

UNIVERSIDADE FEDERAL DE ALAGOAS
CENTRO DE CIÊNCIAS EXATAS E DA NATUREZA
INSTITUTO DE COMPUTAÇÃO
Pós-Graduação em Modelagem Computacional de Conhecimento

**ANÁLISE DE SINAIS PULMONARES UTILIZANDO TÉCNICAS NO DOMÍNIO
TEMPO-FREQÜÊNCIA E CLASSIFICAÇÃO NEURAL**

Alberto Jorge Santos de Almeida

Maceió/AL

2010

ALBERTO JORGE SANTOS DE ALMEIDA

**ANÁLISE DE SINAIS PULMONARES UTILIZANDO TÉCNICAS NO DOMÍNIO
TEMPO-FREQÜÊNCIA E CLASSIFICAÇÃO NEURAL**

Dissertação apresentada ao Programa de Pós-graduação em Modelagem Computacional de Conhecimento do Instituto de Computação da Universidade Federal de Alagoas como requisito parcial para obtenção do grau de Mestre em Modelagem Computacional.

Orientador: **Prof. Dr. Luís Cláudius Coradine**

Co-orientadora: **Prof^ª. Dra. Roberta Vilhena Vieira**

Maceió//AL
2010

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico
Bibliotecária Responsável: Helena Cristina Pimentel do Vale

A447a Almeida, Alberto Jorge Santos de.
Análise de sinais pulmonares utilizando técnicas no domínio tempo-frequência e
classificação neural / Alberto Jorge Santos de Almeida. – 2010.
xvii, 122 f. : il.

Orientador: Luís Cláudius Coradine.

Co-Orientadora: Roberta Vilhena Vieira.

Dissertação (mestrado em Modelagem Computacional de Conhecimento) –
Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2010.

Bibliografia: f. 94-97.

Apêndices. f. [98]-122.

1. Modelagem computacional. 2. Redes neurais (Computação). 3. Processamento
de sinais. 4. Sinais pulmonares . 5. Transformada Wavelt. I. Título.

CDU: 004.4

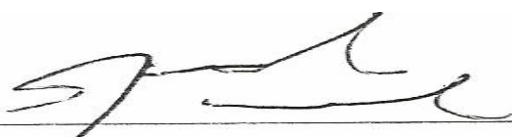
ALBERTO JORGE SANTOS DE ALMEIDA

**Análise de Sinais Pulmonares Utilizando Técnicas no Domínio Tempo-Frequência e
Classificação Neural**

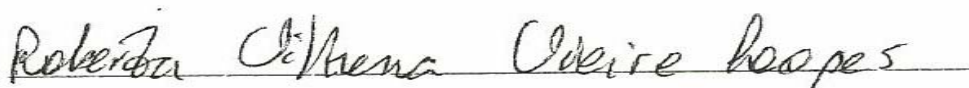
Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre em Modelagem Computacional de Conhecimento pelo Programa multidisciplinar de Pós-Graduação em Modelagem Computacional de Conhecimento da Universidade Federal de Alagoas.

Maceió/AL, 25 de novembro de 2010

BANCA EXAMINADORA



Prof. Dr. Luis Cláudius Coradine
UFAL – Instituto de Computação
Orientador



Prof.ª Dra. Roberta Vilhena Vieira Lopes
UFAL – Instituto de Computação
Co-Orientadora



Prof. Dr. Antonio Fernando de Souza Bezerra
UFAL – Faculdade de Medicina



Prof. Dr. João Marcos Travassos Romano
Unicamp - FEEC

Dedico este trabalho a minha mãe e esposa.

AGRADECIMENTOS

A conclusão deste trabalho só foi possível devido à colaboração de muitas pessoas e ao apoio de algumas instituições:

Ao professor Luís Cláudius Coradine pela orientação, confiança, apoio, incentivo, e sobretudo pela compreensão, sem os quais eu jamais teria concluído este trabalho.

A Professora Roberta Vilhena Vieira, da Universidade Federal de Alagoas – UFAL, pela co-orientação, confiança e apoio mostrando uma visão crítica de meu trabalho.

As professoras Ana Lúcia, Patrícia e Cintia pela colaboração em meu trabalho.

Aos amigos do CESMAC, professores Jarbas Andrade, Antônio Ricardo, Pedro, Sandra Marcia Cartaxo, Adriana Lopes pela orientação e incentivo.

Ao Professor Romis Attux pelas críticas e sugestões.

Aos amigos da UFAL, Marcos Machado, Paulo Coutinho, Roberto Correia e Andrilene.

Às Bibliotecárias Maria Helena Mendes Lessa e Helena Cristina Pimentel do Vale.

A imaginação é mais importante que o conhecimento.

A.. Einstein.

RESUMO

A ausculta é um método da prática clínica, simples, não invasivo, utilizado no diagnóstico de doenças do sistema respiratório. Porém, trata-se de um método impreciso devido, entre outros fatores, às limitações do sistema auditivo, a sobreposição de sons cardíacos e a diferença de sensibilidade auditiva humana, além da característica de resposta espectral limitada de muitos estetoscópios comerciais. Tais fatores contribuem para que o diagnóstico dependa muito da experiência do profissional especialista. A análise acústica de características espectrais de sinais da ventilação pulmonar pode ser uma técnica complementar de diagnóstico, facilitando o processo de detecção e identificação desses sons respiratórios, possibilitando auxiliar a avaliação da gravidade dos sintomas e a eficácia do tratamento. Neste trabalho, buscou-se estruturar um processo de análise de sinais pulmonares, para a identificação de características das patologias respiratórias. Nesse sentido, os sinais foram tratados por processos de filtragem e decompostos em sub-bandas de frequências através da Transformada de *Wavelet* Discreta (DWT), gerando vetores como coeficientes para classificação utilizando uma Rede Neural Artificial. Um estudo de caso com sinais obtidos por testes foi apresentado e devidamente analisado.

Palavras-Chaves: Sinais Pulmonares. Transformada *Wavelet*. Redes Neurais.

ABSTRACT

Auscultation is a method of clinical practice, simple, noninvasive, used to diagnose diseases of the respiratory system. However, it is an imprecise method because, among other factors, the limitations of the auditory system, the overlap of heart sounds and human hearing sensitivity difference, besides the limited spectral response characteristic of many commercial stethoscopes. These factors contribute to the diagnosis relies heavily on the experience of the professional expert. The acoustic analysis of spectral characteristics of signals of ventilation can be a complementary diagnostic technique in facilitating the process of detection and identification of breath sounds, providing aid in the assessment of symptom severity and treatment efficacy. In this study, we attempted to structure a process of analysis of pulmonary signs to identify characteristics of respiratory disorders. Accordingly, the signals were processed by filtering processes and decomposed into sub-frequency bands through discrete wavelet transform (DWT), generating vectors as coefficients for classification using an Artificial Neural Network. A case study with signals obtained from tests was presented and duly considered.

Key Words: Signs Lung. Wavelet Transform. Neural Networks

LISTAS DE FIGURAS

Figura 1 - Representação dos órgãos do sistema respiratório.....	7
Figura 2 - Representação do pulmão.....	8
Figura 3 – Representação dos alvéolos pulmonar.....	9
Figura 4 - Representação da inspiração e expiração pulmonar.....	10
Figura 5 - Representação do estetoscópio mecânico.....	12
Figura 6- Representação do Espirômetro.....	13
Figura 7- Representação gráfica de um exame de espirometria.....	14
Figura 8 - Imagem radiográfica utilizando raio X.....	14
Figura 9- Representação do ouvido humano.....	15
Figura 10 - Réplica do estetoscópio criado por Laënnec.....	17
Figura 11- Modelos de estetoscópios propostos após Laënnec.....	17
Figura 12- Réplica do estetoscópio criado por Arthur LeaRed , 1851.....	18
Figura 13 - Estetoscópio mecânico detalhado.....	19
Figura 14 – Representação da campânula de um estetoscópio.....	19
Figura 15 - Sensor diafragma.....	20
Figura 16- Representação do estetoscópio eletrônico.....	21
Figura 17- Estetoscópio com comunicação Bluetooth.....	22
Figura 18 - Gráfico de sensibilidade auditiva.....	24

Figura 19- Curva da sensibilidade auditiva em função da idade.....	25
Figura 20-Representação de um sinal pulmonar normal no domínio do tempo.....	26
Figura 21- Representação de um brônquio normal e em crise de asma.....	29
Figura 22 - Transformada direta e inversa.....	33
Figura 23 - Representação de um sinal quadrado e suas componentes.....	34
Figura 24 - Representação de um sinal quadrado e suas componentre bases.....	35
Figura 25 - Representação de um sinal senoidal no domínio do tempo e da freqüência.....	37
Figura 26a - Representação de um sinal estacionário.....	37
Figura 26b - Representação de um sinal não estacionário.....	38
Figura 27 - Gráfico de uma função Gaussiana.....	39
Figura 28 - Representação de uma função janelamento.....	39
Figura 29 - Efeito guassiano sobre uma função base senoidal.....	40
Figura 30 - Representação do janelamento de uma STFT.....	41
Figura 31 -Representação da análise com uma única resolução.....	44
Figura 32 - Problema da análise de resolução única.....	44
Figura 33 - Representação de uma <i>wavelet</i> de Morlet.....	45
Figura 34 - Representação da influência do parâmetro a de escala.....	47
Figura 35 - Representação da influência do parâmetro de translação b	47
Figura 36 - Relação tempo freqüência com janelamento variável.....	47
Figura 37 - Representação da decomposição do sinal.....	50

Figura 38 - Representação do processo de filtragem e decimação (L filtro passa-baixa e H filtro passa-alta).....	51
Figura 39 – Decomposição DWT em sub-bandas.....	52
Figura 40 - Representação gráfica da <i>wavelet</i> Harr com contração e deslocamento.....	53
Figura 41 – Representação de quatro modelos de Wavelet-mães da família Daubechies.....	54
Figura 42 - Representação tridimensional de um sinal através da transformada de <i>Wavelet</i>	55
Figura 43 - Representação de um cérebro humano.....	56
Figura 44 - Representação da estrutura básica de um neurônio cerebral.....	58
Figura 45- Representação de um neurônio artificial não-linear	59
Figura 46 - Representação de uma função limiar.....	60
Figura 47 - Representação de uma função linear.....	61
Figura 48 - Representação de uma função sigmóide.....	61
Figura 49 - Representação de algumas topologias para redes neurais: (A) estritamente feedforward, (B) feedforward com conexão direta entre a camada de entrada e saída, e (C) com realimentação.....	62
Figura 50 - Representação de uma rede neural de camada simples	63
Figura 51 - Representação de uma rede neural <i>multilayer</i>	64
Figura 52 – Representação da separabilidade linear.....	67
Figura 53 – Estrutura de uma rede <i>perceptron</i> de múltiplas camadas.....	68
Figura 54 - Diagrama de classificação de sons pulmonares.....	72
Figura 55 - Diagrama da rede neural MLP com 19 entradas, 89 neurônios e 3 saídas	76
Figura 56 - Representação dos vetores de entrada da RNA.....	77
Figura 57 – Teste de hipótese para pacientes com crepitação.....	82

Figura 58 – Teste de hipótese para pacientes com sibilo.....	83
Figura 59 - Sinais resultantes da decomposição <i>wavelet</i> de um ciclo respiratório sibilante.	85
Figura 60 - Sinais resultantes da decomposição <i>wavelet</i> de um ciclo respiratório crepitante.	86
Figura 61 - Representação da árvore de decomposição de um sinal sibilante.....	87
Figura 62 - Representação da árvore de decomposição de um sinal crepitante.....	87
Figura 63 - Representação da distribuição de energia: (a) crepitação e (b) sibilo.....	88

LISTA DE TABELAS

Tabela 1 - Recomendação da CORSA para capturas de sinais respiratórios.....	23
Tabela 2 - Terminologia dos sons adventícios segundo American Thoracic Society ATS.	27
Tabela 3 - Tabela de frequências em pacientes com asma antes a após tratamento.....	31
Tabela 4 - Pico de frequência em pacientes com crepitação.....	78
Tabela 5 - Pico de frequências em pacientes com sibilo.....	80
Tabela 6 - Relação entre os coeficientes e a faixa de frequência.....	84
Tabela 7 - Configuração de saída da rede neural.....	88
Tabela 8 - Resultado da classificação dos sinais com crepitação (C).....	89
Tabela 9 - Resultado da classificação dos sinais normais (N).....	89
Tabela 10 - Resultado da classificação dos sinais sibilante (S).....	89
Tabela 11 – Desempenho das redes consideradas.....	89

LISTA DE ABREVIATURAS E SIGLAS

CWT - *Continuous Wavelet Transform* (transformada *wavelet* contínua)

DFT - *Discrete Fourier Transform* (transformada discreta de Fourier)

DWT - *Discrete Wavelet Transform* (transformada *wavelet* discreta)

FFT - *Fast Fourier Transform* (transformada rápida de Fourier)

MLP - *MultiLayer Perceptron neural network* (rede neural perceptron multicamadas)

MRA - *Multiresolution Analysis* (análise em multiresolução)

STFT - *Short Time Fourier Transform* (transformada de Fourier de curta duração)

TF-WD *Time frequency-wheeze detector*

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Motivação da Dissertação	3
1.2	Objetivo da Dissertação	4
1.3	Metodologia	5
1.4	Organização da Dissertação	6
2	ASPECTOS GERAIS DA MONITORAÇÃO E VENTILAÇÃO PULMONAR	7
2.1	Pulmão	7
2.2	Patologias Pulmonares	10
2.3	Técnicas de diagnósticos	12
2.4	Audição	15
2.5	Ausculta pulmonar	16
2.6	Característica do receptor sonoro	21
2.7	Estetoscópio Eletrônico	21
2.8	Tecnologia Bluetooth	22
2.9	Eficiência dos Estetoscópios	22
2.10	Limitações da ausculta pulmonar	24
2.11	Sons pulmonares	25
2.12	Som Traqueal	26

2.13	Som Vesicular.....	27
2.14	Sons Anormais.....	27
2.15	Crepitação.....	28
2.16	Sibilo.....	29
2.17	Ronco.....	31
3	TÉCNICA PARA PROCESSAMENTO DE SINAIS BIOMÉDICOS.....	32
3.1	Introdução.....	32
3.2	Análise de Fourier.....	33
3.3	Transformada de Fourier.....	36
3.4	Transformada de Fourier de Tempo curto (STFT).....	37
3.5	Wavelet.....	40
3.5.1	Introdução.....	40
3.5.2	Evolução Histórica.....	42
3.5.3	Transformada de <i>Wavelet</i>	43
3.5.4	Propriedades.....	48
3.5.5	Transformada <i>Wavelet</i> Contínua (TWC).....	48
3.5.6	Transformada <i>Wavelet</i> Discreta (TWD).....	48
3.5.7	Análise de Multiresolução.....	50
3.5.8	Tipos de <i>Wavelet</i>	52
3.5.9	<i>Wavelet</i> de Haar.....	53

3.5.10	Wavelet Daubechies.....	53
4	REDES NEURAS ARTIFICIAIS – RNA.....	56
4.1	Introdução.....	56
4.2	Histórico.....	57
4.3	A Rede Neural Artificial.....	58
4.4	Topologia das Redes Neurais Artificiais.....	62
4.5	Estruturas das Redes Neurais Artificiais.....	63
4.5.1	Redes neurais de uma única camada.....	63
4.5.2	Redes neurais de múltiplas camada.....	64
4.6	Aprendizagem da Rede Neural.....	65
4.6.1	Aprendizagem Supervisionada.....	65
4.6.2	Aprendizagem não Supervisionada.....	66
4.7	Rede Neural MLP (<i>Multi Layer Perceptron</i>).....	66
4.8	Algoritmo <i>Backpropagation</i>.....	69
5	ANÁLISE DO PROCESSO DE CLASSIFICAÇÃO DOS SINAIS PULMONARES.....	72
5.1	Metodologia aplicada para classificação dos sinais pulmonares.....	72
5.1.1	Processamento dos sinais.....	73
5.1.2	Extração das características dos sinais utilizando a transformada <i>wavelet</i>	74
5.1.3	Classificação dos diferentes sons através de redes neurais artificiais.....	75
5.2	Resultado e discussão.....	78

5.2.1	Análise dos dados.....	78
5.2.2	Decomposição e extração das características do sinal.....	83
5.2.3	Classificação dos sinais via Rede Neural.....	88
6	CONCLUSÃO	91
6.1	Contribuições	91
6.2	Extensões	92
6.3	Comentários finais	93
	REFERÊNCIAS	94
	APÊNDICES	98
	APÊNDICE A – CURVA DE TREINAMENTO DA REDE NEURAL MLP	99
	APÊNDICE B – ALGORITMO DE CLASSIFICAÇÃO DOS SINAIS DECOMPOSTOS POR WAVELET	100
	APÊNDICE C – ARVORE DE DECOMPOSIÇÃO DE SINAIS CREPITANTES (C1- C15)	107
	APÊNDICE D – ARVORE DE DECOMPOSIÇÃO DE SINAIS SIBILANTE (S1-S15)	115

1 INTRODUÇÃO

As doenças pulmonares estão entre as maiores causas de morte, abrangendo 8% do total de mortes nos Estados Unidos em 1999. Recentes estatísticas estimam que, anualmente, 17 milhões de pessoas nos Estados Unidos sofrem de asma e 1,3 milhões de pneumonia (National Vital Statistic Report, 2001). 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).

No mundo, enquanto a taxa de mortalidade de todas as doenças vem caindo, desde 1965, a mortalidade causada pela doença pulmonar obstrutiva crônica (DPOC) aumentou 163%. Como base de comparação, a taxa de morte por doenças coronárias registrou uma queda, no mesmo período, de 59% (MARCIA, 2007).

No Brasil, 15 milhões de pessoas são afetadas por asma, 20 milhões têm rinite alérgica e 5 milhões de pessoas com idade acima de 40 anos, apresentam doença pulmonar obstrutiva crônica. Esses números mostram que 2 em cada 10 brasileiros são afetados por tais patologias (Doenças Respiratórias Crônicas no Brasil, Outubro 2006).

As doenças respiratórias acometem as vias aéreas, incluindo o nariz e os seios da face, bem como brônquios e pulmão. A maior parte das doenças respiratórias é caracterizada por asma, doença pulmonar obstrutiva crônica, rinite alérgica, doenças ocupacionais dos pulmões e hipertensão pulmonar. As pessoas afetadas têm suas atividades físicas limitadas e apresentam dificuldade em respirar normalmente. Tais patologias afetam todas as idades e representam uma carga considerável tanto para o indivíduo como para a sociedade.

A ausculta pulmonar é uma das técnicas de diagnóstico mais antigas e amplamente usadas devido ao seu baixo custo, grande praticidade e sensibilidade. É uma ferramenta imprescindível da semiologia do tórax na identificação de vários comprometimentos pulmonares, além de proporcionar monitoração da evolução do paciente que apresenta doença pulmonar. Entretanto, a diferença de sensibilidade auditiva, presença de ruído e a limitação de resposta espectral de alguns instrumentos contribuem para a ocorrência de imprecisões nesta técnica, comprometendo o diagnóstico devido à subjetividade inerente à avaliação destes sons. Não é fácil produzir medições quantitativas ou fazer um registro permanente de uma

análise em forma de documento, acompanhamento em longo prazo ou de correlação de som respiratório com outros sinais fisiológicos.

