



**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
CAMPUS CURITIBA**

GERÊNCIA DE PESQUISA E PÓS-GRADUAÇÃO

**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
E INFORMÁTICA INDUSTRIAL - CPGEI**

RODRIGO JARDIM RIELLA

**PROPOSTAS DE TÉCNICAS PARA
CARACTERIZAÇÃO E CLASSIFICAÇÃO
AUTOMÁTICA DE SONS PULMONARES
ADVENTÍCIOS**

TESE DE DOUTORADO

**CURITIBA
OUTUBRO DE 2008**

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial

TESE
apresentada à UTFPR
para obtenção do título de
DOUTOR EM CIÊNCIAS

por

RODRIGO JARDIM RIELLA

**PROPOSTAS DE TÉCNICAS PARA CARACTERIZAÇÃO E
CLASSIFICAÇÃO AUTOMÁTICA DE SONS PULMONARES
ADVENTÍCIOS**

Banca Examinadora

Presidente e Orientador:

Prof. Dr. Percy Nohama UTFPR

Co-orientador:

Prof. Dr. Joaquim Miguel Maia UTFPR

Examinadores:

Prof. Dr. Eduardo Tavares Costa UNICAMP

Profa. Dra. Elisângela Ferretti Manffra PUCPR

Prof. Dr. Henrique Takachi Moriya USP

Prof. Dr. Hugo Vieira Neto UTFPR

Curitiba, Outubro de 2008

Rodrigo Jardim Riella

**PROPOSTAS DE TÉCNICAS PARA CARACTERIZAÇÃO E
CLASSIFICAÇÃO AUTOMÁTICA DE SONS PULMONARES
ADVENTÍCIOS**

**Tese apresentada ao Programa de Pós-Graduação em
Engenharia Elétrica e Informática Industrial da
Universidade Tecnológica Federal do Paraná, como
requisito parcial para a obtenção do título de “Doutor
em Ciências” – Área de Concentração: Engenharia
Biomédica.**

Orientador: Prof. Dr. Percy Nohama

Co-Orientador: Prof. Dr. Joaquim Miguel Maia

Curitiba

2008

Dedico este trabalho ao meu pai Ambires Cecílio Machado Riella (*in memorian*) que durante todo o nosso tempo de convívio me orientou e incentivou a nunca desistir de meus sonhos, por mais dura que seja a caminhada para a sua realização. À minha mãe Irma Jardim Riella por todo apoio e incentivo, mesmo nas horas mais difíceis. À minha esposa Mady Sonda Riella, por todo o amor e compreensão nos momentos em que não foi possível estar presente quando necessário. Ao Prof. Álvaro Luiz Stelle (*in memorian*) por toda orientação e conhecimento dispensados desde a graduação até o desenvolvimento deste trabalho.

À Deus, por ter me dado, além do dom da vida, toda inspiração e força para realizar mais esse passo na minha vida.

AGRADECIMENTOS

Ao meu orientador, Prof. Dr. Percy Nohama, pela confiança depositada e orientação em todos estes anos de trabalho, desde a iniciação científica até a conclusão desta tese de doutorado.

Ao co-orientador Prof. Dr. Joaquim Miguel Maia que, mesmo tomando conhecimento deste trabalho já durante o seu desenvolvimento, contribuiu em muito com o seu aperfeiçoamento orientando a consolidação das metodologias desenvolvidas.

Ao colega de curso Dr. Paulo Roberto Stefani Sanches, pelo auxílio na obtenção de parte dos sons pulmonares, imprescindíveis para a validação das metodologias propostas neste trabalho.

À empresa canadense PixSoft Inc, por permitir o uso dos sons pulmonares contidos em seu *software* “RALE Lung Sounds” no desenvolvimento deste trabalho.

Ao Programa de Pós Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná por, além de permitir o acesso ao curso, oferecer bolsa para a sua realização.

PROPOSTAS DE TÉCNICAS PARA CARACTERIZAÇÃO E CLASSIFICAÇÃO AUTOMÁTICA DE SONS PULMONARES ADVENTÍCIOS

RESUMO

Nesta tese, descrevem-se técnicas matemáticas visando a caracterização e classificação de sons pulmonares adventícios, por meio de sua análise espectral. Para alcançar este objetivo, desenvolveu-se duas novas metodologias, que utilizam Análise em Multiresolução, implementada a partir da Transformada *Wavelet* Discreta. A primeira metodologia desenvolvida é utilizada para classificar automaticamente os sons pulmonares em quatro grupos: sons normais e sons adventícios contínuos e descontínuos, notificando também o caso de ocorrência das duas anomalias no mesmo ciclo respiratório. Durante o processamento, o ciclo respiratório é decomposto até seu décimo nível, calculando a energia dos coeficientes detalhe em cada nível de decomposição, assim como a energia dos coeficientes de aproximação. Deste cálculo, obtém-se uma curva de variação da energia em relação ao nível de decomposição, sendo que as curvas obtidas se mostraram curvas características em relação ao tipo de som adventício. Tais curvas são aplicadas a uma simulação de Rede Neural Artificial de Função de Base Radial, que atua como classificador entre os quatro grupos. Esta técnica foi testada utilizando dez *wavelets*, sendo treinadas com redes neurais para cada uma. Os melhores resultados apresentaram índice de acerto entre 88% e 92,36% para o conjunto de teste, em um total de 275 ciclos respiratórios. A segunda metodologia, denominada Filtragem por Análise Espectral Seletiva, decompõe o som pulmonar até seu quarto nível, calculando o espectro dos coeficientes de aproximação e, baseado na componente de frequência preponderante, calcula um filtro FIR multibanda. Este filtro é utilizado para eliminar todas as componentes espectrais dos coeficientes de aproximação, com exceção do mais proeminente. Após o procedimento de filtragem, o sinal é recomposto através de reconstrução *wavelet*. Para a avaliação de seus resultados, foram testadas dez *wavelets* no processo de decomposição e reconstrução. Para a *wavelet* que apresentou melhores resultados, obteve-se uma atenuação dos sons cardíacos da ordem de 6 dB em relação aos sons adventícios que ocorrem na mesma faixa espectral, utilizando a Densidade Espectral de Potência dos sinais como referência. Esta metodologia mostrou resultados satisfatórios na tarefa de eliminar tanto os ruídos relativos ao fluxo aéreo normal nas vias aeríferas quanto os sons cardíacos, mantendo somente os sons adventícios nas gravações de sons pulmonares.

Palavras Chave:

Sons Pulmonares, Transformada *Wavelet*, Redes Neurais Artificiais, Filtragem Digital.

PROPOSAL OF TECHNIQUES FOR CHARACTERIZATION AND AUTOMATIC CLASSIFICATION OF ADVENTITIOUS LUNG SOUNDS

ABSTRACT

In this thesis, the investigation of methods to characterize and classify adventitious lung sounds by spectral analysis is described. To accomplish this task, two novel techniques were developed, through Multiresolution Analysis, based on the Discrete Wavelet Transform. The first technique aims to detect abnormal sounds and classify them into four groups: normal, continuous and discontinuous adventitious lung sounds, also notifying their simultaneous occurrence. During its processing, the respiratory cycle signal is decomposed up to its tenth level, and the energy present in the detail and approximation coefficients for each decomposition level is calculated, resulting on a curve of energy versus decomposition level. The resulting curves show different signatures for each kind of adventitious sound. These signatures are used as data source for a classifier system based on Radial Basis Function Artificial Neural Networks. This technique was tested for ten different wavelets, training a hundred neural networks for each wavelet, totalizing a thousand neural networks trained. The best performance rates for each wavelet reach values from 88% to 92.36% for the test group, in a set of 275 respiratory cycles. In the second technique, named Filtering by Selective Spectral Analysis, the lung sound is decomposed until its fourth level, the approximation coefficients spectra are calculated and, based on the highest frequency component found on those coefficients, a multiband FIR filter is determined. This filter is used to eliminate all frequency components in the approximation coefficients except the highest one. After the filtering procedure, the signal is recomposed by wavelet reconstruction. In order to evaluate the proposed technique, ten wavelets were used in the decomposition and reconstruction stages. The wavelet which presented the best performance attenuated heart sounds 6 dB more than the adventitious sounds that occur in the same spectral band. For measuring this attenuation, the Power Spectral Density was used. This procedure showed satisfactory results, eliminating the normal airflow noise and cardiac sounds, leaving only the adventitious sounds in the recorded lung sounds.

Keywords:

Lung Sounds, Wavelet Transform, Artificial Neural Networks, Digital Filtering.

SUMÁRIO

RESUMO	ix
ABSTRACT	xi
LISTA DE FIGURAS	xvi
LISTA DE TABELAS	xx
LISTA DE ABREVIATURAS E SIGLAS	xxi
CAPÍTULO 1: INTRODUÇÃO	1
1.1 MOTIVAÇÕES.....	1
1.2 OBJETIVOS.....	3
1.3 ORGANIZAÇÃO DA TESE.....	4
CAPÍTULO 2: ANATOMIA E FISIOLOGIA DO SISTEMA RESPIRATÓRIO	7
2.1 ANATOMIA TORÁCICA.....	7
2.1.1 Caixa torácica.....	7
2.1.2 Vias aeríferas.....	9
2.1.3 Pulmões.....	10
2.2 MECÂNICA RESPIRATÓRIA.....	13
2.2.1 Volumes e capacidades pulmonares.....	16
2.3 AUSCULTA PULMONAR.....	18
2.4 SONS PLEUROPULMONARES.....	20
2.4.1 Sons respiratórios normais.....	20
2.4.1.1 Murmúrio vesicular.....	21
2.4.1.2 Som traqueal.....	22
2.4.1.3 Respiração brônquica.....	22
2.4.1.4 Respiração broncovesicular.....	22
2.4.2 Sons respiratórios adventícios.....	23
2.4.2.1 Descontínuos.....	23
2.4.2.2 Contínuos.....	24
2.4.3 Análise visual dos sons pulmonares.....	26
CAPÍTULO 3: TÉCNICAS DE ANÁLISE ESPECTRAL DE SINAIS	27
3.1 TRANSFORMADA DE FOURIER.....	27
3.2 TRANSFORMADA DISCRETA DE FOURIER (DFT) e TRANSFORMADA RÁPIDA DE FOURIER (FFT).....	29
3.3 TRANSFORMADA DE FOURIER DE CURTA DURAÇÃO E ESPECTROGRAMA.....	31
3.4 TRANSFORMADA <i>WAVELET</i> EM COMPARAÇÃO À STFT.....	34
3.5 TRANSFORMADA <i>WAVELET</i> CONTÍNUA (CWT).....	38
3.6 TRANSFORMADA <i>WAVELET</i> DISCRETA (DWT).....	39
3.7 FAMÍLIAS DE FUNÇÕES <i>WAVELET</i>	44
3.7.1 <i>Wavelets</i> de Daubechies.....	44
3.7.2 <i>Wavelet</i> Meyer.....	45
3.7.3 Coiflets.....	48
3.7.4 Symlets.....	48
3.7.5 <i>Wavelets</i> Biortogonais.....	50

CAPÍTULO 4: REDES NEURAIS ARTIFICIAIS	53
4.1 MODELO DE UM NEURÔNIO.....	54
4.2 ESTRUTURAS DE REDES NEURAIS ARTIFICIAIS.....	56
4.2.1 Redes de camada simples.....	57
4.2.2 Redes de múltiplas camadas.....	57
4.3 TREINAMENTO DE REDES NEURAIS ARTIFICIAIS.....	59
4.3.1 A retropropagação do erro.....	60
4.4 REDES NEURAIS DE FUNÇÃO DE BASE RADIAL.....	63
4.4.1 Treinamento das redes neurais RBF.....	65
CAPÍTULO 5: FERRAMENTAS E TÉCNICAS DE DESENVOLVIMENTO	67
5.1 FORMATOS E BIBLIOTECAS PARA ARQUIVOS DE ÁUDIO E IMAGEM.....	67
5.2 GRAVAÇÕES DE SONS PULMONARES.....	69
5.3 PLATAFORMAS DE DESENVOLVIMENTO.....	70
5.4 NORMALIZAÇÃO DAS GRAVAÇÕES DIGITAIS DOS CICLOS RESPIRATÓRIOS.....	71
5.5 COMPUTAÇÃO DOS ESPECTROGRAMAS.....	74
CAPÍTULO 6: AVALIAÇÃO DE TÉCNICAS DE PROCESSAMENTO PARA ANÁLISE DE SONS PULMONARES	77
6.1 INTRODUÇÃO.....	77
6.2 AVALIAÇÃO DOS SONS RESPIRATÓRIOS UTILIZANDO ESPECTROGRAMAS.....	78
6.2.1 Espectrogramas de Ciclos Respiratórios com Sibilos.....	78
6.2.2 Espectrogramas de Ciclos Respiratórios com Ronco.....	79
6.2.3 Espectrogramas de Ciclos Respiratórios com Estridor.....	81
6.2.4 Espectrogramas de Ciclos Respiratórios com Estertores Finos e Grossos.....	82
6.2.5 Considerações Sobre a Análise de Sons Pulmonares Empregando Espectrogramas.....	84
6.3 AVALIAÇÃO DOS SONS RESPIRATÓRIOS POR TRANSFORMADA WAVELET CONTÍNUA.....	85
6.3.1 Escalogramas dos Sons Respiratórios Normais.....	86
6.3.2 Escalogramas dos Sons Respiratórios Contendo Anomalias Contínuas.....	88
6.3.3 Escalogramas dos Sons Respiratórios Contendo Anomalias Descontínuas.....	91
6.3.4 Considerações Sobre a Análise de Sons Pulmonares Empregando a Transformada Wavelet Contínua.....	93
CAPÍTULO 7: CARACTERIZAÇÃO E CLASSIFICAÇÃO DE SONS PULMONARES EMPREGANDO DWT E REDES NEURAIS RBF	95
7.1 AVALIAÇÃO DOS SONS PULMONARES ATRAVÉS DA DWT.....	95
7.2 CARACTERIZAÇÃO DOS SONS ADVENTÍCIOS ATRAVÉS DA DWT.....	98
7.3 CLASSIFICAÇÃO ATRAVÉS DE SIMULAÇÃO REDES NEURAIS RBF.....	107
7.3.1 Treinamento das simulações de redes neurais RBF.....	109
7.4 RESULTADOS OBTIDOS NA CLASSIFICAÇÃO.....	111
CAPÍTULO 8: CARACTERIZAÇÃO DE SONS ADVENTÍCIOS ATRAVÉS DE FILTRAGEM POR ANÁLISE ESPECTRAL SELETIVA	113
8.1 INTRODUÇÃO.....	113

8.2 METODOLOGIA DE FILTRAGEM POR ANÁLISE ESPECTRAL SELETIVA.....	114
8.3 COMPORTAMENTO DOS SONS PULMONARES.....	118
8.4 RESULTADOS OBTIDOS UTILIZANDO-SE A METODOLOGIA DE FILTRAGEM POR ANÁLISE ESPECTRAL SELETIVA.....	121
CAPÍTULO 9: DISCUSSÃO.....	137
9.1 AVALIAÇÃO DA CLASSIFICAÇÃO DOS SONS PULMONARES ATRAVÉS DA DWT E REDES NEURAS RBF.....	138
9.2 AVALIAÇÃO DA CARACTERIZAÇÃO DOS SONS ADVENTÍCIOS ATRAVÉS DE FILTRAGEM POR ANÁLISE ESPECTRAL SELETIVA.....	141
CAPÍTULO 10: CONCLUSÕES.....	147
10.1 TRABALHOS FUTUROS.....	148
10.2 COMENTÁRIOS FINAIS.....	149
REFERÊNCIAS BIBLIOGRÁFICAS.....	151
APÊNDICE I.....	161
APÊNDICE II.....	164
APÊNDICE III.....	169
APÊNDICE IV.....	172

LISTA DE FIGURAS

Figura 1	Vista posterior do tórax.....	8
Figura 2	Localização dos pulmões no corpo humano.....	9
Figura 3	Vista anterior dos pulmões e da extremidade inferior da traquéia.....	12
Figura 4	Modelo plástico de um brônquio, com algumas de suas ramificações.....	14
Figura 5	Vaso comparável à caixa torácica, com fundo móvel correspondente ao diafragma.....	15
Figura 6	Posições assumidas pelo diafragma ao fim de uma inspiração e de uma expiração normais. Posição das costelas e dos músculos intercostais externos durante a respiração.....	16
Figura 7	Diagrama das incursões respiratórias durante a respiração normal e durante inspiração e expiração máximas.....	17
Figura 8	Regiões de Ausculta Pulmonar.....	19
Figura 9	Espelhamento apresentado pela DFT no intervalo de π a 2π , do intervalo de 0 a π (0 a $fs/2$), devido à periodicidade da análise em sistemas discretos.....	29
Figura 10	Retângulos de Heisenberg de uma análise espectral utilizando a Transformada de Gabor.....	32
Figura 11	Espectrogramas de dois sinais distintos.....	34
Figura 12	Representações gráficas das resoluções frequência x tempo obtidas através do cálculo da STFT e da transformada <i>wavelet</i>	35
Figura 13	Sinal senoidal de 500 Hz com uma pequena descontinuidade e zoom do sinal para facilitar a visualização da descontinuidade.....	36
Figura 14	Espectro do sinal senoidal de 500 Hz, contendo uma descontinuidade, apresentado na figura 13.....	36
Figura 15	Espectrograma do sinal senoidal de 500 Hz, contendo uma descontinuidade, apresentado na figura 13.....	37
Figura 16	Escalograma resultante da Transformada <i>Wavelet</i> Contínua do sinal senoidal contendo uma descontinuidade, apresentado na figura 13, utilizando a função <i>wavelet</i> Daubechies 4.....	37
Figura 17	Processo de decomposição wavelet do sinal $X(n)$	42
Figura 18	Processos de decomposição e reconstrução <i>wavelet</i>	43
Figura 19	Exemplos de funções <i>wavelet</i> e escala da família Daubechies para diferentes suportes.....	46
Figura 20	Módulo do espectro da função wavelet de Meyer e seu sinal no tempo.....	47
Figura 21	Funções escala e <i>wavelet</i> da família <i>Coiflets</i> ordens 1, 3 e 5.....	49
Figura 22	Funções escala e <i>wavelet</i> da família <i>Symlets</i> ordens 4, 8 e 20.....	51
Figura 23	Modelo não-linear de um neurônio.....	55
Figura 24	Tipos de funções de ativação.....	55
Figura 25	Rede neural artificial de camada simples.....	57
Figura 26	Rede neural artificial com duas camadas.....	58
Figura 27	Estrutura das redes neurais de Função de Base Radial (RBF).....	64
Figura 28	Curvas de resposta do filtro FIR calculado a partir do sinal de entrada.....	73
Figura 29	Escala de cores relacionadas à magnitude, utilizada na construção do espectrograma, com unidade em dB mV.....	75
Figura 30	Exemplos de espectrogramas gerados a partir da técnica proposta.....	75
Figura 31	Exemplo de espectrograma de um ciclo respiratório contendo sibilos entre 1,6 e 2,2 s, na fase expiratória.....	79
Figura 32	Espectrograma de um ciclo respiratório com roncos. Os mesmos ocorrem nos tempos entre 0 e 1 s e entre 1,5 e 2,2 s.....	80

Figura 33	Exemplo de espectrograma de sons cardíacos, representados em cada barra vertical.....	81
Figura 34	Espectrograma de um ciclo respiratório com estridor ocorrendo entre 1,4 e 1,9 s, na fase expiratória.....	82
Figura 35	Espectrograma de um ciclo respiratório com estertores finos ocorrendo entre o início do ciclo e 0,6 s, na fase inspiratória.....	83
Figura 36	Espectrograma de um ciclo respiratório com estertores grossos, visualizados em quase todo o ciclo respiratório, na forma de barras verticais.....	84
Figura 37	Análise CWT de um ciclo respiratório normal, variando a escala entre 1 e 32, e as funções <i>mother wavelet</i>	87
Figura 38	Escalogramas de um ciclo respiratório com anomalias contínuas, mais precisamente sibilos, variando a escala entre 1 e 32, e as funções <i>mother wavelet</i>	89
Figura 39	Escalogramas de um ciclo respiratório com roncos, variando a escala entre 1 e 32, e as funções <i>mother wavelet</i>	90
Figura 40	Escalogramas de um ciclo respiratório com anomalias descontínuas, ou estertores finos, variando a escala entre 1 e 32 e as funções <i>mother wavelet</i>	92
Figura 41	Sinais resultantes do primeiro nível de decomposição <i>wavelet</i> de um ciclo respiratório contendo anomalias contínuas.....	96
Figura 42	Sinais resultantes do primeiro nível de decomposição <i>wavelet</i> de um ciclo respiratório contendo anomalias descontínuas.....	97
Figura 43	Curvas de resposta em frequência dos filtros de decomposição $H[n]$ e $L[n]$ para as wavelets Daubechies 2 e Daubechies 10.....	98
Figura 44	Coefficientes de detalhe dos cinco primeiros níveis de decomposição <i>wavelet</i> do ciclo respiratório contendo sibilos, utilizando a <i>wavelet</i> Daubechies 4.....	100
Figura 45	Coefficientes de detalhe dos cinco primeiros níveis de decomposição <i>wavelet</i> do ciclo respiratório contendo estertores finos, utilizando a <i>wavelet</i> Daubechies 4.....	101
Figura 46	Coefficientes de detalhe dos cinco primeiros níveis de decomposição <i>wavelet</i> do ciclo de um som vesicular normal, utilizando a <i>wavelet</i> Daubechies 4.....	102
Figura 47	Curvas médias de Energia x Nível de decomposição <i>wavelet</i> para os grupos de ciclos respiratórios analisados.....	105
Figura 48	Curva de Energia x Nível de decomposição <i>wavelet</i> para os grupos de ciclos respiratórios contendo anomalias contínuas e descontínuas.....	106
Figura 49	Curvas referentes à matriz de acerto obtida na classificação em relação à abertura da RBF.....	112
Figura 50	Espectro resultante do cálculo da FFT dos coeficientes do sinal análise nível 4 de um ciclo respiratório contendo roncos	115
Figura 51	Curvas resultantes do processo de segmentação espectral utilizando cálculo das médias contra a detecção de pico do segmento no ciclo respiratório contendo roncos.....	116
Figura 52	Fluxograma do algoritmo de implementação da metodologia de filtragem por análise espectral seletiva.....	117
Figura 53	Ciclo respiratório normal antes e após a filtragem por análise espectral seletiva.....	119
Figura 54	Ciclo respiratório com estertores finos processado pelo algoritmo de filtragem por análise espectral seletiva.....	120
Figura 55	Ciclo respiratório com sibilos processado pelo algoritmo de filtragem por análise espectral seletiva.....	122

Figura 56	Ciclo respiratório com roncosp processado pelo algoritmo de filtragem por análise espectral seletiva.....	123
Figura 57	Sinal original de um ciclo respiratório contendo roncosp.....	125
Figura 58	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 61, utilizando a <i>wavelet</i> Coiflet 3.....	125
Figura 59	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 61, utilizando a <i>wavelet</i> Biortogonal 3.7.....	126
Figura 60	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 61, utilizando a <i>wavelet</i> Biortogonal 3.9.....	126
Figura 61	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 61, utilizando a <i>wavelet</i> Biortogonal 6.8.....	127
Figura 62	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 61, utilizando a <i>wavelet</i> Biortogonal Reversa 3.7.....	127
Figura 63	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 61, utilizando a <i>wavelet</i> Daubechies 4.	128
Figura 64	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 61, utilizando a <i>wavelet</i> Daubechies 44.	128
Figura 65	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 61, utilizando a <i>wavelet</i> Symlet 8.	129
Figura 66	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 61, utilizando a <i>wavelet</i> Symlet 20.	129
Figura 67	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 61, utilizando a aproximação discreta da <i>wavelet</i> Meyer.	130
Figura 68	Sinal original de um ciclo respiratório contendo estertores grossosp inspiratórios e sibilosp na expiração, com forte contaminação por sons cardíacos.....	131
Figura 69	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 72, utilizando a <i>wavelet</i> Coiflet 3.....	131
Figura 70	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 72, utilizando a <i>wavelet</i> Biortogonal 3.7.....	132
Figura 71	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 72, utilizando a <i>wavelet</i> Biortogonal 3.9.....	132
Figura 72	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 72, utilizando a <i>wavelet</i> Biortogonal 6.8.....	133
Figura 73	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 72, utilizando a <i>wavelet</i> Biortogonal Reversa 3.7.....	133
Figura 74	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 72, utilizando a <i>wavelet</i> Daubechies 4.	134
Figura 75	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 72, utilizando a <i>wavelet</i> Daubechies 44.	134
Figura 76	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 72, utilizando a <i>wavelet</i> Symlet 8.	135
Figura 77	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 72, utilizando a <i>wavelet</i> Symlet 20.	135
Figura 78	Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 72, utilizando a aproximação discreta da <i>wavelet</i> Meyer.	136
Figura 79	Tela inicial do <i>Software</i> de Cálculo e avaliação por espectrogramas.....	161
Figura 80	Interface de abertura de arquivos de áudio wave do <i>Software</i> de Cálculo e avaliação por espectrogramas.....	162
Figura 81	Visualização do espectrograma de um ciclo respiratório com sibilosp.....	163
Figura 82	Tela inicial do <i>Software</i> de análise de sons pulmonares por MRA.....	164

Figura 83	Interface de abertura de arquivos de áudio padrão <i>wave</i> do <i>Software</i> de análise por MRA.....	165
Figura 84	Primeiro nível de decomposição de um ciclo respiratório contendo sibilos.....	166
Figura 85	Visualização dos próximos nove níveis de decomposição do som ciclo respiratório.....	167
Figura 86	Visualização da curva de energia em relação ao nível de decomposição.	168
Figura 87	Tela inicial do <i>Software</i> de <i>Software</i> de treinamento e avaliação de Redes Neurais MLP.....	169
Figura 88	Interface de abertura de arquivos contendo os conjuntos de treinamento e validação para o treinamento da rede neural.....	170
Figura 89	Finalização do treinamento da rede neural MLP.....	171

LISTA DE TABELAS

1	Classificação dos estertores.....	20
2	Comparação entre o custo computacional da DFT x FFT, em número de operações complexas.....	30
3	Sub-bandas de frequências dos coeficientes resultantes do processo de decomposição <i>wavelet</i> dos ciclos respiratórios analisados.....	104
4	Famílias de funções <i>wavelet</i> avaliadas.....	107
5	Índice de acerto máximo obtido por cada função <i>wavelet</i>	112
6	Sub-bandas de frequências dos coeficientes <i>wavelet</i> para cada nível de decomposição dos ciclos respiratórios amostrados a 8 kHz de frequência.....	114
7	Famílias de funções <i>wavelet</i> avaliadas.....	124
8	Atenuação medida, em função da <i>wavelet</i> empregada.....	136
9	Matriz de acerto total na classificação para cada função <i>wavelet</i> e abertura da função de base radial utilizada na simulação de rede neural.....	172

LISTA DE ABREVIATURAS E SIGLAS

CWT	- <i>Continuous Wavelet Transform</i> (transformada <i>wavelet</i> contínua)
DFT	- <i>Discrete Fourier Transform</i> (transformada discreta de Fourier)
DWT	- <i>Discrete Wavelet Transform</i> (transformada <i>wavelet</i> discreta)
FFT	- <i>Fast Fourier Transform</i> (transformada rápida de Fourier)
IFFT	- <i>Inverse Fast Fourier Transform</i> (transformada rápida de Fourier inversa)
LMS	- <i>Least Mean Squares</i> (mínimos quadrados)
MLP	- <i>MultiLayer Perceptron neural network</i> (rede neural perceptron multicamadas)
MRA	- <i>Multiresolution Analysis</i> (análise em multiresolução)
PSD	- <i>Power Spectral Density</i> (densidade espectral de potência)
RBF	- <i>Radial Basis Function</i> (função de base radial)
STFT	- <i>Short Time Fourier Transform</i> (transformada de Fourier de curta duração)

CAPÍTULO 1

INTRODUÇÃO

1.1 MOTIVAÇÕES

Segundo dados do Ministério da Saúde brasileiro, 2001, o número de mortes causadas por doenças respiratórias cresceu 3% no intervalo entre os anos 1980 e 1999, vindo a ser a quinta causa de morte entre os brasileiros no ano de 1999. Segundo JAMIESON *et al.*, 1991 e a Organização Mundial de Saúde, mundialmente, mais de 5% da população sofre de asma e outros problemas respiratórios. Ainda em termos mundiais, mais de 14% das mortes registradas no ano de 2002 foram causadas por doenças ligadas ao sistema respiratório (*World Health Organization*, 2008).

Na prática clínica, um dos primeiros procedimentos adotados para detectar patologias respiratórias consiste na auscultação dos sons pulmonares. Este procedimento é adotado inicialmente devido à sua funcionalidade, ao fato de ser um procedimento não invasivo e possibilitar a rápida detecção de anormalidades fisiológicas. Portanto, por ser o método semiótico mais básico, a detecção e identificação de sons pulmonares torna-se um dos primeiros exames por meio dos quais médicos e fisioterapeutas definem o diagnóstico clínico e a terapêutica decorrente.

Funcionalmente, até os dias atuais, a ferramenta mais utilizada na realização da ausculta por profissionais de saúde ainda é o estetoscópio. Este instrumento, cujo nome provém de *estethos* (peito) e *skopos* (vigilante), foi criado por Laënnec (1819) sendo que, até então, os sons cardíacos e pulmonares eram auscultados colocando-se o ouvido diretamente na parede do tórax. Entretanto, apesar do alto custo de muitos estetoscópios modernos, esses instrumentos continuam sendo apenas simples condutores, que transmitem os sons da superfície do corpo do paciente auscultado aos ouvidos do profissional de saúde. Os estetoscópios raramente são testados e comparados e, normalmente, são escolhidos apenas por sua aparência, reputação ou por propagandas, sem o devido suporte técnico, que prometem melhor desempenho (PASTERKAMP, KRAMAN e WODICKA, 1997). Eles estão muito longe de ser instrumentos acústicos ideais, pois não apresentam curva de resposta em frequência plana em toda região de ocorrência dos sons cardíacos e pulmonares. Usualmente, os estetoscópios amplificam e atenuam seletivamente as bandas de frequência em que se

localizam os sons de interesse clínico, sendo que esta amplificação tende a ocorrer abaixo de 112 Hz, com atenuação das frequências acima deste valor (ABELLA, FORMOLO e PENNEY, 1992). Desta forma, os estetoscópios são condutores acústicos que naturalmente inserem distorções aos sons auscultados. Entretanto, esses são os instrumentos mais largamente utilizados na detecção e reconhecimento de anomalias em sons pulmonares pelos profissionais de saúde.

Assim, na prática clínica, constatam-se algumas dificuldades para detecção e reconhecimento dos sons pulmonares adventícios, resultantes da baixa qualidade com que esses sons chegam aos ouvidos do auscultador. Este problema torna-se ainda mais crítico quando da ausculta de sons pulmonares, uma vez que este pode possuir componentes de frequência fundamental que podem atingir até 2 kHz, sendo atenuadas pelo estetoscópio. Assim, este procedimento exige uma boa sensibilidade auditiva e um alto nível de treinamento deste profissional, além de um ambiente com baixo nível de ruídos acústicos. Esta situação motivou o desenvolvimento de *software* e a composição de bancos de sons pulmonares unicamente com o objetivo de auxiliar o treinamento dos profissionais de saúde no procedimento de ausculta pulmonar (PIXSOFT, 2006; WILKINS, HODGKIN e LOPEZ, 2004).

Segundo a nomenclatura adotada pela *International Lung Sounds Association* (ILSA), os sons respiratórios adventícios podem apresentar dois grandes tipos de anormalidades, relacionadas à patologias: as contínuas e as descontínuas. Os sons adventícios contínuos se subdividem em sibilos, roncos e estridor, sendo os descontínuos subdivididos em estertores finos e grossos (STASZKO *et al.*, 2006; MIKAMI *et al.*, 1987).

Entre as anomalias contínuas destacam-se os sibilos que, segundo Pasterkamp, Kraman e Wodicka (1997), são os sons adventícios mais comumente encontrados. A sua presença relaciona-se à obstrução parcial das vias respiratórias, normalmente associada à asma, sendo que a sua presença na respiração normal pode ser utilizada como parâmetro para a avaliação da severidade da obstrução das vias aéreas (KIYOKAWA *et al.*, 1999).

Vários trabalhos vêm sendo desenvolvidos propondo a caracterização e reconhecimento dos diferentes tipos de sons pulmonares utilizando técnicas de processamento digital de sinais, principalmente a análise espectral por transformada de Fourier e transformada *wavelet* (DU, CHAN, LAM e SUN, 1997; KAHYA, GÜLER e SAHIN, 1997; HADJILEONTIADIS e PANAS, 1997a; MASTOROCOSTAS *et al.*, 2000; KANDASWAMY *et al.*, 2004; GÜLER *et al.*, 2005, GÜLER, POLAT, ERGUN, 2005) ou propondo esta metodologia como incremento aos estudos já desenvolvidos (CUSTÓDIO,

1999). Estes estudos, usualmente, focalizam as tarefas de caracterização ou reconhecimento sobre grupos restritos de sons pulmonares sem propor uma metodologia para realizar ambas as tarefas para todos os grupos de sons pulmonares normais e adventícios.

Visando contribuir com o incremento das potencialidades do procedimento de ausculta, propõe-se neste trabalho a pesquisa de técnicas para a caracterização e o reconhecimento dos sons adventícios passíveis de presença em sons pulmonares, gerando embasamento para o desenvolvimento de um sistema único de análise destes sons. Assim, o desenvolvimento desse sistema poderá auxiliar na tarefa de ausculta dos sons respiratórios, incrementando os resultados obtidos neste processo e contribuindo com a precisão na detecção de patologias respiratórias e de elaboração de diagnósticos através da ausculta pulmonar.

1.2 OBJETIVOS

O objetivo geral do trabalho descrito nesta tese é o de investigar métodos para a detecção, caracterização e reconhecimento automático de sons adventícios nos sons pulmonares gravados digitalmente. Uma vez validados, esses algoritmos poderão ser utilizados no desenvolvimento de um sistema de auxílio à detecção de patologias respiratórias através da análise dos sons pulmonares. Para esta tarefa, propõe-se o desenvolvimento de técnicas de processamento, visando gerar realimentação visual e auditiva, com a caracterização da presença de sons adventícios, além de um parecer automático sobre a sua presença e localização no ciclo respiratório.

Portanto, dentro do escopo proposto, o objetivo geral desta pesquisa pode ser subdividido nos seguintes objetivos específicos:

1. avaliar técnicas de processamento digital de sinais visando a caracterização dos sons adventícios nos sons pulmonares, gerando dados passíveis de utilização como alimentação de um sistema de classificação automática de sons pulmonares, através de redes neurais artificiais;
2. implementar o sistema de classificação automática de sons pulmonares baseado em redes neurais artificiais;

1.3 ORGANIZAÇÃO DA TESE

Esta tese está organizada em dez capítulos. No Capítulo 1, apresentam-se os problemas que motivaram os desenvolvimentos propostos, assim como o seu objetivo geral e seus objetivos específicos.

No Capítulo 2, faz-se uma revisão sobre a base teórica de anatomia e fisiologia do sistema respiratório, que engloba a anatomia torácica, formas de geração dos sons pulmonares normais e adventícios e técnicas de ausculta.

O Capítulo 3 contém uma revisão das teorias matemáticas utilizadas para o desenvolvimento do trabalho proposto, abrangendo as áreas de análise espectral de sinais através das Transformadas de Fourier e Transformada *Wavelet* Contínua e Discreta.

O Capítulo 4 apresenta a base teórica sobre redes neurais artificiais, enfocando as estruturas de redes implementadas e avaliadas na tarefa de classificação automática dos sons pulmonares.

No Capítulo 5 apresentam-se os padrões de arquivo, materiais e as ferramentas de desenvolvimento utilizados na implementação do trabalho proposto, assim como as técnicas e ferramentas básicas desenvolvidas para normalização dos sons utilizados e visualização destes através de espectrogramas.

O Capítulo 6 contém a descrição dos estudos preliminares realizados para análise dos sons pulmonares. Estes estudos foram desenvolvidos através do uso de espectrogramas, pela Transformada Discreta de Fourier, e escalogramas, através da Transformada *Wavelet* Contínua. Apesar destas técnicas não configurarem a base das metodologias propostas, os resultados destes estudos serviram como referência para o seu desenvolvimento.

No Capítulo 7 descreve-se com detalhes o desenvolvimento e os resultados obtidos com a técnica inovadora de classificação dos sons pulmonares normais e adventícios através do uso da Transformada *Wavelet* Discreta, ou decomposição *wavelet*, e de simulações de redes neurais artificiais de função de base radial (RBF).

No Capítulo 8 apresenta-se com detalhes o desenvolvimento e os resultados da técnica inovadora batizada de Filtragem por Análise Espectral Seletiva. Esta técnica, baseada no uso da Transformada *Wavelet* Discreta, Transformada de Fourier e filtros multibanda, possibilita a atenuação dos sons cardíacos e do som do fluxo aéreo normal, mantendo os sinais dos sons adventícios presentes no ciclo respiratório.

O Capítulo 9 contém a avaliação dos resultados obtidos pelas duas técnicas propostas, assim como a discussão destes resultados, situando-os em relação a outros trabalhos correlatos encontrados na literatura.

Finalmente, no Capítulo 10 apresentam-se as conclusões e as propostas de trabalhos futuros deste trabalho.

CAPÍTULO 2

ANATOMIA E FISIOLOGIA DO SISTEMA RESPIRATÓRIO

2.1 ANATOMIA TORÁCICA

As informações apresentadas neste tópico foram revisadas de CIVITA, 1986; LEHRER, 1990; HOLLINSHEAD e ROSSE, 1991 e WEBSTER, 1998.

2.1.1 Caixa Torácica (HOLLINSHEAD e ROSSE, 1991)

O tórax é a parte superior do tronco, que se distingue do abdome pela presença da caixa torácica. O arcabouço esquelético que delimita esta caixa é expansível e elástico, constituído pelo esterno, pelas costelas e pelas cartilagens costais e se apóia em um segmento da coluna vertebral, representado pelas vértebras torácicas, que forma a parede posterior da cavidade torácica, incluída esta na caixa torácica. Os pulmões, brônquios e a traquéia, os quais são os órgãos centrais da respiração, o coração, veias e artérias pulmonares e outros órgãos da circulação estão alojados nesta cavidade.

A parede do tórax consiste do esqueleto torácico e dos tecidos moles associados. A integridade da parede é necessária à criação da pressão sub-atmosférica na cavidade, o que permite a sucção de ar pelos pulmões durante a respiração.

O espaço preenchido pelos pulmões é dividido por um septo mediano largo, conhecido como mediastino, que é ocupado pelo coração, pelas grandes artérias, veias pulmonares e sistêmicas (figura 1). A traquéia e o esôfago entram também no mediastino, procedentes do pescoço, pela abertura torácica superior. Esta abertura, relativamente pequena, delimitada pelo primeiro par de costelas, dá passagem também às grandes artérias e veias da cabeça, do pescoço e dos membros superiores. A abertura torácica inferior é larga e irregular e através dela a cavidade abdominal faz saliência no tórax. As vísceras abdominais e torácicas são separadas umas das outras pelo diafragma, formação musculotendínea que se origina das margens internas da abertura torácica inferior. O diafragma apresenta-se abaulado no tórax, em forma de cúpula, e sua altura varia conforme contrações e relaxamentos rítmicos. Esta ação, semelhante a de um pistão, é um fator importante nos movimentos respiratórios e contribui duas vezes mais do que os movimentos das costelas para as modificações de pressão

e capacidade do tórax. Os pulmões acompanham as excursões das paredes torácicas porque suas superfícies se mantêm aplicada às faces internas das paredes pela pleura.

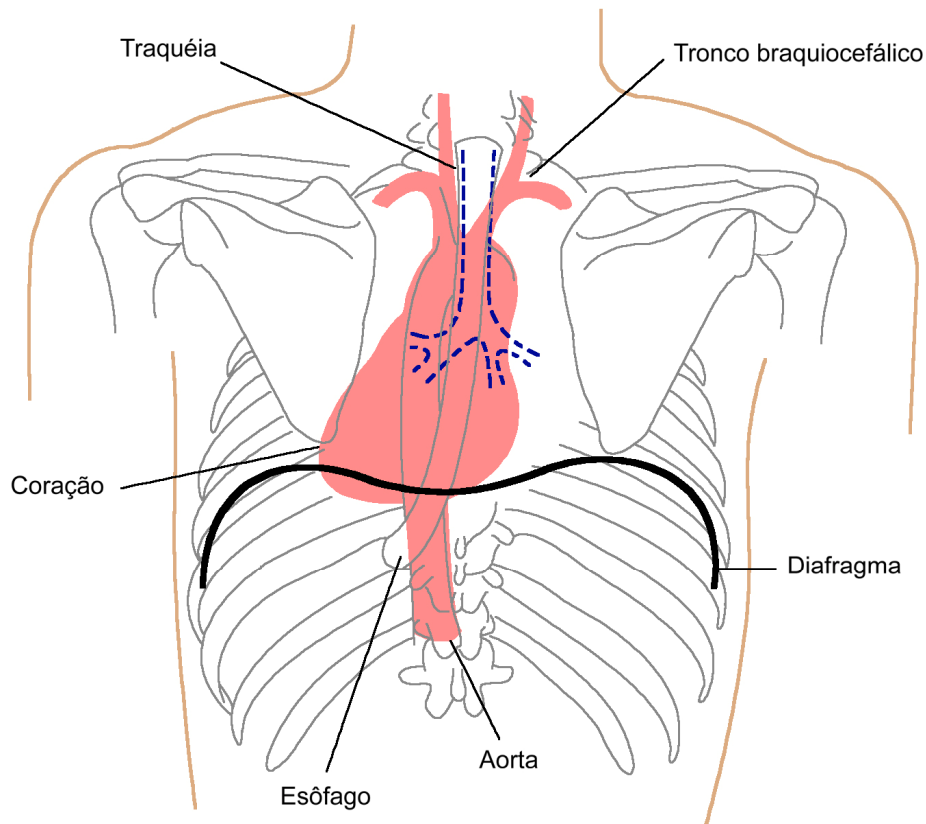


Figura 1: Vista posterior do tórax. As cavidades pleurais, que se estendem sobre a face posterior das cúpulas do diafragma, estão indicadas nas áreas pontilhadas. O coração e as grandes artérias do mediastino são mostrados em tom róseo. Adaptado de Hollinshead e Rosse (1991).

A pleura é uma membrana serosa cujo folheto parietal reveste os dois espaços ociosos de cada lado do mediastino, enquanto seu folheto visceral recobre os pulmões expansíveis. A sua localização pode ser vista na figura 2. Desse modo, o tórax não apenas contém e protege os órgãos centrais da respiração e da circulação, mas o seu mecanismo funcional produz também as modificações necessárias à respiração e ao retorno venoso para o coração.

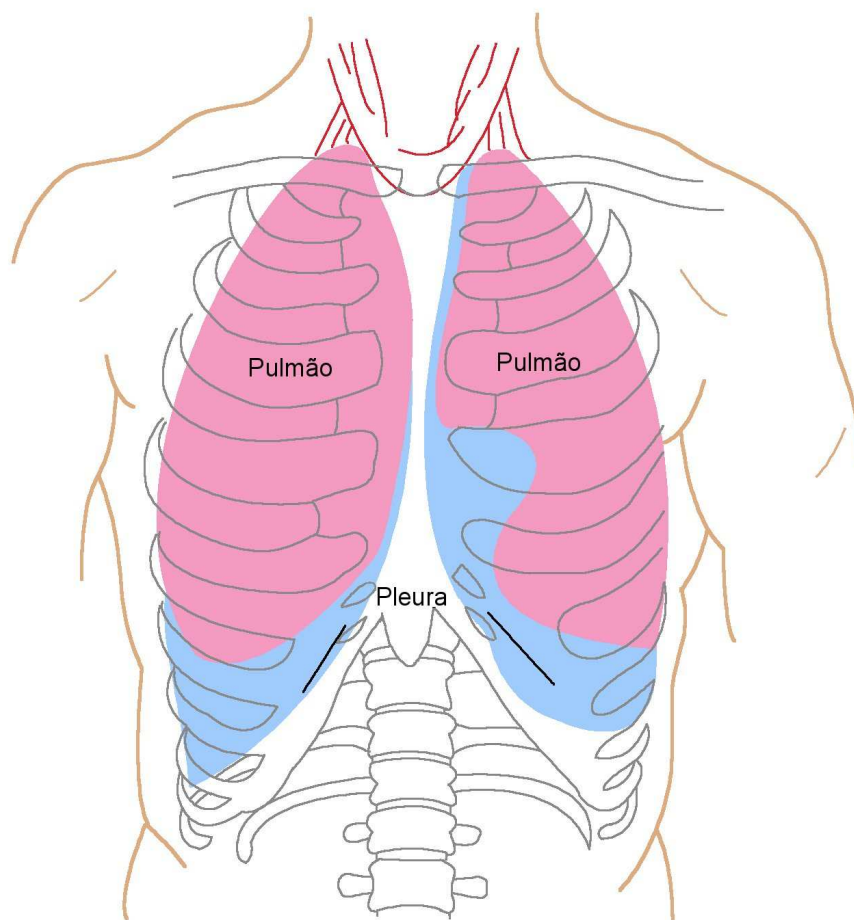


Figura 2: Localização dos pulmões no corpo humano. Em azul, está representada a pleura, membrana dupla que reveste ambos os pulmões. Adaptado de Civita (1986).

2.1.2 Vias Aeríferas

O ar inspirado durante o ciclo respiratório segue caminho por vários órgãos antes de entrar em contato com o sangue, para a oxigenação. Cada um desses órgãos tem uma função específica dentro do aparelho respiratório.

Os orifícios nasais anteriores, representados pelo nariz, captam o ar e o dirigem à cavidade nasal, a qual é dividida pelo septo, que é formado em parte por cartilagem e parte por ossos. As paredes laterais do segmento seguinte, as cavidades nasais são, sobretudo, de osso delgado que apresenta cristas - as conchas, antigamente denominadas cornetos - que se projetam para dentro e para baixo nas cavidades. Elas são cobertas por membrana mucosa e ajudam a aquecer e a umedecer o ar inspirado. As conchas ocupam tanto espaço na cavidade nasal que, ao se tornarem aumentadas por edema, podem bloquear por completo a passagem

de ar. O par de cavidades nasais se abre, por meio de estreita abertura posterior, na parte nasal da faringe e estão separadas da boca pelo palato.

A faringe é um conduto irregular musculofibroso que se localiza entre a boca, porção posterior das fossas nasais e o esôfago, onde termina.

Da parte nasal, o ar passa para a parte oral da faringe e logo penetra na laringe, cuja entrada é mantida constantemente aberta por cartilagens de suporte. Um pouco abaixo da entrada existem pregas que se projetam no interior da laringe e permitem que a passagem permaneça fechada durante a deglutição ou durante o ato de prender a respiração, ou que a passagem permaneça levemente entreaberta, para permitir o escapamento de uma fina camada de ar necessária à fonação. Também utilizadas para a fonação, as cordas vocais são um par de pregas laríngeas. As vibrações geradas por estas pregas neste processo são produzidas a partir da passagem do ar na laringe com as cordas vocais assumindo uma posição reta. A cartilagem anterior proeminente da laringe é a cartilagem denominada de tireóide.

A traquéia, que se inicia na laringe, é um tubo musculofibroso sustentado por uma série de anéis cartilagosos em forma de ferradura, incompletos posteriormente. Ela é mantida permanentemente aberta e, em condições normais, permite fácil passagem de ar. Externamente, ela é proeminente na frente do pescoço em sua base, abaixo da laringe e, após penetrar no tórax, desvia-se discretamente para a direita. A traquéia termina bifurcando-se nos brônquios direito e esquerdo.

Os brônquios são tubos aeríferos envolvidos por uma bainha conjuntivo-cartilaginosa que ainda se localizam fora do parênquima pulmonar. Sucessivas ramificações dos brônquios e dos vasos pulmonares formam o parênquima pulmonar e as ramificações brônquicas terminais, os alvéolos, garantem íntimo contato entre o ar e os vasos sanguíneos.

2.1.3 Pulmões

Os pulmões são órgãos pares, especializados na troca de gases entre o ar atmosférico e o sangue. Seu tecido essencial é um epitélio escamoso, uma camada simples e delgada de células que formam as paredes de espaços diminutos, os alvéolos, e que se colocam entre os capilares da circulação pulmonar e o ar contido nos alvéolos. Os alvéolos estão conectados ao exterior por meio de um sistema ramificado de tubos, a árvore brônquica, e permanecem cheios de ar mesmo durante a expiração. Eles respondem pela maior parte do volume dos pulmões.

Cada um dos pulmões apresenta a forma de um cone irregular, com cerca de 25 cm de altura. As bases, que possuem forma côncava, apóiam-se na curva do diafragma, os ápices, obtusos, chegam até o nível do primeiro par de costelas, situado pouco abaixo da clavícula. As faces externas, com forma convexa, adaptam às paredes do tórax e as faces internas, côncavas e opostas uma à outra, delimitam o mediastino.

Os pulmões não são perfeitamente iguais. O direito é maior e é dividido por duas fissuras em três partes ou lobos. Já o pulmão esquerdo apresenta apenas uma fissura, com a decorrente formação de apenas dois lobos. Apesar de o pulmão direito ter três lobos e o esquerdo apenas dois, existe correspondência entre os segmentos broncopulmonares. Entretanto, o conceito de lobos e a posição das fissuras são úteis para a localização dos segmentos broncopulmonares, mas a segmentação em lobos é inconseqüente no tocante ao funcionamento pulmonar.

As fissuras facilitam os movimentos dos lobos entre si, o que favorece maior distensão e movimento dos lobos inferiores durante a respiração. O pulmão pode ser dividido completamente pelas fissuras e os lobos permanecem unidos apenas no hilo, pelos brônquios e vasos pulmonares. Mais freqüentemente, porém, as fissuras são incompletas e podem até mesmo não existir totalmente.

Ambos os pulmões são cortados entre as faces costal e mediastal pela fissura oblíqua. Esta fissura corta a borda vertebral a uma distância variável abaixo do ápice. No pulmão esquerdo, a fissura oblíqua delimita os lobos superior e inferior.

No pulmão direito, a fissura horizontal separa dois segmentos broncopulmonares no lobo médio. A fissura horizontal começa na fissura oblíqua ao nível da linha axilar média. O lobo médio está entre as fissuras horizontal e oblíqua, que delimitam também os lobos superior e inferior. Esta divisão pulmonar pode ser vista na figura 3.

Em virtude da inclinação para frente e para baixo da fissura oblíqua, os lobos superiores direito e esquerdo e o lobo médio são superiores e anteriores aos lobos inferiores. Os lobos superiores e o médio se projetam na parede torácica anterior, onde são acessíveis à exploração clínica, enquanto os lobos inferiores não são acessíveis anteriormente. O contrário é o que ocorre em vista posterior. As projeções pulmonares posteriores são dominadas pelos lobos inferiores. Apenas uma pequena porção dos lobos superiores é acessível pelo exame do dorso.

Na face interna de cada pulmão observa-se uma grande fenda, o hilo pulmonar. O hilo é uma área em forma aproximada de cunha, na qual as estruturas que formam a raiz do pulmão entram no órgão ou saem dele. O brônquio está na parte superior de cada hilo, mais

posteriormente. Adiante dele está a artéria pulmonar e, num plano ainda mais anterior, a veia pulmonar superior. A veia pulmonar inferior está abaixo do brônquio e ocupa o espaço entre os folhetos do ligamento pulmonar. Dois brônquios adentram o hilo no pulmão direito, sendo eles o brônquio lobar superior direito e o brônquio intermediário. No pulmão esquerdo apenas o brônquio esquerdo adentra o hilo pulmonar, sendo que suas subdivisões ocorrem após essa passagem.

Pelo hilo transitam também os vasos brônquicos, plexos nervosos pulmonares e linfáticos. Diversos linfonodos broncopulmonares estão localizados nele. O ligamento pulmonar, a parte redundante inferior do manguito pleural que rodeia a raiz do pulmão, proporciona o espaço morto no qual a raiz do pulmão pode mover para cima e para baixo durante os movimentos respiratórios, na medida em que as contrações diafragmáticas tracionam para baixo e liberam o mediastino.

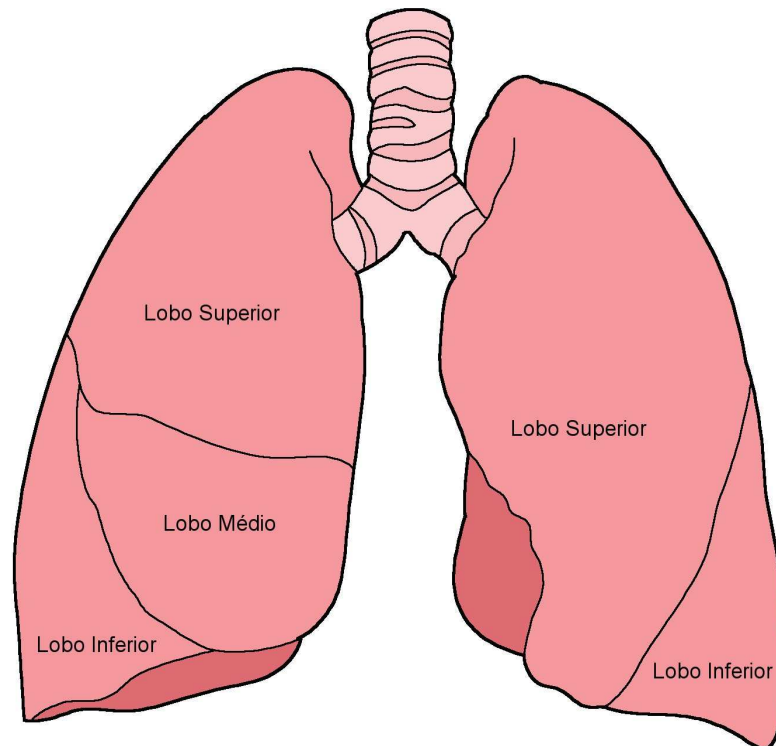


Figura 3: Vista anterior dos pulmões e da extremidade inferior da traquéia. Adaptado de Hollinshead e Rosse (1991).

Os brônquios penetram nos pulmões e ali se ramificam. Cada ramo penetra num lobo e, no interior do lobo, volta a ramificar-se, de modo a estabelecer ligações independentes com os diversos segmentos que compõem cada lobo.

Os segmentos são subdivisões dos lobos e são inteiramente autônomos, sob os aspectos anatômico e funcional. Cada um deles é separado dos segmentos contíguos por finas camadas de tecido conjuntivo. O número total de segmentos é variável, mas, em geral, existem oito no pulmão esquerdo e dez no direito. Pode-se mesmo dizer que cada pessoa possui cerca de dezoito pulmões autônomos, que podem funcionar sem nenhuma dependência uns dos outros (CIVITA, 1986).

Dentro dos segmentos, os bronquíolos continuam a se ramificar, até formarem os diminutos bronquíolos respiratórios, dos quais provêm os condutos alveolares. Estes se abrem em dilatações chamadas sáculos alveolares que, por sua vez, se abrem em outras dilatações, os alvéolos pulmonares, onde se processa a oxigenação do sangue. O conjunto de dutos, sáculos e alvéolos forma um ácino, que tem o aspecto de um cacho de uvas. Num indivíduo adulto, existem ao todo cerca de 700 milhões de alvéolos (CIVITA, 1986), cada um deles sustentado por uma fina trama de fibras reticulares e circundado por vasos capilares. Estas estruturas podem ser vistas na figura 4.

2.2 MECÂNICA RESPIRATÓRIA

As informações apresentadas neste tópico foram revisadas de Civita (1986) e Webster (1998).

Pode-se modelar a mecânica respiratória como uma combinação de elementos mecânicos e pneumáticos (WEBSTER *apud* CHATBURN e PRIMIANO, 1988). A caixa torácica pode ser comparada a um vaso feito de material que apresenta características plásticas e elásticas, com fundo móvel (figura 5) e, portanto, com capacidade variável. Ao mover-se o fundo para baixo, a pressão no interior do vaso torna-se menor que a pressão atmosférica, obrigando o ar externo a percorrer as vias respiratórias e preencher os pulmões, que se inflam, de forma a restabelecer o equilíbrio das pressões. O fundo móvel corresponde ao músculo diafragma, que tem duas cúpulas ajustadas às bases dos pulmões.

A atividade respiratória é regida parcialmente pelo sistema neurovegetativo, parassimpático e simpático, o que torna o ciclo respiratório naturalmente automático que, entretanto, pode ser controlado.

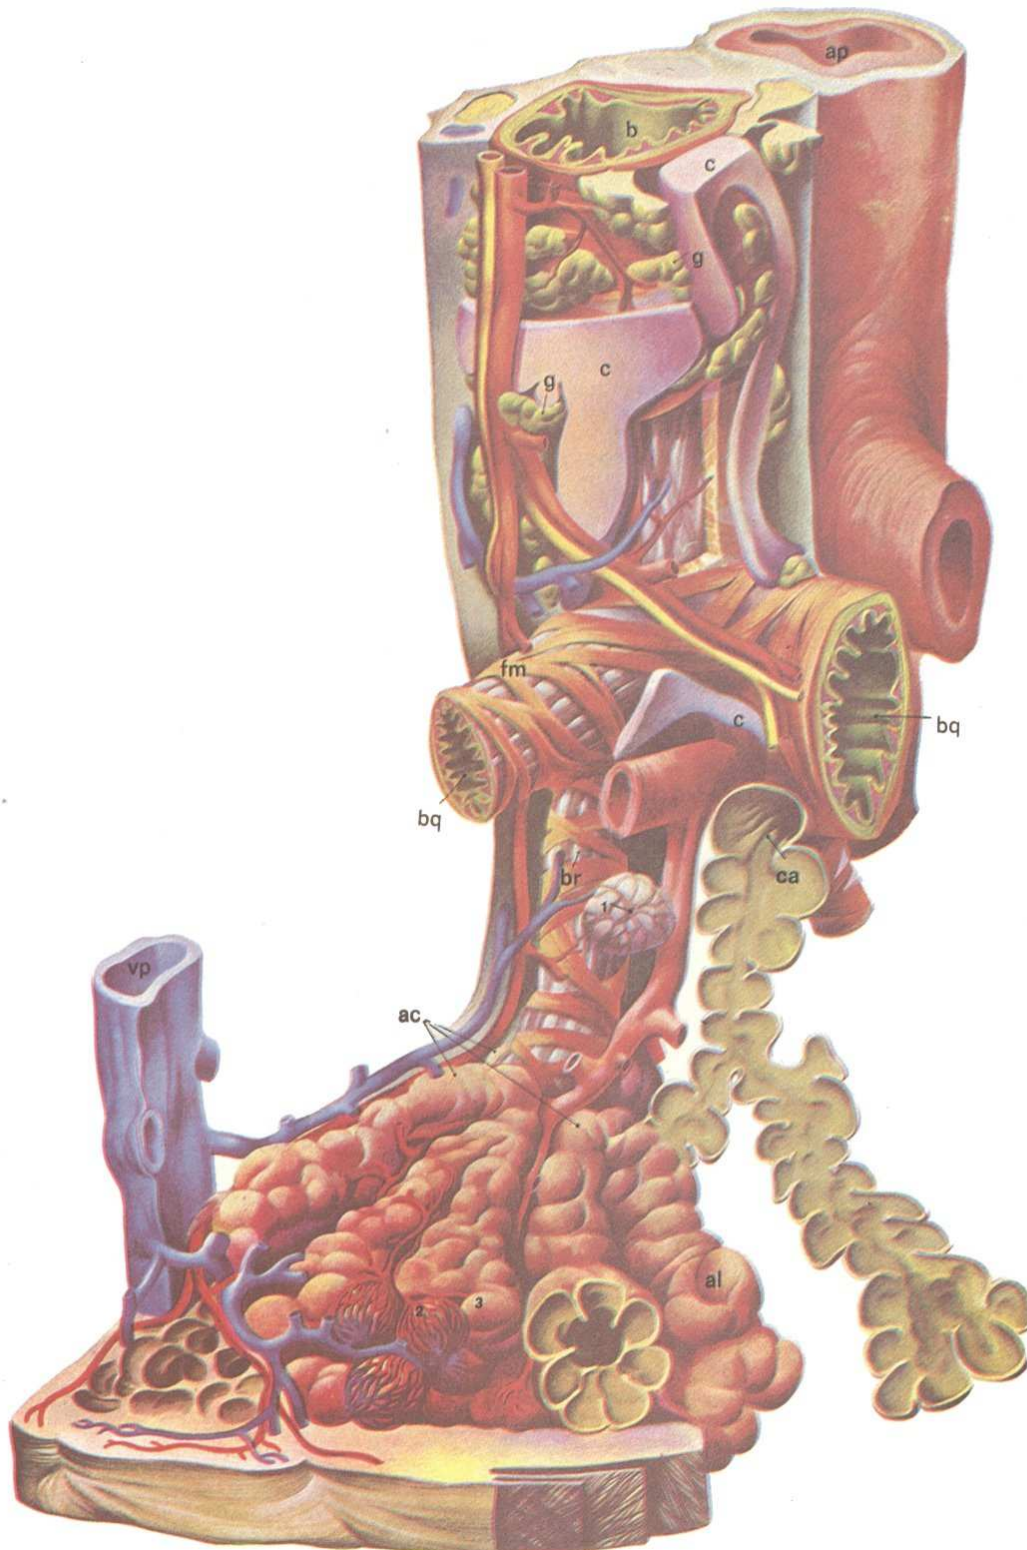


Figura 4: Modelo plástico de um brônquio, com algumas de suas ramificações. Os alvéolos pulmonares apresentam-se em três invólucros: (1) tecido de fibras reticulares; (2) rede de capilares; (3) epitélio; (ap) artéria pulmonar; (b) brônquio; (c) cartilagem; (g) glândula da mucosa do brônquio; (fm) fibras musculares; (bq) bronquíolo; (br) bronquíolo respiratório; (ca) conduto alveolar; (vp) veia pulmonar; (ac) ácinos pulmonares; (al) alvéolos pulmonares (CIVITA, 1986) .

