBWS	db2/db2 /db30/db30/db24/db27
	7	AG	db30/db3/db20/db19/db11/coif3/db18
S_{44}	9	CBWS	db4
		EBWS	db2/db2/db2 /db17/db4/db3
		SNRBWS	sym5/db5/db8/db10/db4/db3
		SNRBWS	db2/db2 /db30/db30/db24/db27
	7	GA	sym4/db15/sym12/sym7/db22/db17/db23

Tabela 6.9: Wavelet selecionada em cada método para os sinais de DP medidos.

Sinal	J	Método	Wavelet Mãe
S_{45}	8	CBWS	db10
		EBWS	db2/db2/db2/db2/db2 /db8/db25/db26/db5
		SNRBWS	db4/db12/db19/db27/sym15/db29/db5/db3/db2
		MEBWS	db4/coif4/sym12/db20/db17/db23/ db2 /db27/ db2
	9	AG	db10/db25/db28/sym8/db9/coif1/sym10/db11/db18
S_{46}	10	CBWS	db10
		EBWS	db2/db2/db2/db2/db2/db2 /coif1/db14/db18/db14
		SNRBWS	db28/sym9/db9/db28/db16/db25/db28/db13/sym11/db30
		MEBWS	sym5/sym9/db12/coif1/sym15/coif1/db28/sym13/db30/db30
	10	AG	db24/sym4/db27/db16/sym6/db20/db21/sym12/db8/sym3
S_{47}	9	CBWS	sym4
		EBWS	db2/db2/db2/db2/db2 /db6/db25/db5/db4
		SNRBWS	sym5/sym13/sym12/db8/db28/db5/sym12/db4/sym5
		MEBWS	sym5/db13/db13/db7/sym13/sym7/db7/db19/db4
	8	AG	db24/sym15/coif2/sym6/db23/coif5/db17/db24
S_{48}	9	CBWS	db10
		EBWS	db2/db2/db2/db2/db2 /db8/ db2 /db13/db4
		SNRBWS	db28/sym14/sym11/db13/sym7/db18/db10/db3/coif2
		MEBWS	sym5/db6/db5/db5/db12/db26/ db2/db2/db2
	10	AG	db12/db7/db23/sym10/db4/db12/coif4/coif1/db17/sym1
S_{49}	9	CBWS	sym15
		EBWS	db2/db2/db2/db2 /db14/ db2/db2 /db21/db4
		SNRBWS	sym4/db5/db7/db26/db17/sym13/sym13/sym15/sym15
		MEBWS	sym5/db7/db7/db16/db30/ db2 /db5/db29/ db2
	11	AG	db6/coif5/coif2/db13/db10/db26/db24/db9/sym5/db9/db5
S_{50}	6	CBWS	sym7
		EBWS	db2/db2 /db10/db8/db12/ db2
		SNRBWS	db29/db25/db27/db9/db23/db8
		MEBWS	db19/sym9/db13/db9/db30/coif1
	11	AG	sym13/db18/db11/coif2/db2/db16/db22/coif1/sym5/db27/db2
S_{51}	6	CBWS	sym9
		EBWS	db2/db2 /db5/db5/ db2/db2
		SNRBWS	db30/db6/coif3/db5/db20/db24
		MEBWS	db5/db5/db5/db5/db29/coif1
	11	AG	db18/db5/db18/db21/sym7/sym9/db24/coif4/coif4/db8/db28
S_{52}	13	CBWS	coif4
		EBWS	db2/db2/db2 /db11/db22/ db2 /coif3/db30/coif2/db4/db27/db30/db27
		SNRBWS	db19/db26/db17/db12/db11/db20/db9/db25/db12/coif5/sym4/coif1/db3
		MEBWS	db4/db5/sym11/db12/db22/ db2 /sym12/db30/ db2 /coif1/ db2/db2/db2
	12	AG	db16/coif5/db26/sym7/coif5/db18/sym8/db8/db12/db15/sym9/sym9

Tabela 6.10: Wavelet selecionada em cada método para os sinais de DP medidos.

Sinal	J	Método	Wavelet Mãe
S_{53}	7	CBWS	db23
		EBWS	db2/db2/db2/db2/db7/db7/db2
		SNRBWS	db28/sym5/sym5/db27/db21/sym15/db26
		SNRBWS	sym5/sym4/sym5/db7/db11/db19/db3
	10	GA	coif4/coif4/coif4/coif4/coif4/coif4/coif4/coif4/coif4
S_{54}	13	CBWS	sym15
		EBWS	db2/db2/db2/db2/db6/db10/db2/db27/db29/db30/db26/db28/db2
		SNRBWS	db2/db4/sym4/db24/sym13/db24/db22/db19/db21/db9/coif1/db2/db5
		MEBWS	sym5/sym5/sym6/db8/sym9/db20/ db2 /db30/db12/db19/db4/db8/db4
		12	AG
S_{55}	13	CBWS	db3
		EBWS	db2/db2/db2/db2/db18/db4/coif1/db2/db15/db30/db27/db28/db27
		SNRBWS	db28/db27/sym11/db26/db28/db2/db5/db16/db16/db6/db6/db2/coif1
		MEBWS	sym5/db7/coif2/sym9/db23/ db2 /coif1/coif1/db12/db4/coif1/db6/db3
		10	AG
S_{56}	11	CBWS	db15
		EBWS	db2/db2/db2/db2/db2/db2/db2/db2/coif1/db30/db26
		SNRBWS	db28/sym4/db9/sym11/db5/db9/db8/db26/db22/coif5/db5
		MEBWS	sym5/db4/db4/db5/db9/sym7/db11/coif1/coif1/db4/coif1
		13	AG
S_{57}	13	CBWS	sym14
		EBWS	db2/db2/db2/db2/db14/db2/db3/coif1/db19/db27/db29/db30/db30/db29
		SNRBWS	db3/db29/db8/sym4/coif3/db6/db4/sym5/db4/coif1/db2/coif2/db24
		MEBWS	db5/db26/db29/db28/ db2 /db4/coif1/db26/db11/db9/db10/db7/ db2
		9	AG
S_{58}	13	CBWS	sym14
		EBWS	db2/db2/db2/db2/db22/db2/db2/db2/sym5/db2/db15/db2/db27/db27/db30
		SNRBWS	db16/db24/db15/sym14/sym7/db26/sym5/sym4/sym14/db4/db4/sym5/sym4
		MEBWS	db3/db30/db21/coif1/ db2/db2/db2/db2 /coif1/db8/db4/coif1/coif1
		11	AG
S_{59}	13	CBWS	db7
		EBWS	db2/db2/db2/db2/db14/coif1/db2/db23/db10/db21/db27/db30/db27
		SNRBWS	db5/db5/sym15/db17/coif2/db4/db5/db14/db13/db2/db3/db4/db3
		MEBWS	db5/db12/db5/db22/ db2 /coif1/coif1/db23/db7/db4/db7/db7/db4
		4	AG
S_{60}	9	CBWS	sym5
		EBWS	db13/db18/ db2/db2 /coif1/ db2/db2 /db27/db4
		SNRBWS	sym8/db29/db18/db23/db14/db5/sym9/sym7/db13
		MEBWS	coif5/db29/ db2 /db30/db3/db3/sym7/sym5/coif1
		11	AG

Tabela 6.11: Wavelet selecionada em cada método para os sinais de DP medidos.

Sinal	J	Método	Wavelet Mãe
S_{61}	13	CBWS	sym16
		EBWS	db2/db2/db2/coif1/sym4/coif1/db28/db4/db27/db27/db28/db27/db27
		SNRBWS	db7/db21/db5/sym13/db9/db25/sym7/sym13/db2/db2/db2/db3/sym11
		MEBWS	db2/db26/db2/db3/sym5/coif1/coif1/coif1/db2/db2/coif1/db2/coif1
	11	AG	db23/db28/sym15/db19/db17/db1/db28/db7/sym1/sym12/db5
S_{62}	9	CBWS	sym6
		EBWS	db2/db2/db2/db2/db2/db19/db2/db4/coif1
		SNRBWS	db28/db9/sym7/db18/db24/db27/sym6/db5/db18
		SNRBWS	sym5/sym5/sym5/db7/db5/db25/db3/db2/db2
	12	GA	db29/coif3/db22/db26/sym3/sym2/sym4/sym7/sym9/db26/db27/sym1
S_{63}	7	CBWS	sym10
		EBWS	db2/db2/db2/db2/db2/db25/db2
		SNRBWS	db28/sym5/db29/db17/db6/db20/db21
		MEBWS	sym5/db7/sym9/db12/db9/db2/db11
	7		db17/db12/sym3/db21/db25/sym3/db26
S_{64}	9	CBWS	sym14
		EBWS	db2/db2/db2/db2/db2/db2/db7/db2/db2
		SNRBWS	db28/db9/sym7/db19/db6/sym13/sym9/db29/sym15
		MEBWS	sym5/sym5/sym9/db26/db3/db25/sym5/db30/db4
	10	AG	db22/sym9/db17/coif3/db6/coif2/sym9/sym9/db30/db30/
S_{65}	13	CBWS	sym4
		EBWS	db2/db8/db2/db2/db2/db11/db2/db2/db19/db27/db30/db27/db27
		SNRBWS	db10/db12/db26/coif1/sym15/sym13/sym12/sym12/db26/db6/db19/db3/db2
		MEBWS	db9/db9/db28/db25/db29/db16/sym13/db30/db4/db6/db6/db5/db5
	9	AG	db4/sym7/sym11/coif2/db13/sym11/sym14/db4/db15
S_{66}	13	CBWS	db2
		EBWS	db2/db2/sym7/db4/db4/db2/db2/db19/coif1/db4/db27/db29/db30
		SNRBWS	sym5/sym5/sym5/coif2/db2/coif2/db4/db2/coif1/db2/db4/coif1/db5
		MEBWS	sym5/sym5/sym5/db7/coif1/coif1/sym5/coif1/coif1/coif1/db2/db2/coif1
	12	AG	db26/db28/db29/db10/coif2/db4/db22/db16/sym11/db24/db10/sym8
S_{67}	8	CBWS	sym12
		EBWS	db2/db2/db2/db2/db2/db2/db29/db2
		SNRBWS	db23/db8/db18/db27/db2/coif2/db26/sym7
		MEBWS	db4/db9/db8/db23/db20/db11/db21/db30
	8	AG	db8/sym9/coif1/sym3/db10/sym7/sym13/sym2
S_{68}	9	CBWS	sym11
		EBWS	db2/db2/db2/db2/db2/db10/db4/db26/db3
		SNRBWS	db4/db2/sym5/db5/db10/sym13/db5/sym14/db23
		MEBWS	db4/sym5/db11/db11/db7/db15/db4/db30/db4
	9	AG	db7/db7/db7/db7/db7/db7/db7/db7

Tabela 6.12: Wavelet selecionada em cada método para os sinais de DP medidos.

Sinal	J	Método	Wavelet Mãe
S_{69}	6	CBWS	coif5
		EBWS	db2/db2/db5/db21/db20/db2
		SNRBWS	db30/db29/db27/db15/db27/db19
		MEBWS	db28/sym5/sym13/db16/db27/ db2
	11	AG	coif5/db22/db21/coif4/sym8/db23/db6/db21/db23/db15/coif3
S_{70}	7	CBWS	sym15
		EBWS	db2/db2/db2/db8/db6/db29/db2
		SNRBWS	db23/db5/db26/db17/db12/db30/db29
		MEBWS	db4/sym5/db19/sym11/sym12/db30/ db2
	11	AG	sym2/db18/db19/db10/db17/db16/coif1/sym5/db9/coif3/db26
S_{71}	7	CBWS	sym15
		EBWS	db2/db2/db2/db2/db6/db23/db2
		SNRBWS	db28/db5/db21/db13/db6/db27/db30
		SNRBWS	sym5/db4/sym5/db28/db7/db27/ db2
	10	GA	sym2/sym5/db17/db13/coif3/sym12/db30/db19/sym15/sym1
S_{72}	7	CBWS	sym15
		EBWS	db2/db2/db2/db2/db2/db19/db2
		SNRBWS	db28/db10/db21/sym7/db30/db30/db24
		MEBWS	sym5/sym5/sym7/db12/sym9/db28/coif1
	8	AG	db27/db26/sym5/sym10/db16/db14/db24/sym3
S_{73}	13	CBWS	db24
		EBWS	db6/db6/db27/ db2/db27/db21/db26/db27/db30/db27/db27/db27/db27
		SNRBWS	sym6/db5/db29/db11/db4/db2/db12/db30/db15/db15/db29/sym9/db25
		MEBWS	db6/db6/db28/ db2/db23/db25/db24/db29/db27/db10/db4/db6/sym4
	11	AG	db22/db8/sym15/coif4/coif5/coif5/db22/db19/db22/db17/sym4
S_{74}	13	CBWS	coif4
		EBWS	db2/db2/db2/db12/db2/db28/db27/db4/db3/db30/db27/db26
		SNRBWS	db28/db21/db30/db11/coif4/db23/sym5/db24/sym6/sym12/db6/db2/db7
		MEBWS	sym9/db19/sym7/sym14/db11/db28/sym5/db25/coif1/db4/db7/coif1/db18/
	13	AG	db22/db22/db7/sym1/db25/db19/sym7/db18/db5/db10/db27/sym2/db25
S_{75}	9	CBWS	sym2
		EBWS	db2/db2/db2/db2/db2/db4/db27/db25/db3/
		SNRBWS	db18/db4/db20/sym12/db25/sym12/sym12/sym5/sym11
		MEBWS	db5/db5/db27/sym14/coif1/ db2/db30/db27/db2
	11	AG	db18/db19/coif5/db26/sym3/db27/db25/coif4/coif3/coif2/db24
S_{76}	8	CBWS	db2
		EBWS	db2/db2/db2/db2/db2/db4/coif1/db2
		SNRBWS	db19/db7/db28/db18/db4/sym11/db13/db30
		MEBWS	db5/db5/db26/db26/ db2/sym5/db4/db2
	12	AG	db23/sym8/db30/coif2/db6/db1/sym15/db26/coif2/db19/db6/sym3

lhora representam o sinal, sua distribuição de energia não necessariamente vai tender a concentrar maior energia no nível de maior importância e sim se aproximará da distribuição de energia do sinal ideal, portanto, obtendo uma melhor performance na redução de ruídos do sinal analisado.

Como o método CBWS se baseia na correlação entre a forma de onda do pulso de DP e a forma de onda da wavelet, não existe nenhuma garantia de que esta informação produzirá coeficientes que se concentrem na banda de maior importância.

Vemos que o método EBWS tenta maximizar a energia na banda de aproximação final, não identificando as bandas nas quais o sinal de DP se concentra. O algoritmo SNRBWS por conseguir na maioria das vezes identificar a banda predominante do pulso de DP buscando a wavelet que gera o maior coeficiente, consegue se sobrepor aos métodos EBWS, CBWS e MEBWS.

Apesar do propósito do algoritmo EBWS ser o de maximizar a energia nos coeficientes de aproximação [30], isto nem sempre ocorrerá, como evidenciado nas Tabelas 6.13 e 6.14, onde nem sempre os resultados nos coeficientes de aproximação final são os maiores. Isso pode ser explicado observando que o método seleciona a wavelet que prove os coeficientes com maior energia de aproximação E_c em um dado nível, mas tal função pode não ser a única que produz um sinal de aproximação com maior percentagem de energia no próximo nível de decomposição. Para demonstrarmos tal efeito o método EBWS foi aplicado ao sinal S_{50} , o qual resultou na seleção das wavelets mostradas na Tabela 6.15. Em seguida impomos a escolha da wavelet *sym4* no nível $j = 2$, que resultou na alteração das wavelets escolhidas nos níveis seguintes e ocasionou o aumento do percentual de energia concentrada nos coeficientes de aproximação final.

O método EBWS também é comprometido por tender a selecionar wavelet de baixa ordem N , como evidenciado nas Tabelas 6.7 a 6.12, onde vemos nos níveis de decomposição inicial a predominância de wavelets *db2* (mostrada em destaque), pois wavelets de ordem baixa normalmente produzem maiores energias nos coeficientes de aproximação. Como vimos no Capítulo 3, a ordem das famílias analisadas está relacionada à regularidade da wavelet. Recorrendo à Seção 3.4.9 observamos que quanto maior a regularidade, mais suave é a forma de onda da wavelet, o que normalmente é desejável para a eliminação de ruídos dos pulsos de DP que frequentemente possuem uma forma de onda suave. Portanto, podemos dizer que wavelets de ordem muito baixa comprometem a eficácia da filtragem. Este é o principal motivo por não termos aplicado a wavelet *Haar* (*db1*) na análise.

Tabela 6.13: Percentagem de energia dos coeficientes de aproximação e detalhe para cada método.

Sinal	Método	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	d_{11}	d_{12}	d_{13}	a_{13}	
S_{38}	CBWS	0.00	0.31	0.90	1.27	4.78	10.83	4.52	0.73	0.29	0.31	0.57	1.05	2.17	72.28	
	EBWS	0.00	1.24	3.58	1.81	17.51	23.43	33.88	5.90	0.77	0.00	0.00	0.00	0.00	11.88	
	SNRBWS	0.00	0.64	5.39	1.84	16.07	36.87	34.05	0.16	0.00	0.19	1.39	0.00	0.00	3.42	
	MEBWS	0.00	0.72	4.01	1.92	20.68	20.73	40.27	7.25	1.04	0.26	0.00	0.00	0.00	3.12	
		d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	a_8						
	AG	0.00	0.02	3.82	0.19	3.59	37.65	52.40	0.00	2.32						
S_{57}		d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	d_{11}	d_{12}	d_{13}	a_{13}	
	CBWS	15.18	9.60	5.79	17.14	27.14	1.27	0.00	0.00	0.02	0.06	0.08	0.08	0.26	23.39	
	EBWS	19.86	12.61	9.67	17.34	36.70	1.12	0.72	0.04	0.00	0.00	0.13	0.00	0.05	1.77	
	SNRBWS	18.86	12.67	6.82	21.50	36.75	0.42	0.00	0.00	0.00	0.00	0.00	0.00	0.00	2.68	
	MEBWS	17.52	14.19	7.49	18.82	37.77	1.55	0.93	0.03	0.07	0.17	0.00	0.00	0.00	1.46	
		d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	a_9					
AG	13.17	12.47	6.42	36.48	30.21	1.14	0.01	0.00	0.00	0.08						
S_{77}		d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	d_{11}	d_{12}	a_{12}		
	CBWS	0.00	0.00	0.00	0.16	0.35	2.35	1.89	0.23	0.00	0.20	0.73	0.00	94.09		
	EBWS	1.22	0.00	0.00	0.00	2.92	11.00	27.34	3.78	0.00	4.21	0.00	0.00	49.53		
	SNRBWS	0.00	0.00	0.00	0.00	5.74	13.15	66.28	0.00	0.00	0.00	0.90	0.00	13.93		
	MEBWS	0.00	0.00	0.00	0.00	6.95	11.39	42.48	9.23	0.00	0.00	0.00	0.00	29.95		
		d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	a_9					
AG	0.00	0.01	0.07	0.64	18.57	45.12	20.06	9.49	5.63	0.42						
S_{79}		d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	d_{11}	d_{12}	d_{13}	a_{13}	
	CBWS	0.00	0.00	0.00	0.00	0.00	0.08	8.02	0.72	0.05	0.02	0.11	0.20	0.51	90.28	
	EBWS	0.00	0.35	0.00	0.00	0.00	0.46	59.21	22.79	0.00	1.78	0.87	3.16	5.41	5.97	
	SNRBWS	0.00	0.00	0.00	0.00	0.00	0.00	63.80	0.80	0.00	0.33	1.39	0.87	2.97	29.84	
	MEBWS	0.00	0.00	0.00	0.00	0.36	0.21	43.64	19.99	0.00	1.04	0.15	0.00	0.64	33.96	
		d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	a_{10}				
AG	0.00	0.00	0.00	0.00	0.00	0.76	57.04	12.78	0.00	0.00	29.42					

Tabela 6.14: Percentagem de energia dos coeficientes de aproximação e detalhe para cada método.