Com o avanço das técnicas computacionais e das tecnologias de sensores, proporcionando a digitalização e gravação de sons respiratórios, surge um interesse entre os pesquisadores da área médica em identificar e entender a correlação entre os sinais acústicos e o comportamento fisiológico. A ausculta pulmonar pode conter informações sobre a estrutura anatômica dos pulmões. Porém, identificar a correlação precisa e o desenvolvimento de um modelo compreensivo de sons pulmonares permanece um desafio devido à complexidade do sistema respiratório (PASTERKAMP, 1997).

As Redes Neurais Artificiais têm se mostrado valiosa ferramenta nos processos de classificação, extração de características, reconhecimento de padrões, etc., e de uma forma geral, em processamento de sinais (HAYKIN, 2008). Mais precisamente, em se tratando de sinais biomédicos, muito se tem pesquisado tendo como parâmetro de ação as redes neurais (LISBOA, IFEACHOR e SZCZEPANIAK, 2000). A perspectiva de classificação de sinais pulmonares utilizando redes neurais tem sido tema de trabalhos recentes, a partir de (DOKUR 2003).

As técnicas de análise Tempo-Frequência, principalmente Transformadas Onduletas-*Wavelet*¹ *Transform* (WT), são muito utilizadas quando os sinais apresentam características não estacionárias, e tem proporcionado uma melhor capacidade e resolução, em comparação com outras como *Fast Fourier Transform* (FFT) ou *Short Time Fourier Transform* (STFT), principalmente em extração de características de sinais complexos (CHUÍ, 1997).

A aplicação de técnicas combinadas em análise de sinais tem se mostrado de grande eficiência, buscando, principalmente unir extração de características e classificação, sendo tema de congressos específicos (ROMAY, 2010).

A análise de sinais pulmonares de forma híbrida utilizando *wavelet* e redes neurais tem se mostrado uma técnica eficiente na busca da classificação de patologias a partir dos tipos de sinais sonoros provenientes da ausculta (KANDASWAMY *et al* 2004).

¹ Palavra de origem francesa “ondelette”, que significa onda pequena.

Neste trabalho, é reforçada a análise híbrida desses tipos de sinais a partir de um estudo de caso, considerando sinais gravados e obtidos por cessão (RIELLA, 2004), buscando desenvolver o processo de separação de alguns sons pulmonares, proporcionando uma ferramenta de auxílio ao especialista médico, na identificação de algumas patologias respiratórias.

1.1 Motivação da Dissertação

Várias tentativas foram feitas ao longo do tempo para a visualização dos sons pulmonares. Tais visualizações estão focadas na amplitude em função do tempo, propriedades temporais e componentes espectrais de frequências. Em 1924, Bass (*apud* MURPHY, 1981), utilizando um microfone capacitivo e um osciloscópio, consegue visualizar a diferença entre sinais pulmonares normais e anormais. Cabot e Dodge (*apud* MURPHY, 1981) conseguem em 1925, a primeira representação gráfica de sons pulmonares gravados com identificação de creptos. Neste estudo, verificou-se que as frequências dos creptos eram superiores aos roncos.

O desenvolvimento de equipamento eletrônico para a gravação e análise de sons biológicos teve início em 1954 com McKusick (VICTOR, 1956), que contribuiu para o campo de sinais cardíacos e pulmonares. Ao adaptar o método de espectrografia da *Bell Telephone Laboratory*, que ele chamou de fonocardiográfico espectral, descobriu que este era capaz de descrever os sons do coração e murmúrios com mais detalhes. McKusick também demonstrou, através de um espectrograma que, creptos úmidos e creptos secos apresentavam frequências diferentes.

Especulações sobre a dificuldade de diferenciar visualmente sons pulmonares foram apresentadas por Forgacs em 1967 (FORGACS, 1967). Ele ressaltou que o estudo foi difícil, porque os sons se sucedem tão rapidamente que nem estertores do indivíduo, nem padrão rítmico feito por sua seqüência, poderiam ser identificados. Ele observou que os osciloscópios mostraram as ondas regulares de um sibilo, mas apenas no tempo de velocidades base para o ciclo respiratório.

Em 1970, Weiss, através de uma nova aferição, permitiu uma visualização global da amplitude dos sons pulmonares incluindo as pausas e as diferenças de duração, bem como um estudo da relação entre as amplitudes de inspiração e expiração (WEISS, 1972). Com o desenvolvimento da tecnologia computacional, novos métodos tornaram possível uma melhor

verificação de sinais pulmonares tais como a análise da forma de onda expandida. A análise da forma de onda de tempo alargado permitiu o desenvolvimento de nova classificação da nomenclatura de sons respiratórios.

Em 1980, Anup Kumar Majumder realiza um estudo publicado como Análise Computacional do Espectro das Freqüências de uma fonopulmografia (MAJUMDER,1980). Nesse trabalho, foi possível o desenvolvimento de um algoritmo capaz de digitalizar os sons pulmonares gravados em fita magnética K7 e sua análise através da transformada de Fourier, evidenciando a diferença entre as densidades espectrais dos sons provenientes de pacientes normais, pacientes com fibrose pulmonar e pacientes com tuberculose.

Em 2007, Taplidou realiza um estudo piloto para o desenvolvimento de uma técnica automática de detecção e monitoramento de sibilos utilizando análise espectral. Este sistema foi intitulado de TF-WD *time frequency-wheeze detector* com a utilização da transformada de Fourier para analisar as componentes no domínio da freqüência especificamente dos sibilos (TAPLIDOU, 2007).

O presente trabalho tem como motivação principal a necessidade de implementação de um sistema computacional capaz de evidenciar de forma quantitativa as diferenças entre os tipos de sons pulmonares composto por sons de sibilo, crepito e normais. Desta forma, pode contribuir na ampliação da gama de identificação de prováveis patologias, pois o som sibilante corresponde a um determinado grupo de doenças, dentre elas a asma; já o som crepitante corresponde a outro grupo de patologias distintas tais como edema pulmonar, inflamações e doença pleural. Esta classificação poderá contribuir como uma ferramenta complementar em diagnósticos respiratórios (RIELLA, 2004).

1.2 Objetivos da dissertação

O objetivo deste trabalho consiste na realização da análise de sinais acústicos pulmonares através da Transformada *Wavelet* e Redes Neurais, principalmente em forma de um estudo de caso, identificando os tipos de sons sibilantes e crepitantes os quais indicam a possibilidade de ocorrência de diversas doenças, tais como a asma, pneumonia e efizematose em fase aguda para o caso de ocorrência em sons classificados de sibilos e fibrose pulmonar, bronqueectasiase, pneumonia em fase inicial, edema pulmonar para os casos de ocorrência de

sons classificados como crepito. Nesse sentido, é uma forma de contribuir para uma melhor identificação e classificação de sons respiratórios anormais de forma não invasiva e com baixo custo.

1.3 Metodologia

A análise de sinais acústicos pulmonares é de suma importância para a compreensão do funcionamento do sistema respiratório e avaliação de seu comportamento frente a determinadas situações. Nesse sentido, pretende-se estabelecer um melhor entendimento deste fenômeno observando uma possível estimação das variáveis envolvidas.

A metodologia envolvida neste trabalho tem como principal foco o processamento de sinais produzidos pelos pulmões. Neste trabalho, foram obtidas 135 amostras em arquivos de sons respiratórios, sendo 45 de sibilos, 45 de creptos e 45 normais, com extensão *wmv*. Estes sons foram fornecidos pela na Faculdade de Ciências Biológicas e da Saúde (FCBS), do Centro Universitário CESMAC. Foram também utilizados arquivos sonoros de repositórios disponíveis na internet, como: <http://www.faemse.org/download.shtml>, <http://www.rale.ca/wheezing>, e além dos arquivos de áudio fornecidos pelo pesquisador R. J. Riella que disponibilizou o banco de dados utilizados em sua tese de doutorado, a qual teve como tema Proposta de Técnica para Caracterização e Classificação Automática de Sons Pulmonares e seu desenvolvimento na Universidade Tecnológica Federal do Paraná, Campus Curitiba em 2008.

Na etapa seguinte, foi utilizado um algoritmo para normalização da amplitude, taxa de amostragem e extração das componentes DC. Em seguida o sinal é decomposto em sub-bandas de frequências através da Transformada de *Wavelet* Discreta (DWT), onde são localizados os principais componentes espectrais dos coeficientes de aproximação e detalhe em cada nível de decomposição. Na terceira etapa, os vetores que são gerados a partir dos coeficientes proeminentes são apresentados à entrada de uma rede neural artificial perceptron multicamadas (MLP - *MultiLayer Perceptron*), que atua como classificador entre os grupos de sons que apresentam características de sibilo, crepito e normal.

1.4 Organizações da Dissertação

De acordo com os objetivos definidos, organizou-se esta dissertação em seis capítulos, incluindo esta introdução. No capítulo 2, apresenta-se uma breve revisão sobre a anatomia e fisiologia pulmonar, histórico da auscultação e as técnicas utilizadas ao longo dos tempos.

No capítulo 3, apresentam-se os aspectos matemáticos em análise de sinais utilizados para o desenvolvimento do trabalho proposto, com ênfase na transformada de *Wavelet*.

No capítulo 4, apresenta-se a base teórica sobre redes neurais artificiais, evidenciando a estrutura da rede implementada na tarefa de classificação dos sons pulmonares.

No capítulo 5, 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 da rede neural artificial MLP.

No capítulo 6 apresentam-se as conclusões e as propostas de trabalhos futuros.

2 ASPECTOS GERAIS DA MONITORAÇÃO E VENTILAÇÃO PULMONAR

2.1 Pulmão

O sistema respiratório é dividido em duas áreas, que são as vias respiratórias superiores e vias respiratórias inferiores. O trato respiratório superior compreende a boca, fossas nasais, nasofaringe, orofaringe e laringe. Este compartimento nasofaringolaríngeo é formado por condutos aéreos que filtram e umidificam o ar, fazendo com que este chegue aos locais de troca gasosa a uma temperatura aproximadamente de 37° C.

A cavidade nasal é responsável pela filtração e aquecimento do ar que entra no sistema respiratório. A faringe é a estrutura responsável pela condução de ar e alimento sendo este direcionado para o estômago. Este direcionamento é feito pela epiglote, que tapa a laringe, não permitindo a passagem de comida para os pulmões.

As vias respiratórias inferiores são constituídas pela traquéia, árvore brônquica e alvéolos, conforme Figura 1.




Figura 1-Representação dos órgãos do sistema respiratório.

Fonte: http://saber.sapo.ao/w/images/2/23/Pasajes_conductores_sisresp.jpg

A traquéia é um grande tubo constituído por anéis de cartilagem que conduzem o ar para dentro do tórax, até se bifurcarem, formando os brônquios. Estes por sua vez, sofrem

inúmeras bifurcações, formando os bronquíolos, terminando em pequenas dilatações chamadas de alvéolos conforme Figura 2.

Os pulmões são órgãos de forma cônica, envolvidos por uma camada de tecido chamada pleura, e que compõem o sistema respiratório. Localizados no interior da caixa torácica, acima do diafragma, têm como função principal a troca passiva de oxigênio e gás carbônico nos alvéolos entre o sangue venoso e o meio ambiente (hematose), atendendo assim às necessidades metabólicas das células, permitindo que se elimine o dióxido de carbono, um elemento residual do processo metabólico celular.

O processo respiratório ocorre com a contração e relaxamento do diafragma (músculo que separa o tórax do abdômen) e dos músculos intercostais. Estes músculos ora comprimem os pulmões (expiração), fazendo com que o ar contido em seu interior seja expulso para fora do organismo e ora expande os pulmões (inspiração) criando assim no interior destes, uma pressão negativa em relação ao meio extra-corpóreo e desta forma aspirando o ar externo para o seu interior.

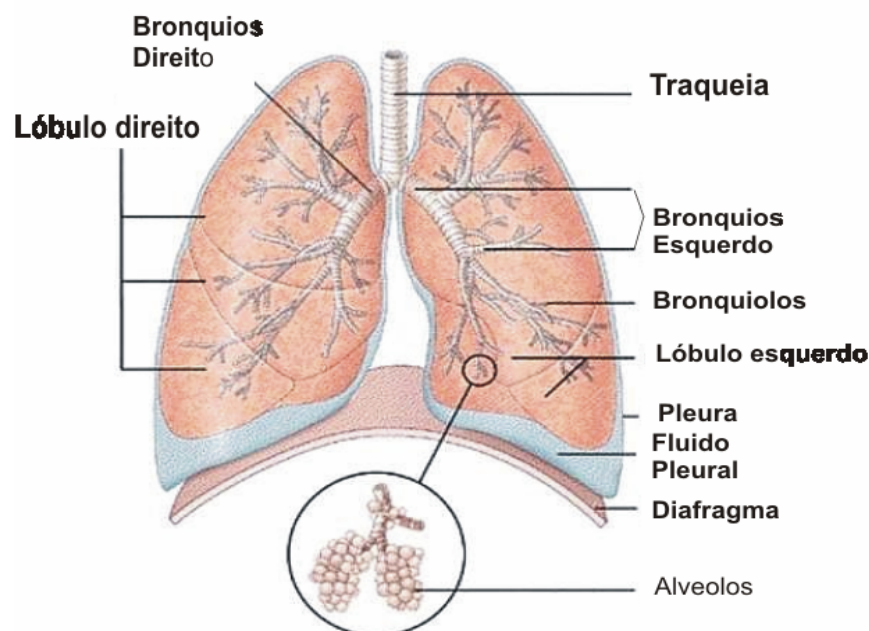


Figura 2 – Representação do pulmão

Fonte: [http:// www.ehow.com/how-does_5246353_right-lung-lobe...](http://www.ehow.com/how-does_5246353_right-lung-lobe...)

O ar chega até o local de trocas gasosas pulmonar através, inicialmente, do nariz ou da boca. Em seguida, passa pela laringe e pelo sistema traqueobrônquico. As vias aéreas

superiores têm função principal de filtrar, umidificar e ajustar a temperatura do ar inspirado. Os bronquíolos terminais compõem as unidades respiratórias finais, chamadas também de parênquima pulmonar, local onde ocorre a troca gasosa. Um adulto tem em média 300 milhões de alvéolos (LEHRER, 2004). Os alvéolos são estruturas semelhantes a sacos localizados nos terminais dos bronquíolos e estão envolvidos pelos capilares pulmonares. Nos alvéolos ocorrem as trocas gasosas, com a entrada de oxigênio na hemoglobina do sangue, constituindo assim a oxiemoglobina, e retirada do dióxido de carbono (Figura 3).




Figura 3 – Alvéolos e representação da troca gasosa.

Fonte: <http://www.infoescola.com/files/2009/08/sistema-respiratorio2.gif>

O fenômeno respiratório ocorre com a alternância mecânica da contração e relaxamento do músculo do diafragma causando uma pressão positiva dentro dos pulmões em relação ao meio extra-corpóreo, quando contraído, e uma pressão negativa, quando relaxado, conforme a Figura 4.

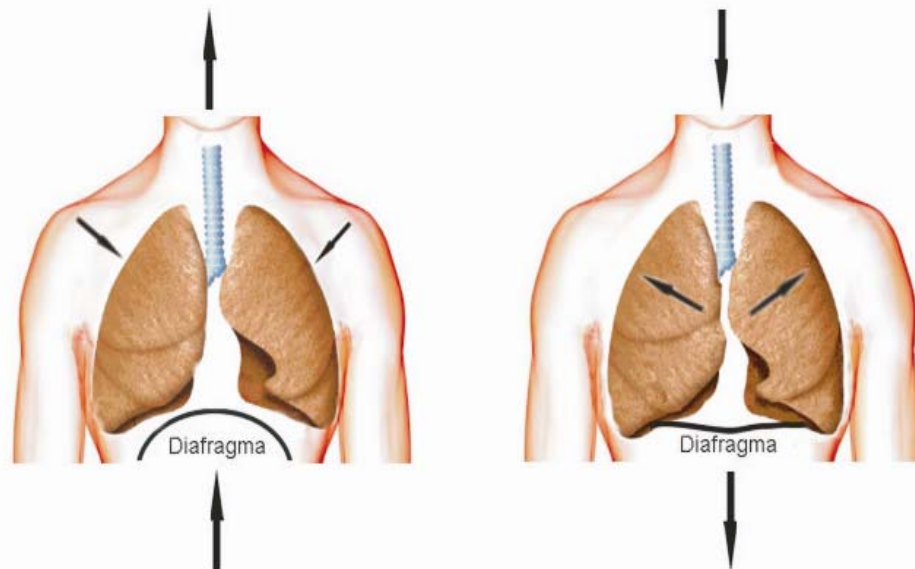


Figura 4 – Representação da inspiração e expiração pulmonar
Fonte: Autor, 2010

2.2 Patologias Pulmonares

As patologias associadas aos pulmões são divididas em duas categorias: (1) doenças obstrutivas, e (2) doenças restritivas. As células que revestem os brônquios possuem três principais tipos de receptores que detectam a presença de substâncias e estimulam os músculos a contrair e a relaxar. Quando estimulados, os receptores betaadrenérgicos produzem o relaxamento muscular e, conseqüentemente, as vias aéreas dilatam-se e facilitam a entrada e a saída do ar.

Os receptores colinérgicos, quando estimulados pela acetilcolina, e os receptores peptidérgicos, quando estimulados pelas neurocininas, fazem com que os músculos contraiam. Desta forma, as vias aéreas estreitam e dificultam a entrada e a saída do ar. A obstrução das vias aéreas pode ser reversível ou irreversível. No caso da asma, a obstrução das vias aéreas é completamente reversível. Na doença pulmonar obstrutiva crônica causada pela bronquite

crônica, a obstrução é parcialmente reversível, enquanto na doença pulmonar obstrutiva crônica causada pelo enfisema, o quadro é irreversível (Manual Merck Saúde para a Família).

Doenças obstrutivas causam obstrução das vias aéreas por conseqüências patológicas tais como: excesso de secreção de muco, inflamação e/ou colapso das paredes respiratórias. São exemplo de doenças obstrutivas a asma, bronquite crônica, laringite enfisema e neoplasma de laringe. A Doença Pulmonar Obstrutiva Crônica é caracterizada por uma mistura de bronquite crônica com enfisema pulmonar. Os pacientes apresentam inflamação dos brônquios (edema e aumento da produção de secreção) e a destruição progressiva dos septos alveolares.