As contrações do diafragma e dos músculos abdominais exercem papel fundamental no mecanismo da respiração, mas, no corpo humano, a respiração conta com outros dispositivos. Repuxados pelos músculos intercostais e outros, o feixe de costelas se expande como um fole (figura 6) e a pressão da cavidade torácica diminui, a fim de provocar a inspiração. A expiração, ao contrário, é passiva. O tecido pulmonar, muito elástico, assume automaticamente a posição de repouso ao faltarem as forças que o mantêm expandido (CIVITA, 1986).

Tanto a respiração abdominal quanto a respiração costal podem ser percebidas com maior nitidez quando o ritmo se acelera para atender às necessidades de oxigenação produzidas por excessiva atividade motora ou por excitação emocional. São nessas condições que o organismo, necessitando de maior ventilação, requer o concurso dos músculos expiratórios, que normalmente são passivos. Esses músculos intercostais ou abdominais abaixam as costelas e levantam o diafragma, comprimindo os pulmões e levando-os a expelir uma quantidade maior de ar.

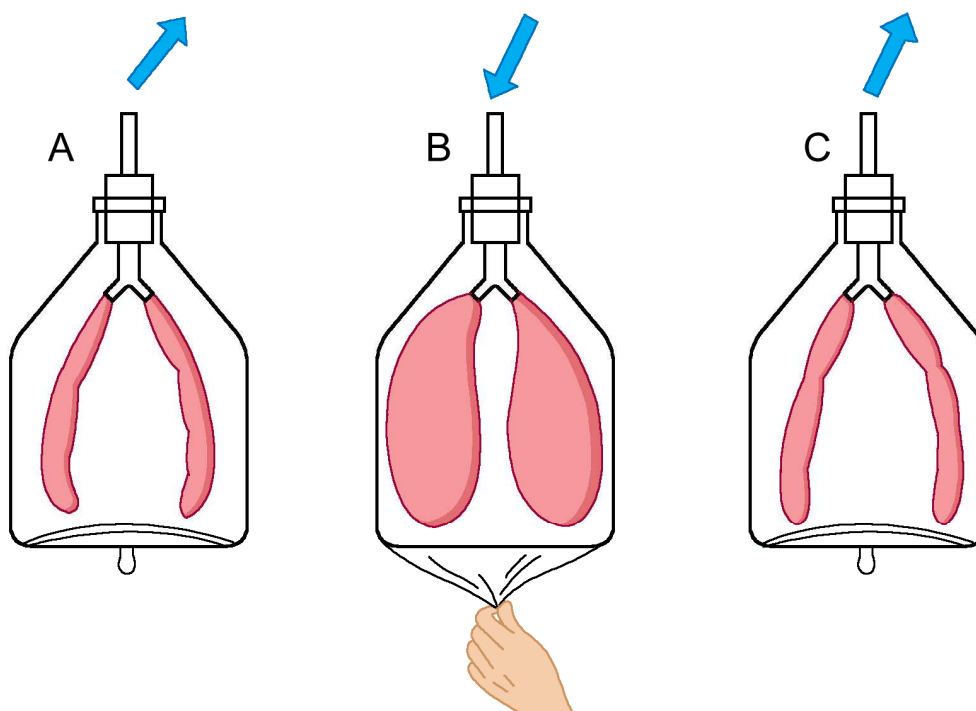


Figura 5: Vaso comparável à caixa torácica, com fundo móvel correspondente ao diafragma. (A) e (C) expiração; (B) inspiração. As setas indicam a direção da corrente de ar. Adaptado de Civita (1986).

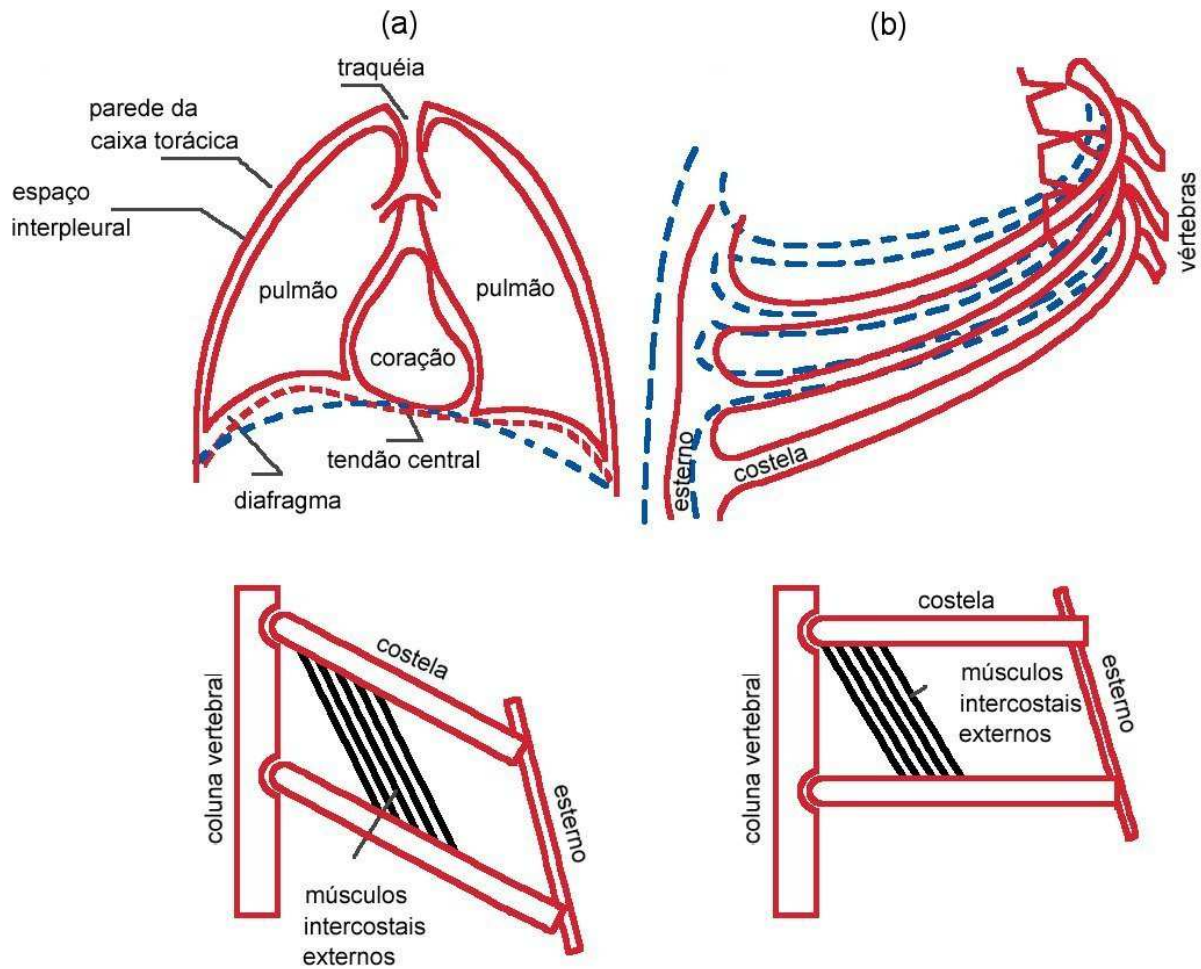


Figura 6: (a) Posição que o diafragma assume ao fim de uma inspiração (traçado azul) e de uma expiração (traçado vermelho) normais. (b) Posição das costelas e dos músculos intercostais externos durante a respiração. Adaptado de Civita (1986).

2.2.1 Volumes e Capacidades Pulmonares (LEHRER, 1990)

A figura 7 ilustra as alterações nos volumes pulmonares nas diferentes fases do ciclo respiratório. Segundo este diagrama, o ar nos pulmões é dividido em quatro volumes e quatro capacidades diferentes. Os valores preditos são dependentes da constituição física do indivíduo, variando conforme o peso, cintura, musculatura, altura, idade e sexo.




Figura 7: Diagrama das incursões respiratórias durante a respiração normal e durante inspiração e expiração máximas (LEHRER, 1990, *apud* GUYTON, 1981).

Os quatro volumes apresentados são:

1. Volume corrente, que é o volume de ar inspirado ou expirado em cada respiração normal em repouso, geralmente ao redor de 500ml;
2. O volume de reserva inspiratória é o volume de ar que pode ser inspirado além do volume corrente normal, geralmente ao redor de 3 l;
3. Volume de reserva expiratória é o volume de ar que ainda pode ser expirado através de uma expiração forçada após o final de uma inspiração normal, geralmente ao redor de 1,1 l;
4. O volume residual se refere ao volume de ar remanescente nos pulmões após uma expiração forçada, geralmente ao redor de 1,2 l.

Quando estes quatro volumes são somados eles equivalem ao volume máximo de expansão pulmonar. Quando dois ou mais dos volumes mencionados são considerados em conjunto, obtêm-se as capacidades pulmonares:

1. Capacidade inspiratória, que é a soma do volume corrente com o volume de reserva inspiratória, o que resulta em aproximadamente 3,5 l;
2. Capacidade residual funcional é o volume de reserva expiratória mais o volume residual, de aproximadamente 2,3 l. Esta é a quantidade de ar que permanece nos pulmões após uma expiração normal;
3. A capacidade vital é a soma do volume de reserva inspiratória com os volumes corrente e de reserva expiratória, com aproximadamente 4,6 l. Esta é a quantidade máxima de ar que um indivíduo pode expelir dos pulmões após uma inspiração e expiração forçadas;
4. Capacidade pulmonar total é o máximo volume os quais os pulmões podem ser expandidos, de aproximadamente 5,8 l, com um esforço inspiratório máximo, incluindo a capacidade vital e o volume residual.

Quando todos os músculos inspiratórios estão totalmente relaxados, os pulmões ficam em um estado de repouso, chamado nível expiratório de repouso. O volume de ar nos pulmões é, então, igual à capacidade residual funcional, ou seja, aproximadamente 2,3 l em um adulto jovem.

O volume residual, ou seja, o ar que não pode ser removido dos pulmões mesmo com uma expiração forçada, possui por funções evitar a colabação das pequenas vias aéreas e fornecer ar para oxigenar o sangue mesmo entre os ciclos respiratórios. Sem o volume residual, estruturalmente, os alvéolos e as pequenas vias aéreas entrariam em colapso. Mesmo caso isto não ocorresse, as concentrações de oxigênio e dióxido de carbono sanguíneas aumentariam e diminuiriam acentuadamente a cada ciclo respiratório.

2.3 AUSCULTA PULMONAR

A ausculta é um método funcional, não invasivo e extremamente eficaz no acompanhamento clínico do tratamento de inúmeras patologias, entre as quais aquelas que envolvem o sistema respiratório. Desta forma, a identificação de sons pulmonares é o meio pelo qual médicos e fisioterapeutas definem o diagnóstico clínico e a terapêutica decorrente.

A ausculta é um método semiológico básico no exame físico dos pulmões. É funcional por excelência, diferente, por exemplo, da percussão que é puramente estática, e permite analisar o funcionamento pulmonar durante o ciclo respiratório. Ela confirma os achados da inspeção e possibilita a identificação de regiões com prejuízo de ventilação ou de eliminação

de secreções. Além disso, a ausculta fornece importante informação sobre a eficácia de um programa de tratamento em resolver problemas pulmonares. A prontidão para a ausculta requer a preparação do equipamento, do paciente e do terapeuta.

De início o examinador coloca-se atrás do paciente, que não deve forçar a cabeça ou dobrar excessivamente o tronco. O paciente deverá estar com o tórax despido e respirar pausadamente, com a boca entreaberta, sem fazer ruído.

Somente um examinador com longa prática na ausculta pulmonar consegue diferenciar os sons normais dos adventícios sendo que casos de erros de reconhecimento podem levar a erros de diagnóstico.

Em clinica médica, a ausculta pulmonar é efetuada basicamente em nove lugares do tórax. A figura 8 ilustra estas nove regiões para ausculta.

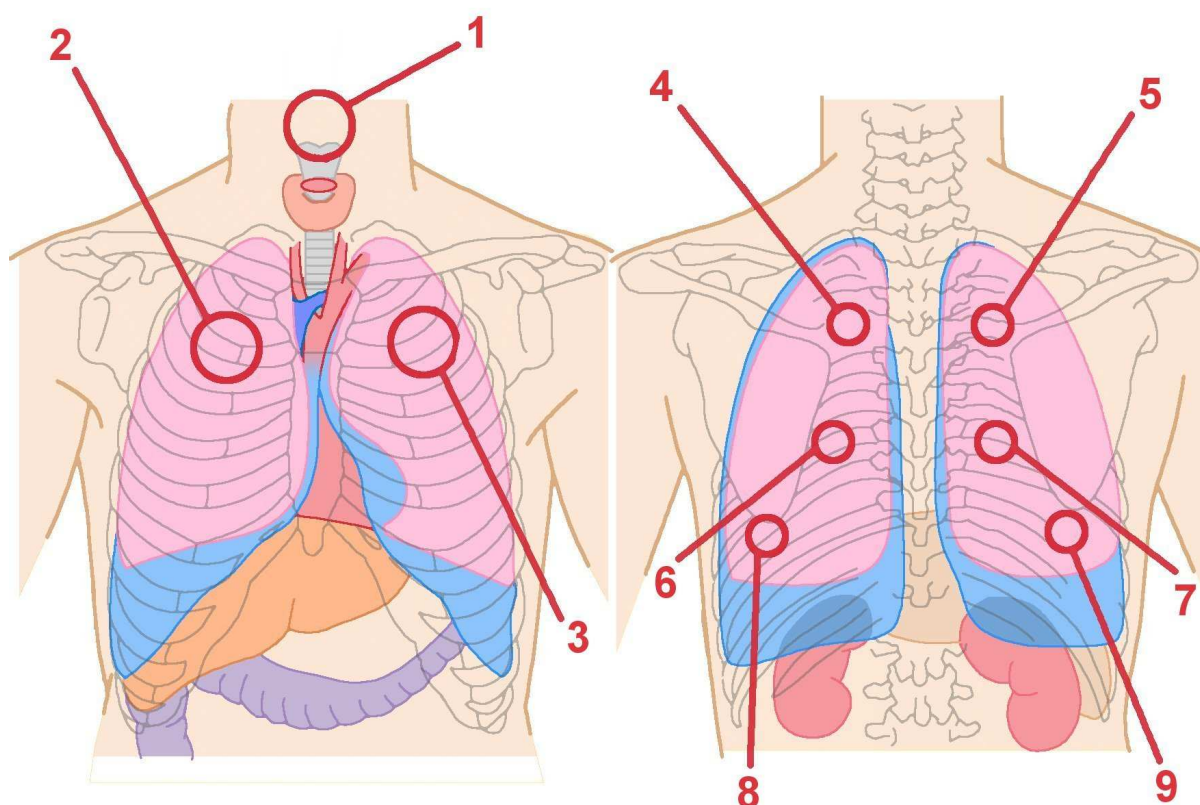


Figura 8: Regiões de Ausculta Pulmonar. 1 - Região traqueal 2 - Região ântero-superior direita da parede do tórax; 3 - Região ântero-superior esquerda da parede do tórax; 4 - Região postero-superior direita da parede do tórax; 5 - Região postero-superior esquerda da parede do tórax; 6 - Região postero-medial direita da parede do tórax; 7 - Região postero-medial esquerda da parede do tórax; 8 - Região postero-inferior direita da parede do tórax; 9 - Região postero-inferior esquerda da parede do tórax. Adaptado de Roque (2003).

2.4 SONS PLEUROPULMONARES

Os sons pleuropulmonares podem ser classificados em sons normais e sons com estertores. Quatro tipos de sons respiratórios são auscultados sobre um tórax normal, sendo eles o murmúrio vesicular ou som vesicular normal, o som traqueal, a respiração brônquica e a respiração broncovesicular (LEHRER, 1990).

De acordo com o editorial, do *American College of Chest Physicians* e a *American Thoracic Society*, publicado em 1975, foi redigido um pronunciamento que trataria de simplificar a terminologia empregada neste setor da semiologia, para reduzir sua complexidade. Postulou-se, então, uma simplificação que vem sendo aceita internacionalmente, sendo utilizada como referência pela *International Lung Sound Association* (ILSA) (MIKAMI *et al*, 1987; SILVA, 1991; STASZKO *et al.*, 2006). De acordo com esta simplificação, os tipos de sons adventícios que podem ser encontrados em sons pulmonares foram classificados de acordo com a tabela 1.

Tabela 1 – Classificação dos sons adventícios pulmonares (SILVA, 1991).

Contínuos	Descontínuos
Roncos	Crepitantes
Sibilos	Subcrepitantes ou bolhosos (grandes, médios e finos)

2.4.1 Sons Respiratórios Normais, revisado de Lehrer (1990) e Silva (1991).

Durante a respiração, em uma pessoa que não apresenta problemas respiratórios, tanto a variação mecânica do aparelho respiratório em si quanto o fluxo gasoso que percorre todos os órgãos deste aparelho geram vibrações que se localizam dentro da gama de frequências audíveis pelo homem, sendo estes chamados de sons respiratórios normais. Estes tipos de sons respiratórios diferem entre si pelos pontos do aparelho respiratório em que são produzidos e, conseqüentemente, pelos locais em que são auscultados.

2.4.1.1 Murmúrio Vesicular

Os ruídos respiratórios ouvidos na maior parte do tórax são produzidos pela turbulência do ar circulante ao chocar-se contra as saliências das bifurcações brônquicas, ao passar por cavidades de tamanhos diferentes, tais como dos bronquíolos para os alvéolos e vice-versa.

O componente inspiratório é mais intenso, mais duradouro e de intensidade mais alta em relação ao componente expiratório que, por sua vez, é quase inaudível. Não se percebe, diferentemente do que ocorre na respiração traqueal, um intervalo silencioso entre as duas fases da respiração.

Ausulta-se o murmúrio vesicular em quase todo o tórax, com exceção apenas das regiões esternal superior e interescápulo-vertebral direita ao nível da 3ª e 4ª vértebras dorsais. Nestas áreas, ouve-se a respiração broncovesicular. Cabe salientar que o murmúrio vesicular não tem intensidade homogênea em todo o tórax, sendo mais forte na parte ântero-superior, nas axilas e nas regiões infra-escapulares. Além disso, sofre variações em sua intensidade dependendo da espessura da parede torácica, sendo mais débil nas pessoas musculosas ou obesas.

As principais modificações da respiração vesicular são a diminuição ou o aumento de sua intensidade e o prolongamento do componente expiratório.

Respiração vesicular mais intensa ocorre quando o paciente respira amplamente e com a boca aberta, após esforço, em crianças e em pessoas magras. Nos portadores de afecções pulmonares unilaterais em caso de mecanismo vicariante, ou compensatório, o murmúrio vesicular torna-se mais intenso no lado afetado.

A diminuição do murmúrio vesicular pode resultar de numerosas causas, entre as quais ressaltam-se: presença de ar (pneumotórax), líquido (hidrotórax) ou tecido sólido (espessamento pleural) na cavidade pleural; enfisema pulmonar, dor torácica de qualquer etimologia que impeça ou diminua a movimentação do tórax, obstrução das vias aéreas superiores (espasmo ou edema da glote, obstrução da traquéia), oclusão parcial ou total de brônquios ou bronquíolos.

Constitui importante alteração do murmúrio vesicular o prolongamento da fase expiratória que, em condições normais, é mais curta e mais suave que a fase inspiratória. Este prolongamento da expiração aparece na asma brônquica, no enfisema e na bronquite espastiforme e traduz de modo objetivo a dificuldade de saída do ar.

2.4.1.2 Som Traqueal

Os sons traqueais são os sinais audíveis na região de projeção da traquéia, no pescoço e na região esternal, que se originam a partir da passagem do ar através da fenda glótica e da própria traquéia.

Diferenciam-se com facilidade os dois componentes do ciclo respiratório, sendo o inspiratório constituído de um ruído soproso, mais ou menos rude, após o qual há um curto intervalo silencioso que separa os dois componentes, e o expiratório, um pouco mais forte e mais prolongado.

2.4.1.3 Respiração Brônquica

A respiração brônquica corresponde ao som traqueal audível na zona de projeção de brônquios de maior calibre, na face anterior do tórax, nas proximidades do esterno.

A respiração brônquica muito se assemelha ao som traqueal, dela se diferenciando apenas por ter o componente expiratório menos intenso.

Nas áreas que correspondem à condensação pulmonar, atelectasia (colapso total ou parcial do pulmão) ou nas regiões próximas de cavernas superficiais ouve-se respiração brônquica no lugar do murmúrio vesicular.

2.4.1.4 Respiração Broncovesicular

Neste tipo de respiração, somam-se as características da respiração brônquica com as do murmúrio vesicular. Deste modo, a intensidade e a duração da inspiração e expiração têm igual magnitude, ambas um pouco mais fortes que no murmúrio vesicular, mas sem atingir a intensidade da respiração brônquica. Nas crianças, devido ao menor tamanho do tórax, a respiração broncovesicular é audível em regiões mais periféricas. Em condições normais, a respiração broncovesicular é auscultada na região esternal superior, na interescápulo-vertebral direita e ao nível da terceira e quarta vértebras dorsais. Sua presença em outras regiões indica a condensação pulmonar, a atelectasia por compressão ou presença de caverna, isto é, nas mesmas condições em que se observa a respiração brônquica. Para que surja este tipo de respiração, é necessário que haja na área lesada alvéolos mais ou menos normais capazes de originar ruído do tipo vesicular.

2.4.2 Sons Respiratórios Adventícios

Patologias respiratórias podem vir a gerar barreiras ao fluxo gasoso ou modificações mecânicas no aparelho respiratório que criam sons característicos, os quais podem ser identificados durante a ausculta. Desta maneira, o acréscimo de algum tipo de som adventício ao som pulmonar está fortemente ligado à presença de algum tipo de anormalidade no aparelho respiratório. Ao longo desta subseção serão descritos os tipos de anomalias que podem estar presentes nos sons pulmonares, suas localizações e relações com doenças respiratórias.

2.4.2.1 Descontínuos

Os sons adventícios descontínuos são caracterizados por sons respiratórios normais acrescidos de ruídos impulsivos de maior ou menor duração, chamados estertores. Esses ruídos apresentam formas de onda características de um impulso com curta duração temporal, seguido de amortecimento. A duração desse impulso, e a conseqüente distribuição de freqüências geradas por ele, refletem-se nas características do som auscultado, gerando a separação entre estertores finos e grossos. Ambos os tipos podem ser auscultados tanto na fase inspiratória quanto na expiratória, dependendo do tipo de patologia presente.

Os estertores finos ocorrem no final da inspiração, apresentam freqüências mais altas, com impulsos de duração curta, e não se modificam com a tosse. Podem ser comparados ao ruído produzido pelo atrito de um punhado de cabelos junto ao ouvido ou ao som percebido ao se fechar ou abrir um fecho tipo velcro. São ouvidos principalmente nas zonas pulmonares influenciadas pela força da gravidade.

Os estertores grossos apresentam freqüências mais baixas e impulsos de maior duração que os finos. Sofrem nítida alteração com a tosse e podem ser ouvidos em todas as regiões do tórax. Diferentemente dos estertores finos, que só ocorrem no meio para o final da inspiração, os estertores grossos são audíveis no início da inspiração e durante a expiração.

O mecanismo de formação destes sons tem sido motivo de polêmicas desde a descoberta do estetoscópio. Aceita-se atualmente que os estertores finos são produzidos pela abertura seqüencial de vias aéreas anteriormente fechadas devido à pressão exercida pela presença de líquido ou exsudato no parênquima pulmonar ou por alteração no tecido de suporte das paredes brônquicas. O primeiro mecanismo explicaria a presença de estertores

finos na pneumonia e na congestão pulmonar da insuficiência ventricular esquerda, enquanto o segundo seria observado nas doenças intersticiais pulmonares.

Os estertores grossos têm origem na abertura e fechamento de vias aéreas, contendo secreção viscosa e espessa, bem como pelo afrouxamento da estrutura de suporte das paredes brônquicas, sendo estes comuns na bronquite crônica e nas bronquiectasias.

Outro tipo de som anormal descontínuo é caracterizado pelo atrito pleural. Em condições normais, os folhetos visceral e parietal da pleura deslizam um sobre o outro durante os movimentos respiratórios sem produzir qualquer ruído. Nos casos de pleurite, por se recobrirem de exsudato, passam a produzir ruído irregular, descontínuo, mais intenso na inspiração, com sonoridade comparada ao ranger de couro atritado. Tal ruído recebe a denominação de atrito pleural. Representa um som de duração maior e frequência baixa, de tonalidade grave, portanto, o que torna fácil de distingui-lo dos estertores.

Para aprender a reconhecê-lo, o examinador pode imitá-lo, colocando uma das mãos de encontro ao próprio ouvido e atritando-o com a outra mão, com forte pressão.

A sede mais comum do atrito pleural são as regiões axilares inferiores, onde os pulmões realizam movimentação mais ampla. O aumento da pressão do receptor do estetoscópio sobre a parede torácica pode torná-lo mais intenso.

Sua causa principal é a pleurite seca. A instalação de derrame pleural determina seu desaparecimento.

2.4.2.2 Contínuos

Os sons anormais contínuos são caracterizados pela presença de ruídos contínuos, ou musicais, durante alguma fase do ciclo respiratório. As classificações destes ruídos são de sibilos, roncos, estridor e grasnidos, sendo sua diferenciação baseada na frequência fundamental, na distribuição espectral e na origem do som.

Segundo Pasterkamp, Kraman e Wodicka (1997), os sibilos são as anomalias mais comumente presentes nos sons pulmonares. Esses ruídos são caracterizados acusticamente por ondas periódicas (SOVIJÄRVI *et al.*, 2000) ou pseudo-periódicas (CHARBONNEAU *et al.*, 2000), com uma frequência fundamental bem definida, que pode variar de aproximadamente 100 Hz a pouco mais de 1 kHz, acrescida de harmônicas de menor amplitude e duração mais longa, normalmente entre 80 e 100 ms, mas podendo exceder 250 ms.

Os sibilos originam-se de vibrações das paredes bronquiolares e de seu conteúdo gasoso, aparecendo na inspiração e na expiração. Em geral, são múltiplos e disseminados por todo o tórax quando são provocados por enfermidades que comprometem toda a árvore brônquica, como acontece na asma e bronquite.

Os mecanismos patológicos e fisiológicos que geram os sibilos ainda não estão completamente claros. O movimento de secreções nas vias aéreas contribui para a sua presença, mas a vibração das paredes das vias aéreas é provavelmente mais significativa (PASTERKAMP, KRAMAN e WODICKA, 1997). Entretanto, a presença de sibilos na respiração normal, não forçada, está relacionada com a severidade da obstrução das vias aéreas, sendo utilizada para avaliação da asma noturna infantil (BENTUR *et al.*, 2003), usada como parâmetro para avaliação da predisposição à asma em crianças (MARTINEZ *et al.*, 1995), verificação da broncoconstrição na asma (KIYOKAWA *et al.*, 1999), entre outras aplicações. Quando os sibilos são localizados numa determinada região, indicam a presença de semi-obstrução por neoplasia ou corpo estranho.

Os roncos são constituídos por sons de mais baixa frequência, portanto mais graves, quando comparados aos sibilos. Neste contexto, Sovijärvi *et al.* (2000) definem os roncos como sibilos de baixa frequência, com duração maior que 100 ms e frequência fundamental menor que 300Hz. Contudo, Pasterkamp, Kraman e Wodicka (1997) sugerem que, ao invés de simplesmente classificar os roncos como sibilos de baixa frequência, torna-se mais útil aplicar este termo para repetições de estruturas sonoras complexas, que possuem uma formação tonal característica, estando relacionadas a presença de secreções nas vias aéreas ou colapsos de regiões pulmonares. Assim, esses sons adventícios originam-se nas vibrações das paredes brônquicas e do conteúdo gasoso quando há estreitamento destes dutos, seja por espasmo ou edema da parede ou secreção aderida a ela, como ocorre na asma brônquica, nas bronquites, nas bronquiectasias e nas obstruções localizadas. Estes podem ser encontrados tanto na inspiração quanto na expiração, mas predominam nesta última. São fugazes, mutáveis, surgindo e desaparecendo em curto período de tempo.

O estridor é um som produzido pela semi-obstrução da laringe ou da traquéia, fato que pode ser provocado por difteria, laringites agudas, câncer da laringe e estenose da traquéia. Sovijärvi *et al.* (2000) definem o estridor como um sibilo de baixa frequência e alta amplitude, originado na laringe ou na traquéia, estando presente mais comumente durante a inspiração. Quando a respiração é calma e pouco profunda, a intensidade do estridor é

pequena, mas na respiração forçada o aumento do fluxo de ar provoca significativa intensidade deste som.

Segundo Pereira, Fagundes e Coletta (2008) são sons musicais breves, presentes na inspiração, que são encontrados principalmente quando da presença de doença pulmonar intersticial, sobretudo na pneumonia de hipersensibilidade. Estes sons sempre ocorrem precedidos por estertores resultam da oscilação das paredes das vias aéreas colabadas quando da ocorrência de uma rápida insuflação (PASTERKAMP, KRAMAN e WODICKA, 1997).

2.4.3 Análise Visual Dos Sons Pulmonares

Visando melhorar o desempenho da ausculta e auxiliar no ensino desta técnica, vários autores (SCHÜTTLER, PENZEL e WICHERT, 1996; LEHRER, 1990; PASTERKAMP, KRAMAN e WODICKA, 1997; PIXSOFT, 2003) vêm utilizando espectrogramas de sons pulmonares gravados como técnica de realimentação visual da ausculta destes sons, ressaltando a presença de anormalidades de forma visual, facilitando assim a detecção destas anomalias.

O espectrograma, que será apresentado na seção 3.3, é um método de análise de sinais que gera uma imagem representativa da variação das frequências de um som ao longo do tempo. Desta maneira, as técnicas de análise espectral, que formam a base tanto da geração do espectrograma quanto das metodologias desenvolvidas para caracterização e classificação dos sons adventícios, serão discutidas no Capítulo 3.

CAPÍTULO 3

TÉCNICAS DE ANÁLISE ESPECTRAL DE SINAIS

Um sinal é definido como uma função de uma ou mais variáveis, a qual veicula informações sobre a natureza de um fenômeno físico (HAYKIN e VAN VEEN, 2001). Para o caso específico deste trabalho, os sinais são definidos como a variação de potencial elétrico em relação ao tempo. Esta variação de potencial elétrico tem relação direta com as variações de pressão geradas durante a gravação dos sons pulmonares, convertidos à forma elétrica pelo transdutor e amplificado pelos circuitos de condicionamento do sistema de gravação.

Assim, os sinais em tratamento neste estudo possuem duas formas básicas de análise de sua variação: a análise temporal, ou no domínio do tempo, e a análise espectral, no domínio da frequência.

Na análise temporal, verifica-se a variação do sinal ao longo do seu tempo de duração, enquanto na análise espectral avaliam-se as frequências componentes deste sinal.

Existem diversas técnicas para a transposição de sinais representados no domínio do tempo para o domínio da frequência e vice-versa, por meio de ferramentas matemáticas que facilitam o estudo dos mais diversos tipos de sinais. Algumas das técnicas mais importantes que possuem este fim serão descritas ao longo deste capítulo.

3.1 TRANSFORMADA DE FOURIER

No século XIX, o matemático francês Jean Baptiste Joseph, Barão de Fourier, demonstrou que qualquer função periódica pode ser expressa como uma superposição de senóides complexas. Muitos anos após a descoberta destas propriedades das funções periódicas, suas idéias foram generalizadas para uso em funções não periódicas e também em sinais discretos no tempo, periódicos e não periódicos.

Na transformada de Fourier, o sinal é representado como uma integral ponderada de senóides complexas em que a variável de integração é a frequência da senóide. Senóides de tempo contínuo com frequências distintas são distintas, de forma que a Transformada de Fourier envolve todas as frequências senoidais de $-\infty$ a ∞ (HAYKIN e VAN VEEN, 2001).

Basicamente, a transformada de Fourier decompõe o sinal em senóides complexas de diferentes frequências, de acordo com as equações de definição (1) e (2). Nestas equações, a

variável t representa o tempo, f a frequência e x denota o sinal a ser transformado. Nota-se que $x(t)$ se refere ao sinal no domínio do tempo, enquanto $X(f)$ representa o sinal no domínio da frequência. Esta conversão é usada para distinguir as representações do sinal nos domínios do tempo e da frequência.

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad (1)$$

$$x(t) = \int_{-\infty}^{\infty} X(f)e^{j2\pi ft} df \quad (2)$$

A equação (1) define a transformada de Fourier de $x(t)$, enquanto a equação (2) define a transformada inversa de Fourier de $X(f)$, que nada mais é que $x(t)$.

Analisando as equações de definição da transformada de Fourier, nota-se que ela funciona da seguinte maneira: o sinal $x(t)$ é multiplicado por um termo exponencial, em uma certa frequência f e, em seguida, é integrado em relação a todo o tempo. Também nota-se que o termo exponencial na equação (1) pode ser definido a partir da equação (3).

$$e^{-j\omega t} = \cos(\omega t) - j\text{sen}(\omega t) \quad (3)$$

A partir da equação (3), pode-se notar que a parte real do termo exponencial da equação (1) representa o cosseno da frequência f , enquanto a sua parte imaginária representa o seno da mesma frequência. Desta forma, a transformada de Fourier nada mais é do que a multiplicação do sinal original por uma expressão complexa com senos e cossenos da frequência f , seguido pela integração deste produto em relação ao tempo.

Entretanto, há uma limitação da análise de sinais utilizando a transformada de Fourier. Como a integração desta transformada é realizada ao longo de todo o tempo, o seu resultado apenas demonstra a presença de uma determinada componente espectral, independentemente da sua localização temporal. Esta limitação indica que a transformada de Fourier por si só não é uma ferramenta suficiente para análise de sinais não periódicos com espectro de frequências variante no tempo, isto é, para sinais não estacionários, mas serve como base para outros métodos de análise que cumprem esta tarefa.

3.2 TRANSFORMADA DISCRETA DE FOURIER (DFT) e TRANSFORMADA RÁPIDA DE FOURIER (FFT)

A transformada discreta de Fourier (DFT) nada mais é que a transformada de Fourier de um sinal discreto. Devido ao fato de estar-se lidando com amostras discretas no tempo, a integral em relação ao tempo que define a transformada de Fourier transforma-se em um somatório, e o intervalo de integração transforma-se no número de amostras constantes no vetor de entrada do sinal analisado. As equações da DFT e da DFT inversa estão definidas em (4) e (5), respectivamente.

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-\frac{2\pi kn}{N}} \quad (4)$$

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k)e^{\frac{2\pi kn}{N}} \quad (5)$$

Contudo, o sinal $X(k)$ que representa a DFT de um sinal $x(n)$ é periódico, apresentando período 2π e, conseqüentemente, um espelhamento do espectro do intervalo de 0 a π no intervalo de π a 2π , devido à representação das frequências negativas, como pode ser visto na figura 9. O intervalo entre as raiais do espectro resultante da DFT apresenta componentes a cada $k\Delta f$, onde $\Delta f = f_s/N$, onde f_s é a frequência de amostragem do sinal discreto e N é o número de amostras contidas no vetor analisado.




Figura 9: Espelhamento apresentado pela DFT no intervalo de π a 2π , do intervalo de 0 a π (0 a $f_s/2$), devido à periodicidade da análise em sistemas discretos. Adaptado de Haykin e Van Veen (2001).

A transformada discreta de Fourier (DFT) mostra-se uma ferramenta poderosa para a análise espectral de sinais em sistemas computacionais. Entretanto, existem limitações

computacionais quanto ao seu uso. Analisando-se a equação (4), nota-se que a função DFT realiza N vezes a soma de uma multiplicação complexa para a computação de uma componente em frequência do sinal. Como o espectro total tem N pontos, o número de multiplicações complexas demandada para o cálculo deste espectro será de N^2 . Desta maneira, o número de operações necessárias para a computação do espectro cresce de forma quadrática com o aumento do número de pontos do vetor de entrada, tornando-a lenta para a computação do espectro com elevada resolução.

Em 1965, uma forma otimizada de cálculo, denominada FFT (*Fast Fourier Transform*, ou transformada rápida de Fourier) foi desenvolvida com o intuito de computar a DFT de forma mais eficiente. Existem diversos tipos de algoritmos para a computação da FFT. Contudo, o primeiro algoritmo desenvolvido com este fim é conhecido por *decimation-in-time* (decimação no tempo), desenvolvido por Cooley e Tuckey (1965).

O algoritmo de decimação no tempo possui este nome devido ao fato de reagrupar os elementos de vetor de entrada no domínio do tempo. Após o reagrupamento, é computada a transformada discreta de Fourier de cada bloco com comprimento 2^n , variando entre blocos de um único pontos até a metade do vetor original. A computação deste algoritmo depende $\log_2 N$ iterações (PRESS, TEUKOLSKY, VETTERLING *et al.*, 1992), ao invés de N^2 da DFT. A tabela 2 apresenta os ganhos computacionais obtidos com a utilização da FFT em relação à DFT.

Tabela 2 – Comparação entre o custo computacional da DFT x FFT, em número de operações complexas.

<i>Número de pontos</i> N	<i>DFT</i> N^2	<i>Transformada rápida de Fourier – FFT</i> $N \log_2 (N)$	<i>Relação entre DFT/FFT</i>
4	16	8	2
8	64	24	2,67
16	256	64	4
32	1024	160	6,4
64	4096	384	10,67
128	16384	896	18,29
256	65536	2048	32
512	262144	4608	56,89
1024	1048576	10240	102,4
2048	4194304	22528	186,18
4096	16777216	49152	341,33

3.3 TRANSFORMADA DE FOURIER DE CURTA DURAÇÃO E ESPECTROGRAMA

A transformada de Fourier de curta duração (STFT, ou *short-time Fourier transform*), é um dos métodos mais utilizados para o estudo de sinais não estacionários (COHEN, 1995). Basicamente, o sinal não estacionário é dividido em segmentos de tempo tidos como estacionários, através da multiplicação deste sinal por uma janela que se desloca no tempo. Após esta operação, são computadas as transformadas de Fourier desses segmentos em separado, mudando-se o intervalo de integração, que passa a possuir um intervalo de tempo definido. Quando esse processo é utilizado em vários segmentos consecutivos do sinal em análise, possibilita-se precisar a existência de componentes em frequência constantes em determinados intervalos de tempo e a variação da presença destas componentes espectrais ao longo do tempo. A transformada de Fourier de curta duração é definida pela equação (6), onde $x(t)$ refere-se ao sinal em análise, $w(t)$ é a função de janela utilizada e τ refere-se ao intervalo temporal de análise. Quando utilizada uma função Gausseana para o processo de segmentação temporal do sinal a STFT também é conhecida como Transformada de Gabor (GABOR, 1946).

$$STFT(\tau, f) = \int [x(t)w(t - \tau)]e^{-j2\pi ft} dt \quad (6)$$

Contudo, o processo de segmentação do sinal em janelas de tempo finito apresenta algumas limitações. Com o estreitamento da banda temporal da função janela obtém-se um incremento na resolução temporal da análise do sinal. Entretanto, os segmentos resultantes apresentarão um conseqüente incremento na largura de banda espectral chegando, em casos de funções janela muito estreitas, a não mais possuir relação com o espectro do sinal. Por outro lado, o aumento da abertura temporal da função janela resulta no incremento da resolução espectral, com conseqüente detrimento da resolução temporal. Desta maneira, a função janela não pode possuir largura temporal pequena para evitar que se obtenham distorções entre o espectro resultante e o espectro do sinal original e não pode ser tão grande de forma que o intervalo temporal abranja características não estacionárias do sinal.

Segundo Cohen, (1995), a limitação do tamanho da janela de tempo utilizada é definida pela equação (7), onde σ_ω é a largura de banda do espectro resultante e σ_t é a duração

do sinal modificado. Essa limitação, conhecida como o princípio da incerteza de Heisenberg, denota que não é possível obter-se simultaneamente alta resolução nos domínios do tempo e da frequência.

$$\sigma_{\omega}\sigma_t \geq \frac{1}{2} \quad (7)$$

A área espectro-temporal gerada pela utilização de uma função de janelamento é minimizada quando se utiliza uma função janela Gausseana $g(t)$, na Transformada de Gabor. Para este caso, no plano tempo-frequência, a distribuição de energia em cada segmento é representada simbolicamente por um retângulo, chamado retângulo de Heisenberg (MALLAT, 1999), conforme a figura 10. Cada retângulo está centrado em (t_0, ω) , possui largura temporal relativa ao desvio padrão de $g(t)$ σ_t e largura espectral relativa à resolução espectral em torno da frequência ω , σ_{ω} .




Figura 10: Retângulos de Heisenberg de uma análise espectral utilizando a Transformada de Gabor. Adaptado de Mallat (1999).

Entretanto, como apenas uma função janela é utilizada durante todo o processo de computação da Transformada de Gabor, as resoluções em ambos os domínios estarão sempre diretamente relacionadas ao desvio padrão da função Gausseana utilizada, causando assim uma relação entre as resoluções temporal e espectral também dependente deste desvio padrão, conforme a equação (7). Desta forma, a análise espectral de sinais variantes no domínio da

freqüência através da Transformada de Gabor resulta em retângulos de Heisenberg com tamanhos fixos em todo o plano tempo-freqüência, dividindo este plano sempre em células de tamanho fixo.

Uma forma de contornar a limitação da largura da função janela e obter uma melhor resolução no tempo sem diminuir em muito esta largura é utilizar a técnica conhecida por sobreposição, ou *overlapping*. Esta técnica consiste em separar o sinal analisado em segmentos de tempo que se sobrepõem entre si, de forma que, mesmo com uma janela de tempo de análise larga, a resolução no tempo diminui. Isto acontece porque a resolução da variação no tempo deixa de depender do tamanho da janela, e sim do intervalo de sobreposição. Com isto, quanto maior este intervalo, melhor será a resolução temporal, uma vez que um pedaço pequeno do sinal será deixado de fora na computação do espectro do próximo segmento. Contudo, o uso de intervalos de sobreposição muito grandes leva a um maior número de cálculos de STFTs, gerando redundâncias nas matrizes espectrais obtidas e “contaminando” o espectrograma em caso de componentes não estacionárias no sinal.

O cálculo de várias STFTs de um sinal em seqüência é a base para a criação de uma matriz espectral chamada espectrograma. O espectrograma é obtido particionando o sinal original em janelas de tempo específicas e computando seguidas STFTs destes trechos, obtendo um plano tridimensional que representa a variação de amplitude das componentes em freqüência no decorrer do tempo. Esse plano pode ser visualizado em uma topografia tridimensional ou como uma imagem bidimensional, onde os eixos das abscissas e ordenadas representam respectivamente o tempo e a freqüência, vindo a amplitude ser representada por uma variação de cores ou tons de cinza.

Em sistemas computacionais digitais, o espectrograma é obtido de forma análoga, entretanto, por se tratar de um sistema discreto, as STFTs são substituídas por DFTs ou FFTs. Devido às características intrínsecas dos sistemas discretos, a figura do espectrograma apresenta variação espectral entre 0 e a metade da freqüência de amostragem do sinal, com resolução dependente do número de amostras utilizadas na transformada. A resolução temporal, por sua vez, é dependente do *overlap* utilizado, sendo, no caso de uso máximo, limitada ao tempo de aquisição de uma amostra. Já, tanto a variação quanto a resolução em amplitude do sinal, que usualmente é normalizada utilizando escala logarítmica (dB), é limitada a resolução máxima das variáveis utilizadas para o seu armazenamento.

A figura 11A apresenta o espectrograma de um sinal com frequência fixa de 1 kHz ao longo de todo o tempo, equivalente a um sinal DC modulado em frequência. Já a figura 11B apresenta o espectrograma de um sinal que possui uma variação contínua de 100 Hz a 4 kHz ao longo do tempo. Este sinal equivale a uma rampa modulada em frequência. Os espectrogramas da figura 11 foram obtidos utilizando frequência de amostragem 8kHz, FFTs de 1024 pontos com janela de Hamming e *overlap* de 3,3ms. A escala de cores utilizada é: vermelho: 0 dB mV, verde: -40 dB mV, azul: -80 dB mV.




Figura 11: Espectrogramas de dois sinais distintos. (a) Sinal de 1 kHz invariante no tempo; (b) Sinal com variação contínua de frequência no tempo, de 100 Hz a 4 kHz. Note-se que o eixo das frequências varia de 0 a 4 kHz, ou a frequência de amostragem dividida por dois.

3.4 TRANSFORMADA *WAVELET* EM COMPARAÇÃO À STFT

A STFT possibilita o cálculo do espectro de frequências de um sinal não estacionário incluindo a sua variação no domínio do tempo. Entretanto, conforme apresentado na seção 3.3, esta técnica apresenta a limitação de concentrar a análise tempo-frequência em retângulos de Heisenberg de tamanho fixo, conforme mostrado na figura 12A. Esta propriedade está ligada diretamente à utilização de senos e cossenos, que são funções de suporte infinito e energia também distribuída infinitamente, como base de decomposição do sinal. Assim, a largura da função janela utilizada na STFT limita a energia da dupla de funções seno-cosseno para um determinado intervalo, mas ainda mantém a energia dessas funções praticamente durante todo este intervalo.

Visando contornar estas limitações, J. Morlet (MORLET, 1983), em um trabalho de análise de sinais sismológicos, propôs uma nova abordagem de análise espectral denominada

transformada *wavelet*, na qual se utilizam funções janela de tamanho variável. Esta propriedade permite que eventos de alta frequência possam ser localizados com maior resolução no domínio do tempo enquanto que eventos de baixa frequência possam ser analisados por janelas de maior duração temporal. Para efetuar esta tarefa, foi proposta a utilização de funções com duração efetiva limitada no domínio do tempo e valor médio igual a zero para realizar a tarefa de decompor o sinal.

Na transformada *wavelet*, a função base utilizada para a decomposição é chamada *wavelet* mãe (*mother wavelet*). Assim, a tarefa de análise através de janelas variáveis é realizada variando a escala da função *wavelet* mãe e transladando-a no tempo.

Desta maneira, a localização temporal das componentes em alta frequência é realizada utilizando-se escalas de tamanho reduzido, enquanto que a análise das componentes de baixa frequência é realizada nas escalas maiores. Esta característica demonstra que a análise *wavelet* resulta, no domínio espectral, em blocos de tamanho variável, relativos à escala da função *wavelet* mãe utilizada e que, por sua vez, é relativa ao inverso da frequência. Esta característica é demonstrada graficamente na figura 12.




Figura 12: Representações gráficas das resoluções frequência x tempo obtida através do cálculo da STFT (a) e escala x tempo obtida pela transformada *wavelet* (b). Note-se que o parâmetro escala da transformada *wavelet* está relacionado ao inverso da frequência.

A transformada *wavelet* apresenta um ganho significativo na análise local de discontinuidades de sinais em relação à Transformada de Fourier e à STFT, pois esta é capaz de, além de decompor o sinal em componentes espectrais relativos à escala da função *wavelet* mãe, realizar a localização temporal de componentes de alta frequência, mesmo com baixa amplitude. Esta propriedade pode ser vista nas figuras 13 a 16. O sinal da figura 13 foi gerado

digitalmente como uma senóide de 500 Hz amostrado a uma taxa de 8 kHz, sendo acrescida uma pequena descontinuidade, visível na figura 13b. Este sinal é submetido à análise pela Transformada de Fourier, STFT e Transformada *Wavelet* Contínua, cujos resultados podem ser vistos graficamente nas figuras 14, 15 e 16, respectivamente. Nesta figura, nota-se claramente que as análises pela Transformada de Fourier e STFT não identificam a presença da descontinuidade por esta possuir energia muito menor que a do sinal que a contém. Por outro lado, a análise por transformada *wavelet* contínua é capaz de localizar com precisão as amostras em que houve a descontinuidade.

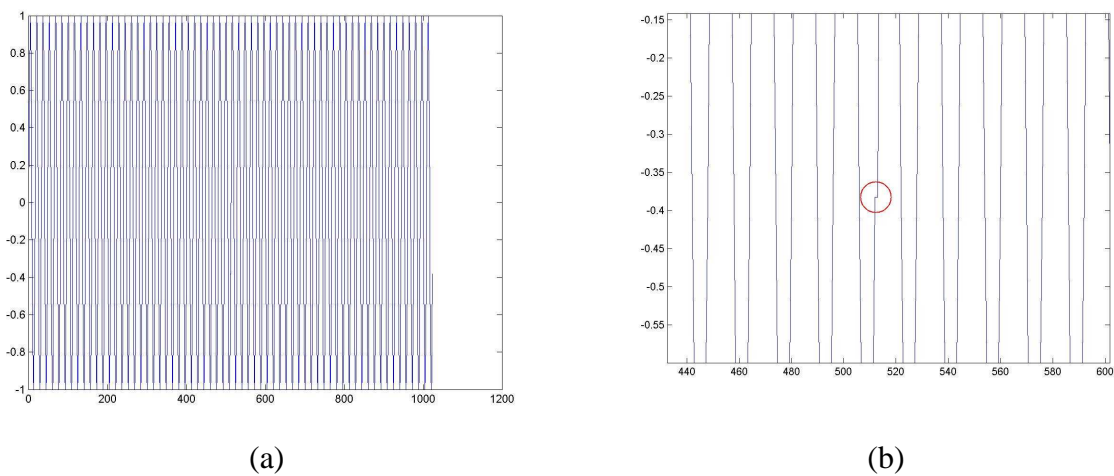


Figura 13: Sinal senoidal com frequência de 500 Hz e uma pequena descontinuidade (a) e zoom do sinal para facilitar a visualização da descontinuidade (b).




Figura 14: Espectro do sinal senoidal de 500 Hz, contendo uma descontinuidade, apresentado na figura 13.

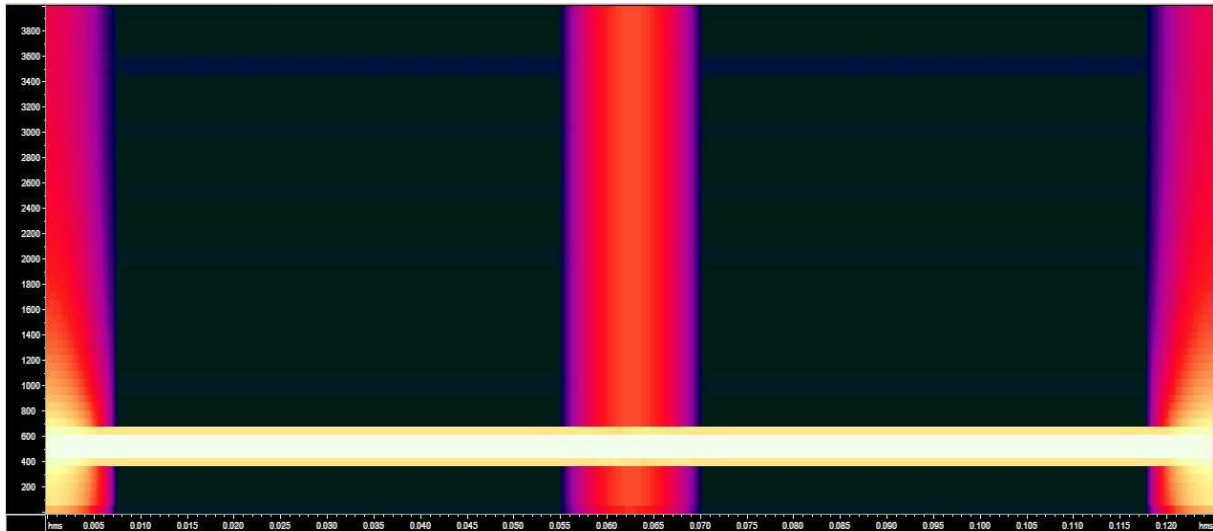


Figura 15: Espectrograma do sinal senoidal de 500 Hz, contendo uma descontinuidade, apresentado na figura 13.

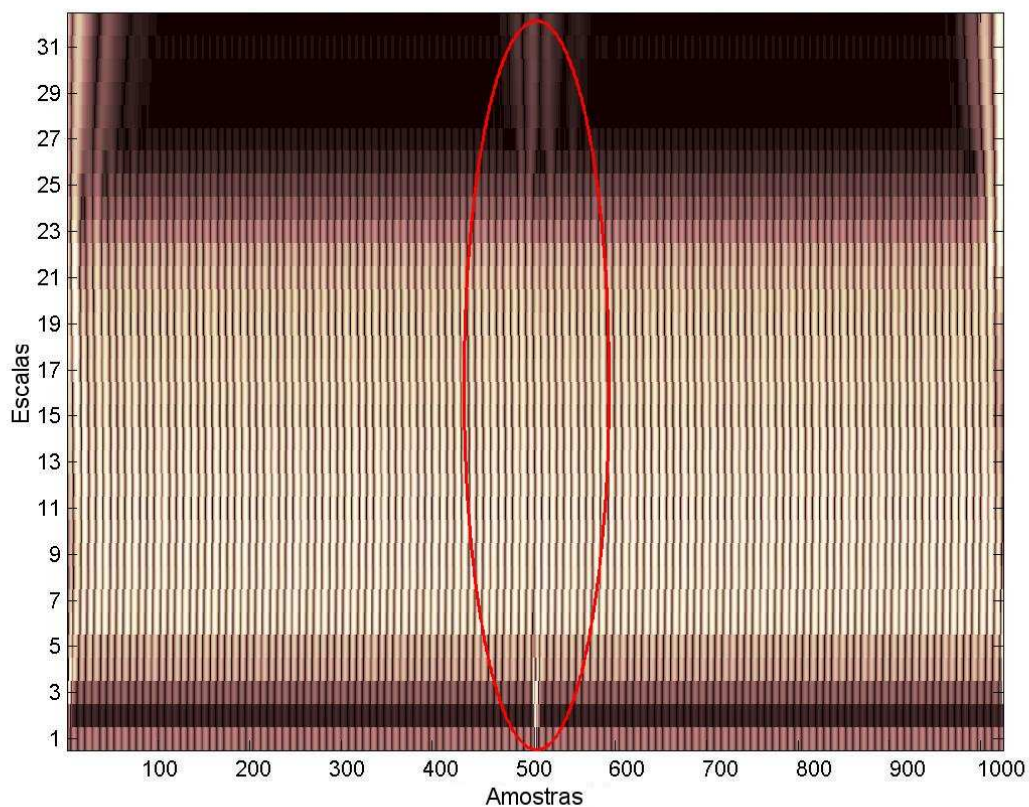


Figura 16: Escalograma resultante da Transformada *Wavelet* Contínua do sinal senoidal contendo uma descontinuidade, apresentado na figura 13, utilizando a função *wavelet* Daubechies 4, apresentada na subseção 3.7.1. A elipse vermelha indica a localização do ponto de descontinuidade do sinal, mais facilmente visível nas escalas menores.

3.5 TRANSFORMADA WAVELET CONTÍNUA (CWT)

A análise *wavelet* é implementada de maneira similar às STFTs, diferindo no ponto em que o sinal é multiplicado por uma função, que é a *wavelet*, similar à função janela das STFTs, sendo a transformada executada separadamente para diferentes segmentos do sinal no domínio do tempo. Desta forma, existem duas diferenças básicas entre as STFTs e a CWT:

1. a Transformada de Fourier de um sinal truncado por uma função janela não é obtido, e um simples pico será visto correspondentemente como uma senóide, e as frequências negativas não são computadas;
2. a largura da janela varia quando a transformada é computada para cada componente espectral simples, o que é provavelmente a característica mais significativa da transformada *wavelet*.

A transformada *wavelet* contínua é definida pela equação (8), na qual o sinal transformado é função de duas variáveis, τ e s , os parâmetros translação e escala, respectivamente, sendo a função $\psi(x)$ a *wavelet* mãe. O termo *wavelet* mãe recebe este nome devido a duas propriedades importantes da análise *wavelet*.

$$CWT_x^\psi(\tau, s) = \Psi_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \psi\left(\frac{t - \tau}{s}\right) dt \quad (8)$$

O termo *wavelet* significa pequena onda. O “pequeno” refere-se à condição de que esta função deva possuir janela temporal de comprimento finito, conforme expresso na equação (9). A onda refere-se à condição de que esta função é oscilatória, devendo obrigatoriamente satisfazer a condição descrita na equação (10). O termo mãe implica que a função com diferentes regiões de ação, utilizada no processo de transformação, é derivada de uma função principal, ou seja, a *wavelet* mãe. Em outras palavras, a *wavelet* mãe é um protótipo para a geração de várias funções janela.

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad (9)$$

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (10)$$

O termo translação é utilizado no mesmo sentido que nas STFTs, e está relacionado à posição da janela quando esta é aplicada sobre o sinal. Este termo, conseqüentemente, corresponde à informação no domínio do tempo. Na transformada *wavelet* não se obtém um parâmetro referente à frequência, como obtido na transformada de Fourier, mas sim um parâmetro escala, que é definido como o inverso da frequência, uma vez que refere-se ao comprimento da função *wavelet* aplicada.

3.6 TRANSFORMADA WAVELET DISCRETA (DWT)

Diferentemente da relação entre a transformada de Fourier contínua e a DFT, onde a segunda refere-se apenas a aplicação da primeira em sinais discretos, a transformada *wavelet* discreta (*discrete wavelet transform*, DWT) propõe uma forma alternativa de análise espectral em relação à CWT. Nesta abordagem, diferentemente da abordagem da transformada discreta de Fourier, a discretização ocorre na aplicação das funções *wavelet* e escala na análise da variável, e não na variável independente em si.