Sinal	Método	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	d_{11}	d_{12}	d_{13}	a_{13}	
S_{111}	CBWS	0.00	0.00	0.00	0.00	0.00	0.00	8.92	0.00	0.00	0.00	0.00	0.23	0.50	90.35	
	EBWS	0.00	0.00	0.00	0.00	0.00	0.00	86.50	7.61	3.10	0.00	0.00	0.00	0.00	2.79	
	SNRBWS	0.00	0.00	0.00	0.00	0.00	0.00	98.05	0.00	0.00	0.00	0.00	0.00	0.00	1.95	
	MEBWS	0.00	0.00	0.00	0.00	0.00	0.00	81.98	5.75	2.91	0.00	0.00	0.00	0.00	9.36	
		d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	d_{11}	a_{11}			
	AG	0.00	0.00	0.00	0.00	0.00	0.00	44.90	0.00	0.00	0.00	0.00	55.10			
S_{126}		d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	d_{11}	a_{11}			
	CBWS	0.00	0.00	0.00	0.00	0.15	0.37	0.52	0.51	0.57	0.16	1.33	96.40			
	EBWS	0.00	0.00	0.00	0.00	0.07	0.40	0.73	0.34	2.12	2.63	22.44	71.26			
	SNRBWS	0.00	0.00	0.00	0.00	0.87	1.56	3.70	15.50	3.45	21.70	38.80	14.42			
	MEBWS	0.00	0.00	0.00	0.00	0.06	0.45	0.79	1.09	8.26	9.38	34.90	45.07			
		d_1	d_2	d_3	d_4	d_5	d_6	a_6								
AG	0.00	0.00	0.00	0.00	2.21	14.43	83.36									
S_{128}		d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	d_{11}	a_{11}			
	CBWS	0.00	0.00	0.00	0.00	0.00	0.68	1.08	1.22	0.92	1.07	0.47	94.57			
	EBWS	0.00	0.00	0.00	0.00	0.00	0.00	0.56	0.21	2.32	4.75	17.94	74.23			
	SNRBWS	0.00	0.00	0.00	0.00	0.00	0.00	3.64	16.50	0.00	23.07	39.54	17.25			
	MEBWS	0.00	0.00	0.00	0.00	0.00	0.00	0.00	2.02	21.36	36.44	18.90	21.28			
		d_1	d_2	d_3	d_4	a_4										
AG	0.00	0.00	0.00	0.00	100.00											
S_{160}		d_1	d_2	d_3	d_4	d_5	d_6	a_6								
	CBWS	0.00	0.00	0.00	0.00	68.18	9.12	22.69								
	EBWS	0.00	0.00	0.00	0.00	24.58	65.55	9.88								
	SNRBWS	0.00	0.00	0.00	0.00	22.07	76.39	1.54								
	MEBWS	0.00	0.00	0.00	0.00	10.84	84.36	4.80								
		d_1	d_2	d_3	d_4	d_5	d_6	a_6								
AG	0.01	0.00	0.00	2.47	64.46	29.28	3.78									

Tabela 6.15: Comparação do EBWS e EBWS alterado.

Sinal			Nível de decomposição						
			1	2	3	4	5	6	
S_{50}	Wavelet	EBWS	db2	db2	db9	db6	db18	db2	
		EBWS Alterado	db2	sym4	db8	sym13	db22	sym9	
			Coeficientes						
			d_1	d_2	d_3	d_4	d_5	d_6	a_6
	Energia (%)	EBWS	0	0	0	0	14.36	79.12	6.52
	EBWS Alterado	0	0	0	0	14.57	76.67	8.76	





Figura 6.9: Energia dos coeficientes de aproximação por nível para cada wavelet: (a) permitindo a seleção da função $db1$; (b) excluindo $db1$ da seleção.

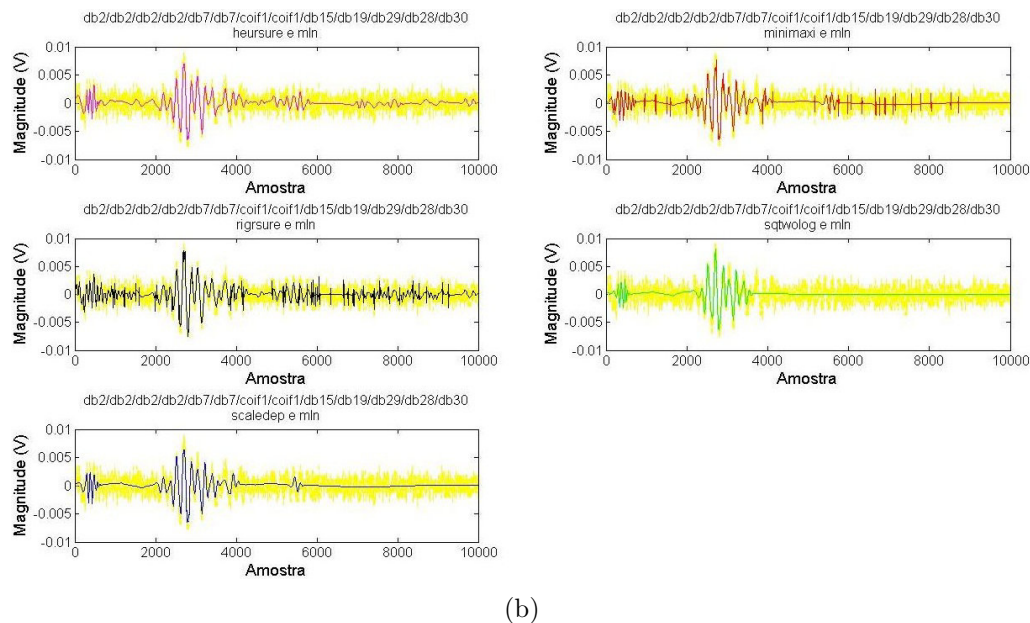
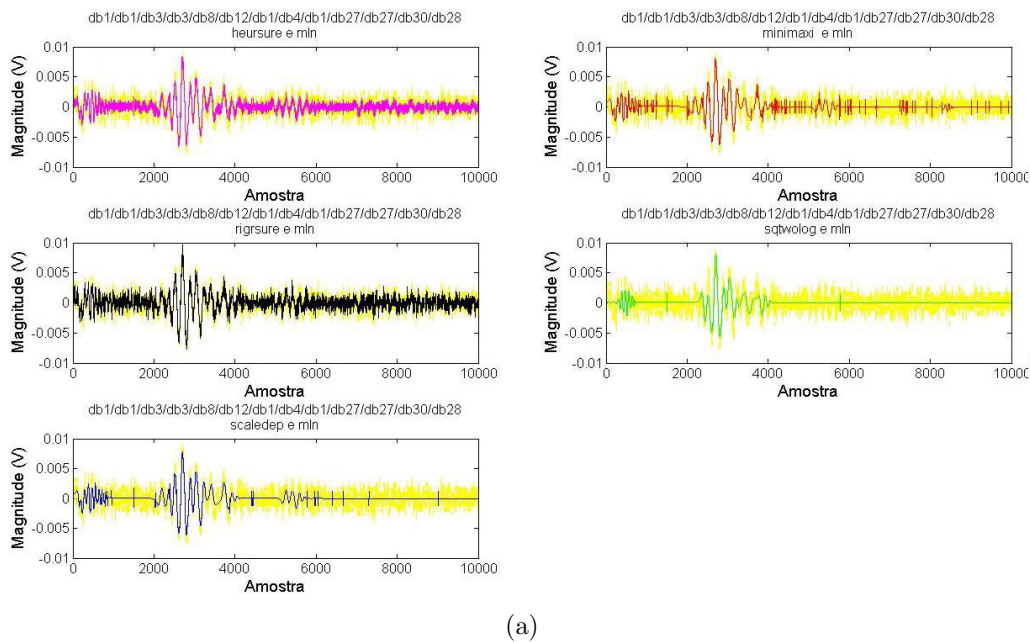


Figura 6.10: Resultados de filtragem do algoritmo EBWS: (a) permitindo a seleção da função *db1*; (b) excluindo *db1* da seleção.

Observe a Fig. 6.9 onde ilustramos o efeito da seleção da wavelet pelo algoritmo EBWS para o mesmo sinal de DP. Na Fig. 6.9 (a) permitimos a escolha da wavelet *db1* e no segundo só são consideradas as wavelets acima de *db2*. De imediato torna-se obvio a tendência pela seleção de wavelets de ordem mais baixa, principalmente nos estágios de decomposição iniciais. Na Fig. 6.10 mostramos os resultados de filtragem obtidos usando os diferentes tipos de regra de seleção em conjunto com

o fator de reescala mln e a função de limiarização abrupta, a Fig. 6.10(a) mostra os piores resultados para ambas as regras de seleção comparados aos da Fig. 6.10(b), onde não é permitida a seleção quando comparados aos da wavelet $db1$.

O método MEBWS também tende a concentrar a energia nos coeficientes de maior importância; no entanto, ao tentar maximizar a energia sofre do mesmo problema do EBWS em selecionar wavelets de baixa ordem, como mostrado nas Tabelas 6.7 a 6.12.

Nas Fig. 6.11 a 6.16, mostramos alguns dos sinais de DP resultantes para os 5 métodos, acompanhados da distribuição de potência dos sinais sobre as diferentes bandas geradas pela decomposição wavelet (delimitadas pela linha vertical); o espectro de potência do sinal de DP obtido com a filtragem por meio de cada método de busca pode ser comparado com o espectro de potência do sinal ideal. Podemos verificar que o espectro do sinal gerado pelo método SNRBWS na maioria dos casos (S_{38} , $S_{63} + ng_{SNR=4}$, $S_{71} + ng_{SNR=4}$ e $S_{26, SNR=4}$), é mais próximo do sinal ideal, se comparado aos obtidos pelo CBWS, EBWS e MEBWS, sendo superando apenas pelo algoritmo Genético, como era de se esperar, já que este explora todos os parâmetros envolvidos na filtragem, mostrando-se superior a todos os demais métodos.

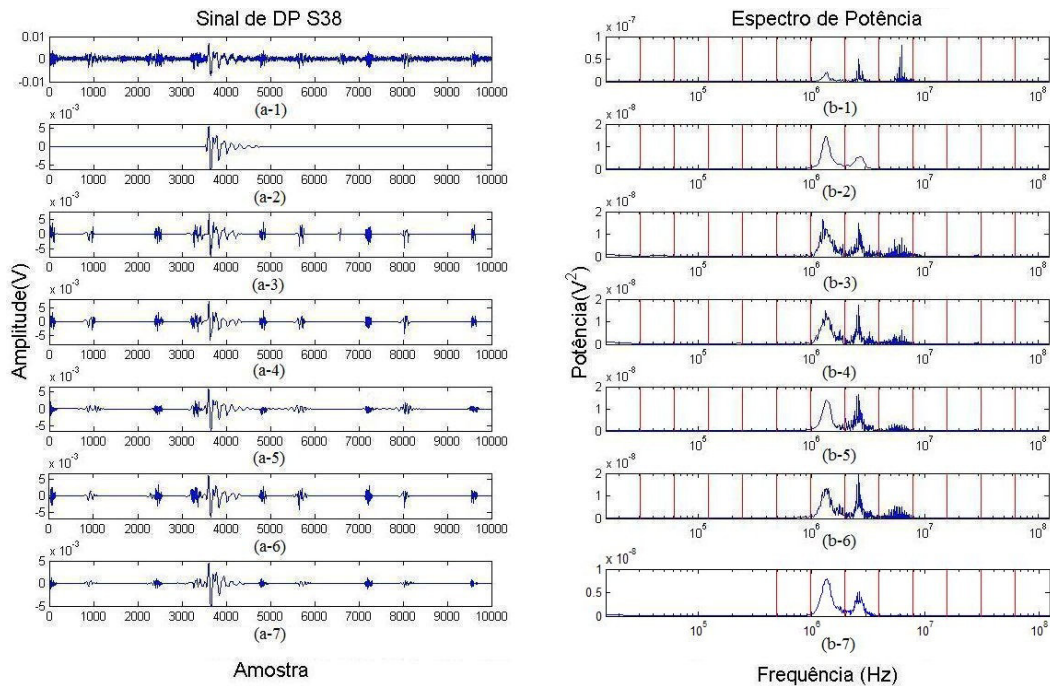


Figura 6.11: Resultado de redução de ruídos para S_{38} : formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.

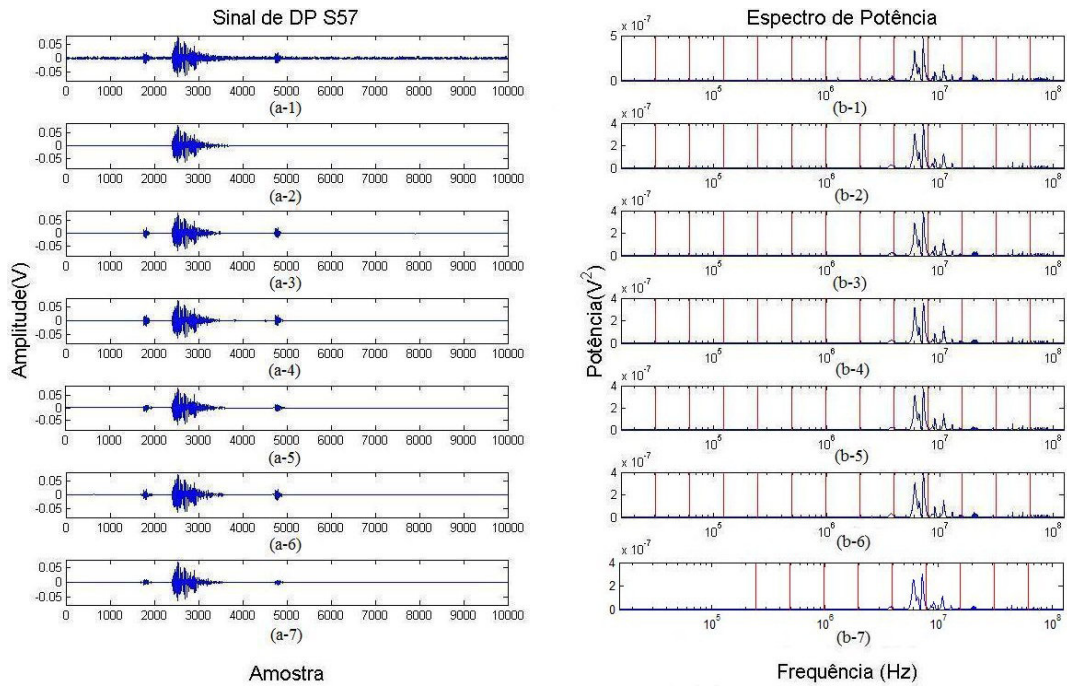


Figura 6.12: Resultado de redução de ruídos para S_{57} : formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.

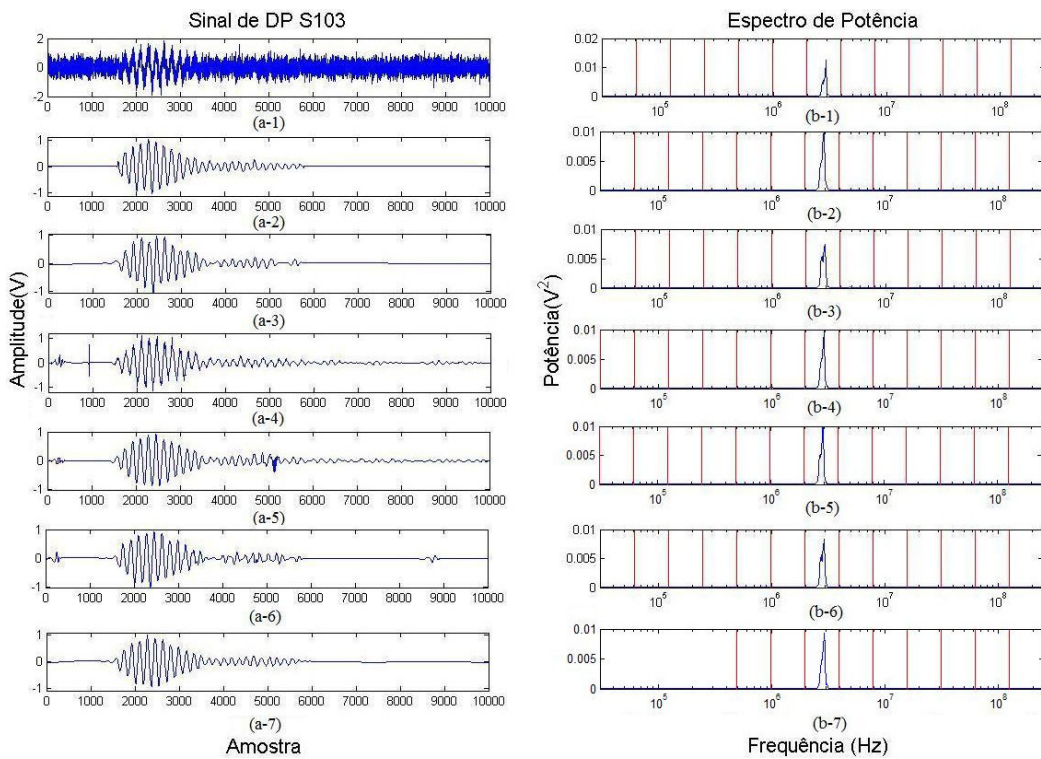


Figura 6.13: Resultado de redução de ruídos para $S_{63} + ng_{SNR=1}$: formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.




Figura 6.14: Resultado de redução de ruídos para $S_{71} + ng_{SNR=4}$: formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.

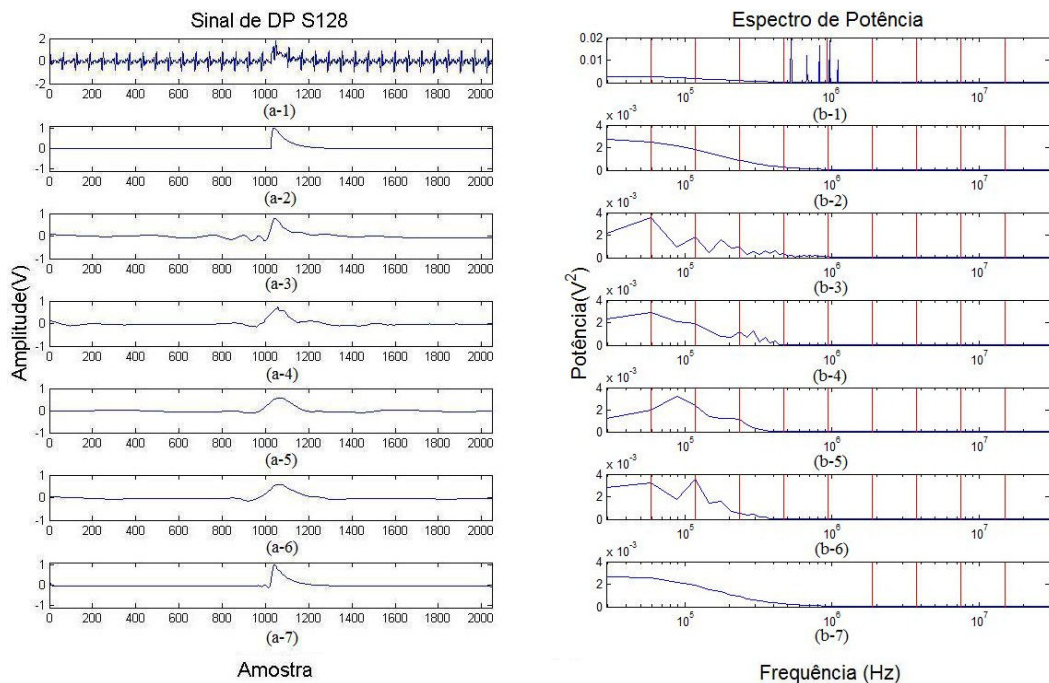


Figura 6.15: Resultado de redução de ruídos para $S_3, SNR=4$: formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.

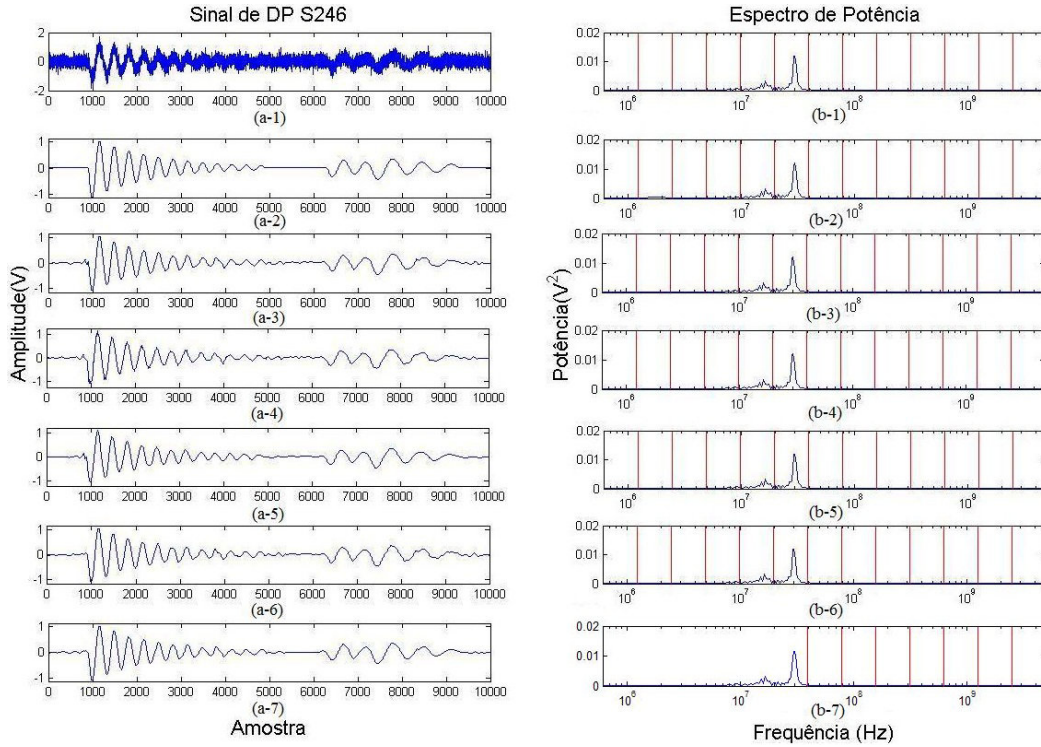


Figura 6.16: Resultado de redução de ruídos para $S_{26, SNR=4}$: formas de onda do (a-1) sinal com ruído, (a-2) sinal ideal, (a-3) CBWS, (a-4) EBWS, (a-5) SNRBWS, (a-6) MEBWS, (a-7) AG; espectro de potência (b-1) sinal com ruído, (b-2) sinal ideal, (b-3) CBWS, (b-4) EBWS, (b-5) SNRBWS, (b-6) MEBWS, (b-7) AG.