As doenças restritivas apresentam características mecânicas de baixa complacência pulmonar (razão entre a variação de volume pela variação de pressão), com maior retração elástica do parênquima associado ou não a uma menor produção de surfactante alveolar. Esta situação causa um aumento da tensão superficial na parede dos alvéolos, o que faz com que eles apresentem uma tendência mais forte ao colapamento, ou seja, o ar tende a ser expulso dos alvéolos, quando não se produz uma quantidade adequada de surfactante. Nesta situação, irá penetrar uma quantidade menor de oxigênio nos alvéolos e, conseqüentemente, haverá uma diminuição da ventilação. Desta forma, para que haja a mesma entrada de ar que numa situação normal, é necessário o emprego de um esforço maior junto à musculatura relacionada à inspiração aumentando o trabalho elástico do sistema respiratório.

A doença pulmonar restritiva é caracterizada pela diminuição da capacidade total pulmonar por redução da expansão do parênquima pulmonar, estando o fluxo respiratório normal ou proporcionalmente reduzido. Duas condições gerais podem ocasionar o defeito restritivo: distúrbios na parede torácica, como é o caso das doenças neuromusculares, poliomielite, obesidade grave, doenças pleurais, ou doenças infiltrativas e intersticiais, como é o caso dos edemas pulmonares e a Síndrome da Angústia Respiratória Aguda (SARA).

Na primeira condição, a expansibilidade da caixa torácica é reduzida, de tal forma que o tórax, por motivos diversos, não se expande totalmente, reduzindo a pressão entre os pulmões e a pressão atmosférica, diminuindo a quantidade de ar inspirado. No segundo caso, o problema se dá a nível alveolar, quando o parênquima é afetado e a função da troca gasosa a nível capilar é insuficiente para manter a hematose. Esse tipo de condição pode ser compreendido também como redução do volume pulmonar. As doenças restritivas são

caracterizadas por fibrose intersticial ou inflamação capaz de causar enrijecimento dos pulmões ou solidificação de secreções nas vias aéreas.

São exemplos de doenças restritivas: sarcoidose, fibrose pulmonar, pneumonia, tuberculose, escleroderma, reumatóide pulmonar, etc.

2.3 Técnicas de Diagnósticos

O diagnóstico diferencial de patologias pulmonares utiliza vários recursos, sendo os mais comuns a ausculta, a espirometria e a radiografia (Raio X). A ausculta pulmonar consiste em ouvir os sons provenientes dos pulmões que são transmitidos até a caixa torácica fornecendo subsídios aos profissionais para esclarecimento de diagnóstico. Esta técnica é auxiliada pelo estetoscópio, que tem a capacidade de amplificar certas frequências audíveis de interesse.



Figura 5 – Representação do estetoscópio mecânico

Fonte: <http://eliomardelima.zip.net/images/estetoscopio.jpg>

A espirometria é uma técnica que avalia a capacidade mecânica do sistema respiratório através da medição da capacidade volumétrica de ar bem como a taxa expiratória de ar através da curva tempo-volume. Este exame é bastante utilizado em diagnóstico de doenças obstrutivas e restritivas. As diversas doenças que comprometem os pulmões podem modificar sua complacência, de modo que os volumes e capacidades previstas para uma pessoa se alteram, e isso é detectado por provas de função pulmonar como a espirometria (MARCIA, 2007).



Figura 6 – Representação Espirômetro

Fonte: <http://www.cmdc.com.br/espiro.jpg>

O exame de espirometria consiste de dois procedimentos básicos: uma máxima inspiração e uma máxima expiração. O volume de ar que entra e sai dos pulmões em cada ciclo determina o volume corrente. O volume de ar que é possível se inspirar, além do volume corrente, é chamado de volume de reserva inspiratório. Da mesma forma, o volume de ar que é possível se expirar, além do volume corrente, é chamado de volume de reserva expiratório.

Ao realizar uma máxima expiração, nem todo o ar contido nos pulmões é expulso. Assim, mesmo sob o efeito de uma máxima expiração, ainda existe um determinado volume de ar nos pulmões, chamado de volume residual. A capacidade pulmonar total é a soma dos volumes básicos relacionados à ventilação, incluindo o volume residual. A capacidade vital é o somatório dos volumes, sem levar em conta o volume residual. A figura 7 representa diversas curvas padrão da espirometria.




Figura 7 – Representação gráfica de um exame de espirometria.

Fonte: <http://www.medicinageriatrica.com.br/wp-content/uploads>

O raio-X é uma técnica de imagem radiográfica em que a radiação atravessa o tórax e sensibiliza um filme foto sensível produzindo neste uma imagem da estrutura interna e o estado desta conforme Figura 8. A técnica de raios-X é comumente utilizada em diagnóstico de doenças pulmonares restritivas. No Brasil, os raios-X dos sistemas respiratórios, para fins diagnósticos de tuberculose pulmonar, são chamados de Abreugrafia, que diz respeito a uma incidência sobre uma pequena área do pulmão.



Figura 8 – Imagem radiográfica utilizando raio X

Fonte: <http://www.rime.pt/media/uploads/images/examtype/Raio>

2.4 Audição

A audição, termo originário do latim *auditione*, é um dos cinco sentidos humanos capazes de reconhecer o som emitido pelo ambiente dentro de determinadas amplitudes e faixa de frequência. Os sons são propagações de ondas mecânicas que têm a capacidade de sensibilizar o ouvido humano, excitando os nervos auditivos e causando-nos a sensação que chamamos de audição. O ouvido humano, ao ser atingido por uma onda sonora, tem seu tímpano excitado pela pressão do ar que o faz vibrar. Esta vibração é transmitida a um conjunto de ossos e músculos do sistema auditivo que amplifica e transforma estes sinais vibracionais em sinais elétricos que são enviados ao cérebro através do nervo auditivo. No cérebro os sinais elétricos são interpretado conforme Figura 9.

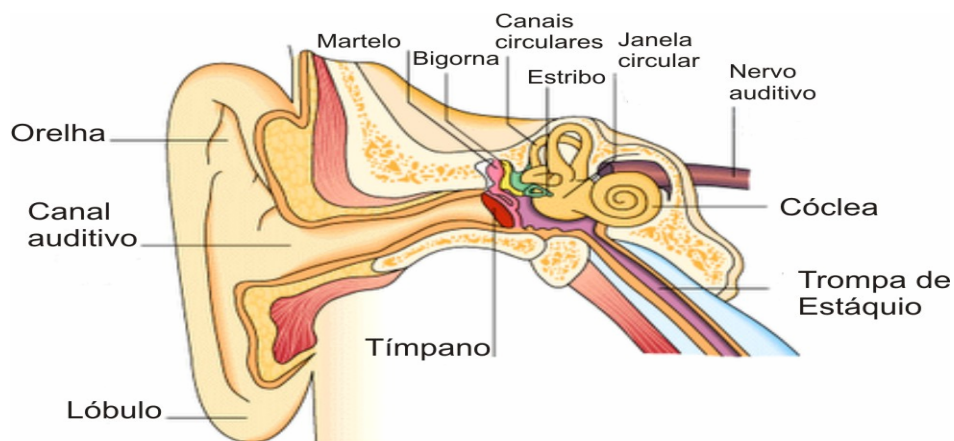


Figura 9 – Representação do ouvido humano.

Fonte: http://3.bp.blogspot.com/_gkrhN5QBApc/SM2C1mQFe4I/

Os sons são vibrações criadas por uma fonte alternada de compressão e rarefação do ar e que possuem três características principais: frequência, intensidade e duração. A frequência representa o número de vibrações ou ciclos por segundos e tem como unidade o hertz (Hz). Esta característica sonora importante é conhecida como timbre.

A intensidade está relacionada a quatro fatores que determinam se o som é forte ou fraco, que são: a amplitude das vibrações, o tipo da fonte geradora da energia sonora, a distância entre a fonte e o ouvido a qual a onda sonora irá percorrer e o meio através do qual as vibrações passam. A duração das vibrações determina o tempo em que o som é interpretado pelo ouvido como, por exemplo, um sibilo curto ou longo.

2.5 Ausculta Pulmonar

Desde os tempos mais remotos, o homem tem conhecimento de que o seu corpo emite sons relacionados ao seu funcionamento próprio. A prática de ouvir sons é chamada de ausculta e tem sido desenvolvida ao longo da história para a diagnóstico de doenças desde a Grécia antiga por Hipócrates, em 400 a.C. (DALMAY, 1995). A ausculta pulmonar é um método semiológico básico no exame físico dos pulmões (PORTO, 2005). Clinicamente este é um método simples, de baixo custo e não invasivo, com aplicações tanto no caso de diagnósticos como no caso de monitoração terapêutica em doenças dos sistemas respiratórios.

Os gregos antigos reconheciam pelo menos dois tipos de sons característicos: atrito pleural e o ruído hidroaéreo (avaliação da função respiratória). A utilização da auscultação em exames clínicos modernos teve início no século XVIII com o médico Leopold Auenbrugger, ao observar que, através da auscultação direta, colocando o ouvido no tórax do indivíduo, era possível perceber sons dos batimentos cardíacos, bem como do sistema bronco pulmonar, e que estas informações poderiam auxiliar no diagnóstico dos exames físicos.

No entanto, este método era desconfortável e anti higiênico, tanto para o médico bem como para o paciente, principalmente em pacientes obesos, ou mesmo ainda inapropriado, para o caso de pacientes do sexo feminino. Em 1816, René Théophile Hacinthe Laënnec proporcionou um grande avanço no diagnóstico de patologias pulmonares e cardíacas com o invento do estetoscópio, estabelecendo, a partir de autópsia, a relação entre sons auscultados sobre o tórax e patologias, tais como: edema pulmonar, pneumonia, tuberculose, bronquite, enfisema pulmonar e outras (PORTO, 2005).

A história do estudo dos sons pulmonares passa também pela história do estetoscópio. Laennec, além de inventar o estetoscópio, comparou os sons com achados após a morte e, já em 1819, apesar de sua frágil saúde, publicou os resultados de seus estudos no “*Traité de L’Auscultation Médiante*” (Tratado de ausculta mediada). Nesta obra, foram introduzidos os termos: sopro, crepitações, dentre outros.

Desta forma, o invento do estetoscópio, do grego *stêthos* (torax) *skopein* (olhar), não só possibilitou uma ausculta mais clara dos sons respiratórios mas, também, evitou o indesejável contato com o paciente, sendo assim a mais importante ferramenta para a diagnose pulmonar até a invenção da radiografia no início do século XX.

Após testar vários materiais e formatos, Laënnec definiu um cilindro de madeira oco de 3,5 cm de diâmetro e 25 cm de comprimento conforme Figura 10. Posteriormente novos formatos foram desenvolvidos para uma melhor ausculta tanto respiratória como cardíaca como ilustra a Figura 11.



Figura 10 – Réplica do estetoscópio criado por Laënnec.

Fonte: http://www.sciencemuseum.org.uk/images/object_images/535x535/10284184.jp



Figura 11 – Modelos de estetoscópios propostos após Laënnec.

Fonte: (De Bishop, P.J., in Tikian & Conover, 1991, p. 5.)

Estes modelos foram utilizados até 1851, quando Arthur LeaRed propôs um novo modelo de estetoscópio duplo feito de tubo látex, similar aos estetoscópios modernos conforme Figura 12



Figura 12- Réplica do estetoscópio criado por Arthur LeaRed e, 1851

Fonte:<http://www.antiquemed.com/binauralstethoscopeim>

O estetoscópio deu mais um passo evolutivo quando, em 1894, Bianchi inventou o “diafragma rígido”; em 1925 Bowles e Sprague combinaram a campânula com o diafragma rígido e, em 1955, Rappaport, Sprague e Groom aperfeiçoaram-no nos moldes atuais.

O Som respiratório é o resultado da turbulência do ar ao passar nas vias aéreas as quais transmite as ondas sonoras através do parênquima pulmonar e da parede torácica, fazendo com que estas cheguem até a superfície do cor

po. O uso deste aparelho oferece um dos mais importantes e simples métodos diagnósticos e de informações sobre a estrutura e a função do pulmão por uma forma não invasiva (PASTERKAMP, 1997).

Apesar do custo elevado dos modernos aparelhos, os mesmos são simples condutores de sons entre as superfícies corpóreas do paciente e os ouvidos do examinador, podendo amplificar ou atenuar seletivamente em um certo espectro de interesse clínico (PASTERKAMP, 1997). Os estetoscópios atualmente estão divididos em convencionais (mecânicos) e eletrônicos. Os convencionais apresentam os mesmos princípios funcionais do século XIX, onde a amplificação sonora ocorre através de um tubo ressonante conforme

Figura 2.12. É composto por olivas (1), extensores (2), um tubo flexível de látex em formato de Y(3), e um receptor que pode ser campânula e/ou diafragma (4 e 5), conforme figura 13.




Figura 13 – Estetoscópio mecânico detalhado
Fonte: www

As olivas auriculares são peças em formato anatômico, que se encaixam ao canal auditivo do examinador. Os tubos de condução formados pelos extensores e pelo tubo flexível são condutos que proporcionam a transmissão do som com pouca distorção da campânula ou diafragma até aos ouvidos do examinador. Campânula, conforme Figura 14, é uma peça de contato com o corpo do examinado, formada de uma câmara rasa e aberta na parte que irá ter contato com o paciente, sendo esta mais apropriada para percepção de sons graves como é o caso dos sons cardíacos.



Figura 14 – Representação da campânula de um estetoscópio
Fonte: Autor, 2010

O sensor diafragma é composto por uma câmara rasa sendo a face que entra em contato com o paciente fechada por uma membrana conforme Figura 15. Este sensor é mais apropriado para altas frequências como é o caso de sons pulmonares.



Figura 15 – Sensor diafragma

Fonte: Autor, 2010

As vibrações acústicas provenientes dos pulmões se propagam até a superfícies do corpo onde atinge o estetoscópio. No caso dos estetoscópios de diafragma, as vibrações são transmitidas até a membrana rígida que por ressonância vibra com intensidade maior, amplificando o sinal. Para os estetoscópios de campânula, a superfície da pele é que funciona como diafragma. As propriedades inerentes das membranas deslocam as frequências para baixo ou para cima. Tais características são: quanto maior o diâmetro da membrana ou da campânula (dependendo do tipo de estetoscópio), menor será o valor das frequências de ressonância, ou seja, diâmetros maiores favorecem as baixas frequências (filtro passa baixa); quanto menor o diâmetro, maior o valor das frequências de ressonância (filtro passa alta); em situações em que a membrana (diafragma ou pele do paciente) está submetida a uma grande pressão, mais elevados serão os valores das frequências de ressonância da mesma (filtro passa alta); a redução da pressão sobre a membrana favorece as frequências mais baixas (filtro passa baixa).

Assim, existe a possibilidade de se variar a gama de frequências de ressonância mudando-se a pressão e/ou o diâmetro da membrana. No caso dos estetoscópios de campânula, podem-se variar frequências de interesse apenas ajustando-se a pressão dos mesmos contra a pele do paciente.

2.6 Características do Receptor Sonoro.

A forma do sino também altera as frequências de ressonância. Quanto maior for o valor do seu volume interno, mais alta será a sua frequência de ressonância. Ainda em relação ao tamanho do sino, é importante salientar que se deve observar um volume mínimo de modo a não permitir que, no caso de exame em pessoas obesas, o seu interior não seja preenchido pelo tecido do paciente. O volume reduzido também é importante, uma vez que quanto menor o volume de ar dentro do sistema do estetoscópio, maior a variação de pressão sentida.

2.7 Estetoscópio Eletrônico

Os estetoscópios digitais apresentam formato semelhante aos mecânicos conforme Figura 16. São constituídos por de extensores, tubo de látex em forma de Y e olivas de borracha, mas o sensor é composto por único diafragma para todas as aplicações cardíacas e pulmonares.



Figura 16 – Estetoscópio eletrônico

Fonte:

A principal diferença entre estetoscópios mecânicos e os digitais são que estes apresentam dispositivos eletrônicos inseridos em seu interior com a finalidade de amplificar o sinal de interesse, filtrar ruídos ambientes indesejáveis e selecionar a faixa de frequência pretendida para o caso de sinais cardíacos e pulmonares. Estas faixas diferentes permitem uma detecção mais exata e até precoce dos sintomas.

Outra vantagem dos estetoscópios eletrônicos é a possibilidade de gravação digital em tempo real, possibilitando a reprodução e edição posterior do sinal analisado além da disponibilidade por meios digitais entre os profissionais da área. A transmissão do sinal

captado pelo estetoscópio é transmitida via infravermelho ou *Bluetooth* para um computador padrão IBM-PC para serem armazenados, compartilhados ou apenas mantidos em arquivo, visando posterior análise. Entretanto, apesar de mais eficiente, o estetoscópio digital apresenta uma grande desvantagem que é o alto custo em relação aos mecânicos.

2.8 Tecnologia *Bluetooth*

A tecnologia *Bluetooth* é um novo padrão de comunicação sem-fio WPAN (*Wireless Personal Area Network*) que utiliza curta distância e possui baixo custo, permitindo a comunicação sem fio entre aparelhos eletrônicos, dentre eles telefones celulares, *Palmtops*, computadores, *scanners*, impressoras, equipamentos de escritório, estetoscópios, assistentes pessoais (PDA).



Figura.17 – Estetoscópio com comunicação Bluetooth
Fonte: Autor, 2010

2.9 Eficiência dos estetoscópios

O calibre e o comprimento do tubo flexível influem diretamente no desempenho do estetoscópio. Isto porque, como as variações de pressão no ouvido, produzidas pelo movimento da pele ou do diafragma, são inversamente proporcionais ao volume interno do estetoscópio, tem-se que um volume mínimo acarreta pressões máximas e, em consequência, sons de máxima intensidade. Devido à dificuldade na padronização de aquisição de dados entre os diversos laboratórios, além da falta de sistematização, a comunidade europeia

financiou o projeto CORSA (*Computarizad Respiratory Sound Analysis*), que estabeleceu diretrizes para a análise de investigação de sons pulmonares (PONTE, 2008) A Tabela 1 mostra algumas recomendações da CORSA para sistemas de captura de sons respiratórios.

Tabela 1 – Recomendação da CORSA para capturas de sinais respiratórios.

Microfone	Piezelétrico/Eletreto
Sensibilidade	> 1mV/Pa
Frequência de corte de Filtro	60Hz
Frequência de corte Filtro passa baixa	1600 a 3000 Hz
Taxa de amostragem	4 a 22,5 KHz
Número de bits	12, 14, 16
Digitalização	Conversor A/D comercial

Fonte: PONTE, 2008

Os sons pulmonares são produzidos pelo escoamento turbulento dos fluidos ao longo do sistema respiratórios. Esta turbulência é decorrente dos obstáculos que as vias aéreas oferecem à passagem de ar, como as bifurcações e variações abruptas de diâmetro, que causam grande quantidade de turbilhões e conseqüentemente ocasionando um escoamento ruidoso. Este ruído em forma de som propaga-se até a superfície do corpo onde pode ser analisado e correlacionado com o funcionamento pulmonar. A ausculta pulmonar é feita sobre toda a região anterior, posterior e lateral do tórax, mas, como essas ondas sonoras tendem a se refletir (atenuando-se) quando atravessam o meio líquido para o meio ósseo, se evita a auscultação sobre as escápulas (PONTE, 2008).