Os trabalhos base para desenvolvimento da transformada *wavelet* discreta datam de 1976 quando CROISER, ESTEBAN e GALAND, 1976, em um trabalho voltado à compressão de sinais de voz, desenvolveram uma técnica para decompor sinais discretos em dois sinais contendo metade do tamanho original, utilizando processos de filtragem e sub-amostragem. Já CROCHIERE, WEBER e FLANAGAN, 1976, desenvolveram um estudo similar aplicado à codificação de sinais de voz, batizando o seu esquema de análise como codificação em sub-bandas (*sub band coding*). Em 1983, Burt e Adelson (BURT E ADELSON, 1983) desenvolveram uma técnica similar à codificação em sub-bandas, para aplicação em codificação de imagens, chamando-a de codificação piramidal (*pyramidal coding*), conhecida também como análise em multiresolução (*Multiresolution Analysis*, MRA), nomenclatura também muito utilizada para DWT. VETTERLI e LE GALL, 1989, implementaram algumas melhorias no esquema de codificação por sub-bandas, removendo algumas redundâncias existentes no algoritmo de codificação piramidal, e aplicando-as em codificação de voz.

O princípio básico da análise em sub-bandas de frequência é o mesmo adotado na transformada *wavelet* contínua. Contudo, esta análise propõe uma representação tempo-escala

do sinal através da decomposição em sub-bandas de frequência utilizando bases ortonormais, implementadas através de bancos de filtros digitais.

A CWT caracteriza-se por realizar o cálculo da correlação entre o sinal e a função *wavelet* mãe, em várias escalas, que são utilizadas como parâmetro de similaridade entre o sinal e a função *wavelet* mãe. Desta maneira, a CWT é basicamente computada alterando-se a escala da janela de suporte da função *wavelet* e convoluindo-a com o sinal em análise.

No caso da DWT, são utilizados filtros com diferentes frequências de corte para realizar a análise do sinal em diferentes escalas, sendo que o sinal é processado por uma série de filtros passa-baixas e passa-altas, com o objetivo de se realizar a análise das componentes de baixa e alta frequência separadamente. Estes filtros são caracterizados pelas propriedades da função *wavelet* utilizada na sua construção, que serão discutidas na seção 3.7. Entretanto, as bases ortonormais das funções *wavelet* discretas estão associadas não somente à função *wavelet* mãe $\psi(x)$, mas também à função escala $\phi(x)$, também conhecida como *father wavelet*. Assim, na DWT, a função *wavelet* mãe está relacionada aos detalhes, ou ao filtro passa-altas enquanto que a função escala relaciona-se com as aproximações, ou ao filtro passa-baixas, formando ambas as funções uma base ortonormal. Desta maneira, a análise da informação espectral do sinal é efetuada através das operações de filtragem. Em contrapartida, a análise no fator escala, referente ao comprimento do vetor de coeficientes, é efetuada através de operações de subamostragem, para o caso de decomposição, e sobreamostragem, na reconstrução do sinal.

A análise em multiresolução, formulada por Mallat e Meyer em 1986, consiste em dividir o sinal original X_0 em uma seqüência de subespaços fechados X_j , que satisfaçam a propriedade (Daubechies, 1992):

$$\dots X_2 \subset X_1 \subset X_0 \subset X_{-1} \subset X_{-2} \dots$$

Desta maneira, a metodologia de análise em multiresolução propõe uma representação tempo-escala do sinal através da obtenção desta seqüência de subespaços pela aplicação de filtros digitais, que são relativos às funções escala ϕ e *wavelet* ψ . Portanto, o sinal é processado por um par de filtros passa-baixas e passa-altas, com certas propriedades, com o objetivo de realizar a segmentação dos subespaços de baixa e alta frequência, sendo que essas funções estão ligadas diretamente a estes filtros (passa-baixas para a função escala ϕ e passa-altas para a função *wavelet* ψ). As propriedades de cada uma dessas funções são definidas de acordo com as propriedades desejadas quando da construção da função *wavelet*.

A função escala ϕ , para $\{\phi_{0,n}; n \in Z\}$, forma uma base ortonormal para o espaço X_j , conforme descreve a equação (11), enquanto a função *wavelet* ψ , para $\{\psi_{j,k}; j, k \in Z\}$ segundo a equação (12), forma uma base ortonormal para W_j (Daubechies, 1992).

$$\phi_{j,k}(t) = 2^{-j/2} \phi(2^{-j}t - k), j, k \in Z \quad (11)$$

$$\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j}t - k), j, k \in Z \quad (12)$$

W_j é definido como o complemento ortogonal de X_j em X_{j-1} a partir da equação (13), com $X_j \perp W_j$ e onde \oplus denota a soma direta entre os coeficientes dos vetores.

$$X_{j-1} = X_j \oplus W_j, j \in Z \quad (13)$$

Assim, a partir da equação (14), o sinal X_0 pode ser decomposto de acordo com a equação (13), simplesmente iteragindo o processo J vezes.

$$X_0 = X_j \oplus \bigoplus_{k=0}^{J-j-1} W_{j-k} \quad (14)$$

As seqüências de subespaços $\{X_j\}_{j \in Z}$ e $\{W_j\}_{j \in Z}$, no espaço $L^2(\mathfrak{R})$ são chamadas de subespaços ou coeficientes de aproximação e detalhe, respectivamente. Uma vez que o subespaço X_j é obtido a partir da função escala ϕ , o subespaço aproximação refere-se às componentes espectrais de baixa freqüência, enquanto o subespaço detalhe, obtido a partir da função *wavelet* ψ , refere-se às componentes espectrais de alta freqüência. Desta forma, a projeção ortogonal do sinal de entrada em W_j e X_j , utilizando as bases ortonormais de (11) e (12), decompõem o sinal de entrada em componentes de baixa freqüência, contidos em V_j , e de alta freqüência, contidos nos espaços $W_i, i=1, \dots, j$.

A grande vantagem da análise em multiresolução consiste em que, através da equação (14), a soma direta dos componentes de baixa freqüência X_j com as de alta freqüência W_j resulta no sinal original. A decomposição do sinal de entrada em espaços aproximação e detalhe é a base da análise em multiresolução MRA (MALLAT, 1999), e pode ser realizada utilizando um par de filtros de resposta finita ao impulso (FIR) H, L, respectivamente, passas altas e passas baixas, no processo de decomposição e seus adjuntos H' e L', para o processo de reconstrução. O esquema de decomposição até o segundo nível pode ser representado graficamente conforme a figura 17, que representa a decomposição até a obtenção dos subespaços aproximação e detalhe até o segundo nível de decomposição.

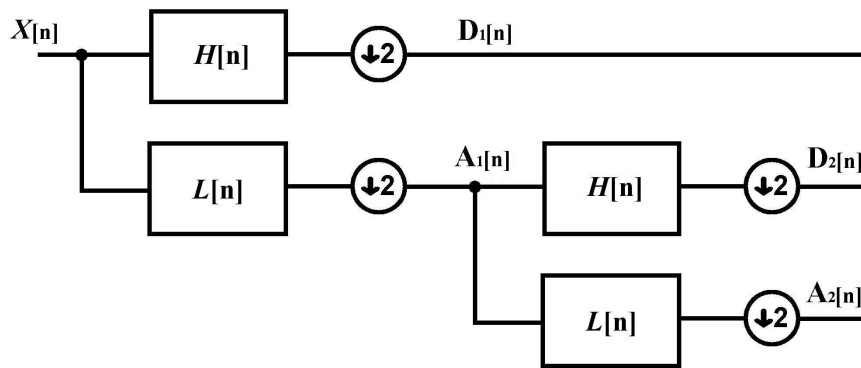


Figura 17: Processo de decomposição *wavelet* do sinal $X(n)$.

Assim, o processo de decomposição *wavelet* divide por dois a resolução temporal do sinal uma vez que, finalizada a decomposição, somente a metade das amostras caracteriza o sinal inteiro. Entretanto, esta operação dobra a resolução em frequência, já que a banda espectral do sinal agora representa apenas a metade da banda de frequências do sinal original, reduzindo, assim, a incerteza no domínio da frequência pela metade.

Note-se que, conforme as equações (13) e (14), o procedimento de decomposição *wavelet* pode ser repetido, gerando novos níveis de decomposição adicionais. A cada nível, as operações de filtragem e sub-amostragem resultam na metade do número das amostras apresentando, conseqüentemente, metade da resolução temporal, metade de banda de frequências original e o dobro da resolução em frequência.

Uma vez decomposto o sinal, as componentes em frequência mais proeminentes no sinal original apresentam amplitudes elevadas nas sub-bandas da DWT que incluem estas frequências particulares, assim como ocorre na Transformada de Fourier. Entretanto, a principal diferença entre a DWT e a transformada de Fourier caracteriza-se pelo fato de que a localização temporal dessas componentes em frequência não se perde. Entretanto, a localização temporal de uma componente em frequência apresenta uma resolução dependente do nível de decomposição em que ela se encontra sendo que, quanto mais alta a componente em análise, mais baixo o nível de decomposição que a representa e, conseqüentemente, maior a resolução no domínio do tempo. Assim, o procedimento de decomposição *wavelet* apresenta a característica de apresentar uma boa resolução no domínio do tempo para as altas frequências e uma boa resolução no domínio da frequência para as componentes de baixas frequências. Por outro lado, as componentes em frequência pouco relevantes no sinal original apresentam amplitudes muito baixas, sendo que estas sub-bandas da DWT podem ser rejeitadas com pouca perda da informação principal, permitindo assim a compressão de dados.

Uma propriedade importante da DWT é a relação entre as respostas ao impulso das funções escala e *wavelet*. Estes filtros não são independentes entre si, estando relacionados conforme a equação (15), onde $H[n]$ representa a resposta ao impulso do filtro passa-altas, $L[n]$ a resposta ao impulso do filtro passa-baixas e T o número de coeficientes dos filtros.

$$H[T - 1 - n] = (-1)^n \cdot L[n] \quad (15)$$

Na equação (15), nota-se que os filtros são formados pelos índices ímpares alternados e invertidos entre si. Os filtros que satisfazem esta propriedade são conhecidos como filtros espelhados em quadratura (*Quadrature Mirror Filters*, QMF). A reconstrução do sinal original é facilmente obtida uma vez que os filtros de meia banda espectral formam bases ortonormais. Desta maneira, é possível reconstruir-se o sinal adotando-se o mesmo procedimento de decomposição seguindo, porém, a ordem inversa. Neste processo, os coeficientes dos sinais aproximação e detalhe obtidos na decomposição são sobreamostrados em uma ordem de dois, filtrados através dos filtros de síntese $H'[n]$ e $L'[n]$, respectivamente, filtro passa-altas e passa-baixas e então adicionados. O ponto interessante aqui é que, para as bases ortonormais, os filtros da análise e da síntese são idênticos, exceto à reversão no tempo. A equação (16) descreve a reconstrução, para cada nível e a figura 18 ilustra este procedimento.

$$x[n] = \sum_{k=0}^N (D'[k] \cdot H'[2k - n]) + (A'[k] \cdot L'[2k - n]) \quad (16)$$

Contudo, para que a reconstrução perfeita do sinal original seja possível, é necessário utilizar-se filtros de meia banda perfeitos. Embora não seja possível construir filtros ideais, sob determinadas circunstâncias é possível encontrar os filtros que fornecem a reconstrução perfeita.

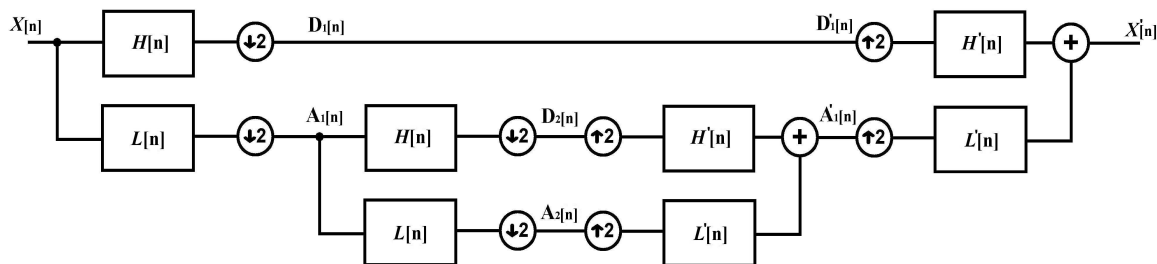


Figura 18: Processos de decomposição e reconstrução *wavelet*.

3.7 FAMÍLIAS DE FUNÇÕES WAVELET

Conforme discutido nas seções 3.5 e 3.6, a CWT e a DWT constituem ferramentas de aplicação simples em sistemas computacionais, com resultados que oferecem razoáveis ganhos quando comparados à análise espectral por Transformada de Fourier e Transformada de Fourier de Curta Duração. Entretanto, a base dessas técnicas consiste no projeto tanto das funções *wavelet* mãe e escala quanto de seus respectivos filtros de decomposição e reconstrução. Desta maneira, foram propostas inicialmente várias bases ortonormais que cumprem os requisitos de aplicação da CWT e DWT, principalmente por Ingrid Daubechies (DAUBECHIES, 1992), a mais relevante pesquisadora na área de *wavelets*. As principais *wavelets* de bases ortonormais serão apresentadas nas subseções 3.7.1 a 3.7.4. Posteriormente, visando possibilitar tanto a simetria das funções *wavelet* quanto a reconstrução exata do sinal foram propostas abordagens de bases biortogonais para a análise *wavelet*, criando as funções *wavelet* biortogonais, sendo estas funções apresentadas na subseção 3.7.5.

3.7.1 Wavelets de Daubechies

Ingrid Daubechies criou as funções *wavelet* ortonormais de suporte compacto, batizadas de família de *wavelets* de Daubechies. Estas funções possuem a característica de possuir um máximo número de momentos nulos para um dado suporte. Esta característica implica em uma maior eficiência dos filtros de decomposição, com maior fator de qualidade dentro do suporte utilizado. Desta maneira, assim como a *wavelet* de Haar (HAAR, 1910), as *wavelets* de Daubechies possuem uma função escala, necessária para a aplicação da análise em multiresolução. As *wavelets* da família Daubechies não possuem expressão analítica, com exceção feita à função db1, sendo obtidas a partir do seu filtro de decomposição $H[n]$. O cálculo dos coeficientes deste filtro é realizado resolvendo o sistema formado pelas equações (19) a (21) (DAUBECHIES, 1992), onde n refere-se ao tamanho do suporte da função *wavelet*

mãe, $b = 0, 1, \dots, \left(\frac{n}{2}\right) - 1$ e $l = 0, 1, \dots, \left(\frac{n}{2}\right) - 1$.

$$\sum_{k=0}^{n-1} (-1)^k h_k k^b = 0 \quad (19)$$

$$\sum_{k=0}^{n-1} h_k = 2 \quad (20)$$

$$\sum_{k=0}^{n-1} h_k h_{k+2l} = 0 \quad (21)$$

Uma vez resolvido o sistema formado pelas equações (19) a (21) para um dado suporte n , as funções escala e *wavelet* são obtidas a partir das equações (22) e (23).

$$\phi(t) = \sum_k h_k \phi(2t - k) \quad (22)$$

$$\psi(t) = \sum_k l_k \phi(2t - k) \quad (23)$$

Exemplos de funções escala e *wavelet* da família Daubechies para alguns suportes são mostrados na figura 19.

3.7.2 Wavelet Meyer

A *wavelet* Meyer foi desenvolvida por Yves Meyer (MEYER, 1986) através de uma função com banda de frequências limitada, cuja transformada de Fourier apresenta forma suave. Esta suavidade resulta em um rápido decaimento assintótico no domínio do tempo, o que resulta em uma função *wavelet* sem suporte compacto e continuamente diferenciável. Contudo, apesar do seu suporte não ser compacto, este rápido decaimento resulta em uma energia muito concentrada, gerando um suporte efetivo localizado no intervalo $[-8, 8]$ conforme ilustra a figura 20.

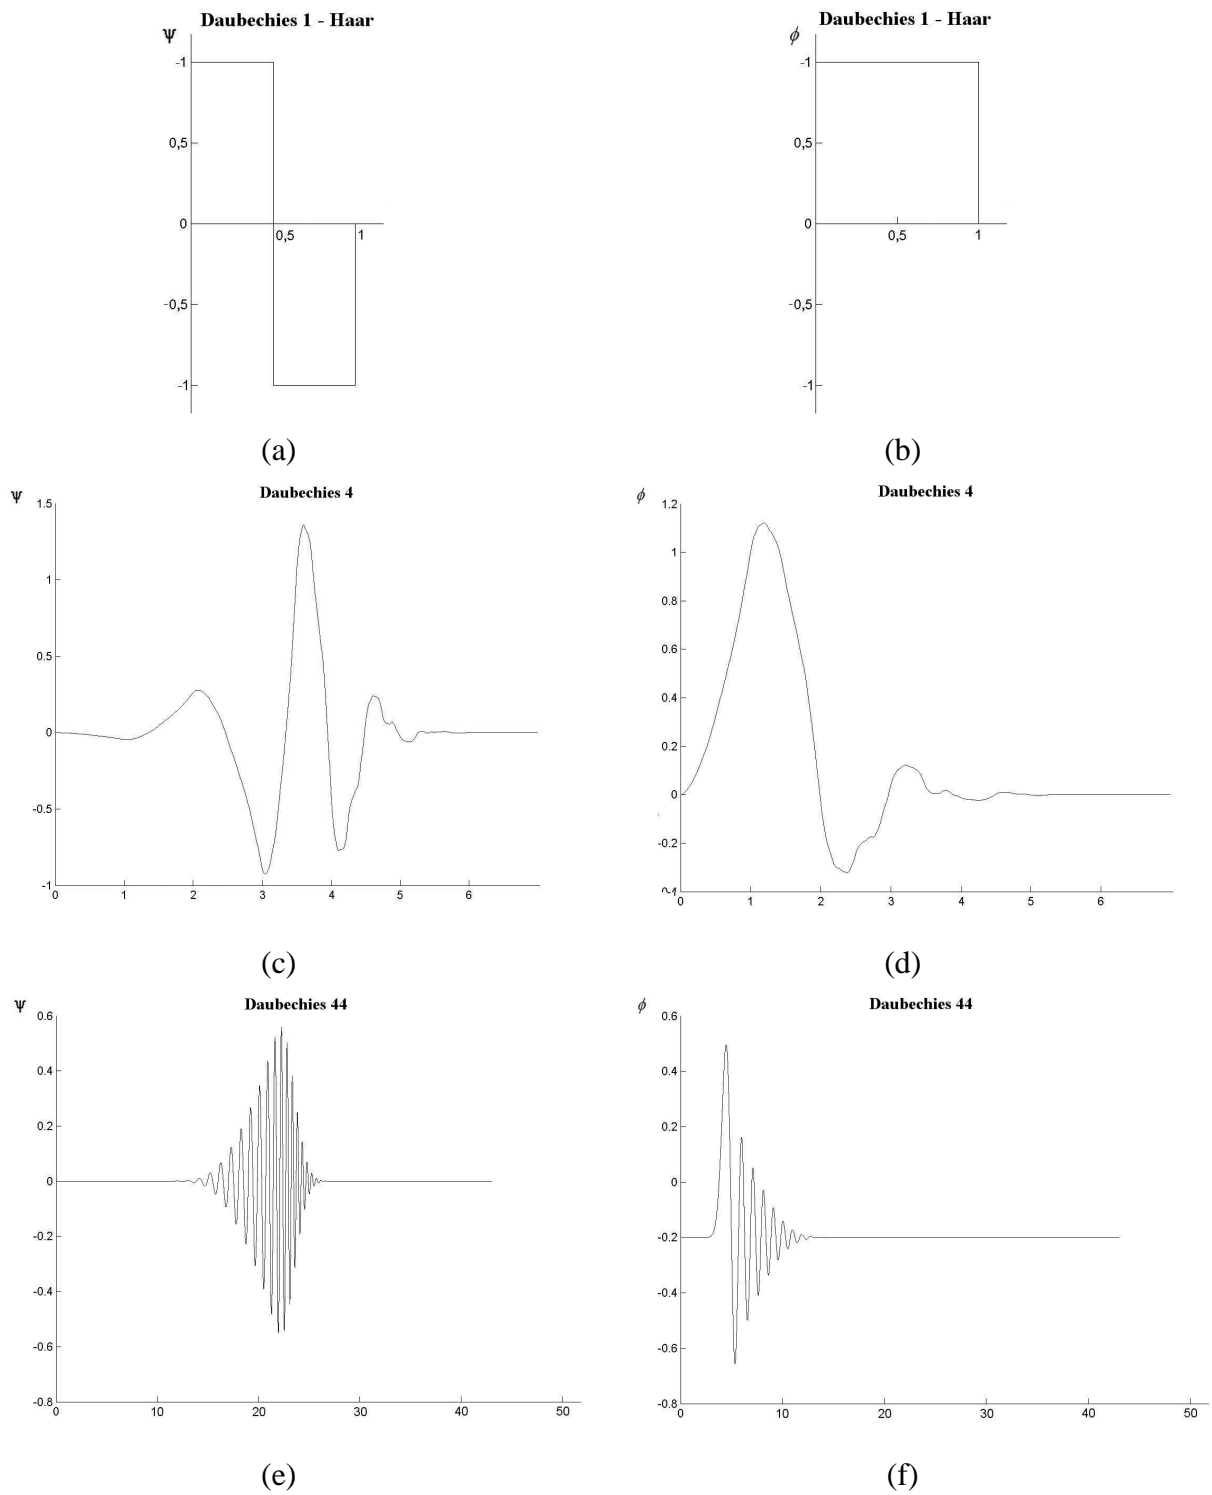


Figura 19: Exemplos de funções *wavelet* e escala da família Daubechies para diferentes suportes. Funções *wavelet* (a) e escala (b) para suporte 1, igual à *wavelet* de Haar, funções *wavelet* (c) e escala (d) para suporte 4 e funções *wavelet* (e) e escala (f) para suporte 44.

Assim, tanto a função *wavelet* ψ quanto a função escala ϕ são definidas no domínio da frequência, através de uma função auxiliar v e, então, transpostas para o domínio do tempo. Essas funções são definidas conforme as equações (24) e (25) (DAUBECHIES, 1992), sendo $\hat{\psi}$ e $\hat{\phi}$, respectivamente, a transformada de Fourier das funções *wavelet* e escala Meyer. Já a função auxiliar v deve satisfazer a propriedade descrita na equação (26).

$$\begin{aligned} \hat{\psi}(\omega) &= (2\pi)^{-\frac{1}{2}} e^{\frac{i\omega}{2}} \text{sen}\left(\frac{\pi}{2} v\left(\frac{3}{2\pi}|\omega|-1\right)\right) & \text{para } \frac{2\pi}{3} \leq |\omega| \leq \frac{4\pi}{3} \\ \hat{\psi}(\omega) &= (2\pi)^{-\frac{1}{2}} e^{\frac{i\omega}{2}} \text{sen}\left(\frac{\pi}{2} v\left(\frac{3}{4\pi}|\omega|-1\right)\right) & \text{para } \frac{4\pi}{3} \leq |\omega| \leq \frac{8\pi}{3} \\ \hat{\psi}(\omega) &= 0 & \text{para os outros casos.} \end{aligned} \quad (24)$$

$$\begin{aligned} \hat{\phi}(\omega) &= (2\pi)^{-\frac{1}{2}} & \text{para } |\omega| \leq \frac{2\pi}{3} \\ \hat{\phi}(\omega) &= (2\pi)^{-\frac{1}{2}} \cos\left(\frac{\pi}{2} v\left(\frac{3}{2\pi}|\omega|-1\right)\right) & \text{para } \frac{2\pi}{3} \leq |\omega| \leq \frac{4\pi}{3} \\ \hat{\phi}(\omega) &= 0 & \text{para } |\omega| > \frac{4\pi}{3} \end{aligned} \quad (25)$$

$$\begin{aligned} v(x) &= 0 & \text{para } x \leq 0 \\ v(x) &= 1 & \text{para } x \geq 1 \\ v(x) + v(1-x) &= 1 \end{aligned} \quad (26)$$

Graficamente, a função *wavelet* Meyer e o módulo de seu espectro são definidos conforme a figura 20, como exemplo da função auxiliar $v(x) = x^4(35 - 84x + 70x^2 - 20x^3)$ para $x \in [0,1]$ (DAUBECHIES, 1992).




Figura 20: Módulo do espectro (a) e sinal no tempo (b) da função *wavelet* de Meyer.

Apesar de a *wavelet* Meyer não possuir suporte compacto, que configura uma característica necessária para a obtenção dos filtros de síntese e análise, existe uma aproximação bastante fiel desta *wavelet* através de filtros FIR, que possibilitam o cálculo da transformada *wavelet* discreta através da *wavelet* Meyer. Esta aproximação é conhecida como “*Discrete approximation of the Meyer Wavelet*”, ou *Discrete Meyer Wavelet* (MISITI *et al.*, 2004).

3.7.3 Coiflets

As Coiflets foram criadas por Ingrid Daubechies em 1989, por sugestão de R. Coifman. Este sugeriu que valeria a pena construir bases de *wavelets* ortonormais com máximos momentos nulos não apenas para a função *wavelet*, mas também para a função escala (DAUBECHIES, 1992). Com esta propriedade, procurou-se manter uma maior semelhança entre o sinal original e o sinal processado. Desta forma, o filtro de análise $H[n]$ é sempre o par do filtro espelhado em quadratura QMF do filtro $L[n]$, com suporte sempre múltiplo de 6. As funções *wavelet* mãe da família *Coiflets* são denominadas $coifN$, sendo N referente à ordem da função. Contudo, alguns autores utilizam $2N$ ao invés de N , principalmente devido ao fato da função *wavelet* possuir $2N$ momentos nulos, com função escala possuindo $2N-1$ momentos nulos. Ambas as funções possuem suporte compacto com tamanho $6N-1$.

Pode-se afirmar que as Coiflets são menos assimétricas que as *wavelets* Daubechies. Já em relação ao suporte, pode-se afirmar que as Coiflets N comparam-se às Daubechies $3N$. Em relação aos momentos nulos, as Coiflets N comparam-se às Daubechies $2N$ (MISITI *et al.*, 2004). A figura 21 ilustra algumas funções escala e *wavelet* da família Coiflets.

3.7.4 Symlets

As funções da família Symlets foram construídas visando dar máxima simetria possível para as bases de funções ortonormais. Este foi o motivo pelo qual esta família de funções recebeu este nome, sendo que, pelo fato de elas não serem realmente simétricas, alguns autores não as chamam de Symlets (MISITI *et al.*, 2004).

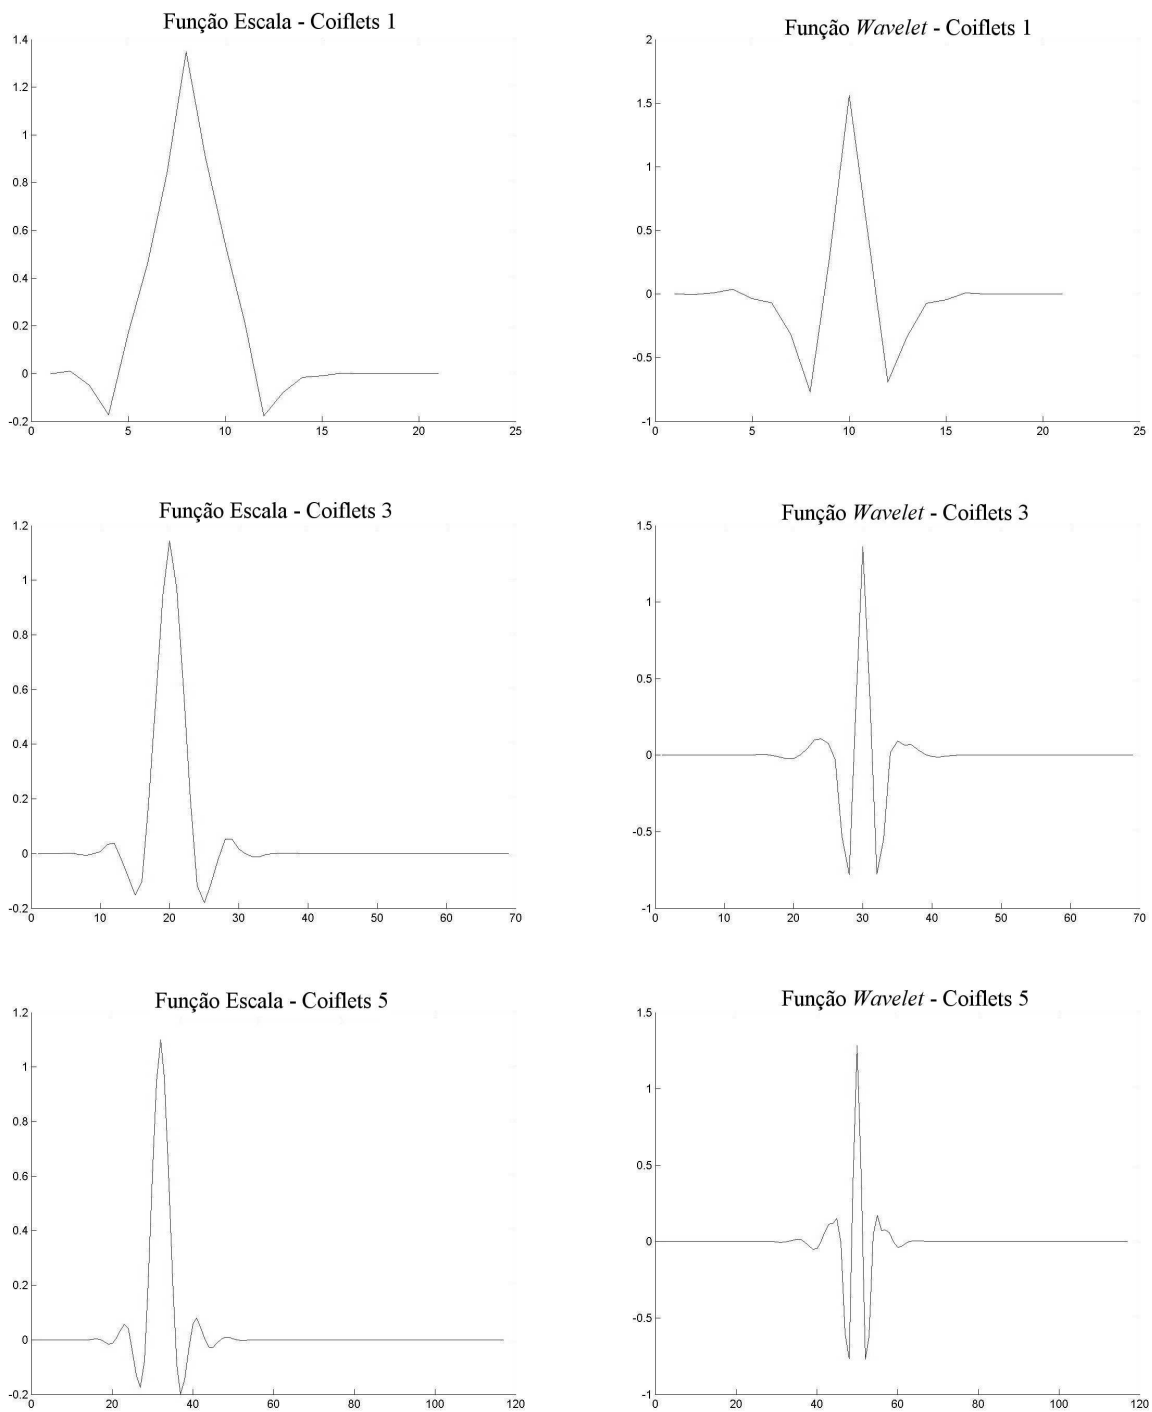


Figura 21: Funções escala e wavelet da família *Coiflets* ordens 1, 3 e 5.

Desta maneira, essas são *wavelets* aproximadamente simétricas, propostas por I. Daubechies como modificações à própria família Daubechies. Contudo, as propriedades das duas famílias *wavelet* são bastante similares. Também nesta família, o filtro de análise $H[n]$ forma sempre o par QMF de $L[n]$, que apresenta sempre suporte de valor par maior ou igual a 4. As respostas em frequência dos filtros $H[n]$ e $L[n]$ melhoram à medida que o suporte da função *wavelet* aumenta.

As *wavelets* mãe da família Symlets variam bastante a sua ordem, vindo de 2 a 45. Esta família apresenta algumas características gerais tais como: possuir suporte compacto com menor assimetria e maior decaimento em relação à largura, quando comparado à família Daubechies. A figura 22 contém exemplos de funções escala e *wavelet* da família Symlets.

3.7.5 Wavelets Biortogonais

Um fator bastante conhecido na comunidade de codificação e análise em sub-bandas refere-se ao fato de que simetria e reconstrução exata são incompatíveis se os mesmos filtros (para caso de filtros FIR) são utilizados tanto nos processos de decomposição quanto de reconstrução (DAUBECHIES, 1992), com exceção da *wavelet* de Haar. Para contornar esta limitação, Cohen, Daubechies e Feauveau, (1992), propuseram a utilização de duas *wavelets* ao invés de uma, para o processo de decomposição e reconstrução. Desta forma, possibilita-se a utilização de funções *wavelet* simétricas com suporte compacto para obter a reconstrução exata do sinal em análise.

Contudo, juntamente com esta abordagem, surgem algumas questões relacionadas à análise de multiresolução e como as bases de *wavelets* associadas vão diferir das bases ortonormais. Na realidade, desde que os filtros satisfaçam certas condições, o que se obtém é um esquema que corresponde a duas bases de *wavelets* duais, associadas a duas diferentes multiresoluções (DAUBECHIES, 1992). Assim, para possibilitar a reconstrução exata, propõe-se a construção de quatro seqüências $H = (h_n)_{n \in \mathbb{Z}}$, $L = (l_n)_{n \in \mathbb{Z}}$, $\tilde{H} = (\tilde{h}_n)_{n \in \mathbb{Z}}$ e $\tilde{L} = (\tilde{l}_n)_{n \in \mathbb{Z}}$, duas das quais serão utilizadas na decomposição (H, L) e duas para reconstrução (\tilde{H}, \tilde{L}) .

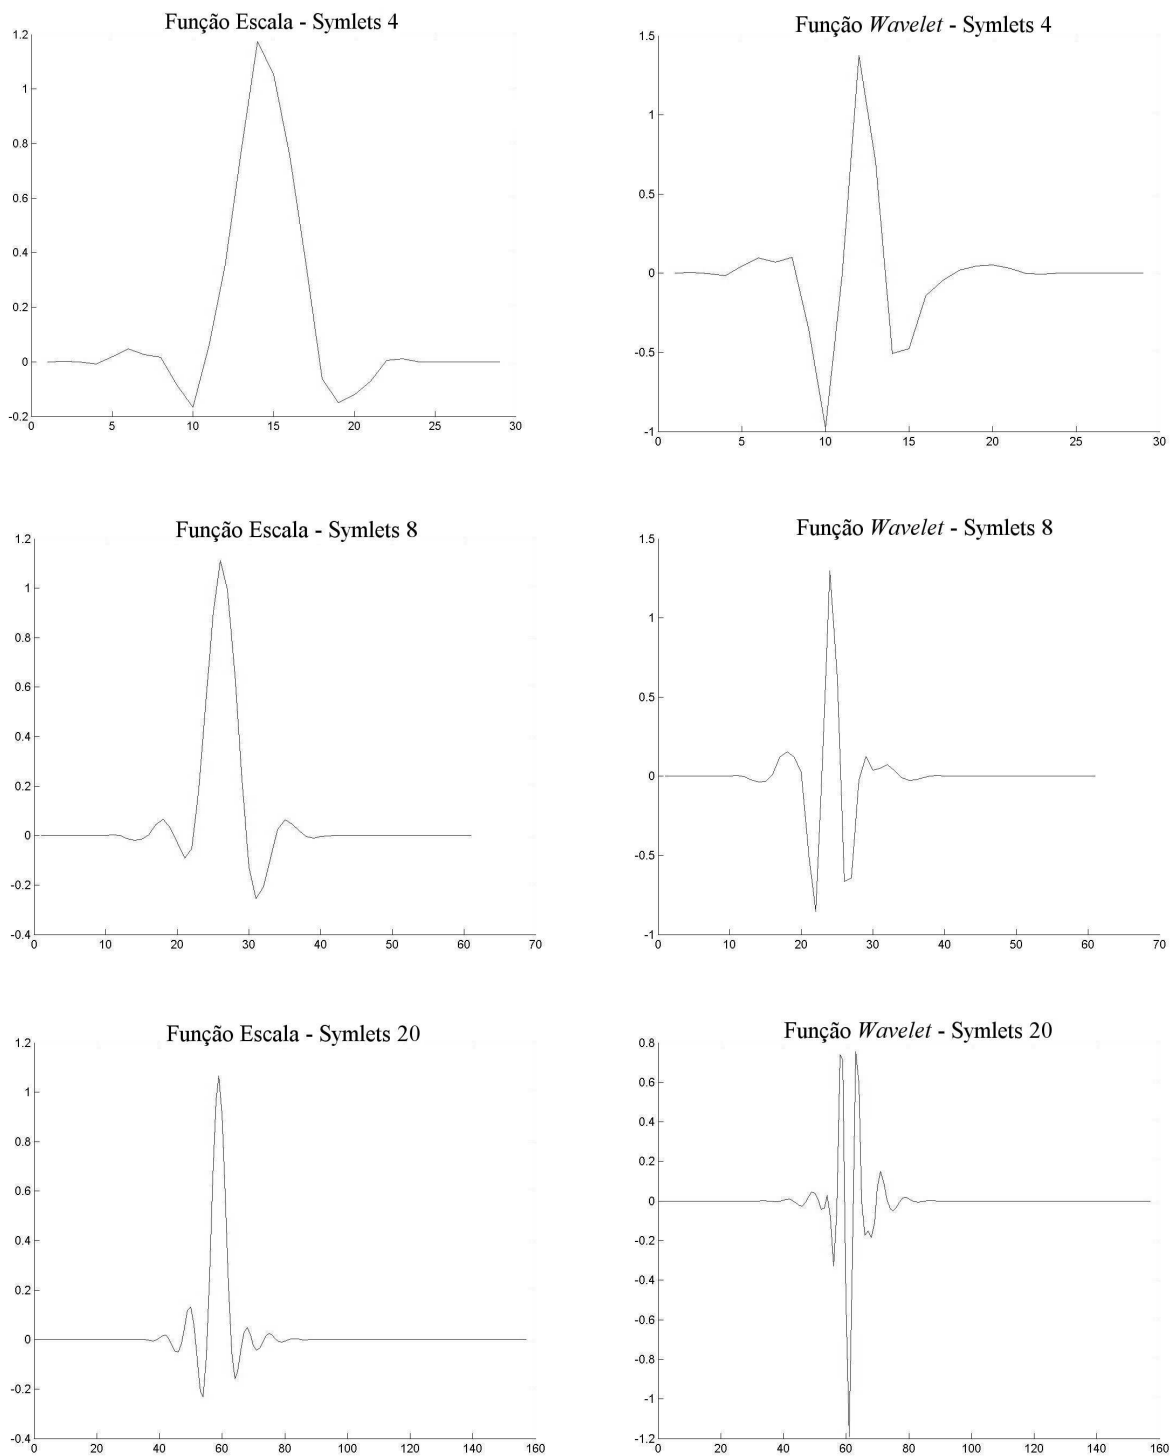


Figura 22: Funções escala e *wavelet* da família Symlets ordens 4, 8 e 20.

A obtenção de bases de funções *wavelet* biortogonais segue o seguinte princípio: tendo como base um sinal $x_{0,k} k \in Z$, convoluindo-o com $H[n]$ e $L[n]$ e subamostrando-o em uma ordem de dois para a decomposição e obtenção dos coeficientes de aproximação e detalhe, utilizam-se as equações (27) e (28).

$$d_{1,n} = \sum_k H_{2n-k} x_{0,k} \quad (27)$$

$$a_{1,n} = \sum_k L_{2n-k+1} x_{0,k} \quad (28)$$

Para a reconstrução do sinal, através dos vetores de coeficientes de detalhe e aproximação $d_{1,n}$ e $a_{1,n}$ é realizada a operação reversa, sobreamostrando-se os vetores em uma ordem de dois intercalando zeros entre as amostras, convolucionando-os com os filtros de reconstrução (\tilde{H}, \tilde{L}) e somando-se os resultados, conforme a equação (29).

$$\tilde{x}_{0,l} = \sum_n \left[\tilde{H}_{2n-l} d_{1,n} \oplus \tilde{L}_{2n-l+1} a_{1,n} \right] \quad (29)$$

Para se obter a reconstrução exata, deve-se impor a condição $\tilde{x}_0 = x_0$, o que resulta na equação (30).

$$\sum_n \left[\tilde{H}_{2n-l} H_{2n-k} + \tilde{L}_{2n-l+1} L_{2n-k+1} \right] = \delta_{lk} = \begin{cases} 1, l=k \\ 0, l \neq k \end{cases} \quad (30)$$

Desta forma, conforme a construção das funções para as bases ortonormais (DAUBECHIES, 1992), obtêm-se as seguintes regras de construção para as duplas de funções escala e *wavelet* biortogonais, conforme as equações (31) a (34). Daubechies, (1992), apresenta todos os critérios para verificar a biortogonalidade das bases destas equações, assim como Mallat (1999) apresenta os critérios necessários às funções *wavelet* biortogonais no tocante à análise em multiresolução.

$$\phi(t) = \sqrt{2} \sum_n H_n \phi(2t - n) \quad (31)$$

$$\tilde{\phi}(t) = \sqrt{2} \sum_n \tilde{H}_n \phi(2t - n) \quad (32)$$

$$\psi(t) = \sqrt{2} \sum_n L_{n+1} \phi(2t - n) \quad (33)$$

$$\tilde{\psi}(t) = \sqrt{2} \sum_n \tilde{L}_{n+1} \tilde{\phi}(2t - n) \quad (34)$$

CAPÍTULO 4

REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais são sistemas de processamento de informação que possuem algumas características em comum com as redes de neurônios biológicos (FAUSETT, 1994). Basicamente, são sistemas que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes, que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento. Já o cérebro humano, no nascimento, possui cerca de 100 bilhões de neurônios, sendo que a maioria está localizada no cérebro.

Segundo Haykin (2001), uma rede neural artificial é um processador massivamente paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Ainda, segundo o mesmo autor, a rede neural extrai o seu poder computacional através, primeiro, de sua estrutura paralelamente distribuída e segundo de sua habilidade de aprender e, portanto, de generalizar. A generalização se refere ao fato da rede neural produzir saídas adequadas para entradas que não estavam presentes durante o treinamento. Essas duas capacidades de processamento de informação tornam possível para as redes neurais resolver problemas complexos e de grande escala que atualmente são intratáveis por outros métodos.

4.1 MODELO DE UM NEURÔNIO

Uma rede neural artificial é composta por unidades de processamento, os neurônios, que são divididos em quatro partes: as sinapses, o *bias* ou polarização, o somador e a função de ativação, conforme a figura 23. Essas unidades são conectadas às entradas ou entre si por canais de comunicação, ou sinapses, que estão associadas a um determinado peso. Durante o processamento, o neurônio representado na figura 23, multiplica o valor de suas entradas x_n pelos pesos sinápticos w_{kn} e apresenta os resultados ao somador. Até este ponto, as operações descritas constituem um combinador linear. À saída do somador é acrescido o valor da polarização b_k , que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente. Ao acrescentar-se a polarização à saída do somador obtêm-se o campo local induzido v_k . A não-linearidade do neurônio é dada pela função de ativação $\varphi(\cdot)$, que tem como função limitar a amplitude da saída y_k por ele apresentada. Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$ (HAYKIN, 2001). Desta maneira, as operações realizadas por um neurônio são descritas pelas equações (35) e (36).

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (35)$$

$$y_k = \varphi(u_k + b_k) \quad (36)$$

As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento não linear de uma rede neural artificial vem da não-linearidade das funções de ativação de cada neurônio e, conseqüentemente, das interações entre os neurônios da rede.

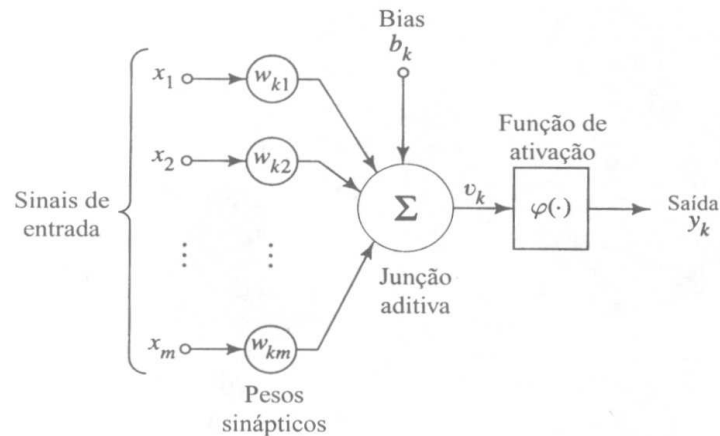


Figura 23: Modelo não-linear de um neurônio (HAYKIN, 2001).

A função de ativação, dada por $\varphi(v)$, gera a saída do neurônio de acordo com o valor de campo local induzido v . Entre os vários tipos de funções com este fim destacam-se três tipos básicos: a função limiar, linear por partes e a função sigmóide. Exemplos dessas três funções são ilustradas graficamente na figura 24.

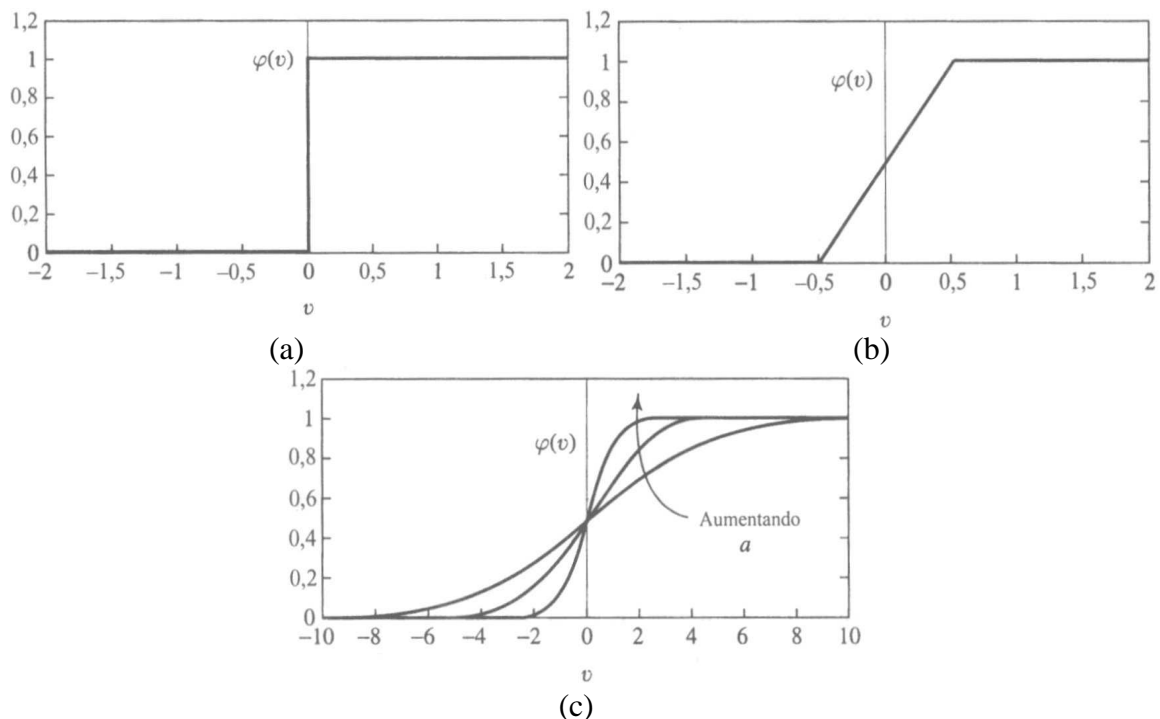


Figura 24: Tipos de funções de ativação: (a) Função limiar; (b) Função linear por partes; (c) Função sigmóide para parâmetro de inclinação a variável (HAYKIN, 2001).

A função limiar, também conhecida como função de *Heaviside*, está descrita na equação (37). Esta função foi utilizada por McCulloch e Pitts (1943) e descreve a propriedade tudo-ou-nada do modelo dos mesmos autores.

$$\begin{aligned} \varphi(v) &= 1 \text{ se } v_k \geq 0 \\ &0 \text{ se } v_k < 0 \end{aligned} \quad (37)$$

Na função linear por partes, descrita pela equação (38), assume-se que o fator de amplificação dentro da região de limiar de operação é a unidade. Esta forma de função de ativação pode ser vista como uma aproximação de um amplificador não linear. Assim, a função linear por partes se comporta como um combinador linear se o campo local induzido v se mantiver dentro de uma determinada faixa de operação e vindo a saturar caso este valor extrapole a região de operação, de forma a se comportar como uma função de limiar para este caso.

$$\varphi(v) = \begin{cases} 1, & v \geq +1/2 \\ v, & +1/2 > v > -1/2 \\ 0, & v \leq -1/2 \end{cases} \quad (42)$$

A função sigmóide, que apresenta gráfico em forma de s, como pode ser visto na figura 24c, é de longe a forma mais comum de função de ativação utilizada na construção de redes neurais artificiais. Ela é definida como uma função estritamente crescente que exhibe um balanceamento adequado entre comportamento linear e não-linear. Um exemplo de função sigmóide é a função logística, definida pela equação (39), onde a é o parâmetro de inclinação da função sigmóide.

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (39)$$

Variando-se o valor de a obtêm-se funções sigmóides com diferentes inclinações (figura 24c). No limite, com o parâmetro de inclinação a tendendo ao infinito, a função sigmóide se torna uma função de limiar. Enquanto a função limiar assume os valores 0 ou 1, uma função sigmóide assume um intervalo contínuo de valores entre 0 e 1. Pode-se notar que a função sigmóide é diferenciável, enquanto que a função limiar não o é, o que é uma característica importante para alguns tipos de algoritmos de treinamento de redes neurais artificiais. Esta característica será explorada na subseção 4.3.1.

4.2 ESTRUTURAS DE REDES NEURAS ARTIFICIAIS

Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior. Várias arquiteturas

distintas podem ser formadas arranjando os neurônios em uma rede neural, mas a classificação mais abrangente as separa em dois grupos básicos: as redes de camada simples e de múltiplas camadas.

4.2.1 Redes de camada simples

As redes neurais artificiais de camada simples, ou de uma camada, são redes que possuem apenas uma matriz de pesos, ou seja, apenas uma coluna de neurônios separa a entrada do sistema de sua saída. Desta forma, as entradas de cada neurônio estão conectadas às entradas do sistema e suas saídas correspondem às saídas da rede. Entretanto não há comunicação entre os neurônios da rede. A figura 25 mostra a representação de uma rede neural artificial de uma única camada.




Figura 25 : Rede neural artificial de camada simples (HAYKIN, 2001).

4.2.2 Redes de múltiplas camadas

Uma rede neural artificial também pode apresentar diversas camadas, sendo então chamada de *multilayer*, ou multicamada. Neste tipo de rede, a saída apresentada é computada através das conexões dos neurônios com as entradas e entre si, sendo que cada coluna de neurônios caracteriza uma camada, classificada em três grupos: camada de entrada, onde se localizam as entradas do sistema, e onde os neurônios da primeira

camada escondida se comunicam com os padrões que são apresentados à rede; camadas intermediárias ou ocultas, onde as saídas apresentadas pela camada anterior, que pode ser a de entrada ou outra camada escondida, são processadas e a camada de saída, onde o resultado final é processado e apresentado. Adicionar uma ou mais camadas ocultas a uma rede neural, torna-a capaz de extrair estatísticas de ordem elevada dos sinais de entrada. Em um sentido livre, a rede adquire uma perspectiva global, apesar de sua conectividade local, devido ao conjunto extra de conexões sinápticas e da dimensão extra de interações neurais (CHURCHLAND e SEJNOWSKI, 1992).

A estrutura da figura 26 ilustra uma rede neural artificial *feedforward* (alimentada adiante) com uma camada oculta. Nela, o sinal é apresentado na camada de entrada, processado adiante pela camada intermediária, e sua saída calculada e apresentada na camada de saída. Como cada um dos nós de uma camada está conectado a todos os nós da camada seguinte, esta rede neural é dita totalmente conectada. Caso estivesse faltando alguma conexão entre os nós de camadas adjacentes, a rede seria dita parcialmente conectada. Pode-se notar na figura 26 que é comum que camadas diferentes tenham números diferentes de neurônios.

Uma rede neural é especificada principalmente pela sua topologia, pelas características de suas conexões e pelas regras de treinamento.




Figura 26: Rede neural artificial com duas camadas (HAYKIN, 2001).

4.3 TREINAMENTO DE REDES NEURAIIS ARTIFICIAIS

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Desta maneira, elas aprendem através de exemplos.

A propriedade mais importante das redes neurais é a habilidade de aprender através de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicados aos seus pesos sinápticos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais. Estes algoritmos diferem entre si, principalmente, pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Neste contexto, existem dois paradigmas de aprendizado: o aprendizado supervisionado, onde é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada e o aprendizado não supervisionado, ou auto-organização, onde a regra de treinamento tende a convergir diferentes pontos de saída para diferentes grupos de entrada, sem apresentar um padrão específico de saída para uma determinada entrada.

Denomina-se ciclo ou época, uma apresentação de todos os N pares entrada-saída do conjunto de treinamento no processo de aprendizado. A correção dos pesos em uma época pode ser executada em dois modos: o modo padrão, onde a correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada época ocorrem N correções. Já no modo *batch*, apenas uma correção é feita por época. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro fazem-se as correções dos pesos.

4.3.1 A retropropagação do erro

A descoberta, feita por vários pesquisadores independentes, e a disseminação de um método geral e efetivo para o treinamento de redes neurais de múltiplas camadas (RUMELHART, HINTON e WILLIAMS, 1986, McCLELLAND e RUMELHART, 1988) foi o principal fator do aparecimento das redes neurais como um método para a solução de uma variada gama de problemas. Este algoritmo chama-se retropropagação do erro (*error backpropagation* ou apenas *backpropagation*) ou regra delta generalizada e é baseado no método do gradiente descendente, visando minimizar o erro quadrático total apresentado pela saída da rede (FAUSSET, 1994).

Segundo (HAYKIN, 2001), o algoritmo da retropropagação do erro funciona da seguinte maneira: tendo-se como padrão um neurônio j , o erro em sua saída na iteração n , isto é, na apresentação do n -ésimo exemplo de treinamento, é definido pela equação (40). Nesta equação, $y_j(n)$ se refere ao sinal funcional que aparece na saída do neurônio j na iteração n e $d_j(n)$ é a resposta desejada nesta iteração.

$$e_j(n) = d_j(n) - y_j(n) \quad (40)$$

Define-se o valor instantâneo da energia do erro para o neurônio j como $\frac{1}{2}e_j^2(n)$. Desta forma, o valor instantâneo da energia total do erro $\xi(n)$ é obtido de acordo com a equação (41), onde C é o conjunto de todos os neurônios da camada de saída da rede. Considerando que N represente o número total de padrões constantes no conjunto de treinamento, a energia média do erro quadrático ξ_{med} é obtida a partir da equação (42).

$$\xi(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (41)$$

$$\xi_{med} = \frac{1}{N} \sum_{n=1}^N \xi(n) \quad (42)$$

Tanto a energia instantânea do erro $\xi(n)$ quanto a energia média do erro ξ_{med} são funções dependentes de todos os parâmetros livres da rede, isto é, dos pesos sinápticos e

dos níveis de polarização. Desta maneira, o objetivo do processo de aprendizagem é ajustar os parâmetros livres da rede neural visando minimizar ξ_{med} . Com este objetivo, considera-se um método simples de treinamento onde os pesos são atualizados padrão a padrão, formando uma época, quando todo o conjunto de treinamento é apresentado à rede. Os ajustes dos pesos são realizados de acordo com os respectivos erros calculados para cada padrão apresentado.

A polarização do modelo do neurônio, apresentado na seção 4.1, pode ser atribuído como um peso da rede neural ligado à uma entrada fixa de valor unitário. Desta maneira, o neurônio j , para um conjunto de entrada x_m , apresenta o campo local induzido de acordo com a equação (43). Desta maneira, a saída $y_j(n)$ apresentada pelo neurônio é definida pela equação (44).

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)x_i(n) \quad (43)$$

$$y_j(n) = \varphi_j(v_j(n)) \quad (44)$$

O algoritmo da retropropagação do erro aplica uma correção $\Delta w_{ji}(n)$ ao peso sináptico $w_{ji}(n)$ proporcional à derivada parcial $\frac{\partial \xi(n)}{\partial w_{ji}(n)}$. Este gradiente determina a direção de busca no espaço de pesos para o peso sináptico $w_{ji}(n)$ e pode ser expresso de acordo com a equação (45) (HAYKIN, 2001).

$$\frac{\partial \xi(n)}{\partial w_{ji}(n)} = \frac{\partial \xi(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (45)$$

Diferenciando-se ambos os lados da equação (45) em relação a $e_j(n)$, obtém-se a equação (46).

$$\frac{\partial \xi(n)}{\partial e_j(n)} = \partial e_j(n) \quad (46)$$

Diferenciando-se ambos os lados da equação (40) em relação a $y_j(n)$, obtém-se a equação (47).

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (47)$$

A seguir, diferenciando-se a equação (44) em relação a $v_j(n)$, obtém-se a equação (48), onde $\varphi'(\cdot)$ representa a diferenciação da função de ativação $\varphi(\cdot)$ em relação a $v_j(n)$.

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi_j'(v_j(n)) \quad (48)$$

Finalmente, ao diferenciar-se a equação (43) em relação a $w_{ji}(n)$ resulta a equação (49).

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (49)$$

Aplicando as equações (46) a (49) na equação (45) produz a equação (50).

$$\frac{\partial \xi(n)}{\partial w_{ji}(n)} = -e_j(n) \varphi_j'(v_j(n)) y_i(n) \quad (50)$$

Desta forma, a correção $\Delta w_{ji}(n)$ aplicada ao peso sináptico $w_{ji}(n)$ é definida pela regra delta, na equação (51), onde η é o parâmetro da taxa de aprendizagem do algoritmo da retropropagação. O uso do sinal negativo na equação (51) indica a descida do gradiente no espaço de pesos, isto é, a busca de uma direção para a mudança de peso que reduza o valor de $\xi(n)$.

$$\Delta w_{ji}(n) = -\eta \frac{\partial \xi(n)}{\partial w_{ji}(n)} \quad (51)$$

Das equações (50) e (51) pode-se notar que o fator chave envolvido no cálculo do ajuste de peso $\Delta w_{ji}(n)$ é o sinal de erro $e_j(n)$ na saída do neurônio j . Neste contexto, pode-se identificar dois casos distintos, dependentes da localização do neurônio na rede.

No caso do neurônio j ser um neurônio de saída, cada nó é suprido com uma resposta desejada particular, fazendo com que o cálculo do sinal de erro associado seja direto. Para o caso do neurônio j ser um nó oculto, o cálculo da atribuição do erro torna-se um pouco mais complexa. Apesar de oculto, o neurônio j compartilha a responsabilidade pelo erro cometido na saída da rede. Este problema é resolvido retropropagando o erro através de toda a rede.

Em implementações práticas desta metodologia de treinamento, definem-se dois conjuntos dentro do universo de dados, um para ser utilizado no processo de treinamento e outro para a validação deste treinamento. Aplicando-se o algoritmo de retropropagação do erro monitora-se a evolução do treinamento avaliando-se a evolução do erro quadrático total simultaneamente para os conjuntos de treinamento e validação. Esse processo é realizado visando monitorar a variação do erro nos dois conjuntos e assim evitar casos de especialização da rede, quando esta apresenta valores baixos de erro para o conjunto treinado e altos para o conjunto de validação, apresentando uma pobre generalização. Em alguns casos, avalia-se a rede utilizando um terceiro grupo não utilizado no processo de treinamento, visando confirmar a generalização obtida no conjunto de validação.