6.6 Resultados e Discussões

Para todos os sinais analisados aplicamos a função de limiarização abrupta em conjunto com todos os métodos de cálculo do valor de limiar (*heursure*, *minimaxi*, *rigrsure*, *sqtwolog* e *scaledep*) e todos os fatores de reescala (*one*, *sln* e *mln*), os quais foram citados e discutidos no Capítulo 3. Todos estes parâmetros de filtragem foram aplicados aos algoritmos de seleção da wavelet CBWS, EBWS, SNRBWS, MEBWS e AG. Para execução do método AG assumimos uma população com tamanho $\mu = 80$ indivíduos, evoluindo a mesma por somente 4 iterações, devido à grande quantidade de sinais de DP para ser processada. Os resultados de redução de ruídos obtidos para alguns dos sinais de DP simulados e medidos são mostrados nas Tabelas 6.16 a 6.20, onde são apresentados apenas os resultados dos parâmetros de filtragem que forneceram os melhores resultados, os quais foram determinados através da função de aptidão f_{Apt} . Também são apresentados os valores obtidos para alguns dos outros critérios de avaliação descritos na Seção 5.1. Os melhores valores obtidos estão destacados em negrito.

Nestas tabelas podemos ver que o método proposto SNRBWS proporciona os

melhores resultados que os métodos EBWS e CBWS (normalmente utilizados na literatura), além de ser superior ao método MEBWS. Entretanto, o método de busca AG é superior a todos os demais. Procuramos mostrar que os demais métodos também são capazes de fornecer os melhores resultados, mas ainda assim, apesar de não mostrarmos todos os sinais de DP analisados (260), o comportamento visto nas tabelas se mantém, dando melhores resultados para o AG seguido pelo SNRBWS.




Figura 6.17: Resultado de redução de ruídos para $S_{48, SNR=4}$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.




Figura 6.18: Resultado de redução de ruídos para $S_{49, SNR=4}$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.




Figura 6.19: Resultado de redução de ruídos para $S_{52}, SNR=4$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.




Figura 6.20: Resultado de redução de ruídos para $S_{59}, SNR=4$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.




Figura 6.21: Resultado de redução de ruídos para $S_{71}, SNR=4$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.




Figura 6.22: Resultado de redução de ruídos para $S_3, SNR=0,5$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.




Figura 6.23: Resultado de redução de ruídos para $S_7, SNR=0,5$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.




Figura 6.24: Resultado de redução de ruídos para $S_9, SNR=0,5$: formas de onda do (a) sinal com ruído, (b) sinal ideal, (c) CBWS, (d) EBWS, (e) SNRBWS, (f) MEBWS, (g) AG.

As Fig. 6.17 a 6.24 evidenciam que os resultados visualmente superiores quanto à redução de ruídos correspondem aos melhores parâmetros mostrados nas Tabelas 6.16 a 6.20. Entretanto, nem sempre os melhores resultados dos parâmetros de avaliação estão concentrados no mesmo método; frequentemente pode ocorrer que em situações onde temos bons parâmetros globais, haja uma piora nos parâmetros

locais. Tome como exemplo o sinal S_{38} , em que o AG fornece o melhor resultado; no entanto dois de seus parâmetros (EA_{max} e EA_{min}) são piores do que os obtidos com o SNRBWS. Por isso é que para indicar se uma filtragem é adequada, devemos verificar vários critérios de avaliação, não podendo nos basear somente em alguns poucos critérios, como foi feito em alguns trabalhos analisados [26, 30, 71, 83].

A seguir são mostrados os resultados da comparação da filtragem utilizando os diversos métodos de decomposição.

Tabela 6.16: Resultados de filtragem.

Sinal	J	Limiarização	Método	EMA	EQM	CC	DEn	$DSNR$	EA_{max}	EA_{min}	ΔT_{pmax}	ΔT_{pmin}	ΔT_s	Dk	f_{Apt}
S_{38}	13	<i>sqtwolog/mln/hard</i>	CBWS	2.18E-04	2.76E-07	0.7309	0.5853	1.34	33.92	30.74	0.2187	0.1939	0.22	29.67	-0.91
		<i>sqtwolog/mln/hard</i>	EBWS	2.27E-04	2.51E-07	0.7429	0.4913	1.49	5.90	35.56	0.4374	0.0277	0.44	31.64	0.48
		<i>sqtwolog/mln/hard</i>	SNRBWS	2.06E-04	1.94E-07	0.8001	0.4520	2.49	5.41	9.95	0.0273	0.2215	0.03	28.48	18.96
		<i>sqtwolog/mln/hard</i>	MEBWS	2.15E-04	2.44E-07	0.7609	0.5569	1.80	2.12	14.93	0.1367	0.1939	0.14	31.34	3.06
	8	<i>scaledep/soft</i>	AG	1.29E-04	6.70E-08	0.9100	0.3352	3.72	9.47	19.92	0.0000	0.1385	0.00	0.68	26.13
S_{42}	10	<i>sqtwolog/mln/hard</i>	CBWS	1.32E-03	2.07E-06	0.9915	0.0337	1.74	0.52	2.33	0.0000	0.0000	0.00	3.63	6.42
		<i>scaledep/hard</i>	EBWS	1.32E-03	2.18E-06	0.9897	0.0314	1.52	1.57	1.21	0.0000	0.0000	0.00	1.60	9.20
		<i>sqtwolog/mln/hard</i>	SNRBWS	1.33E-03	2.21E-06	0.9901	0.0337	1.46	1.46	2.07	0.0000	0.0000	0.00	0.35	11.00
		<i>scaledep/hard</i>	MEBWS	1.39E-03	2.51E-06	0.9872	0.0279	0.89	1.18	1.38	0.0000	0.0000	0.00	2.32	7.40
	8	<i>scaledep/hard</i>	AG	4.15E-04	5.86E-07	0.9914	0.0015	4.76	0.59	1.20	0.0000	0.0000	0.00	0.25	15.98
S_{51}	6	<i>scaledep/hard</i>	CBWS	6.24E-04	1.23E-06	0.9707	0.0004	6.72	1.34	1.81	0.0879	2.0987	0.89	0.09	18.73
		<i>scaledep/hard</i>	EBWS	5.17E-04	8.45E-07	0.9800	0.0049	8.39	0.81	2.91	0.0000	0.0296	0.10	0.09	21.71
		<i>scaledep/hard</i>	SNRBWS	5.04E-04	7.13E-07	0.9832	0.0124	9.15	1.58	1.25	0.0000	0.0296	0.98	0.79	22.15
		<i>scaledep/hard</i>	MEBWS	5.64E-04	9.37E-07	0.9779	0.0119	7.97	4.37	0.99	0.0293	0.0296	0.98	0.85	19.71
	11	<i>scaledep/hard</i>	AG	4.88E-04	9.24E-07	0.9781	0.0066	8.01	2.12	0.02	0.0879	0.0591	0.59	0.17	20.90
S_{59}	13	<i>sqtwolog/mln/hard</i>	CBWS	6.29E-04	2.70E-06	0.8695	0.2758	2.11	1.98	1.23	0.0401	0.0000	0.04	30.95	-31.98
		<i>sqtwolog/mln/hard</i>	EBWS	4.24E-04	2.56E-06	0.8741	0.2508	2.27	2.13	11.73	0.0000	0.0000	0.00	32.88	-34.68
		<i>sqtwolog/mln/hard</i>	SNRBWS	4.23E-04	2.48E-06	0.8793	0.2613	2.44	3.75	2.49	0.0000	0.0000	0.00	30.28	-30.29
		<i>scaledep/hard</i>	MEBWS	4.70E-04	2.62E-06	0.8736	0.2796	2.25	0.33	3.17	0.0000	0.0000	0.00	33.77	-35.93
	4	<i>sqtwolog/one/soft</i>	AG	5.85E-04	7.76E-07	0.9559	0.0287	6.60	7.44	17.63	0.0802	0.0397	0.08	8.75	15.42
S_{62}	9	<i>scaledep/hard</i>	CBWS	1.37E-03	5.48E-06	0.9761	0.0142	0.91	3.18	2.43	0.0776	0.0402	1.01	0.38	15.74
		<i>scaledep/hard</i>	EBWS	1.24E-03	5.09E-06	0.9777	0.0215	1.20	1.52	1.84	0.0776	0.1609	3.03	1.37	15.00
		<i>sqtwolog/mln/hard</i>	SNRBWS	9.95E-04	2.91E-06	0.9874	0.0010	3.73	1.80	1.02	0.0776	0.0805	1.52	1.19	22.59
		<i>scaledep/hard</i>	MEBWS	1.26E-03	4.66E-06	0.9796	0.0255	1.56	2.18	0.02	0.0000	0.0402	1.01	0.66	17.08
	12	<i>sqtwolog/sln/soft</i>	AG	1.19E-03	3.05E-06	0.9868	0.0579	3.26	4.19	2.35	0.0388	0.0402	1.01	0.04	23.30

Tabela 6.17: Resultados de filtragem.

Sinal	J	Limiarização	Método	EMA	EQM	CC	DEn	$DSNR$	EA_{max}	EA_{min}	ΔT_{pmax}	ΔT_{pmin}	ΔT_s	Dk	f_{Apt}
S_{76}	8	<i>sqtwolog/mln/hard</i>	CBWS	1.26E-03	5.18E-06	0.9888	0.0095	2.22	0.84	2.48	0.0000	0.4972	0.00	1.07	12.36
		<i>sqtwolog/mln/hard</i>	EBWS	1.31E-03	4.97E-06	0.9892	0.0098	2.41	0.46	0.20	0.0000	0.4972	0.00	0.67	13.29
		<i>sqtwolog/mln/hard</i>	SNRBWS	1.34E-03	4.92E-06	0.9894	0.0135	2.47	3.12	2.71	0.0000	0.4972	0.92	0.08	14.14
		<i>sqtwolog/mln/hard</i>	MEBWS	1.20E-03	4.39E-06	0.9905	0.0125	2.96	0.01	0.04	0.0000	0.4972	0.00	0.96	13.69
	12	<i>rigrsure/mln/soft</i>	AG	1.13E-03	3.83E-06	0.9917	0.0341	3.35	2.09	2.86	0.0000	0.4972	0.92	0.21	15.43
S_{79}	13	<i>scaledep/hard</i>	CBWS	7.98E-03	1.28E-04	0.9686	0.0495	10.60	12.26	5.73	0.1588	6.3921	1.21	0.22	19.52
		<i>heursure/sln/hard</i>	EBWS	7.50E-03	1.51E-04	0.9617	0.0056	9.70	10.97	32.46	0.3177	6.5151	0.32	1.63	15.93
		<i>sqtwolog/sln/hard</i>	SNRBWS	7.04E-03	8.63E-05	0.9788	0.0498	12.31	5.10	2.34	0.2541	0.1844	0.25	0.14	21.84
		<i>heursure/mln/hard</i>	MEBWS	6.47E-03	8.96E-05	0.9775	0.0263	12.05	1.50	5.68	6.7344	6.4536	6.74	0.61	20.47
	10	<i>scaledep/hard</i>	AG	5.52E-03	6.01E-05	0.9855	0.0584	13.91	3.15	5.60	0.2859	0.1844	0.29	0.11	23.58
S_{88}	13	<i>scaledep/hard</i>	CBWS	3.46E-04	3.78E-07	0.9290	0.0004	7.86	18.37	27.63	0.4422	0.1557	25.00	3.56	10.41
		<i>scaledep/hard</i>	EBWS	3.77E-04	4.39E-07	0.9180	0.0246	7.32	11.58	17.86	0.8292	0.2595	1995.24	5.30	3.96
		<i>scaledep/hard</i>	SNRBWS	2.67E-04	1.75E-07	0.9683	0.0289	11.34	6.26	12.51	0.0553	0.3114	2.38	0.93	19.24
		<i>sqtwolog/sln/hard</i>	MEBWS	3.88E-04	3.19E-07	0.9464	0.0341	8.75	9.12	9.25	0.4975	0.2595	2029.76	0.35	13.28
	11	<i>scaledep/hard</i>	AG	3.46E-04	3.11E-07	0.9436	0.0468	8.91	1.47	10.22	0.5528	0.3633	8.33	0.65	16.97
S_{89}	13	<i>scaledep/hard</i>	CBWS	1.01E-03	2.96E-06	0.8568	0.1763	5.09	22.64	4.95	0.0000	1.9744	21.21	1.69	13.42
		<i>minimaxi/mln/hard</i>	EBWS	1.01E-03	3.38E-06	0.8112	0.0187	3.88	52.96	55.65	0.0000	0.0581	18.86	18.59	-15.49
		<i>sqtwolog/sln/hard</i>	SNRBWS	1.07E-03	3.37E-06	0.8381	0.2398	4.75	0.99	24.78	2.0235	0.0290	30.98	1.60	12.50
		<i>sqtwolog/sln/hard</i>	MEBWS	1.10E-03	3.07E-06	0.8451	0.1698	4.90	8.82	20.09	0.0000	0.0290	7.07	3.30	10.92
	6	<i>heursure/mln/hard</i>	AG	1.75E-03	5.97E-06	0.7124	0.2927	2.44	31.15	21.26	0.0587	1.9744	6.06	1.33	8.02
S_{92}	13	<i>scaledep/hard</i>	CBWS	8.71E-04	2.09E-06	0.7312	0.0602	2.40	43.33	39.98	0.0537	91.6915	47.71	19.32	-23.24
		<i>rigrsure/mln/hard</i>	EBWS	7.02E-04	1.81E-06	0.7624	0.1441	2.61	128.07	7.23	0.0537	1.8133	48.37	71.39	-100.05
		<i>heursure/mln/hard</i>	SNRBWS	7.21E-04	1.83E-06	0.7610	0.1894	2.34	15.67	28.31	0.0269	1.7050	45.75	13.68	-11.94
		<i>heursure/mln/hard</i>	MEBWS	6.90E-04	1.83E-06	0.7576	0.1439	2.57	3.72	1.22	44.3609	1.8403	3413.07	5.84	-3.11
	13	<i>sqtwolog/sln/hard</i>	AG	8.99E-04	2.55E-06	0.6666	0.0945	1.38	3.83	19.40	1.7991	1.6779	29.41	0.72	6.24

Tabela 6.18: Resultados de filtragem.

Sinal	J	Limiarização	Método	EMA	EQM	CC	DEn	$DSNR$	EA_{max}	EA_{min}	ΔT_{pmax}	ΔT_{pmin}	ΔT_s	Dk	f_{Apt}
S_{95}	13	<i>heursure/mln/hard</i>	CBWS	6.67E-04	1.54E-06	0.6859	0.4004	0.10	14.81	24.54	7.2012	0.1558	50.10	8.47	-7.65
		<i>heursure/mln/hard</i>	EBWS	5.29E-04	1.37E-06	0.7166	0.3729	0.82	24.03	28.51	7.2754	7.2430	45.63	16.16	-18.33
		<i>sqtwolog/mln/hard</i>	SNRBWS	7.15E-04	1.42E-06	0.7148	0.2300	1.53	8.05	4.85	7.2012	4.6340	55.73	4.93	-0.13
		<i>heursure/mln/hard</i>	MEBWS	5.21E-04	1.33E-06	0.7243	0.3604	1.02	9.79	16.01	7.2383	4.5950	45.63	12.00	-11.18
	12	<i>scaledep/hard</i>	AG	4.88E-04	8.57E-07	0.8480	0.0009	4.87	2.42	25.03	0.2970	21.5343	3.88	2.90	8.26
S_{103}	13	<i>rigrsure/one/hard</i>	CBWS	4.59E-02	4.12E-03	0.9560	0.0846	8.74	6.79	7.59	0.2111	7.2242	0.21	0.33	17.59
		<i>heursure/mln/hard</i>	EBWS	4.19E-02	6.30E-03	0.9289	0.1658	6.49	1.87	1.06	6.7117	7.9685	6.71	1.48	13.23
		<i>heursure/mln/hard</i>	SNRBWS	3.72E-02	4.05E-03	0.9550	0.1308	8.58	6.86	0.47	0.0422	7.4869	0.04	1.27	16.17
		<i>rigrsure/one/hard</i>	MEBWS	5.86E-02	1.04E-02	0.8802	0.2368	3.92	2.31	5.22	7.1760	0.0438	7.18	1.78	9.70
	9	<i>rigrsure/one/hard</i>	AG	2.83E-02	1.81E-03	0.9802	0.0680	12.40	7.14	0.54	0.2955	0.1751	0.30	0.32	22.10
S_{111}	13	<i>sqtwolog/sln/hard</i>	CBWS	1.72E-04	7.08E-08	0.9453	0.0008	8.71	6.83	10.40	0.1221	0.1962	31.48	0.38	17.05
		<i>sqtwolog/sln/hard</i>	EBWS	1.28E-04	5.77E-08	0.9540	0.0455	9.39	2.56	10.89	7.4858	0.1177	24.58	0.46	17.87
		<i>sqtwolog/sln/hard</i>	SNRBWS	1.31E-04	3.51E-08	0.9726	0.0128	11.70	0.19	9.00	0.0814	7.2577	0.51	0.31	21.52
		<i>sqtwolog/sln/hard</i>	MEBWS	1.41E-04	5.03E-08	0.9612	0.0191	10.11	4.56	0.20	0.0000	0.0000	5.89	0.32	19.64
	11	<i>sqtwolog/mln/hard</i>	AG	9.11E-05	2.06E-08	0.9838	0.0394	13.90	2.29	5.01	0.0814	0.0392	0.34	0.04	25.05
S_{118}	11	<i>scaledep/hard</i>	CBWS	4.93E-02	3.92E-03	0.9430	0.0986	6.21	3.76	0.00	0.3846	0.0000	3185.71	4.21	7.44
		<i>heursure/sln/hard</i>	EBWS	4.64E-02	3.22E-03	0.9604	0.0332	7.36	21.92	0.00	0.1923	0.0000	7.14	1.97	16.18
		<i>heursure/sln/hard</i>	SNRBWS	4.49E-02	2.97E-03	0.9603	0.0884	7.46	11.93	0.00	1.2500	0.0000	150.00	4.45	10.19
		<i>heursure/sln/hard</i>	MEBWS	4.70E-02	3.37E-03	0.9545	0.0757	6.97	8.54	0.00	0.8654	0.0000	171.43	5.39	7.46
	10	<i>sqtwolog/sln/hard</i>	AG	4.39E-02	3.51E-03	0.9471	0.1496	6.44	7.76	0.00	0.1923	0.0000	28.57	5.52	9.44
S_{126}	11	<i>rigrsure/sln/hard</i>	CBWS	4.47E-02	3.67E-03	0.9477	0.1316	6.15	3.66	0.00	0.3846	0.0000	35.71	1.22	15.38
		<i>heursure/sln/hard</i>	EBWS	4.25E-02	2.87E-03	0.9650	0.0824	7.45	16.73	0.00	0.1923	0.0000	0.00	0.39	19.33
		<i>heursure/sln/hard</i>	SNRBWS	4.13E-02	2.72E-03	0.9685	0.0746	7.73	3.79	0.00	0.0962	0.0000	7.14	0.16	20.32
		<i>heursure/sln/hard</i>	MEBWS	3.94E-02	2.46E-03	0.9742	0.0923	8.07	1.33	0.00	0.0962	0.0000	7.14	0.26	21.00
	6	<i>scaledep/hard</i>	AG	4.16E-02	2.80E-03	0.9664	0.0811	7.57	4.93	0.00	0.0962	0.0000	7.14	0.10	20.09

Tabela 6.19: Resultados de filtragem.