Os sons respiratórios podem ser auscultados através de estetoscópio ou captados na superfície do tórax com a utilização de microfones. O CORSA recomenda a utilização de microfones piezelétricos (posicionados diretamente sobre o tórax) ou de eletreto com acopladores acústicos (TAPLIDOU, 2007).

2.10 Limitações da Ausculta Pulmonar

Os sistemas sensoriais apresentam um limite mínimo e um limite máximo para responder a um estímulo. A ausculta pulmonar apresenta algumas limitações devidas tanto às características próprias do ouvido humano em perceber determinadas frequências de áudio bem como à propriedade dos estetoscópios de deslocarem as frequências de ressonância para a faixa de baixas ou altas frequências, o que torna este método propenso a variações de interpretação e possíveis diagnósticos equivocados.

A avaliação objetiva de sons respiratórios, por meio de técnicas analógicas e digitais, deve ser mais confiável, pois informações significantes podem ser obtidas através da análise da frequência, o que a torna uma promessa para o desenvolvimento de uma nova classe de instrumentos de diagnóstico médico. No entanto não é toda onda mecânica que ao chegar ao ouvido pode ser convertida em informação, pois um fator limitante da audição humana é a intensidade relacionada com a frequência (STANLEY, 1974).

O ouvido mediano jovem pode detectar vibrações sonoras com frequência aproximadamente entre 16 e 16.000Hz, embora a sensibilidade varie muito dentro desta faixa. A sensibilidade máxima está na faixa entre 3.000 e 4.000Hz. Abaixo e acima disto a sensibilidade cai drasticamente (LEHRER, 2004) conforme Figura 18.

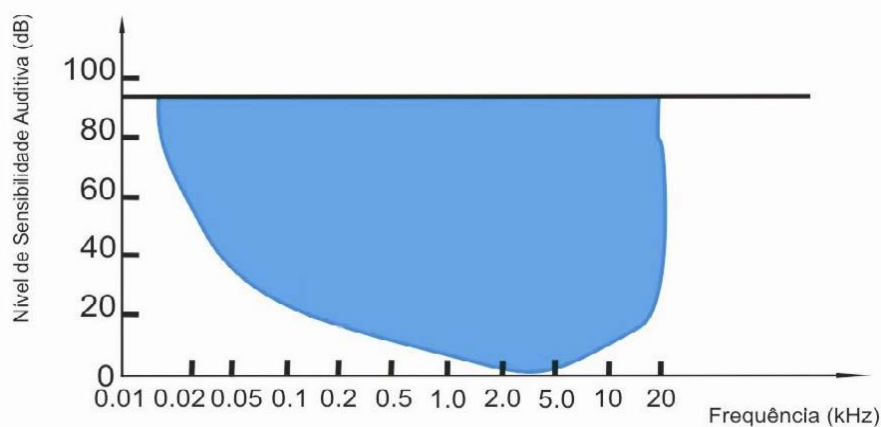


Figura 18 – Gráfico de sensibilidade auditiva.

Fonte: Desenvolvido com base na Figura do livro *Physics of the body*, 2nd ed. Madison, 1999

A intensidade sonora é relativa e é verificada pela relação entre duas intensidades, sendo a primeira referente à intensidade do som em questão e a segunda é a característica do limiar da audição. A unidade sonora é dada em decibel (dB). Um decibel consiste de dez vezes o logaritmo de base dez da razão entre duas intensidades sonoras.

Um outro fator limitante é que limites superiores desta faixa normalmente decresce com a idade bem como a sensibilidade conforme Figura 19.




Figura 19 – Curva de sensibilidade auditiva em função da idade

Fonte: http://www.sabereletronica.com.br/files/image/interface_1_homem.jpg

2.11 Sons Pulmonares

Os sons respiratórios podem ser percebidos na traquéia e no torax. Durante o ciclo ventilatório, o som pode aparecer no início, no meio, no final da inspiração, da expiração ou em todo o ciclo (PIRILLA, 1995). Alguns fatores podem limitar a ausculta destes sons, como o tipo de estetoscópio, a sensibilidade auditiva e a habilidade do examinador (STEWART, 1931).

Existem variações regionais na intensidade do som. No ápice, o som é menos intenso durante uma inspiração feita a partir do volume residual. Por outro lado, na base, o som é menos intenso no início da inspiração, a sua intensidade aumenta progressivamente e atinge o seu máximo em cerca de 50% da capacidade vital. A Figura 20 representa um sinal pulmonar respiratório no domínio do tempo de um paciente saudável.




Figura 20 – Representação de um sinal pulmonar normal no domínio do tempo.
Fonte: Autor, 2010

As diferenças observadas no conteúdo de frequência dos sons de respiração em pacientes com asma e DPOC podem refletir alteração de geração de som ou de transmissão, devido às alterações estruturais dos brônquios e do tecido do pulmão circundante nestas doenças.

2.12 Som Traqueal

Os sons traqueais são audíveis na região da traquéia, no pescoço e na região external. São originados pela passagem do ar através da fenda glótica e na própria traquéia; diferenciam-se com facilidade seus dois componentes, sendo um inspiratório constituído de um som soproso, rude, após o qual há um intervalo de tempo silencioso que divide os componentes inspiratórios e o expiratório.

O som traqueal é bem percebido nas duas fases do ciclo respiratório sendo na expiração mais intenso e ausculta-se sobre a traquéia ou laringe. A energia principal dos sons traqueal se estende até 1000 Hz, com um acentuado diminuição da potência acima destas frequência.

2.13 Som Vesicular

A respiração brônquovesicular é semelhante ao som traqueal, diferenciando-se apenas por ter o componente expiratório menos intenso. Nas áreas que correspondem à condensação pulmonar, atelectasia ou nas regiões próximas de cavernas superficiais é possível ouvir esta respiração.

2.14 Sons Anormais

Os eventos de doenças pulmonares afetam diretamente não só o timbre sonoro produzido pela respiração, mas a transmissão destes através das vias aéreas à superfície torácica. Toda vez que existe consolidação, existe aumento da transmissão do som, ou broncofonia (PORTO, 2005). Sons anormais, também chamados de sons adventícios, são caracterizados pela presença de baixas e altas frequências e são causados por consolidação dos pulmões, atelectasia que é um colapso de parte ou de todo o pulmão, ou fibrose. Os sons pulmonares anormais, ou ruídos adventícios, podem ser classificados em sibilos, crepitações e roncos ou, também, podem ser classificados pelo seu caráter contínuo e descontínuo.

Tabela 2 – Terminologia dos sons adventícios segundo a American Thoracic Society - ATS

Termo sugerido	Classificação	Termo alternativo
Crepitações	Descontínuo	Estertores crepitantes
Sibilos	Contínuo, diapasão alto	Estertores sibilantes Estertores musicais Roncos sibilantes
Roncos	Contínuo, diapasão baixo	Estertores sonoros Sibilo de diapasão baixo

Fonte: Segundo o Ad Hoc Pulmonary Nomenclature Committee da American Thoracic Society e do American College of Chest Physicians.

2.15 Crepitação

As crepitações, também chamados de estertores, consistem de sons curtos, explosivos, descontínuos, não musicais e estão associados a patologias cardiopulmonares. Quando localizados na traquéia estão relacionados a doenças obstrutivas, e são produzidos pela passagem de bolhas de ar pelas obstruções parciais das vias aéreas principais. Tipicamente ocorre no início da fase inspiratória, e em toda a fase expiratória.

Quando localizados nas paredes do torax são associados à doenças restritivas, e são produzidos pela súbita abertura das vias aéreas periférica, especialmente os alvéolos e ocorre tipicamente no final da fase inspiratória (GINA, 2004). Com o processo do envelhecimento e com a perda do recolhimento elástico, as crepitações tendem a aumentar (PIRILLA, 1995). Os sons creptantes podem diminuir durante um exame clínico após várias tomadas de ausculta pulmonares devido ao fato de haver uma maior expansão da área do pulmão e redução de áreas previamente comprometidas.

As crepitações também foram encontradas em pessoas jovens e sadias quando realizavam uma inspiração profunda a partir do volume residual, mas não da capacidade residual funcional. Este dado nos leva a crer que estes sons não são exclusivos de indivíduos com acometimento patológico e sim, também, dos volumes pulmonares envolvidos durante a ausculta (PIRILLA, 1995). Laennec caracterizou, em seu tratado de auscultação pulmonar, os sons creptantes em: creptações úmidas; creptações mucosas, creptações secas e creptações sibilantes.

As características de sons secos e úmidos não são mais recomendadas. Segundo a *American Thoracic Society* (ATS), as creptações finas são designadas para os sons de alta frequência e pequenas durações que ocorrem normalmente no final da inspiração, não se alterando com a tosse. As creptações grossas são sons de duração mais longa e frequências mais altas, que ocorrem mais precocemente e se alteram com a tosse. Nos casos de fibrose pulmonar, as creptações normalmente ocorrem no meio até o final da inspiração ou em todo o ciclo inspiratório do paciente.

Já nos casos de asbestose pulmonar, são observadas crepitações finas no início ou no final de cada inspiração. Nos casos de bronquiectasia, as crepitações ocorrem somente no início ou no meio da inspiração. Nesta patologia existe uma perda da elasticidade e do


componente muscular, de forma que as paredes dos brônquios se colapsam na expiração seguida de uma abertura súbita na inspiração (PIRILLA, 1995).

Na pneumonia, as crepitações podem variar conforme a fase da doença. No período agudo decorrente do edema e infiltração de células inflamatórias com estreitamento dos brônquios, as crepitações ocorrem no meio do ciclo inspiratório. Já na fase de recuperação esta ocorrência se verifica no final da inspiração pois o parênquima pulmonar torna-se mais seco, alterando as características sonoras (PIRILLA, 1995).

O aparecimento de crepitações pode ser um sinal precoce da doença respiratória, como por exemplo, asbestose. Dependendo da gravidade do fechamento das pequenas vias aéreas, as crepitações tendem a ocorrer em primeiro lugar na região basal dos pulmões e, mais tarde, quando a doença progride, também nas zonas superiores dos pulmões.

2.16 Sibilos

Sibilos são sons musicais semelhantes aos “assobios”, contínuos, que ocorrem na maioria das doenças obstrutivas e são produzidos pela estreitamento da passagem de ar através das vias aéreas tais como a asma (Figura 21).



Brônquio normal (à esquerda) e na asma (à direita)

Figura 21 – Representação de um brônquio normal e em crise de asma

Fonte: <http://www.drpereira.com.br/fotos/asmal.jpg>

A formação do sibilo é uma interação entre o calibre da via aérea e a passagem em jato do ar que produz vibrações nas estruturas pulmonares (DALMAY, 1995). São ruídos contínuos com duração maior que 250ms e geralmente encontrados na fase expiratória. Conforme a *American Toracic Society (ATS)*, estes sons mostram variações de frequência aproximadamente de 400 Hz.

Em situações clínicas onde isso ocorre, como na asma, a redução da luz da via aérea associada à diminuição de elastância que acompanha o edema, permitem que alguns pacientes possam até apresentar sibilos audíveis à distância (PIRILLA, 1995). Estudos realizados por I. Mazic, S. Sovilj, R. Magjarevic mostram que 70% dos pacientes com crise de asma apresentam sibilo. Além da asma, outras patologias pulmonares envolvem estes sinais clínicos tais como: secreções, corpo estranho, tumores intraluminais, compressões externas por alguma massa.

Em situações em que mais de uma via aérea seja obstruída, é possível encontrar sibilos com timbre diferente que são os chamados sibilos polifônicos. Curiosamente, indivíduos sadios podem produzir sibilos quando exercem expirações forçadas e seus mecanismos não são totalmente elucidados (PASTERKAMP, 1997). Os sibilos são produzidos nas vias aéreas e requerem o fechamento dos brônquios para serem produzidos. Os sibilos acompanham as patologias que levam à obstrução de fluxo aéreo, como exemplo a asma e DPOC, mas podem acontecer em inúmeras outras doenças que acometem as vias aéreas. É popularmente chamado de "chiado".

Estudo realizado por Baughman, publicado no jornal da *American College of Chest Physicians*, mostra a relação entre as frequências de pacientes asmáticos antes e após o uso de broncodilatador, conforme Tabela 3.

Tabela 3 – Frequências em pacientes com asma antes e após tratamento

Amostra	Frequência (Hz) antes tratamento	Frequência (Hz) após tratamento
1	460	330
2	310	210
3	420	220
4	580	300
5	430	320
6	470	280
7	400	250
8	400	330
9	440	470
10	550	230

Fonte: BAUGHMAN, 1984

Neste estudo fica evidente que pacientes sibilantes, com patologia de asma, apresentam frequência dominante acima de 210 Hz após tratamento.

2.17 Roncos

Os roncos são sons semelhantes aos sibilos, contínuos, audíveis na inspiração e na expiração, causados geralmente em vias aéreas com secreção e com frequência inferior a 200Hz (DALMAY, 1995). O ronco é um chiado de baixa frequência contendo amortecimento rápido com duração > 100ms, podendo ser encontrado, por exemplo, em pacientes com secreções ou estreitamento das grandes vias aéreas e com colapsibilidade anormal das vias aéreas.

3 TÉCNICAS PARA PROCESSAMENTO DE SINAIS BIOMÉDICOS

3.1 Introdução

Ao se analisar qualquer sinal com representação no domínio do tempo, várias de suas informações não estão claramente visíveis ou disponíveis. Desta forma, a representação temporal pode não ser a melhor forma de se analisar um sinal ao se buscar características específicas, tais como a densidade de potência, análise espectral das frequências, etc. Para este caso, a utilização de técnicas matemáticas mais complexas é o mais recomendado para que se possam extrair características não observáveis diretamente quando a análise do sinal é realizada no domínio do tempo.

A necessidade de uma ferramenta de análise que decomponha sinais em ondas harmônicas contínuas nos seus constituintes, de modo a que se possa analisar o seu conteúdo e não apenas a evolução da sua forma no tempo é um dos mais antigos assuntos em análise matemática e é de grande importância para a ciência.

Em meados do século XVIII, Euler, Bernoulli e Lagrange já discutiam a representação de sinais periódicos através de séries trigonométricas. Fourier (1768-1830) desenvolveu em seu estudo sobre a condução de calor pelos corpos a formulação de que um fenômeno de natureza periódica pode ser decomposto em uma série de funções senoidais, com amplitudes variáveis e frequências múltiplas da frequência fundamental, com fases coincidentes ou inversas.

São exemplos de técnicas matemáticas as transformadas, dentre as diversas pode-se citar: a transformada de Fourier, a transformada rápida de Fourier, transformada janelada de Fourier, transformada de *wavelet*, etc. A utilização de uma transformada permite, por exemplo, que um sinal no domínio do tempo possa ser analisado no domínio da frequência e posteriormente reconstituído através da transformada inversa conforme figura 22

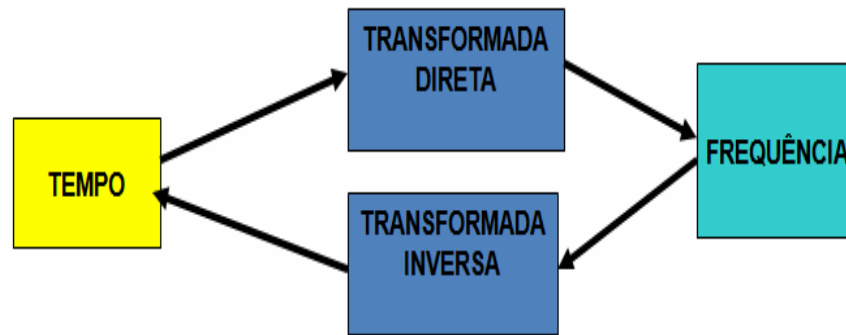


Figura 22 – Transformada direta e inversa
 Fonte: Autor, 2010

A transformada janelada de Fourier permite a visualização do sinal através da separação destes em trecho (janelas de tempo). Ajustando-se devidamente o trecho em análise, é possível presumir certa estacionaridade do sinal naquele intervalo de tempo, porém o tamanho da janela mantém-se constante em todo o plano tempo frequência. Desta forma o sinal analisado só poderá apresentar uma boa resolução no domínio do tempo ou uma boa resolução no domínio da frequência, mas não em ambos simultaneamente. Portanto, se as frequências a serem analisadas de um sinal forem muito baixas, elas podem não se encaixar em uma janela de tamanho pequena e assim não será possível detectar este intervalo do sinal.

Esta limitação não ocorre com a transformada *Wavelet*, visto que a janela de análise não apresenta comprimento fixo, variando conforme o processo de expansão (escala) de uma função base transladada no tempo, o que possibilita a transformação de um sinal do domínio do tempo para o domínio tempo x frequência, fazendo-se a *wavelet* uma das soluções para a avaliação de eventos transitórios.

3.2 Análise de Fourier

A análise de Fourier surgiu a partir das tentativas do matemático francês Jean Baptiste Joseph Fourier (1768-1830) para encontrar a solução de um problema prático, a condução do calor em um anel de ferro. Fourier demonstrou que se pode obter uma função descontínua a partir da soma de funções contínuas, conforme ilustra a figura 23 que representa um sinal quadrado e suas componentes harmônicas no domínio do tempo. O sinal quadrado original

com amplitude de pico igual a 1 poderá então ser reconstituído através da somatória das diversas harmônicas que têm amplitude e frequência diferente.

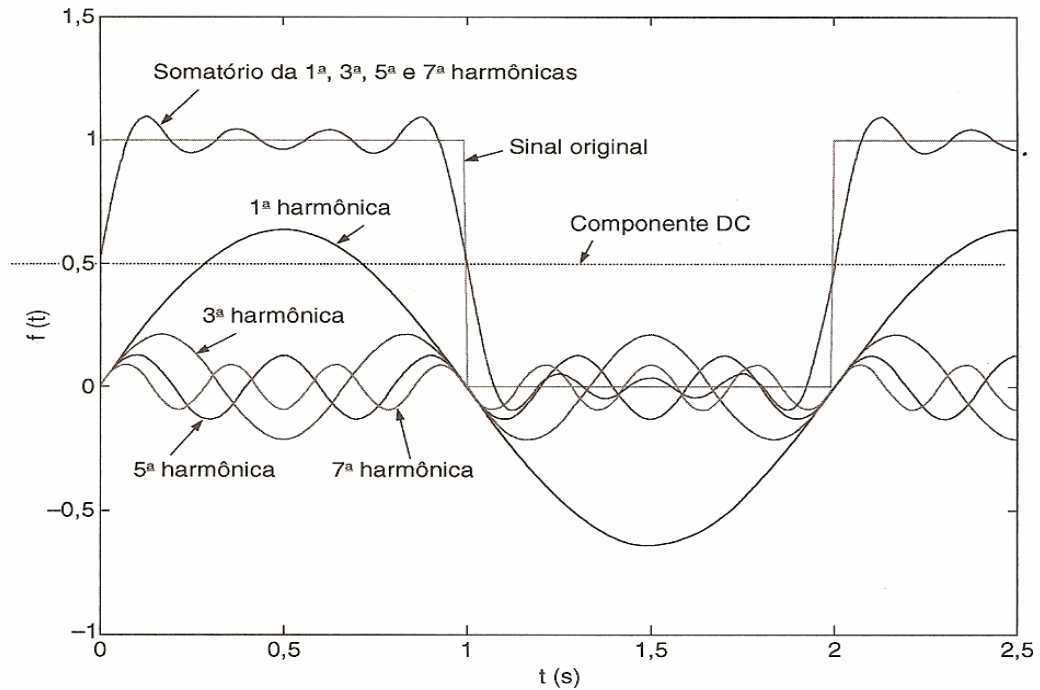


Figura 23 – Representação de um sinal quadrado e suas componentes
Fonte: BALBINOT, 2006

A série de Fourier é muito utilizada nas ciências em geral: Matemática, Engenharia, Computação, Música, Ondulatória, Processamento de Imagens, etc. É um dos instrumentos matemáticos utilizado na análise de sinais periódicos, dentre eles, os elétricos, especialmente em áudio e telecomunicações, pois postulam que qualquer sinal periódico no tempo pode ser expandido em termos de senos e co-senos através dos coeficientes de uma série trigonométrica.