4.4 REDES NEURAIS DE FUNÇÃO DE BASE RADIAL

Diferentemente da abordagem clássica da retropropagação do erro, utilizada nas redes neurais perceptron multicamadas, as redes de função de base radial (*Radial Basis Function*, RBF) apresentam outro enfoque conceitual, que impactam tanto na topologia da rede quanto no seu método de treinamento. Nas redes neurais perceptron multicamadas, o treinamento é visto como um problema de varredura em um espaço multidimensional em busca do ponto em que há a minimização do erro quadrático total das saídas em relação aos padrões apresentados durante o processo de treinamento. Este treinamento baseia-se no método do gradiente descendente, conforme apresentado na seção 4.3.1. Assim, em termos de generalização, presume-se que este ponto de mínimo erro possa ser extrapolado para o conjunto de dados não treinados, ou conjunto de validação.

Nas redes neurais de função de base radial, o processo de aprendizagem equivale a definir curvas dentro de um espaço de alta dimensionalidade capazes de separar os diferentes agrupamentos dentro do conjunto de entrada. Sendo que a generalização é

dada pela interpolação da saída dos agrupamentos definidos dentro desta superfície, utilizando funções lineares. Desta maneira, as redes neurais RBF são redes multicamadas compostas por três camadas com funções específicas, conforme ilustrado na figura 27.

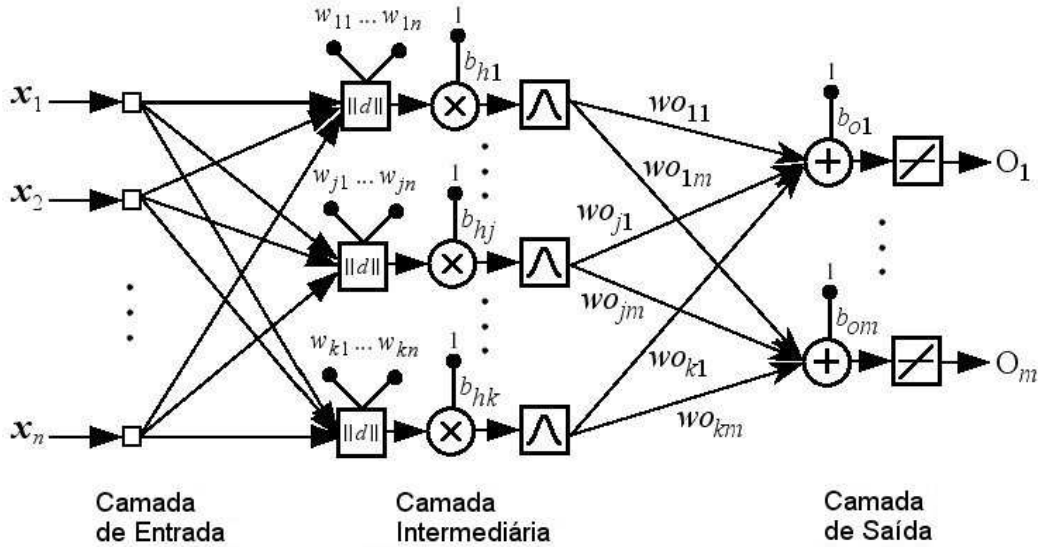


Figura 27: Estrutura das redes neurais de Função de Base Radial (RBF).

Nesta estrutura de rede neural, a camada de entrada tem por função apenas apresentar à rede os dados sob classificação, conectando-os a todos os neurônios. Nos neurônios da camada oculta, ao invés da computação de uma combinação linear entre o vetor de entrada x_n e os pesos sinápticos do neurônio w_n , como ocorre nos neurônios perceptron, calcula-se a distância euclidiana entre estes vetores, conforme a equação (52), sendo este valor multiplicado pela polarização b_n para o cálculo do campo local induzido v . Posteriormente, o campo local induzido é aplicado à função de base radial utilizada como função de ativação do neurônio, sendo usualmente utilizada uma função Gausseana. Finalmente, a camada de saída é composta por neurônios que possuem a mesma estrutura dos neurônios perceptron, com a diferença de utilizar uma função de ativação linear, que é responsável pela interpolação entre os agrupamentos definidos pelos neurônios da camada intermediária e por fornecer a resposta da rede aos sinais de ativação aplicados à camada de entrada (HAYKIN, 2001).

$$d = \sqrt{\sum_{n=0}^{N-1} (x_n - w_n)^2} \quad (52)$$

Desta forma, cada neurônio da camada intermediária representa um agrupamento em um espaço multidimensional, com dimensão definida pela ordem do vetor de pesos sinápticos, igual à ordem do vetor de entrada, com centro definido pelos valores dos pesos sinápticos e limite definido pela abertura da função de base radial. Já os neurônios da camada de saída efetuam a aproximação linear entre os agrupamentos definidos pelos neurônios da camada intermediária para os valores de entrada, gerando a interpolação entre estes agrupamentos e, conseqüentemente, a generalização.

Nesta filosofia, o treinamento de uma RBF torna-se basicamente um problema de aproximação das funções dentro do espaço de alta dimensionalidade, em que cada agrupamento está associado a uma região espacial, sendo necessário assim localizar o centro e delimitar as áreas destas regiões dentro deste espaço. Assim, quanto maior a dimensão adotada para a definição deste espaço, maior a suavidade na separação desses agrupamentos.

Comparativamente, uma rede neural RBF usualmente necessita de mais neurônios do que as redes neurais perceptron treinadas por retropropagação do erro, no tratamento de um mesmo problema. Estas estruturas de redes neurais são muito eficientes quando a dimensão do conjunto de entrada é reduzida. Entretanto, quando o número de entradas não é pequeno, as redes perceptron multicamadas apresentam uma maior capacidade de generalização. Este fato está ligado diretamente à necessidade de funções de base radial para a resolução de um problema, que aumenta exponencialmente com o aumento da dimensão da entrada. Contudo, esta estrutura de rede neural pode ser treinada em uma fração do tempo requerido para o treinamento de uma rede que utiliza o treinamento por retropropagação (HAYKIN, 2001).

4.4.1 Treinamento das redes neurais RBF

Uma vez que a filosofia das redes neurais RBF é basicamente o modelamento de uma superfície em um espaço multidimensional, o treinamento destas redes resume-se a busca desses centros e a definição da forma e abertura das funções de base radial. Estas características devem ser obtidas de forma que cada função de base radial melhor represente os conjuntos passíveis de classificação. Assim, a definição dos pesos da camada de saída linear cabe apenas interpolar as ativações da camada intermediária de forma mais otimizada.

Várias outras abordagens foram propostas para a solução destas questões. Para a localização dos centros e definição das funções de base radial foram propostas abordagens como a utilização de centros fixos escolhidos aleatoriamente dentro de um conjunto de treinamento (LOWE, 1989), seleção dos centros de forma supervisionada ou auto-organizada (LOWE, 1989; MOODY e DARKEN, 1989), agrupamento hierárquico supervisionado (LIPPMANN, 1989; LEE e RHEE, 1991) e utilização de algoritmos genéticos para evolução dos centros (MUSAVI *et al.*, 1992), entre outros. Na tarefa de definição dos pesos da camada de saída foram propostas técnicas como pseudo-inversão e Orthogonal Least Squares (OLS) (CHEN, COWAN, e GRANT, 1991).

Um dos métodos de mais rápido treinamento das redes neurais RBF é conhecido por projeto exato (DEMUTH, BEAGLE e HAGAN, 2007). Neste método, os vetores utilizados no conjunto de treinamento são atribuídos como centros dos conjuntos no espaço multidimensional formado pelos pesos sinápticos dos neurônios da camada intermediária. Estes agrupamentos definem os neurônios da camada intermediária da rede, sendo atribuído um valor fixo ao desvio padrão da função de base radial. Portanto, os pesos sinápticos de cada neurônio são iguais aos coeficientes do vetor de treinamento sendo, conseqüentemente, o número de neurônios da camada intermediária da rede neural igual ao número de exemplos utilizados durante o treinamento. Este método de treinamento será abordado de forma mais aprofundada na descrição da metodologia de classificação desenvolvida, na subseção 7.3.1.

CAPÍTULO 5

FERRAMENTAS E TÉCNICAS DE DESENVOLVIMENTO

Durante o desenvolvimento das metodologias de caracterização e reconhecimento de sons pulmonares adventícios, foram utilizadas várias ferramentas de projeto de *software* e bibliotecas de manipulação de sons e imagens que não foram desenvolvidas neste trabalho, mas serviram de base para a manipulação de dados e construção das ferramentas de implementação e validação das metodologias propostas.

Inicialmente, foram definidos os padrões de arquivos de áudio e imagem a serem utilizados no trabalho, as plataformas de desenvolvimento e os métodos práticos para a manipulação destes arquivos nos ambientes de programação. Os métodos utilizados para esta manipulação de arquivos demandaram o uso de bibliotecas específicas, que implementam funções de manipulação de arquivos para viabilizar o acesso aos dados constantes nos arquivos utilizados, sendo que algumas bibliotecas foram substituídas por funções de manipulação de arquivos proprietárias desenvolvidas durante os estudos.

Além das ferramentas de desenvolvimento, os arquivos de áudio contendo os sons pulmonares, imprescindíveis para a avaliação dos métodos, foram obtidos a partir de diferentes repositórios disponíveis na Internet ou a partir de *software* didáticos para o ensino da ausculta adquiridos durante a realização deste trabalho. A origem e as características destes arquivos de áudio serão apresentadas na seção 5.2.

5.1 FORMATOS E BIBLIOTECAS PARA ARQUIVOS DE ÁUDIO E IMAGEM

O método mais prático para o estudo e desenvolvimento das técnicas de análise dos sons pulmonares consiste em processar estes sons de forma *offline*, ou seja, trabalhando com gravações, o que elimina a necessidade de contínuos testes *in loco*, agiliza o processo de validação das metodologias e permite comparações justas entre os diferentes métodos, através do uso da mesma base de dados.

Como o objetivo deste trabalho consiste em propor técnicas inovadoras de análise, filtragem e reconhecimento dos sons adventícios nos sons pulmonares e investigar a sua eficácia e suas limitações, os requisitos de tamanho e compactação dos arquivos utilizados foram deixados em segundo plano, optando-se por arquivos que facilitassem a obtenção e o

processamento dos dados. Desta forma, optou-se por utilizar o formato de arquivo de áudio padrão *wave*, e geração das imagens dos espectrogramas utilizando o padrão *bitmap*.

Os arquivos de áudio são representações digitais de uma onda sonora amostrada, sendo que o padrão de arquivos *wave* utiliza a técnica mais simples para executar esta tarefa. Estes arquivos são constituídos por um cabeçalho, que contém as informações referentes aos métodos e codificações utilizados durante a gravação, e o vetor de amostras propriamente dito, com a seqüência de amostras que define a onda. Assim, qualquer programa que tenha por objetivo reproduzir ou processar a onda sonora deve se ajustar às condições de gravação do arquivo, constantes no cabeçalho. As informações mais importantes para o processamento, contidas no cabeçalho do arquivo *wave* são: o formato do arquivo, o formato e a resolução das amostras, o número de amostras, a frequência de amostragem, o número de canais e o tipo de curva de quantização utilizada.

A abertura e extração dos dados contidos nos arquivos de áudio *wave* são operações básicas necessárias para a obtenção dos dados para processamento no *software*. Contudo, alguns ambientes de desenvolvimento não disponibilizam classes ou bibliotecas que contenham os formatos e funções necessárias para a manipulação deste tipo de arquivo. Uma vez que algumas rotinas desenvolvidas para estudo e implementação das metodologias propostas foram realizadas utilizando linguagem de programação C++, foi inicialmente utilizada a biblioteca de vinculação dinâmica (DLL) *libsndfile*, desenvolvida por Erik de Castro Lopo (LOPO, 2003), para este fim. Maiores detalhes das ferramentas de programação utilizadas serão descritas na seção 5.3.

A *libsndfile* é uma biblioteca dinâmica construída na linguagem C, para ser utilizada em ambientes desta linguagem de programação. Ela implementa funções de leitura e escrita de arquivos de áudio amostrado, entre eles os arquivos *wave*, e conversão entre os formatos. Entretanto, com o avanço do trabalho, preferiu-se desenvolver uma classe própria, em linguagem de programação C++, para realizar as funções de manipulação de arquivos *wave*. Assim, a biblioteca *libsndfile* foi substituída durante o processo de desenvolvimento e testes da técnica proposta.

O armazenamento de imagens em sistemas digitais ocorre na forma de arquivos binários que contêm a codificação da imagem. Desta forma, a imagem original é dividida em pontos, chamados *pixels*. A cada *pixel* é atribuído um valor, que corresponde à intensidade do ponto. O número de *pixels* pela área da imagem define a sua resolução, em número de pontos. Já o número de bits do valor que é atribuído ao *pixel* define a resolução das cores utilizadas na imagem, que pode variar de apenas 1 até 32 bits. Entretanto, quanto maior for o número de

pixels ou maior a resolução de cada *pixel* ou ainda o crescimento dos dois parâmetros simultaneamente, maior será o tamanho do arquivo resultante. Como o padrão de arquivo de imagem *bitmap* não possui compressão de dados, a sua maior limitação é o espaço em memória ocupado pelo mesmo quando a imagem é muito grande e possui uma alta resolução em cores. Contudo, este formato é o mais simples para o processamento, uma vez que a matriz de dados está disponível sem a necessidade de algoritmos de descompressão para obtê-la. Desta forma, os arquivos de imagem *bitmap* ocupam uma grande área de memória, mas facilitam o acesso aos dados para o processamento.

Com o objetivo de facilitar os processos de abertura, extração de dados, processamento e armazenamento de imagens em arquivos padrão *bitmap* nas rotinas desenvolvidos neste trabalho, foi utilizada a biblioteca de vinculação dinâmica (DLL) para processamento de imagens DILabiem, desenvolvida por Rovani, Gamba e Osowsky (2000). Essa biblioteca foi criada com o objetivo de facilitar as atividades de desenvolvimento de rotinas para processamento de imagens, implementando variáveis e funções de manipulação de arquivos de imagem, nos formatos *bitmap* e *Portable Grayscale Map*. Assim, a incorporação desta biblioteca no programa foi de fundamental importância na conversão da matriz do espectrograma calculado em imagens digitais, para a avaliação dos sinais processados através das técnicas propostas, utilizando imagens no formato *bitmap*.

5.2 GRAVAÇÕES DE SONS PULMONARES

A base para o estudo e desenvolvimento das metodologias propostas são as gravações dos sons pulmonares, uma vez que elas são o objeto de estudo de todo este trabalho. Assim, a obtenção destas gravações foi imprescindível tanto para a construção quanto para a avaliação desses métodos. Felizmente, algumas universidades e pesquisadores (BARRETO, 1999; FRASER, 2003; WILKINS, HODGKIN e LOPEZ, 2004; PIXSOFT, 2006) criam repositórios que disponibilizam gravações de sons pulmonares com objetivos didáticos e de desenvolvimento de pesquisas.

Como um dos objetivos principais das metodologias propostas é a independência da fonte de gravação, foram utilizados diferentes repositórios de sons pulmonares, somado um total de quatro, sendo dois mantidos por universidades e dois utilizados como material didático ao ensino da ausculta. Os repositórios utilizados como fonte de dados neste trabalho são: o *site* da Internet MedBahia, mantido pelo curso de medicina da Universidade Federal da Bahia (BARRETO, 1999), o *site* da Internet mantido por Dave Fraser, da escola de medicina

da *University of California, Davis* (FRASER, 2003), os sons disponíveis como material de apoio ao trabalho de Wilkins, Hodgkin e Lopez (2004) e os sons gravados pela empresa PixSoft, disponíveis em seu software *R.A.L.E. Lung sounds*, versão estudantil, e em seu *site* na Internet (PIXSOFT, 2006). As gravações de sons pulmonares feitas pela empresa PixSoft e utilizadas neste trabalho foram autorizadas expressamente pela mesma, tendo sido estas obtidas de seu *site* na Internet (PIXSOFT, 2006) e do software *R.A.L.E. Lung sounds*, versão estudantil, adquirido durante a execução deste trabalho.

Entretanto, como os objetivos desses repositórios estão voltados para o ensino da ausculta para profissionais de saúde, muitas vezes estes não disponibilizam informações técnicas sobre a metodologia utilizada na gravação. A única exceção, nos repositórios utilizados como fonte neste trabalho, foi o do mantido pela empresa PixSoft. Segundo esta, os sons gravados na superfície do tórax e do pescoço foram feitos utilizando-se acelerômetros de contato modelo EMT25C da marca Siemens, sendo que as gravações feitas na boca utilizaram microfones de eletreto ECM140 da marca Sony. Os sinais gravados foram processados por um filtro passa-altas Butterworth de 1ª ordem, com frequência de corte de 7,5 Hz para a eliminação da componente de corrente contínua. Estes sinais também foram processados por outro filtro, um passa-baixas Butterworth de 8ª ordem, com frequência de corte de 2,5 kHz como filtro *anti-aliasing*. A frequência de amostragem destes sinais são de 10 kHz, sendo que alguns foram sobreamostrados a partir de arquivos com frequência de amostragem original de 5 kHz. A conversão analógico-digital utilizou níveis de quantização de 16 bits, em um computador pessoal modelo IBM-PC, sendo que alguns arquivos foram originalmente quantizados a 12 bits sendo, em seguida, convertidos para 16 bits.

Durante os testes da metodologia proposta foram utilizados 275 ciclos respiratórios gravados de 36 diferentes pacientes, com idades variando de bebês recém-nascidos a 78 anos.

5.3 PLATAFORMAS DE DESENVOLVIMENTO

Para o desenvolvimento dos programas que implementem as funções descritas neste trabalho, foram utilizados três ambientes de desenvolvimento, dois voltados para a linguagem de programação C++ para Windows e um utilizando a ferramenta matemática MatLab.

Durante os estudos preliminares, visando a abertura dos arquivos de sons pulmonares em formato *wave*, e geração dos espectrogramas destes sons, foi utilizada e atualizada a ferramenta desenvolvida para análise e reconhecimento de sibilos em sons pulmonares

(RIELLA, 2004), que foi desenvolvida utilizando o ambiente de desenvolvimento Borland C++ Builder, versão 1.0.

Para a implementação e avaliação das metodologias de decomposição *wavelet* e cálculo da magnitude da energia em relação ao nível de decomposição, foi desenvolvido um software na ferramenta Borland C++ Builder versão 6.0. Esta plataforma foi escolhida para esta função por conter objetos que facilitam a implementação de gráficos interativos, que não estão inclusos na versão 1.0. Entretanto, a biblioteca *libsndfile* mostrou-se incompatível com esta ferramenta, o que motivou o desenvolvimento de uma classe própria para manipulação de arquivos *wave* utilizando esta plataforma. As rotinas de treinamento das redes neurais Perceptron multicamadas também foram implementadas utilizando essa ferramenta de desenvolvimento.

Contudo, como a avaliação das metodologias propostas envolveram uma matriz de testes utilizando várias famílias de funções *wavelet* e vários treinamentos de redes neurais para os resultados obtidos para cada uma destas famílias, a implementação das metodologias foi portada para o ambiente de desenvolvimento MatLab, que possibilitou a computação desses testes de forma mais ágil.

5.4 NORMALIZAÇÃO DAS GRAVAÇÕES DIGITAIS DOS CICLOS RESPIRATÓRIOS

Ao se gravar um arquivo de áudio em um sistema digital, o primeiro parâmetro que define a resolução do sinal obtido é a frequência de amostragem. É comum gravar-se voz a uma frequência de amostragem de 8 kHz, o que garante uma banda de passagem de 4 kHz, com a mesma inteligibilidade obtida em um telefone comum. Entretanto, em gravações com resoluções superiores, pode-se chegar a frequências de amostragem da ordem de 44 kHz, para qualidade de sinal equivalente aos CDs de áudio.

Como os arquivos de áudio contendo os sons pulmonares, descritos na seção 5.2, apresentam diferentes tipos de configuração de frequência de amostragem, estas tiveram de ser normalizadas. Este processo foi implementado visando manter a uniformidade da informação espectral contida em todos os ciclos respiratórios analisados e, conseqüentemente, normalizar tanto a informação constante no eixo das ordenadas dos espectrogramas, referente ao espectro do segmento do sinal calculado na STFT, quanto as representações das sub-bandas de frequência obtidas no processo de decomposição *wavelet*, algoritmo base das metodologias desenvolvidas neste estudo.

Desta maneira, para normalizar a frequência de amostragem de todos os arquivos de áudio analisados, foi implementado um novo filtro *anti-aliasing* e um algoritmo de sub-amostragem, que normaliza a frequência de amostragem do sinal para 8 kHz.

Ao abrir o arquivo de áudio a ser analisado, a rotina de normalização obtém o valor da frequência de amostragem original a partir do cabeçalho do arquivo, calcula os coeficientes de um filtro FIR (*finite impulse response*, ou de resposta finita ao impulso) para agir como novo filtro *anti-aliasing*, e o aplica ao sinal original. O filtro calculado é um passa-baixas de 100 coeficientes, com frequência de corte de 3,5 kHz e função janela de Hamming. Este filtro é necessário porque, mesmo com o sinal original já amostrado, este pode conter frequências acima da metade da nova frequência de amostragem. Se estas não forem eliminadas antes da nova amostragem, ocorrerá o fenômeno da sobreposição espectral, distorcendo o espectro resultante. De acordo com a frequência de amostragem normalizada, a banda passante abrange 0 a 4kHz, sendo que a banda de 500 Hz entre o corte do novo filtro *anti-aliasing* e o ponto de Nyquist ($f_s/2$) foi utilizada como margem de segurança para desvanecimento da curva de corte do filtro.

A figura 28 apresenta as curvas de resposta do filtro utilizado para dois sinais com distintas frequências de amostragem. A figura 28a apresenta a curva de resposta do filtro calculado para um arquivo que tenha frequência de amostragem original de 44,1kHz (qualidade de CD), enquanto que a figura 28b mostra a curva de resposta deste filtro quando o sinal é amostrado a 11kHz.

O número de coeficientes escolhido para o filtro determina um corte abrupto na região de interesse, como visto na figura 28. Como os sons pulmonares são processados *offline*, o atraso de 100 amostras aplicado pelo filtro *anti-aliasing* perde a relevância, sendo que este fator deve ser considerado em um sistema que utilize este método em tempo real.

Para efetuar a sub-amostragem, foi implementado um algoritmo que, a partir do número de amostras e da frequência de amostragem do sinal original, contidos no cabeçalho do arquivo, calcula a relação entre este número e o número de amostras correspondente para o mesmo sinal amostrado a 8kHz. Esta relação é definida pela equação (53), onde Na_n é o número novo de amostras, Na_a define o número de amostras atual e Fs_a se refere à frequência de amostragem original do sinal.

$$Na_n = \frac{8000 * Na_a}{Fs_a} \quad (53)$$

Como todos os arquivos utilizados possuíam frequência de amostragem original acima de 8kHz, o método utilizado para reduzir esta frequência consistiu em criar um novo vetor de amostras, realizando a interpolação linear entre amostras do vetor original em intervalos regulares. O intervalo de média entre amostras é calculado a partir do novo número de amostras que o sinal deve apresentar para a nova frequência de amostragem, calculado a partir da equação (53). Desta forma, este intervalo i é calculado a partir da equação (54).

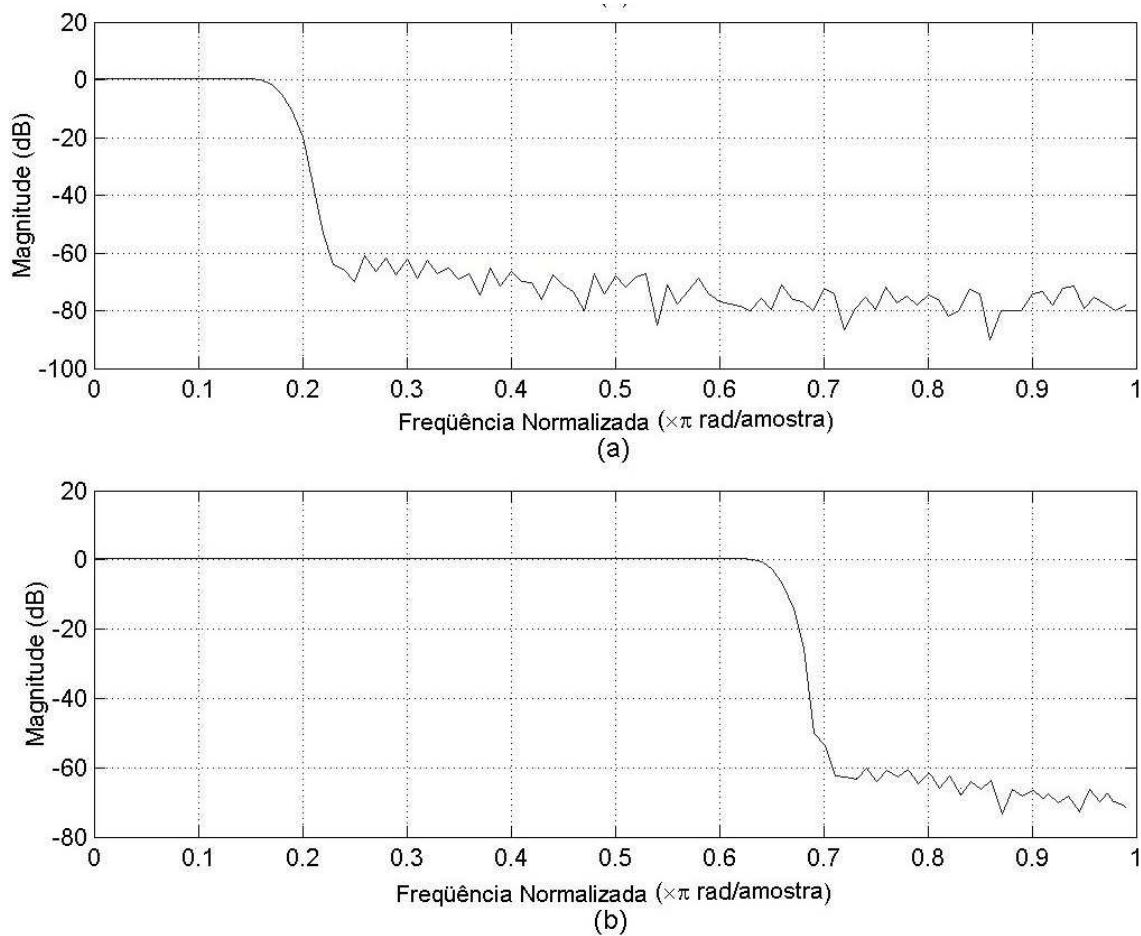


Figura 28: Curvas de resposta do filtro FIR calculado a partir do sinal de entrada. (a) Para um sinal amostrado a 44,1 kHz. (b) Para um sinal amostrado a 11 kHz.

$$i = \frac{Na_a}{Na_a - Na_n} \quad (54)$$

5.5 COMPUTAÇÃO DOS ESPECTROGRAMAS

O padrão utilizado para a geração do espectrograma, quanto à FFT, foi baseado no *software R.A.L.E. lung sounds*. Este padrão é definido pelo uso de FFTs de 1024 pontos, com janela de Hamming. Para a frequência de amostragem de 8 kHz, este valor corresponde a uma resolução espectral de aproximadamente 7,8 Hz. Para incrementar a resolução temporal, foi utilizado sobreposição de 994 amostras, o que, para a mesma frequência de amostragem, garante uma resolução temporal de 3,75 ms por linha de espectro.

O incremento da sobreposição tem a vantagem de “esticar” a figura resultante das anomalias descontínuas presentes nos sons pulmonares, sem alterar a figura das anomalias contínuas, caracterizando melhor a sua presença. Apresenta também a vantagem de aumentar o tamanho do espectrograma obtido, possibilitando a diminuição de pontos representativos e, conseqüentemente, aumentando a sua nitidez. Entretanto, o aumento da sobreposição resulta em um conseqüente aumento do tempo computacional despendido na computação do espectrograma, uma vez que quanto maior é este parâmetro maior o número de FFTs a serem computadas.

Seguindo esta linha, são computadas FFTs de 1024 pontos a cada 30 amostras do sinal, sendo que os 512 pontos resultantes, referentes à variação de magnitude deste sinal, são convertidos para a escala em dB mV, e armazenadas em uma coluna de uma matriz. Assim, ao fim do processamento de todo o sinal, a matriz resultante apresenta em cada coluna a variação de uma linha do espectro, em cada linha a variação temporal de uma determinada frequência e, em cada ponto, o valor da magnitude de uma frequência em um determinado tempo, em dB mV. Desta forma, esta matriz apresenta dimensão variável, com um número fixo de linhas igual a 512 e um número de colunas definido, aproximadamente, pelo tempo de duração do sinal dividido pela duração do intervalo fora da sobreposição, de aproximadamente 3,75ms. Estas variações são determinadas pelas mudanças na frequência de amostragem normalizada, definida na equação (54).

O próximo passo após a computação do espectrograma é a geração da sua figura representativa, a partir da matriz calculada. Com este fim, foi utilizada a biblioteca C para processamento de imagens DILabiem, que possibilitou a transformação da matriz em um arquivo padrão *bitmap* com resolução de 256 cores. As cores utilizadas na figura do espectrograma são associadas à magnitude da componente em frequência, seguindo a escala disposta na figura 29. Assim, cada ponto da matriz é transformado em um *pixel* da imagem,

com seus valores de posição tempo x frequência transformados na posição do *pixel* dentro da imagem e com o valor da magnitude do sinal transformado em uma cor, seguindo a figura 29.




Figura 29: Escala de cores relacionadas à magnitude, utilizada na construção do espectrograma, com unidade em dB mV.

Como cada ponto da matriz do espectrograma é transformado em um *pixel*, a imagem resultante apresenta uma boa nitidez, quando observada em monitores coloridos com resolução 800 x 600 *pixels* ou superiores. Contudo, esta técnica apresenta como desvantagem o fato de, como não há normalização nas dimensões da figura, apresentar uma imagem resultante com comprimento variável, relativo ao tempo de duração do sinal analisado. Entretanto, o eixo das frequências permanece inalterado, uma vez que a dimensão da FFT utilizada é invariante.

Exemplos dos espectrogramas obtidos utilizando as técnicas descritas podem ser vistas na figura 30. A figura 30a mostra o espectrograma gerado a partir de um sinal composto por duas senóides de 1 kHz e 3 kHz, com duração de 300 ms. Já a figura 30b mostra um ciclo respiratório que contém sibilos na fase expiratória. A presença dos sibilos pode ser visualizada pelas linhas horizontais contidas no espectrograma. Exemplo de telas do software desenvolvido para cálculo e avaliação por espectrogramas estão contidos no Apêndice I.

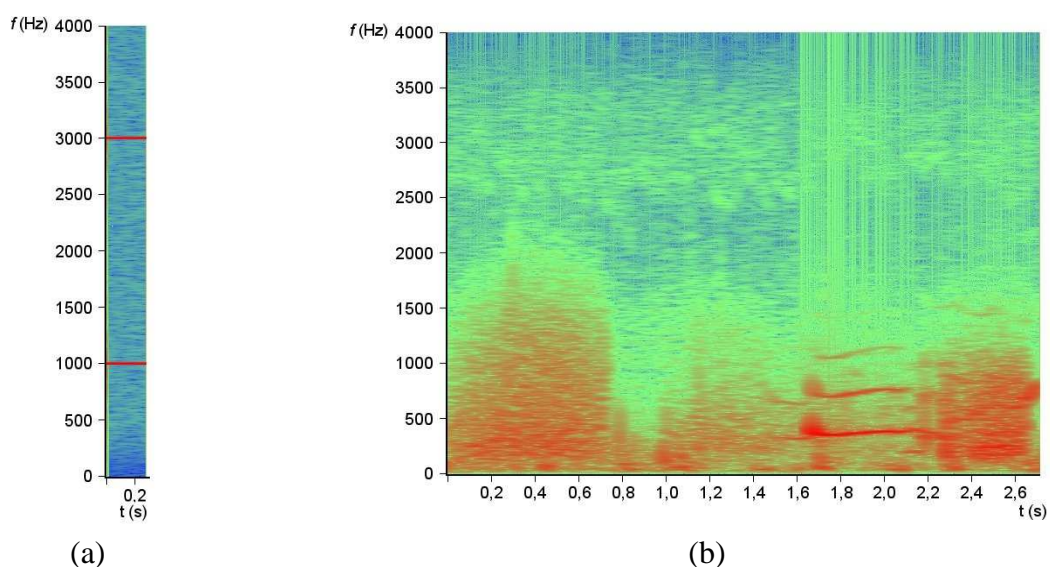


Figura 30: Exemplos de espectrogramas gerados a partir da técnica proposta. (a) Espectrograma de um sinal composto por duas senóides de 1 kHz e 3 kHz. (b) Espectrograma de um som pulmonar com sibilo.

CAPÍTULO 6

AVALIAÇÃO DE TÉCNICAS DE PROCESSAMENTO PARA ANÁLISE DE SONS PULMONARES

6.1 INTRODUÇÃO

Como apresentado na seção 2.3, a ausculta pulmonar é um método de simples aplicação clínica, não invasivo e útil na detecção de patologias no sistema respiratório. Visando auxiliar os profissionais de saúde que lidam com esses tipos de patologias, foram desenvolvidas duas técnicas inovadoras que auxiliam e incrementam a precisão e a confiabilidade do processo de ausculta, aumentando, assim, a rapidez na obtenção de um diagnóstico preciso. O desenvolvimento destas técnicas é fruto de estudos das características dos sinais dos sons respiratórios normais e adventícios nos domínios do tempo e frequência, visando isolar os sinais característicos dos sons adventícios e classificá-los, gerando realimentações tanto na forma de classificação automática dos sons adventícios quanto do som adventício isolado dos demais sons fisiológicos, com a sua localização temporal no ciclo respiratório.

Para a composição das técnicas propostas de reconhecimento e caracterização automática dos sons adventícios, foram realizadas análises desses sinais através do uso da STFT, CWT e DWT. Apesar de a DWT ter sido a técnica que resultou na base dos algoritmos de classificação e caracterização apresentados como inovadores neste trabalho, e que serão apresentados nos capítulos 7 e 8, os resultados obtidos através da análise pelas duas técnicas anteriores serviram como estudo base que norteou o desenvolvimento destas técnicas. Além deste fato, o cálculo do espectrograma dos ciclos respiratórios serviu como ferramenta de análise qualitativa da técnica de filtragem por análise espectral seletiva, que isola o sinal dos sons adventícios, e será apresentada no capítulo 8.

Assim, ao longo deste capítulo são apresentadas as análises preliminares realizadas nos sons pulmonares utilizando as três técnicas de processamento digital de sinais citadas anteriormente, até o ponto em que estas convergem para as duas novas metodologias desenvolvidas.

6.2 AVALIAÇÃO DOS SONS RESPIRATÓRIOS UTILIZANDO ESPECTROGRAMAS

Uma vez que este trabalho propõe o prosseguimento dos estudos realizados por Riella, Stelle e Nohama (2002); Riella, Nohama, Borges e Stelle (2003); Riella (2004), deu-se continuidade à metodologia aplicada naquele estudo, verificando a sua aplicabilidade em outros tipos de sons respiratórios adventícios. Esta metodologia baseou-se no cálculo do espectrograma do ciclo respiratório gravado digitalmente em arquivos *wave*, filtragem e limiarização da imagem do espectrograma visando isolar as linhas horizontais características dos sibilos, projeção no eixo espectral da imagem tratada e classificação através de uma rede neural MLP. Assim, realizou-se a análise do comportamento das imagens obtidas através da análise da STFT dos ciclos respiratórios com diferentes tipos de sons adventícios. Uma vez que esta metodologia apresentou resultados satisfatórios para a caracterização e reconhecimento automático dos sibilos, inicialmente foi avaliada sua potencialidade de uso para caracterização e reconhecimento dos outros tipos de sons adventícios.

6.2.1 Espectrogramas de Ciclos Respiratórios com Sibilos

De acordo com o que foi apresentado na seção 2.4, os sibilos são formados por uma frequência fundamental bem definida, normalmente acima de 100 Hz e duração usualmente maior que 80 ms. Estas características geram imagens bem definidas quando da computação do espectrograma de ciclos respiratórios que o contém.

A imagem, apresentada na figura 31, apresenta linhas horizontais centradas na frequência fundamental do sibilo e nas suas frequências harmônicas, que representam a distribuição espectro-temporal das frequências componentes do sibilo. Estas linhas horizontais ocorrem porque, conforme apresentado na seção 5.5, o retângulo de Heisenberg dos espectrogramas utilizados possuem 3,75 ms de largura temporal e 7,8 Hz de largura espectral. Assim, a presença de uma componente espectral bem definida, e com duração maior que 80 ms, apresentará alta amplitude nos poucos retângulos no eixo das ordenadas referente a esta componente espectral e suas redondezas e nos muitos retângulos no eixo das abscissas, referente ao tempo de duração temporal desta componente.

A região espectral de ocorrência dos sibilos, acima dos 100 Hz, praticamente impossibilita que estes se encontrem na mesma região de ocorrência dos sons cardíacos, que comumente contaminam os sons pulmonares auscultados.

Essas características foram utilizadas por Riella, (2004), como base para o desenvolvimento de um sistema de caracterização e reconhecimento automático de sibilos em sons pulmonares.




Figura 31: Exemplo de espectrograma de um ciclo respiratório contendo sibilos entre 1,6 e 2,2 s na fase expiratória.

6.2.2 Espectrogramas de Ciclos Respiratórios com Ronco

Uma das anomalias de natureza exclusivamente contínua que se contrapõe aos sibilos são os roncos. Devido à sua característica de apresentar um sinal periódico, que se encontra na região das baixas frequências, os roncos apresentam linhas horizontais características semelhantes às dos sibilos no espectrograma, como pode ser visto na figura 32. Assim, as diferenças básicas entre os espectrogramas resultantes de ciclos respiratórios contendo roncos e sibilos são: a posição da linha horizontal indicativa da frequência fundamental do ronco em uma posição inferior no espectrograma, devido a seu valor mais baixo em frequência, e um espalhamento espectral mais acentuado que a dos sibilos, uma vez que o ronco apresenta mais energia, reforçando assim também as suas frequências harmônicas.




Figura 32: Espectrograma de um ciclo respiratório com roncos. Os mesmos ocorrem nos tempos entre 0 e 1 s e entre 1,5 e 2,2 s.

Uma vez que as linhas horizontais características do espectrograma dos roncos se assemelham muito com as dos sibilos, poder-se-ia inicialmente especular que a técnica utilizada por Riella, (2004), também poderia vir a apresentar bons resultados para o reconhecimento dos roncos, sendo necessário apenas o treinamento de uma nova rede neural artificial com este fim. Entretanto, os sons cardíacos apresentam-se em uma faixa de frequências que pode vir a intercalar-se com a frequência fundamental dos roncos, conforme ilustrado na figura 33. Este sombreamento em frequência entre os sons pulmonares adventícios e os sons cardíacos pode resultar em erros de detecção quando do uso desta técnica, devido ao fato destes dois tipos de sinais gerarem picos na projeção espectral do espectrograma.

Outro fator que pode gerar confusão no reconhecimento dos roncos, quando do uso da técnica proposta por Riella, (2004), é o maior espalhamento espectral dos roncos, que pode gerar picos espalhados na projeção espectral do espectrograma filtrado e limiarizado, também resultando em maior confusão no reconhecimento, uma vez que este prioriza os picos isolados nesta projeção.




Figura 33: Exemplo de espectrograma de sons cardíacos, representados em cada barra vertical. Note-se que a frequência fundamental destes sons, de aproximadamente 100 Hz, coincide com a frequência fundamental dos roncos, na figura 32.

6.2.3 Espectrogramas de Ciclos Respiratórios com Estridor

O estridor, por ser uma anomalia contínua, também apresenta uma longa duração temporal, com frequências dominantes no espectro do seu sinal característico. Entretanto, diferentemente dos roncos e dos sibilos, esta anomalia não apresenta a característica de possuir uma frequência fundamental e suas harmônicas, mas sim várias frequências dominantes espalhadas uniformemente no espectro e uma alta magnitude em relação ao som respiratório normal. Um exemplo de espectrograma de um som respiratório contendo estridor na fase expiratória pode ser visto na figura 34.

Sendo assim, a figura do espectrograma deste tipo de anomalia apresenta uma área retangular de alta magnitude, devido à sua característica de possuir maior largura espectral, quando comparado aos outros tipos de sons adventícios contínuos, contrastando com uma duração temporal compatível com os outros tipos de anomalias contínuas.

Essas características resultam em uma imagem única no espectrograma, em que tanto a projeção espectral quanto temporal apresentam elevada amplitude na região de ocorrência do estridor. Assim, notou-se que as características espectro-temporais obtidas através do espectrograma dos ciclos respiratórios contendo estridor podem ser tratadas modificando-se a

metodologia proposta por RIELLA, (2004). Entretanto, para a caracterização e reconhecimento do estridor através desta metodologia, seria necessário um novo modelamento da rede neural artificial utilizada, abrangendo também dados da projeção temporal do espectrograma.




Figura 34: Espectrograma de um ciclo respiratório com estridor ocorrendo entre 1,4 e 1,9 s na fase expiratória.

6.2.4 Espectrogramas de Ciclos Respiratórios com Estertores Finos e Grossos

Conforme pode ser visto nas figuras 35 e 36, os estertores, por apresentarem características temporais impulsivas, com conseqüente alta largura espectral, criam barras verticais no espectrograma no momento de sua ocorrência. Estas barras verticais ocorrem de forma indistinta tanto para os estertores finos quanto grossos. Um dos fatores de diferenciação entre os estertores finos e grossos no espectrograma é a largura de suas colunas. Esta diferença pode ser claramente visualizada nas figuras 35 (que apresenta estertores finos) e 36 (com estertores grossos).

Entretanto, as figuras características apresentadas pelos estertores em espectrogramas não são de muito auxílio para o seu reconhecimento automático. Pode-se notar na figura 35 que a proximidade temporal entre os impulsos gerados pelos estertores finos faz com que haja

uma intersecção entre as suas colunas, ou figuras características, chegando muitas vezes a gerar uma só coluna que integra a ocorrência de vários estertores, como é o caso desta figura. Este fato ocorre porque a proximidade temporal entre os estertores finos é menor que a resolução temporal do retângulo de Heisenberg obtido pelo cálculo do espectrograma, neste caso, de 3,75 ms.

Assim, o desenho característico dos estertores finos no espectrograma, quando da ocorrência de várias anomalias com curto espaço de tempo entre si, gera uma figura que representa uma larga banda espectral, devido à forma impulsiva dos estertores, com uma larga duração temporal, devido à intersecção de suas colunas representativas. Esta característica pode vir a gerar confusão entre as figuras do espectrograma de estertores e do estridor, uma vez que esta anomalia contínua também apresenta uma grande largura espectral e uma grande duração temporal. As características citadas podem ser também visualizadas no espectrograma de um ciclo respiratório com estertores grossos, como na figura 36.




Figura 35: Espectrograma de um ciclo respiratório com estertores finos ocorrendo entre o início do ciclo e 0,6 s na fase inspiratória.




Figura 36: Espectrograma de um ciclo respiratório com estertores grossos, visualizados em quase todo o ciclo respiratório, na forma de barras verticais.

6.2.5 Considerações Sobre a Análise de Sons Pulmonares Empregando Espectrogramas

Conforme visto ao longo da seção 6.2, os espectrogramas geram imagens características bem definidas para os diferentes sons adventícios passíveis de presença nos sons pulmonares. Estas imagens características podem ser reconhecidas por um usuário experiente, que conheça o significado das representações obtidas pelos espectrogramas, na análise dos sons pulmonares.

Entretanto, as figuras obtidas a partir dos sons adventícios claramente apresentam características de cruzamento tanto no domínio do tempo quanto da frequência. Este cruzamento ocorre tanto entre os sons adventícios entre si, como no caso do estridor e dos estertores finos e grossos, quanto entre os sons pulmonares adventícios e outros sons fisiológicos, como o caso dos roncos e os sons cardíacos.

Portanto, apesar de os espectrogramas mostrarem grande utilidade como ferramenta de visualização dos sons adventícios, a confusão entre as suas figuras dificulta o desenvolvimento de sistemas de reconhecimento automático, como a metodologia de Riella (2004) o fez apenas para os sibilos. Assim, os resultados deste estudo preliminar apontaram para a busca de outra solução de técnica de processamento para extração de dados para

caracterização e classificação dos sons adventícios, sendo os espectrogramas utilizados apenas para auxílio na visualização dos resultados obtidos.

6.3 AVALIAÇÃO DOS SONS RESPIRATÓRIOS POR TRANSFORMADA WAVELET CONTÍNUA

Seqüencialmente à avaliação da caracterização das anormalidades em sons respiratórios através do uso de espectrogramas, foi realizado um estudo do comportamento dos sons pulmonares através da CWT. Para efetuar esta análise, foram traçados os escalogramas dos sons pulmonares, avaliando a potencialidade desta técnica em ressaltar as diferenças entre os diversos tipos de anomalias, além da sua potencialidade na localização temporal da sua ocorrência. A abordagem de visualização por escalogramas facilita a avaliação de várias escalas da mesma função *wavelet* mãe, utilizando a mesma figura. Quando alguma escala específica apresentou potencial na solução do problema de caracterização, esta foi avaliada separadamente. Assim, foi avaliada a capacidade deste tipo de processamento em extrair informações relevantes para a caracterização visual dos tipos de anomalias presentes e, conseqüentemente, a remoção de informações irrelevantes para o reconhecimento automático.

Na avaliação do uso de escalogramas na tarefa de caracterização dos sons adventícios em sons pulmonares, foram utilizadas as funções *wavelet* mãe da família Daubechies, variando o suporte das funções entre a Daubechies 1 e 15 e a escala em valores entre 1 e 32.


As funções *wavelet* mãe Daubechies foram escolhidas para o estudo inicial devido aos resultados obtidos por KANDASWAMY *et al.*, 2004, em que estas funções *wavelet* mãe apresentaram melhores resultados no reconhecimento de sons adventícios. Usualmente, trabalhos envolvendo a avaliação de várias funções *wavelet* mãe limitam-se a escalas até 20. Sendo assim, a gama de escalas foi escolhida visando cobrir uma faixa significativa, possibilitando assim a verificação da presença de sinais característicos nos escalogramas obtidos.

6.3.1 Escalogramas dos Sons Respiratórios Normais


Como estudo inicial de análise dos ciclos respiratórios utilizando a transformada *wavelet*, foram traçados escalogramas de sons pulmonares normais, verificando o seu desenho característico em função da variação das funções *wavelet* mãe e escalas, visando localizar propriedades que possibilitem a caracterização deste tipo de som pulmonar. Exemplificando, os escalogramas traçados utilizando as funções *wavelet* mãe Daubechies 1, 5, 10 e 15, de um ciclo respiratório que não apresenta qualquer tipo de som anômalo são mostrados na figura 37.

As figuras obtidas através da análise por transformada *wavelet* contínua dos ciclos respiratórios normais indicam que as componentes de alta frequência são bem caracterizadas nas escalas mais altas. Esta propriedade é incrementada com o aumento do suporte da função *wavelet* mãe utilizada. Este fato ocorre porque, conforme visto na subseção 3.7.1, para um dado suporte N da função *wavelet* mãe de Daubechies, resultam $2N$ coeficientes, o que torna a resolução desta função duplamente crescente em relação ao suporte. Assim, ocorre um conseqüente aumento no nível de detalhes contidos nestas funções, sendo estes detalhes correspondentes às componentes de alta frequência. Desta maneira, o aumento do suporte gera como conseqüência um aumento na resolução do escalograma.


Entretanto, notou-se que os escalogramas apresentam agrupamentos na ocorrência de componentes de alta frequência, como pode ser notado na pequena oscilação que ocorre entre 0,7 e 1,1 s, ou entre as amostras 5600 e 6400, no ciclo normal utilizado como exemplo na figura 37. Estes agrupamentos são uma conseqüência da computação da magnitude dos escalogramas, que utilizam a magnitude absoluta dos coeficientes para o desenho do plano tridimensional.




(a)




(b)



(c)



(d)



(e)

Figura 37 – Análise CWT de um ciclo respiratório normal, variando a escala entre 1 e 32, e as funções *wavelet* mãe. (a) Sinal no domínio do tempo e escalogramas utilizando as funções (b) Daubechies 1, (c) Daubechies 5, (d) Daubechies 10 e (e) Daubechies 15.

6.3.2 Escalogramas dos Sons Respiratórios Contendo Anomalias Contínuas

A figura 38a mostra o sinal no domínio do tempo e os escalogramas utilizando as funções Daubechies 1 (b), 5 (c), 10 (d) e 15(e) de um ciclo respiratório contendo sibilos. Nesta figura, nota-se claramente a detecção temporal do início da ocorrência do sibilo no tempo 1,45s, aproximadamente na amostra 11600, nos escalogramas traçados utilizando as funções Daubechies de ordem 5 ou maior.

Verificou-se também a mesma propriedade obtida na análise dos sons normais, em que o aumento do suporte da função *wavelet* mãe diminui o agrupamento temporal resultante nas componentes de alta frequência nos escalogramas, sendo visível na figura 38e uma separação mais nítida das componentes harmônicas que ocorrem a partir do tempo 2s, ou amostra 16000, o que gera um indício de localização temporal de suas componentes no ciclo respiratório. Esta separação é mais nítida na gama de escalas entre 3 e 9 onde, nos escalogramas gerados com as ordens mais altas, houve o maior pico nos coeficientes relativos à amostra que marca o início da ocorrência do sibilo.

Em um ciclo respiratório contendo roncões, cujo exemplo encontra-se na figura 39, notam-se praticamente as mesmas características encontradas nos ciclos respiratórios contendo sibilos, em que as funções *wavelet* mãe de maior suporte são capazes de localizar temporalmente a ocorrência do som adventício. Entretanto, como os roncões possuem frequência fundamental mais baixa, esta localização ocorre apenas para as escalas mais altas, de forma mais relevante a partir da escala 15, contrapondo-se assim com a localização dos sibilos, ocorrida a partir das escalas mais baixas. Entretanto, as escalas mais altas, referentes às baixas frequências também foram capazes de localizar temporalmente os sibilos, com a desvantagem de localizar também os ruídos do fluxo aéreo normal.

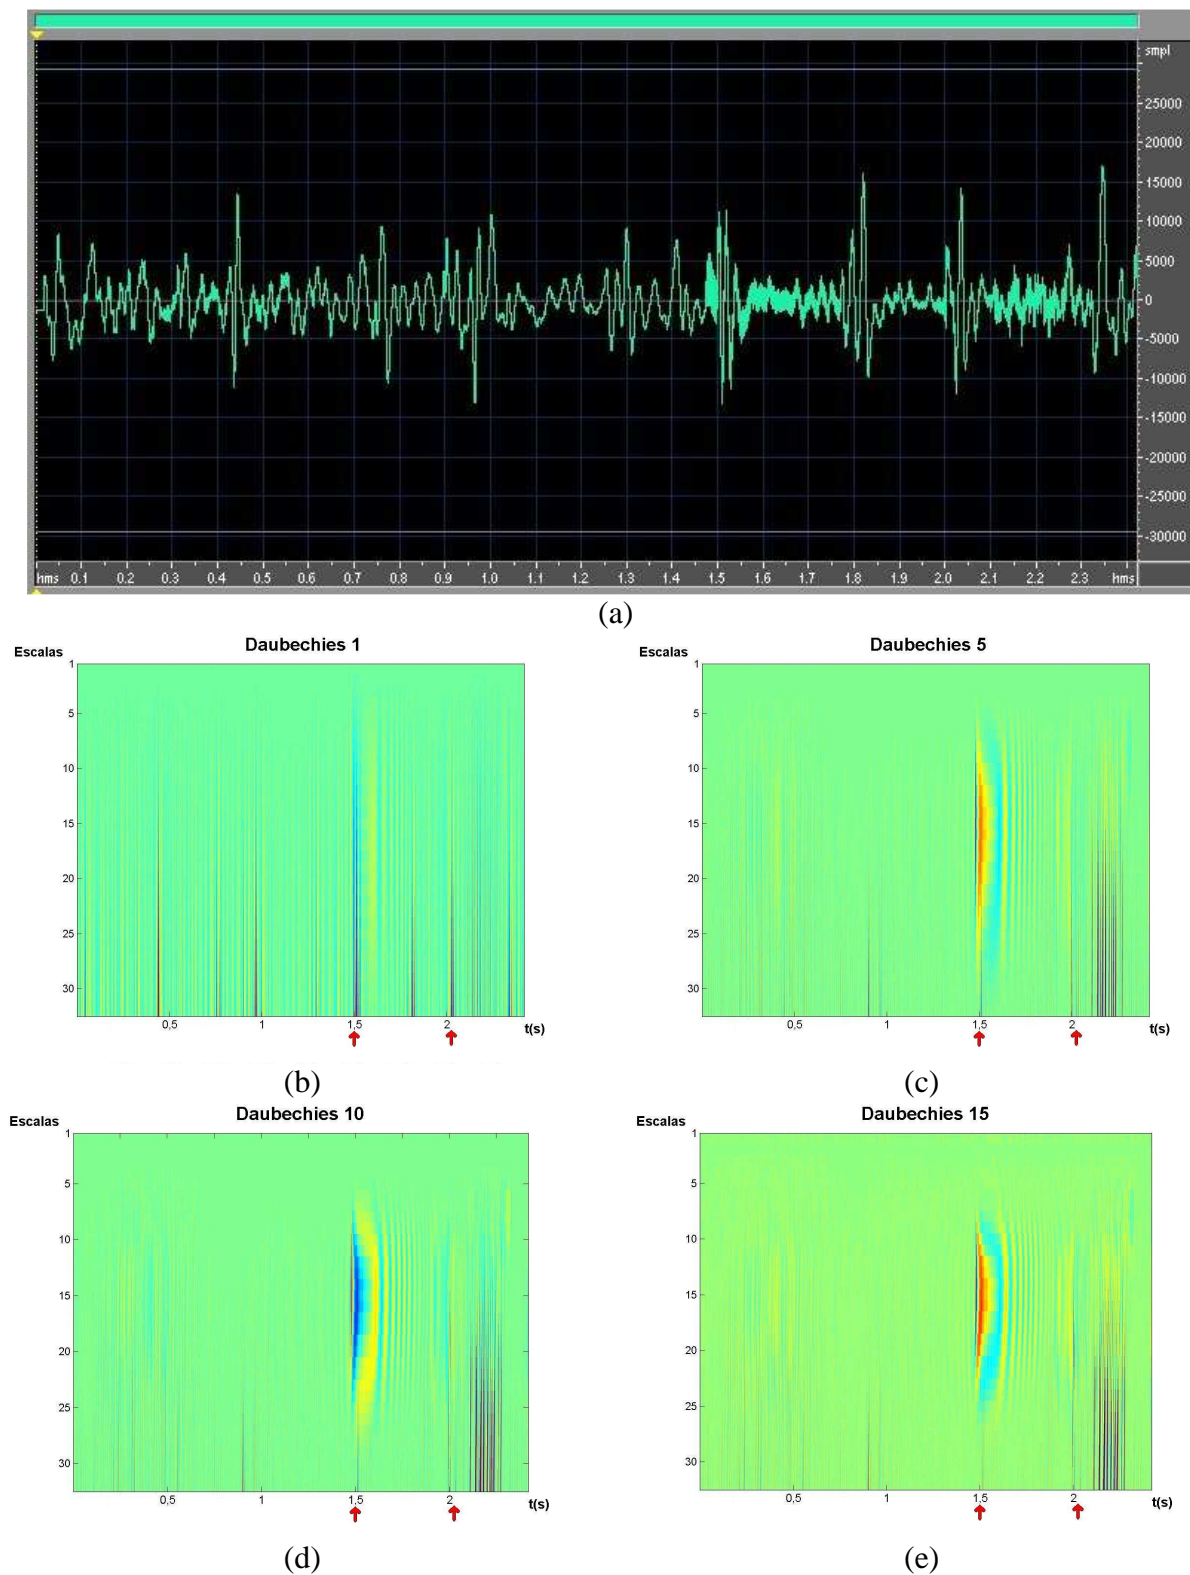




Figura 38: Escalogramas de um ciclo respiratório com anomalias contínuas, mais precisamente sibilos, variando a escala entre 1 e 32, e as funções *wavelet* mãe. (a) Sinal no domínio do tempo e escalogramas utilizando as funções (b) Daubechies 1, (c) Daubechies 5, (d) Daubechies 10 e (e) Daubechies 15.




(a)




(b)



(c)



(d)



(e)


Figura 39: Escalogramas de um ciclo respiratório com roncos, variando a escala entre 1 e 32, e as funções *wavelet* mãe. (a) Sinal no domínio do tempo e escalogramas utilizando as funções (b) Daubechies 1, (c) Daubechies 5, (d) Daubechies 10 e (e) Daubechies 15.

6.3.3 Escalogramas dos Sons Respiratórios Contendo Anomalias Descontínuas


Os escalogramas de um ciclo respiratório contendo anomalias descontínuas, calculados seguindo os mesmos parâmetros dos outros tipos de sons pulmonares, são ilustrados na figura 40, juntamente com o seu sinal no domínio do tempo. Este ciclo respiratório apresenta estertores finos na fase inspiratória.

Analisando-se os escalogramas da figura 40 nota-se que a CWT foi capaz de localizar a posição temporal da ocorrência dos estertores em toda a gama de suportes de funções *wavelet* mãe utilizada nesta análise, principalmente quando do uso de funções com maior suporte. As setas nos escalogramas da figura 40 mostram a localização temporal de início e fim da ocorrência dos estertores. Contrapondo-se às características verificadas na localização dos sons adventícios contínuos, a localização temporal dos sons descontínuos também apresentou bons resultados nas escalas mais baixas. Esta propriedade é compatível com o fato de as escalas mais baixas da CWT estarem ligadas às altas frequências.


O agrupamento temporal verificado nos escalogramas dessas anomalias apresenta uma significativa largura temporal, que praticamente impossibilita a localização temporal de cada estertor isoladamente. Contudo, a computação da CWT utilizando apenas uma escala, sem o cálculo absoluto da magnitude, possibilita esta localização. Neste contexto, observando-se os grandes estertores que ocorrem entre 0,15 e 0,6s nota-se que a CWT, no conjunto de *wavelets* mãe testado, apresenta uma melhor caracterização da presença dos estertores nas escalas entre 25 e 30.




(a)




(b)



(c)



(d)



(e)

Figura 40: Escalogramas de um ciclo respiratório com anomalias descontínuas, ou estertores finos, variando a escala entre 1 e 32 e as funções *wavelet* mãe. (a) Sinal no domínio do tempo, (b) Daubechies 1, (c) Daubechies 5, (d) Daubechies 10 e (e) Daubechies 15.

6.3.4 Considerações Sobre a Análise de Sons Pulmonares Empregando a Transformada Wavelet Contínua

Avaliando-se os resultados preliminares obtidos pela análise dos ciclos respiratórios através dos escalogramas, resultantes do cálculo da CWT destes ciclos, nota-se que estes escalogramas também geraram desenhos característicos na ocorrência de sons adventícios. Estas representações também foram capazes de localizar a ocorrência desses sons nos ciclos respiratórios com maior precisão quando comparadas aos espectrogramas. Esta maior precisão da localização temporal se deve ao fato de a STFT utilizada possuir resolução temporal de 3,3 ms enquanto que a CWT, por sua característica de função real e implementação convolutiva, é capaz de efetuar a localização temporal nas proximidades da amostra de início da ocorrência, dependendo de seu suporte efetivo, o que neste caso encontra-se na ordem de centenas de microssegundos.