Sinal	J	Limiarização	Método	EMA	EQM	CC	DEn	$DSNR$	EA_{max}	EA_{min}	ΔT_{pmax}	ΔT_{pmin}	ΔT_s	Dk	f_{Apt}
S_{127}	11	<i>sqtwolog/mln/hard</i>	CBWS	1.26E-01	6.14E-02	0.0084	0.7247	-2.27	71.21	0.00	83.4615	0.0000	1285.71	14.48	-31.08
		<i>heursure/one/hard</i>	EBWS	8.72E-02	4.30E-02	0.1307	0.2083	-2.27	76.77	0.00	12.5000	0.0000	7.14	69.42	-106.87
		<i>heursure/one/hard</i>	SNRBWS	6.35E-02	1.29E-02	0.6775	0.5617	-1.44	69.28	0.00	2.0192	0.0000	5521.43	21.93	-32.51
	4	<i>heursure/one/hard</i>	MEBWS	7.27E-02	2.06E-02	0.2634	0.8654	-8.60	91.78	0.00	22.9808	0.0000	5614.29	24.58	-48.45
	4	<i>sqtwolog/mln/hard</i>	AG	4.10E-02	2.18E-03	0.9822	0.0476	9.65	2.09	0.00	0.0962	0.0000	7328.57	0.69	18.65
S_{136}	11	<i>sqtwolog/mln/hard</i>	CBWS	4.09E-02	2.41E-03	0.9767	0.0046	5.55	3.02	0.00	0.6731	0.0000	4357.14	2.20	11.78
		<i>sqtwolog/sln/hard</i>	EBWS	6.76E-02	1.63E-02	0.6435	0.3776	-4.79	18.72	0.00	0.9615	0.0000	3428.57	7.49	-14.19
		<i>sqtwolog/mln/hard</i>	SNRBWS	4.17E-02	3.08E-03	0.9554	0.0097	4.47	2.27	0.00	0.0962	0.0000	6871.43	3.22	8.15
		<i>sqtwolog/sln/hard</i>	MEBWS	6.91E-02	1.75E-02	0.5552	0.5056	-6.10	29.56	0.00	0.2885	0.0000	6842.86	11.92	-23.00
	7	<i>scaledep/hard</i>	AG	3.85E-02	1.72E-03	0.9925	0.0497	6.82	1.09	0.00	0.2885	0.0000	42.86	0.18	21.07
S_{145}	11	<i>rigrsure/one/hard</i>	CBWS	5.80E-02	5.96E-03	0.9016	0.1965	4.14	24.51	0.00	0.6731	0.0000	128.57	9.69	-3.23
		<i>heursure/sln/hard</i>	EBWS	5.32E-02	4.86E-03	0.9153	0.2392	4.79	2.68	0.00	0.1923	0.0000	157.14	4.84	5.23
		<i>heursure/sln/hard</i>	SNRBWS	4.79E-02	5.76E-03	0.8772	0.2372	4.07	37.12	0.00	2.4038	0.0000	1042.86	12.60	-9.29
		<i>heursure/sln/hard</i>	MEBWS	4.93E-02	5.62E-03	0.8997	0.2333	4.19	35.42	0.00	1.6346	0.0000	200.00	11.65	-7.60
	10	<i>sqtwolog/sln/hard</i>	AG	5.27E-02	4.14E-03	0.9443	0.2051	5.67	3.96	0.00	0.0962	0.0000	178.57	2.22	10.13
S_{147}	9	<i>heursure/one/hard</i>	CBWS	3.31E-02	5.48E-03	0.7926	0.0328	3.67	16.23	0.96	4.8356	0.3774	650.00	6.45	-0.70
		<i>sqtwolog/sln/hard</i>	EBWS	6.65E-02	1.03E-02	0.6982	0.5001	2.55	9.62	49.98	0.7737	0.1887	75.00	18.76	-20.37
		<i>heursure/sln/hard</i>	SNRBWS	4.36E-02	4.72E-03	0.8412	0.1727	4.87	1.15	16.63	0.2901	0.0943	62.50	3.58	8.36
		<i>rigrsure/one/hard</i>	MEBWS	3.69E-02	5.26E-03	0.7807	0.1887	2.80	46.75	20.49	5.9961	0.2830	2125.00	20.56	-23.81
	8	<i>sqtwolog/sln/hard</i>	AG	4.73E-02	5.72E-03	0.7835	0.0313	3.48	4.96	13.46	0.1934	0.0000	75.00	0.06	11.10
S_{157}	4	<i>sqtwolog/one/hard</i>	CBWS	7.01E-02	6.26E-02	0.4066	4.7674	0.63	96.64	109.57	42.8433	38.8679	18350.00	16.25	-29.27
		<i>sqtwolog/one/hard</i>	EBWS	7.77E-02	3.03E-02	0.4612	1.9022	0.80	78.43	180.59	13.1528	27.3585	14512.50	8.81	-17.47
		<i>sqtwolog/sln/hard</i>	SNRBWS	3.12E-02	1.74E-02	0.6440	1.2813	2.17	61.94	105.47	90.4255	80.4717	24500.00	8.70	-14.63
		<i>sqtwolog/one/hard</i>	MEBWS	4.36E-02	2.71E-02	0.5572	2.0229	1.46	81.64	129.15	84.6228	85.3774	23750.00	3.86	-10.01
	5	<i>scaledep/soft</i>	AG	8.01E-03	7.88E-04	0.9695	0.0274	11.90	11.80	1.09	0.0967	0.0943	12825.00	6.44	20.37

Tabela 6.20: Resultados de filtragem.

Sinal	J	Limiarização	Método	EMA	EQM	CC	DEn	$DSNR$	EA_{max}	EA_{min}	ΔT_{pmax}	ΔT_{pmin}	ΔT_s	Dk	f_{Apt}
S_{175}	11	<i>sqtwolog/mln/hard</i>	CBWS	2.64E-02	2.55E-03	0.9046	0.0409	6.79	3.95	5.58	0.0967	0.0000	12825.00	7.79	3.88
		<i>sqtwolog/sln/hard</i>	EBWS	2.38E-02	2.55E-03	0.9017	0.0097	6.58	43.45	34.40	0.0000	0.1887	12.50	18.62	-10.21
		<i>sqtwolog/mln/hard</i>	SNRBWS	4.61E-02	4.19E-03	0.8777	0.0492	4.24	10.30	2.48	0.2901	0.0943	62.50	0.21	13.14
		<i>heursure/mln/hard</i>	MEBWS	3.34E-02	3.03E-03	0.8894	0.1241	5.30	23.55	18.19	0.0967	0.2830	1337.50	12.40	-6.06
	10	<i>heursure/mln/soft</i>	AG	3.44E-02	4.50E-03	0.8271	0.5740	0.44	28.08	16.72	0.0967	0.4717	11375.00	0.04	5.96
S_{190}	13	<i>heursure/one/hard</i>	CBWS	3.63E-02	7.73E-03	0.3175	0.4149	-4.12	54.08	1.16	0.2708	217.0588	41.09	33.65	-57.33
		<i>heursure/one/hard</i>	EBWS	2.64E-02	7.38E-03	0.3408	0.4264	-4.01	45.99	11.42	67.2985	400.0000	99.15	29.63	-57.09
		<i>sqtwolog/mln/hard</i>	SNRBWS	4.21E-02	8.06E-03	0.2482	0.4980	-4.97	68.17	25.52	1.9579	217.3856	48.30	50.06	-84.44
		<i>heursure/one/hard</i>	MEBWS	3.42E-02	7.28E-03	0.4420	0.1370	-2.17	57.69	0.81	59.8417	217.5163	85.97	47.04	-76.32
	8	<i>sqtwolog/mln/hard</i>	AG	1.36E-02	1.83E-03	0.8588	0.2861	2.99	6.79	23.11	0.0000	0.1961	45.12	5.60	3.40
S_{196}	13	<i>sqtwolog/mln/hard</i>	CBWS	2.09E-02	5.29E-03	0.4960	0.7631	-6.43	54.15	0.78	0.2708	217.0588	99.39	66.82	-108.56
		<i>sqtwolog/mln/hard</i>	EBWS	1.97E-02	5.80E-03	0.4121	0.8404	-8.54	54.13	13.01	60.0083	400.0000	96.52	148.17	-238.62
		<i>heursure/one/hard</i>	SNRBWS	3.32E-02	6.20E-03	0.3643	0.7663	-7.17	68.31	25.49	1.9579	217.3856	48.30	17.41	-36.43
		<i>minimaxi/one/hard</i>	MEBWS	1.51E-02	4.53E-03	0.5941	0.6876	-4.55	59.13	2.91	59.8417	217.5163	12.91	12.66	-23.95
	9	<i>sqtwolog/mln/hard</i>	AG	2.08E-02	2.58E-03	0.7947	0.3294	1.22	17.42	7.64	0.1041	0.3268	45.61	4.44	2.31
S_{209}	13	<i>sqtwolog/mln/hard</i>	CBWS	2.45E-02	1.42E-03	0.9613	0.0354	9.11	28.25	26.88	0.0000	234.4516	0.06	2.72	11.07
		<i>minimaxi/sln/hard</i>	EBWS	1.97E-02	9.84E-04	0.9729	0.0056	10.58	35.78	22.19	0.0000	0.2581	0.06	0.88	21.04
		<i>rigrsure/sln/hard</i>	SNRBWS	2.40E-02	1.98E-03	0.9453	0.0053	7.55	0.57	17.37	0.2599	235.0968	16.03	6.33	3.73
		<i>heursure/sln/hard</i>	MEBWS	2.81E-02	2.08E-03	0.9424	0.0008	7.31	7.35	0.88	0.2400	0.0000	0.80	5.09	10.44
	12	<i>scaledep/hard</i>	AG	1.56E-02	8.17E-04	0.9773	0.0001	11.37	7.35	3.99	0.2000	0.2581	0.34	1.64	22.30
S_{285}	13	<i>scaledep/hard</i>	CBWS	8.27E-02	1.42E-02	0.9380	0.1095	1.83	2.64	4.50	0.4241	0.1411	0.42	1.24	9.23
		<i>rigrsure/mln/hard</i>	EBWS	8.65E-02	1.50E-02	0.9342	0.1084	1.60	0.08	4.95	0.2610	0.3448	0.26	1.24	9.02
		<i>sqtwolog/sln/hard</i>	SNRBWS	8.40E-02	1.45E-02	0.9365	0.1093	1.75	1.18	1.12	0.1631	0.0627	0.16	1.21	9.30
		<i>minimaxi/sln/hard</i>	MEBWS	8.39E-02	1.45E-02	0.9367	0.1129	1.76	1.69	4.27	0.0653	0.0470	0.07	1.23	9.21
	11	<i>minimaxi/sln/soft</i>	AG	8.22E-02	1.26E-02	0.9413	0.0043	1.94	3.92	5.24	0.1142	0.0470	0.11	1.00	9.71

6.6.1 Resultados Percentuais e Médios

Para compararmos os resultados, indicaremos, para alguns dos parâmetros de avaliação, o percentual de pulsos analisados em que cada método de decomposição forneceu o melhor resultado. Em seguida apresentaremos os valores médios dos resultados obtidos, comparando-os.

CBWS x EBWS

A Fig. 6.25 mostra a comparação entre os métodos de seleção da wavelet CBWS e EBWS tomando a função de aptidão como parâmetro de avaliação. Ao contrário do sugerido em [30], o CBWS obteve os melhores resultados em 61% dos casos em relação ao método EBWS. Provavelmente em [30] o método não foi investigado levando em conta uma quantidade significativa de sinais, o que pode ter fornecido a conclusão inadequada de que o EBWS é superior ao CBWS.

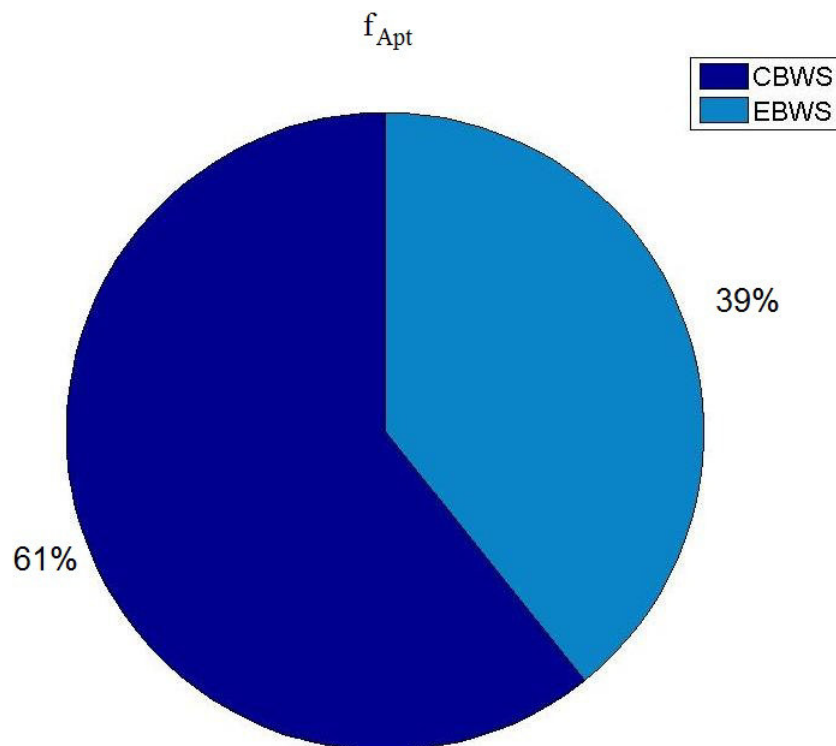


Figura 6.25: Comparação da função de aptidão para os pulsos de DP utilizando os métodos EBWS e CBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.

Também verificamos os resultados percentuais para outros parâmetros de avaliação, sendo os resultados obtidos mostrados na Fig. 6.26. Novamente o método CBWS obtém os melhores resultados para a grande maioria dos parâmetros, exceto para o EMA e o DEn, confirmando o resultado fornecido na Fig. 6.25.

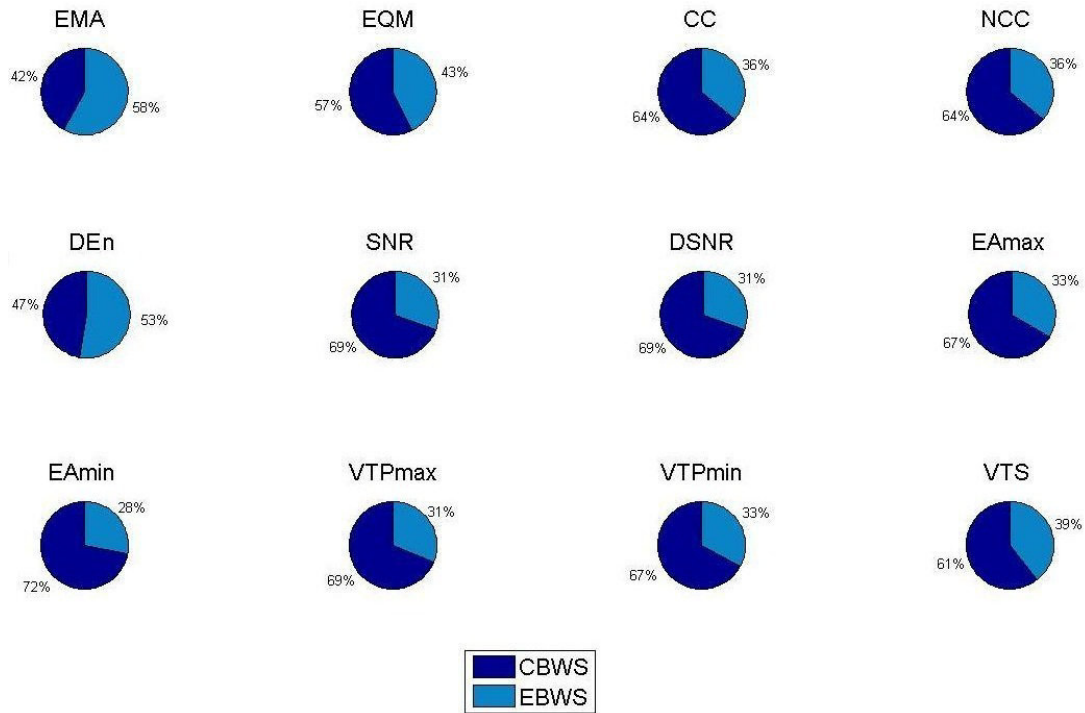


Figura 6.26: Comparação dos resultados das filtragens dos pulsos de DP utilizando os métodos EBWS e CBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.

SNRBWS x MEBWS

Para averiguar quais os métodos de seleção inspirados na maximização da informação do sinal nos coeficientes de maior importância se sai melhor investigamos a quantidade percentual de vezes em que o SNRBWS e o MEBWS fornecem uma melhor performance de filtragem. A Fig. 6.27 mostra a comparação entre estes métodos de seleção da wavelet em relação à função de aptidão. O método SNRBWS se mostra superior ao maximizar o coeficiente de maior importância usando a SNR como critério de seleção (o método MEBWS tenta maximizar os coeficientes com base na energia). A explicação para tal resultado se encontra no mesmo problema observado para o método EBWS na Seção 6.5.1, i.e., o critério de energia tende a dar maior importância a wavelets de ordem mais baixa. Podemos verificar nas Tabelas 6.7 a 6.12, que em muitos casos ocorre a seleção da wavelet *db2*, provocando os mesmos problemas observados no EBWS.

Os resultados percentuais obtidos para os parâmetros de avaliação são mostrados na Fig. 6.28. O algoritmo SNRBWS obtém os melhores resultados para todos os parâmetros verificados, confirmando o resultado da Fig. 6.27.




Figura 6.27: Comparação da função de aptidão para os pulsos de DP utilizando os métodos SNRBWS e MEBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.

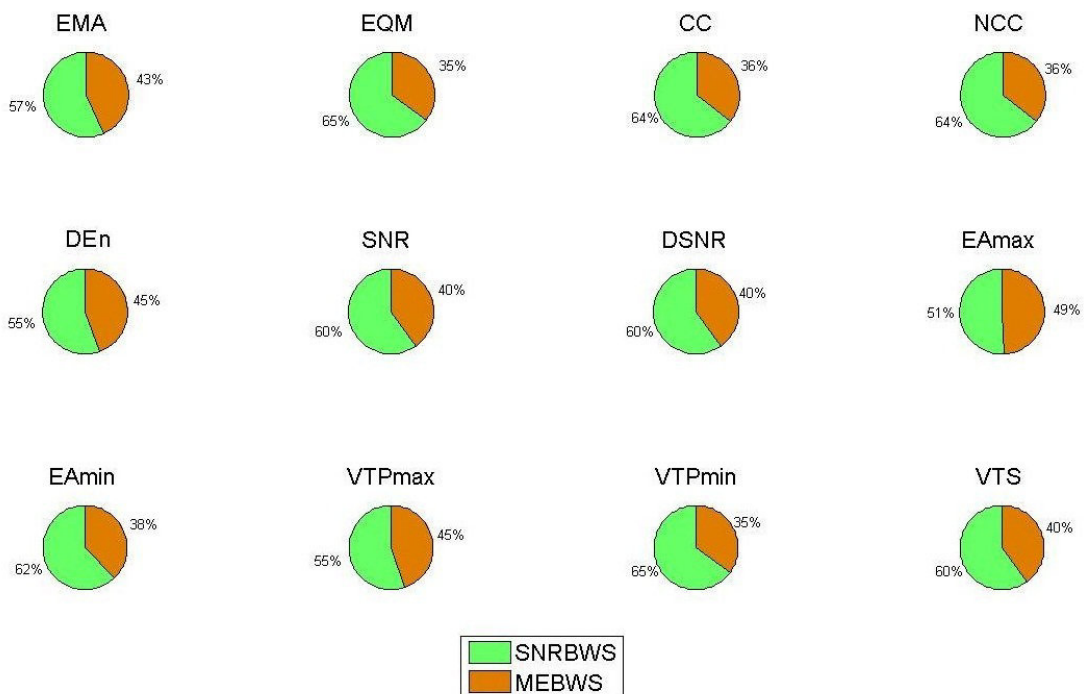


Figura 6.28: Comparação dos resultados das filtragens dos pulsos de DP utilizando os métodos SNRBWS e MEBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.

Comparação entre os Métodos de Seleção da Wavelet Mãe

Comparando a performance de todos os métodos baseados na seleção da wavelet mãe obtemos os resultados percentuais ilustrados na Fig. 6.29. Observe que o SNRBWS proposto se mostrou superior a todos os demais métodos em 42% dos casos; em segundo temos o método CBWS, seguido pelo método MEBWS e pelo EBWS.

Podemos dizer que o MEBWS, ao tentar concentrar a energia nos coeficientes de que detém a maior parte da informação do sinal, entretanto, é superado pelo método CBWS. Já o SNRBWS consegue claramente superar todos os demais, indicando que a ideia de se buscar pela wavelet mãe que concentra as componentes do sinal com mais alto SNR sobre os coeficientes de maior importância é mais adequada do que maximizar a energia dos coeficientes de aproximação, a energia nos coeficientes de maior relevância ou a correlação da wavelet mãe com o sinal de DP.




Figura 6.29: Comparação da função de aptidão para os pulsos de DP utilizando os métodos CBWS, EBWS, SNRBWS e MEBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.

Como nos casos anteriores, mostramos na Fig. 6.30 os resultados obtidos para os parâmetros de avaliação incluindo os parâmetros utilizados na formação da função custo (p_g , p_l e Dk). Novamente vemos que o método SNRBWS é superior a todos os

demais para a grande maioria dos parâmetros de avaliação, perdendo apenas para o CBWS nos critérios VTPmax, VTPmin e VTS.

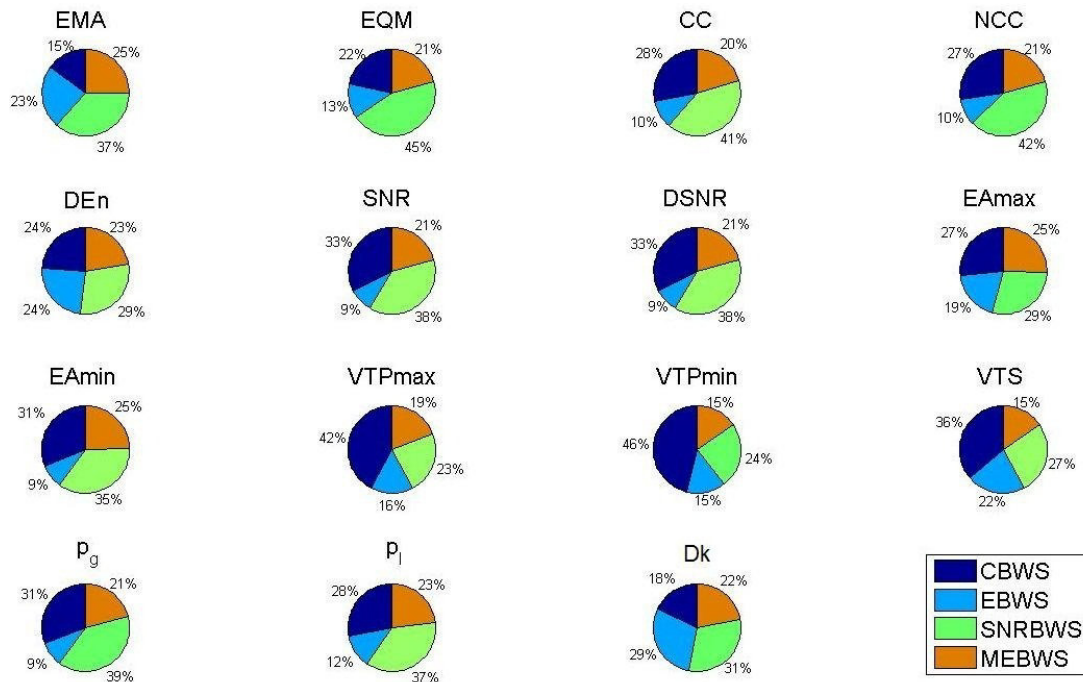


Figura 6.30: Comparação dos resultados das filtragens dos pulsos de DP utilizando os métodos CBWS, EBWS, SNRBWS e MEBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.