Uma série numérica $f(t)$ pode ser escrita dessa forma:

Se $f: \mathbb{R} \rightarrow \mathbb{R}$ é uma função periódica de período $2T$ -periódica, suave por partes e integrável no intervalo simétrico $[-T, T]$ então, a sua *Série de Fourier* é dada por:

$$f(t) = a_0/2 + \sum_{n=1}^{\infty} a_n \cos(n\omega_0 t) + \sum_{n=1}^{\infty} b_n \text{sen}(n\omega_0 t) \quad (3.1)$$

Onde os coeficientes podem ser dados pelas expressões:

$$a_n = \frac{1}{T} \int_{-T}^T f(t) \cos(n\omega_0 t) dt, \quad (3.2)$$

$$b_n = \frac{1}{T} \int_{-T}^T f(t) \sin(n\omega_0 t) dt, \quad (3.3)$$

Para $n \geq 1$, a_0 pode ser obtido se tomarmos $n = 0$ no coeficiente a_n .

A frequência que denominamos de fundamental, $\omega_0 = \frac{2\pi}{T}$, representa a frequência mais baixa em que a função temporal será decomposta e $a_0, a_1, \dots, a_n, \dots, b_0, b_1, \dots, b_n$ são os coeficientes da função trigonométrica. A figura 3 representa um sinal quadrado, sendo suas componentes dadas por:

$$f(x) = 5 + 4 \operatorname{sen} x + (4/3) \operatorname{sen} 3x + (4/5) \operatorname{sen} 5x + \dots \quad (3.4)$$




Figura 24 – Representação de um sinal quadrado e suas componentes base.

Fonte: www.bfbrasil.com/forum/showthread.php?t42900

A primeira parcela da equação (3.4) é um sinal que representa a componente DC com valor 5. A segunda parcela $4 \operatorname{sen} x$ representa a componente fundamental com a mesma frequência do sinal quadrado, maior amplitude e maior proximidade deste. As parcelas seguintes são múltiplas da componente fundamental.

3.3 Transformada de Fourier (FT)

A transformada de Fourier (FT) foi desenvolvida inicialmente para a análise de sinais contínuos, porém a utilização da mesma em tecnologia digital possibilitou a adaptação deste método para análise de sinais discretizados e conseqüentemente o desenvolvimento de processos computacionais mais rápidos.

A utilidade da transformada de Fourier está na sua habilidade de analisar um sinal aperiódico no domínio do tempo pelo domínio da freqüência como afirma GRAPS (1995). Ao se aplicar a transformada de Fourier (FT) em uma função ou um sinal temporal $f(t)$ é possível extrair informações sobre as freqüências contidas neste, porém as informações sobre a localização destas freqüências no domínio do tempo não é possível. A transformada contínua de Fourier é definida pela equação (3.5)

$$F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-j\omega t} dt \quad (3.5)$$

Onde $j = \sqrt{-1}$, $\omega = \frac{2\pi}{T}$, e $e^{-j\omega t} = \cos(\omega t) - j \text{sen}(\omega t)$

Na equação (3.9) para cada $2\pi f$ ($f=1/T$), se obtém um número complexo que contém informações de magnitude e de fase das componentes de freqüência f .

A transformada inversa de Fourier é dada pela equação abaixo:

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega)e^{j\omega t} d\omega \quad (3.6)$$

Desta forma, uma função complexa no domínio do tempo pode ser representada de forma simplificada no domínio da freqüência, constituindo uma somatória de senos e cosenos. Logo, se for gerado um sinal senoidal de amplitude 1volt e freqüência 3Hz e aplicada a transformada de Fourier, obtém-se no domínio da freqüência, uma concentração de energia em torno da freqüência fundamental deste sinal. A figura 25 ilustra um sinal no domínio do tempo $s(t)$ representado no domínio da freqüência $S(\omega)$.




Figura 25 – Representação de um sinal senoidal no domínio do tempo e da frequência.
 Fonte: ARAUJO, 2009

3.4 Transformada de Fourier de tempo curto (STFT)

Segundo GOSWAMI & CHAN (1999), a transformada de Fourier é uma ferramenta matemática poderosa para análise de sinais estacionários, porém considerando que para a realização de cálculos de todo o espectro de frequência do sinal é necessário ter o conhecimento completo deste, e que qualquer perturbação em um determinado trecho do sinal provoca uma grande mudança em escopo global do sinal, isto torna Fourier uma ferramenta não tão interessante para trabalho com séries de sinais não estacionários cujo conteúdo espectral varia no tempo, como é o caso de sinais biomédicos. A figura 26a representa um sinal estacionário onde não há ocorrência de variações ao longo do tempo, porém a figura 26b representa o gráfico de um sinal não estacionário onde ocorre a variação de frequência e amplitude.




Figura 26a – Representação de um sinal não estacionário.
 Fonte: Autor, 2010




Figura 26b – Representação de um sinal não estacionário.

Fonte: Autor, 2010

Assim, a análise de um sinal em um determinado instante de tempo não terá exatidão, pois será impossível verificar quais frequências estão presentes em um dado intervalo de tempo, por outro lado, se o intervalo de tempo é infinito, será possível identificar cada uma das frequências presentes, porém não a localização desta no domínio do tempo (incerteza no domínio do tempo). A transformada de Fourier apresenta estas características, visto que trata do sinal no intervalo $[-\infty, \infty]$, conforme equação 3.11

$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt \quad (3.7)$$

Para minimizar a perda de informações temporais da transformada de Fourier, foram desenvolvidas algumas técnicas. Em 1946 Dennis Gabor, prêmio Nobel de física em 1971, propõe uma modificação na equação da transformada de Fourier com o objetivo de balancear a análise dos domínios tempo frequência e desta forma melhorar o tratamento de sinais não-estacionários. Sua idéia fundamental é analisar apenas uma pequena seção do sinal a cada intervalo de tempo. Para isso, é definida uma função janela a ser multiplicada pelo sinal no domínio do tempo. Esta modificação proporcionou o tratamento dos sinais sob intervalos, possibilitando uma característica de localidade à análise de Fourier. Para solucionar os limites da integral, Gabor incluiu no interior da integral a função gaussiana $g(t)$. Assim o produto da função gaussiana pelo sinal $f(t)$ limita a região a ser analisada, ou seja cria um janelamento temporal do sinal, conforme equação 3.12

$$F(\omega) = \int_{-\infty}^{\infty} g^*(t - \tau) f(t) e^{-j\omega t} dt \quad (3.8)$$

A figura 27 abaixo representa uma função gaussiana




Figura 27 – Gráfico de uma função gaussiana $g(t)$
Fonte: TRIOLA, 2008

O deslocamento de um intervalo para o outro é realizado movendo a região de maior energia, ou seja, deslocando a função gaussiana através do parâmetro τ . A técnica ficou conhecida como Transformada de Gabor ou STFT (do inglês: *Short Time Fourier Transform*), e pode ser interpretada como uma janela deslizante de tamanho fixo que percorre o sinal, definindo intervalos a serem processados por uma espécie de “Transformada de Fourier Local” (OLIVEIRA 2003), conforme figura 28




Figura 28 – Representação da função janelamento
Fonte: MATLAB, 7

A figura 29 representa a interpretação para a Transformada de Gabor onde a função gaussiana age diretamente sobre as funções senoidais de base. A resposta entre a função

gaussiana e a senoide funciona como uma modulação em amplitude, gerando uma onda oscilatória com energia concentrada e delimitada.




Figura 29 – Efeito gaussiano sobre uma função base senoidal

Fonte: ARAUJO, 2009

Esta resposta mostra a consequência diretamente do princípio da incerteza, pois limitando a senoide no tempo $s(t)$ (maior resolução no tempo), temos uma resposta mais espalhada com menor resolução no domínio da frequência $S(\omega)$.

3.5 Wavelet

3.5.1 Introdução

“A transformada wavelet é uma ferramenta que fatia dados ou funções ou operadores em componentes frequenciais diferentes, e então estuda cada componente com uma resolução casada com sua escala”

I. Daubechies

A transformada janelada de Fourier permite a visualização do sinal através da separação destes em trecho (janelas de tempo). Ajustando-se devidamente o trecho em

análise, é possível presumir certa estacionaridade do sinal naquele intervalo de tempo, porém o tamanho da janela mantém-se constante em todo o plano tempo frequência. Desta forma o sinal analisado só poderá apresentar uma boa resolução no domínio do tempo ou uma boa resolução no domínio da frequência, mas não em ambos simultaneamente. Portanto, se as frequências a serem analisadas de um sinal forem muito baixas, elas podem não se encaixar em uma janela de tamanho pequena e assim não será possível detectar este intervalo do sinal. A figura 30 representa o exemplo de uma janela com largura de 1 milissegundo em que só “cabem” frequências acima de 1kHz.

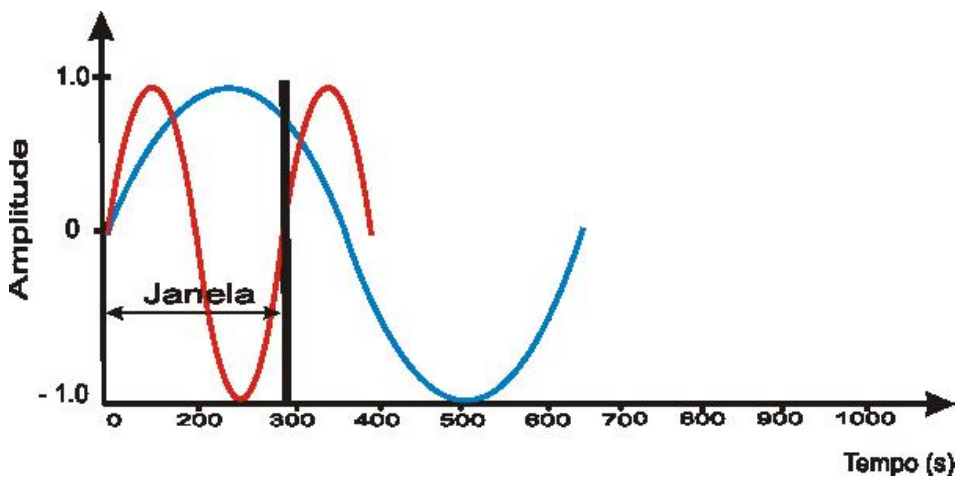


Figura 30 – Representação do janelamento de uma STFT
 Fonte: RICCIOTTI, 2006

Um dos processos utilizados para análise de sinais é realizado através do método conhecido como *Wavelet*; que apresenta como características a concentração de energia localizada em um dado ponto no tempo, permitindo a análise de fenômenos transitórios, não-estacionários e variantes no tempo, mantendo as características oscilatórias das ondas, o que possibilita a análise no domínio do tempo e da frequência (TASWELL, 1994).

A teoria *wavelet* está baseada na representação de funções genéricas em termos de “*blocos construtivos básicos*”, ou “*átomos*”, fixos em diferentes escalas e posições. Desta forma a *Wavelet* é uma função que tem a capacidade de descrever e decompor funções no domínio da frequência, possibilitando a análise em diferentes escalas de tempo e frequência destas funções. A decomposição do sinal temporal não será mais efetuada em termos de senos e cosenos, como acontecia no caso de Fourier, mas em termos de funções localizadas no

tempo (funções que assumem valores num intervalo de tempo não definido) e sem escala fixa. Assim parte-se de uma certa função que se deseja analisar e obtém-se a base em outra função.

A decomposição de uma função temporal que utiliza *Wavelets* é denominada de transformada *Wavelet*. A Transformada *Wavelet* é considerada uma técnica por janelamento, semelhante à STFT, porém com a dimensão da janela variável, o que permite uma análise do sinal no espaço tempo frequência, podendo ainda identificar quais componentes espectrais existem em um determinado intervalo de tempo. “A partir da análise *wavelet* é possível ter a visualização tanto da floresta quanto de uma árvore” (GRAPS, 1995).

3.5.2 Evolução Histórica

A utilização de *wavelets* em análise e processamento de sinais é relativamente recente, com início da década de 1980. A necessidade de se focalizar um sinal sob várias escalas diferentes e analisá-lo com várias resoluções surgiu independentemente em várias áreas da matemática, física e engenharia.

Em 1910, durante os estudos para construção de bases para representar funções, Haar construiu a primeira família *wavelet* ortonormal de suporte compacto que leva o seu nome, porém, apesar destas *wavelets* terem características interessantes, não eram continuamente diferenciáveis, o que limitava sua aplicabilidade. Durante os anos 30, pesquisadores descobriram novas vantagens das *wavelets* com estudos de funções-base com variação de escala, onde as funções-base são um conjunto de funções que, somadas, compõem uma determinada função.

Apesar das funções-base apresentarem escala variável, era necessária uma representação do sinal que permitisse sua análise em tempo e frequência, como cita Balian (RABELO, 1999):

A informação útil é, de fato, freqüentemente veiculada ao mesmo tempo pelas freqüências emitidas e pela estrutura temporal do sinal. A representação de um sinal como função do tempo exhibe mal o espectro das freqüências em jogo, enquanto que ao contrário sua análise de Fourier mascara o instante de emissão e a duração de cada um dos elementos do sinal. Uma representação adequada deveria combinar as vantagens destas duas descrições complementares, apresentando além disso um caráter discreto melhor adaptado à teoria de comunicações.

O desenvolvimento das *wavelets* teve início em 1982, com o geofísico francês Jean Morlet, que em seus trabalhos de geoexploração teve necessidade de uma ferramenta matemática capaz de fazer a análise de frequências altas e baixas simultaneamente. Assim como a maioria dos sinais na natureza, os sísmicos também são de natureza não-estacionária com componente fundamental de baixa frequência, porém com ocorrência de variações em alta frequências, para isto foi criado um mecanismo em que a função de janela pudesse ser comprimida ou expandida.

Grossmann incrementa o poder da ferramenta desenvolvendo a fórmula inversa à integral da transformada de Morlet. Posteriormente, Mallat incrementou ainda mais a ferramenta com a análise de multiresolução. Anos depois, Ingrid Daubechies baseou-se no trabalho de Mallat para construir o conjunto de *wavelets* de base ortonormal que são as mais utilizadas atualmente.

A partir de 1994 verifica-se uma tendência de vários segmentos da comunidade científica em explorar o potencial das *wavelets* principalmente em aplicações de codificação, representação e compressão de sinais. Observa-se a partir de então um interesse em torno de aplicações gráficas, especialmente compressão de imagens e processamento gráfico em multiresolução.

3.5.3 Transformada de *Wavelet*

A análise de sinais através da Transformada de Fourier foi concebida para verificar sinais estacionários, ou seja, funções cujo espectro não varia no decorrer do tempo. Desta forma, a análise de Fourier não tem caráter local, é puramente frequencial, como pode ser explicado pelo Princípio da Incerteza de Gabor-Heisenberg o qual estabelece que seja possível fazer correspondências entre os intervalos de tempo de uma função e as bandas de frequência presentes. Contudo, afirma que a diminuição do intervalo de tempo (maior exatidão no domínio do tempo) reflete numa maior incerteza no domínio da frequência (GABOR 1946).

A transformada de Gabor é um avanço matemático que consegue fazer a análise do sinal nos domínios do tempo e frequência simultaneamente. Porém, o problema ainda não está completamente resolvido, pois uma vez definido o tamanho das janelas de processamento, a

relação de incerteza entre os domínios não pode ser alterada. A análise passa a considerar um intervalo fixo, uma única resolução para todas as frequências. A análise de resolução única é representada graficamente pela figura 31




Figura 31 – Representação da análise com uma única resolução
Fonte: ARAUJO, 2009

Uma vez escolhido o tamanho da janela ele é o mesmo para todas as frequências e isto incorre em imprecisões. Isto pode se exemplificado observando-se um sinal que inicialmente senoidal sofre uma mudança de frequência e de forma, passando a ser triangular conforme figura 32.




Figura 32- Problema da análise de resolução única
Fonte: ARAUJO, 2009

É possível observar que uma mudança no formato e frequência do sinal não é facilmente perceptível quando se usa uma janela fixa. É necessária então uma melhor resolução para as altas frequências, o que não é possível na análise de Gabor. Generalizando, a dinâmica dos sinais de alta frequência pode ser percebida por meio da observação de um

curto intervalo ou pequenas janelas de tempo, enquanto a dinâmica dos sinais de baixa frequência só é compreendida após a análise de um intervalo maior ou janelamento mais amplo.

Conforme mostrado anteriormente, a Transformada de Gabor é ineficiente para a análise destes sinais, pois promove uma análise com uma única resolução. Definir um tamanho fixo para janela gaussiana que se adéque a análise de todas as frequências é praticamente impossível. Assim, Morlet desenvolveu uma nova técnica matemática que permitia a análise sobre múltiplas resoluções (ARAUJO, 2009). A técnica ficou conhecida como Transformada *Wavelet*. A expressão *Wavelet* significa “ondinha”. Semelhante a Gabor, Morlet fez utilização de ondas oscilatória porém, não mais senoidais e com energia concentrada, conforme ilustra a figura33.




Figura 33 – Representação de uma *wavelet* de Morlet
Fonte: ARAUJO, 2009

As transformadas *Wavelet* são funções obtidas a partir de uma função protótipo chamadas de *wavelet* mãe $\Psi(t)$, transladadas (deslocamento no tempo) e dilatadas (contrações) de forma diferente entre si, que tem como objetivo a obtenção de uma família de funções.

A transformada *Wavelet* é definida pela equação 3.9, onde a é o parâmetro de escala (contração ou dilatação) que permite a expansão da energia ou janelamento durante a análise das menores frequências e comprimir na análise das altas frequências. O parâmetro b é que

define a localização temporal em que as frequências ocorrem e equivale ao τ da transformada de Gabor.


$$W(a, b) = \int_{-\infty}^{+\infty} f(t) \Psi_{a, b}(t) dt \quad (3.9)$$

Desta forma a transformada *Wavelet* representa um sinal como a soma de *Wavelet* de uma mesma família, de modo semelhante à transformada de Fourier, onde $\Psi_{a, b}(t)$ é denominada de *Wavelet-mãe* e definida conforme equação (3.10)


$$\Psi_{a, b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (3.10)$$

A utilidade das *wavelets* consiste na possibilidade de atuarem como funções base para a composição de outras funções. As bases *wavelets* podem ser redundantes ou ortonormais de uma forma mais sofisticada que as bases senoidais dos métodos de Fourier.