Em contrapartida, os escalogramas dos ciclos respiratórios analisados não foram capazes de gerar figuras características diferentes para diferentes tipos de sons adventícios, nem tampouco apresentar uma escala específica capaz de isolar os diferentes tipos de sons adventícios. Nesta linha, notou-se apenas que as escalas mais baixas são capazes de localizar os sons adventícios descontínuos, enquanto que as mais altas caracterizam melhor os contínuos, quando utilizadas funções *wavelet* mãe de maior suporte. Contudo, as escalas mais altas também são capazes de localizar temporalmente os sons do fluxo aéreo normal, como visto na figura 37, além de não isolar totalmente a presença dos sons adventícios descontínuos, como visto na figura 40. Desta forma, não foi possível encontrar conjuntos de escalas nos escalogramas capazes de isolar apenas um tipo de som adventício, para servir como fonte de dados para classificação. Assim, estes fatores tornam ineficiente o uso desta técnica para a classificação dos diferentes sons adventícios nos sons pulmonares.

Os resultados obtidos pela análise por Transformada Wavelet Contínua indicaram apenas um ganho significativo em relação à análise por espectrogramas para o problema de isolar os sons adventícios e gerar uma fonte de dados para a classificação automática: uma melhor localização temporal da ocorrência destes sons.

Portanto, estes resultados motivaram o estudo da aplicação da Transformada Wavelet Discreta no tratamento deste problema, sendo que esta abordagem se configurou como a técnica de processamento de sinais chave para o desenvolvimento das metodologias inovadoras apresentadas neste trabalho. Desta forma, a descrição dos resultados obtidos

utilizando a DWT, assim como as novas metodologias propostas, são apresentadas nos Capítulos 7 e 8.

CAPÍTULO 7


CARACTERIZAÇÃO E CLASSIFICAÇÃO DE SONS PULMONARES EMPREGANDO DWT E REDES NEURAIS RBF

7.1 AVALIAÇÃO DOS SONS PULMONARES ATRAVÉS DA DWT


A metodologia utilizada no estudo preliminar do comportamento da DWT dos sons adventícios foi a computação da MRA, ou decomposição *wavelet*, dos ciclos respiratórios, avaliando os seus respectivos sinais detalhe e aproximação para cada nível de decomposição. Assim como nas análises por STFT e CWT, este procedimento foi realizado visando encontrar sinais característicos que possibilitem a classificação desses ciclos respiratórios quanto ao tipo de anomalia, englobando também os casos de ausência.

Inicialmente, realizou-se uma avaliação dos sinais resultantes do primeiro nível de decomposição *wavelet* utilizando as funções da família Daubechies, baseado na metodologia empregada por Kandaswamy *et al.* (2004), visando encontrar uma função que caracterize diferentes tipos de anomalias presentes no ciclo respiratório. Portanto, foram avaliados os resultados da decomposição *wavelet* utilizando-se as funções Daubechies 1 a 10, em ciclos respiratórios normais, com anomalias contínuas e com anomalias descontínuas.


As figuras 41 a, b e c são exemplos de sinais resultantes do primeiro nível de decomposição *wavelet* de um ciclo respiratório contendo anomalias contínuas, mais especificamente sibilos, para as funções Daubechies 2, 3 e 4, respectivamente. Nessas figuras, nota-se claramente que, a partir da função Daubechies 3, os coeficientes detalhe perdem cada vez mais informações quanto à presença do sibilo, sendo esta informação praticamente eliminada quando do uso da função Daubechies 4. Já as figuras 42 a, b e c mostram a mesma gama de funções *wavelet* no caso de um ciclo respiratório contendo anomalias descontínuas, sendo estas estertores finos. Neste caso, o aumento da ordem da função *wavelet* entre os níveis 2 a 4 não surtiu o mesmo efeito verificado no caso das anomalias contínuas, apresentando atenuação dos coeficientes detalhe para estes níveis sem, entretanto, atenuá-los totalmente.



(a)




(b)




(c)


Figuras 41: Sinais resultantes do primeiro nível de decomposição *wavelet* de um ciclo respiratório contendo anomalias contínuas, utilizando as função Daubechies 2 (a), 3 (b) e 4 (c).



(a)




(b)



(c)

Figuras 42: Sinais resultantes do primeiro nível de decomposição *wavelet* de um ciclo respiratório contendo anomalias descontínuas, utilizando as função Daubechies 2 (a), 3 (b) e 4 (c).

Assim, notou-se que, com o aumento da ordem da *wavelet* Daubechies utilizada no processo de decomposição *wavelet*, houve uma maior seletividade na caracterização das anomalias contínuas e descontínuas, nos coeficientes detalhe. Esta característica é compatível com a estrutura básica das *wavelet* Daubechies, descritas na subseção 3.7.1, que também apresentam o dobro do número de coeficientes em relação ao seu suporte. Conseqüentemente, o incremento do suporte da *wavelet* Daubechies utilizada reflete diretamente no número de pólos dos filtros de decomposição e reconstrução e no seu fator de qualidade, sendo que um maior suporte reflete-se em um filtro com fator de qualidade mais acentuado. Esta propriedade encontra-se exemplificada na figura 43, que apresenta a resposta em freqüência dos filtros $H[n]$ e $L[n]$ das *wavelets* Daubechies 2 e $10.\pi$



Figuras 43: Curvas de resposta em freqüência dos filtros de decomposição $H[n]$ (em vermelho) e $L[n]$ (em azul) para as *wavelets* Daubechies 2 (a) e Daubechies 10 (b).

Devido às propriedades verificadas nos ensaios preliminares de processamento dos sons pulmonares através da decomposição *wavelet*, optou-se por aprofundar a análise por meio desta técnica, utilizando a função Daubechies 4, uma vez que esta função mostrou-se como um limiar de separação, nos coeficientes detalhe do primeiro nível de decomposição, entre ciclos respiratórios com anomalias contínuas e descontínuas, conforme as figuras 41c e 42c. Este aprofundamento foi realizado através de novos processos de decomposição dos ciclos respiratórios contendo sons adventícios contínuos, utilizando essa *wavelet*.

7.2 CARACTERIZAÇÃO DOS SONS ADVENTÍCIOS ATRAVÉS DA DWT

De acordo com os resultados preliminares obtidos na análise dos sons pulmonares adventícios, apresentados na seção 7.1, vislumbrou-se a possibilidade de caracterização destes sons utilizando o processo de decomposição *wavelet*.

A técnica proposta faz uso das características espectrais dos diferentes grupos de sons adventícios para traçar curvas que demonstrem mais claramente essas características, gerando um conjunto de dados compactos que, posteriormente, são utilizados como fonte de informação para um sistema de reconhecimento de padrões baseado em redes neurais artificiais.

Conforme descrito na seção 2.4, os sons pulmonares adventícios contínuos apresentam como característica espectral a presença de uma ou mais frequências preponderantes durante um tempo relativamente longo, na ordem de dezenas ou centenas de milissegundos. Esta propriedade, que gera sinais característicos visíveis em espectrogramas, conforme apresentado na seção 6.2, resulta em uma relativa alta energia distribuída em poucas bandas de frequência, isto é, a energia desses sons adventícios encontra-se localizada principalmente na região espectral de suas frequências preponderantes.

Os sons adventícios descontínuos são formados por cadeias de ruídos impulsivos de maior ou menor duração, para os estertores grossos e finos, respectivamente. Esta propriedade, também visível em espectrogramas, resulta em uma menor magnitude de energia, sendo esta mais uniformemente distribuída ao longo do espectro.

Já os sons do fluxo aéreo normal, com exceção feita aos sons traqueais, apresentam maior concentração de energia na região de baixas frequências, apresentando também componentes de menor amplitude distribuídas uniformemente no espectro. Esta concentração de energia nas baixas frequências acentua-se ainda mais quando há contaminação dos sons pulmonares pelos sons cardíacos.

De acordo com essas características, as sub-bandas de frequência resultantes do processo de decomposição *wavelet* dos sons pulmonares refletem as diferentes distribuições de energia, de acordo com o tipo de som adventício presente no som pulmonar, contemplando também a sua ausência. Esta propriedade pode ser visualizada graficamente nas figuras 44, 45 e 46, que apresentam os coeficientes detalhe dos cinco primeiros níveis de decomposição de ciclos respiratórios contendo sons adventícios contínuos (sibilo) e descontínuos (estertores finos) e um som vesicular obtido de um voluntário saudável. Nessas figuras, a magnitude M é representada em valores de 16 bits das amostras do conversor analógico-digital. Apesar de estas amostras terem relação direta com a pressão acústica do som adquirido, a obtenção deste valor de pressão acústica depende do conhecimento da curva de resposta circuito de aquisição, que não é fornecido pelos repositórios.

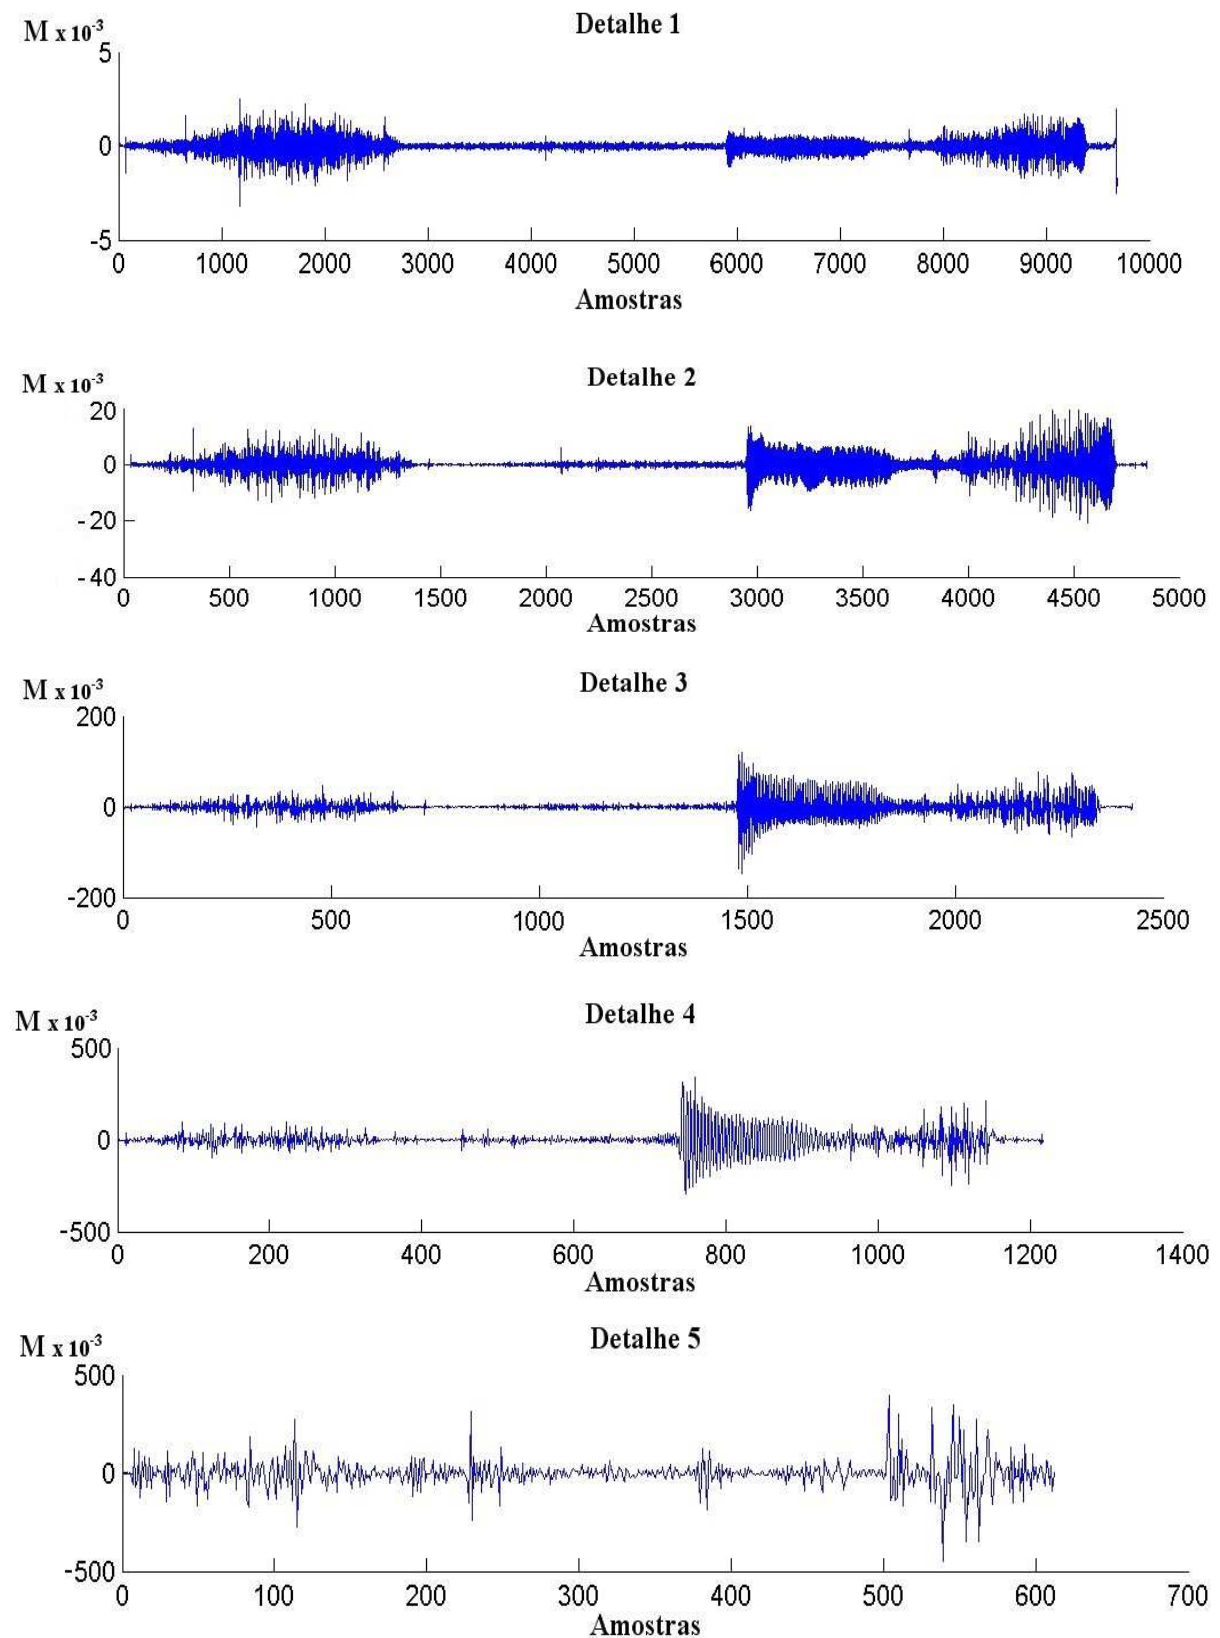


Figura 44: Coeficientes de detalhe dos cinco primeiros níveis de decomposição *wavelet* do ciclo respiratório contendo sibilos, utilizando a *wavelet* Daubechies 4.




Figura 45: Coeficientes de detalhe dos cinco primeiros níveis de decomposição *wavelet* do ciclo respiratório contendo estertores finos, utilizando a *wavelet* Daubechies 4.

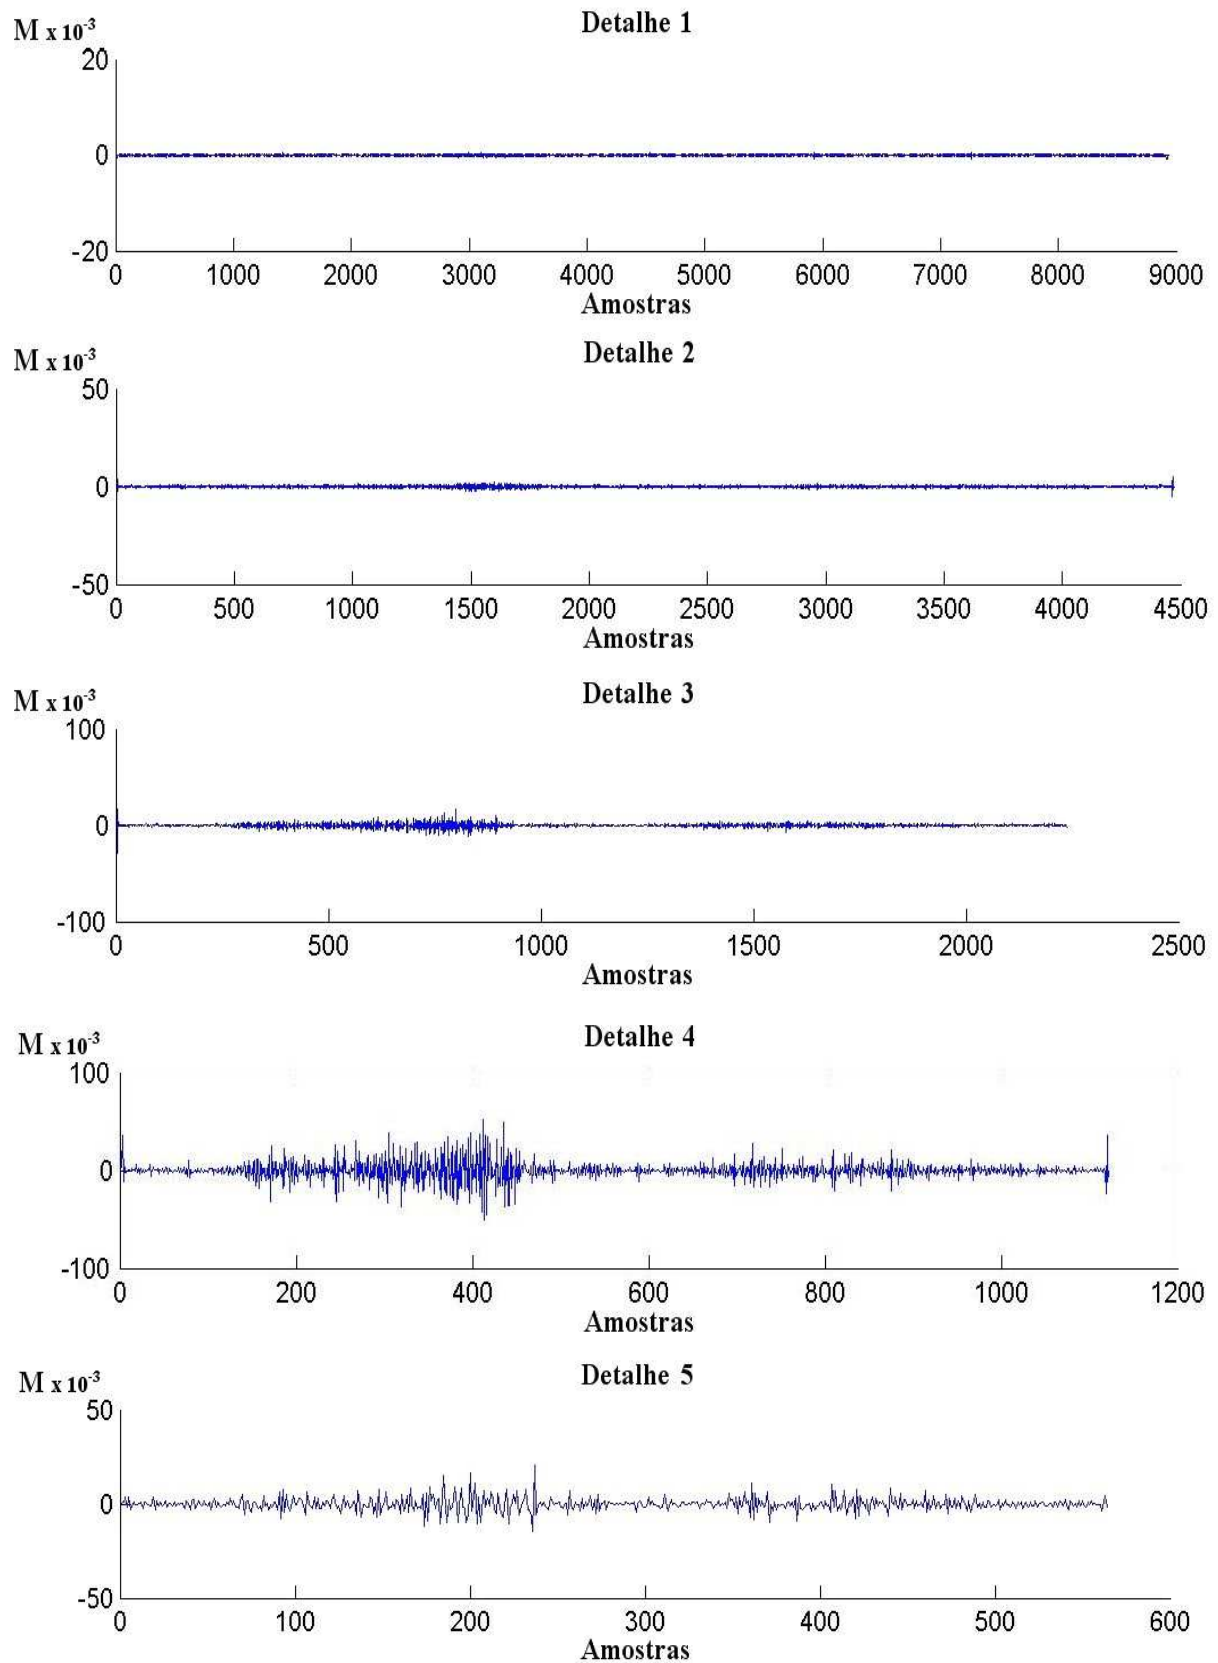


Figura 46: Coeficientes de detalhe dos cinco primeiros níveis de decomposição *wavelet* do ciclo de um som vesicular normal, utilizando a *wavelet* Daubechies 4.

Os sinais apresentados nas figuras 44 e 45 exemplificam a distribuição de energia obtida para cada tipo de som adventício, dentro dos grupos contínuos e descontínuos. No ciclo respiratório contendo o som adventício contínuo da figura 44, nota-se que a amplitude do sinal do sibilo apresenta uma variação brusca entre os coeficientes detalhe 2 e 3, atingindo níveis mais altos nos coeficientes detalhe 4 e 5. As bandas de frequência referentes a cada nível de coeficientes detalhe, para a frequência de amostragem adotada, são apresentadas na tabela 3. Este comportamento é compatível com as características espectrais das anomalias contínuas, indicando que a frequência fundamental e as harmônicas deste sibilo encontram-se na faixa entre 125 e 500 Hz.

Em contrapartida, o sinal do ciclo respiratório contendo estertores finos, na figura 45 apresenta um crescimento gradual da amplitude dos coeficientes detalhe com o aumento do nível de decomposição apresentando, já nos coeficientes detalhe 2, uma amplitude máxima compatível com a apresentada pelos sibilos no nível 4.


Já o sinal do som vesicular da figura 46 apresenta muito baixa amplitude nos coeficientes detalhe dos primeiros níveis de decomposição, relativas às altas frequências. Pela característica destes sinais, a maior parte da energia se encontra concentrada nas regiões abaixo de 125 Hz, vindo a refletir nos coeficientes detalhe do nível seis em diante.

Assim, a verificação da capacidade da técnica de processamento por decomposição *wavelet* em separar as componentes que caracterizam a presença e o tipo de anomalia, entre os grupos de sons adventícios contínuos e descontínuos, motivou o desenvolvimento de uma metodologia de análises dos sons respiratórios adventícios utilizando esta técnica. Assim, uma vez que as gravações digitais dos ciclos respiratórios foram normalizadas para a frequência de amostragem de 8 kHz, arbitrou-se a realização da decomposição *wavelet* desses ciclos até o décimo nível. Este nível foi escolhido por, além de segmentar o sinal do ciclo respiratório em sub-bandas de frequências audíveis, denotar sub-bandas de frequências nos sinais detalhe 9 e 10, e sinal aproximação 10, abaixo do limiar dessas frequências, levando em conta inclusive segmentos de frequências que não possam ser utilizadas no processo de ausculta, que é puramente auditivo. A relação entre os sinais obtidos no processo de decomposição *wavelet* e suas respectivas bandas de frequências está descrita na tabela 3.


Tabela 3 – Sub-bandas de frequências dos coeficientes resultantes do processo de decomposição *wavelet* dos ciclos respiratórios analisados.

Coefficientes	Banda de Frequências (Hz)
Detalhe 1	2000 – 4000
Detalhe 2	1000 – 2000
Detalhe 3	500 – 1000
Detalhe 4	250 – 500
Detalhe 5	125 – 250
Detalhe 6	62,5 – 125
Detalhe 7	31,25 – 62,5
Detalhe 8	15,625 – 31,25
Detalhe 9	7,8125 – 15,625
Detalhe 10	3,90625 – 7,8125
Aproximação 10	0 - 3,90625


Como o fator de caracterização utilizado nesta metodologia reside no nível de amplitude resultante dos coeficientes detalhe dos dez primeiros níveis de decomposição *wavelet*, calculou-se a energia dos coeficientes detalhe para cada nível de decomposição, com o objetivo de se diminuir o montante de dados em análise. Assim, comparou-se a variação da energia contida em cada nível de decomposição *wavelet* frente ao tipo de anomalia, nos grupos de anomalias contínuas, descontínuas e ciclos normais. A figura 47 mostra os gráficos de valores de média, em cor azul, e desvio padrão, em cor bordô, da variação da energia em relação ao nível de decomposição *wavelet* para os grupos de ciclos respiratórios propostos. No cálculo desses gráficos, foram utilizados 25 ciclos normais, 31 contendo anomalias contínuas e 32 contendo anomalias descontínuas, utilizando os filtros da função *wavelet* mãe Daubechies 4 no processo de decomposição. Exemplos de telas do software desenvolvido para a realização desta análise estão contidas no apêndice II.



(a)



(b)



(c)

Figura 47 – Curvas médias de Energia x Nível de decomposição *wavelet* para os grupos de ciclos respiratórios analisados (a) ciclos respiratórios normais, (b) ciclos respiratórios com anomalias contínuas e (c) ciclos contendo anomalias descontínuas. Cada nível de decomposição corresponde à energia média e desvio padrão dos coeficientes detalhe deste nível.

Além dos casos de presença de anomalias contínuas e descontínuas isoladamente, existe a possibilidade de ocorrência destes sons adventícios simultaneamente em um mesmo ciclo respiratório. Nesses casos, os componentes de alta frequência aumentam a energia nos níveis iniciais de decomposição, enquanto os sons anômalos contínuos aumentam os níveis médios. Então, as curvas resultantes neste caso indicam alta energia em todos os níveis de decomposição, conforme ilustrado na figura 48, que mostra o desenho da curva típica para ciclos respiratórios contendo sons anômalos contínuos e descontínuos. No processo de obtenção deste gráfico, foram utilizados 24 ciclos respiratórios contendo anomalias contínuas e descontínuas.




Figura 48 – Curva de Energia x Nível de decomposição *wavelet* para os grupos de ciclos respiratórios contendo anomalias contínuas e descontínuas. Cada nível de decomposição corresponde à energia média e desvio padrão dos coeficientes detalhe deste nível.

As curvas obtidas da distribuição da energia contida nos coeficientes detalhe em relação ao nível de decomposição mostraram-se capazes de refletir as características espectrais dos diferentes sons adventícios, gerando uma informação compacta e de análise simples. Entretanto, a análise visual destas curvas visando reconhecer a presença de sons adventícios ainda configura-se como um critério puramente qualitativo, sendo necessária a aplicação de uma técnica de mensuração para avaliar quantitativamente a eficiência desta metodologia na classificação dos sons pulmonares.

Concomitantemente, existe outra questão qualitativa a ser analisada na avaliação desta metodologia. Todas as curvas até este momento foram computadas utilizando-se como base os filtros de decomposição da função *wavelet* mãe Daubechies 4. Entretanto, como apresentado na seção 3.7, cada uma das famílias de funções *wavelet* foi construída visando

dar maior ênfase às propriedades específicas das funções como número de momentos nulos, simetria e resposta em frequência. Sendo assim, nenhuma destas famílias foi projetada com o objetivo específico de atender aos requisitos utilizados nesta metodologia. Este fato cria a necessidade de se analisar a resposta de cada uma destas famílias, incluindo a variação do suporte das funções *wavelet* dentro de cada família, buscando qual destas funções apresenta melhor resultado para a metodologia proposta.

Portanto, visando aplicar um critério mensurável para avaliação quantitativa da metodologia proposta como técnica de processamento para classificação dos sons pulmonares, empregou-se uma abordagem baseada em uma rede neural artificial como classificador, utilizando as curvas de energia por nível de decomposição *wavelet* como dados de entrada. Neste método de classificação foram apresentados os resultados da computação das curvas de energia por nível de decomposição *wavelet* utilizando dez diferentes funções, de seis diferentes famílias de *wavelets*. As funções ensaiadas estão descritas na tabela 4.

Tabela 4 – Famílias de funções *wavelet* avaliadas.

Famílias de bases Ortonormais	Famílias Biortogonais
Daubechies 4 e 44	Biortogonal 3.7
Symlets 8 e 20	Biortogonal 3.9
Coiflet 3	Biortogonal 6.8
Aproximação discreta da <i>wavelet</i> Meyer	Biortogonal reversa 3.7

Assim, além de ser utilizada como metodologia de avaliação da técnica proposta, a rede neural foi integrada a esta técnica para ser utilizada como classificador automático dos sons pulmonares. Contudo, uma vez que a análise da performance desta metodologia engloba a avaliação das várias famílias *wavelet* concomitantemente com os resultados apresentados pelas redes neurais, ambas as avaliações foram realizadas de forma unificada, gerando assim uma matriz de testes de treinamento das redes neurais juntamente com a função *wavelet* utilizada no processo de decomposição. A metodologia adotada no desenvolvimento, treinamento e testes dessas redes neurais está descrita na seção 7.3.

7.3 CLASSIFICAÇÃO ATRAVÉS DE REDES NEURAI RBF

Durante os testes iniciais para a escolha da estrutura de rede neural artificial a ser utilizada como algoritmo de classificação dos sons pulmonares, experimentou-se a implementação de uma rede neural artificial MLP, treinada a partir do algoritmo de

retropropagação do erro, como classificador na avaliação da metodologia proposta. Alguns exemplos das interfaces do software desenvolvido para o treinamento deste tipo de rede neural são mostrados no Apêndice III. Esta escolha foi feita devido ao fato de este tipo de rede neural ter apresentado resultados satisfatórios na técnica desenvolvida para reconhecimento de sibilos (RIELLA, 2004).

Nos testes preliminares, a aplicação da rede neural MLP mostrou-se pouco ágil frente a gama de testes necessária para avaliação da metodologia proposta, levando em conta o número de funções *wavelet* a serem ensaiadas. Para a realização deste ensaio, deve-se extrair os valores de energia em relação ao nível de decomposição *wavelet* para cada uma destas funções *wavelet*, treinando algumas redes neurais para cada resultado obtido de decomposição. Conforme a tabela 4, as famílias propostas para avaliação somam dez, o que resulta, ao mínimo, em uma ordem de dezenas de redes neurais a serem treinadas para se obter uma avaliação consistente do método como fonte de dados para a classificação e das próprias potencialidades da rede neural como algoritmo classificador.

Durante os ensaios preliminares das redes MLP, estas se mostraram lentas no processo de convergência a um erro mínimo considerado aceitável, despendendo algumas horas neste processo. Este comportamento já era esperado, sendo também observados nos ensaios da metodologia de reconhecimento de sibilos (RIELLA, 2004). Ele reside no fato de ter de se utilizar valores muito baixos para a taxa de aprendizagem η da regra delta, conforme a equação (51), no Capítulo 4. Esses valores são utilizados visando evitar que passos muito grandes na atualização dos pesos sinápticos venham a desviar o gradiente descendente do caminho de menor erro no espaço dos pesos. Assim, o baixo valor da taxa de aprendizagem resulta em um maior número de épocas de treinamento necessárias para varrer o mesmo espaço, em busca do ponto de menor erro. Conseqüentemente, o algoritmo de retropropagação do erro torna-se mais lento.

Desta maneira, procurou-se utilizar abordagens de redes neurais artificiais que possibilitassem um processo de treinamento mais ágil, viabilizando assim a avaliação de um maior número de funções *wavelet* dentro da metodologia proposta de classificação de sons pulmonares. De acordo com este critério, foi escolhida a utilização de redes neurais RBF, devido à sua característica de rápido tempo de treinamento, conforme o algoritmo escolhido.

A estrutura das redes neurais RBF ensaiadas seguiu o formato padrão, apresentado na seção 4.4. Nesta estrutura, o número de entradas é igual à quantidade de componentes do vetor a ser analisado, sendo 11 para este caso, referentes à energia contida nos coeficientes de detalhe de cada um dos dez primeiros níveis de decomposição juntamente com a energia contida nos coeficientes de aproximação nível 10. O número de neurônios da camada

intermediária, para o algoritmo de treinamento utilizado e descrito na subseção 7.3.1, é igual ao número de exemplos utilizados no conjunto de treinamento, configurando um total de 44 neurônios. Finalmente, o número de neurônios da camada de saída é igual ao número de grupos passíveis de classificação, somando um total de 4 agrupamentos.

Como função de base radial utilizada nos neurônios da camada intermediária, foi empregada a função Gaussiana, definida na equação (55), onde s define o desvio padrão, ou abertura desta função. Este parâmetro define o quão abrangente será a função de base radial e, conseqüentemente, o tamanho do espaço delimitado pelo agrupamento definido por um determinado neurônio.

$$f(n) = e^{-\left(\frac{n}{s}\right)^2} \quad (55)$$

7.3.1 Treinamento das redes neurais RBF

Como descrito, o primeiro objetivo da aplicação das redes neurais artificiais RBF é o de fornecer um parâmetro quantitativo para a avaliação das curvas de energia em relação ao nível de decomposição *wavelet* obtidas a partir de diferentes funções *wavelet*. Como segundo objetivo, propõe-se avaliar a resposta da rede neural em si, verificando se esta pode ser utilizada como método de classificação na metodologia proposta.

Desta forma, priorizou-se a utilização do algoritmo de treinamento que dependa o menor tempo neste processo. Assim, o algoritmo escolhido para treinamento e, no caso específico da RBF, utilizado para a delimitação da estrutura da rede neural foi o treinamento supervisionado de projeto exato, obtido a partir do conjunto de treinamento (DEMUTH, BEAGLE e HAGAN, 2007).

Neste método, os vetores utilizados no conjunto de treinamento são atribuídos como centros dos agrupamentos definidos pelos neurônios da camada intermediária da rede neural, sendo atribuído um valor fixo ao desvio padrão da função de base radial, igual para todos os agrupamentos e definido como parâmetro de entrada. Desta forma, os pesos sinápticos de cada neurônio serão iguais aos valores dos coeficientes do vetor de treinamento a ele atribuído sendo, conseqüentemente, o número de neurônios da camada intermediária da rede neural igual ao número de exemplos utilizados no conjunto de treinamento. Já as polarizações dos neurônios da camada intermediária são obtidos a partir da abertura escolhida para a RBF, conforme a equação (56) (DEMUTH, BEAGLE e HAGAN, 2007), onde s é a abertura da RBF. Este valor de polarização assegura que a RBF assumirá valor 0,5 para vetores de entrada que possuam distância euclidiana igual a $-s$ ou s .

$$b_n = \frac{\sqrt{-\ln(0,5)}}{s} = \frac{0,83255}{s} \quad (56)$$

Já os pesos sinápticos e polarizações da camada de saída são calculados apresentando o conjunto de treinamento aos neurônios da camada intermediária frente ao conjunto de saída desejado. Uma vez que a função de ativação destes neurônios é linear, para obter estes pesos basta resolver a equação (57), onde wb é a matriz de pesos sinápticos juntamente com os *bias* da camada de saída, A é a matriz de saída da camada intermediária e T é a matriz de padrões de saída para o conjunto de treinamento.

$$wb \bullet A = T \quad (57)$$

O treinamento de redes neurais RBF através do projeto exato apresenta a vantagem de ser extremamente rápido, uma vez que não se utiliza de algoritmos de busca de pontos específicos no espaço multidimensional em análise. Esta vantagem abre espaço para outra, que se refere à fácil inserção de novos agrupamentos em uma rede já existente, uma vez que é muito rápido treiná-la novamente. Além destas, este tipo de treinamento assegura um índice de acerto de 100% para o conjunto de treinamento, uma vez que este conjunto é utilizado como base para obtenção dos centros dos agrupamentos.

Em contrapartida, este método de treinamento praticamente exige o ensaio de várias aberturas das RBF, em busca de uma que maximize a generalização da rede, uma vez que não há regra determinística para o cálculo destas aberturas.

Devido a esta desvantagem do método de treinamento das redes neurais RBF através do projeto exato, tornou-se necessária a execução de uma busca exaustiva de redes neurais, sendo as linhas definidas pelo conjunto de curvas resultante do processo de decomposição para as dez famílias *wavelet* testadas e as colunas formadas pela abertura da RBF projetada para o reconhecimento. Entretanto, como o processo de treinamento e validação de cada rede neural é muito rápida, na ordem de segundos, pôde-se computar esta matriz de ensaios sem dificuldades.

Desta forma, o processo de treinamento definido englobou o teste de 100 diferentes aberturas das funções RBF para cada conjunto de curvas obtidas no processo de decomposição para uma família de funções *wavelet*, resultando em um total de 1000 redes RBF treinadas. Como apresentado na seção 7.3, foram utilizados 44 ciclos respiratórios como conjunto de treinamento, o que configura 16% do conjunto de sons pulmonares utilizados no desenvolvimento desta metodologia.

7.4 RESULTADOS OBTIDOS NA CLASSIFICAÇÃO

Para se realizar a avaliação do desempenho das curvas de energia por nível de decomposição das diferentes famílias *wavelet* propostas, foi realizado o seguinte procedimento: inicialmente, foram computadas as curvas de energia por nível de decomposição de todos os 275 ciclos respiratórios disponíveis para análise, para cada uma das dez funções *wavelet* propostas. Este procedimento resultou em dez diferentes agrupamentos de 275 curvas, sendo cada agrupamento relativo às curvas obtidas pela função *wavelet* correspondente. Posteriormente, foram selecionados 44 ciclos respiratórios para formar o conjunto de treinamento, sendo selecionados aleatoriamente 11 ciclos de cada grupo de classificação. Conseqüentemente, este procedimento resultou em dez agrupamentos de 44 curvas utilizadas como conjunto de treinamento, uma para cada função *wavelet*. De posse dos conjuntos de treinamento, foram treinadas 100 redes neurais para cada conjunto de treinamento, variando o valor da abertura da RBF da rede treinada no intervalo [1, 100]. Ao fim de cada treinamento foi apresentado todo o conjunto de curvas disponíveis, obtidas utilizando a função *wavelet* avaliada, computando, assim, o índice de acerto total da rede em teste.

A variação do índice de acerto em função da abertura da RBF e da função *wavelet* utilizada é apresentada graficamente na figura 49. A tabela com todos os resultados obtidos, que geraram estes gráficos, encontra-se no Apêndice IV. Uma vez que, para a técnica de treinamento utilizada, o resultado da classificação apresenta índice de acerto de 100% para o conjunto de treinamento, os valores destes índices foram computados considerando-se apenas o conjunto de validação.

A tabela 5 contém os valores referentes aos melhores resultados obtidos na classificação por função *wavelet*.




Figura 49: Curvas referentes à matriz de acerto obtida na classificação em relação à abertura da RBF. As curvas são individuais por função *wavelet*.

Tabela 5 - Índice de acerto máximo obtido por cada função *wavelet*.

Função Wavelet	Acerto no Conjunto de Validação (%)	Abertura da RBF
Biortogonal 3.7	88	27
Biortogonal 3.9	83,27	42; 43
Biortogonal 6.8	92,36	22; 25; 26
Coiflet 3	89,82	16; 17
Daubechies 4	86,55	20; 21
Daubechies 44	89,45	15
Meyer Discreta	86,18	14
Biortogonal Reversa 3.7	92	72; 73
Symlet 8	90,91	13
Symlet 20	88	58; 59; 60

CAPÍTULO 8

CARACTERIZAÇÃO DE SONS ADVENTÍCIOS ATRAVÉS DE FILTRAGEM POR ANÁLISE ESPECTRAL SELETIVA

8.1 INTRODUÇÃO

Um dos pontos de confusão na caracterização, tanto no processamento automático quanto na ausculta de sons pulmonares, ocorre pela sobreposição destes com outros sons fisiológicos auscultados, principalmente pelos sons cardíacos. Esta sobreposição é especialmente complicadora quando da ocorrência de roncos, uma vez que estes se localizam na mesma região espectral dos sons cardíacos, impossibilitando a sua separação através de processos de filtragem usuais. Este problema tem motivado o desenvolvimento de trabalhos que visam isolar os sons pulmonares dos cardíacos, sendo as primeiras propostas apresentadas por (KOMPIS e RUSSI, 1992; HADJILEONTIADIS e PANAS, 1997b) e mais recentemente, os trabalhos de GNITECKI *et al.*, 2005; POURAZAD, MOUSSAVI e THOMAS, 2006; CHARLESTON-VILLALOBOS *et al.*, 2006; FLORES-TAPIA, MOUSSAVI e THOMAS, 2007.

Por outro lado, a principal vantagem do processo de decomposição *wavelet* reside no fato de este ser reversível, possibilitando a obtenção dos coeficientes das sub-bandas específicas, contendo as diferentes componentes do sinal original ainda no domínio do tempo, e reconstruí-las no sinal original, praticamente sem perda de informação. Portanto, este processo pode ser utilizado para segmentar o sinal do ciclo respiratório em sub-bandas de frequências, atuando apenas na região espectral específica de sobreposição dos sons cardíacos e pulmonares.

Desta maneira, foi desenvolvida uma metodologia que tem por objetivo extrair sons característicos de anomalias contínuas, na região espectral de ocorrência dos sons cardíacos, mantendo intactos os sons constantes em outras regiões de frequência, utilizando como base os sons pulmonares gravados digitalmente e retornando-os processados também em arquivos de áudio. Assim, o objetivo desse algoritmo é o de fornecer uma realimentação ao profissional de saúde na forma de um sinal de áudio contendo apenas os sons adventícios presentes nos sons pulmonares, sendo estes livres da interferência de sons cardíacos.

8.2 METODOLOGIA DE FILTRAGEM POR ANÁLISE ESPECTRAL SELETIVA

Inicialmente, na metodologia proposta, os sinais dos sons pulmonares são segmentados em sub-bandas de frequências através do processo de decomposição *wavelet* até o 4º nível. Este nível foi escolhido devido ao fato de os roncos, sons anômalos que se confundem em frequência com os sons cardíacos, possuírem frequência fundamental de, em valores máximos, 200 Hz (KANDASWAMY *et al.*, 2004). Assim, os coeficientes *wavelet* referentes à aproximação no nível 4, para a frequência de amostragem de 8 kHz, referem-se à banda de frequências de 0 a 250 Hz, conforme a tabela 6. Assim, a metodologia de filtragem por análise espectral seletiva age sobre os coeficientes *wavelet* do sinal aproximação nível 4, deixando intacta a informação dos outros tipos de sons adventícios, presentes nas outras bandas espectrais.

Tabela 6 – Sub-bandas de frequências dos coeficientes *wavelet* para cada nível de decomposição dos ciclos respiratórios amostrados a 8 kHz de frequência.

Coefficientes Wavelet	Banda de Frequências (Hz)
Detalhe 1	2000 – 4000
Detalhe 2	1000 – 2000
Detalhe 3	500 – 1000
Detalhe 4	250 – 500
Aproximação 4	0 – 250

Finalizado o processo de decomposição *wavelet*, a metodologia propõe a execução da análise espectral dos coeficientes *wavelet* do sinal aproximação através do cálculo de sua FFT, conforme o exemplo mostrado na figura 50. Este procedimento de análise espectral é realizado visando localizar as componentes espectrais de maior relevância nos coeficientes de aproximação, sendo estes indícios da ocorrência de roncos. Este indício cresce com o aumento da frequência de localização dos picos espectrais, uma vez que os sons cardíacos localizam-se na região das frequências mais baixas, contendo banda espectral entre 20 e 150 Hz (LEHRER, 1990; HADJILEONTIADIS e PANAS, 1997b; HADJILEONTIADIS e PANAS, 1998). Assim, a detecção da localização espectral dos roncos possibilita a filtragem dos outros sinais, mantendo intacto o conteúdo destes roncos.




Figura 50: Espectro resultante do cálculo da FFT dos coeficientes de aproximação nível 4 de um ciclo respiratório contendo roncos.

Contudo, como a FFT dos coeficientes *wavelet* de aproximação do ciclo respiratório retorna um espectro com tamanho, em número de amostras, igual ou muito próximo ao tamanho original do sinal, este deve ser comprimido. Esta compressão é utilizada para obter-se uma curva característica do espectro com resolução igual ao comprimento do filtro FIR FFT a ser calculado. Assim, a metodologia proposta calcula a razão de segmentação do espectro original em relação ao comprimento do filtro a ser calculado, de 56 coeficientes, aplicando-a, então, sobre o espectro.

No processo de redução, foram confrontados algoritmos de cálculo da média entre amostras do espectro dentro de cada segmento contra algoritmos de detecção de pico dentro de cada segmento. A figura 51 mostra a comparação dos resultados obtidos com ambos os algoritmos.




Figura 51: Curvas resultantes do processo de segmentação espectral utilizando cálculo das médias, em preto, contra a detecção de pico do segmento, em azul, no ciclo respiratório contendo roncos. As curvas em vermelho apresentam a detecção do ponto de maior amplitude.

Desta forma, foi escolhido o processo de segmentação por detecção de pico, uma vez que este apresentou uma menor distorção na representação da envoltória de espectro original. Esta metodologia de segmentação também apresentou melhores resultados na computação de filtros multibanda, através da técnica de projeto de filtros FIR FFT.

Com o espectro original dos coeficientes do sinal aproximação comprimido, realiza-se a seleção da componente de frequência mais relevante no espectro computando, assim, a resposta em frequência do filtro FIR. Realizando-se a IFFT real da resposta em frequência do filtro, como descrito na equação (5), obtém-se os coeficientes de um filtro multibanda (OPPENHEIM e SCHAFER, 1989) FIR passa-faixa de 56 coeficientes, com banda passante centrada na frequência fundamental do ronco. O número de coeficientes foi ensaiado entre 20 e 256 visando encontrar um filtro que representasse a curva de resposta esperada com a maior fidelidade possível, com um mínimo tempo de processamento.

Uma vez que o processo é computado de forma *offline*, isto é, sobre o som gravado do ciclo respiratório, aplica-se o filtro utilizando as formas direta e reversa compensando, deste modo, a resposta em fase do filtro aplicado. Esta forma de aplicação do filtro também

assegura que o processo de reconstrução *wavelet* não apresentará distorções devido à resposta em fase do filtro aplicado. Assim, minimiza-se a distorção do resultado acústico do ronco no som processado, facilitando o processo de caracterização.

Após o processo de filtragem, o sinal é reconstruído, utilizando-se como base os coeficientes *wavelet* do sinal aproximação 4 filtrado, sendo este sinal armazenado novamente em um arquivo de áudio padrão *wave*. Desta operação, resulta um sinal do som pulmonar com as componentes espectrais localizadas abaixo de 250 Hz atenuadas, excetuando-se a componente espectral de mais alta amplitude. O fluxograma da metodologia desenvolvida de filtragem por análise espectral seletiva é apresentado na figura 52.

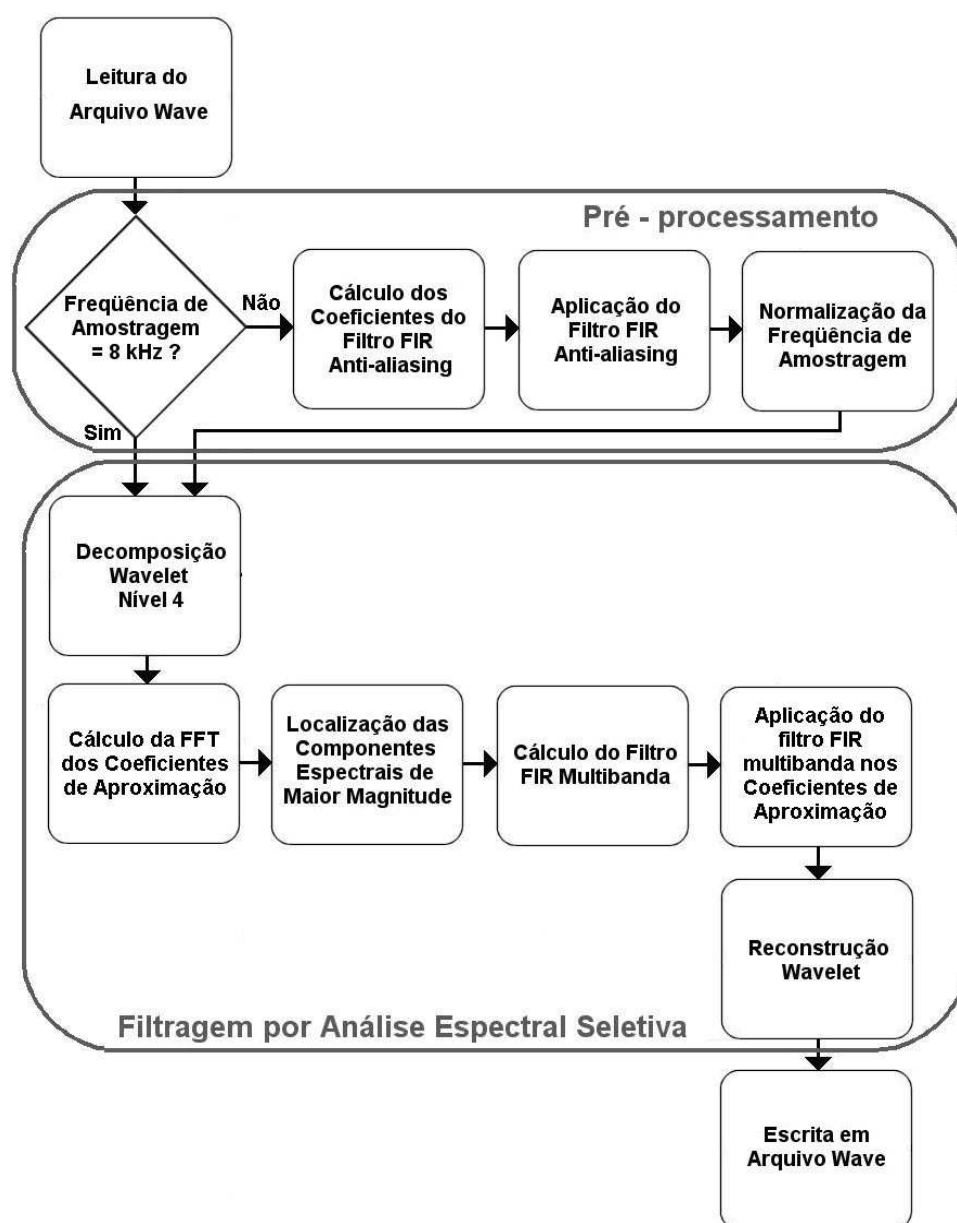



Figura 52: Fluxograma do algoritmo de implementação da metodologia de filtragem por análise espectral seletiva, utilizada para separação dos sons adventícios pulmonares dos outros sons fisiológicos.

8.3 COMPORTAMENTO DOS SONS PULMONARES



Os sons respiratórios normais possuem a maior parte de suas componentes espectrais contidas na região abrangida pelos coeficientes de aproximação. Entretanto, estas componentes não se concentram em poucas frequências específicas, mas sim encontram-se distribuídas de forma quase uniforme nesta sub-banda. Como o algoritmo de filtragem por análise espectral seletiva mantém apenas a componente espectral mais proeminente nesta sub-banda, a sua aplicação resulta em uma significativa atenuação dos sinais com grande largura de banda espectral, conforme ilustrado na figura 53.

Em relação aos sons adventícios descontínuos, as componentes em frequência destes extrapolam a sub-banda de frequências correspondente aos coeficientes de aproximação nível 4, sendo que esta região apresenta a intersecção dos ruídos da respiração normal com as componentes de baixa frequência das anomalias descontínuas. Desta maneira, o espectro resultante nesta sub-banda representa muito mais as componentes dos sons normais do que as representativas das anomalias descontínuas. Portanto, a aplicação do algoritmo de filtragem por análise espectral seletiva filtra grande parte dos ruídos característicos do fluxo aéreo normal juntamente com os componentes de baixa frequência dos sons adventícios descontínuos. Entretanto, como as componentes de baixa frequência desses sons adventícios possuem menor informação em relação às suas componentes de alta frequência, a sua eliminação não compromete a sua inteligibilidade. A figura 54 exemplifica o resultado da aplicação do algoritmo de filtragem por análise espectral seletiva em um ciclo respiratório contendo anomalias descontínuas.

Para o caso de ciclos respiratórios contendo sons adventícios contínuos, a metodologia proposta no algoritmo de filtragem por análise espectral seletiva apresenta dois resultados distintos, dependendo do tipo de anomalia. Os sons adventícios contínuos que possuam frequência fundamental e harmônicas acima da sub-banda coberta pelos coeficientes de aproximação nível quatro apresentam resultado muito semelhante aos encontrados nos ciclos respiratórios com anomalias descontínuas, ou seja, apresentam os ruídos resultantes do fluxo aéreo normal praticamente eliminados, restando apenas os sons adventícios. Este fato ocorre para a maioria dos sibilos e para o estridor. A figura 55 ilustra esta propriedade, apresentando o resultado da aplicação do algoritmo de filtragem por análise espectral seletiva em um ciclo respiratório com sibilos. Nos espectrogramas da figura 55b nota-se que as linhas horizontais que ocorrem entre 1,5 e 2 s, que são as figuras características do sibilo, não são atenuadas quando da aplicação do algoritmo.




(a)





(b)

Figura 53: Ciclo respiratório normal antes e após a filtragem por análise espectral seletiva. Sinais no domínio do tempo (a) e seus respectivos espectrogramas (b). Nota-se no espectrograma do sinal processado a manutenção apenas da componente espectral de maior amplitude na faixa abaixo de 250 Hz.



(a)



(b)

Figura 54: Ciclo respiratório com estertores finos processado pelo algoritmo de filtragem por análise espectral seletiva. Sinais no domínio do tempo (a) e seus respectivos espectrogramas (b). Nota-se no espectrograma do sinal processado a manutenção apenas da componente espectral de maior amplitude na faixa abaixo de 250 Hz.

Já as anomalias contínuas que se localizam na faixa espectral coberta pelos coeficientes de aproximação nível quatro, quase na sua totalidade formada pelos roncós, apresentam a sua frequência fundamental mantida pelo algoritmo proposto. Uma vez que, em todos os ciclos respiratórios testados, a frequência fundamental da anomalia contínua aparece no espectro dos coeficientes de aproximação nível 4 como a componente espectral de maior relevância, este sinal é selecionado para ser o centro da banda de passagem do filtro FIR, descrito na seção 8.2. Desta maneira, finalizado o processo de filtragem, obtém-se apenas o sinal referente à frequência fundamental do ronco nos coeficientes de aproximação nível 4. Este procedimento resulta, após a reconstrução, em um sinal de áudio com os ruídos característicos dos sons normais e eventuais sons cardíacos contaminantes bastante atenuados, ressaltando apenas a frequência fundamental do ronco. Entretanto, uma vez que o processo de filtragem mantém apenas esta frequência fundamental, este se apresenta atenuado em relação à sua amplitude original, sendo as frequências harmônicas presentes na sub-banda dos coeficientes de aproximação eliminadas. A figura 56 ilustra um ciclo respiratório com roncós antes e após a aplicação do algoritmo de filtragem por análise espectral seletiva.

8.4 RESULTADOS OBTIDOS UTILIZANDO-SE A METODOLOGIA DE FILTRAGEM POR ANÁLISE ESPECTRAL SELETIVA

A metodologia de filtragem por análise espectral seletiva foi desenvolvida visando solucionar o problema da caracterização das anomalias nos sons respiratórios, atenuando os sons referentes aos ruídos do fluxo aéreo gerados no processo de respiração e, principalmente, os sons cardíacos, que contaminam o som captado dificultando o processo de reconhecimento dos sons pulmonares adventícios. Portanto, esta metodologia gera como resultado um sinal de áudio com os sons adventícios destacados, podendo estes serem mais facilmente visualizados tanto na forma de onda do ciclo respiratório no tempo quanto em seu espectrograma. Já no caso dos sons pulmonares normais, este processamento resulta em um som muito atenuado em relação ao original, tanto para os ruídos referentes ao fluxo aéreo nas vias respiratórias quanto para os sons cardíacos contaminantes, como era de se esperar.









Figura 55: Ciclo respiratório com sibilos processado pelo algoritmo de filtragem por análise espectral seletiva. Sinais no domínio do tempo (a) e seus respectivos espectrogramas (b). Nota-se no espectrograma do sinal processado a atenuação da banda abaixo de 250 Hz e a manutenção dos sinais dos sibilos, caracterizados pelas linhas horizontais entre 1,5 e 2 s.



(a)



(b)

Figura 56: Ciclo respiratório com roncos processado pelo algoritmo de filtragem por análise espectral seletiva. Sinais no domínio do tempo (a) e seus respectivos espectrogramas (b). Nota-se que a manutenção da principal componente espectral na faixa abaixo de 250Hz preserva a frequência fundamental do ronco.

Para computação dos resultados da metodologia de filtragem por análise espectral seletiva, foi avaliado o desempenho de dez diferentes funções *wavelet* nos processos de decomposição e reconstrução, utilizando como base de análise o conjunto de 275 ciclos respiratórios disponíveis. Nos sinais resultantes da aplicação da metodologia de filtragem, foi verificada a atenuação obtida nos sons cardíacos contaminantes, nos casos em que estes ocorrem, em comparação à atenuação obtida quando da presença de roncos. Como critério quantitativo de avaliação dessa atenuação, foi utilizada a densidade de potência espectral (*Power Spectral Density*, PSD) desses sinais, avaliando a atenuação obtida na faixa espectral dos coeficientes de aproximação, conforme GNITECKI *et al.*, (2005). Para o cálculo da PSD, foram utilizadas FFTs de 4096 pontos, com função janela de Hamming.

Além dessa atenuação, avaliou-se a qualidade da reconstrução do sinal de áudio obtido no processo de reconstrução. As famílias de funções *wavelet* utilizadas nos testes foram as mesmas empregadas na avaliação da metodologia proposta para classificação automática dos sons pulmonares, apresentada na tabela 4, na seção 7.2. Para facilitar o acompanhamento, essas famílias são rerepresentadas na tabela 7.

Tabela 7 – Famílias de funções *wavelet* avaliadas.

Famílias de bases Ortonormais	Famílias Biortogonais
Daubechies 4 e 44	Biortogonal 3.7
Symlets 8 e 20	Biortogonal 3.9
Coiflet 3	Biortogonal 6.8
Aproximação discreta da <i>wavelet</i> Meyer	Biortogonal reversa 3.7

Os resultados obtidos para o caso de um ciclo respiratório contendo ronco, com frequência fundamental de aproximadamente 90 Hz, obtidos para cada uma das famílias *wavelet*, estão contidos nas figuras 58 a 67, juntamente com o sinal original, na figura 57. Nas figuras 57 a 67 nos gráficos referentes ao PSD dos sinais, com índice (c), as barras vermelhas delimitam a região espectral de atuação do algoritmo e o círculo vermelho indica a distribuição espectral do sinal do ronco. A região espectral específica do ronco foi utilizada como parâmetro para cálculo da atenuação deste sinal. Neste som respiratório, não há informações sobre o paciente.