Comparação entre todos os Métodos

Por fim agrupamos todos resultados fornecidos pelos métodos de seleção da wavelet e pelo método AG para verificar a performance do método AG ao buscar por todos as variáveis envolvidas na filtragem do sinal.

A Fig. 6.31 mostra os resultados percentuais em que cada método foi melhor. Podemos verificar que o AG foi melhor em cerca de 86% dos casos, demonstrando sua superioridade em relação aos demais métodos aqui apresentados. Na verdade tal performance poderia chegar a 100% caso optássemos por aumentar o número de iterações para término da execução do algoritmo e/ou aumentássemos o tamanho da população μ . Observe ainda que na sequência o SNRBWS continua superior aos demais.

A Fig. 6.32 mostra os percentuais para cada parâmetro de avaliação, comparando os resultados vemos a superioridade do método AG em todos os parâmetros.




Figura 6.31: Comparação da função de aptidão para os pulsos de DP utilizando os métodos CBWS, EBWS, SNRBWS, MEBWS e AG. O percentual indica o número de casos em que cada método obteve melhor resultado.




Figura 6.32: Comparação dos resultados das filtragens dos pulsos de DP utilizando os métodos CBWS, EBWS, SNRBWS e MEBWS. O percentual indica o número de casos em que cada método obteve melhor resultado.

Resultados Médios

Com as análises percentuais anteriores, temos apenas uma ideia de quantas vezes cada método apresentou melhor performance, mas não temos ideia do grau de melhora provido. Para permitir uma melhor percepção dos resultados obtidos os valores médios dos parâmetros obtidos com cada algoritmo são mostrados na Tabela 6.21. Note que o método AG é superior em praticamente todos os parâmetros exceto para E_{Amin} , onde perde para o método SNRBWS, que o sucede na classificação de melhor método. Portanto, a eficiência de ambos os métodos propostos nesta dissertação é comprovada.

Tabela 6.21: Valores médios dos parâmetros obtidos com cada algoritmo.

Parâmetros	Método				
	CBWS	EBWS	SNRBWS	MEBWS	AG
EMA	0.0776	0.0679	0.0668	0.0707	0.0523
EQM	0.0419	0.0351	0.0311	0.0365	0.0175
CC	0.7212	0.7023	0.7407	0.7092	0.7898
NCC	0.7165	0.6971	0.7361	0.7049	0.7855
DEn	1.425	1.017	0.781	1.114	0.462
SNR	6.697	5.804	6.818	6.190	8.088
$DSNR$	3.515	2.621	3.635	3.008	4.896
E_{Amax}	33.26	42.85	31.40	38.80	22.45
E_{Amin}	41.13	47.77	25.10	37.18	28.15
$VTPmax$	23.55	44.28	12.79	24.68	10.14
$VTPmin$	81.03	80.54	67.74	61.73	26.44
VTS	12.65	14.85	8.60	16.12	6.80
p_g	12.51	11.17	13.09	11.88	16.33
p_l	4.98	5.77	3.94	4.77	2.55
Dk	10.85	20.27	11.89	12.21	1.50
f_{Apt}	-8.75	-25.01	-8.69	-11.20	11.52

6.6.2 Resultados de Tempo de Execução

Em [30] Li *et al.* mostram que a maior vantagem do método EBWS se encontra no tempo gasto no processo de busca das wavelets, sendo bem inferior em relação ao do método CBWS, como podemos verificar na Fig. 6.33, que compara os tempos de execução dos quatro métodos de seleção da wavelet mãe. No entanto, o SNRBWS proposto por nós possui um tempo médio de processamento ainda melhor que o fornecido pelo EBWS, sendo, portanto, superior a todos os demais. Os algoritmos dos métodos SNRBWS e EBWS são muito parecidos; entretanto, o tempo gasto

para calcular a energia dos coeficientes de aproximação E_c é superior ao gasto para calcular o SNR, que depende de uma única operação de divisão do máximo valor absoluto dos coeficientes.




Figura 6.33: Comparação do tempo de processamento entre os métodos CBWS, EBWS, SNRBWS e MEBWS: (a) tempo de processamento; (b) tempo de processamento normalizado.

Na Fig. 6.34 mostramos a comparação destes métodos com o AG. Fica clara a desvantagem do método AG, na qual apesar de ser muito superior nos resultados de redução de ruídos, apresenta um alto tempo de processamento, sendo que este tempo será diretamente proporcional ao tamanho da população e ao número de ciclos evolucionários estabelecidos *a priori*. No entanto se levarmos em consideração que é razoável assumir que, para um determinado tipo de equipamento de alta tensão, os pulsos de DP medidos possuirão formas de onda semelhantes, variando em sua amplitude, podemos demandar um pouco de tempo no processamento do AG para determinar os parâmetros ótimos a serem aplicados para aquele equipamento em específico durante todo o processo de medição.




Figura 6.34: Comparação do tempo de processamento entre os métodos CBWS, EBWS, SNRBWS, MEBWS e AG: (a) tempo de processamento; (b) tempo de processamento normalizado.

Um tempo de processamento pequeno é uma característica importante para

implementações em um sistema de medição em tempo real. Utilizamos um computador com processador Intel [®] Core [™] 2 Quad CPU Q9400 de velocidade 2.66 GHz, memória de 2 GB e sistema operacional Microsoft Windows Vista Home Premium 64 bit para processar todos os cálculos feitos no Matlab.

6.6.3 Resultados dos Parâmetros de Limiarização

Após processar os dados obtidos com a filtragem dos 260 sinais de DP para as 13 diferentes combinações de parâmetros de cálculo e de reescala do valor de limiar aplicados na redução de ruídos por transformada wavelet com os métodos CBWS, EBWS, SNRBWS, MEBWS e AG, verificamos a quantidade de vezes em que cada combinação obteve a melhor aptidão com base na f_{Apt} . Estes valores são mostrados na Tabela 6.22, com a percentagem ilustrada na Fig. 6.35. Observe que os parâmetros de filtragem mais adequados são dados pela combinação do método *sqtwolog* com fator de reescala *mln*, ainda que os sinais ideais estimados para os pulsos de DP medidos de equipamentos de alta tensão tenham sido gerados com o parâmetro *scaledep*, o qual é muito aplicado na literatura de filtragem de DP por transformada wavelet, por gerar um menor erro de amplitude, conforme discutido no Capítulo 3. Entretanto, ao gerar um erro menor de amplitude, é provável que uma quantidade maior de coeficientes ruidosos não seja muito atenuada; ainda assim o método *scaledep* apresenta um excelente desempenho na filtragem dos pulsos de DP. Além deste, podemos destacar o método *sqtwolog* e *heursure* com fator de reescala *sln*, os quais também mostram bons resultados.

Podemos dizer que para aplicação em certa filtragem de pulsos de DP, onde não se dispõe de tempo para analisar qual o melhor parâmetro a ser aplicado, o mais adequado seria utilizar o parâmetro *sqtwolog* com fator *mln*. Definitivamente os métodos *minimaxi* e *rigrsure* não se mostram interessantes para aplicação em filtragem de sinais de DP.

Tabela 6.22: Contagem de melhores resultados para cada parâmetro de filtragem.

Método	<i>heursure</i>			<i>minimaxi</i>			<i>rigrsure</i>			<i>sqtwolog</i>			<i>scaledep</i>
	<i>one</i>	<i>sln</i>	<i>mln</i>	<i>one</i>	<i>sln</i>	<i>mln</i>	<i>one</i>	<i>sln</i>	<i>mln</i>	<i>one</i>	<i>sln</i>	<i>mln</i>	
Fator de reescala													-
Contagem	49	162	133	24	50	61	91	29	47	37	164	231	222




Figura 6.35: Comparação dos melhores parâmetros de filtragem. O percentual indica o número de casos em que cada combinação de parâmetros aplicados na filtragem wavelet forneceu o maior valor de aptidão.

Podemos estender a análise dos melhores parâmetros de filtragem para cada método de seleção da wavelet mãe, investigando qual valor de cada parâmetro se sai melhor com cada um destes métodos. A Tabela 6.23 mostra a quantidade de vezes em que cada parâmetro apresentou a melhor filtragem do sinal. Vemos que para os métodos CBWS e SNRBWS os parâmetros *sqtwolog* e *mln* forneceram uma maior quantidade de melhores resultados; para o EBWS o método *heursure* combinado ao fator *sln* se saiu melhor; e para o MEBWS a combinação *sqtwolog* com *sln* é superior. Repare, entretanto, que o método *scaledep* é o melhor para 31% dos resultados obtidos com o algoritmo de seleção de parâmetros de filtragem AG, levando em conta que o método AG supera todos os demais, por buscar os parâmetros capazes de fornecerem os melhores resultados de redução de ruídos. Isto implica que a melhor filtragem a ser obtida esta associada ao parâmetro *scaledep*; portanto, entendemos que o parâmetro de calculo do valor de limiar *scaledep* é aquele que fornecerá os melhores resultados, mas não podemos afirmar que este é o melhor parâmetro para ser utilizado com os demais métodos que selecionam somente a wavelet mãe.

Tabela 6.23: Contagem de melhores resultados isoladamente para cada parâmetro de filtragem.

	Método	<i>heursure</i>			<i>minimaxi</i>			<i>rigrsure</i>			<i>sqtwolog</i>			<i>scaledep</i>
		<i>one</i>	<i>sln</i>	<i>mln</i>	<i>one</i>	<i>sln</i>	<i>mln</i>	<i>one</i>	<i>sln</i>	<i>mln</i>	<i>one</i>	<i>sln</i>	<i>mln</i>	
	Fator de reescala													-
Contagem	CBWS	10	29	15	7	7	14	20	2	6	13	22	64	51
	EBWS	12	45	29	3	12	19	22	8	7	7	34	35	27
	SNRBWS	15	42	34	4	8	7	13	3	7	5	29	58	35
	MEBWS	11	35	33	8	15	11	24	2	5	8	46	33	29
	AG	1	11	22	2	8	10	12	14	22	4	33	41	80

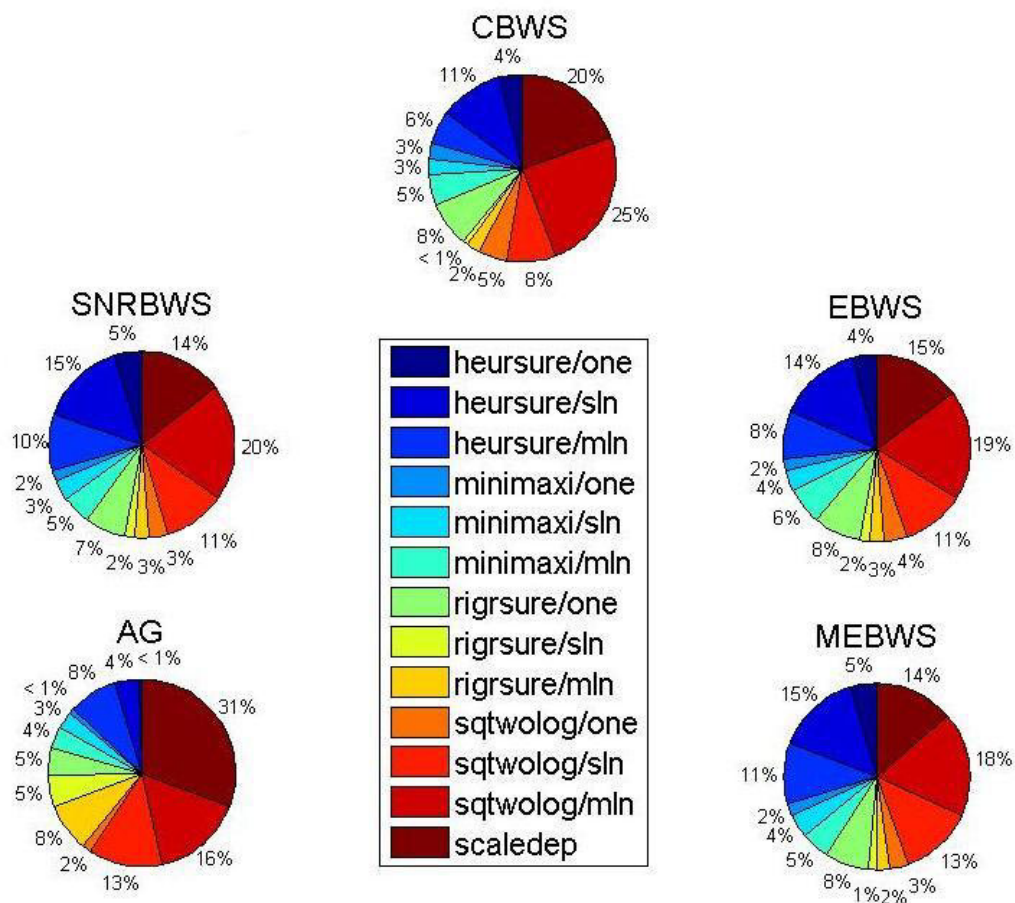


Figura 6.36: Comparação dos melhores parâmetros de filtragem para cada método de seleção da wavelet e para o método AG. O percentual indica o número de casos em que cada combinação de parâmetros aplicados na filtragem wavelet forneceu o maior valor de aptidão.

6.6.4 Avaliação do Algoritmo PSBLS com a Função de Aptidão

Para avaliarmos a performance do algoritmo de seleção de nível PSBLS, mostrado no Capítulo 5, optamos por escolher 12 sinais de pulso de DP, dentre eles S_{38} , S_{41} , S_{43} , S_{48} , S_{51} , S_{57} , S_{60} , S_{68} , S_{71} , S_{81} ($S_{41} + ng_{SNR=4}$), S_{132} ($S_{4,SNR=0,5}$) e S_{166} ($S_{10,SNR=4}$). Em seguida, aplicamos os métodos de seleção wavelet CBWS, EBWS, SNRBWS e MEBWS combinados com o método de cálculo do valor de limiar *sqtwo-log*, com fator de reescala *mln* e função de limiarização abrupta (*hard*), já que os mesmos mostraram fornecer os melhores resultados de redução de ruídos dentre os demais parâmetros para 18% dos pulsos avaliados.

Para cada sinal escolhido variamos o número de níveis de decomposição de $j = 1$ até J_{max} e calculamos o valor da função custo f_{Apt} com os diferentes métodos de seleção da wavelet mãe.

Os dados obtidos foram expostos nas Tabelas 6.24 e 6.25, onde identificamos o número de níveis de decomposição que produz o maior valor de aptidão, i.e., a melhor filtragem para cada sinal de DP em cada método. Observe que o melhor valor de aptidão, ao contrário do que se poderia esperar, nem sempre estará no mesmo número de níveis para ambos os métodos. Entretanto, pode-se dizer que os maiores valores de aptidão, em ambos os métodos de seleção da wavelet, estarão distribuídos em níveis próximos. Podemos ainda dizer que o nível de decomposição que produz o melhor resultado também depende das funções mãe utilizadas no processo de filtragem wavelet.

Comparando o número de níveis de decomposição onde ocorre o melhor custo com o número encontrado pelo algoritmo PSBLS (J_P), vemos que, apesar de nem sempre fornecer o melhor valor de aptidão, este se mostra satisfatório em identificar um nível de decomposição que gera bons resultados. Note que para a maioria dos sinais analisados o método SNRBWS se mostra superior.

Ao contrário do que sugerem os autores em [32] ao dizer que, mesmo sendo dispendioso, o uso do número máximo níveis na redução de ruídos wavelet garante bons resultados, vemos nas Fig. 6.37 (b) e (d) que o nível máximo ocasionou uma piora significativa da filtragem, principalmente para o EBWS. Então, podemos apenas afirmar que, para número de níveis mais alto, existe uma tendência em se gerar resultados satisfatórios, já que conseguimos obter uma maior quantidade de detalhes das componentes de frequência presentes no sinal, facilitando a redução de ruídos na etapa de limiarização.

Para facilitar a visualização destas propriedades, plotamos alguns gráficos, mostrados na Fig. 6.37, os quais contêm a evolução da aptidão dos métodos para cada nível de decomposição. Outro fator importante é que para todos os sinais avaliados, mesmo um método fornecendo o maior valor de custo, este não necessariamente obtém o melhor valor em filtragens realizadas para um outro número de níveis de decomposição.

Estas particularidades, juntamente com o fato de que o algoritmo PSBLS não é capaz de determinar o melhor nível, reforçam a ideia de se utilizar um algoritmo para buscar todos os parâmetros de forma conjunta, exigência esta que pode ser atendida pelo AG.

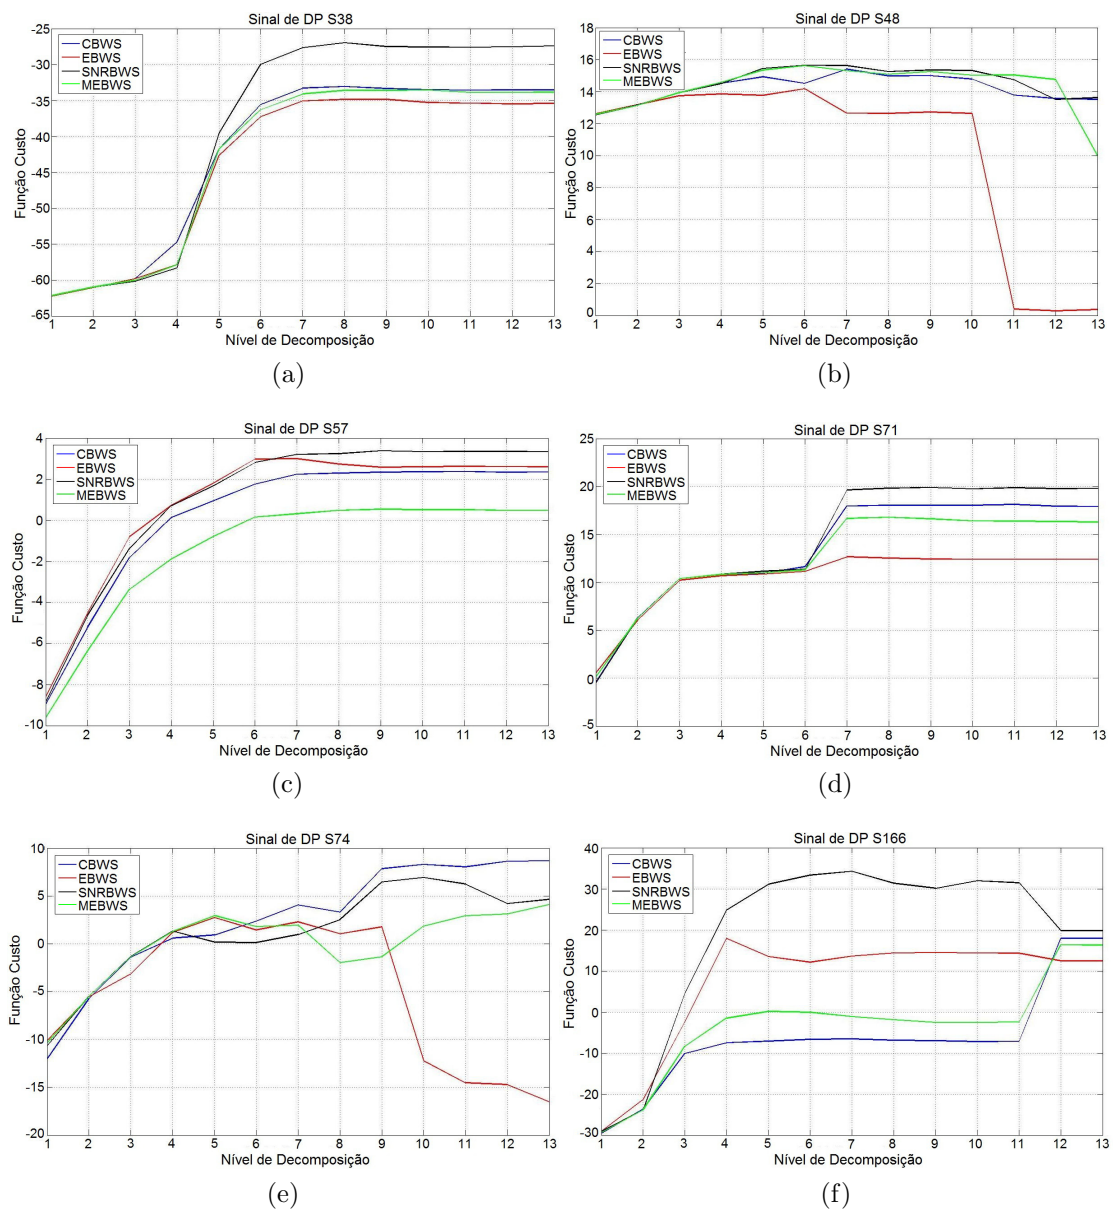


Figura 6.37: Valor de aptidão em cada nível de decomposição: (a) sinal S_{38} ; (b) sinal S_{48} ; (c) sinal S_{57} ; (d) sinal S_{71} ; (e) sinal S_{74} ; (f) sinal $S_{10, SNR=4}$.