As funções geradas a partir de translações e escalas da *wavelet-mãe* são denominadas de *wavelet-filhas*. Variando-se apropriadamente os termos a e b , constrói-se a base das funções da transformada *wavelet*, onde a constante $\frac{1}{\sqrt{a}}$ é usada para normalização da energia da função, evitando que as mudanças de escalas modifiquem a energia desta, fazendo com que à medida que a função é comprimida a sua amplitude aumenta. A figura 34 e 35 representa graficamente o comportamento de uma onda *wavelet* com a variação da escala a e o parâmetro de translação b em função do tempo.



$$f(t) = \Psi(t) ; \quad a = 1$$



$$f(t) = \Psi(t) ; \quad a = 1/2$$




Figura 34 – Representação da influência do parâmetro a de escala.

Fonte: Autor, 2010

Variando-se o parâmetro de translação b obtém-se o deslocamento do sinal no eixo do tempo conforme figura 3.14




Figura 35 – Representação da influência do parâmetro de translação b .

Fonte: Autor, 2010

Este método tem uma grande abrangência e poder para a análise e compressão de sinais com alta precisão de resolução no tempo para eventos de curta duração (altas frequências) e uma alta precisão de resolução na frequência para eventos de longa duração (baixa frequência). A figura 36 representa o processo de janelamento flexível, onde tempo e frequência não são fixas.




Figura 36- Relação tempo frequência com janelamento variável

Fonte: MATLAB, 7

3.5.4 Propriedades

Algumas propriedades devem ser satisfeitas para uma *wavelet* Ψ seja útil em aplicações práticas em processamento de sinais e na análise de espaços funcionais. Estes requisitos são:

- i Energia finita – esta propriedade implica que, $\int_{-\infty}^{\infty} |\Psi(t)|^2 dt < \infty$ o que torna possível a reconstrução do sinal devido à conservação de energia, através da transformada inversa.
- ii Condição de admissibilidade: a função *wavelet* mãe $\Psi(t)$ deve possuir média nula, ou seja, $\int_{-\infty}^{\infty} \Psi(t) dt = 0$.
- iii Possuírem certo grau de regularidade (suavidade)
- iv Suporte compacto: A maioria da energia desta *wavelet* está restrita a um intervalo finito, ou seja, a função é exatamente zero fora deste intervalo. Esta propriedade garante boa localização espacial, logo $\Psi(t) \rightarrow 0$ rapidamente quando $t \rightarrow \infty$.

3.5.5 Transformada *Wavelet* Contínua (TWC)

A Transformada *Wavelet* Contínua (TWC) é definida como a soma em todo o tempo do sinal multiplicado pela função *Wavelet*-mãe Ψ em uma dada escala e transladada no domínio do tempo. Esta transformada gera coeficientes em funções da escala e da posição como definido equação 3.13. Existem diferentes tipos de *Wavelets*-mãe que podem ser utilizados em uma TWC, sendo cada tipo mais apropriado a um sinal conforme a similaridade.

3.5.6 Transformada *Wavelet* Discreta (TWD)

A utilização da transformada *wavelet* em sua forma matemática discreta dispensa as fases sensíveis a erros e que são de difícil implementação em tempo real, devido à implementação computacional ser direta. A Transformada *wavelet* pode ser utilizada sob a forma discreta, sem perder suas qualidades e propriedades, e portando de maneira numericamente estável (SILVA, 2006).

Como na Transformada *wavelet* contínua a variável temporal t , os parâmetros de translação e escala descritos pela equação 3.13, variam de forma infinitesimal o torna a implementação desta transformada de alto custo computacional. A alteração infinitesimal na função de base implica de forma inexpressiva sobre o resultado do produto interno. Desta forma, definir variações espaçadas dos parâmetros a e b não compromete a capacidade de análise.

A transformada *wavelet* discreta apresenta os parâmetros de escala a e de deslocamento b apenas valores discretos. Esta discretização está expressa nas equações 3.15 e 3.16

$$a = a_0^{-m} \quad (3.11)$$

$$b = nb_0 a_0^{-m} \quad (3.12)$$

Onde os termos a_0 e b_0 são chamados respectivamente de passos de escala e transição responsáveis pela variação de a e b . As variáveis m e n pertencem ao conjunto dos inteiros positivos e são parâmetros discretos. Assim a transformada *wavelet* conforme a equação 3.13 considera os parâmetros discretos.

$$W(m, n) = \frac{1}{\sqrt{a_0^{-m}}} \int_{-\infty}^{+\infty} f(t) \Psi \left(\frac{t - nb_0 a_0^{-m}}{a_0^{-m}} \right) dt \quad (3.13)$$

Para um bom desempenho da DWT, deve-se escolher criteriosamente os valores de a_0 e b_0 . A mais simples e comum escolha é fazendo $a_0 = 2$ e $b_0 = 1$. Nesse caso a transformada *wavelet* é chamada diádica-ortonormal. Diádica pela potenciação na base 2, e ortonormal pela formação de bases ortonormais (funções de quadrado integráveis) pelas famílias de *wavelets* expandidas (Vetterli, 1992).

3.5.7 Análise de Multiresolução

O uso de filtros para o cálculo da TWD é a forma mais eficiente de análise de sinais, e esta técnica foi desenvolvida em 1989 pelo engenheiro francês Stephane Mallat, que implementou o algoritmo piramidal chamado de análise multi-resolução (AMR), onde o sinal a ser analisado é decomposto sucessivamente através de banco de filtros. Esta técnica exigiu menos recursos computacionais que os algoritmos propostos anteriormente, e, portanto tornou-se a maneira mais eficiente de se analisar sinais através da transformas de *wavelet*.

A análise de multiresolução é uma técnica que permite analisar os sinais em múltiplas bandas de freqüências através de um filtro passa-baixa e outro passa-alta conforme figura 37.

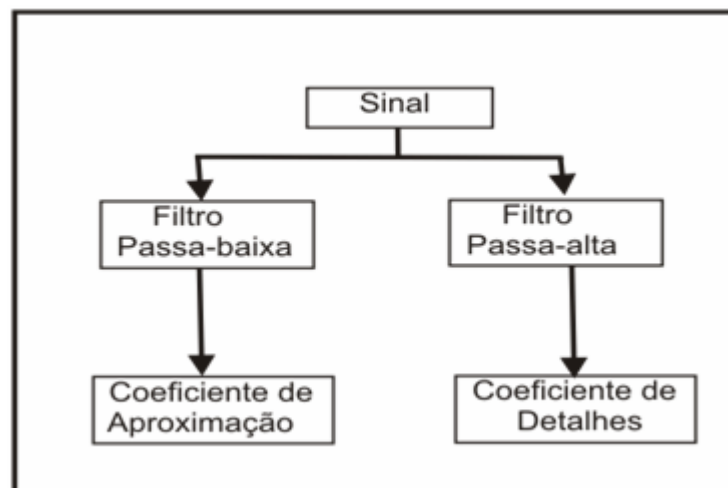


Figura 37 – Representação da decomposição do sinal.

Fonte: Autor, 2010

O filtro passa-alta produz os coeficiente chamados de detalhe da decomposição da *wavelet*, já o filtro passa-baixa produz coeficientes de aproximação. As componentes de baixa freqüência contêm a maior quantidade de informação e sua remoção compromete drasticamente o sinal. As componentes de alta freqüência representam os detalhes da informação de tal forma que sua remoção altera o sinal, porém não afeta a sua inteligibilidade.

O fato de as *wavelet* representarem sinais comprimidos significa que cada decomposição possui uma determinada informação do sinal em diferente células tempo-freqüência devidamente ajustada.

O processo de decomposição por multiresolução consiste em uma codificação em sub-bandas de forma interativa com sucessivas decomposições, onde o sinal filtrado pelos filtros passa-baixa (L) e passa-alta (H) sofre uma decimação, dando origem aos coeficientes *wavelet* de aproximação (cA) e detalhe (cD), sendo cada um com a metade da dimensão do sinal original conforme figura 38.

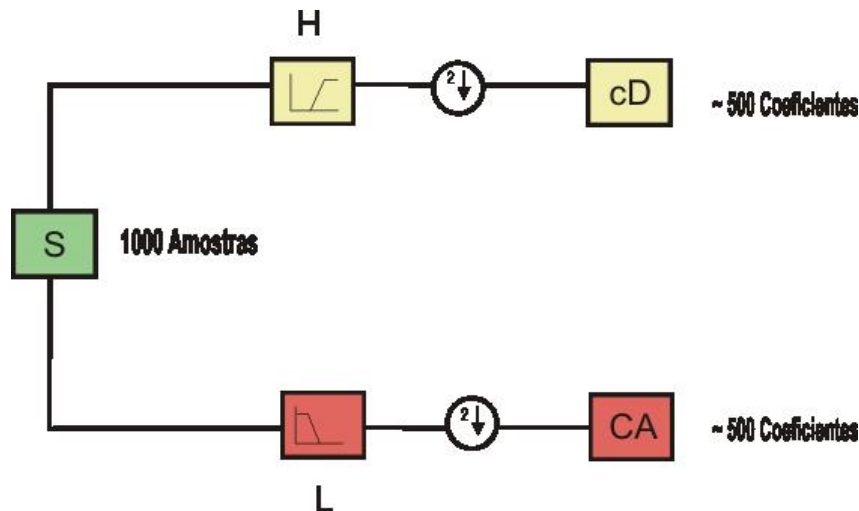


Figura 38 – Representação do processo de filtragem e decimação (L filtro passa-baixa e H filtro passa-alta).

Fonte:RICCIOTTI. 2006

A decimação é um processo em que parte do sinal discreto é descartado espaçadamente, que equivale a uma reamostragem de um sinal contínuo com taxa de amostragem menor. Este processo é interativo com sucessivas decomposições nos coeficientes de aproximação e detalhamento, resultando em uma árvore de decomposição da *wavelet* em sub-bandas que pode ser vista como uma estrutura de banco de filtros chamada de filtro de quadratura conforme figura 39.

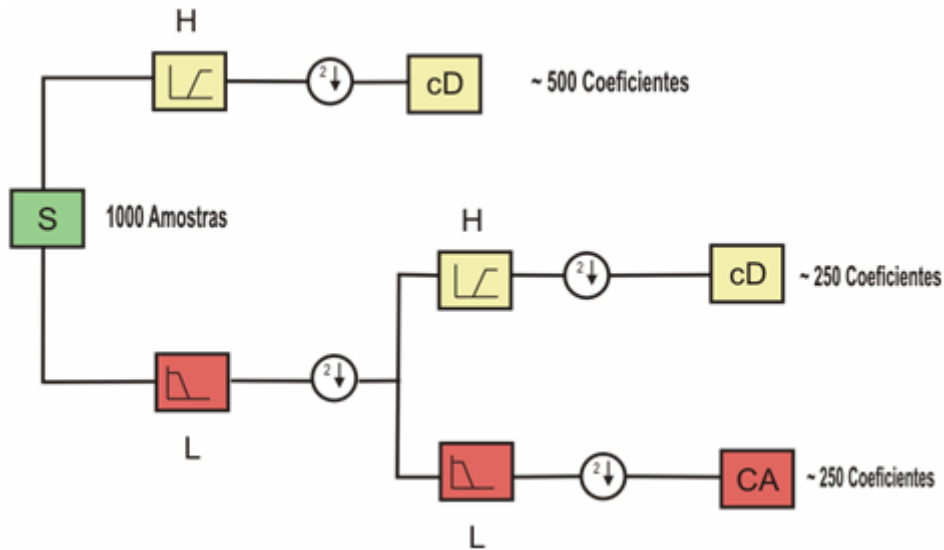


Figura 39 – Decomposição DWT em sub-bandas
 Fonte: RICCIOTTI. 2006

O símbolo $\downarrow 2$, conhecido como operador de decimação por dois, indica que a cada dois valores obtidos na convolução, um é descartado. Na realidade, o operador é apenas simbólico, os valores “desnecessários” não são calculados, uma vez que calcular coeficientes para descartar em seguida é um desperdício computacional.

O princípio de Nyquist estabelece que os sinais devem ser amostrados com uma frequência superior ao dobro da máxima frequência presente. Como consequência, se um sinal é amostrado a uma frequência f_s , a análise espectral só deve considerar as frequências inferiores a metade de f_s .

3.5.8 Tipos de *Wavelet*

Atualmente vários tipos de *wavelets* são citados na literatura. O uso destas estão associado à aplicação específica do sinal. Vários pesquisadores estão desenvolvendo novas regras para a construção de novas *wavelet*, conforme as necessidades e restrições e que cada aplicação. Com isto, conclui-se que é possível gerar uma diversidade infinita de *wavelets* diferentes adequada ao processamento de um tipo de sinal específico levando à obtenção de resultados melhores.

3.5.9 *Wavelet* de Haar

Desenvolvida por Haar por volta de 1910, esta *wavelet* é a mais simples e possui dois coeficientes de filtros, de tal forma que uma faixa de transição longa é garantida. A função da *Wavelet* Haar é representada por uma onda quadrada simétrica e ortogonal. A figura 40 mostra uma *wavelet* Haar com contração e deslocamento, gerando $W(2t)$ e $W(2t-1)$.




Figura 40 – Representação gráfica da *wavelet* Harr com contração e deslocamento
 Fonte: FARIA, 1997

3.5.10 *Wavelet* Daubechies

Estas *wavelet* foram criadas por Ingrid Daubechies no início dos anos 80 e apresentam capacidade de análise e síntese muito mais efetiva do que as *wavelet* de Harr e estão ligadas a famílias de filtros com propriedades especiais. Estes filtros são ortogonais e apresentam máxima planura ou suavidade nas funções maximizando a taxa de decaimento obtendo-se assim uma melhor resolução no domínio do tempo. As *Wavelets* de Daubechies são assimétricas, contínuas e quanto maior o número de decaimentos mais suave será a banda de transição. Estas *Wavelets* foram pioneiras no sentido de tornar prática a análise discreta. Nas *Wavelets* de Daubechies o número de momentos nulos determina sua numeração conforme figura 41.

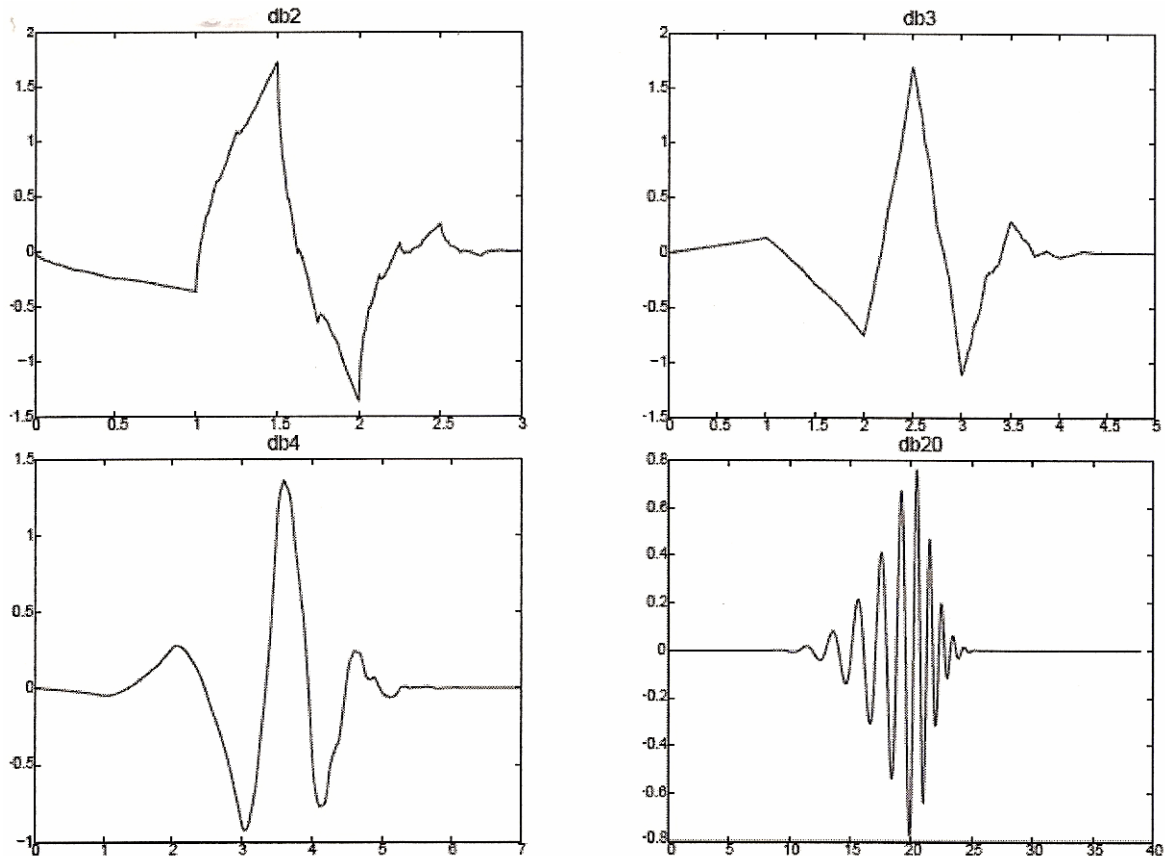


Figura 41 – Representação de quatro modelos de *wavelet*-mães da família Daubechies.
 Fonte: SILVA, 2006

Daubechies construiu uma série de outras *wavelets* ortogonais, dentre elas as *Symlets*, que mantêm algumas características da família das Daubechies, entretanto, elas foram projetadas para satisfazer as condições de simetria e fase linear, não sendo perfeitamente simétricas, pois a condição de ortogonalidade torna isto impossível.

As *wavelets* de *Coiflet*, também construídas por Daubechies, limitam os momentos de decaimento na função *wavelet* e também na função escala. Como vantagem, os coeficientes de aproximação podem ser representados pelas amostras do sinal. No entanto a ordem dos filtros torna-se elevada.

O espectro da transformada wavelet é um gráfico em 3 dimensões onde a altura significa a importância dos coeficientes das *wavelets*, ou seja, a importância de cada ponto da escala (eixo y). Em outras palavras, a altura mede qual a frequência que mais aparece no conjunto de dados naquele exato momento do eixo do tempo. Esse espectro é mostrado na figura 42, onde o eixo x é o tempo, o eixo y é a escala e o eixo z é a amplitude dos coeficientes, ou a própria transformada wavelet.