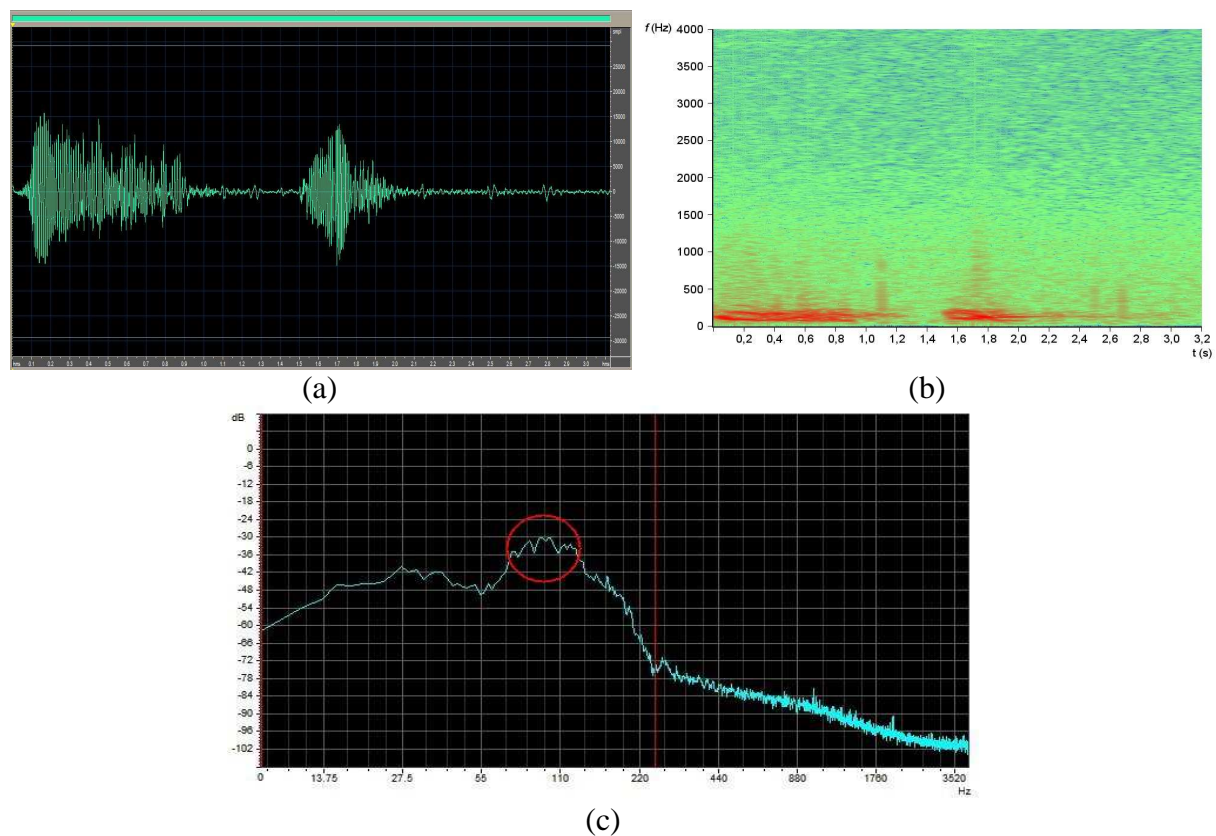


Figura 57: Sinal original de um ciclo respiratório contendo roncos. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

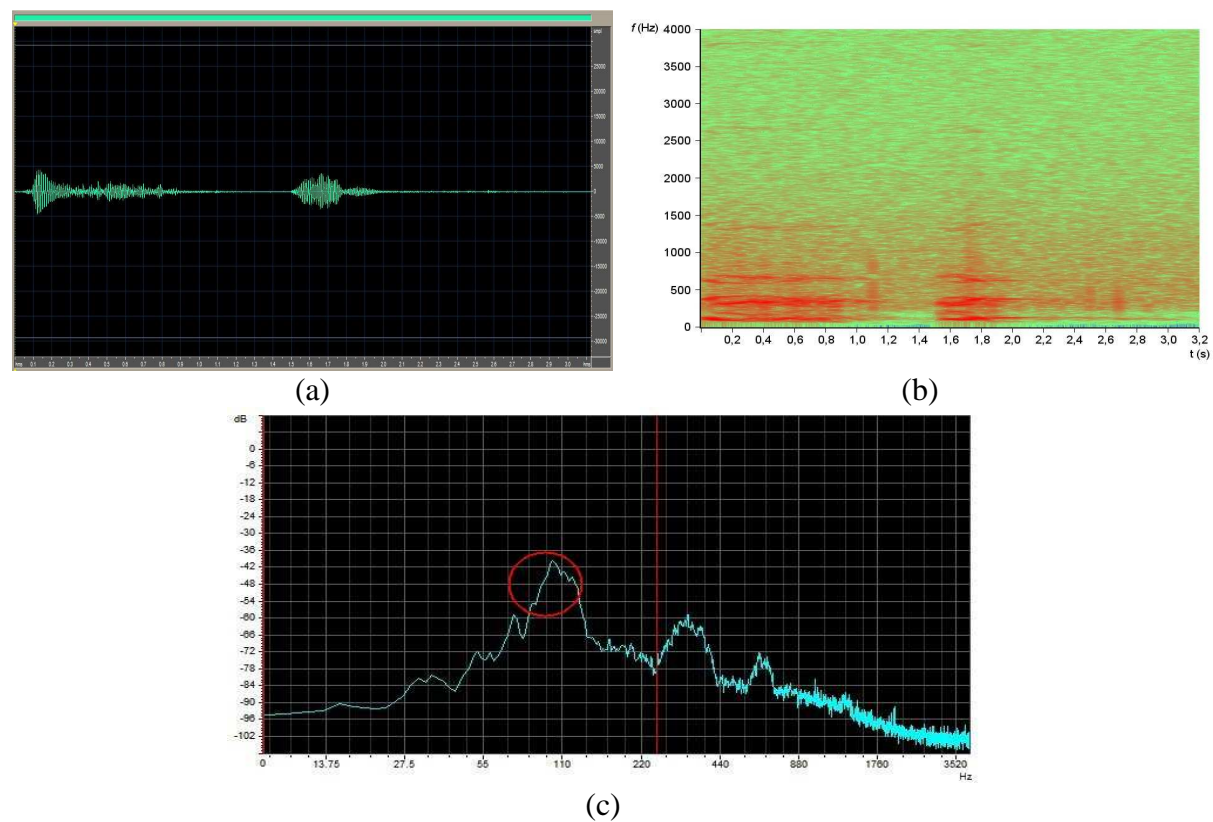


Figura 58: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 57, utilizando a *wavelet* Coiflet 3. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

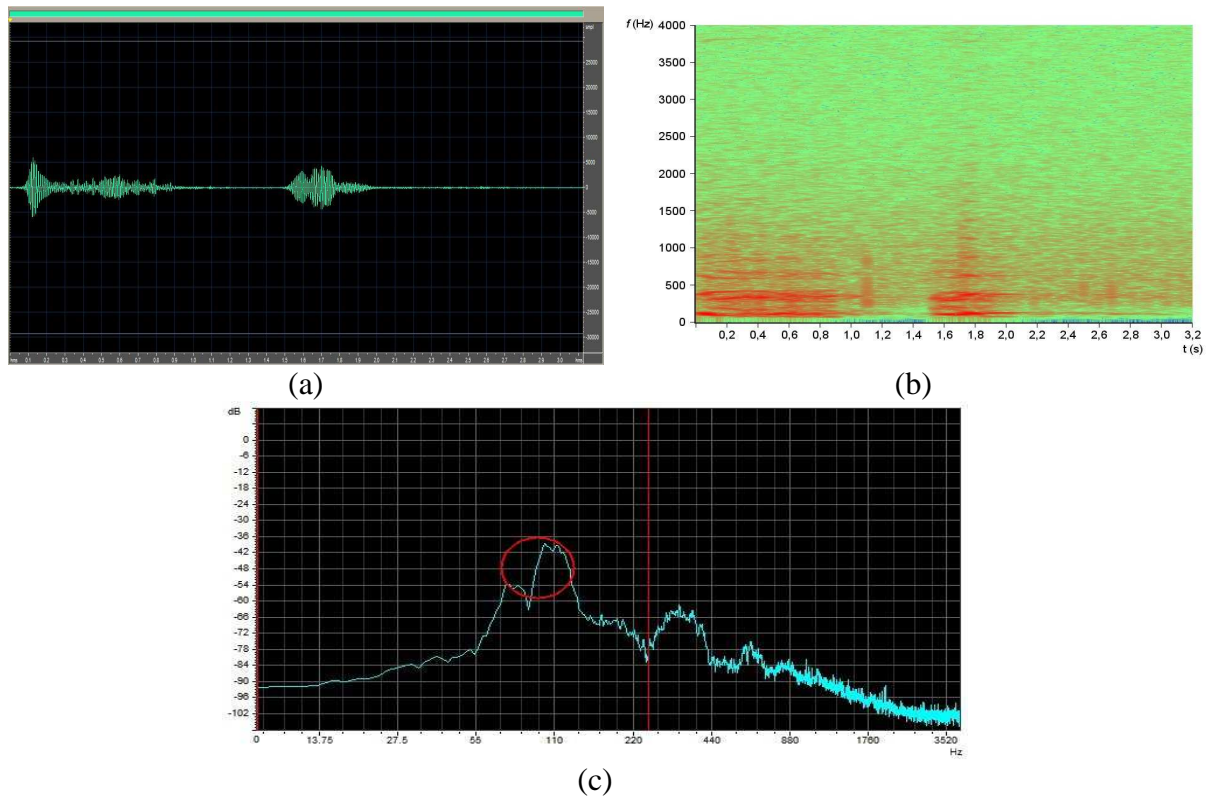


Figura 59: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 57, utilizando a *wavelet* Biortogonal 3.7. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

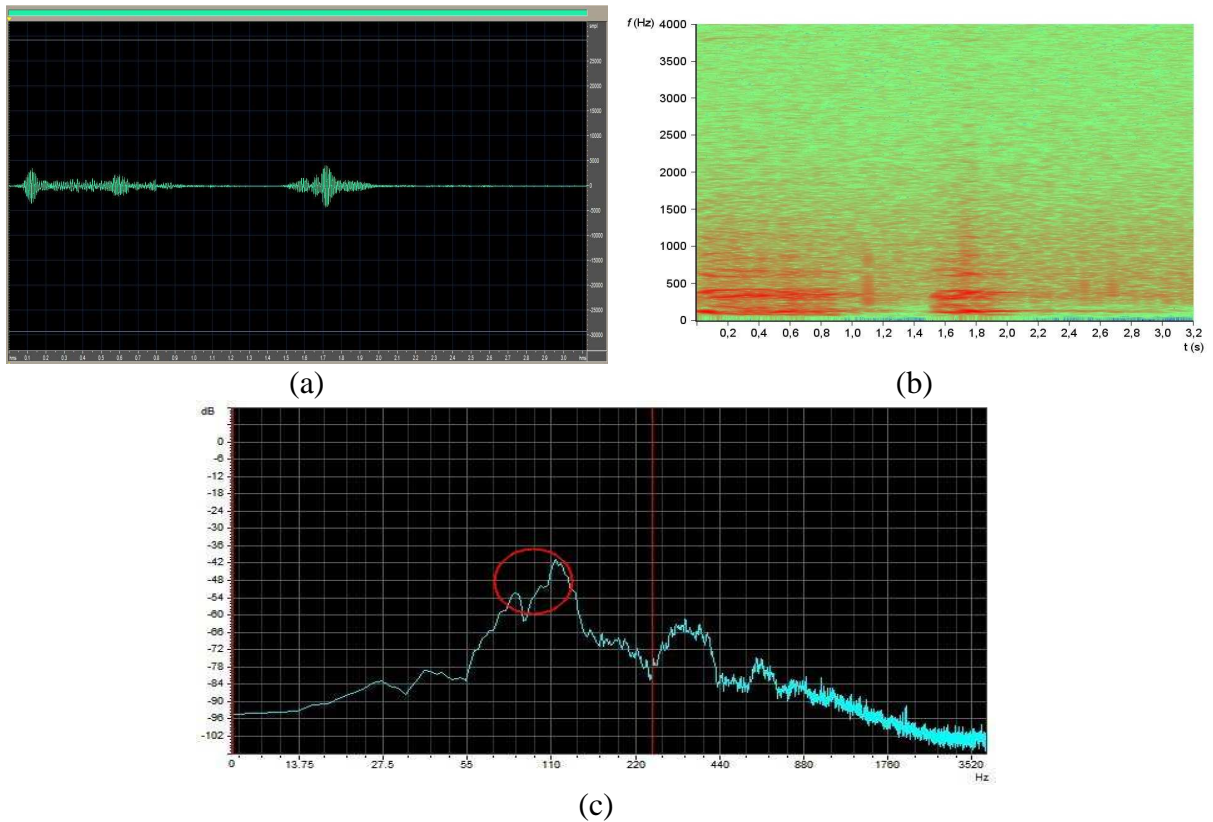


Figura 60: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 57, utilizando a *wavelet* Biortogonal 3.9. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

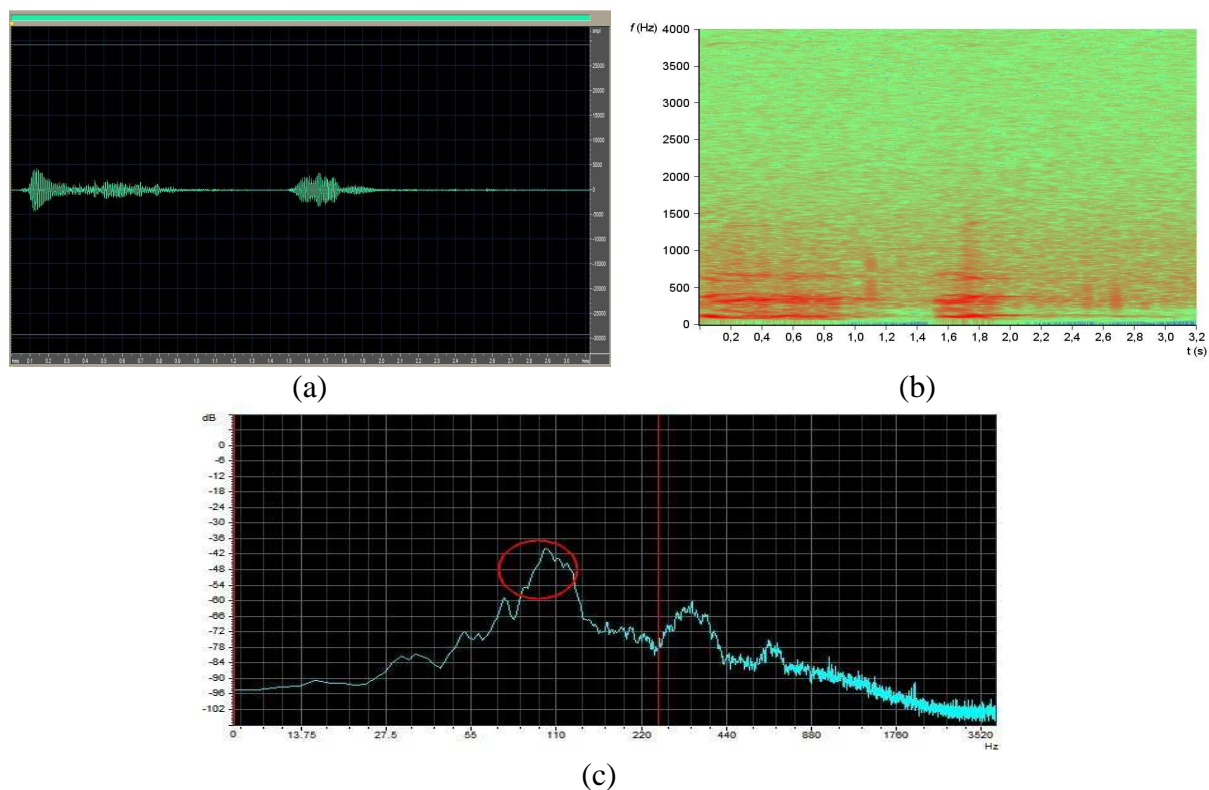


Figura 61: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 57, utilizando a *wavelet* Biortogonal 6.8. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

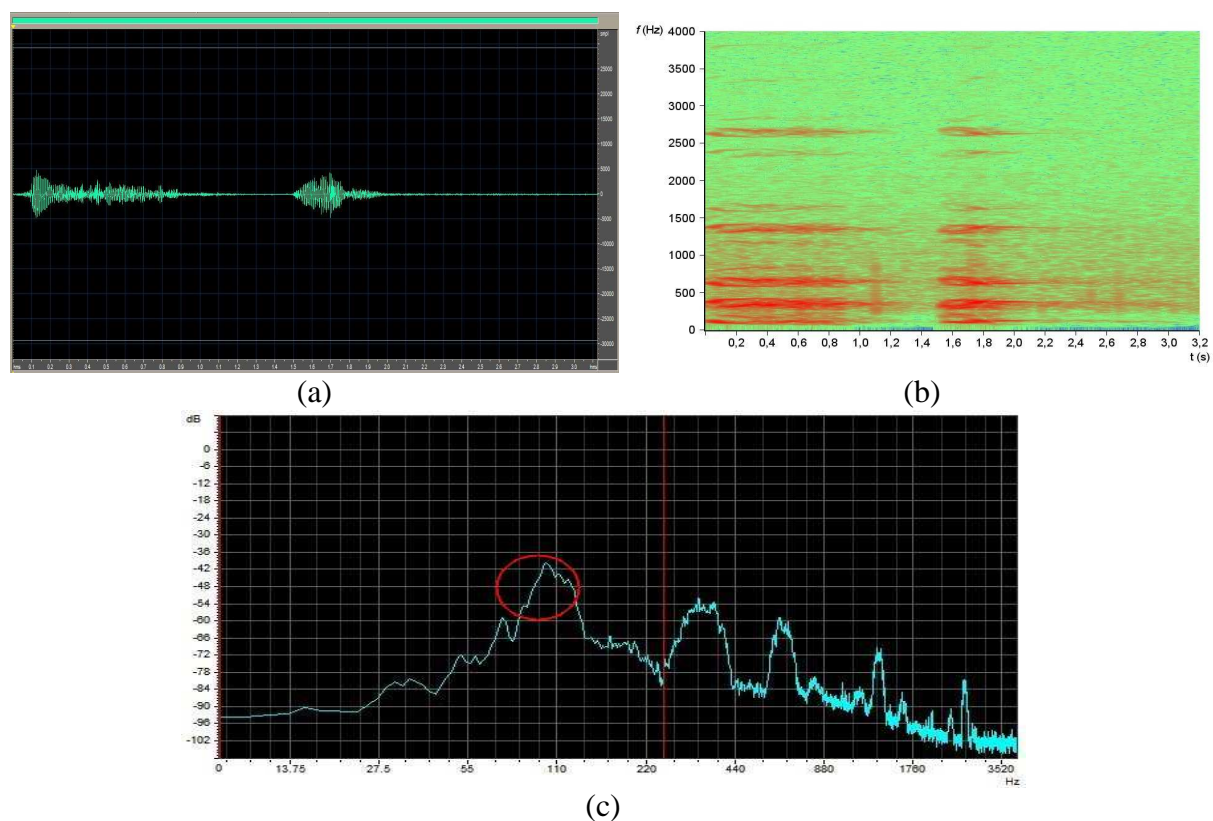


Figura 62: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 57, utilizando a *wavelet* Biortogonal Reversa 3.7. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

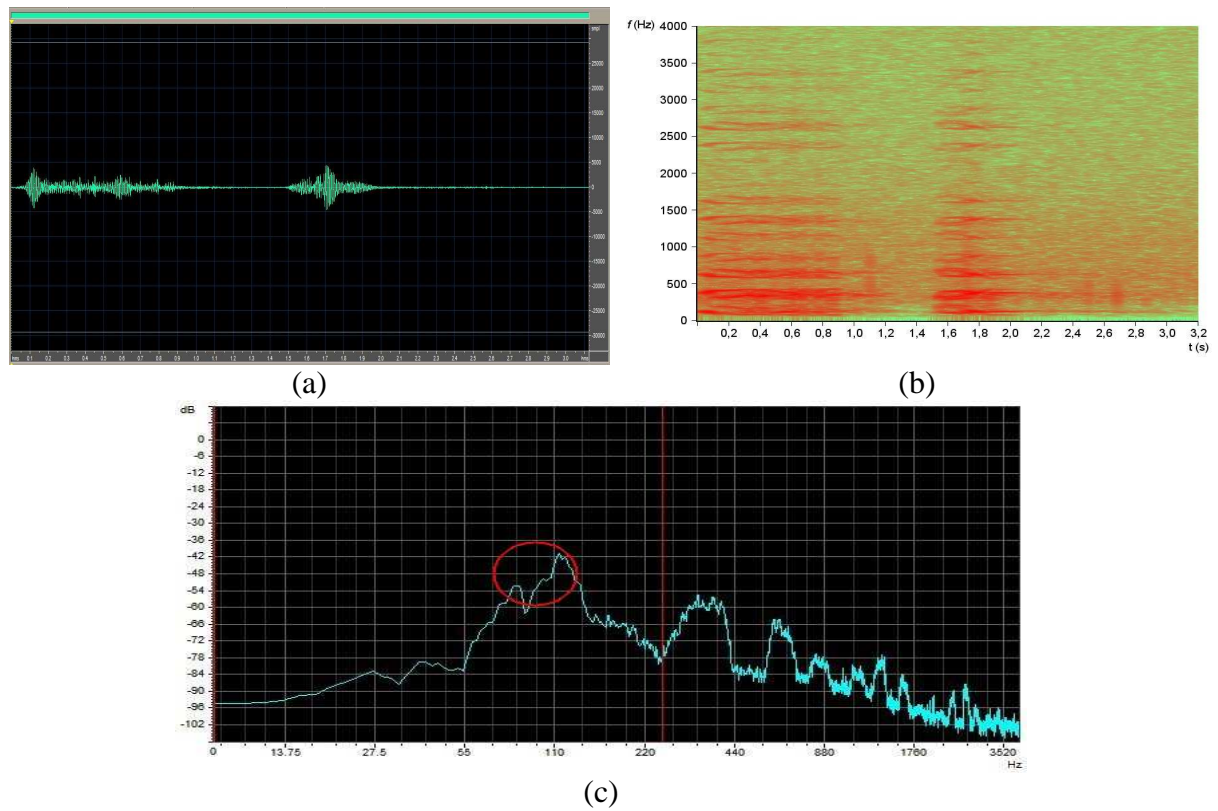


Figura 63: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 57, utilizando a *wavelet* Daubechies 4. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

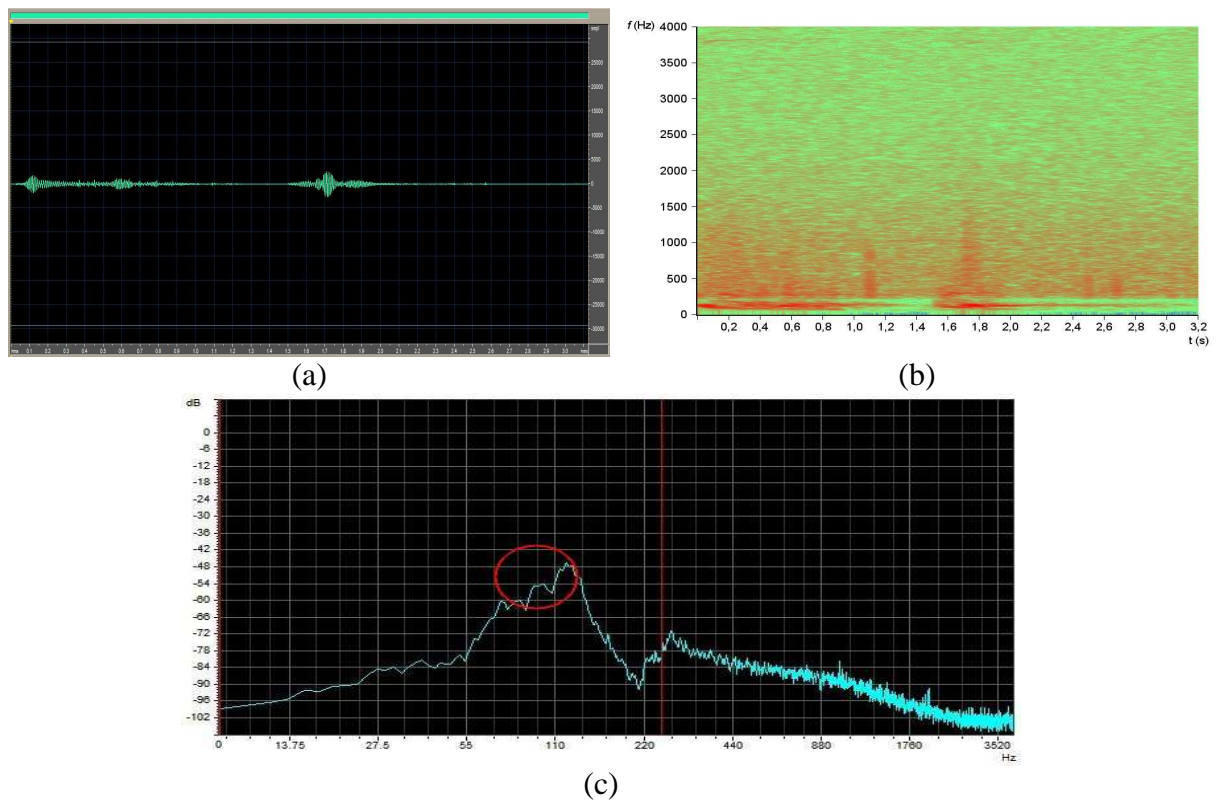


Figura 64: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 57, utilizando a *wavelet* Daubechies 44. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

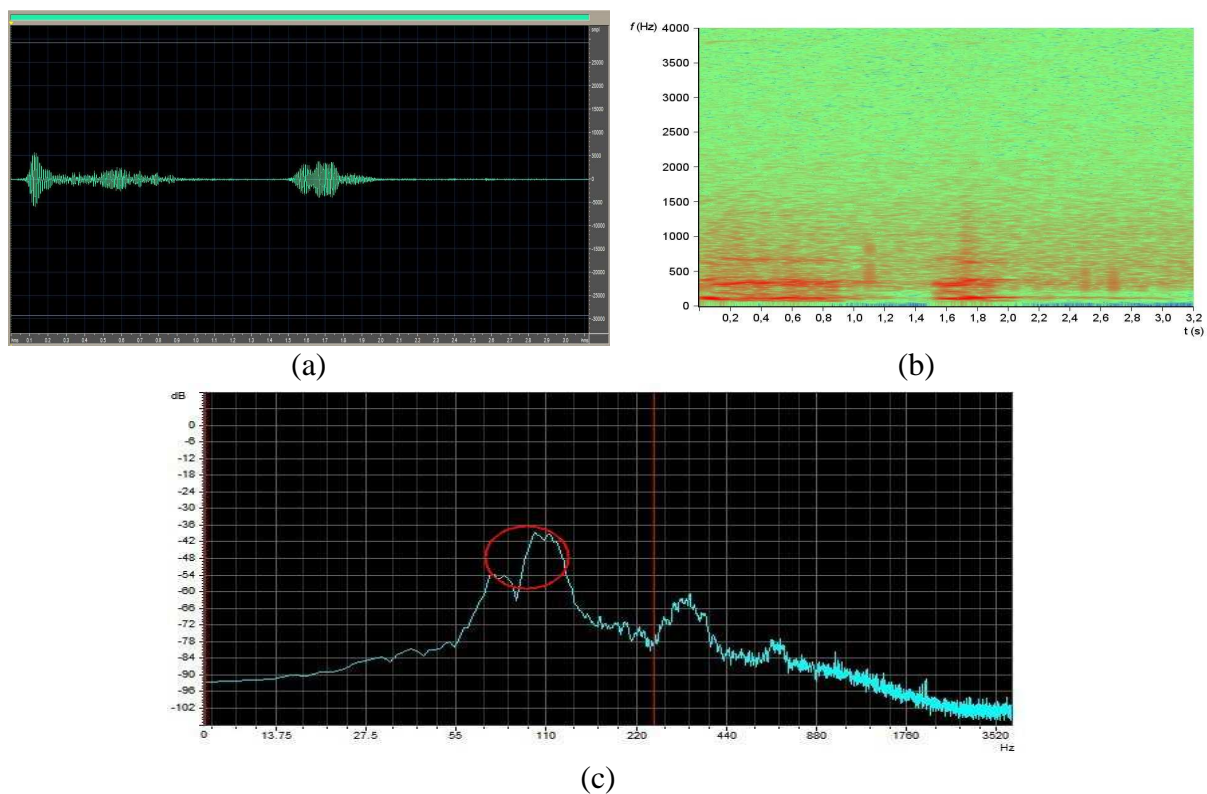


Figura 65: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 57, utilizando a *wavelet* Symlet 8. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

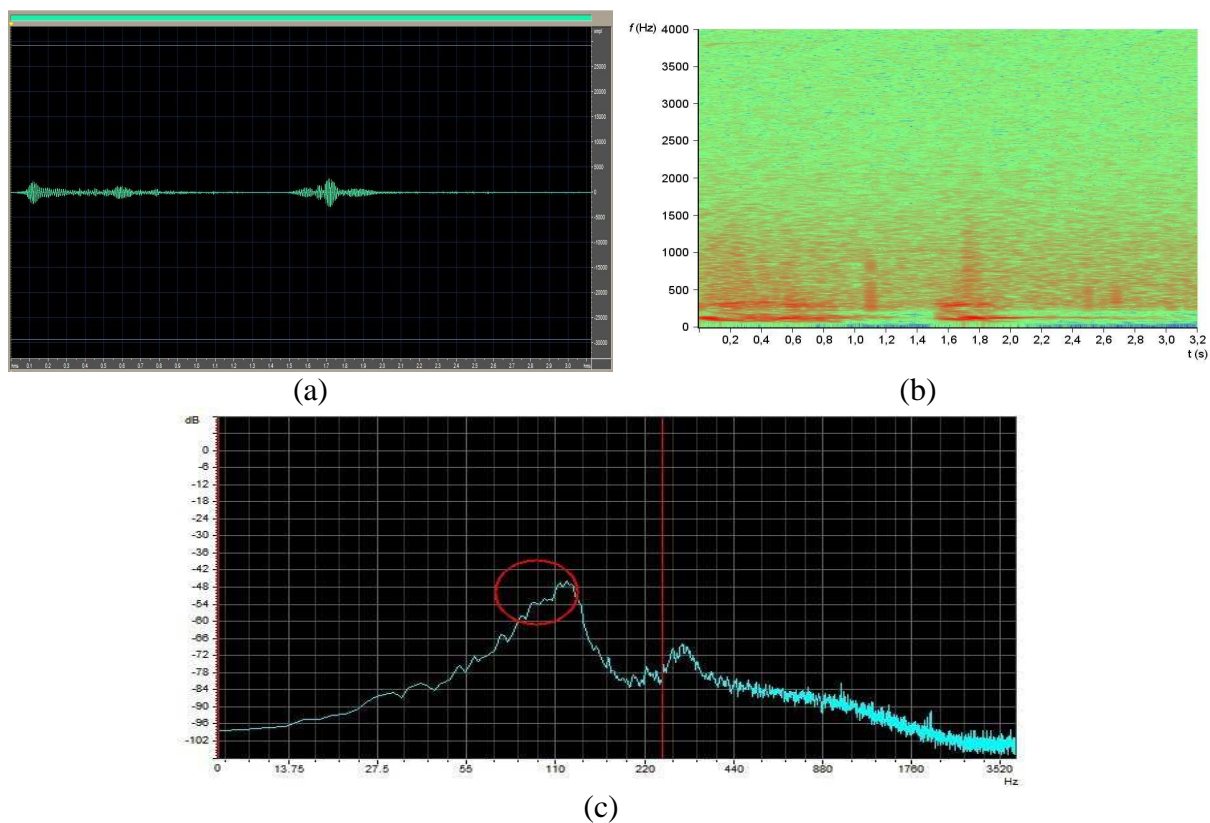


Figura 66: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 57, utilizando a *wavelet* Symlet 20. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

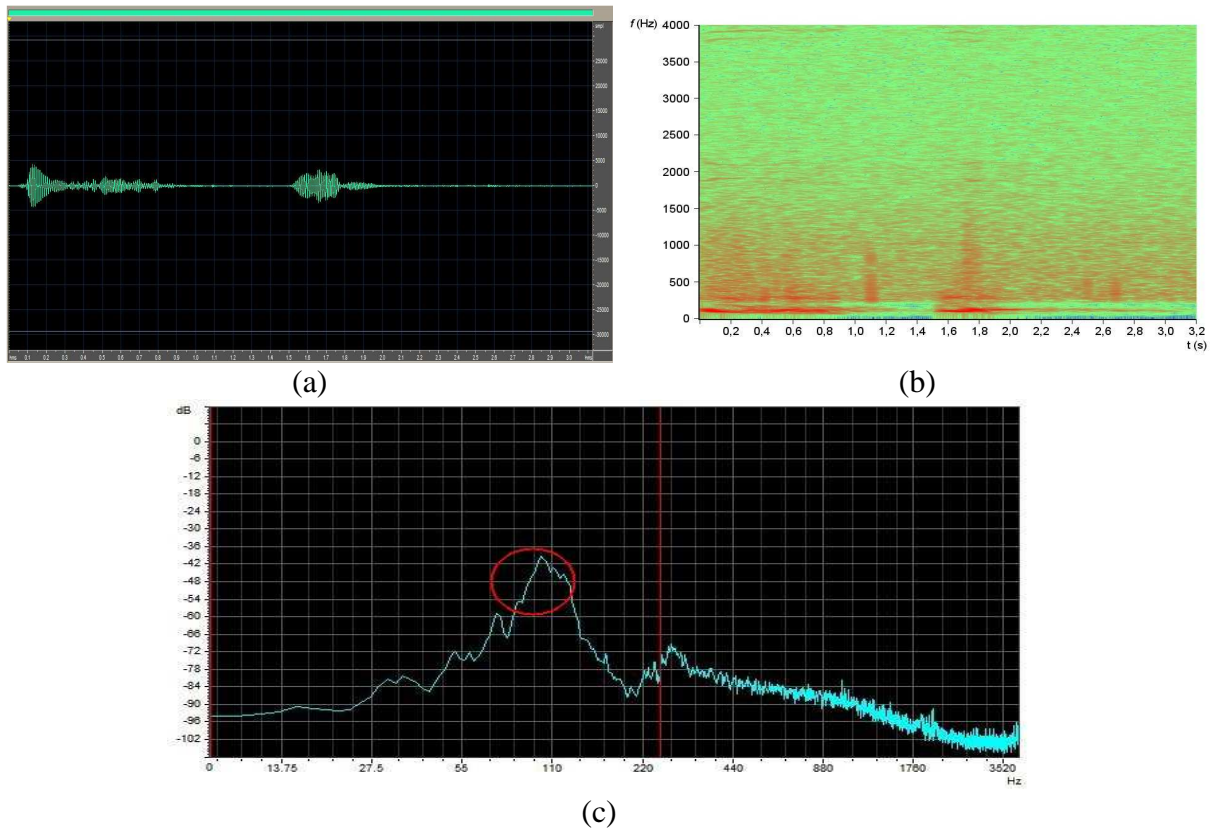


Figura 67: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 57, utilizando a aproximação discreta da *wavelet* Meyer. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

As figuras 69 a 78 apresentam os resultados obtidos para o caso de um ciclo respiratório contendo estertores grossos inspiratórios e sibilos na expiração, com grande contaminação por sons cardíacos, para cada uma das famílias *wavelet* ensaiadas. O sinal original do som pulmonar é apresentado na figura 68. Assim como nas figuras 57 a 67, nas figuras 69 a 78, os gráficos referentes ao PSD dos sinais, com índice (c), as barras vermelhas delimitam a região espectral de atuação do algoritmo e o círculo vermelho indica a distribuição espectral dos sons cardíacos. A região espectral específica desses sons foi utilizada como parâmetro para cálculo da atenuação deste sinal. Neste som também não há informações sobre o paciente.

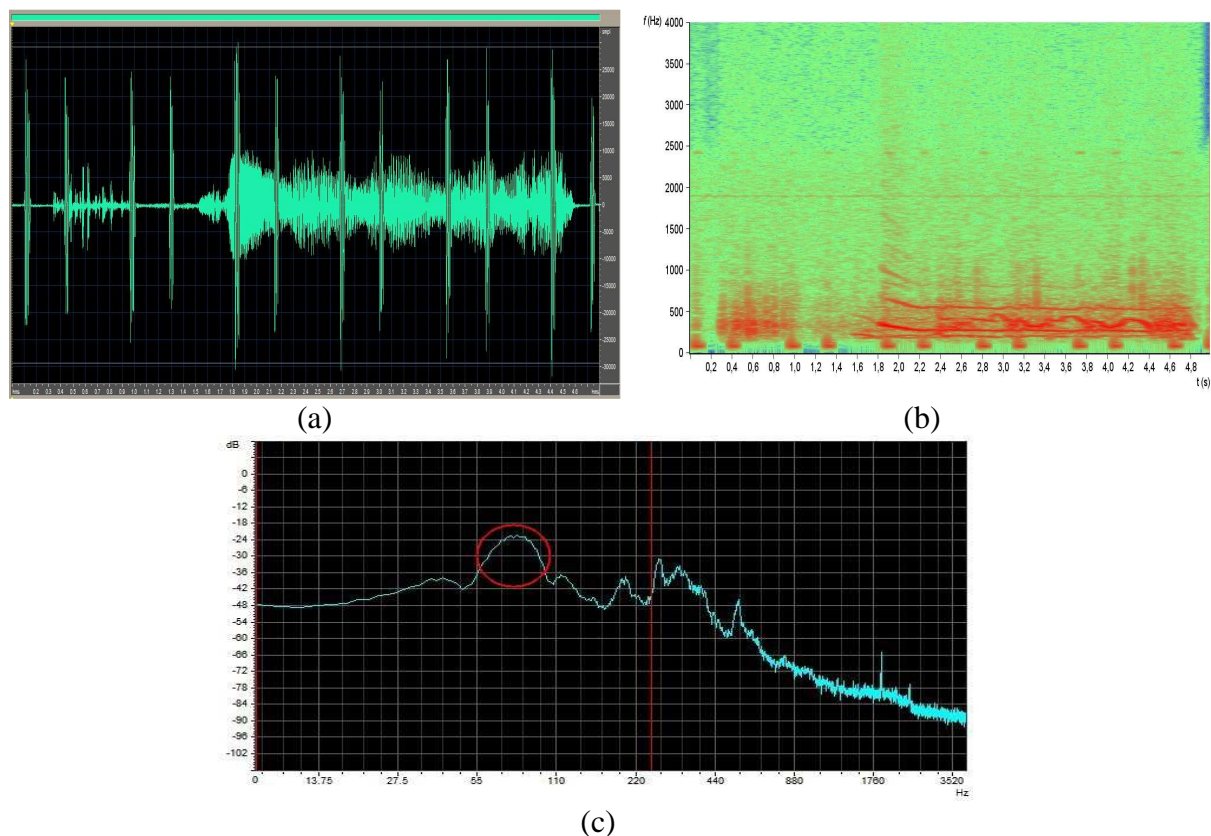


Figura 68: Sinal original de um ciclo respiratório contendo estertores grossos inspiratórios e sibilos na expiração, com forte contaminação por sons cardíacos. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

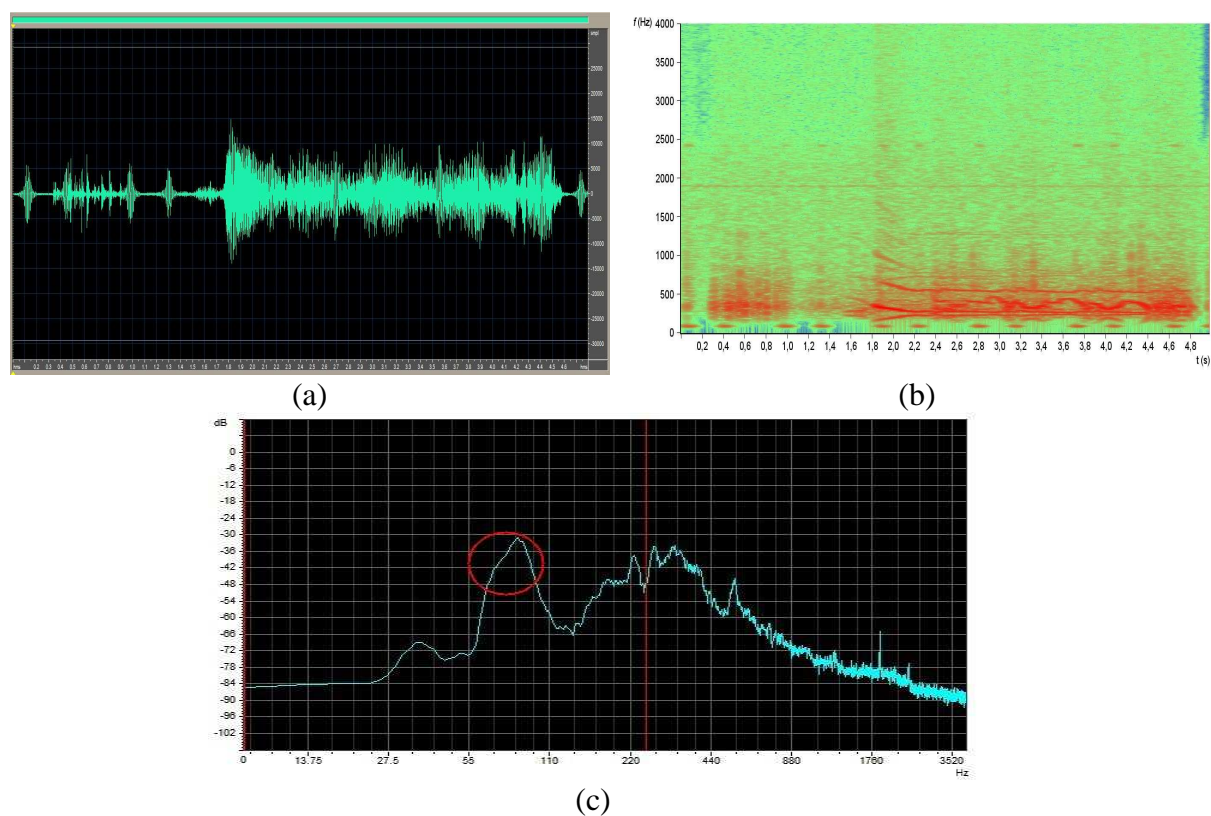


Figura 69: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 68, utilizando a *wavelet* Coiflet 3. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

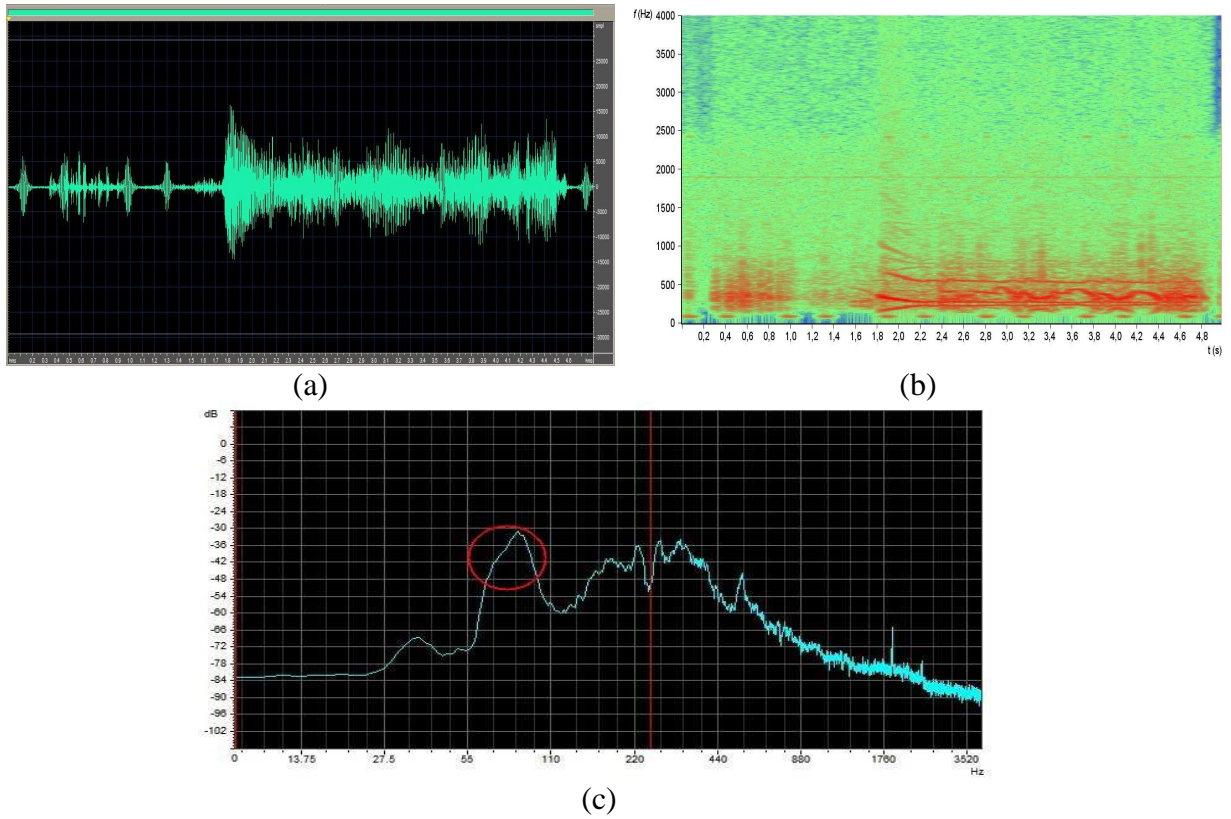


Figura 70: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 68, utilizando a *wavelet* Biortogonal 3.7. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

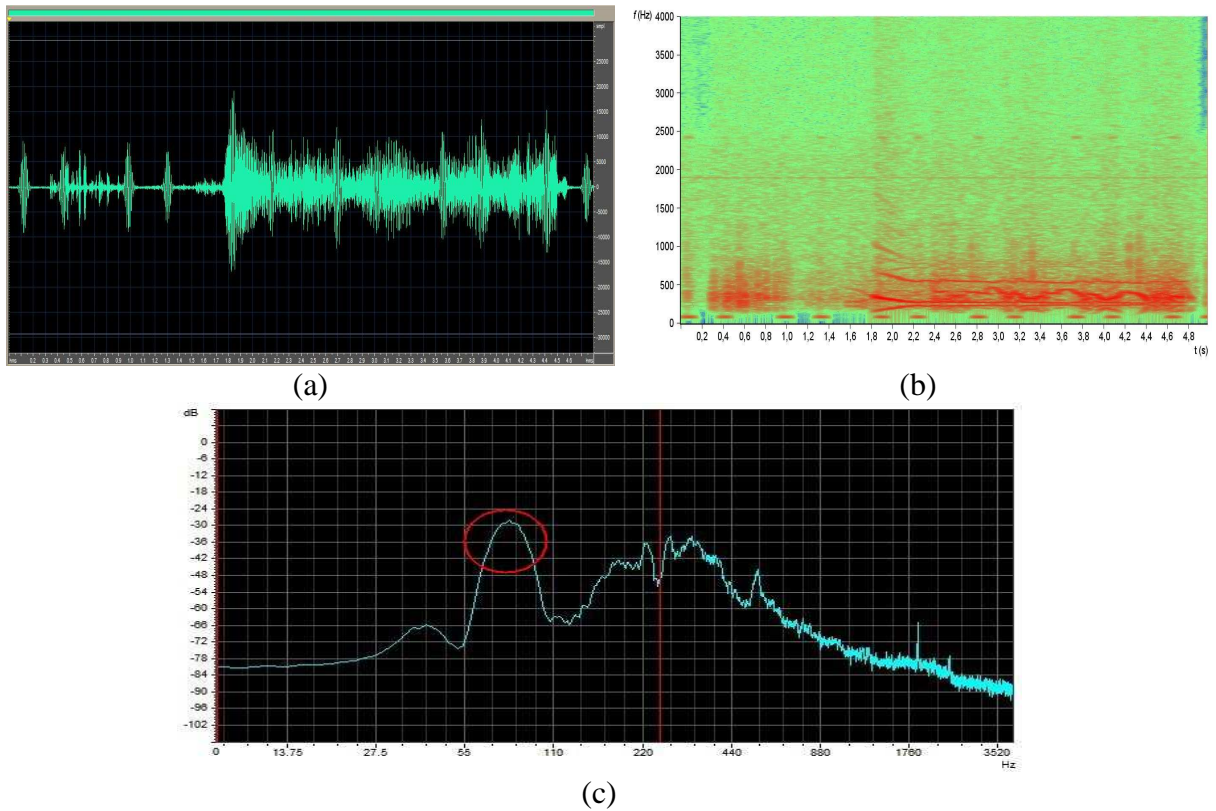


Figura 71: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 68, utilizando a *wavelet* Biortogonal 3.9. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

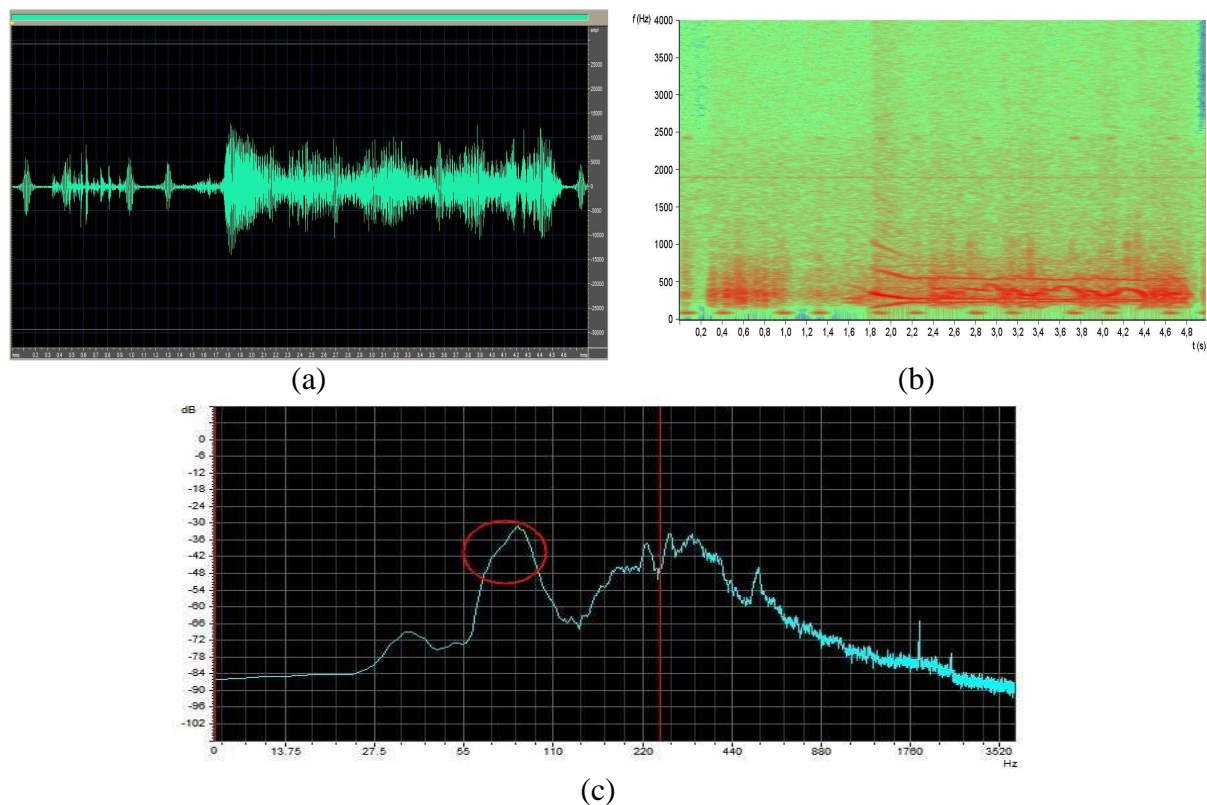


Figura 72: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 68, utilizando a *wavelet* Biortogonal 6.8. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

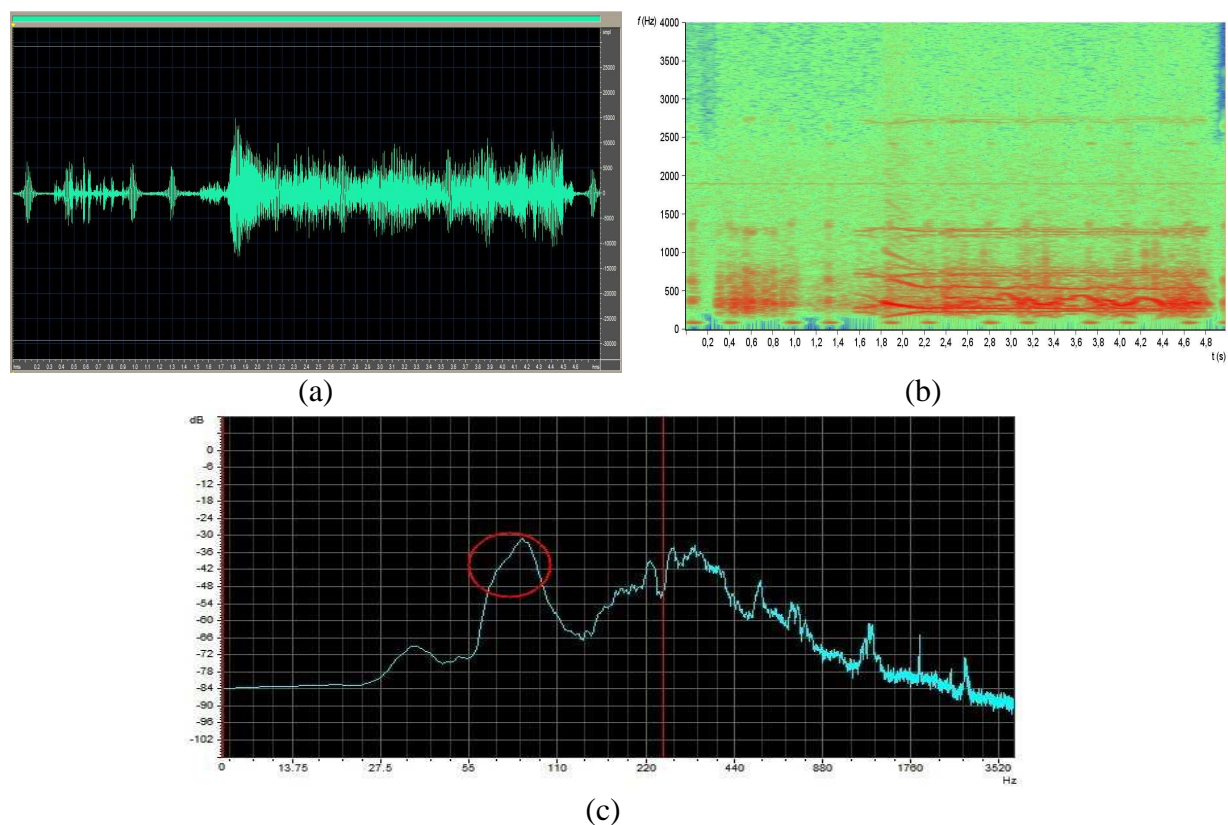


Figura 73: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 68, utilizando a *wavelet* Biortogonal Reversa 3.7. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

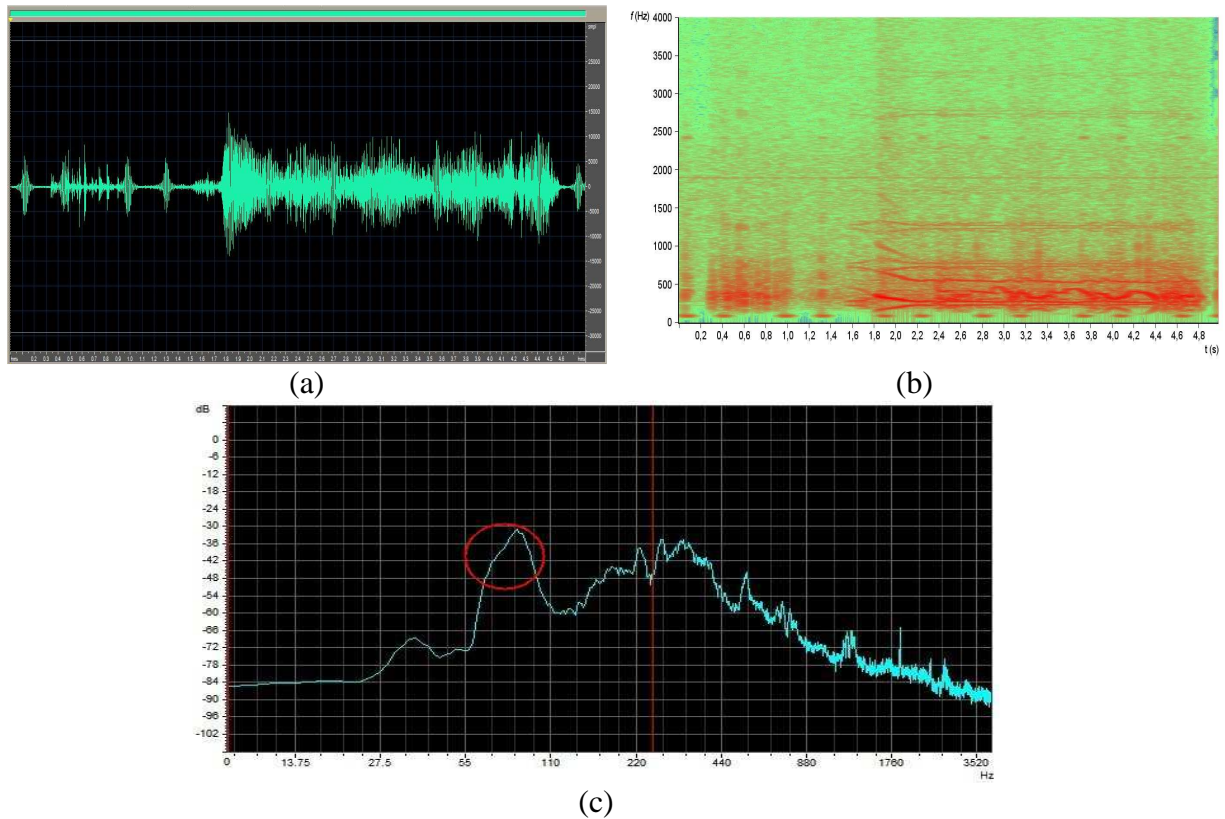


Figura 74: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 68, utilizando a *wavelet* Daubechies 4. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