Tabela 6.24: Evolução da função custo por nível de decomposição.

Sinal	J_P	Método	1	2	3	4	5	6	7	8	9	10	11	12	13
S_{38}	13	CBWS	-62.262	-61.07	-59.80	-54.71	-41.74	-35.54	-33.26	-33.06	-33.35	-33.49	-33.56	-33.52	-33.53
		EBWS	-62.262	-61.07	-59.80	-57.82	-42.65	-37.23	-35.07	-34.84	-34.84	-35.29	-35.38	-35.47	-35.40
		SNRBWS	-62.181	-61.01	-60.19	-58.31	-39.59	-29.93	-27.67	-26.96	-27.51	-27.56	-27.59	-27.52	-27.40
		MEBWS	-62.179	-60.96	-60.03	-57.86	-41.78	-36.27	-34.09	-33.59	-33.60	-33.56	-33.86	-33.88	-33.85
S_{41}	6	CBWS	11.04	11.73	12.45	12.99	12.95	13.08	13.04	13.09	13.10	13.15	-	-	-
		EBWS	10.93	11.31	11.81	12.15	11.63	11.45	11.41	10.83	8.99	9.34	-	-	-
		SNRBWS	11.11	11.78	12.61	12.89	12.70	12.96	12.92	12.90	12.76	12.56	-	-	-
		MEBWS	11.08	11.54	11.99	12.49	12.14	12.12	12.14	11.83	11.45	10.89	-	-	-
S_{43}	6	CBWS	9.82	10.72	12.64	13.21	14.38	14.41	14.48	14.16	14.13	14.31	-	-	-
		EBWS	9.07	10.71	11.85	12.51	13.49	13.51	13.48	12.68	12.56	12.72	-	-	-
		SNRBWS	9.35	10.69	12.61	13.61	14.03	14.22	14.26	14.17	14.45	14.67	-	-	-
		MEBWS	9.07	10.71	12.21	12.69	12.64	13.51	12.47	13.24	13.22	12.60	-	-	-
S_{48}	9	CBWS	12.57	13.13	13.93	14.51	14.93	14.52	15.40	14.99	15.00	14.79	13.79	13.57	13.51
		EBWS	12.61	13.18	13.74	13.86	13.77	14.17	12.65	12.63	12.72	12.63	0.41	0.29	0.37
		SNRBWS	12.55	13.14	13.93	14.50	15.45	15.65	15.63	15.25	15.35	15.33	14.75	13.51	13.63
		MEBWS	12.57	13.14	13.93	14.57	15.35	15.62	15.31	15.09	15.25	15.02	15.03	14.76	10.00
S_{51}	6	CBWS	-6.99	-6.13	11.79	16.14	16.17	13.07	12.98	12.94	12.93	12.90	12.79	12.78	12.69
		EBWS	-6.88	-4.47	11.74	16.08	17.41	15.89	15.72	15.31	15.34	15.33	15.33	15.33	15.33
		SNRBWS	-6.98	-5.55	11.91	16.22	16.24	18.82	18.68	18.69	18.68	18.63	18.63	18.60	18.54
		MEBWS	-6.97	-5.58	11.72	16.05	15.44	17.97	17.60	17.20	17.18	17.31	17.30	17.30	17.31
S_{57}	13	CBWS	-8.95	-5.22	-1.83	0.14	0.94	1.76	2.24	2.29	2.34	2.35	2.37	2.33	2.35
		EBWS	-8.60	-4.50	-0.81	0.72	1.80	2.98	2.99	2.73	2.58	2.60	2.62	2.61	2.60
		SNRBWS	-8.86	-4.63	-1.39	0.71	1.66	2.80	3.20	3.24	3.38	3.33	3.35	3.35	3.34
		MEBWS	-9.63	-6.37	-3.37	-1.89	-0.79	0.15	0.31	0.48	0.53	0.51	0.51	0.48	0.48

Tabela 6.25: Evolução da função custo por nível de decomposição.

Sinal	J_P	Método	1	2	3	4	5	6	7	8	9	10	11	12	13
S_{60}	9	CBWS	12.17	12.22	11.53	11.48	11.49	10.89	9.87	9.67	9.43	9.75	9.65	9.43	9.79
		EBWS	12.22	12.59	11.92	11.90	12.26	10.07	9.40	8.17	7.85	7.87	7.82	7.85	7.77
		SNRBWS	12.21	12.30	11.44	11.45	12.29	12.16	11.90	12.45	12.44	12.42	12.46	12.41	12.38
		MEBWS	12.21	12.34	11.69	11.60	11.86	11.06	9.97	8.89	8.59	8.58	8.58	8.55	8.52
S_{66}	9	CBWS	-156.91	-152.55	-56.92	-16.64	8.83	6.19	3.99	3.49	3.43	3.15	3.13	3.12	3.37
		EBWS	-156.91	-152.55	-29.16	6.84	9.24	11.39	12.98	13.51	13.55	13.69	13.75	13.81	13.83
		SNRBWS	-157.22	-155.00	-35.30	-1.45	3.94	5.51	7.53	8.12	8.20	7.95	7.75	7.57	7.40
		MEBWS	-157.22	-155.00	-35.30	1.37	7.26	9.17	11.86	12.61	12.65	11.93	12.05	10.75	10.76
S_{74}	10	CBWS	-12.06	-5.74	-1.40	0.60	0.92	2.38	4.04	3.30	7.84	8.30	8.04	8.62	8.67
		EBWS	-10.13	-5.52	-3.14	1.20	2.72	1.44	2.29	1.04	1.77	-12.22	-14.54	-14.71	-16.53
		SNRBWS	-10.68	-5.51	-1.31	1.32	0.16	0.11	0.98	2.53	6.45	6.94	6.24	4.21	4.63
		MEBWS	-10.37	-5.50	-1.35	1.29	2.94	1.79	1.93	-1.98	-1.36	1.83	2.93	3.11	4.10
S_{81}	10	CBWS	-77.09	-76.22	-77.99	-73.13	-60.83	-36.62	-10.00	-4.22	-3.43	-5.28	18.14	17.95	17.92
		EBWS	-76.36	-72.16	-62.41	-53.99	-7.67	-31.61	-59.80	-68.39	-80.12	-85.73	12.42	12.42	12.42
		SNRBWS	-76.85	-74.43	-70.24	-62.90	-44.88	-27.83	-0.63	-0.95	-1.68	-5.85	19.87	19.79	19.81
		MEBWS	-75.91	-72.34	-68.94	-61.35	-48.33	-36.52	-20.69	-18.29	-11.58	-10.77	16.40	16.36	16.30
S_{132}	11	CBWS	-42.38	-38.53	-37.21	-21.10	-13.59	-6.31	-4.17	-4.34	-4.39	-3.71	-3.14	17.95	17.92
		EBWS	-42.17	-39.38	-35.11	-14.14	-1.77	-14.96	-14.94	-17.80	-38.58	-44.68	-58.35	12.42	12.42
		SNRBWS	-39.52	-38.58	-35.26	-17.52	-1.05	-9.70	-22.56	-27.63	-31.88	-42.63	-47.16	19.79	19.81
		MEBWS	-39.52	-38.58	-36.50	-13.61	-3.04	-13.46	-21.42	-28.43	-45.81	-115.21	-112.49	16.36	16.30
S_{166}	11	CBWS	-29.55	-23.63	-10.12	-7.49	-7.09	-6.69	-6.59	-6.90	-6.98	-7.20	-7.19	17.95	17.92
		EBWS	-29.12	-21.31	-2.36	17.93	13.49	12.13	13.61	14.36	14.48	14.34	14.31	12.42	12.42
		SNRBWS	-29.11	-23.87	4.54	24.82	31.10	33.31	34.26	31.32	30.11	31.97	31.48	19.79	19.81
		MEBWS	-29.42	-23.90	-8.38	-1.49	0.13	-0.09	-1.12	-1.90	-2.56	-2.58	-2.47	16.36	16.30

Capítulo 7

Conclusões e Sugestões

Um dos maiores desafios do setor elétrico é garantir um fornecimento contínuo de energia eliminando quaisquer tipo de interrupções decorrentes de falhas em equipamentos de alta tensão essenciais nas etapas de geração, transmissão e distribuição de energia elétrica. Portanto, é primordial atestar as condições destes equipamentos, principalmente no que diz respeito ao isolamento, que em casos de falha pode causar severos danos pessoais e materiais.

A técnica de medição de descargas parciais tem se mostrado eficaz em fornecer um diagnóstico preditivo do isolamento de equipamentos elétricos de alta tensão. Entretanto, estas medições de DP são afetadas por ruídos oriundos de diversas fontes, os quais acometem a qualidade das medições e conseqüentemente a capacidade de um diagnóstico adequado.

A transformada wavelet tem sido uma ferramenta efetiva na redução ou até mesmo eliminação de alguns destes ruídos, principalmente ruído branco e ruídos de espectro discreto. A aplicação da WT depende de um conjunto de variáveis, que exercem grande influência na qualidade da filtragem. A determinação dos parâmetros ótimos a serem aplicados na filtragem wavelet dos sinais de DP representa um desafio com muito a ser explorado.

Nesta dissertação apresentamos algumas alternativas para melhorar a performance da filtragem de sinais de DP, verificando algumas propriedades da decomposição por WT que ainda não haviam sido totalmente exploradas.

Muito se ve na literatura técnica da busca pela função wavelet responsável por decompor os sinais sob análise. Alguns dos métodos mais importantes apresentados são o CBWS e o EBWS, que selecionam as wavelets que maximizam, respectivamente, a correlação e a percentagem da energia de aproximação. Verificando que o

sinal a ser tratado pode concentrar sua energia em determinadas bandas, apresentamos um novo método de seleção do número de níveis de decomposição adequados para decompor um sinal (baseado nas sugestões dadas em [105]), dois métodos de seleção da wavelet mãe, o SNRBWS e o MEBWS, que buscam maximizar o coeficiente de maior valor absoluto e a energia nos coeficientes que detêm maior parte da informação do sinal de DP desejado, respectivamente. Por fim, avaliando o processo de redução de ruídos por meio da WT, como um problema de otimização multivariável, desenvolvemos um método de busca baseado em AG para determinar todos os parâmetros ótimos necessários para a filtragem wavelet do sinal.

O AG necessita da função custo para avaliar uma população de candidatos. Esta função depende de um conjunto de critérios de avaliação combinados a constantes que determinam a importância de cada um destes critérios na aptidão de cada indivíduo, de forma a permitir identificar os bons candidatos dentro da população. É necessário cuidado ao determinar os valores dos pesos, para não darmos muita importância a um único critério, o que ocultaria o valor dos demais critérios em análise.

Simulamos um total de 180 pulsos com diferentes tipos e composições de ruídos branco uniforme e Gaussiano, e ruído de espectro discreto AM, além de termos selecionado 40 pulsos de DP de vários equipamentos de alta tensão medidos em campo e em laboratório e a partir destes originamos mais quarenta pulsos contaminados com ruído branco Gaussiano com $SNR = 4$, totalizando 260 pulsos de DP distintos. Estes sinais foram processados utilizando os diferentes métodos de seleção de wavelet mãe, com o algoritmo PSBLS para a seleção do número de níveis de decomposição aplicado na filtragem em conjunto com os diferentes métodos de cálculo e reescala do valor de limiar, e o método de busca AG.

Inicialmente, determinamos um sinal ideal estimado e o aplicamos na determinação das wavelets mãe. Vimos diferentes métodos de seleção que selecionam as wavelets de formas distintas. O CBWS aplica uma única wavelet a todos os níveis de decomposição maximizando a correlação com o sinal ideal. O método EBWS seleciona uma wavelet para cada escala de decomposição e, por se basear na maximização da energia nos coeficientes de aproximação, acaba por dar prioridade às wavelets de mais baixa ordem, as quais normalmente não são tão desejáveis para tratamento de sinais de DP por deixarem passar uma quantidade maior de coeficientes ruidosos. Além disso, ao contrário do que sugerem seus idealizadores [30], o EBWS nem sempre garantirá que os coeficientes de aproximação possuam o máximo nível de energia, comparado aos demais métodos, pois ao selecionar a wavelet que fornece a maior percentagem de energia em um nível, os coeficientes gerados pela decom-

posição do sinal podem não ser aqueles que fornecerão um maior nível de energia no próximo nível. O MEBWS seleciona a wavelet também com base na maximização da energia, no entanto o faz para os coeficientes que detém uma maior quantidade do sinal de DP. Isso acarretará uma melhora no sinal filtrado, mas ainda assim haverá uma preferência pela seleção de wavelet de baixa ordem, pois ambos se baseiam na maximização da energia. Já no método SNRBWS, que maximiza o maior coeficiente absoluto identificando os coeficientes importantes para composição do sinal de DP, tal parâmetro seleciona wavelets de ordens mais elevadas, sendo um motivo importante para termos dado preferência pela maximização do SNR e não da energia. Repare que sempre as mesmas wavelets serão selecionadas por estes métodos para cada sinal ideal. Já o método GA, por buscar o melhor parâmetro avaliando uma população de indivíduos gerados aleatoriamente e gerar novos descendentes também de forma aleatória, pode selecionar wavelets distintas para o mesmo sinal ideal em execuções distintas, mas sempre fornece a wavelet que provê o máximo valor de custo.

Ao maximizar o coeficiente de maior valor absoluto o método SNRBWS tende a se aproximar de forma mais eficaz da distribuição do espectro de potência do sinal de DP ideal, fornecendo assim, em geral, melhores resultados de filtragem que os métodos CBWS, EBWS e MEBWS.

Analisamos os resultados do número de vezes em que cada método apresentou o maior valor de aptidão. Inicialmente comparando o CBWS com o EBWS, vimos que apesar de os autores em [30] sugerirem uma melhor performance do método EBWS em nossas simulações o CBWS apresentou performance superior em cerca de 61% dos casos e também foi superior para os demais critérios de avaliação, confirmando sua eficiência. Provavelmente os autores não exploram o método EBWS para um grupo extenso de sinais, o que levou a conclusões equivocadas.

Em outra comparação analisamos os dois novos métodos propostos o SNRBWS e o MEBWS, o SNRBWS se mostrou melhor para 64% dos casos e também é o melhor para os demais critérios verificados. Devido ao fato de que a seleção pela maximização do maior valor absoluto é superior a utilização do critério de energia, que tende a escolher funções de ordem mais baixa, piorando o resultado do método.

Em seguida comparamos os quatro métodos de seleção da wavelet mãe CBWS, EBWS, SNRBWS e MEBWS. Neste caso o melhor método para 42% dos casos foi o método SNRBWS, seguido pelo CBWS, MEBWS e com o EBWS em último. O que mostra a tendência do SNRBWS em prover os melhores resultados em uma filtragem o MEBWS, mesmo tentando concentrar a informação nos coeficientes que contêm a maior parte do sinal não consegue superar o CBWS, o qual mostra que a

ideia de buscar por wavelets que se assemelhem a forma de onda do pulso apresenta uma boa performance.

Por fim comparamos todos os quatro métodos com o AG. Os resultados obtidos não deixam nenhuma dúvida da habilidade do método AG de identificar de forma muito superior os melhores parâmetros para filtragem do sinal. Isso se deve à sua esparsa área de busca, onde consegue explorar por parâmetros que levem a um ótimo, Entretanto ainda houve uma pequena parcela de sinais onde os demais métodos foram superiores; isso se deve a pouca quantidade de iterações realizadas para busca de um ótimo (4 iterações). O método AG poderia facilmente atingir o melhor valor de função custo para 100% dos sinais analisados caso aumentássemos o número de iterações e/ou o tamanho da população, claro as custas de um maior tempo de processamento do mesmo.

Para termos uma ideia mais clara da capacidade de cada método analisamos o valor médio obtido para diversos critérios de avaliação. Novamente o método AG superior aos demais métodos, como era de se esperar já que o método explora os diversos parâmetros envolvidos na filtragem wavelet.

Para avaliar o tempo gasto por cada algoritmo na análise dos dados, apresentamos o tempo médio para encontrar as wavelets para cada método de seleção. Além de apresentar os melhores parâmetros de filtragem, o SNRBWS foi o mais rápido comparado aos demais, sendo seguido pelo EBWS, MEBWS e CBWS. Isso porque o cálculo da SNR feito pelo SNRBWS demanda um menor tempo de processamento do que o gasto para calcular a energia dos coeficientes.

Também mostramos o tempo médio de processamento do método AG e aqui se encontra a grande desvantagem deste método, por levar muito tempo para calcular a função custo de toda a população. Entretanto, se não há preocupação com o tempo necessário para determinar quais os parâmetros ótimos para análise de cada equipamento, devemos optar por este método, cuja performance se mostra muito superior às dos demais. Caso necessitemos de rapidez na busca por uma wavelet mais adequada, podemos recorrer ao método SNRBWS, que é eficiente e rápido.

Como executamos para cada método todas as variações no cálculo do valor de limiar, optamos por identificar qual destas teve a melhor eficiência em prover o melhor resultado de cada método, por meio da contagem do número de vezes em que cada combinação de parâmetros forneceu o melhor resultado. No geral, vimos que o método *sqtwolog* combinado ao fator de reescala *mln* forneceu uma quantidade maior de melhores resultados, sendo precedido pelo método *scaledep*, ainda que os sinais ideais tenham sido gerados pela decomposição wavelet do sinal ruidoso

de DP com o método de cálculo do limiar *scaledep*. Entretanto quando analisamos individualmente, vimos que cada método de busca tende a obter melhores resultados utilizando um determinado tipo de parâmetro. Se considerarmos que o AG fornece os melhores resultados, podemos dizer que o método *scaledep* se mostrou superior aos demais parâmetros.

Por fim, ao avaliar a eficácia do algoritmo PSBLS, concluímos que apesar de nem sempre prover os melhores resultados, fornece um número de níveis que frequentemente proporciona bons resultados de filtragem. Portanto, este método surge como uma forma mais atrativa de seleção do número de níveis, já que nem sempre escolher o número de níveis, mais alto proverá o melhor resultado para um determinado tipo de sinal de DP. Outro ponto importante é que mesmo um método fornecendo o maior valor de custo, este não necessariamente obtém o melhor valor em filtrações realizadas para um outro número de níveis de decomposição.

Considerando todos os resultados, vemos que o método SNRBWS obtém excelente performance de filtragem com um menor tempo de processamento, mostrando que a proposta de maximizar o máximo valor absoluto dos coeficientes tende a fornecer melhores resultados por concentrar uma maior quantidade de informação nos coeficientes de maior importância para composição do sinal de DP. O método AG é claramente superior a todos os demais, pecando somente no tempo para processar o algoritmo; mas se o tempo de processamento não for determinante, esta será, de longe, a melhor opção para se determinar os parâmetros a serem aplicados ao sinal de DP sob análise.

A função custo desenvolvida se mostra eficiente em determinar os melhores indivíduos, i.e., em permitir identificar os melhores resultados de filtragem. Além de ser útil como parâmetro de comparação entre os diversos métodos avaliados.

Tentamos com esta dissertação chamar a atenção para alguns campos da WT, aplicada à redução de ruídos de sinais de DP, ainda não explorados, mostrando soluções que contribuirão para aprimorar o conhecimento existente na literatura. Entretanto, muitas áreas da filtragem de sinais de DP por WT, precisam ser investigadas. No parágrafo a seguir levantamos algumas sugestões que podem ser estudadas.

7.1 Sugestões

Como percebemos, embora os métodos aqui apresentados mostrem resultados satisfatórios, estes ainda podem ser aprimorados, principalmente o método AG, que

apesar de eficiente necessita de bastante tempo para encontrar os parâmetros ótimos. Seria interessante investigar a possibilidade de se criar uma nova função custo que não necessite de valores de pesos ou de ajuste, utilizando uma quantidade menor de parâmetros. Isso provavelmente ocasionaria a redução do tempo de processamento.

Poderia ser avaliada a possibilidade de se inserir algum conhecimento na criação da população inicial utilizando o método SNRBWS, que provou fornecer bons resultados, o que acarretaria na redução do tempo de processamento.

No AG, mesmo buscando os diversos parâmetros, não avaliamos todas as funções de limiarização discutidas no Capítulo 3, então seria interessante investigar a performance do método perante as diversas funções de limiarização existentes, podendo também analisar um modo de buscar pelo melhor valor de limiar, e não mais buscar pelo melhor método de cálculo deste valor (conforme realizamos neste trabalho). Este processo poderia ser inserido como uma etapa de busca local dos melhores indivíduos obtidos a cada ciclo evolucionário, obtendo resultados ainda melhores mesmo para um pequena quantidade de ciclos.

Avaliar a performance do algoritmo SNRBWS com métodos adaptativos de seleção dos valores de limiar, por exemplo, o método genético de busca empregado em [83] juntamente com o algoritmo EBWS.

Investigar se o método SNRBWS poderia ser aperfeiçoado ao se decompor, nos níveis seguintes, os coeficientes de maior importância identificados pela SNR. Decompondo não apenas o coeficiente de aproximação, mas também os coeficientes de detalhe, i.e., fugindo da estrutura piramidal empregada pela DWT para uma estrutura similar a empregada na WPT.