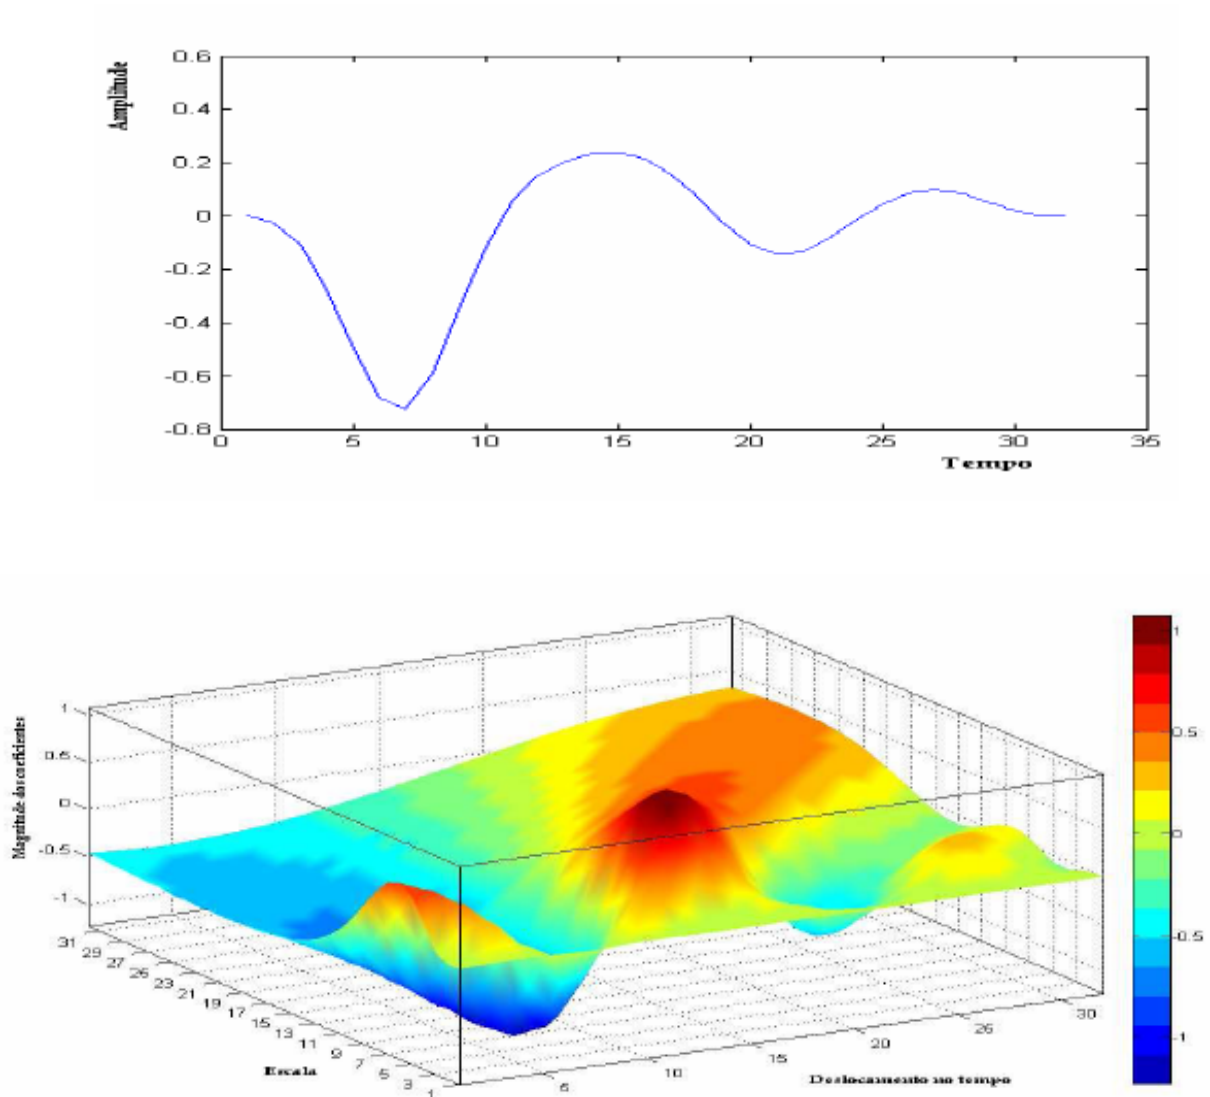


Figura 42 – Representação tridimensional de um sinal através da transformada de *Wavelet*
 Fonte: OLIVEIRA, 2009

A Transformada *Wavelet* possibilita a aquisição de informações que não são obtidas por meio das Transformadas de Fourier e Gabor. Estas informações tornam as mudanças de frequência mais visíveis, proporcionando maior clareza a análise espectral. E por isso, vêm sendo utilizadas em diversas aplicações de tratamento de sinais de áudio e vídeo, compressão de imagens, reconhecimento de voz, etc. O objetivo deste trabalho é mostrar que tais informações podem ser utilizadas, também, para detecção de patologias pulmonares.

4 REDES NEURAIAS ARTIFICIAIS - RNA

A rede neural artificial (RNA) consiste de um modelo matemático não linear, baseado no funcionamento do cérebro humano. Conforme sua configuração pode ser classificado em concentrado ou distribuído, contínuo ou discreto ou ainda, estocástico ou determinístico.

4.1 Introdução

Na última década, grandes avanços foram realizados na identificação e análise de sistemas dinâmicos utilizando modelos não lineares provenientes da inteligência artificial. Nesta área, destacam-se os modelos obtidos a partir de regras sintáticas (lógica difusa) e principalmente, os que utilizam funções de ativação (redes neurais).

Um cérebro humano é formado por uma grande malha com cerca de 10 bilhões de neurônios, sendo cada um tipicamente conectado a outros 10.000. Esta rede tem a capacidade de aprender e identificar padrões além, de processar informações em paralelo.




Figura 43- Representação de um cérebro humano

Fonte: Stanforde (2004)

Conforme a figura 43 é possível identificar os pontos em amarelo que são os corpos celular neural biológico interligados entre si. A comunicação entre os neurônios é realizada através de impulsos eletroquímicos, e o somatório de todos estes impulsos que chegam a um neurônio representa uma quantidade de energia capaz de gerar um grau de ativação ou resposta, o qual é transmitida para o neurônio subsequente.

As redes neurais artificiais foram implementadas baseadas em diversos elementos de processamento interconectados onde cada um recebe e envia informação a uma célula neural. Com uma malha muito menor de elementos do que o cérebro humano as RNAs são capazes de aprender, executar operações não lógicas, transformações e comparações, descobrir regras ou relações e testar situações em paralelo de um problema específico (TAFNER. 1996). Tais características justificam grande aplicabilidade desta ferramenta em diversos ramos da ciência e tecnologia tais como:

- Geoprocessamento – identificações de imagens de satélite;
- Classificação de sinais biomédicos;
- Economia – previsão de índices econômicos;
- Indústrias – reconhecimento de padrões em linha de montagem;
- Recursos hídricos – previsão de chuva e vazão, modelos chuva-vazão

4.2 Histórico

Em 1943, o neurofisiologista *Warren Cullough* e o matemático *Walter Pitts* estabelecem uma analogia entre processamento de um circuito eletrônico baseado em resistores variáveis e amplificadores com o modelo de uma célula cerebral humana.

Em 1949, o psicólogo *Donald Hebb* explicou o processo celular de aprendizagem no cérebro, contribuindo para a base do aprendizado das RNAs, propondo a utilização de níveis de energia (pesos) para que uma RNA possa assimilar o conhecimento. Em 1951 *Marvin Minsky* constrói o primeiro neurocomputador chamado de *Snark*, ainda sem aplicação prática. Durante o final dos anos 50, *Frank Rosenblatt* implementa a primeira RNA semelhante às utilizadas até hoje a qual foi denominada de *Perceptron*, é uma rede de uma única camada capaz de aprender e identificar padrões conforme a proposta de *Hebb*. Em 1960, *Widrow e Hoff* formulam a RNA *Adaline* (*Adaptative Linear Element*). Em 1969 é então publicado por *Marvin Minsky e Seymour Papert* o livro ‘PERCEPTRON’ o qual resumira severas críticas sobre as pesquisas em RNA, o que causou sério impacto nos investimentos nessa tecnologia até quando *Paul Werbos* lançou as bases do algoritmo de treinamento de retropropagação;(*backpropagation*), as quais foram publicadas em 1986 por *Rummelhart e McClelland*.

4.3 A Rede Neural Artificial

As redes neurais artificiais (RNAs) se baseiam na simulação do neurônio biológico, que é constituído basicamente por dendritos, axônio e corpo celular conforme figura 44.




Figura 44 – Representação da estrutura básica de um neurônio cerebral
 Fonte: LINHARES; GEWANDSZNAJDER, 1997.

Os neurônios são as unidades de processamento e, por isso, são essenciais para o seu funcionamento e as conexões entre os vários neurônios formam a topologia da rede neural. Os dendritos funcionam como entradas para os sinais proveniente de outros neurônios. Os axônios atuam como canal de transmissão do impulso e as conexões ou sinapse entre os dendritos e os axônios são de natureza eletroquímica e medeiam as interações entre os neurônios. A sinapse imposta ao neurônio pode ser excitatória ou inibitória conforme a polaridade do neurotransmissor. Desta forma, o fluxo de informações entra pela árvore dentrital e sai pelo axônio.

Uma rede neural artificial é formada por unidades de processamento chamadas de neurônios, os quais são divididos em sinapse, o *bias* ou polarização, o somador e a função de ativação como mostra a figura 45

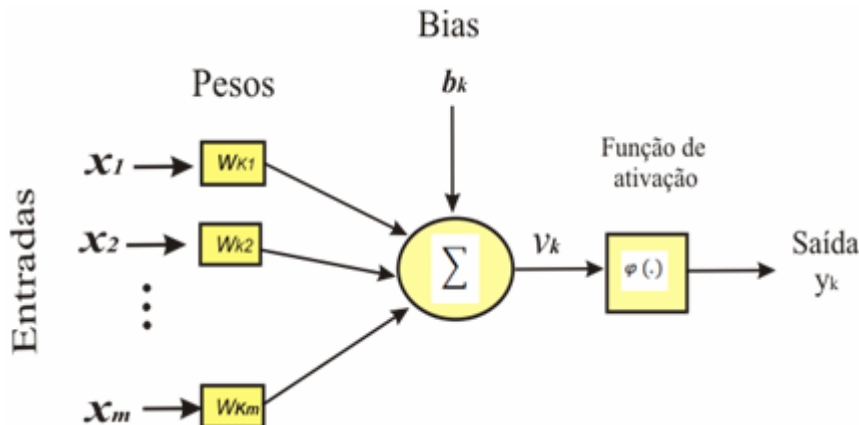


Figura 45- Representação de um neurônio artificial não-linear

Fonte: HAYKIN, 2001

As unidades da rede neural estão conectadas às entradas e entre si pelas sinapse ou canais de comunicação e estas são relacionados a um peso. Os valores x_1, x_2, \dots, x_m correspondem aos sinais de entrada da rede, e $w_{k1}, w_{k2}, \dots, w_{km}$ correspondem aos pesos simpáticos do neurônio k ; u_k é a saída linear consequência da combinação dos sinais de entrada. O neurônio recebe diversos sinais de entrada através dos dendritos x_n e cada sinal é multiplicado por um peso w_{kn} , sendo o resultado apresentado à entrada do somador (Σ). A saída do somador é uma combinação linear dos sinais ponderados da entrada. Se esta soma for superior a um determinado limite, será gerado um potencial de ação na saída que será por sua vez transmitido para os demais neurônios.

As operações realizadas por um neurônio padrão k podem ser representadas pelas seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (4.1)$$

$$y_k = \varphi(u_k + b_k) \quad (4.2)$$

A função de ativação $\varphi(.)$ restringe a amplitude da saída de um neurônio, uma vez que limita o intervalo de saída da amplitude do sinal para um valor finito encerrado no intervalo $[0,1]$ ou ainda alternadamente entre $[-1,1]$. O neurônio será ativado (saída próxima de 1), quando entradas “corretas” forem apresentadas à entrada da RNA, e será desativado

(saída próxima de zero), quando entradas “erradas” forem apresentadas à rede (RUSSEL & NORVIG, 2004).

As principais funções de transferência mais utilizadas são: função limiar ou degrau, linear por partes ou rampa e a função sigmóide.

Muitas vezes as funções de transferência possuem características restritivas: isto significa que podem não produzir efeitos num neurônio seguinte quando o estímulo for abaixo de um valor mínimo. As funções rampa e degrau possuem ações restritivas para valores extremos. Isto significa que, ultrapassado certo limite, a função dispara o valor 0; 1 ou -1.

A função degrau apresenta um limiar de corte, resultando somente valor um ou zero de acordo com o valor dado como entrada. Esta função foi utilizada por McCulloch e Pitts em 1943 e descreve a propriedade tudo-ou-nada do modelo dos mesmos autores e está descrita na equação (4.3)

$$\varphi(v) = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases} \quad (4.3)$$




Figura 46 – Representação de uma função limiar
Fonte: HAYKIN, 2001

A função linear por partes ou rampa, está descrita na equação (4.4) e apresenta um fator de amplificação linear dentro da região limite de operação. Assim esta função se comporta como um combinador linear caso o valor induzido v esteja inserido dentro de

determinada faixa operacional. Caso o valor v extrapole a faixa de operação a função atinge a região de saturação.

$$\varphi(v) = \begin{cases} 1, & v \geq 0,5 \\ v, & 0,5 > v - 0,5 \\ 0, & v \leq 0,5 \end{cases} \quad (4.4)$$




Figura 47- Representação de uma função linear
Fonte: HAYKIN, 2001

A função sigmóide representada na figura 48, é uma função estritamente crescente com balanceamento entre o comportamento linear e o não-linear. Esta função é descrita na equação (4.5) onde a é o parâmetro de inclinação.

$$\varphi = \frac{1}{1 + e^{-av}} \quad (4.5)$$




Figura 48- Representação de uma função sigmóide.
Fonte: HAYKIN, 2001

Com o parâmetro a tendendo a infinito, a função sigmóide se torna uma função limiar. Observa-se que esta função é diferenciável, característica esta importante para alguns algoritmos de treinamento de RNA.

4.4 Topologia das Redes neurais Artificiais

As redes neurais são classificadas em dois tipos básicos quanto à topologia que são: Feedforward e Feedback ou Recorrentes. Esta topologia representa o padrão de conectividade entre as unidades componentes da rede.

A rede neural feedforward é caracterizada por apresentar o fluxo de dados em um único sentido, no caso da entrada para a saída, onde nenhuma atividade de feedback ou laço é executada. Existe ainda, outra topologia que representa a topologia *feedforward* em um sentido mais estrito denominada de topologia estritamente *feedforward* a qual é caracterizada pelo fato de todas as unidades enviarem suas saídas apenas para unidades localizadas na próxima camada. [Nascimento, 2004]. A figura 49 representa os tipos de topologia das redes neurais.




Figura 49 – Representação de algumas topologias para redes neurais: (A) estritamente feedforward, (B) feedforward com conexão direta entre a camada de entrada e saída, e (C) com realimentação.

Fonte: Nascimento, 2004.

As redes neurais artificiais feedforward realizam um mapeamento do espaço de entrada para o espaço de saída, podendo acontecer a necessidade de implementação de camadas ocultas com a intenção de lograr superfícies de decisão mais complexas. Geralmente são aplicadas em modelos não-lineares dedicados a reconhecimento de padrões e classificação, enquanto que as redes neurais artificiais feedback possuem como aplicação típica a memória endereçada por conteúdo, como é o caso da rede de Hopfield. (Nascimento, 2004).

O segundo tipo de topologia são as redes neurais recorrentes que executam a retro-alimentação, isto é os neurônios da saída estão conectados a outros neurônios da entrada, sendo suas saídas determinadas pelas entradas atuais e saídas anteriores.

4.5 Estruturas das Redes Neurais Artificiais

A organização de uma rede neural artificial típica é formada por unidades que podem estar conectadas às unidades da camada posterior formando um arranjo de neurônios. Estes arranjos são separados em dois grupos básicos que são as redes de camada simples e de múltiplas camadas. A capacidade de representação das relações entre o espaço de entrada e de saída é determinada pelo número de camadas da rede neural.

4.5.1 Redes de uma única camada

As redes neurais artificiais de camada simples, são redes que apresentam uma única camada de neurônios conectados entre as entradas e a saída do sistema da rede, não havendo comunicação entre os neurônios conforme figura 50.




Figura 50 – Representação de uma rede neural de camada simples
Fonte: HAYKIN, 2001

4.5.2 Redes de múltiplas camadas

Uma RNA dispõe os neurônio em camadas, podendo estas serem múltiplas, chamada de *multilayer*, ou multicamada. Estas camadas, conforme figura 51 são: camada de entrada que são as unidades que recebem os padrões; camadas intermediárias ou ocultas que realiza o processamento e extrai os padrões e a camada de saída que conclui e apresenta a resultado final. O tamanho do vetor de saída é que define o número de neurônios desta camada. Um maior número de camadas em uma RNA implica em uma melhor capacidade de aprendizado, porém apresenta problemas de generalização. 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 figura 51 ilustra uma rede neural artificial *multilayer feedforward* com uma camada oculta. Nesta rede, o sinal é apresentado à entrada e processado pela rede intermediária, em seguida o sinal é calculado e apresentado na saída. Como todos os neurônios estão conectados a todos os nós da camada seguinte, temos então uma rede totalmente conectada. Caso contrário, teríamos uma rede parcialmente conectada.




Figura 51 – Representação de uma rede neural *multilayer*
 Fonte: HAYKIN, 2001

4.6 Aprendizagens da Rede Neural

Uma rede tem a capacidade de aprender a responder de forma precisa a um determinado conjunto de estímulos recebidos, através da modificação dos pesos em suas entradas. Por isso, as RNAs podem se adaptar para uma resposta a um padrão específico (OSÓRIO, 1991).

Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural artificial são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado de acordo com a maneira pela qual a modificação dos parâmetros ocorre. (Mendel, 1970). Desta forma as RNAs aprendem através de exemplos e isto é realizado de forma interativa ajustando os pesos simpáticos. O aprendizado de uma RNA pode ter duas formas de treinamento, o supervisionado ou o aprendizado não supervisionado.

4.6.1 Aprendizagem Supervisionada

Neste tipo de aprendizagem a RNA deverá possuir um conjunto de treinamento de entrada com a respectiva saída desejada fornecida pelo supervisor. Para cada entrada processada é obtida uma resposta que é então comparada com a resposta desejada para a obtenção do erro. Conforme a diferença entre o valor deseja e a saída, ou seja, o erro, os pesos são alterados com o objetivo de redução desta diferença. Este processo é repetido até que os erros tornem-se aceitáveis.

As RNAs *Perceptron* são exemplo de redes supervisionadas onde o algoritmo de treinamento sugerido por *Widrow e Hoff*, também conhecido como regra delta, constitui um dos mais simples, conforme equação (4.3). Os valores dos pesos são atribuídos inicialmente de forma aleatória; em seguida calcula-se a resposta, compara esta com o valor deseja e calcula-se o erro. Caso este erro não seja aceitável, faz-se o ajuste dos pesos proporcionalmente ao erro.

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (4.3)$$

onde:

$w_{ji}(n+1)$ - valor do peso corrigido na conexão ij na iteração $(n+1)$;

$w_{ji}(n)$ - valor antigo do peso na conexão ij na iteração (n) ;

$\Delta w_{ji}(n)$ - variação do no valor do peso na conexão ij proporcional ao erro na iteração (n) .