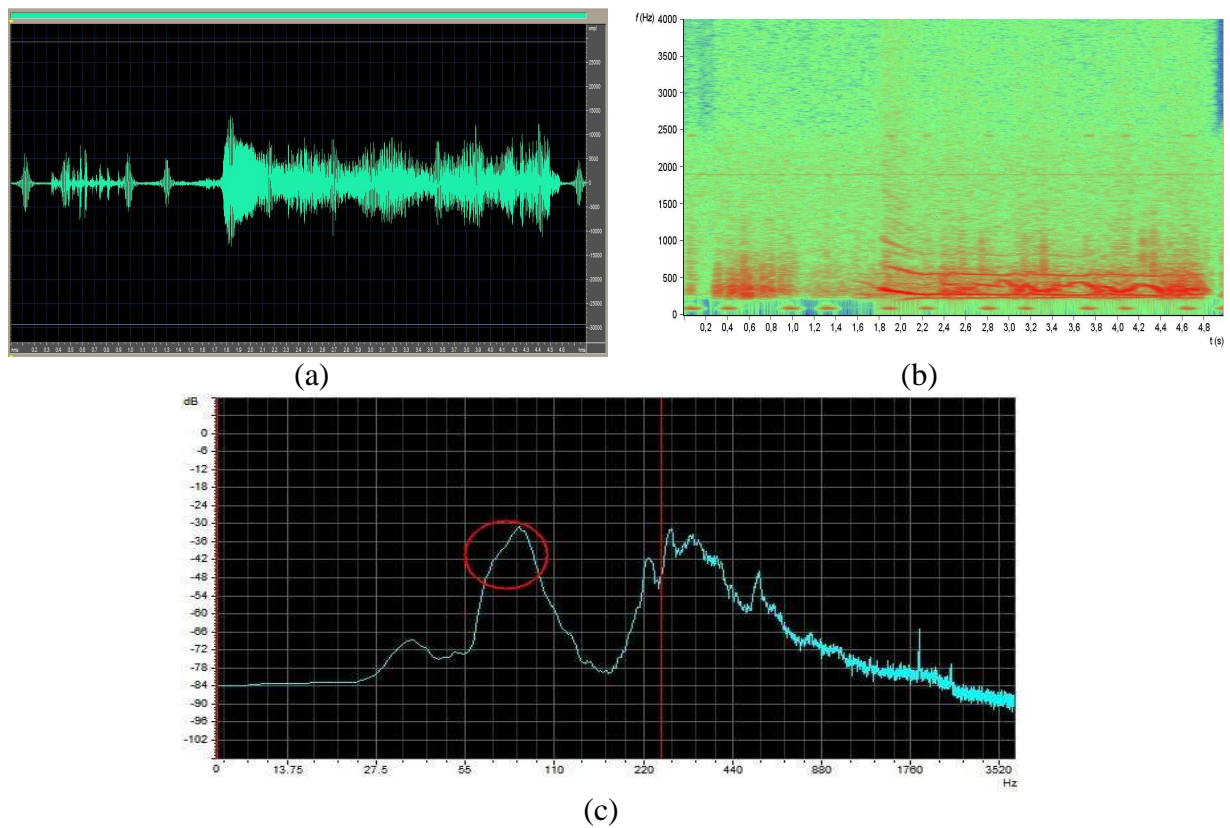


Figura 75: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 68, utilizando a *wavelet* Daubechies 44. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

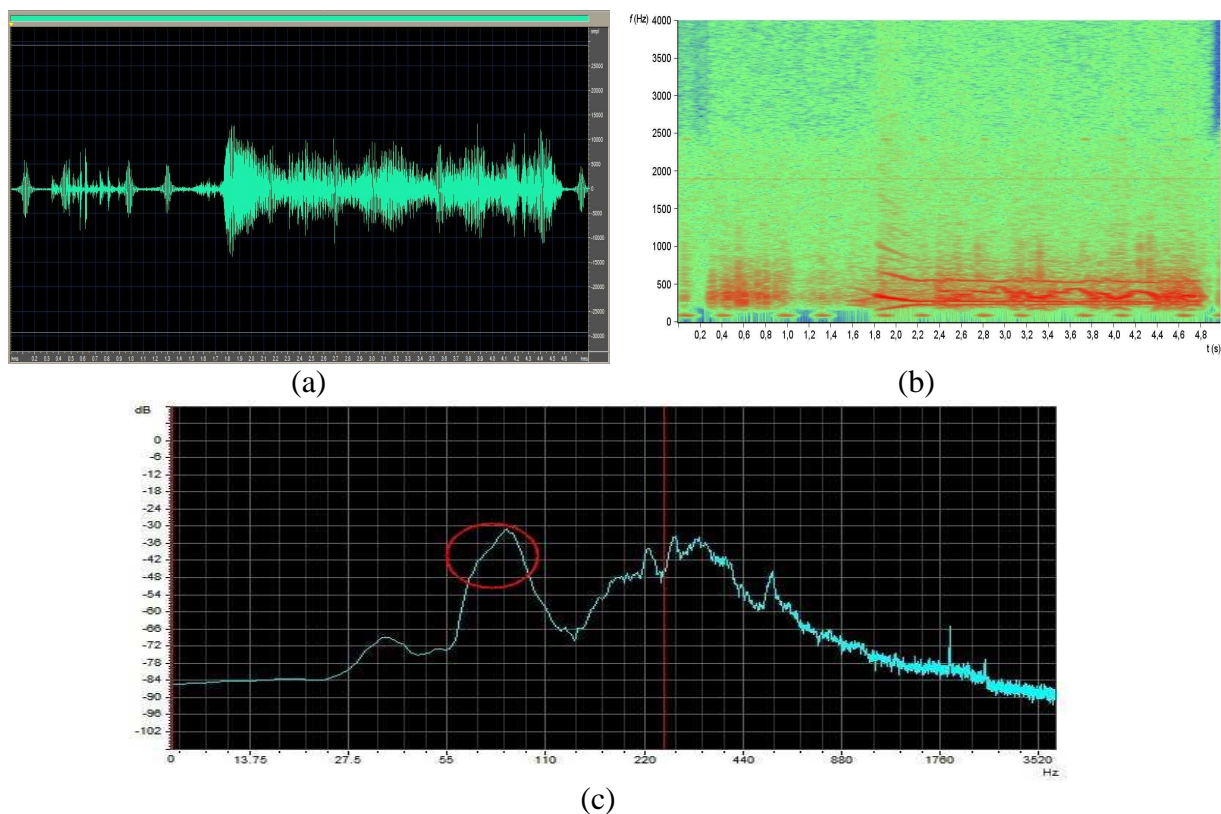


Figura 76: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 68, utilizando a *wavelet* Symlet 8. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

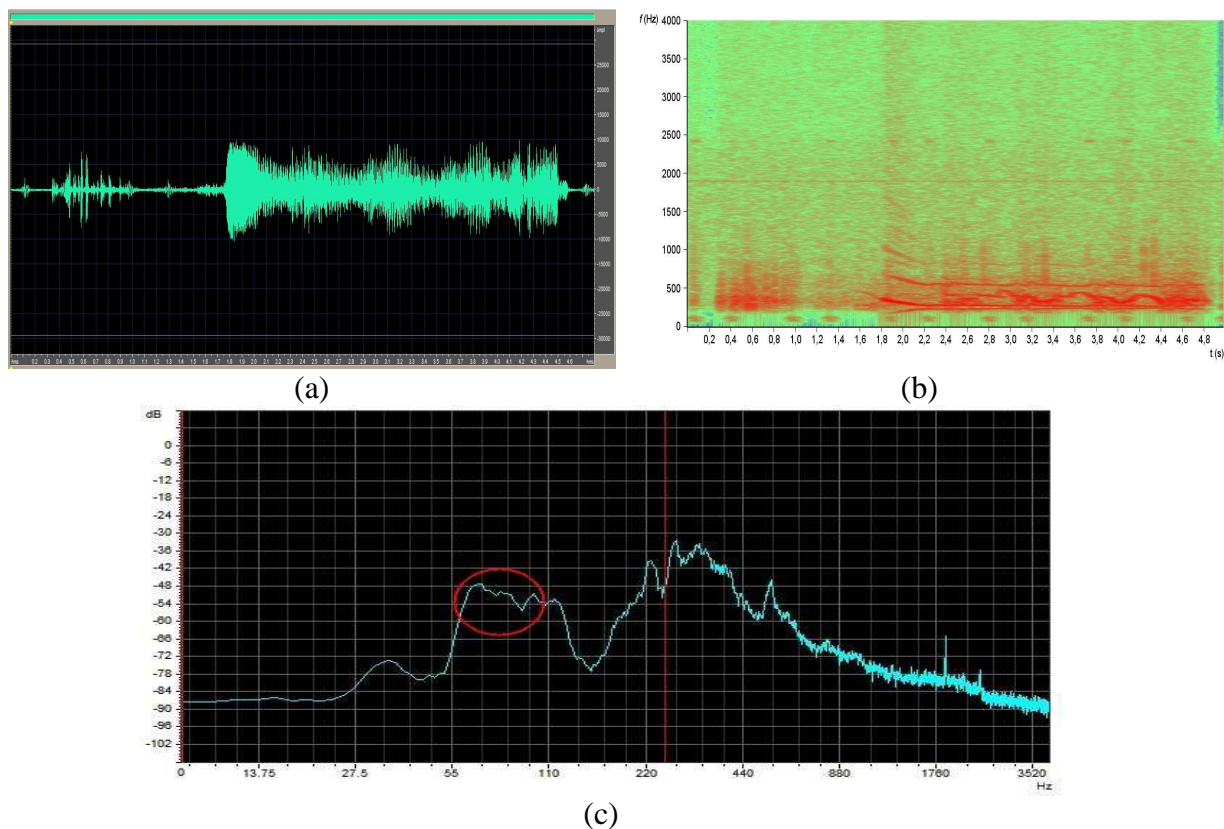


Figura 77: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 68, utilizando a *wavelet* Symlet 20. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

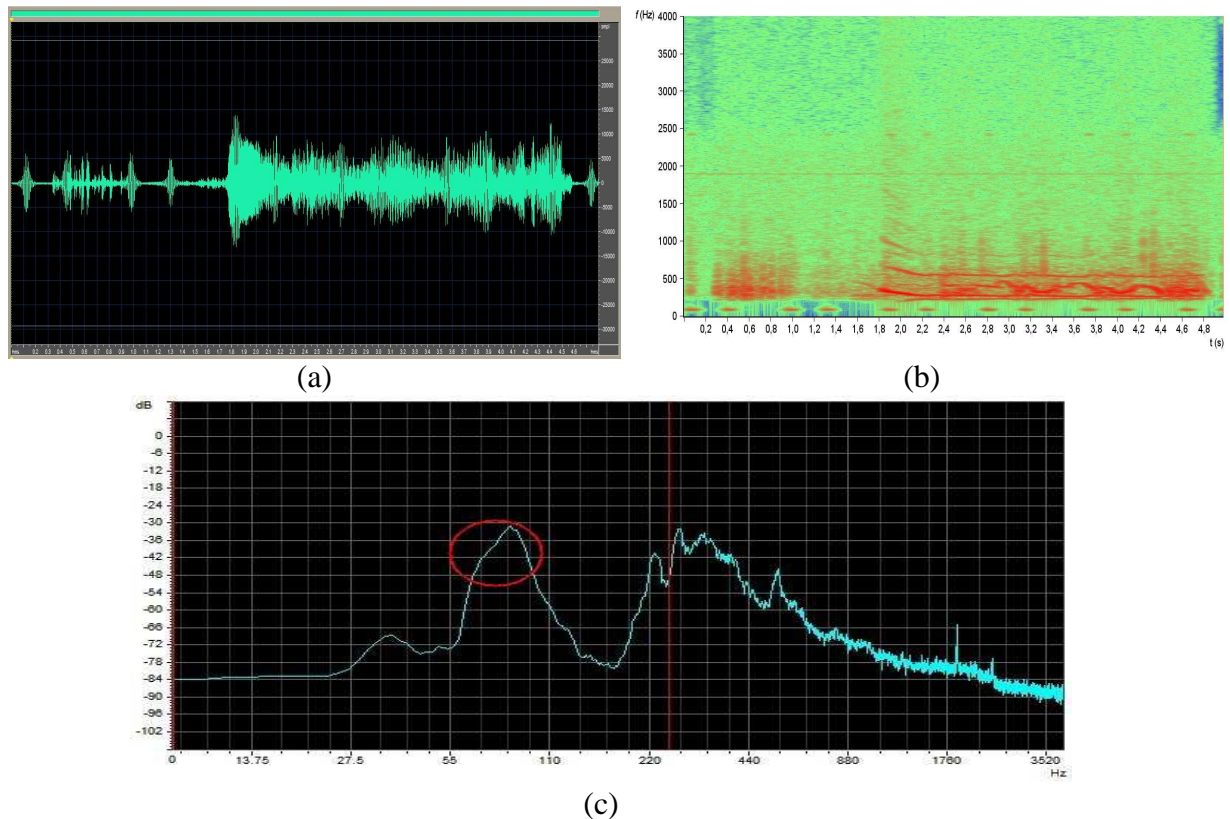


Figura 78: Resultado da filtragem por análise espectral seletiva do ciclo respiratório da figura 68, utilizando a aproximação discreta da *wavelet* Meyer. Sinal no domínio do tempo (a), espectrograma (b) e PSD (c).

De forma quantitativa, os níveis de atenuação obtidos na medição do PSD dos sons contidos na faixa espectral de abrangência dos coeficientes de aproximação nível 4, compreendida entre 0 e 250 Hz, para as diferentes famílias de funções *wavelet*, estão contidas na tabela 8. Uma vez que sibilos podem ocorrer na faixa superior desta sub-banda de frequências, a sua atenuação também foi medida, sendo seus valores de atenuação também apresentados nesta tabela.

Tabela 8 – Atenuação medida, em função da *wavelet* empregada.

Função Wavelet	Atenuação média dos Roncos (dB)	Atenuação média dos sons Cardíacos (dB)	Atenuação dos Sibilos (dB)
Biortogonal 3.7	9	9	≤ 5
Biortogonal 3.9	11	10	≤ 3
Biortogonal 6.8	11	13	≤ 2
Coiflet 3	12	13	≤ 3
Daubechies 4	13	12	≤ 4
Daubechies 44	18	21	≤ 1
Meyer Discreta	11	14	≤ 1
Biortogonal Reversa 3.7	11	10	≤ 4
Symlet 8	10	13	≤ 3
Symlet 20	16	22	≤ 1

CAPÍTULO 9

DISCUSSÃO

Neste capítulo, discutem-se os resultados obtidos e o desempenho das técnicas desenvolvidas frente aos objetivos propostos no início deste trabalho. Assim, são analisadas as técnicas de classificação dos sons pulmonares e de filtragem por análise espectral seletiva, apresentadas como inovadoras, uma vez que apenas estas geraram um conjunto de resultados suficientemente sólidos para serem passíveis de avaliação.

Deve-se ressaltar que entre os grupos de sons respiratórios considerados normais, utilizados para testes, foram excluídos os sons obtidos por ausculta na região traqueal, tanto para os testes da metodologia de obtenção das curvas de energia pelo nível de decomposição *wavelet* quanto para a filtragem por análise espectral seletiva. Isto ocorreu devido às características intrínsecas desse tipo de som respiratório. Durante o processo de aquisição dos sons traqueais, encosta-se a campânula do estetoscópio diretamente na região traqueal, conforme visto na figura 8. Contudo, como nesta região de ausculta a membrana do estetoscópio apresenta uma proximidade maior do duto aerífero em relação aos outros pontos de ausculta, ocorre uma maior amplificação dos ruídos relativos ao fluxo de ar, presentes nos sons respiratórios normais. Esta maior amplificação afeta tanto a distribuição da energia nos níveis de decomposição *wavelet* quanto a região espectral de abrangência do algoritmo de filtragem por análise espectral seletiva, sendo necessário um estudo específico da aplicação dessas metodologias para tal tipo de som respiratório. Entretanto, este não foi realizado devido ao pequeno número de ciclos respiratórios gravados na região traqueal disponíveis para análise, totalizando apenas quatro.

No início desta pesquisa, foi realizada uma análise da utilização de espectrogramas, da CWT e da DWT nos processos de caracterização e geração de dados para classificação dos diferentes sons pulmonares, normais e adventícios. Conforme apresentado nas subseções 6.2.5 e 6.3.4, as duas primeiras técnicas de análise espectral não apresentaram resultados que indicassem uma clara distinção entre os diferentes tipos de sons adventícios, sendo preteridas pelo uso da DWT, que serviu como base para as duas metodologias propostas nesta tese.

9.1 AVALIAÇÃO DA CLASSIFICAÇÃO DOS SONS PULMONARES ATRAVÉS DA DWT E REDES NEURAIS RBF

A técnica de classificação dos diferentes sons adventícios presentes nos sons pulmonares, descrita no Capítulo 7, foi desenvolvida utilizando as propriedades espectrais intrínsecas desses diferentes tipos de sons, e o impacto que a sua presença causa nas diferentes sub-bandas de frequência, obtidas a partir da decomposição *wavelet* do ciclo respiratório. Portanto, para análise dos resultados obtidos na aplicação desta técnica, utilizaram-se dois enfoques: um qualitativo, baseado na análise visual das curvas obtidas e um quantitativo, baseado na aplicação das simulações de redes neurais RBF na classificação automática dos sons pulmonares e análise dos seus índices de acerto, considerando cada uma das famílias de *wavelets* testadas.

Inicialmente, em uma análise qualitativa, verifica-se que os gráficos da variação da distribuição da energia nos níveis de decomposição *wavelet* para os diferentes tipos de sons adventícios presentes nos ciclos respiratórios, apresentados na seção 7.2, representam uma notável distinção em sua distribuição para os diferentes grupos de anomalias. Essa distinção mostra uma boa repetitividade para os valores de energia dos níveis de decomposição a partir do terceiro nível. Este fato pode ser notado pela estabilidade e gradual decaimento do desvio padrão encontrado para a energia contida nos coeficientes detalhe desses níveis, propriedade que motivou o desenvolvimento desta técnica. Assim, a própria análise visual das curvas de energia pelo nível de decomposição *wavelet* por si só já pode ser utilizada como um indicativo da presença e grupo de som adventício presente no ciclo respiratório. Entretanto, apenas o procedimento de análise visual dessas curvas ainda mantém a desvantagem da necessidade de treinamento dos profissionais de saúde, não acostumados a utilizar tais técnicas. Desta forma, não se recomenda a utilização da análise visual dessas curvas como um procedimento a ser utilizado em prática clínica, mas sim empregá-las como fonte de dados para o reconhecimento automático, conforme implementado na complementação desta técnica, gerando um indicativo automático.

Quantitativamente, na análise conjunta dos resultados obtidos na tarefa de classificação automática frente às diferentes famílias *wavelet*, verifica-se que os índices de acerto na classificação apresentaram uma curva bastante similar entre as diferentes famílias, estabilizando o índice de acerto no reconhecimento na faixa entre 70 a 90% para praticamente todas as famílias *wavelet* ensaiadas, a partir da abertura 19 da função de base radial das redes

neurais. Esta curva, apresentada na figura 49 da seção 7.4, indica que não se pode afirmar que, entre o conjunto de famílias *wavelet* testadas, existam variações significativas que apontem uma grande vantagem da utilização de uma função *wavelet* específica, uma vez que a diferença no índice de acerto entre a pior e a melhor família apresentou-se como apenas 4,36%, conforme a tabela 5.

Analisando-se quantitativamente os resultados apresentados pela técnica como um todo, unindo o processamento através do cálculo da energia nos dez primeiros níveis de decomposição *wavelet* juntamente com a classificação através do uso de uma simulação de rede neural RBF, constata-se que esta apresenta resultados significativamente sólidos para justificar a sua utilização como técnica de classificação automática dos sons pulmonares. Esta afirmação baseia-se principalmente nos índices de acerto obtidos na generalização das redes, atingindo 92,36% para o uso da *wavelet* Biortogonal 6.8, para as aberturas 22, 25 e 26 da função de base radial. Além dos resultados obtidos, a utilização de simulações de redes neurais artificiais RBF na técnica proposta apresenta a vantagem de possibilitar o rápido re-treinamento da rede em caso de erros, fato não possível para o caso do uso de redes MLP. Assim, a técnica proposta possibilita, além da classificação automática a partir dos dados treinados, a interação com o usuário desta metodologia, possibilitando a atualização dinâmica do sistema de classificação.

Na literatura, encontram-se várias abordagens para a detecção e classificação de sons pulmonares. Inúmeros trabalhos focalizam a detecção de sons adventícios específicos, como em DU *et al.* (1997); KAHYA, GÜLER e SAHIN (1997); MASTOROCOSTAS *et al.* (2000); HADJILEONTIADIS (2003), que apresentaram diferentes metodologias para a classificação, mas apenas das anomalias descontínuas presentes em sons pulmonares.

Neste contexto, DU *et al.* (1997), propõem uma técnica utilizando um modelo de um estertor como função *wavelet*, através da transformada *wavelet* contínua, para a detecção de estertores no ciclo respiratório, apresentando índice de detecção de 99,8% sem, entretanto, gerar uma classificação automática. KAHYA, GÜLER e SAHIN (1997), realizam subdivisões do ciclo respiratório para análise, modelos auto-regressivos para o modelamento dos estertores e três estágios de classificação para a detecção de estertores no ciclo respiratório. Esta metodologia resultou em um índice de classificação da ordem de 70%. Já MASTOROCOSTAS *et al.* (2000), desenvolveram uma técnica baseada em um filtro ortogonal *fuzzy* para análise em tempo real dos estertores, apresentando índices de acerto na classificação entre 79,55% e 96%, apenas para a classificação dos estertores. Finalmente, HADJILEONTIADIS (2003), propõe uma metodologia de análise por discriminação

automática para a separação apenas nos subgrupos de sons adventícios descontínuos.

Por outro lado, SCHÜTTLER, PENZEL e WICHERT (1996); HADJILEONTIADIS e PANAS (1997a); KIYOKAWA *et al.* (1999), também abordam em seus trabalhos os sons adventícios específicos, sendo que estes autores, entretanto, focaram sua caracterização apenas em grupos de normais e sons com anomalias contínuas. Contudo, esses autores apresentam apenas resultados qualitativos de sua análise dos sons adventícios contínuos, não podendo ser comparados diretamente aos resultados apresentados no presente trabalho.

LOUD e DOOIJES (1996) apresentam resultados de classificação de pacientes a partir da sua patologia, em dois conjuntos: com asma e saudáveis, a partir da análise dos sons respiratórios não podendo, portanto, ser possível a comparação direta dos resultados obtidos por esses autores com os obtidos nesta tese.

GÜLER *et al.* (2005), também apresentam uma abordagem de reconhecimento baseado na classificação da patologia a partir dos sons pulmonares. Nesta técnica, propõe-se a divisão do ciclo respiratório em seis partes, utilizando o cálculo dos coeficientes cepstrais e classificação em dois estágios, utilizando redes neurais MLP. Esta técnica apresentou um índice de acerto entre 70% e 80% para a classificação dos sons respiratórios isoladamente, sem conexão com o paciente, assim como utilizado na técnica proposta neste trabalho.

CUSTÓDIO (1999), em sua tese de doutoramento, realiza uma análise dos sons pulmonares através do cálculo do grau de caoticidade desses sons, utilizando expoentes de Lyapunov. Na metodologia proposta neste trabalho, o autor propõe a caracterização dos sons pulmonares normais e adventícios, nestes dois grandes grupos, através dos níveis dos expoentes de Lyapunov positivos encontrados nesses sons, relacionados ao seu grau de não-linearidade. Apesar deste trabalho utilizar escalogramas como referência para avaliação dos expoentes de Lyapunov encontrados nos sons pulmonares, propõe como trabalho futuro uma análise mais detalhada desses sons através da transformada *wavelet*.

MARTINEZ-HERNANDEZ *et al.* (2005), propõem a classificação em dois grupos: sons normais e anormais. Para a classificação esses autores utilizam um sistema de aquisição multicanal de sons pulmonares, extração de parâmetros através de modelos auto-regressivos (AR) e classificação através de redes supervisionadas treinadas a partir do algoritmo de retropropagação do erro. Nesse trabalho, os autores obtiveram um índice de acerto máximo de 87,68% dentro do grupo proposto.

Já FOLLAND *et al.* (2004), apesar de não proporem uma metodologia para classificação de sons pulmonares propriamente dito, realizaram uma comparação entre as redes neurais MLP, RBF e probabilísticas (CPNN) para análise de sons bronquiais e

traqueais. Em suas conclusões, recomendam o uso das redes neurais RBF e CPNN em detrimento às MLPs, por obterem índices de acerto de 96,2%, 97,8% e 77,8% para cada uma das redes, respectivamente.

Os trabalhos que mais se aproximam à proposta de classificação dos sons pulmonares apresentada neste trabalho são os desenvolvidos por KANDASWAMY *et al.* (2004); e GÜLER, POLAT e ERGUN (2005), os quais serviram como base de comparação no desenvolvimento dos estudos.

KANDASWAMY *et al.* (2004), realizam a classificação de sons adventícios através da decomposição *wavelet* até o sétimo nível, com sinais amostrados a 11 kHz. Após a decomposição, os coeficientes *wavelet* obtidos em todos os níveis são aplicados a uma rede neural artificial MLP. A metodologia desenvolvida neste trabalho alcançou um resultado geral máximo de 92% utilizando a *wavelet* Daubechies 8. Assim, a técnica desenvolvida nesta tese obteve um índice de acerto equivalente à obtida por aqueles autores, utilizando uma metodologia diferente. Entretanto, a técnica proposta apresenta a vantagem de possibilitar o rápido re-treinamento da simulação da rede neural artificial em casos de erro de classificação, devido à utilização da rede neural RBF.

A mesma vantagem pode ser apontada quando da comparação com o trabalho de GÜLER, POLAT, ERGUN (2005), que propõem a classificação em três grupos: normais, sibilos e estertores. Nesta técnica, calcula-se o PSD do ciclo respiratório diretamente como método de processamento para um classificador baseado em uma rede neural MLP, sendo os parâmetros de entrada selecionados como treinamento à rede neural escolhidos através de algoritmos genéticos, vindo a apresentar índices de acerto entre 83 e 93% em um conjunto de 129 sons analisados. Assim, além da vantagem citada, a técnica desenvolvida engloba a dupla ocorrência de sons adventícios, apresentando valores similares de índice de acerto na classificação.

9.2 AVALIAÇÃO DA CARACTERIZAÇÃO DOS SONS ADVENTÍCIOS ATRAVÉS DE FILTRAGEM POR ANÁLISE ESPECTRAL SELETIVA

Assim como os resultados obtidos na técnica desenvolvida de classificação automática dos sons pulmonares, a avaliação da metodologia inovadora de filtragem dos sons adventícios através do algoritmo de filtragem por análise espectral seletiva foi realizada de forma qualitativa e quantitativa. A análise qualitativa foi realizada analisando-se os sinais obtidos

nos domínios do tempo e frequência (espectrogramas) e através da análise dos sinais de áudio obtidos após o processamento. Já a análise quantitativa ocorreu por meio da análise dos valores obtidos de atenuação dos sinais cardíacos frente aos obtidos para os roncos, através das diferentes famílias *wavelet* testadas.

Avaliando-se qualitativamente a resposta da técnica proposta aos diferentes sons adventícios, verificou-se que eles mantêm suas características inalteradas quando possuem frequências fundamental e harmônicas fora da faixa dos coeficientes do sinal aproximação nível 4. Para o caso das anomalias que apresentam uma maior largura espectral, como as anomalias descontínuas e o estridor, constatou-se uma atenuação em suas componentes de baixa frequência sem, entretanto, haver descaracterização da anomalia. Essas propriedades foram verificadas em todas as funções *wavelet* testadas, não apresentando diferenças significativas entre as famílias para esses casos.

O som adventício que mais sofre distorção com a aplicação do algoritmo de filtragem por análise espectral seletiva é o ronco, que sempre ocorre na faixa de atuação da filtragem. Desta forma, conforme sua proposta, o algoritmo deve manter apenas a frequência fundamental da anomalia intacta, eliminando as suas componentes harmônicas até 250 Hz. Neste ponto, várias famílias de funções *wavelet* testadas não foram capazes de isolar apenas a frequência fundamental do ronco, gerando reflexões desta frequência fundamental que contaminaram todo o sinal, facilmente visíveis nos espectrogramas dos sinais processados. As famílias que apresentaram esta distorção foram as Biortogonais 3.7, 3.9 e 6.8, Biortogonal Reversa 3.7, Daubechies 4, Coiflet 3 e Symlet 8, sendo esta distorção bastante severa nas *wavelets* Daubechies 4 e Biortogonal Reversa 3.7. Em termos de audibilidade, essa distorção causa uma sonoridade “metálica” indesejada ao som do ronco, dificultando a sua identificação.

Este efeito ocorre devido à ordem dos filtros de decomposição e reconstrução utilizados no processo de análise em multiresolução, sendo verificado nas famílias que possuem filtros de ordem mais baixa. Devido à sua baixa ordem, os filtros espelhados apresentam uma maior banda espectral na sua intersecção, que reflete nas componentes espectrais durante a reconstrução. Assim, a operação de filtragem realizada nos coeficientes aproximação não é refletida nas mesmas componentes espectrais presentes nos coeficientes detalhe, que são refletidos durante o processo de reconstrução.

Por possuírem filtros com ordem mais alta, as *wavelets* Meyer Discreta, Symlet 20 e Daubechies 44 não apresentaram tal distorção, mantendo o sinal da frequência fundamental do ronco sem distorções.

Quantitativamente, utilizando os valores de PSD como referência para o cálculo da atenuação obtida para os sons cardíacos e para o ronco, verificou-se uma clara diferença entre as diferentes *wavelets* testadas, conforme a tabela 8 na seção 8.4. Também nesta análise, as *wavelets* que possuem filtros de maior ordem apresentaram melhores resultados.

Para as *wavelets* Biortogonais 3.7, 3.9 e 6.8, Biortogonal Reversa 3.7, Daubechies 4, Coiflet 3 e Symlet 8, a diferença de atenuação obtida para os roncões e para os sons cardíacos foi muito baixa, entre 0 e 3 dB, havendo casos de atenuação maior dos roncões, para as *wavelets* Biortogonal 3.7, Biortogonal Reversa 3.7 e Daubechies 4. Já as *wavelets* de maior ordem apresentaram uma melhor atenuação dos sons cardíacos em relação aos roncões, com a desvantagem de a atenuação global também se verificar maior.

Desta maneira, significativamente a *wavelet* que mostrou melhores resultados na aplicação da técnica de filtragem por análise espectral seletiva dentro das funções testadas foi a Symlet 20. Este fato decorre desta *wavelet* não apresentar distorção espectral durante a reconstrução do sinal e por apresentar uma diferença de atenuação média de 6 dB entre os roncões e os sons cardíacos, maior que qualquer outra *wavelet* testada.

A abordagem proposta na técnica de filtragem por análise espectral seletiva, de isolar os sons adventícios presentes nos sons pulmonares, não apresentou igualdade com nenhum trabalho encontrado na literatura. Os trabalhos que mais se aproximam à abordagem proposta referem-se à filtragem dos sons cardíacos dos sons pulmonares (KOMPIS e RUSSI, 1992; HADJILEONTIADIS e PANAS, 1997b; GNITECKI *et al.*, 2005; POURAZAD, MOUSSAVI e THOMAS, 2006; CHARLESTON *et al.*, 2006; FLORES-TAPIA, MOUSSAVI e THOMAS, 2007) ou à extração de sons adventícios específicos, normalmente os descontínuos (MASTOROCOSTAS e THEOCHARIS, 2007; MASTOROCOSTAS, STAVRAKLOUDIS e THEOCHARIS, 2008).

Dentre as técnicas de extração dos sons cardíacos presentes nos sons pulmonares, KOMPIS e RUSSI (1992), propõem o uso de filtros adaptativos utilizando mínimos quadrados (LMS) como algoritmo de atualização dos coeficientes dos filtros. Nesta técnica, obtiveram valores de atenuação, medidas em porcentagem, na faixa entre 24% e 49%. HADJILEONTIADIS e PANAS (1997b), adicionam à metodologia de KOMPIS e RUSSI (1992), o uso de análise por estatísticas de alta ordem (HOS). Nesse trabalho, a avaliação do nível de redução dos sons cardíacos é obtida a partir de um índice percentual de redução. Utilizando este índice, a técnica apresentou redução entre 63% e 71% da amplitude dos sons cardíacos.

GNITECKI *et al.* (2005), realizaram uma comparação da redução obtida nos sons cardíacos por meio de dois algoritmos distintos: cancelamento de ruído através de mínimos quadrados recursivos e cancelamento de ruído através do uso de *wavelets*. Esses autores propuseram o uso dos níveis de PSD obtidos para avaliar a redução dos sons cardíacos, sendo as atenuações medidas em decibéis. Os resultados apresentados fazem uma comparação entre os métodos propostos, avaliando a redução em duas bandas espectrais diferentes, entre 20 e 40Hz e entre 40 e 70Hz. Os melhores resultados foram obtidos pelo método de cancelamento baseado em *wavelets*, utilizando a *wavelet* Daubechies 8, apresentando atenuação média variando entre 3,2 e 4,97 dB nas bandas espectrais avaliadas.

O trabalho de POURAZAD, MOUSSAVI e THOMAS, 2006, apresenta uma proposta que se aproxima da metodologia utilizada na filtragem por análise espectral seletiva, uma vez que esta também faz uso da DWT. A proposta apresentada por esses autores é baseada na decomposição do sinal do som pulmonar através do processo de decomposição *wavelet*, extração do sinal do som cardíaco, aplicação de interpolação no segmento faltante e reconstrução ao sinal original. Entretanto, este trabalho apresenta principalmente avaliações qualitativas dos resultados obtidos, avaliando as formas de onda resultantes. Quantitativamente, utiliza-se apenas o cálculo do espectro de potências médio dos sinais processados, apresentando reduções médias entre 0,79 e 0,94 dB.

CHARLESTON *et al.* (2006), propõem o uso de decomposição empírica, dizimação temporal e filtragem, através do uso de filtros FIR, para a eliminação dos sons cardíacos presentes nas gravações de sons pulmonares obtidas a partir de um sistema de aquisição multicanal por estes desenvolvida. Entretanto, para a computação dos resultados foram utilizadas simulações de sons pulmonares contaminados por sons cardíacos. Os resultados também foram apresentados e avaliados de forma apenas qualitativa.

Finalmente, FLORES-TAPIA, MOUSSAVI e THOMAS (2007), apresentam uma técnica semelhante à proposta por POURAZAD, MOUSSAVI e THOMAS (2006), adotando os processos de decomposição *wavelet*, extração dos sinais dos sons cardíacos e reconstrução. Entretanto, nessa proposta substituiu-se a interpolação realizada nas regiões onde os sinais cardíacos foram extraídos pela utilização de um algoritmo de predição linear. Os resultados quantitativos foram obtidos pela análise dos valores de PSD em quatro diferentes bandas espectrais, nos intervalos 20 a 40Hz, 40 a 70Hz, 70 a 150Hz e 150 a 300Hz. Os resultados apresentaram uma atenuação média do sinal nestas bandas variando entre 0,5 e 20 dB, dependendo da banda espectral. Entretanto, os valores de atenuação obtidos são relacionados

apenas com as bandas de frequência nos resultados apresentados, não medindo diretamente a atenuação obtida nos sinais dos sons cardíacos.

Comparando-se a metodologia proposta com as desenvolvidas especificamente para a extração de sons adventícios descontínuos, pode-se afirmar que os resultados são equivalentes, uma vez que em ambos os casos obtém-se como saída apenas os sinais dos sons adventícios. Entretanto, os trabalhos de MASTOROCOSTAS e THEOCHARIS (2007); MASTOROCOSTAS, STAVRAKOUDIS e THEOCHARIS (2008), por se especializarem apenas nos sons descontínuos, também propõem a separação desses sons adventícios nos seus sub-grupos.

CAPÍTULO 10

CONCLUSÕES

Neste trabalho, foram apresentados os resultados da análise dos sons pulmonares normais e adventícios, utilizando como base suas características de distribuição espectral. Esta análise foi realizada visando à classificação e caracterização de sons adventícios, cuja presença relaciona-se a patologias do sistema respiratório.

Neste contexto, foram propostas e avaliadas duas metodologias inovadoras que cumprem os objetivos de classificar os sons pulmonares nos grupos normais, contendo sons adventícios contínuos, descontínuos e ambos, isolando o sinal do som adventício no ciclo respiratório. Essas metodologias, quando aplicadas em conjunto, são capazes de gerar um parecer automático da presença de sons adventícios em um ciclo respiratório e retornar um sinal de áudio em que este aparece isolado, mostrando-se mais facilmente audível e podendo ser utilizado para localização temporal do som adventício.

A técnica proposta para classificação dos sons pulmonares baseada na DWT como técnica de processamento e uma simulação de rede neural RBF como classificador, apresentou índice de acerto comparável aos melhores índices de acerto encontrados na literatura para propostas semelhantes. Além dessa característica, pode-se afirmar que a técnica desenvolvida utiliza uma metodologia inovadora, uma vez que não consta precedente da metodologia proposta em trabalhos correlatos encontrados na literatura, possibilitando a vantagem de re-treinamento rápido em casos de erro de classificação.

A outra proposta inovadora deste trabalho corresponde ao desenvolvimento da técnica de filtragem por análise espectral seletiva, aplicada à extração dos sons adventícios dos sons pulmonares. Pode-se afirmar que a técnica é inédita tanto pela sua abordagem quanto pelas técnicas utilizadas em sua construção, não sendo nenhuma destas encontradas na literatura. Esta metodologia mostrou-se eficaz para toda gama de ciclos respiratórios testados, para três funções *wavelet* dentro do conjunto de funções testadas: Meyer Discreta, Daubechies 44 e Symlets 20, sendo a última escolhida como melhor função para esta aplicação, devido à sua maior capacidade de atenuar os sons cardíacos em relação aos roncos, os quais ocorrem na mesma faixa espectral. Entretanto, os sons adventícios mostraram-se naturais nos sinais de áudio referentes ao processamento utilizando estas três funções *wavelet*.

10.1 TRABALHOS FUTUROS

Os *softwares* desenvolvidos neste trabalho foram implementados visando, inicialmente, à análise e testes das metodologias propostas. Estes *softwares* foram desenvolvidos separadamente para o teste de cada técnica, utilizando diferentes plataformas. Assim, propõem-se como trabalhos de continuação desta pesquisa, as seguintes alterações do aplicativo:

- unificação das linguagens de programação utilizadas, de forma a possibilitar a integração das metodologias propostas em um único *software*; e
- desenvolvimento de uma interface única e amigável para ambos os *softwares*, para classificação e caracterização dos sons pulmonares, incluindo a integração da visualização do espectrograma desses sons.

Uma vez que as técnicas desenvolvidas nesta tese baseiam-se em sons pulmonares gravados digitalmente, outra proposta de trabalho futuro refere-se ao desenvolvimento de um equipamento de aquisição de sons respiratórios, de forma a possibilitar a utilização dessas técnicas em ambiente clínico.

No desenvolvimento da técnica de classificação dos sons pulmonares através da DWT, as redes neurais RBF foram utilizadas como parâmetro quantitativo na avaliação da classificação dos sons adventícios. Assim, propõe-se como trabalho futuro a implementação de outras técnicas de treinamento das redes neurais RBF e mesmo a utilização de redes neurais auto-organizáveis, traçando um comparativo dos resultados obtidos na metodologia proposta com as várias redes neurais ensaiadas.

A metodologia proposta de filtragem por análise espectral seletiva baseia-se, durante a construção de seu filtro, na detecção da frequência mais preponderante nos coeficientes análise nível 4. Uma proposta de futuro estudo incremental a esta técnica é o teste da utilização de filtros adaptativos, através do algoritmo LMS, ao invés de filtros FIR Multibanda. Tal técnica é proposta por GNITECKI *et al.*, 2005, para atenuação dos sons cardíacos. Entretanto, a atuação desta técnica de forma restrita aos coeficientes de aproximação pode resultar em ganhos à técnica de filtragem por análise espectral seletiva.

As novas metodologias de análise e caracterização dos sons adventícios pulmonares propostas neste trabalho apresentam aplicabilidade clínica imediata, sendo implementadas diretamente em *softwares* que podem ser executados em qualquer microcomputador pessoal comum. Além dessa possibilidade, as técnicas de processamento digital de sinais utilizadas como base no desenvolvimento das metodologias propostas não requerem uma grande

complexidade computacional para a sua execução. Esta característica possibilita a implementação dessas técnicas em sistemas embarcados, com menor poder computacional e maior portabilidade, sendo assim possível a construção de um equipamento portátil de análise de sons pulmonares que utilize as técnicas propostas.

Contudo, o uso clínico de tais metodologias depende de um sistema de aquisição de sons pulmonares, atualmente em desenvolvimento. Além do sistema de aquisição, as técnicas desenvolvidas neste trabalho podem ser utilizadas como base para o desenvolvimento de técnicas de classificação automática da patologia associada ao som pulmonar adventício detectado, criando um sistema de classificação em dois níveis. Esse sistema deve basear-se, além das informações obtidas apenas dos sons auscultados, nas informações obtidas na anamnese do paciente.

10.2 COMENTÁRIOS FINAIS

Na prática clínica, as técnicas não invasivas de diagnóstico, tratamento e acompanhamento da evolução de patologias são tidas como prioritárias, devido a sua aplicação simples e ao menor risco de exposição do paciente.

Assim, as novas técnicas propostas foram desenvolvidas com a intenção de criar não somente metodologias de reconhecimento automático de sons adventícios em sons pulmonares, mas algoritmos eficazes que possam auxiliar os profissionais de saúde no diagnóstico de patologias respiratórias. Tais metodologias foram concebidas visando retornar não somente um diagnóstico automático, mas gerar dados ao profissional para que este possa tirar suas próprias conclusões sobre este resultado. De acordo com os resultados obtidos, conclui-se que as técnicas propostas são robustas e confiáveis o suficiente para serem utilizadas como auxílio na detecção dos sons adventícios nos sons pulmonares, principalmente quando esta análise é realizada utilizando-se vários ciclos respiratórios de um mesmo paciente. Finalmente, as novas técnicas propostas possibilitam a criação de um sistema analisador automático dos sons pulmonares, que possa ajudar a incrementar a exatidão e velocidade do diagnóstico clínico, através de uma nova ferramenta de auxílio à ausculta.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABELLA, M., FORMOLO, J., PENNEY, D. G. Comparison of the acoustic properties of six popular stethoscopes. **J. Acoust. Soc. Am.** Vol. 91, p. 2224-2228, 1992.
- BARRETO, D. M., **Ausulta Pulmonar**, 1999 Disponível em: <http://orbita.starmedia.com/~medbahia/pulmonar.htm>. Acessado em 12/2003.
- BENTUR, L., BECK, R., SHINAWI, M., NAVEH, T., GAVRIELY, N., Wheeze monitoring in children for assessment of nocturnal asthma and response to therapy, **European Respiratory Journal**, Vol. 21, p.621-626, 2003.
- BILLINGS, S. A., ZHENG, G. L., Radial Basis Function Networks Configuration Using Genetic Algorithms, **Neural Networks**, Vol. 8, No. 6, p. 877-890, 1995.
- BURT, P. J., ADELSON, E. H., The Laplacian Pyramid as a Compact Image Code, **IEEE Transactions on Communications**, Vol. COM-31, No. 4, April 1983, pages 532-540.
- CANDY, J. V., **Signal processing: the modern approach**. New York: McGraw Hill, 1988.
- CHARBONNEAU, G., ADEMOVIC, E., CHEETHAM, B. M. G., MALMBERG, L. P., VANDERSCHOOT, J., SOVIJÄRVI, A. R. A., Basic techniques for respiratory sound analysis, **European Respiratory Review**, Vol. 10, Issue 77, p.625-635, 2000.
- CHARLESTON-VILLALOBOS, S., DOMINGUEZ-ROBERT, L. F., GONZALEZ-CAMARENA, R., JAMA-CORRALES, A. T., **Heart sounds interference cancellation in lung sounds**, Conf.Proc.IEEE Eng Med Biol Soc. 1:1694-7.:1694-1697, 2006.
- CHATBURN, R. L., PRIMIANO JR, F. P., Mathematical models of respiratory mechanics, in Chatburn, R.L., Craig, K.C., **Fundamentals of Respiratory Care Research**, Norwalk, CT: Appeton & Lange, 1988.

- CHEN, S., COWAN, C. F. N., GRANT, P. M., Orthogonal Least Squares Algorithm for Radial Basis Function Networks, **IEEE Transactions on Neural Networks**, Vol. 2, No. 2, p.302-309, 1991.
- CHURCHLAND, P. S., SEJNOWSKI, T. J., **The Computational Brain**, Cambridge, Ma: MIT Press, 1992.
- CIVITA, V. o Aparelho respiratório. **Grandes Temas da Medicina – Manual Ilustrado de Anatomia, Doenças e Tratamentos**, São Paulo: Nova Cultural, 1986.
- COHEN, L., **Time-Frequency Analysis**, New Jersey: Prentice-Hall PTR, 1995.
- COHEN, A, DAUBECHIES, I, FEAUVEAU, J. C., Biorthogonal bases of compactly supported wavelets, **Communications on Pure and Applied Mathematics**, Vol.45 NO.5, 1992.
- COOLEY, J., TUKEY, J., An algorithm for the machine calculation of complex Fourier series. **Math Comput.**, 1965.
- CROCHIERE, R., WEBER, S., FLANAGAN, J., Digital coding of speech in sub-bands, **Proceedings of the ICASSP**, Vol. 1, p. 233—236, 1976.
- CROISER, A., ESTEBAN, D., GALAND, C., Perfect channel splitting by use of interpolation/decimation/tree decomposition techniques, **International Conference of Information Sciences and Systems**, p. 443-446, 1976.
- CUSTÓDIO, R. F., **Análise Não-Linear no Reconhecimento de Padrões Sonoros: Estudo de Caso para Sons Pulmonares**, Tese de Doutorado (Universidade Federal do Rio Grande do Sul, Programa de Pós-Graduação em Computação), Porto Alegre, RS, 1999.
- DAUBECHIES, I., **Ten Lectures on Wavelets**, Cambridge University Press, Cambridge 1992.

- DEMUTH, H., BEAGLE, M. e HAGAN, M., **Neural Networks Toolbox User's Guide**, The MathWorks Inc., Nineth printing, 2007.
- DU, M., CHAN, F. H. Y., LAM, F. K., SUN, J., Crackle Detection and Classification Based on Matched Wavelet Analysis, **Proceedings of 19th Annual International Conference of IEEE Engineering in Medicine and Biology Society**, p. 1638-1641, Chicago, 1997.
- EGGERMONT, J. J., **The Correlative Brain: Theory and Experiment in Neural Interaction**, New York, Springer-Verlag, 1990.
- FAUSETT, L. V. **Fundamentals of Neural Networks: Architectures, Algorithms and Applications**, New Jersey, Prentice-Hall, 1994.
- FLORES-TAPIA, D., Z. M. MOUSSAVI, G. THOMAS, Heart sound cancellation based on multiscale products and linear prediction, **IEEE Trans Biomed Eng** Vol. 54:234-243, 2007.
- FOLLAND, R., HINES, E., DUTTA, R., BOILOT, P., MORGAN, D., Comparison of neural network predictors in the classification of tracheal-bronchial breath sounds by respiratory auscultation, **Artificial Intelligence in Medicine**, Vol 31:211-220, 2004.
- FRASER, D. **IMD 420-C Review of Lung Sounds**, Disponível em: <http://medocs.ucdavis.edu/IMD/420C/sounds/lngsound.htm>. Acessado em 12/2003.
- GABOR, D., Theory of Communication, **J. IEE**, Vol. 93: 429-457, 1946.
- GNITECKI, J., HOSSAIN, I., PASTERKAMP, H., MOUSSAVI, Z. **Qualitative and quantitative evaluation of heart sound reduction from lung sound recordings**. **IEEE Trans.Biomed.Eng** 52:1788-1792, 2005.
- GNITECKI, J., MOUSSAVI, Z. M., Separating heart sounds from lung sounds. Accurate diagnosis of respiratory disease depends on understanding noises, **IEEE Eng Med Biol Mag**, Vol 26 p.20-29, 2007.

GUITON, A. C., **Textbook of Medical Physiology**, 6th edition, Philadelphia, W. B. Saunders, 1981.

GÜLER, E. C., SANKUR, B., KAHYA, Y. P., RAUDYS, S. Two-stage classification of respiratory sound patterns. **Computers in Biology and Medicine** Vol 35 p.67-83, 2005.

GÜLER, I., POLAT, H., ERGUN, U., Combining neural network and genetic algorithm for prediction of lung sounds. **J.Med.Syst**, Vol 29, p217-231, 2005.

HAAR, A., Zur Theorie der orthogonalen Funktionensysteme, **Mathematische Annalen**, 1910.

HADJILEONTIADIS, L. J., PANAS, S. M. (1), Nonlinear analysis of musical lung sounds using the biocoherence index, **Proceedings of 19th Annual International Conference of IEEE Engineering in Medicine and Biology Society**, Chicago, IL p.1126-1129, 1997.

HADJILEONTIADIS, L. J., PANAS, S. M. (2), Adaptive Reduction of Heart Sounds from Lung Sounds Using Fourth-Order Statistics, **IEEE Transactions On Biomedical Engineering**, Vol. 44, No. 7, July 1997.

HADJILEONTIADIS, L. J., PANAS, S. M., A wavelet-based reduction of heart sound noise from lung sounds, **International Journal of Medical Informatics**, Vol.52, pp 183–190, 1998.

HADJILEONTIADIS, L. J., Discrimination analysis of discontinuous breath sounds using higher-order crossings, **Medical and Biological Engineering and Computing**, Vol 41:445-455, 2003.

HAYKIN, S., **Redes Neurais: Princípios e Prática**. Porto Alegre, Bookman, 2001.

HAYKIN, S., VAN VEEN, B., **Sinais e sistemas**. Porto Alegre, Bookman, 2001.

HOLLINSHEAD, W. H., ROSSE, C., **Anatomia**. Rio de Janeiro, Interlivros, 1991.

- JAMIESON, G., CHEETHAM, B. M. G., MORUZZI, J. L., EARIS, J. E., **Digital signal processing of lung sounds**, 1991.
- JOHNSON, R. C., BROWN, C., **Cognizers: Neural Networks and Machines that Think**. New York, John Wiley & Sons, 1988.
- KAHYA, Y. P., GÜLER, E. C., SAHIN, Respiratory Disease Diagnosis Using Lung Sounds, **Proceedings of 19th Annual International Conference of IEEE Engineering in Medicine and Biology Society**, p. 2051-2053, Chicago, 1997.
- KANDASWAMY, A., KUMAR, C. S., RAMANATHAN, R. P., JAYARAMAN, S., MALMURUGAN, N., Neural classification of lung sounds using wavelet coefficients, **Computers in Biology and Medicine**, Vol.34, p.523-537, 2004
- KIOKAWA, H., YONEMARU, M., HORIE, S., KASUGA, I., ICHINOSE, Y., TOYAMA, K., Detection of nocturnal wheezing in bronchial asthma using intermittent sleep tracheal sounds recording, **Respirology**, Vol.4 p.37-45, 1999.
- KOMPIS, M., RUSSI, E., Adaptive Heart-Noise Reduction Of Lung Sounds Recorded By A Single Microphone, **Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society**, Vol.14, 1992.
- LAËNNEC, R. T. H., De l'auscultation mediate ou traité du diagnostic de maladies des poumons et du Coeur, fondé principalement sur ce nouveau moyend d'exploration, Brosson et Chaudé, Paris, 1819.
- LEE, S., RHEE, M.K. A gaussian potencial function network with hierarchically self-organizing learning, **Neural Networks**, Vol. 4, p. 207-224, 1991.
- LEHRER, S., **Entendendo os Sons Pulmonares**, São Paulo, Roca, 1990.
- LIPPMANN, R. P., Pattern Classification Using Neural Networks, **IEEE Communications Magazine**, 1989, Vol.27, p. 47-64.

- LOPO, E. C., **Libsndfile: a C library for reading and writing files containig sample sounds**, Disponível em: <http://www.zip.com.au/~erikd/libsndfile/>. Acessado em 12/2003.
- LOWE, D., **Adaptive Radial Basis Function Nonlinearities and the Problem of Generalization**, 1st IEE International Conference on Artificial Neural Networks, London, 1989.
- MALLAT, S., **A Wavelet Tour of Signal Processing**, 2^a Edição, San Diego, CA, Elsevier, 1999.
- MARTINEZ, F. D., WRIGHT, A. L., TAUSSIG, L. M., HOLBERG, C. J., HALONEN, M., MORGAN, W. J., THE GROUP HEALTH MEDICAL ASSOCIATES, Asthma and wheezing in the first six years of life, **The New England Journal of Medicine**, Vol. 332, Issue 3, p.133-138, 1995.
- MARTINEZ-HERNANDEZ, H. G., JAMA-CORRALES, C. T., GONZALEZ-CAMARENA, R., CHARLESTON-VILLALOBOS, V. S., CHI-LEM, G., Computerized classification of normal and abnormal lung sounds by multivariate linear autoregressive model, **Conference Proceedings of IEEE Engineering in Medicine and Biology Society**, Vol 6:5999-6002, 2005.
- MASTOROCOSTAS, A. P., TOLIAS, Y. A., THEOCHARIS, J. B., HADJILEONTIADIS, L. J. e PANAS, S. M., An Orthogonal Least Squares-Based Fuzzy Filter for Real-Time Analysis of Lung Sounds, **IEEE Transactions on Biomedical Engineering**, Vol. 47, No. 9, September 2000.
- MASTOROCOSTAS, P. A., THEOCHARIS, J. B., A dynamic fuzzy neural filter for separation of discontinuous adventitious sounds from vesicular sounds, **Computers in Biology and Medicine**, Vol 37:60-69, 2007.
- MASTOROCOSTAS, P. STAVRAKLOUDIS, D., THEOCHARIS, J., A pipelined recurrent fuzzy model for real-time analysis of lung sounds, **Engineering Applications of Artificial Intelligence**, 2008.

- McCULLOCH, W. S., PITTS, W., A logical calculus of the ideas immanent in nervous activity, **Bulletin of Mathematical Biophysics**, 1943.
- McLELLAND, J. L., RUMELHART, D. E., **Explorations in Parallel Distributed Processing**, Cambridge, Ma: MIT Press, 1988.
- MEYER, Y., Ondelettes, Fonctions Splines et Analyses Graduées, **Lectures given at the University of Torino**, 1986.
- MIKAMI, R., MURAO, M, CUGELL, D.W., CHRETIEN, J., COLE, P., MEIER-SYDOW, J., et al. **International symposium on lung sounds**. Synopsis of preceedings. Chest. 92(2):342-5, 1987.
- MINISTÉRIO DA SAÚDE, Anuário estatístico de saúde do Brasil, 2001, Disponível em: <http://portal.saude.gov.br/saude/aplicacoes/anuario2001/index.cfm>, Acessado em: 06/2006.
- MISITI, M., MISITI, Y., OPPENHEIM, G., POGGI, J. M., **Wavelet Toolbox User's Guide**, The MathWorks Inc., Third printing, 2004.
- MOODY, J., DARKEN, C. J., Fast Learning in Networks of Locally-tuned Processing Units, **Neural Computation**, Vol.1, p.281-294, 1989.
- MORLET, J., Sampling theory and wave propagation, in NATO ASI Series, Vol. 1, **Issues in Acoustic Signal/Image processing and recognition**, C. H. Chen ed., Spring-Verlag, Berlin, p. 233-261, 1983.
- MUSAVI, M.T., AHMED, W., CHAN, K.H., FARIS, K.B., HUMMELS, D.M. On the training of radial basis function classifiers, **Neural Networks**, Vol. 5, p. 595-603, 1992.
- MURPHY, R., A simplified introduction to lung sounds, Fornecido juntamente com a fita de ensino de sons pulmonares: **Stethophonics**, Wellesley Hills, 1977.
- OPPENHEIM, A.V., SHAFER, R.W., **Discrete-Time Signal Processing**. Englewood Cliffs, NJ: Prentice Hall, 1989.

LOUD, M., DOIJES, E. H., Automated Breath Sound Analysis, **Proceedings of 18th Annual International Conference of IEEE Engineering in Medicine and Biology Society**, Amsterdam, p.990-992, 1996.

PASTERKAMP, H., KRAMAN, S. S., WODICKA, G. R., State of the Art: Respiratory sounds, advances beyond the stethoscope, **American Journal of Respiratory and Critical Care Medicine**, Vol.156 p.974-987, 1997.

PEREIRA, C. A. C., FAGUNDES, P. C., COLETTA, E. N. A., Dispneia e grasnidos, Casos Clínicos da Sociedade Brasileira de Pneumologia e Tisiologia, Caso 12, Disponível em: http://www.sbpt.org.br/_sbpt.php?op=paginas&tipo=pagina&secao=19&pagina=545, Acessado em: 12/2008.

PIXSOFT, **The RALE repository**, Disponível em: <http://www.rale.ca>, Acessado em: 07/2006.

POURAZAD, M. T., MOUSSAVI, Z., THOMAS, G., Heart sound cancellation from lung sound recordings using time-frequency filtering, **Med.Biol.Eng Comput.** Vol. 44:216-225, 2006.

PRESS, W. H., TEUKOLOSKY, S. A., VETTERLING W. T., FLANNERY, B. P., **Numerical Recipes in C: the Art of Scientific Computing**, 2nd edition, Cambridge MA, Cambridge University Press, 1992.

PROAKIS, J. G., RADER, C. M., LING F., NIKIAS, C. L., **Advanced Digital Signal Processing**, New York, MacMillan Publishing Company, 1992.

RIELLA, R. J., STELLE, A. L., NOHAMA, P., Caracterização de anomalias descontínuas em sons pulmonares gravados, **Anais do II Seminário de Trabalhos Individuais do Curso de Pós-Graduação em Engenharia Elétrica e Informática Industrial**, Curitiba, 2002.

RIELLA, R. J., NOHAMA, P., BORGES, R. F., STELLE, A. L., Automatic Wheezing Recognition in Recorded Lung Sounds. **Proceedings of 25th Annual International**

Conference of IEEE Engineering in Medicine and Biology Society, Cancun, 2003. p. 2535-2538.

RIELLA, R. J., **Proposta de Metodologia para Caracterização e Reconhecimento de Sibilos em Sons Pulmonares**, Dissertação de mestrado (Curso de Pós-Graduação em Engenharia Elétrica e Informática Industrial – CPGEI). Curitiba, CEFET-PR, 2004.

RIELLA, R. J., STELLE, A. L., NOHAMA, P., A Wavelet-Based Algorithm for Lung Sounds Classification. **Proceedings of the 12th International Conference on Biomedical Engineering**, Cingapura, 2005.

ROQUE, W, PULSA Pulmonary Sound Analyzer, 2003 Disponível em: <http://www.mat.ufrgs.br/~roque/pulsa.html>. Acessado em 07/2008.

ROVANI, A. Z., GAMBA, H. R., OSOWSKY, J., Biblioteca para implementação de algoritmos de processamento digital de imagens, **Anais do V Seminário de Iniciação Científica** , Curitiba, p.9-12, 2000.

RUMELHART, D. E., HINTON, G. E., WILLIAMS, R. J., Learning Representations by back-propagating error, **Nature**, p.533-536, 1986.

SCHÜTTLER, F., PENZEL, T., WICHERT, P. V., Digital recording and computer-based analysis of lung sounds, **Proceedings of 18th Annual International Conference of IEEE Engineering in Medicine and Biology Society**, Amsterdam, p.2301-2302, 1996.

SHEPHERD, G. M., KOCH, C., Introduction to synaptic circuits, in **The Synaptic Organization of the Brain**, Shepherd, G. M., New York, Oxford University Press, p3-31, 1990.

SILVA, L. C. C., **Compêndio de Pneumologia**, São Paulo, Fundo Editorial BYK Prociex, 1991.

SOVIJÄRVI, A. R. A., DALMASSO, F., VANDERSCHOOT, J., MALMBERG, G., RIGHINI, G., STONEMAN, S. A. T., Definition of terms for applications of respiratory sounds, **European Respiratory Review** Vol. 10, Issue 77, p597-610, 2000.

STASZKO, K. F., LINCHO, C., ENGELKE, V. C., FIORI, N. S., SILVA, K. C., NUNES, E. I., ZHANG, L., Terminologia da ausculta pulmonar utilizada em publicações médicas brasileiras, no período de janeiro de 1980 a dezembro de 2003, **J Bras Pneumol** Vol. 32, 2006.

TOLIAS, Y. A., HADJILEONTIADIS, L. J., PANAS, S. M, Real-Time Separation of Discontinuous Adventitious Sounds from Vesicular Sounds Using a Fuzzy Rule-Based Filter, **IEEE Transactions on Information Technology in Biomedicine**, Vol. 2, No. 3, September 1998.