Sabendo da existência de uma extensa quantidade de variações de WT, acreditamos que adaptar e investigar a performance dos métodos de seleção do número de níveis, seleção das wavelets mãe e de busca AG aos diferentes tipos de WT ampliaria o entendimento e conseqüentemente a capacidade de cada método para estas WT.

Referências Bibliográficas

- [1] 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.
- [2] BORSI, H. “A PD Measuring and Evaluation System Based on Digital Signal Processing”, *IEEE Trans. Dielect. Electr. Insul.*, v. 7, pp. 21–29, 2000.
- [3] NAGESH, V., GURURAJ, B. I. “Digital Filters for Rejecting Discrete Spectral Interference in On-site PD Measurements”, *IEEE Trans. Electr. Insul.*, v. 28, pp. 73–85, 1993.
- [4] KHAM, S. Z., ZHU, D., JIN, X., et al. “A New Adaptive Technique for On-line Partial Discharge Monitoring”, *IEEE Trans. Electr. Insul.*, v. 2, pp. 700–707, 1995.
- [5] ZARGARI, A., BLACKBURN, T. R. “Application of Adaptive Filters for the Estimation of Partial Discharge Signals in Noisy Environments”, *IEEE Int. Conf. Properties and Application of Dielectric Materials*, v. 1, n. 6, pp. 212–215, 1997.
- [6] NETTO, P. S. R., SILVA, S. L., EDUARDO, A. B. D. *Digital Signal Processing System Analysis and Design*. 2 ed. New York, Cambridge, 2001.
- [7] 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.
- [8] KREUGER, F. H. *Partial Discharge Detection in High-Voltage Equipment*. 1 ed. London, Butterworths, 1989.
- [9] 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.

- [10] *IEC 60270 - High-voltage Test Techniques: Partial Discharge Measurements, Third Edition (2000)*, 3 ed., 2000.
- [11] GULSKI, E. “Analysis of Partial Discharges”, *IEEE TDEI*, v. 2, n. 5, pp. 822–837, Oct. 1995.
- [12] MASON, H. M. “Enhancing the Significance of PD Measurements”, *IEEE TDEI*, v. 2, n. 5, pp. 876–888, Oct. 1995.
- [13] LEMKE, E. *WD1.33 Guide for Partial Discharge Measurements in Compliance to IEC 60270*. Relatório técnico, CIGRÉ, 2008.
- [14] PEDERSEN, A., CRICHTON, G., MCALLISTER, I. W. “The Theory and Measurement of Partial Discharge Transients”, *IEEE TEI*, v. 26, n. 3, pp. 487–497, Jun. 1991.
- [15] EDIN, H. *Partial Discharges Studied with Variable Frequency of the Applied Voltage*. Phd thesis in electrical engineering, Kungl Tekniska Hogskolan, Stockholm-Sweden, 2001.
- [16] BOGGS, S. A. “Partial Discharge Part III: Cavity-Induced PD in Solid Dielectrics”, *IEEE EIM*, v. 6, n. 6, pp. 11–20, Nov.-Dec. 1990.
- [17] DISSADO, L. A., FOTHERGILL, J. C. *Electrical Degradation and Breakdown in Polymers*. Universidade de Michigan, USA, Peter Peregrinus Ltd., 1992.
- [18] GEMANT, A., PHILIPPOFF, W. “Die Funkenstrecke mit Vonkondensator”, *Zeitschrift fur Technische Physik*, v. 13, n. 9, pp. 425–430, 1932.
- [19] ACHILLIDES, Z., GEORGHIOU, G., KYRIAKIDES, E. “Partial Discharges and Associated Transients: the Induced Charge Concept Versus Capacitive Modeling”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 15, n. 6, pp. 1507–1516, Dec. 2008.
- [20] MCALLISTER, I. “Partial Discharge in Spheroidal Voids Void Orientation”, *IEEE TDEI*, v. 4, n. 4, pp. 456–461, Aug. 1997.
- [21] NIKOLAY, P. K. E. A. “Development of Partial Discharge Model, Simulation and Measurement”, *CEIDP*, pp. 214–217, 1999.

- [22] LEMKE, E. S. P., ELZE, H., RUSSWURM, D. “Experience in the Calibration Techniques for Calibrating PD Calibrators”, *European Conference on High Voltage Measurements and Calibration*, v. 3, 1996.
- [23] DEVINS, J. C. “The Physics of Partial Discharges in Solid Dielectrics”, *IEEE TEI*, v. 19, n. 5, pp. 475–495, Oct. 1984.
- [24] BARTNIKAS, R., NOVAK, J. P. “On the Character of Different Forms of Partial Discharge and Their Related Terminologies”, *IEEE TEI*, v. 28, n. 6, pp. 956–968, Dec. 1993.
- [25] 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.
- [26] 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.
- [27] GAOUDA, A., EL-HAG, A., ABDEL-GALIL, T., et al. “On-line Detection and Measurement of Partial Discharge Signals in a Noisy Environment”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 15, n. 4, pp. 1162–1173, Aug. 2008. ISSN: 1070-9878. doi: 10.1109/TDEI.2008.4591239.
- [28] 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.
- [29] 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, 2000. doi: 10.1109/ICPADM.2000.876113.
- [30] 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.

- [31] HENG, D. Z., HE, L. S., LEI, W. “Selection of the Optimal Wavelet Bases For Wavelet De-noising of Partial Discharge Signal”, *Signal Processing Systems (ICSPS), 2010 2nd International Conference on*, v. 3, pp. 400–404, Jul. 2010. doi: 10.1109/ICSPS.2010.5555675.
- [32] ZHOU, X., ZHOU, C., KEMP, I. “An Improved Methodology for Application of Wavelet Transform to Partial Discharge Measurement Denoising”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 12, n. 3, pp. 586–594, Jun. 2005. ISSN: 1070-9878. doi: 10.1109/TDEI.2005.1453464.
- [33] KRUEGER, F. H. *Partial Discharge Detection in High-Voltage Equipment*. 1 ed. London, England, Butterworths, 1989.
- [34] KRANZ, H. “Fundamentals in Computer Aid PD Processing, PD Pattern Recognition and Automated Diagnosis in GIS”, *IEEE TDEI*, v. 7, pp. 12–20, 2000.
- [35] 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.
- [36] KREUGER, F. H., GULSKI, E. “Automatisiertes Messsystem zur Erfassung von Teilentladungs-Kenngrößen für die Beurteilung elektrischer Isolierungen.” *Technisches Messen*, pp. 124–129, 1989.
- [37] GULSKI, E. *Computer-Aided Recognition of Partial Discharges Using Statistical Tools*. Tese de Doutorado, TU Delft, 1991.
- [38] PLATH, K. D., PLATH, R., EMANUEL, et al. “Synchrone Dreiphasige Teilentladungsmessung an Leistungs Transformatoren vor Ort und im Labor”, *ETG conference on Diagnostic*, 2002.
- [39] WEISSENBERG, F., PLATH, R., KALKNER. “On-Site PD Detection at Cross-Bonding Links of HV Cables”, *CIGRE Session 2004*, 2004.
- [40] KALKNER, OBRALIC, PLATH, et al. “Synchronous 3-Phase Partial Discharge Detection on Rotating Machines”, *CIGRE Session 2006*, 2006.
- [41] 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.

- [42] 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-jun. 2000. ISSN: 0883-7554. doi: 10.1109/57.845021.
- [43] NAGESH, V., GURURAJ, B. I. “Evaluation of Digital Filters for Rejecting Discrete Spectral Interference in On site PD Measurement”, *IEEE Trans. Elect. Insul.*, v. 28, pp. 73–85, 1993.
- [44] 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.
- [45] 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. 354367, Apr. 2003.
- [46] DEY, D., CHATTERJEE, B., CHAKRAVORTI, S., et al. “Cross-wavelet Transform As a New Paradigm For Feature Extraction From Noisy Partial Discharge Pulses”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 17, n. 1, pp. 157–166, Feb. 2010. ISSN: 1070-9878. doi: 10.1109/TDEI.2010.5412014.
- [47] SALAMA, M. M. A., BARTNIKAS, R. “Determination of Neural Network Topology for Partial Discharge Pulse Pattern Recognition”, *IEEE Trans. Neural Networks*, v. 13, pp. 444–456, 2002.
- [48] 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”, *Science, Measurement Technology, IET*, v. 4, n. 3, pp. 177–192, May. 2010. ISSN: 1751-8822. doi: 10.1049/iet-smt.2009.0023.
- [49] BURRUS, C. S. *Introduction to Wavelets and Wavelet Transforms: A Primer*. Rice University, Houston, Texas, Pentice Hall, 1997.
- [50] MITRA, S. K. *Digital Signal Processing - A Computer-Based Approach*. University of California, Santa Barbara, The McGraw-Hill, 1998.
- [51] 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.

- [52] COOLEY, J. W., TUKEY, J. W. “An Algorithm for the Machine Computation of Complex Fourier Series.” *Mathematics of Computation*, v. 19, pp. 207–301, 1965.
- [53] SONG, X., ZHOU, C., HEPBURN, D. M., et al. “Second Generation Wavelet Transform for Data Denoising in PD Measurement”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 14, n. 6, pp. 1531–1537, december 2007. ISSN: 1070-9878. doi: 10.1109/TDEI.2007.4401237.
- [54] GARBOR, D. “Theory of Ccommunication”, *Journal of the Institute of Electrical Engineering*, v. 93, pp. 429–457, 1946.
- [55] HLAWATSCH, F., BOUDREAUX-BARTELS, G. F. “Linear and Quadratic Time-Frequency Signal Representation”, *IEEE Signal Processing Magazine*, v. 4, pp. 21, 1992.
- [56] POLIKAR, R. “The Story of Wavelets”, *IMACS/IEEE CSCC’99 Proceedings*, pp. 5481–5486, 1999.
- [57] VAIDYANATHAN. *Multirate Systems and Filter Banks*. Englewood Cliffs, NJ, Pentice Hall, 1993.
- [58] WILEY, J., SONS. *Signal Analysis: Wavelets, Filter Banks, Time-Frequency Transforms and Applications*. University of Wollongong, Australia, Alfred Mertins, 1999.
- [59] DAUBECHIES, I. “Ten Lectures on Wavelet”, *Society for Industrial and Applied Mathematics*, 1992.
- [60] MALLAT, S. G. “Multifrequency Channel Decompositions of Images and Wavelet Models”, *IEEE Transactions on Acoustics Speech and Signal Processing*, v. 37, pp. 2091–2110, 1989.
- [61] MEYER, Y. “Ondelettes et Fonction Splines”, *Seminare EDP, Ecole Polytechnique*, Dec. 1986.
- [62] COHEN, A., DAUBECHIES, I., FEAUVEAU, J. C. “Biorthogonal Bases of Compactly Supported Wavelets”, *Communications on Pure and Applied Mathematics*, pp. 485–560, 1992.
- [63] VETTERLI, M., HERLEY, C. “Wavelets and Filters Banks: Theory and Design”, *IEEE Transactions on Signal Processing*, v. 40, pp. 2207–2232, 1992.

- [64] DAUBECHIES, I. “The Wavelet Transform, Time-frequency Localization and Signal Analysis”, *IEEE Trans. on Inf Theory*, v. 36, n. 5, pp. 961–1005, Sep. 1990.
- [65] VETTERLI, KOVAEEVIC, J. *Wavelets and Subband Coding*. Englewood Cliffs, NJ, Prentice-Hall, 1995.
- [66] ABRY, P. *Ondelettes et Turbulence. Multirésolutions, Algorithmes de Décomposition, Invariance D'échelles*. Paris, Diderot Arts, 1997.
- [67] COHEN, A. *Ondelettes, Analyses Multirésolution et Traitement Numérique du Signal*. Tese de Doutorado, University of Paris IX, Dauphine, 1992.
- [68] MISITI, M., MISITI, Y., OPPENHEIM, G., et al. *Wavelet Toolbox Users Guide*. The MathWorks, Inc., Mar. 2012.
- [69] KIM, C. H., AGGARWAL, R. “Wavelet transforms in Power Systems. Part II. Examples of Application to Actual Power System Transients”, *Power Engineering Journal*, v. 15, n. 4, pp. 193–202, Aug. 2001. ISSN: 0950-3366. doi: 10.1049/pe:20010404.
- [70] MALLAT, S. G. “A Theory For Multiresolution Signal Decomposition: the Wavelet Representation”, *IEEE Transaction Pattern Anal*, v. 11, pp. 674–693, 1989.
- [71] LI, J., GRZYBOWSKI, S., DU, L., et al. “Extraction of Partial Discharges from Noises by Use of Wavelet and Pulse-Sequence Analysis”. In: *Electrical Insulation and Dielectric Phenomena, 2006 IEEE Conference on*, pp. 656–659, Oct. 2006. doi: 10.1109/CEIDP.2006.312017.
- [72] 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.
- [73] 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.
- [74] HAO, L., LEWIN, P., HUNTER, J., et al. “Discrimination of Multiple PD Sources Using Wavelet Decomposition and Principal Component aAnalysis”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 18,

n. 5, pp. 1702–1711, Oct. 2011. ISSN: 1070-9878. doi: 10.1109/TDEI.2011.6032842.

- [75] 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.
- [76] 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.
- [77] DONOHO, D. L., JOHNSTONE, I. M. “Adapting to Unknown Smoothness via Wavelet Shrinkage”, *J. Amer. Stat. Assoc*, v. 90, pp. 1200–1224, 1995.
- [78] CHANG, S., YU, B., VETTERLI, M. “Adaptive Wavelet Thresholding For Image Denoising and Compression”, *IEEE Trans. Image Process*, v. 9, pp. 1532–1546, 2000.
- [79] MIHCAK, M. K., KOZINTSEV, I., RAMCHANDRAN, K., et al. “Low-complexity Image Denoising Based on Statistical Modeling of Wavelet Coefficients”, *IEEE Signal Process*, v. 6, pp. 3003–303, 1999.
- [80] QU, T., WANG, S., CHEN, H., et al. “Adaptive Denoising Based on Wavelet Thresholding Method”, *6th Intl. Conf. Signal Process*, pp. 120–123, 2002.
- [81] DONOHO, D. L. “De-noising by Soft-Thresholding”, *IEEE Trans. Inf. Theory*, v. 41, pp. 613–627, 1995.
- [82] DONOHO, D. L., JOHNSTONE, I. M. “Ideal Spatial Adaptation by Wavelet Shrinkage”, *Biometrika*, v. 81, pp. 425–455, 1994.
- [83] LI, J., CHENG, C., JIANG, T., et al. “Wavelet De-noising of Partial Discharge Signals Based on Genetic Adaptive Threshold Estimation”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 19, n. 2, pp. 543–549, Apr. 2012. ISSN: 1070-9878. doi: 10.1109/TDEI.2012.6180248.
- [84] STEIN, C. “Estimation of the mean of a multivariate normal distribution”, *Annals of Statistics*, v. 9, pp. 1135–1053, 1981.
- [85] EIBEN, A. E., SMITH, J. E. *Introduction to Evolutionary Computing*. Boston, USA, Springer, 2007.

- [86] ZHANG, X. P., DESAI, M. D. “Adaptive Denoising Based on SURE Risk”, *IEEE Signal Processing Letters*, v. 5, pp. 265–267, 1998.
- [87] 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.
- [88] NASRI, M., NEZAMABADI-POUR, H. “Image Denoising in the Wavelet Domain Using a New Adaptive Thresholding Function”, *Neurocomputing*, v. 72, pp. 1012–1025, 2009.
- [89] ZHANG, X. P. “Thresholding Neural Network For Adaptive Noise Reduction”, *IEEE Trans. Neural Networks*, v. 12, pp. 567584, 2001.
- [90] DARWIN, C. *The Origin of Species*. London, England, Murray, John, 1859.
- [91] JONG, K. A. D. *An Analysis of the Behavior of a Class of Genetic Adaptive Systems*. Tese de Doutorado, University of Michigan, 1975.
- [92] HOLLAND, J. H. “Genetic Algorithms and the Optimal Allocation of Trials”, *SIAM J. of Computing*, v. 2, pp. 88–105, 1973.
- [93] KOZA, J. R. *Genetic Programming*. London, England, Cambridge, 1992.
- [94] LIANG, Y., LEUNG, K.-S., LEE, K.-H. “A Novel Binary Variable Representation for Genetic and Evolutionary Algorithms”, *IEEE Congress on Evolutionary Computation*, pp. 536–543, 2006.
- [95] ZHANG, L., CHANG, H., XU, R. “Equal-width Partitioning Roulette Wheel Selection in Genetic Algorithm”, *Conference on Technologies and Applications of Artificial Intelligence*, pp. 62–67, 2012.
- [96] TANG, K. S., MAN, K. F., KWONG, S., et al. “Genetic Algorithms and Their Applications”, *IEEE Signal Processing Magazine*, v. 13, n. 6, pp. 22–37, 1996.
- [97] GOLDBERG, D. E. “Genetic Algorithm in Search, Optimization, and Machine Learning”, *Addison Wesley Publishing Company*, 1989.
- [98] WHITLEY, D. “Using Reproductive Evaluation to Improve Genetic Search and Heuristic Discovery”, *Proc. 2nd Int. Conf. Genetic Algorithms*, pp. 108–115, 1987.
- [99] HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. MIT Press, MA, USA, Cambridge, 1992.

- [100] EIBEN, A. E., AARTS, E. H. L., VAN HEE, K. M. “Global Convergence of Genetic Algorithms: A Markov Chain Analysis”, *Lecture Notes in Computer Science*, v. 496, pp. 4–12, 1991.
- [101] DE JONG, K. A., SARMA, J. “Generation gaps revisited”, *Foundations of Genetic Algorithms*, v. 2, pp. 19–28, 1992.
- [102] DAWKINS, R. “The selfish gene”, *Oxford University Press*, 1976.
- [103] MOSCATO, P. A. *On Evolution, Search, Optimization, Genetic Algorithms and Material Arts: Towards Memetic Algorithms*. Relatório técnico, Tech. Rep. Caltech Concurrent Computation Program Report, 826, Caltech, Pasadena, California, 1989.
- [104] Spring (Ed.). *Distributed Co-evolutionary Genetic Algorithms for Multi-criteria and Multi-constraint Optimisation*, Heidelberg, New York, 1994. AISB Workshop, LNCS.
- [105] CARVALHO, A. T. D. *Redução de Ruídos de Medição de DP em Equipamentos de Alta Tensão Baseada na Análise Multiresolução de Sinais*. Tese de Doutorado, Doctoral degree qualifying examination, Federal University of Rio de Janeiro (UFRJ), Dec. 2012.
- [106] KEPPEL, G., ZEDECK, S. “Data Analysis for Research Designs-Analysis of Variance and Multiple Regression/Correlation Approaches”, *W. H. Freeman and Company*, 1989.
- [107] AMORIM, H., LEVY, A., CARVALHO, A. T. D., et al. “Medições de Descargas Parciais no Campo - Aspectos Práticos em Geradores e Motores”, *Cigrè*, v. 13, Maio 2009.
- [108] AMORIM JR., H. P., CARVALHO, A. T. D., CUNHA, C. F. F. D. C., et al. “On-Site Measurements of Partial Discharges Through Tap of the Bushings Brazilian Experience in Power Transformers”, *Solid Dielectrics (ICSD), 2013 IEEE International Conference on*, pp. 1020–1023, Jun./Jul. 2013. ISSN: 2159-1687.
- [109] SUN, C., LUO, B., DU, L., et al. “Method of Directional Difference Balance to Suppress Electromagnetic Interference in On-line Monitoring Partial Discharge in Transformers”, *Proceedings of the CSEE*, v. 18, pp. 340–344, 1998.
- [110] VELOSO, F. C., SILVA, L. E. B., NORONHA, I., et al. “Detection of Partial Discharge in Power Transformers Using Rogowski Coil and Multiresolu-

- tion Analysis”, *Brazilian Power Electronics Conference - COBEP*, pp. 1006–1110, 2009.
- [111] HERNANDEZ, V. R. G. C. *Evolution of Partial Discharge Waveshapes in Spherical Cavities Using Ultra Wide Band Techniques*. Phd, Thesis University of Manchester, 1994.
- [112] MORSHUIS, P. “Assessment of Dielectric Degradation by Ultrawide-band PD Detection”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 2, n. 5, pp. 744–760, Oct. 1995. ISSN: 1070-9878. doi: 10.1109/94.469971.
- [113] CAMPBELL, S. R., STONE, G. C., SEDDING, H. G. “Application of Pulse Width Analysis to Partial Discharge Detection”, *IEEE International Symposium on Electrical Insulation*, pp. 345–348, 1992.
- [114] CAMPBELL, S. R., STONE, G. C., SEDDING, H. G. “Characteristics of Partial Discharge Pulses from Operating Rotating Machines”, *IEEE International Symposium on Electrical Insulation*, pp. 229–332, 1994.
- [115] DEJEAN, H., DEJEAN, P. P. F., GOLDMAN, M. “On Site Very High Frequency PD Pulse Measurements on Full Size Rotating Machine Stator for Discharge Type Recognition”, *IEEE International Conference on Partial Discharge*, pp. 66–67, 1993.
- [116] JUDD, D., FARISH, O., HAMPTON, B. F. “The Excitation of UHF Signals by Partial Discharges in GIS”, *IEEE Trans. Dielect. Electr. Insul.*, v. 3, pp. 213–228, Oct. 1996.
- [117] SHETTY, P. K., SRIKANTH, R., RAMU, T. S. “Modeling and On-line Recognition of PD Signal Buried in Excessive Noise”, *Signal Process*, pp. 2389–2401, 2004.
- [118] CAVALLINI, A., CONTIN, A., MOMTANARI, G. C. “Advanced PD Inference in On-field Measurement: Part I: Noise Rejection”, *IEEE Trans. Dielect. Electr. Insul.*, v. 10, n. 2, pp. 216–224, Apr. 2003.
- [119] POMPILI, M., MAZZETTI, C., BARTNIKAS, R. “Simultaneous Measurements of PD in Oil Using Conventional Narrow Band and Ultra wide Band Detection Systems”, *International Conference on Conduction and Breakdown in Dielectric Liquids*, v. 12, pp. 185–188, Jul. 1996.