VETTERLI, M., LE GALL, D., Perfect reconstruction FIR filter banks: some properties and factorizations, **IEEE Transactions on Acoustics, Speech, and Signal Processing**, Volume 37, Issue 7, p.1057 – 1071, July 1989.

WEBSTER, J. G., **Medical Instrumentation: Application and Design**, 3rd edition, New York, John Wiley & Sons, 1998.

WILKINS, R. HODGKIN, J., LOPEZ, B. **Fundamentals Lung and Heart Sounds**, Third edition, Elsevier, 2004.

WORLD HEALTH ORGANIZATION, “Data and statistics“
<http://www.who.int/research/en/>, Acesso em 04/2008.

APÊNDICE I

Interfaces do *Software* desenvolvido para Cálculo e avaliação por espectrogramas.

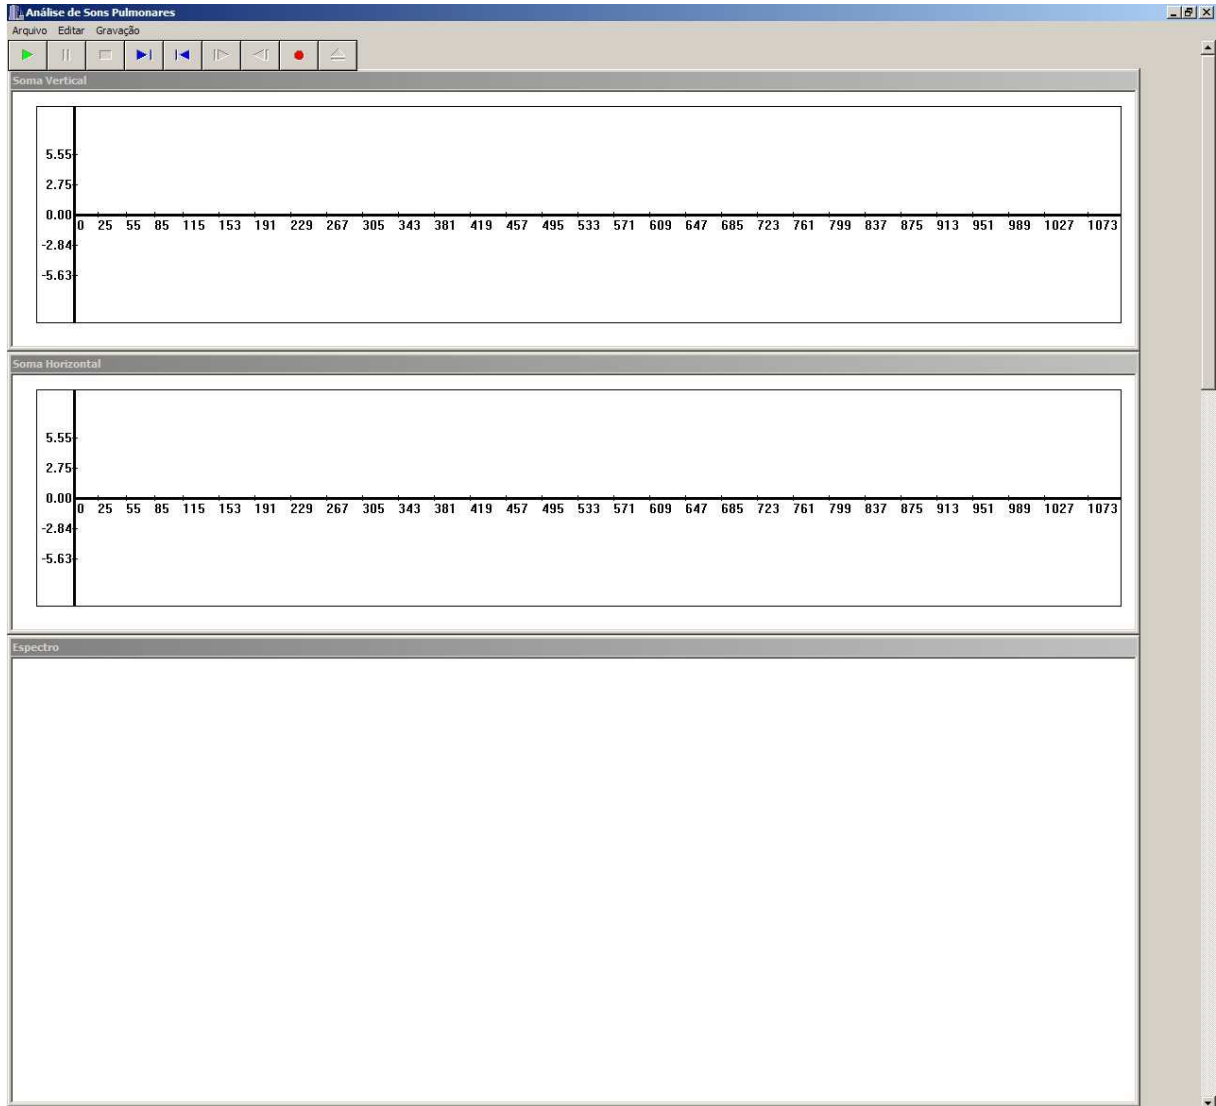


Figura 79 – Tela inicial do *Software* de Cálculo e avaliação por espectrogramas. Este software foi atualizado a partir do software de reconhecimento de sibilos (RIELLA, 2004).

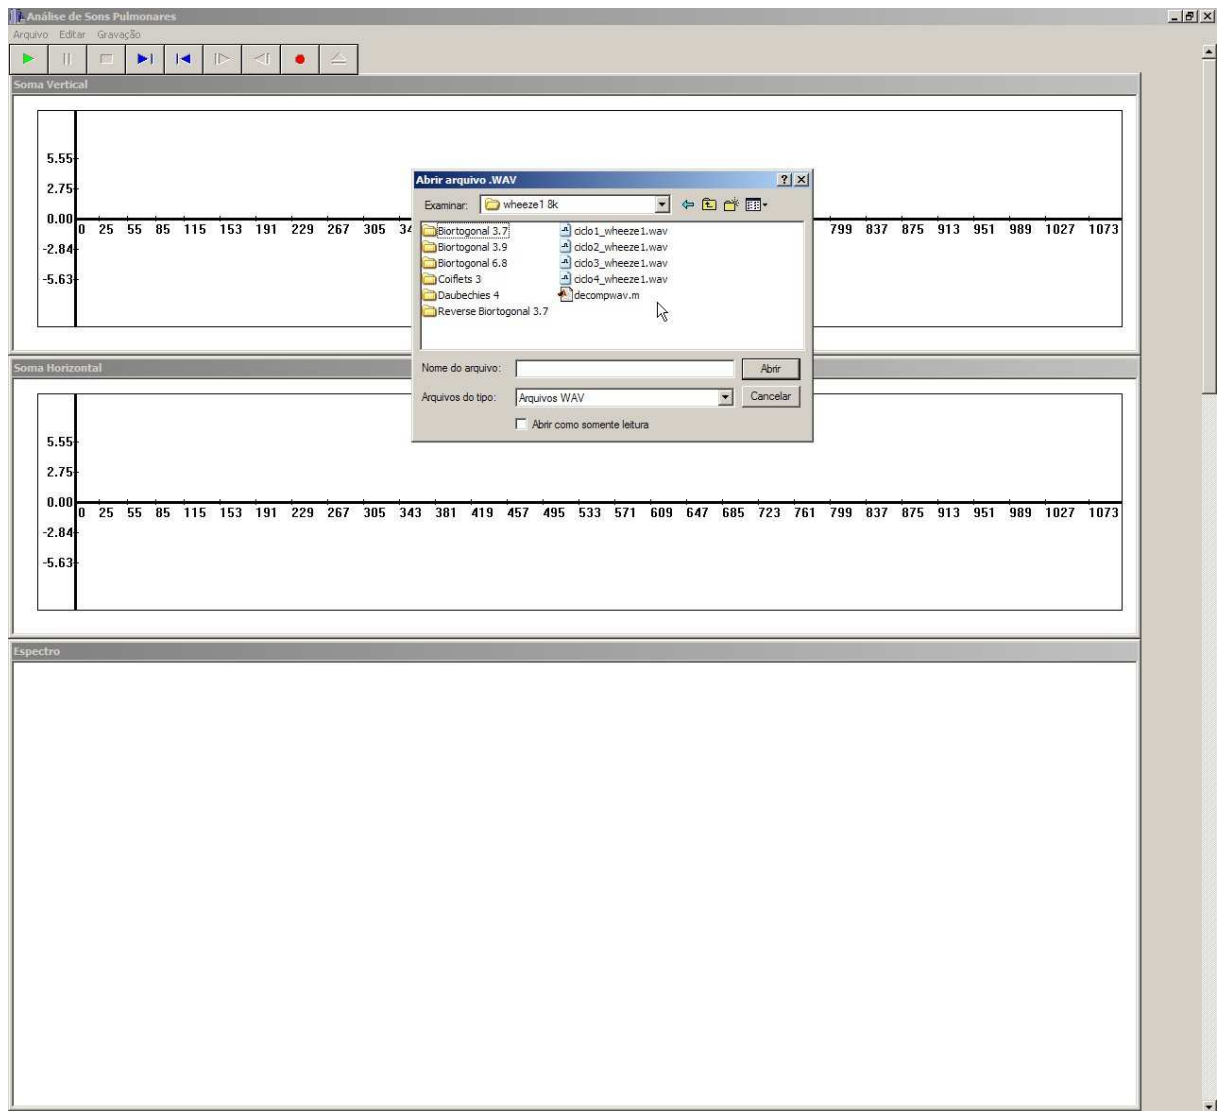


Figura 80 – Interface de abertura de arquivos de áudio wave do *Software* de Cálculo e avaliação por espectrogramas.

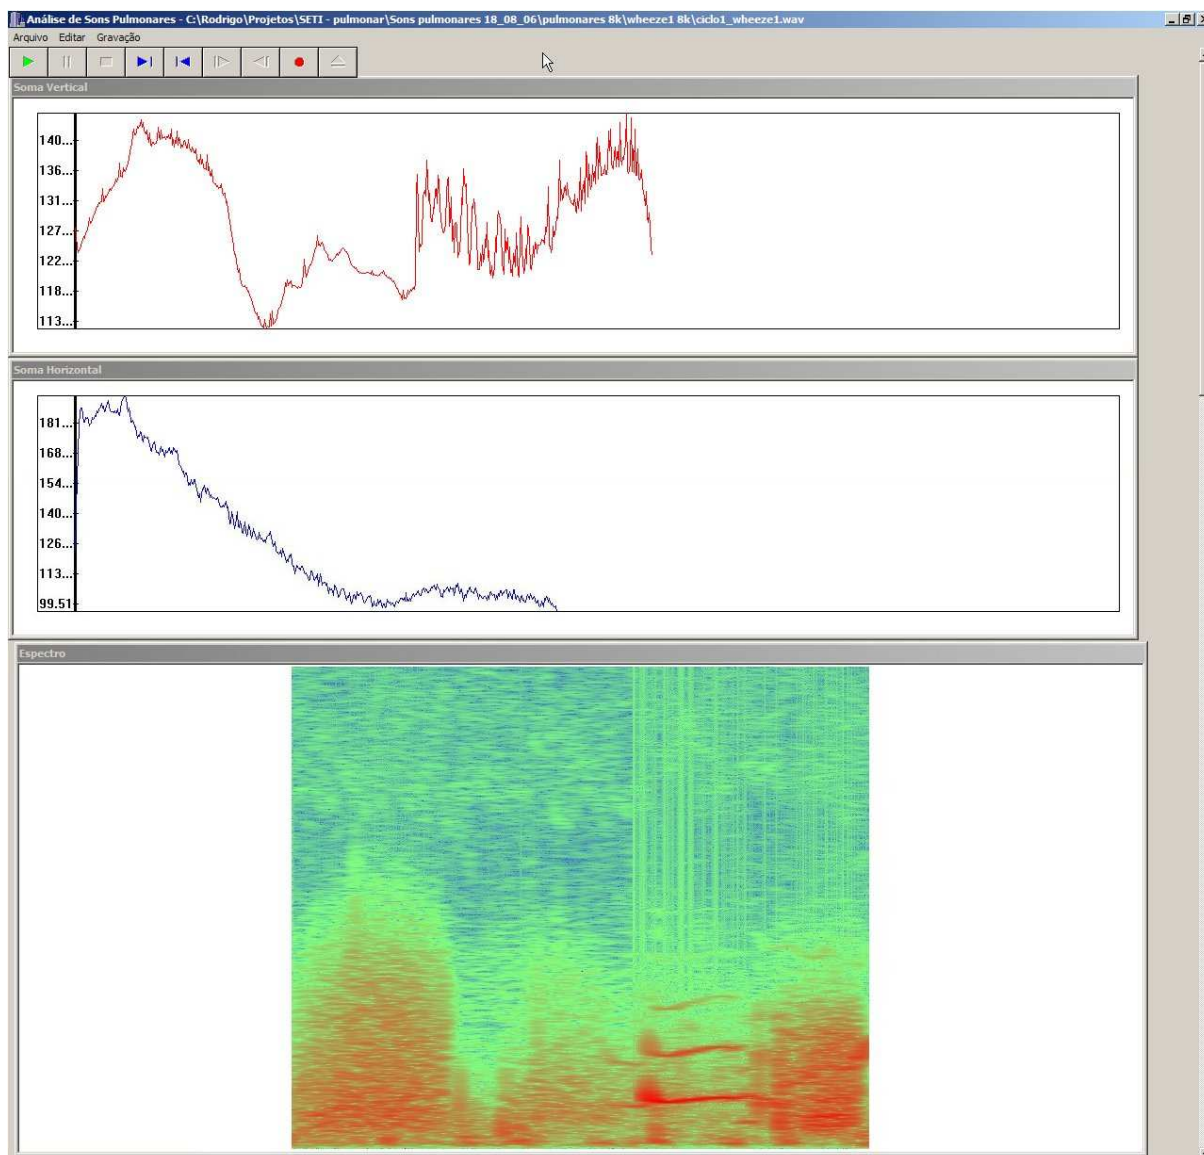


Figura 81 – Visualização do espectrograma de um ciclo respiratório com sibilos. Os gráficos superiores referem-se à projeção horizontal, em vermelho e vertical, em azul, do espectrograma.

APÊNDICE II

Interfaces do *Software* desenvolvido para análise dos sons pulmonares através de Análise em Multiresolução e cálculo da energia contida em cada nível de decomposição.

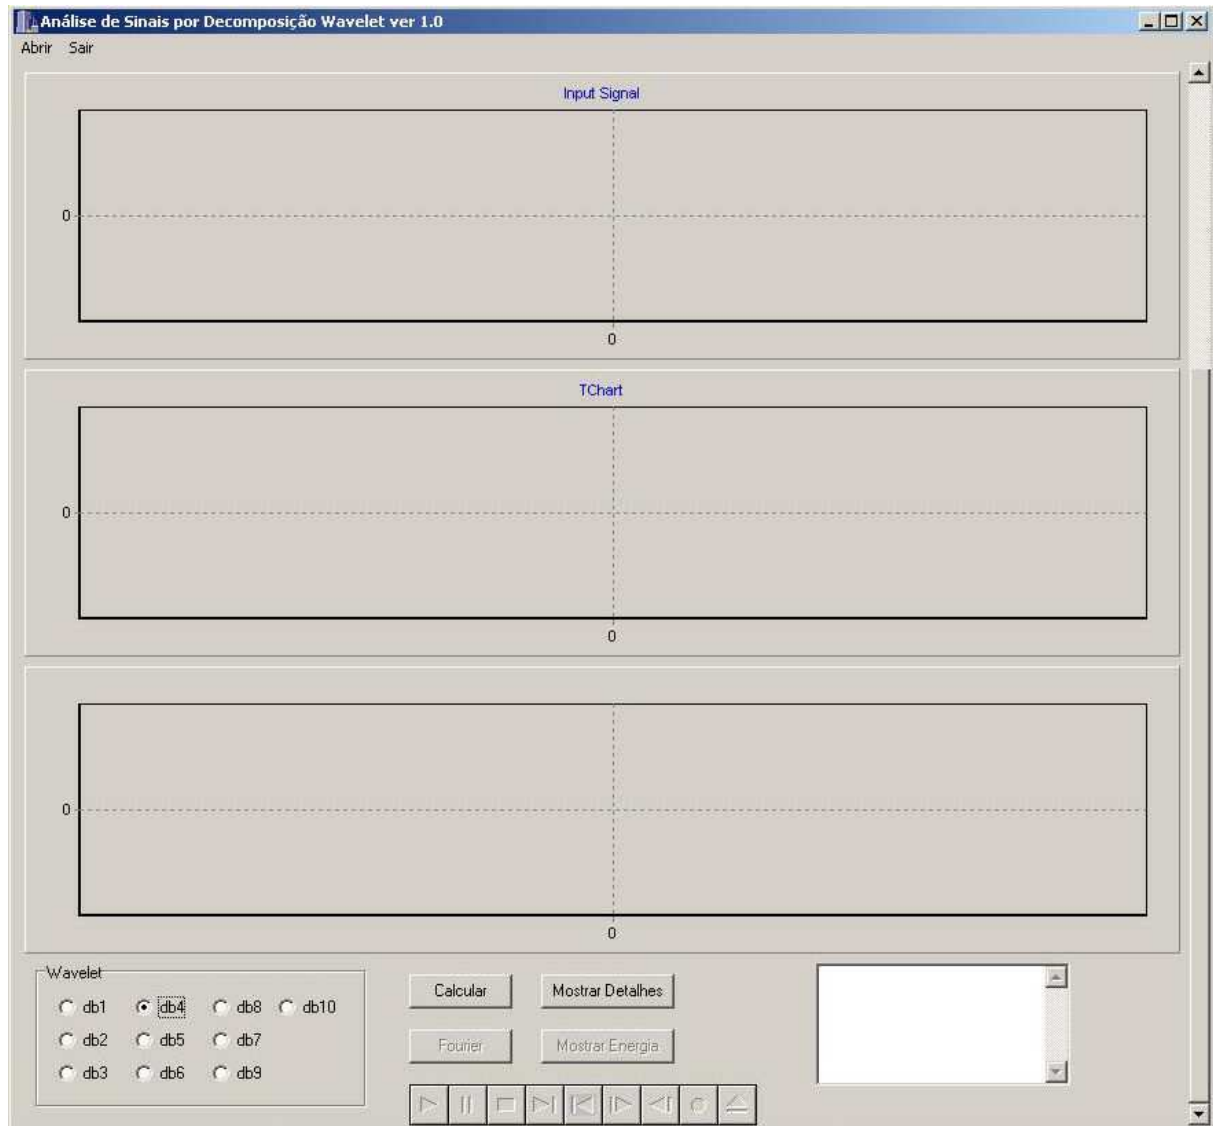


Figura 82 – Tela inicial do *Software* de análise de sons pulmonares por MRA.

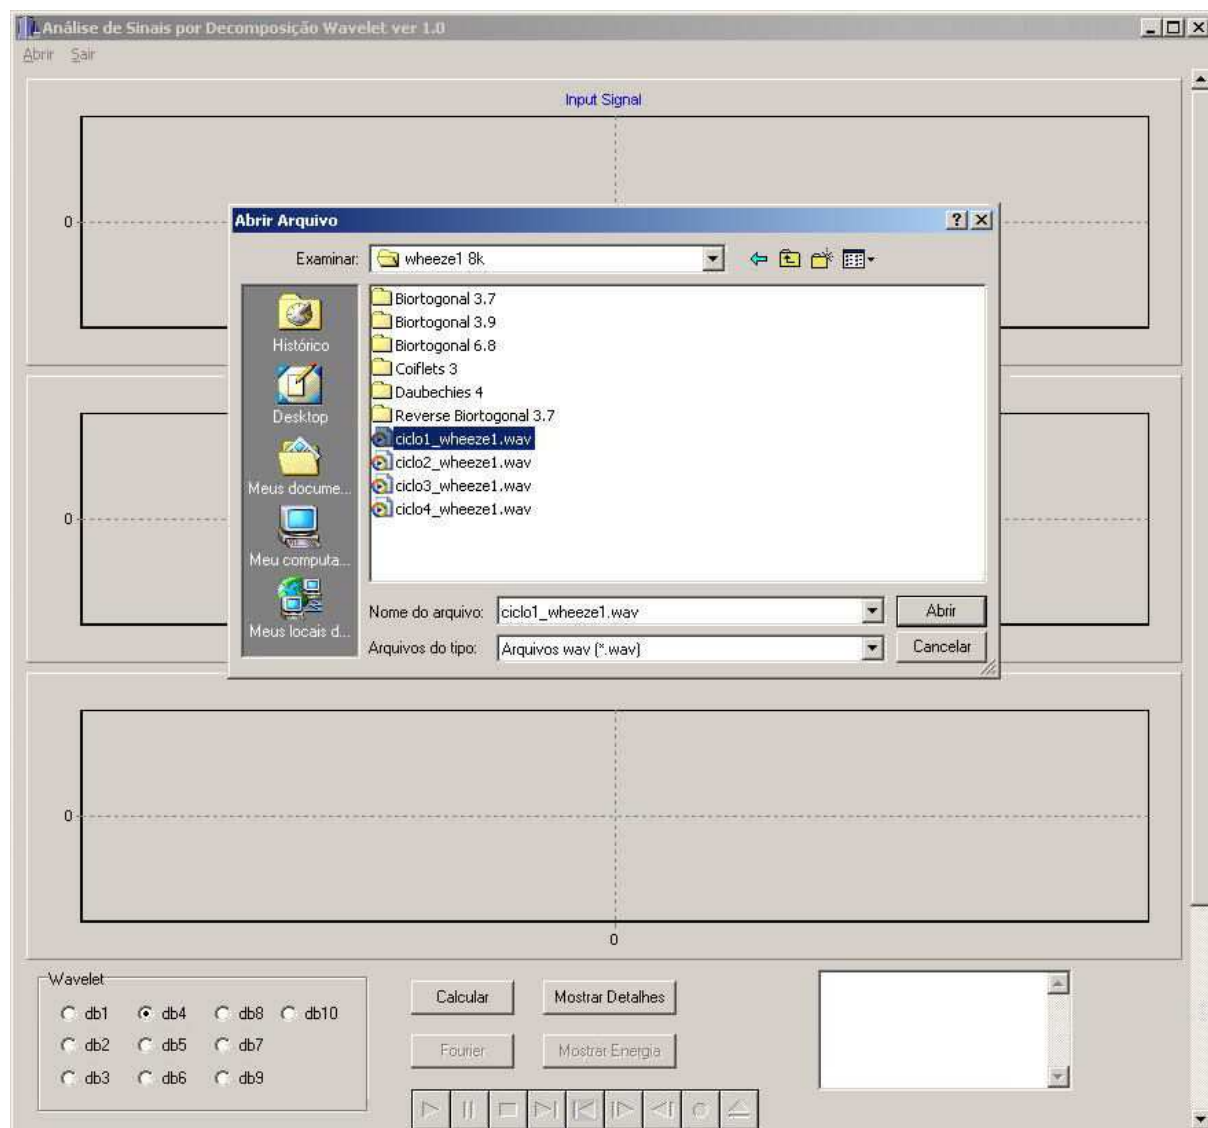


Figura 83 – Interface de abertura de arquivos de áudio padrão wave do Software de análise por MRA.

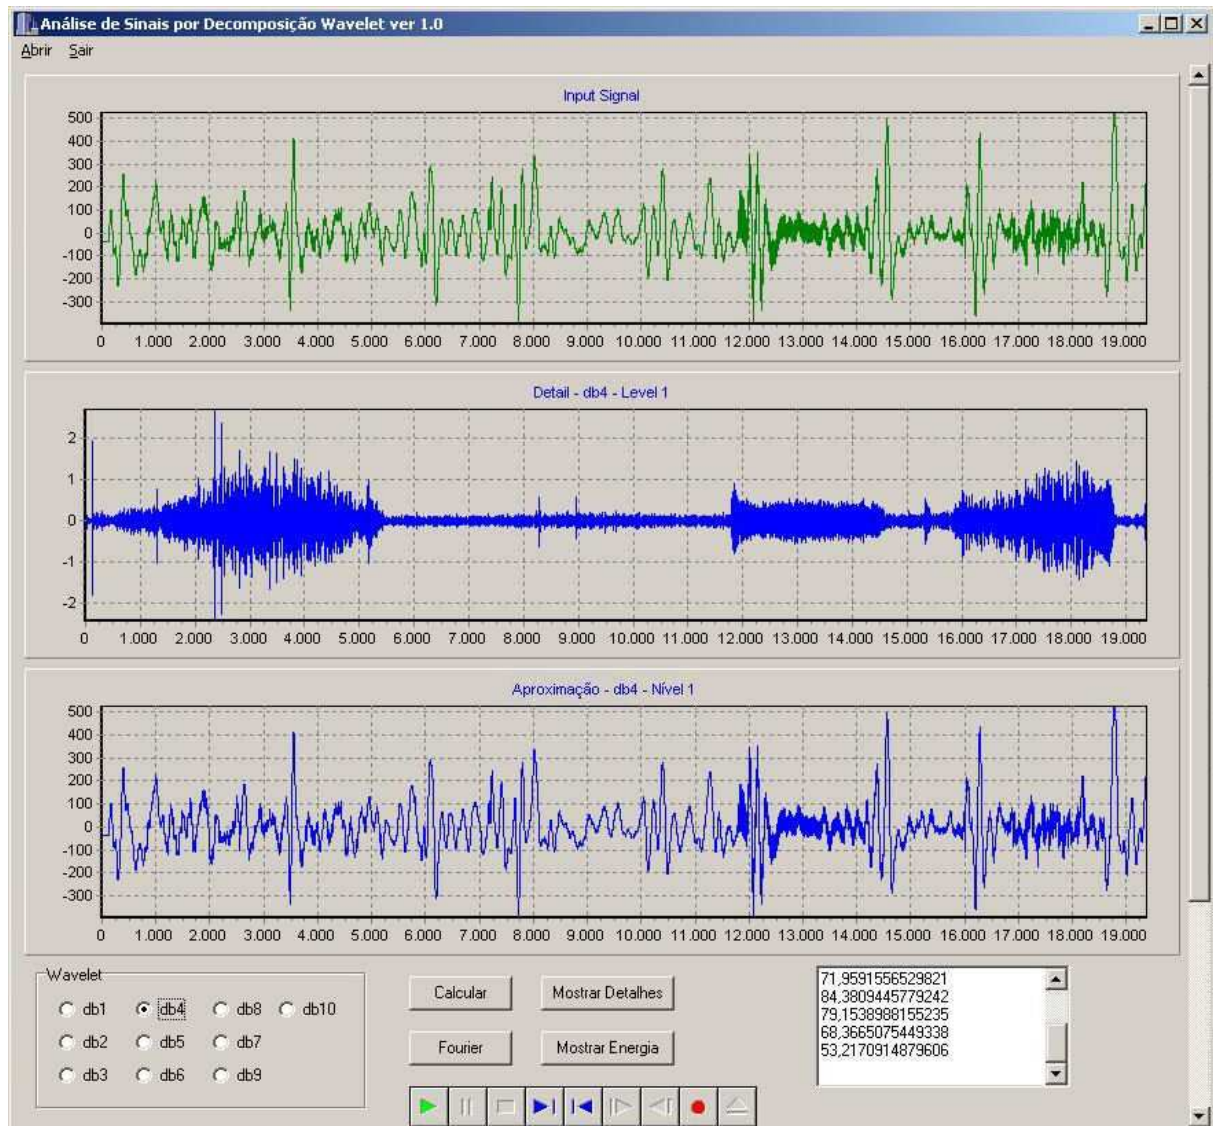


Figura 84 – Primeiro nível de decomposição de um ciclo respiratório contendo sibilos. No gráfico superior são desenhados o sinal original e reconstruído, para testes do algoritmo MRA.

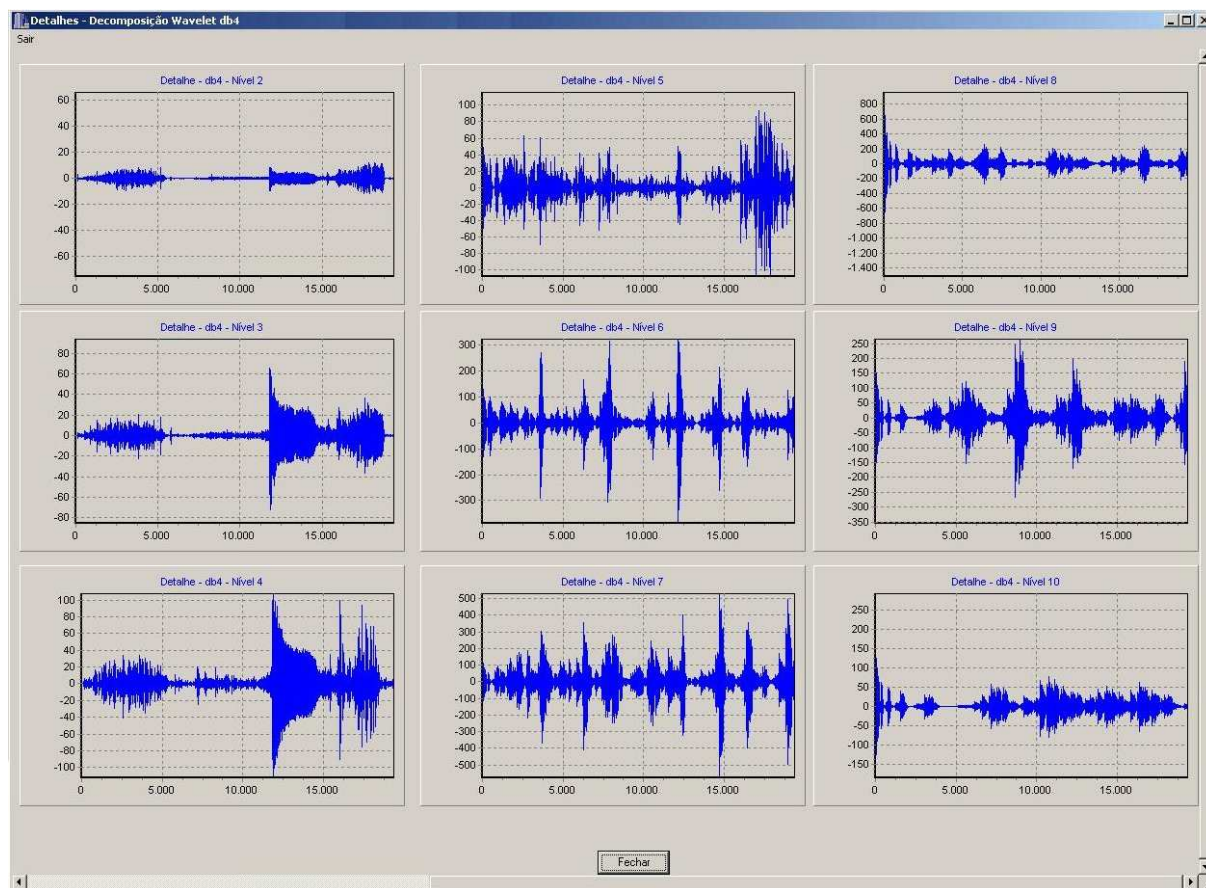


Figura 85 – Visualização dos próximos nove níveis de decomposição do som ciclo respiratório.

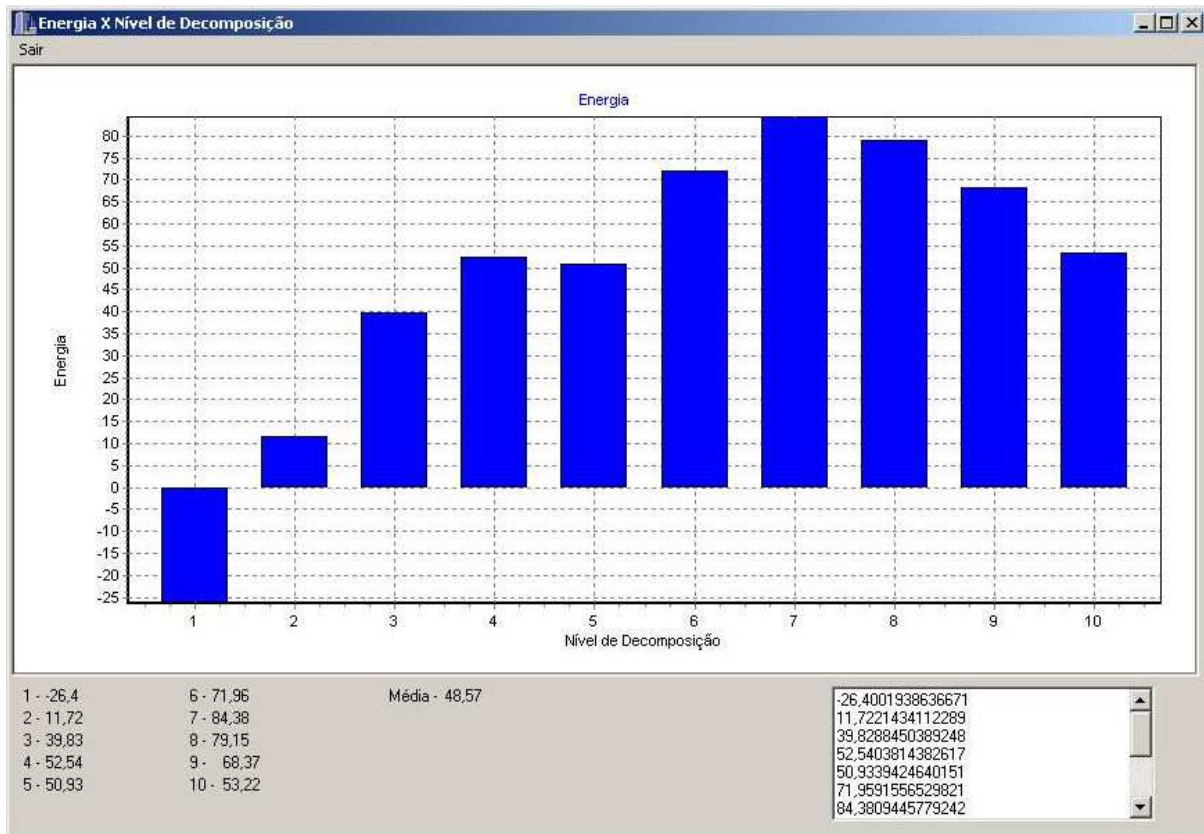


Figura 86 – Visualização da curva de energia em relação ao nível de decomposição. A tabela no canto inferior direito possibilita a exportação dos dados para outro aplicativo.

APÊNDICE III

Interfaces do *Software* desenvolvido para treinamento e avaliação de redes neurais MLP. Este *software* foi utilizado nas primeiras avaliações do método de classificação dos sons adventícios.

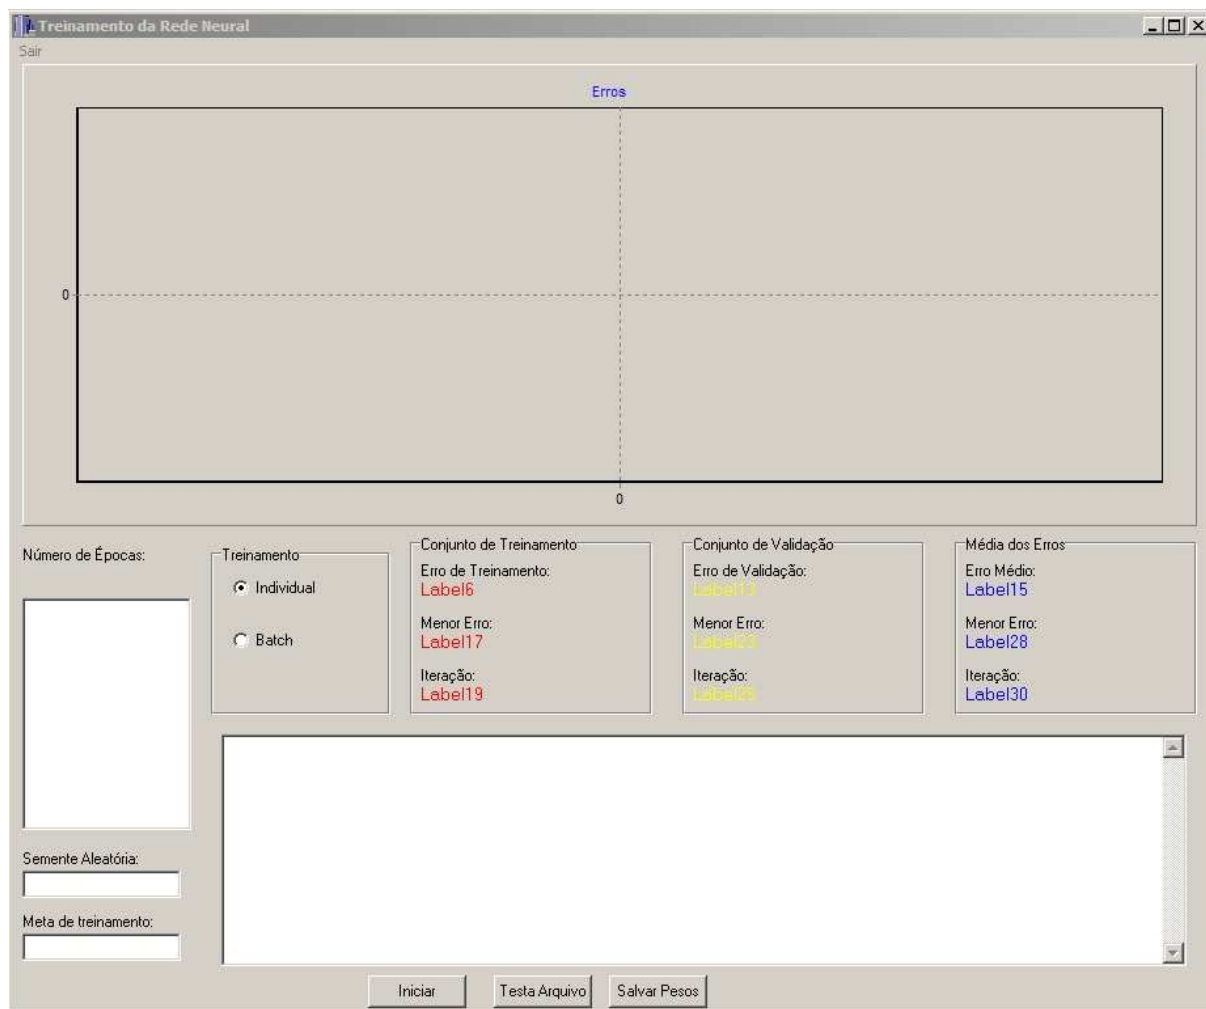


Figura 87 – Tela inicial do *Software* de *Software* de treinamento e avaliação de Redes Neurais MLP.

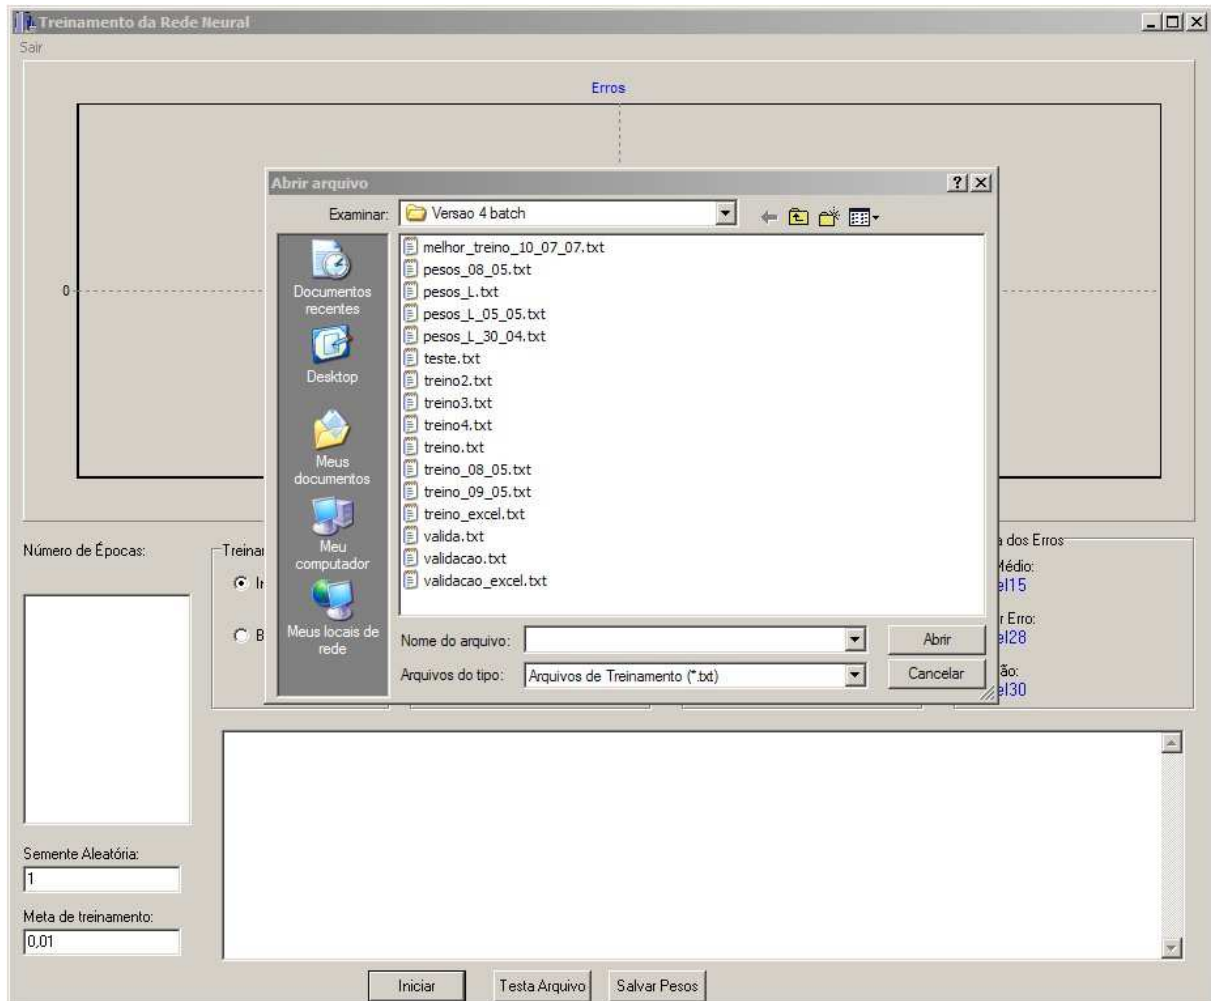


Figura 88 – Interface de abertura de arquivos contendo os conjuntos de treinamento e validação para o treinamento da rede neural. Uma vez abertos os arquivos, o software inicia o treinamento, atualizando os gráficos e tabelas ao fim de cada época de treinamento.

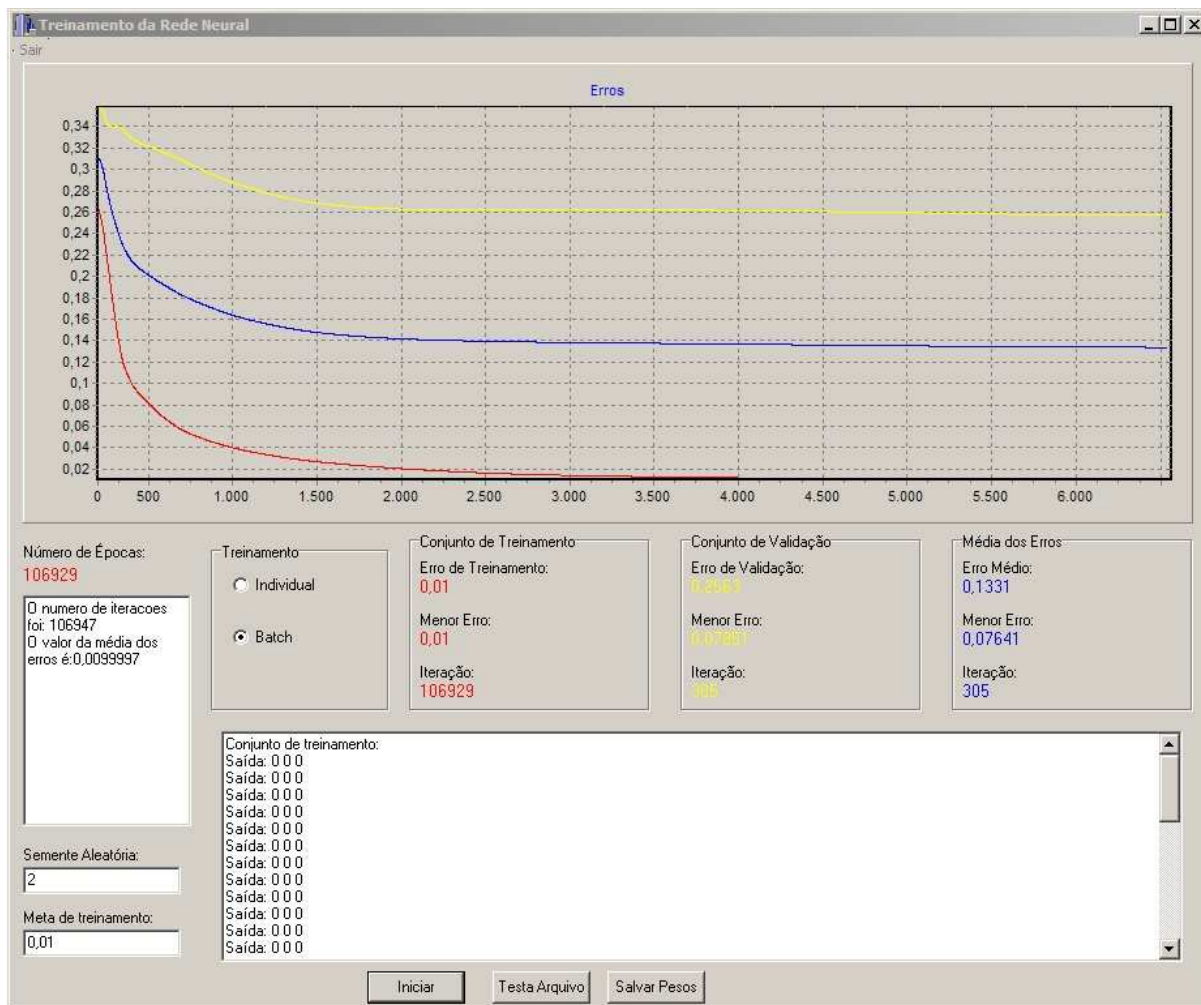


Figura 89 – Finalização do treinamento da rede neural MLP. Neste ponto, observam-se as curvas de evolução do erro para os conjuntos de treinamento e validação. Após o fim do treinamento, é possível salvar os pesos da rede neural em um arquivo texto, clicando sobre o botão “Salvar Pesos”.

APÊNDICE IV

Tabela 9 - Matriz de acerto total na classificação para cada função *wavelet* e abertura da função de base radial utilizada na simulação de rede neural.

Abertura da RBF	Bior			Coif 3	db 4	db 44	dmey	rbior		
	3.7	3.9	6.8					3.7	Sym 8	Sym 20
1	53,45	53,45	53,45	53,45	53,09	53,45	53,45	53,45	53,45	53,45
2	53,45	53,45	53,45	53,45	53,09	53,45	25,82	53,45	53,45	25,45
3	32,73	25,82	25,82	32,73	37,09	32,00	27,64	32,00	32,36	25,82
4	39,27	54,91	38,55	27,27	33,45	25,82	40,36	37,82	38,91	34,55
5	56,73	56,73	57,09	41,82	30,18	54,55	41,09	28,00	36,36	40,36
6	60,36	60,36	33,09	62,91	41,09	57,09	36,36	37,09	39,64	33,09
7	65,82	64,00	37,82	67,64	43,64	30,91	68,00	34,91	45,09	36,73
8	54,91	67,64	44,36	56,00	49,82	62,91	73,09	45,45	44,36	66,18
9	60,73	59,27	48,00	75,27	42,55	66,91	76,73	56,00	48,00	71,64
10	66,18	60,36	72,00	64,00	72,00	70,55	79,27	61,45	77,82	76,36
11	63,27	66,18	82,91	82,18	75,27	74,91	82,18	62,55	83,27	80,36
12	69,82	69,45	86,91	88,00	82,91	81,09	84,36	66,55	88,73	83,64
13	73,45	72,36	75,27	89,09	84,36	84,36	85,45	70,18	90,91	85,45
14	76,36	76,36	89,09	89,09	85,09	88,00	86,18	75,64	89,82	84,36
15	80,73	68,00	89,82	89,45	84,36	89,45	84,73	77,45	89,45	84,73
16	80,00	69,82	90,18	89,82	85,09	88,00	83,27	91,27	88,73	85,09
17	82,18	63,27	87,64	89,82	84,73	87,64	82,91	91,27	87,64	85,45
18	84,36	65,45	88,73	89,09	85,45	86,91	82,91	91,27	86,91	85,09
19	84,73	66,91	89,82	89,09	85,82	86,18	82,18	91,27	80,00	84,73
20	75,64	78,55	90,91	89,45	86,55	86,91	82,91	91,27	80,36	84,73
21	76,36	78,91	91,27	83,64	86,55	86,55	82,91	86,55	80,73	84,73
22	76,73	80,00	92,36	83,64	82,18	85,82	84,00	89,09	80,73	85,09
23	77,82	80,36	92,00	83,27	81,82	85,82	84,73	89,09	81,09	85,45
24	77,82	81,09	92,00	83,64	83,27	85,82	82,18	90,18	81,09	84,73
25	78,18	81,45	92,36	83,64	83,64	84,00	82,55	83,27	81,09	84,73
26	78,55	81,82	92,36	84,00	84,00	84,36	83,64	83,64	81,09	84,73
27	88,00	81,82	88,00	84,00	84,36	84,36	83,64	83,64	81,09	84,00
28	87,27	81,82	88,73	83,64	84,73	85,09	84,36	84,00	80,73	84,36
29	86,91	82,18	88,36	84,00	85,09	85,09	84,36	84,00	80,73	84,36
30	77,09	82,18	88,00	84,00	85,82	85,82	84,73	84,36	80,73	84,36
31	76,73	82,55	88,00	84,36	85,82	86,55	84,73	84,36	80,73	84,36
32	76,73	82,91	92,00	84,00	85,82	86,55	84,73	84,36	80,73	85,09
33	76,00	82,18	91,64	83,64	85,82	86,55	84,73	84,36	81,45	85,45
34	76,00	82,55	90,91	83,64	85,09	86,55	84,73	84,73	81,45	85,45
35	76,36	82,55	90,18	83,64	85,45	86,55	84,73	86,55	81,09	85,45
36	76,00	81,09	90,18	84,00	85,82	86,18	84,73	86,91	80,36	85,09
37	76,00	80,73	88,73	84,36	85,82	86,18	84,73	86,91	80,36	85,45
38	75,64	81,09	88,73	83,64	85,82	86,91	85,09	86,91	80,36	85,45
39	75,64	81,82	88,00	83,64	85,82	87,27	85,45	86,91	80,00	85,45
40	76,00	82,55	87,64	84,00	86,18	87,27	85,09	86,18	79,64	85,82
41	76,00	82,91	86,55	83,64	86,18	87,27	84,73	86,18	79,64	85,45
42	74,91	83,27	88,36	83,27	85,45	88,00	84,36	86,55	79,64	85,45
43	74,55	83,27	89,09	82,55	85,09	88,73	84,36	87,64	79,27	85,45
44	73,45	82,91	89,09	82,55	85,45	88,73	84,00	87,64	78,91	85,45
45	81,45	82,91	86,91	82,91	85,82	88,73	84,00	88,36	78,18	85,82
46	80,00	82,55	86,55	82,55	85,45	88,73	84,00	89,09	78,55	86,18
47	79,64	82,55	86,55	82,18	84,36	88,36	83,27	88,73	78,91	86,18
48	80,36	72,36	86,91	82,18	83,27	87,64	82,91	89,09	78,91	86,55

49	80,36	72,73	86,18	82,55	83,27	87,64	82,91	88,73	79,64	86,91
50	80,00	73,09	86,18	82,55	83,27	87,64	82,91	89,45	80,00	87,64
51	80,00	73,09	86,18	82,55	83,27	87,64	82,55	89,45	80,00	87,64
52	80,00	72,73	86,18	82,91	83,27	88,00	82,91	89,45	79,27	87,64
53	85,82	72,73	86,18	82,91	83,27	88,36	82,55	89,45	79,27	87,27
54	85,82	73,45	86,18	82,91	82,91	87,64	81,82	89,45	80,73	87,27
55	86,18	72,73	86,18	82,91	82,55	87,27	81,82	89,09	80,36	87,64
56	85,82	72,73	77,45	82,91	82,18	88,00	81,82	89,09	81,09	87,64
57	85,82	72,00	77,45	82,91	81,82	88,00	81,45	89,45	81,09	87,27
58	85,82	72,00	77,45	82,55	81,82	88,73	81,45	89,09	81,45	88,00
59	85,45	69,82	77,09	82,55	81,45	88,00	81,82	88,73	82,18	88,00
60	85,45	69,45	76,73	82,55	81,45	88,00	82,18	89,09	82,18	88,00
61	85,82	81,82	77,82	82,18	81,09	88,00	82,18	88,73	82,18	87,64
62	85,82	81,82	77,45	82,18	80,73	88,00	82,18	89,09	82,55	87,64
63	85,82	81,45	77,09	82,18	80,36	88,00	81,82	89,09	83,27	87,64
64	85,82	80,36	76,73	81,82	80,36	88,00	82,18	89,09	82,91	87,64
65	85,82	80,00	76,73	81,82	79,64	87,27	82,18	89,09	83,27	87,64
66	78,91	80,36	77,09	81,82	78,18	87,27	82,18	89,09	83,27	87,64
67	78,18	80,00	77,09	81,82	77,82	87,27	81,82	89,09	83,27	87,27
68	78,18	80,00	76,73	81,82	77,45	86,55	81,45	89,09	83,27	87,27
69	77,82	80,00	76,36	81,82	77,09	86,18	81,09	89,09	82,91	87,27
70	77,82	79,64	76,00	81,09	77,09	86,18	80,73	89,09	82,91	87,27
71	77,82	80,00	76,00	81,09	77,45	86,18	80,36	89,09	83,27	86,91
72	77,82	79,64	76,00	80,36	77,45	85,82	80,00	92,00	83,27	86,91
73	76,73	79,64	76,00	80,00	77,45	85,45	80,00	92,00	83,27	86,91
74	76,36	79,64	76,00	80,00	77,45	85,45	80,00	91,64	83,27	86,91
75	75,64	79,27	75,64	80,00	77,45	85,45	79,64	91,27	83,27	86,91
76	75,64	79,27	75,64	80,00	77,45	85,45	79,64	91,27	83,27	86,91
77	75,64	79,27	75,64	79,27	77,45	85,45	79,64	91,27	83,27	86,91
78	75,27	79,27	75,64	79,27	77,09	85,45	79,64	91,27	83,64	87,27
79	84,73	78,55	75,27	79,27	77,09	85,09	79,27	91,27	83,27	87,27
80	85,09	78,55	75,27	78,91	77,09	85,09	78,91	91,27	82,91	87,27
81	85,09	78,18	75,27	78,91	77,09	85,09	78,55	91,27	82,91	87,27
82	85,09	78,18	75,27	78,91	76,73	84,73	78,55	90,91	82,91	87,27
83	84,36	77,82	75,27	78,55	76,73	84,00	81,09	86,18	83,27	87,27
84	84,36	77,82	75,27	78,18	77,09	83,27	81,09	86,18	83,27	87,27
85	84,00	77,82	75,64	78,18	76,73	83,27	81,09	86,18	83,27	87,27
86	84,00	77,82	75,64	77,82	76,73	82,91	81,09	89,82	83,27	87,27
87	84,00	77,82	75,27	77,82	76,73	82,91	81,09	89,45	83,27	87,27
88	84,00	77,82	74,91	77,82	76,73	82,55	81,09	89,45	82,91	87,27
89	84,36	77,82	74,91	77,82	76,73	82,55	81,09	89,45	82,91	87,27
90	84,36	78,18	75,27	77,82	76,36	82,55	80,73	89,09	82,55	87,27
91	84,36	78,18	75,27	80,00	76,36	82,18	81,09	86,18	82,91	86,55
92	84,36	78,18	75,27	80,00	76,36	81,82	80,73	85,82	82,91	86,55
93	84,36	77,82	75,27	78,18	76,36	81,82	80,73	85,09	82,55	86,55
94	84,36	77,82	74,91	78,18	76,36	81,45	80,36	84,36	82,55	86,55
95	84,00	77,82	74,91	78,18	76,36	81,45	80,36	84,36	82,55	86,55
96	84,00	77,82	74,18	78,18	76,36	80,73	80,36	84,36	82,55	86,55
97	84,00	77,82	74,18	78,91	76,36	80,73	80,36	84,00	82,55	86,55
98	84,00	77,45	73,82	78,91	76,36	81,09	80,36	84,00	82,55	86,55
99	84,73	77,09	73,82	78,91	76,36	81,09	80,36	84,00	82,55	86,55
100	84,73	76,36	73,82	78,91	76,36	80,73	80,36	83,64	82,55	86,55

RESUMO

Nesta tese, descrevem-se técnicas matemáticas visando a caracterização e classificação de sons pulmonares adventícios, por meio de sua análise espectral. Para alcançar este objetivo, desenvolveu-se duas novas metodologias, que utilizam Análise em Multiresolução, implementada a partir da Transformada Wavelet Discreta. A primeira metodologia desenvolvida é utilizada para classificar automaticamente os sons pulmonares em quatro grupos: sons normais e sons adventícios contínuos e descontínuos, notificando também o caso de ocorrência das duas anomalias no mesmo ciclo respiratório. Durante o processamento, o ciclo respiratório é decomposto até seu décimo nível, calculando a energia dos coeficientes detalhe em cada nível de decomposição, assim como a energia dos coeficientes de aproximação. Deste cálculo, obtém-se uma curva de variação da energia em relação ao nível de decomposição, sendo que as curvas obtidas se mostraram curvas características em relação ao tipo de som adventício. Tais curvas são aplicadas a uma simulação de Rede Neural Artificial de Função de Base Radial, que atua como classificador entre os quatro grupos. Esta técnica foi testada utilizando dez wavelets, sendo treinadas cem redes neurais para cada uma. Os melhores resultados apresentaram índice de acerto entre 88% e 92,36% para o conjunto de teste, em um total de 275 ciclos respiratórios. A segunda metodologia, denominada Filtragem por Análise Espectral Seletiva, decompõe o som pulmonar até seu quarto nível, calculando o espectro dos coeficientes aproximação e, baseado na componente de frequência preponderante, calcula um filtro FIR multibanda. Este filtro é utilizado para eliminar todas as componentes espectrais dos coeficientes de aproximação, com exceção do mais proeminente. Após o procedimento de filtragem, o sinal é recomposto através de reconstrução wavelet. Para a avaliação de seus resultados, foram testadas dez wavelets no processo de decomposição e reconstrução. Para a wavelet que apresentou melhores resultados, obteve-se uma atenuação dos sons cardíacos da ordem de 6 dB em relação aos sons adventícios que ocorrem na mesma faixa espectral, utilizando a Densidade Espectral de Potência dos sinais como referência. Esta metodologia mostrou resultados satisfatórios na tarefa de eliminar tanto os ruídos relativos ao fluxo aéreo normal nas vias aeríferas quanto os sons cardíacos, mantendo somente os sons adventícios nas gravações de sons pulmonares.

PALAVRAS-CHAVE

Sons Pulmonares, Transformada *Wavelet*, Redes Neurais Artificiais, Filtragem Digital.

ÁREA/SUB-ÁREA DO CONHECIMENTO

3.13.00.00-6: Engenharia Biomédica
3.13.01.01-0: Processamento de Sinais Biológicos
1.03.00.00-7: Ciência da Computação

2008

N. 38