Apêndice A

Circuitos de Medição de DP

Conforme mencionado na Seção 2.1, o fenômeno de DP pode se manifestar de diversas maneiras, seja em forma de calor, luz, som, reação química e radiação eletromagnética, portanto o mesmo pode ser detectado por diferentes métodos. Obviamente cada método possui suas vantagens e desvantagens, o que afeta diretamente o nível de confiabilidade do diagnóstico a respeito das DP ocorrendo em um objeto sob teste. O método mais empregado, por ser mais sensível, é o método elétrico que permite detectar os pulsos de corrente que aparecem nos terminais do equipamento em teste, em função da ocorrência de descargas no interior das cavidades contidas no isolamento do objeto avaliado.

Para a adequada medição em laboratório de descargas parciais em tensão alternada, a norma IEC 60270 [10] faz menção a três circuitos básicos que se distinguem pelo arranjo da impedância de medição Z_m . No circuito mostrado na Fig. A.1, o objeto sob ensaio C_a é posto em paralelo com um capacitor de acoplamento C_k , que proporciona um caminho de baixa impedância para altas frequências, em série com a impedância de medição Z_m , através da qual os sinais de DP serão detectados e transmitidos por meio de um cabo apropriado (coaxial ou fibra ótica) até o sistema de aquisição. Um Filtro (no caso representado por um indutor) é utilizado para bloquear ruídos eletromagnéticos de alta frequência oriundos da fonte de alta tensão que alimenta o equipamento em teste. Também possui a finalidade de prevenir um curto circuito para o sinal de DP através da fonte de alta tensão. Um sinal de sincronismo é obtido de um divisor de tensão capacitivo formado pelos capacitores C_1 e C_2 , o que permite ao sistema detectar o ângulo de fase em que cada pulso de DP ocorre. Em alguns casos, quando da inexistência do divisor, o sinal pode ser adquirido a partir da fonte de 110 V ou 220 V da própria alimentação do sistema de medição, desde que sejam respeitados os limites de segurança dos equipamentos e das pessoas. Entretanto, a maneira mais eficiente de adquirir um sinal de referência

é através da própria impedância de medição [107].




Figura A.1: Circuito de medição de DP com impedância de medição Z_m em série com capacitor de acoplamento C_k .

Outro circuito aplicado na medição de DP é ilustrado na Fig. A.2, no qual Z_m é posto em série com o condutor de aterramento do objeto testado. Seu uso também é indicado quando a capacitância C_a é muito alta. A desvantagem deste circuito é que se faz necessário o uso de uma interrupção da conexão do terra do equipamento em teste, o que na prática nem sempre pode ser realizado. Além do mais a tensão nos terminais do sistema de medição pode se elevar a níveis perigosos, caso o objeto em teste entre em curto circuito, podendo danificar o sistema e por em risco a vida daqueles que o operam.




Figura A.2: Circuito de medição DP com impedância de medição Z_m em série com o objeto de teste C_a .

Caso a medição seja muito afetada por ruídos de fonte externa, o circuito de ponte balanceada, mostrado na Fig. A.3, pode ser empregado. Este circuito faz uso de um ramo de referência composto por um objeto C_{a2} em série com uma impedância Z_{m2} , que conduz o sinal DP até a entrada negativa $-In$ de um amplificador diferencial interno ao sistema de medição, e em paralelo está o ramo sob teste, formado pelo objeto a ser testado C_{a1} em série com uma impedância Z_{m1} , que por

sua vez conduz o sinal para entrada positiva $In+$ do amplificador. As impedâncias Z_{m1} e Z_{m2} podem ser balanceadas e os ruídos externos de modo comum podem ser cancelados por meio do amplificador diferencial, portanto é primordial que o circuito seja projetado de maneira simétrica para que os sinais ruidosos cheguem ao mesmo tempo na entrada do amplificador, permitindo que sejam cancelados e assim somente os sinais de DP, que chegarão em instantes distintos em ambas entradas, serão amplificados e processados pelo sistema de medição. Além disso, o objeto de referência C_{a2} deve ter geometria e capacitância equivalentes ao do objeto testado.

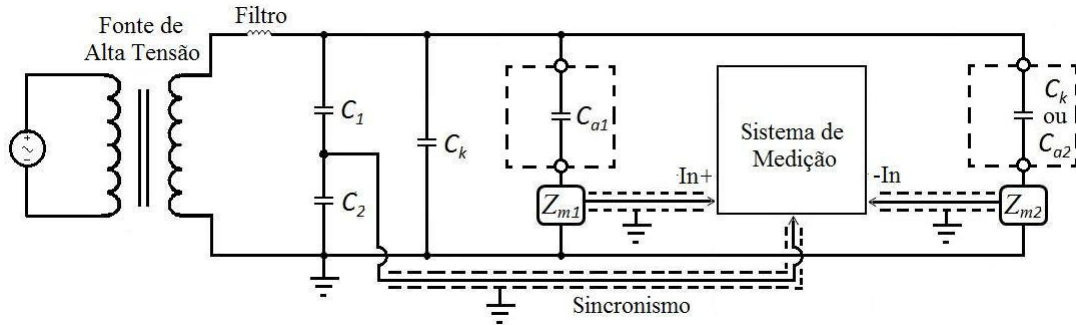


Figura A.3: Circuito de medição de DP de ponte balanceada.

Em medições em campo onde o equipamento não pode ser retirado de operação, o papel da fonte de alta tensão é exercido pela própria tensão de alimentação oriunda da rede e não se pode fazer uso do Filtro aplicado nos circuitos de ensaio em laboratório.

A.1 Capacitor de Acoplamento e Impedância de Medição

O capacitor de acoplamento C_k é inserido nos circuitos de medição para atenuar a magnitude 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 . Portanto, para uma medição de boa qualidade, é preciso que o capacitor C_k tenha baixa indutância e não emita uma grande quantidade de sinais de DP, para que não insira distorções nos sinais de DP oriundos de C_a . Além disso, seu valor deve ser alto o suficiente para evitar influência de capacitâncias parasitas existentes no circuito, o que poderia atenuar os pulsos de DP. Recomenda-se que $C_k/C_a > 0.1$ [13].

A impedância Z_m (também denominada de quadripólo) faz a conversão do pulso de corrente DP em um pulso de tensão equivalente, para que este possa ser processado no sistema de medição. Normalmente é formada por um circuito ressonante

RLC que pode ser projetado em diferentes configurações, dependendo do equipamento em análise, ou por um circuito RC. Um exemplo de impedância é mostrado na Fig. A.4, em que R_m é o resistor de medição, C_m é a capacitor de medição, L_m é o indutor *shunt* e Sc_1 e Sc_2 são supressores de correntes inseridos no circuito como uma proteção para uma possível sobretensão. Na Fig. A.4 verificamos que o uso de C_k em série com Z_m forma um filtro passa altas, atenuando consideravelmente a alta tensão aplicada e permitindo a passagem do sinal de DP, já que este ocorre em alta frequência. Observe também que é possível obter o sinal de sincronismo diretamente pela impedância de medição.

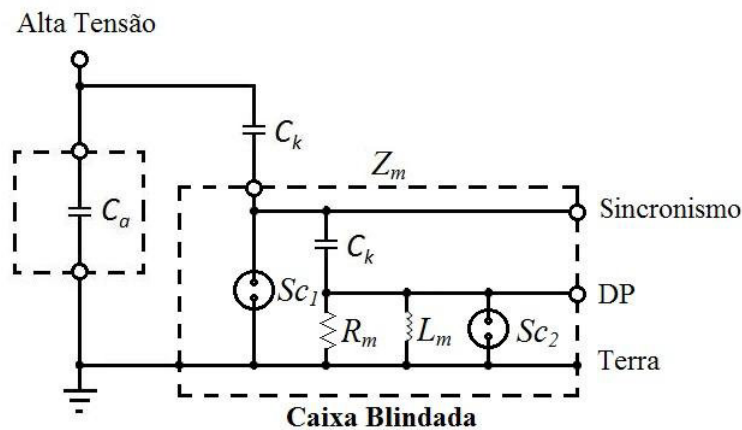


Figura A.4: Circuito equivalente de acoplamento para medição de DP.

Circuitos detectores do tipo RLC correspondem a sistemas de detecção de banda estreita, portanto com maior imunidade a ruídos, mas podem causar erros de integração para pulsos ocorrendo quase simultaneamente. Já os circuitos do tipo RC provêm uma medição em banda mais larga, com banda passante normalmente limitada pelos parâmetros parasitas do circuito [44].

A impedância pode ser formada somente com R_m , mas são necessários cuidados, pois caso haja harmônicos ou outros sinais de maior frequência com magnitudes elevadas pode ocorrer sobretensão na saída de Z_m , o que danificaria o sistema de medição.

É indicado que as conexões entre os terminais da impedância com o capacitor de acoplamento e com o objeto em teste sejam mantidas tão próximas quanto possível para minimizar efeitos na banda passante do circuito de detecção [10].

Normalmente o circuito ilustrado na Fig. A.1 é o mais empregado para medição de DP e, dependendo do equipamento a ser avaliado, podem ocorrer variações nos tipos de impedâncias de medição ou capacitores de acoplamento aplicados, mas via de regra o arranjo do circuito é similar aos descritos pela norma IEC 60270 [10].

Alguns desses arranjos serão discutidos nas subseções que se seguem.

A.2 Circuito para Medição de Transformadores

Para medição de transformadores se faz uso do circuito exposto na Fig. A.5. Podemos notar que o mesmo é análogo ao circuito da Fig. A.1. Entretanto, para captar os sinais de sincronismo e de DP não há a necessidade do uso de um circuito divisor de tensão e de um capacitor de acoplamento externos ao objeto em teste, pois ambos papéis serão cumpridos pelos capacitores C_k e C_m no interior da bucha do transformador. Para se ter acesso a esses sinais basta interligar a saída do tap da bucha com a impedância de medição Z_m do tipo RC ou RLC, que por sua vez será interligada ao sistema de medição. A impedância Z_m deve ser projetada de modo que forneça tanto o sinal de sincronismo, quanto o sinal de DP [108].

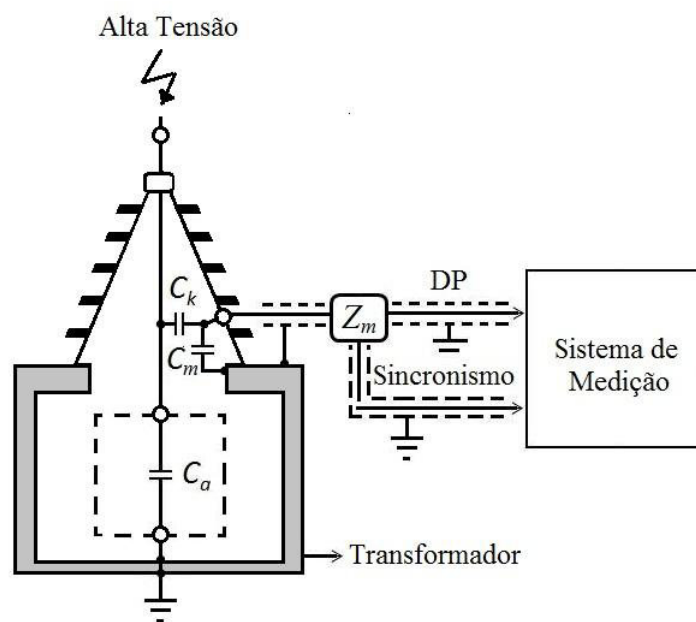


Figura A.5: Circuito de medição de DP para transformadores.

É possível que seja utilizada uma impedância de medição a mais entre o transformador e o cabo de aterramento, a fim de permitir diferenciar entre os ruídos gerados por pulsos *corona* e os sinais de DP no interior do transformador em teste, pois o ruído *corona* gera pulsos que fluem pelas impedâncias na mesma direção (fornecem pulsos com mesma polaridade) enquanto que os sinais de DP fluem em direções contrárias (fornecem pulsos de polaridades opostas) [71, 109]. A impedância utilizada no cabo de aterramento pode ser um transformador de corrente de alta frequência ou uma bobina de Rogowski [110].

A.3 Circuito para Medição de Subestações Isoladas a Gás (GIS)

Em GIS o arranjo do circuito de medição típico é mostrado no circuito da Fig. A.6. Observe que o capacitor de acoplamento C_k é uma cinta capacitiva, como a ilustrada na Fig. A.7(a), também podemos usar a saída de Ultra Alta Frequência (*Ultra High Frequency* - UHF) existente no próprio tubo que envolve o gás isolante SF₆ e o condutor, conforme mostrado na Fig. A.7(b). Nessa configuração, não há necessidade de se empregar uma impedância de medição.

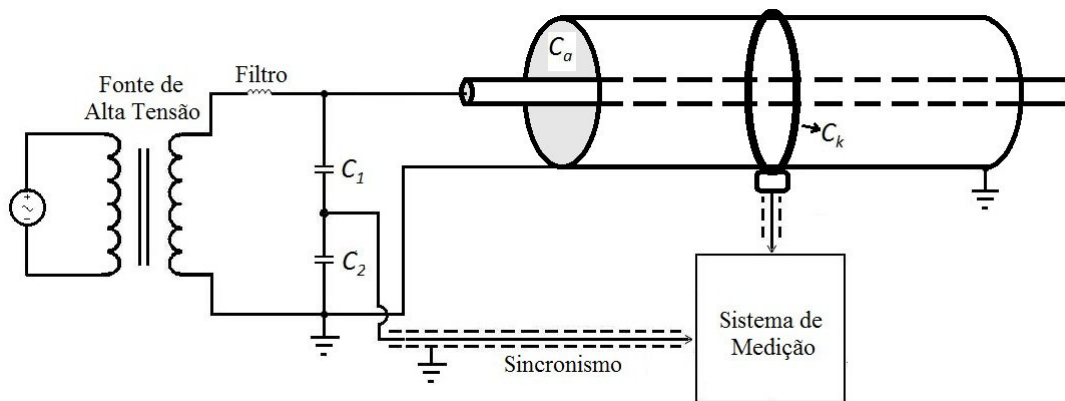



Figura A.6: Circuito de medição DP para GIS.



(a) Cinta Capacitiva.



(b) Saída UHF.

Figura A.7: Tipos de sensores (capacitores de acoplamento C_k) aplicados na medição de DP em GIS.

A.4 Circuito para medição de Transformadores de Corrente, Transformadores de Potência (TP) e Pararraio

Na medição de TC, TP e PR a impedância Z_m consiste de um transformador de corrente de alta frequência ou uma bobina de Rogowski inserida no cabo de aterramento do equipamento em teste [111], conforme ilustrado na Fig. A.8, o que garante uma isolamento galvânica entre o sistema de medição e o circuito de alta tensão, proporcionando uma maior segurança durante os testes.



Figura A.8: Medição de DP em TC utilizando um transformador de corrente de alta frequência.

A.5 Sistemas de Medição de DP

O filtro passa-altas formado por C_k e Z_m faz com que os pulsos de DP capturados sejam diferenciados. Para que o sistema possa realizar a avaliação da carga aparente de forma adequada, se faz necessário integrar os sinais obtidos.

A avaliação da carga aparente é baseada no processo de quase-integração. Segundo [10] a integração do sinal pode ser feita por meio de um filtro passa-bandas sintonizado em uma faixa na qual a amplitude do espectro de frequência do pulso DP é aproximadamente constante. Na Fig. A.9 a banda passante do sistema de medição (B) está localizada no interior da banda coberta pelo espectro de frequência do pulso de DP (A), sendo f_1 e f_2 as frequências de limite inferior e superior (localizadas no ponto em que a magnitude do ganho do filtro corresponde a -6 dB) respectivamente.




Figura A.9: Princípio de quase-integração de pulsos DP.

O filtro fornecerá um pulso de tensão com valor de pico proporcional ao pulso de corrente no tempo, representando a carga aparente. Outro detalhe é que a duração do pulso de saída será muito maior que a do pulso DP de entrada. Para tanto, o processo de quase-integração é válido somente para frequências de limite superior f_2 abaixo de 500 kHz.

A norma IEC 60270 [10] classifica os instrumentos de medição de DP em banda larga, banda estreita e banda ultra larga, os quais serão discutidos nas subseções a seguir.

A.6 Instrumentos de Banda Larga

Para que seja classificado como instrumento de medição de banda larga, a impedância de transferência do sistema, levando em conta a combinação de diferentes dispositivos acoplados com o sistema de medição, deve apresentar largura de banda $\Delta f = f_2 - f_1$ dentro dos valores recomendados pela norma IEC 60270 [10]:

$$30 \text{ kHz} \leq f_1 \leq 100 \text{ kHz} \quad (\text{A.1})$$

$$f_2 \leq 500 \text{ kHz} \quad (\text{A.2})$$

$$100 \text{ kHz} \leq \Delta f \leq 400 \text{ kHz} \quad (\text{A.3})$$

A resposta do instrumento de banda larga a um pulso de corrente de DP é uma oscilação amortecida e com a duração do pulso de saída bem superior à do pulso de entrada. Ainda assim o sistema é capaz de identificar a polaridade dos pulsos e ao aplicar circuitos integradores é possível obter pulsos com área proporcional à área do sinal de entrada, fornecendo assim uma medida para carga aparente. O tempo de resolução ao pulso para pulsos consecutivos é menor que $10 \mu\text{s}$.

Apesar de ser designado como banda larga, tal sistema consegue cobrir apenas uma estreita faixa do espectro de frequência coberto pelos pulsos de DP, o qual pode cobrir amplas faixas (na ordem de MHz e até mesmo GHz) [13, 19].

A.7 Instrumentos de Banda Estreita

Instrumentos de banda estreita possuem uma pequena largura de banda e sua frequência central f_m pode ser excursionada ao longo de uma ampla faixa de frequência. A norma IEC 60270 [10] recomenda valores para Δf e f_m , nas seguintes faixas:

$$9 \text{ kHz} \leq \Delta f \leq 30 \text{ kHz} \quad (\text{A.4})$$

$$50 \text{ kHz} \leq f_m \leq 1 \text{ kHz} \quad (\text{A.5})$$

Um indicativo de que o sistema de medição é de banda estreita é o fato de que a banda passante é bem menor que a frequência central. O instrumento também produz uma resposta oscilatória amortecida lenta ao pulso de entrada, com valores de pico (positivo e negativo) proporcionais à carga aparente. O tempo de resolução ao pulso é tipicamente acima de $180 \mu\text{s}$.

A desvantagem de tal sistema é que a resolução a pulsos subsequentes é baixa e, devido à sua lenta resposta ao impulso DP, podem ocorrer erros de medição por excitação de pulsos refletidos ou oscilantes. A principal vantagem deste é que são menos suscetíveis a ruídos, podendo eliminar de forma satisfatória grande parte desse ruídos através do ajuste da frequência central.

A.8 Instrumentos de Banda Ultra Larga

Aplicando os dispositivos de acoplamento adequados e instrumentos que possam prover bandas passantes elevadas, pode-se medir DP em equipamentos com parâmetros distribuídos, como cabos, máquinas rotativas e GIS, que em geral apresentam alguns pulsos de DP mais rápidos, ou seja, em faixas de frequências mais elevadas, ou ainda obter informações da origem ou da física de fenômenos de DP.

A medição de DP em UHF tem sido reconhecida como uma importante ferramenta na detecção de faltas em GIS, cabos e geradores, devido a apresentarem alta sensibilidade [76, 112–116]. Medições para bandas de UHF são inevitavelmente mais suscetíveis a interferências, como ruído branco e colorido, entre outros [45, 117, 118].

Em [119] foram realizados experimentos de detecção de pulsos de DP em líquidos isolantes com tempo de subida muito rápido, estendendo-se a faixa de GHz. Utilizando um circuito convencional de banda larga o autor concluiu que o mesmo se mostra capaz de detectar pulsos mais rápidos ocorrendo em baixa intensidade.

A norma IEC 60270 não fornece nenhuma recomendação para este tipo de investigação, pois segundo esta tais métodos ou instrumentos, em geral, não quantificam diretamente a carga aparente dos pulsos de corrente DP.

No entanto, com o progresso tecnológico, grandes avanços têm sido obtidos na área eletrônica destinada à aquisição de dados e na área de processamento de sinais por meio do uso de computadores, dando origem a sistemas capazes de adquirir informações em bandas de frequência na faixa de GHz, o que permite a eliminação de estágios de pré-processamento analógico empregados no processo de quase-integração e detecção de pico. Portanto, é possível digitalizar a forma de onda dos pulsos de DP sem a necessidade do uso dos circuitos mencionados, os quais causam grande alteração da forma de onda obtida pela impedância de medição. Isto abre portas para exploração de novas técnicas de processamento digital no que diz respeito à filtragem dos dados, identificação da fonte de origem dos pulsos e classificação dos tipos de defeitos existentes em um objeto sob análise, podendo assim aumentar a sensibilidade do sistema ao lidar com ambientes muito ruidosos.