A apresentação de todos os N pares entrada saída de um conjunto de treinamento é denominado de ciclo ou época, onde a correção dos pesos ocorre a cada apresentação à rede de um exemplo de conjuntos de treinamento. O erro do exemplo é que define o valor do peso, desta forma a cada época ocorre N correções. Um outro modo é o *batch*, onde apenas uma correção é feita por cada ciclo e todos os exemplos pertencentes ao conjunto de treinamento têm seu erro médio calculado para as correções dos pesos.

4.6.2 Aprendizagem não Supervisionada

Na aprendizagem não-supervisionada, também conhecida como auto-supervisionada, os padrões são exposto para a rede e ela é responsável por agrupar os sinais de característica semelhante, não sendo necessário conhecimento prévio das saídas. Tal supervisão está presente nas redes neurais artificiais de Kohonen, em que o algoritimo de treinamento busca a classificação dos sinais de entrada (NASCIMENTO, 2004).

4.7 Rede Neural MLP (*Multi Layer Perceptron*)

Segundo HAYKIN (2001), o *perceptron* é uma das formas mais simples de uma rede neural classificar padrões linearmente separáveis, onde a rede consiste de uma estrutura de pesos simpáticos e bias balanceáveis.

A estrutura de redes neurais baseadas em *perceptron* bem como o meio para o ajuste dos pesos, fora desenvolvido em 1958, como já fundamentado por Frank Rosenblatt, onde os pesos sinápticos eram aleatórios e ajustado no decorrer do processo de treinamento.

A utilização de um único neurônio na estrutura da rede poderia separar linearmente duas classes; por outro lado, criando uma estrutura onde mais de um neurônio é utilizado, tem-se a separação em mais de duas classes, mas eles precisam ainda ser linearmente separáveis (HAYKIN, 2001).




Figura 52 – Representação da separabilidade linear

Fonte: SPAETH, 2008

Uma característica do modelo *perceptron* é a inexistência da camada intermediária, e isso gera uma rede capaz de representar bem somente relações linearmente independentes. Para solucionar esta restrição, foi apresentado o modelo *Perceptron* de Múltipla Camada (MLP – *Multi Layer Perceptron*) que com a existência de camadas intermediárias elimina a limitação. Uma rede MLP que possui apenas uma camada oculta pode representar qualquer função contínua, por menor que seja o grau de aproximação (BIANCHINI, 2001).

As redes neurais MLP também conhecida como *feedward* é uma das mais popular e conhecida RNA que permite a solução de problemas onde as classes são não-linearmente separáveis. São RNAs constituídas por um conjunto de neurônios disposto em camadas que são; a camada de entrada, camada intermediária e camada de saída. Cada neurônio está diretamente conectado a todos os neurônios da camada subsequente sem haver conexão direta entre os neurônios de entrada e os de saída. Semelhante a RNA *Perceptron* os pesos são introduzidos entre as conexões os quais são ajustados durante o processo de treinamento com o objetivo de minimizar os erros da saída da RNA. Em uma rede MLP o fluxo de sinais se propaga em uma única direção de forma progressiva, ou seja da entrada para a saída conforme figura 52.

As entradas de cada camada são multiplicadas pelos respectivos pesos de cada conexão, onde os neurônios intermediários recebem uma combinação linear dos elementos de entrada que, por sua vez, geram estímulo na função transferência a qual emite uma resposta na saída da rede.

As redes MLP representam um avanço da rede *perceptron*, onde a arquitetura da rede é *feedward* com múltiplas camadas como mostra a figura 53.




Figura 53 – Estrutura de uma rede *perceptron* de múltiplas camadas.

Fonte: HAYKIN, 2001, p.186

Esta configuração confere à rede MLP a capacidade de separação de padrões não linearmente separáveis (HAYKIN, 2001).

Esta classe de rede é treinada de forma supervisionada com o algoritmo de retropropagação de erro chamado de *backpropagation*. As características apresentadas por uma MLP são:

- Função de ativação não linear, como exemplo tem-se a função sigmoideal;
- A rede possui uma ou mais camadas escondidas, o que dá o poder da extração de características cada vez mais complexas dos vetores de valores de entrada;
- A rede apresenta grande quantidade de conexões determinadas pela suas sinapses.

4.8 Algoritmo *Backpropagation*

O algoritmo retropropagação de erro ou apenas *backpropagation* foi desenvolvido por Paul Werbos em 1974, porém popularizado em 1986 por *Rumelhart, Hinton e Williams*. Este algoritmo foi considerado como o principal fator do aparecimento das RNAs como método para a análise e solução de extensa gama de problemas e é classificado como um método de otimização que minimiza a soma de quadrados de erros.

O objetivo deste algoritmo é ajustar os coeficientes das variáveis independentes para minimizar o erro ao quadrado entre os valores de regressão e a variável dependente. Desta forma os coeficientes ficam correlacionado a uma única variável independente, logo todas as variáveis têm a mesma influência sobre o erro. No caso do algoritmo *backpropagation* nem todos os pesos têm a mesma responsabilidade sobre o erro da rede visto que existe correlação direta entre os pesos de entrada e a primeira camada intermediária, porém os pesos das camadas seguintes estão relacionados com as variáveis modificadas por combinações lineares e pelas funções de transferência.

O algoritmo de retropropagação de erro funciona da seguinte forma: tomando-se como padrão um neurônio j , teremos que o erro em sua saída na n -ésima interação de treinamento é definido conforme a equação (4.7), onde $y_j(n)$ está relacionado ao sinal da saída do neurônio j na interação n e $d_j(n)$ é o valor desejado de saída nesta interação (HAYKIN, 2001)

$$e_j(n) = d_j(n) - y_j(n) \quad (4.7)$$

A energia instantânea do erro para o neurônio j é definida como $\frac{1}{2} e_j^2(n)$. Assim o valor total da energia instantânea do erro é da do pela equação (4.8).

$$\xi(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (4.8)$$

Onde C é o conjunto de todos os neurônios da saída da rede. Seja N o total de padrões do conjunto de treinamento, a energia média do erro é dada por :

$$\xi_{med} = \frac{1}{N} \sum_{n=1}^N \xi(n) \quad (4.9)$$

A energia instantânea do erro $\xi(n)$ assim como a energia média do erro ξ_{med} , são dependentes dos pesos sinápticos e níveis de polarização, portanto o processo de

aprendizagem consiste em ajustar os parâmetros livres da RNA com o objetivo de minimizar ξ_{med} , onde os pesos são atualizados padrão a padrão, formando uma época, no instante em que o conjunto de treinamento é apresentado à entrada da rede.

O modelo de neurônio da seção 4.2 pode ter um peso unitário fixo ligado a uma entrada. Assim o neurônio j , para um conjunto de entrada x_m apresentará uma saída conforme a equação (4.10) e a saída $y_j(n)$ conforme a equação (4.11).

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) x_i(n) \quad (4.10)$$

$$y_j(n) = \varphi_j(v_j(n)) \quad (4.11)$$

A correção de peso sináptico $\Delta w_{ji}(n)$ aplicada pelo algoritmo de retropropagação é proporcional à derivada parcial $\frac{\partial \xi(n)}{\partial w_{ji}(n)}$ que determina a direção de busca no espaço de pesos para o peso sináptico $\Delta w_{ji}(n)$ e pode ser expresso de acordo com a equação (4.12) (HAYKIN,2001).

$$\frac{\partial \xi(n)}{\partial w_{ji}(n)} = \frac{\partial \xi(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (4.12)$$

Diferenciando-se ambos os lados da equação (4.12) em relação a $e_j(n)$, teremos a equação (4.13)

$$\frac{\partial \xi(n)}{\partial e_j(n)} = \partial e_j(n) \quad (4.13)$$

Diferenciando ambos os lados da equação (4.7) em relação a $y_j(n)$, obtém-se a equação abaixo (4.14)

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (4.14)$$

Em seguida diferenciando-se a equação (4.11) em relação a $v_j(n)$, obtém-se a equação (4.15) onde $\varphi'(\cdot)$ representa a diferenciação da função de ativação $\varphi(\cdot)$ em relação a $v_j(n)$.

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad (4.15)$$

Finalizando, diferenciando-se a equação (4.10) em relação a $w_{jk}(n)$ teremos a equação:

$$\frac{\partial v_j(n)}{\partial w_{jk}(n)} = y_k(n) \quad (4.16)$$

Aplicando (4.13) a (4.16) na equação (4.12) teremos :

$$\frac{\partial \xi(n)}{\partial w_{jk}(n)} = -e_j(n) \varphi'_j(v_j(n)) \quad (4.17)$$

Assim, a correção $\Delta w_{jk}(n)$ aplicada ao peso simpático $w_{jk}(n)$ é definida pela equação (4.18), onde η é dado como parâmetro da taxa de aprendizagem do algoritmo de retropropagação. O sinal negativo representa a descida do gradiente do espaço dos pesos com o objetivo de reduzir o valor de $\xi(n)$.

$$\Delta w_{jk}(n) = -\eta \frac{\partial \xi(n)}{\partial w_{jk}(n)} \quad (4.18)$$

Conforme as equações (4.17) e (4.18), pode-se observar que o principal fator para o ajuste de pesos $\Delta w_{jk}(n)$ é o sinal erro $e_j(n)$ da saída da rede. Para um neurônio de saída j , cada nó é alimentado com uma resposta particular desejada, o que faz com que o cálculo do sinal de erro seja direto. No caso do neurônio j ser oculto o cálculo do erro se torna mais complexo já que este neurônio compartilha a responsabilidade pelo erro da saída da rede.

Em uma implementação prática são definidos dois conjuntos no universo de dados, sendo um para treinamento e outro para a validação do treinamento. Ao aplicar o algoritmo de retropropagação de erro monitora-se a evolução do treinamento em função da evolução do erro quadrático total, paralelamente para o conjunto de treinamento e validação. Esse processo evita casos de especialização da rede, quando esta apresenta valores baixo para o conjunto de treinamento e alto para o conjunto de validação o que implica em uma pobre generalização.

5 ANÁLISE DO PROCESSO DE CLASSIFICAÇÃO DOS SINAIS PULMONARES

5.1 Metodologia aplicada para classificação dos sinais pulmonares

Nesta etapa deste trabalho é apresentada a metodologia proposta para a classificação e análise dos diferentes sons pulmonares, relacionados a sibilo e crepitação. Esta metodologia é composta das seguintes etapas:

- Processamento dos sinais;
- Extração das características dos sinais utilizando a transformada de *wavelet*;
- Classificação dos diferentes sons através de redes neurais artificiais (RNA).

O diagrama de classificação proposto é mostrado na figura 54. Esta metodologia de classificação, além de fazer a separação dos sinais utilizando a ferramenta *wavelet*, produz compactação de dados o que minimiza o custo computacional gasto para a realização da classificação.

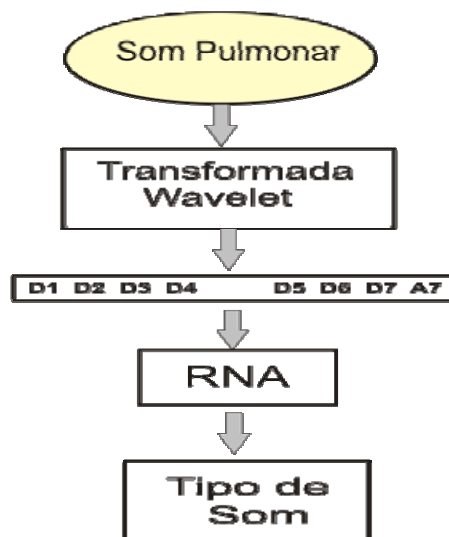


Figura 54 – Diagrama de classificação de sons pulmonares
Fonte: Autor, 2010

5.1.1 Processamento dos sinais

A metodologia desenvolvida para a caracterização e reconhecimento de sons pulmonares utilizou várias ferramentas de *software* e bibliotecas de manipulação que serviram de base para implementação e validação da proposta metodológica. Os arquivos de áudio contendo os sons pulmonares, imprescindíveis para a avaliação dos métodos, foram obtidos a partir de diferentes repositórios disponíveis na Internet.

Considerando que o objetivo deste trabalho consiste em propor técnicas de análise e reconhecimento dos sons adventícios pulmonares, investigando a sua eficácia e limitações, os requisitos de tamanho e compactação dos arquivos de áudio utilizados não foram considerados, optando-se por utilizar o formato de arquivo de áudio padrão *wave*, já que este utiliza uma técnica mais simples para executar esta tarefa.

Os arquivos de áudio utilizados como base deste trabalho foram adquiridos das seguintes fontes: *site* da internet mantido por Dave Fraser, da escola de medicina da *University of California*, os sons gravados pela empresa *PixSoft*, disponíveis em seu software *R.A.L.E. Lung sounds*, versão estudantil, arquivo disponibilizado pelo pesquisador R. J. Riella, além dos arquivos disponibilizados pela Faculdade de Ciências Biológicas e da Saúde pertencente ao Centro Universitário Cesmac, os quais foram utilizados como estudo de caso.

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 11025 Hz, até 44 kHz, para qualidade de sinal equivalente aos CDs de áudio. (RIELLA, 2008).

Para se obter uma uniformização das características dos arquivos de áudio, foi necessária uma normalização da frequência de amostragem e da amplitude do sinal. Para a normalização da frequência de amostragem, foi utilizado um algoritmo de sub-amostragem o qual normalizou a frequência para 12.800Hz. Outro parâmetro necessário para a adequação do sinal foi a eliminação da componente contínua ou nível DC presente em cada sinal. A remoção deste componente eliminou ruídos que dificultariam a classificação.

5.1.2 Extração das características dos sinais utilizando a transformada *wavelet*

Nesta etapa deste trabalho foi utilizada a análise multiresolução (AMR) descrita no capítulo 4 desta dissertação, ou decomposição *wavelet* dos ciclos respiratórios, observando os seus sinais de detalhe e aproximação de cada nível de decomposição. Este procedimento teve o objetivo de encontrar características dos sinais que possibilitem a classificação destes quanto ao tipo de anomalia respiratória. Os sinais foram decompostos em sete níveis e a *wavelet* mãe selecionada para a análise dos sinais foi a “db8” da família *Daubechies*, por possuir suporte compacto além de apresentar melhor resultados em reconhecimento de sons adventícios (KANDASWAMY, 2004), além de que não existem 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%, (RIELLA, 2008).

A decomposição dos sinais pulmonares pela análise em multiresolução (AMR) possibilita a separação em detalhes dos conteúdos originais em diferentes bandas de frequência. Desta forma, é possível determinar através dos coeficientes quais tipos de fenômeno estão sendo caracterizados. Através da AMR, os sinais são decompostos e representados pelos coeficientes de aproximação e detalhe. Considerando um sinal $s(n)$ em tempo discreto, este é representado no nível 1 por $a_1(n)$ e $d_1(n)$, obtidos pela equações 6.1 e 6.2, as quais representam os coeficientes de aproximação e de detalhes do sinal original $s(n)$, respectivamente

$$a_1(n) = \sum_k h(k - 2n)s(k) \quad (6.1)$$

$$d_1(n) = \sum_k g(k - 2n)s(k) \quad (6.2)$$

Os parâmetros $h(n)$ e $g(n)$ representam os coeficientes dos filtros (FIR – *finite impulse response*) passa-baixa e passa-alta respectivamente.

As características de cada coeficiente utilizadas para representar a distribuição do sinal no espaço tempo frequência foram:

- Média dos valores absolutos dos coeficientes em cada sub banda;
- Desvio padrão dos coeficientes em cada sub banda;

- Energia dos coeficientes em cada sub banda;
- Razão entre as médias dos valores absolutos de cada sub banda adjacente.

5.1.3 Classificação dos diferentes sons através de redes neurais artificiais

A capacidade de aprender com exemplos aliado ao alto grau de regularidade e paralelismo torna as RNAs uma excelente ferramenta em tarefas de classificação. As RNAs são amplamente usadas no campo de modelagem em biomedicina, análise de dados e classificação de diagnóstico (LISBOA, 2002).

A técnica de multiresolução, possibilita a geração de um conjunto de dados compacto sobre os coeficientes dos sinais pulmonares que servem como fonte de informação para um sistema de reconhecimento de padrões tais como redes neurais artificiais.

O objetivo da aplicação de uma rede neural artificial é o fornecimento de um parâmetro quantitativo para a avaliação da energia dos coeficientes relevantes computados pela decomposição *wavelet*, além da verificação da rede neural como método de classificação de padrões.

A rede neural implementada para a classificação da metodologia proposta foi a MLP, treinada com o algoritmo de retropropagação de erro *backpropagation resilient*. Esta escolha foi feita devido ao fato deste tipo de rede neural ter apresentado resultados satisfatórios na técnica desenvolvida para classificação de sons pulmonares (KANDASWAMY, 2004). Para cada tipo de som pulmonar uma classe correspondente é associada, sendo estas em número de três que são: crepitação, normal e sibilo. Com o objetivo de se obter um treinamento eficiente, os vetores de entrada correspondentes às características dos coeficientes foram normalizados em um intervalo de [0, 1.0].

$$y = \begin{cases} [0.9 \ 0.1 \ 0.1] & \text{classe dos sons de crepto} \\ [0.1 \ 0.9 \ 0.1] & \text{classe dos sons normais} \\ [0.1 \ 0.1 \ 0.9] & \text{classe dos sons de sibilo} \end{cases}$$

Os vetores de saída modificam os vetores de entrada x_k , $k = 1, 2, \dots, K$, onde K é o número de sinais pulmonares. Após o processo de codificação o conjunto de dados é dividido em dois subconjuntos que são o grupo de treinamento D_{train} e o grupo de teste D_{test} , onde:

$$D_{\text{train}} = \{x_k, y_k / k = 1, 2, \dots, K_{\text{train}}\} \text{ é usado para o treinamento da rede}$$

$$D_{\text{test}} = \{x_k, y_k / k = 1, 2, \dots, K_{\text{test}}\} \text{ é usado para validar a classificação}$$

Para a proposta deste trabalho foram utilizados um total de 165 sinais pulmonares, sendo 55 crepitação, 55 normais e 55 sibilo. Durante o treinamento da rede foram utilizados 30 sinais de cada classe, totalizando 90 sinais para o conjunto de treinamento. Para a validação 10 sinais de cada classe e para teste 15 sinais. Dentre estes sinais, encontram-se 45 sinais para estudo de caso disponibilizado pela Faculdade de Ciências Biológicas e da Saúde do Centro Universitário CESMAC. A rede neural foi configurada com 89 neurônios na camada intermediária. Considerando que para cada sinal foram extraídos coeficientes de 5 níveis (d3, d4, d5, d6 e d7) e que para cada nível de decomposição foram analisadas 4 características conforme abordado anteriormente, teremos então um vetor com 19 características para cada sinal e como estes deverão ser classificados em três classes distintas, temos inicialmente uma rede 19-89-3.

A representação gráfica da rede é mostrada na figura 55 abaixo




Figura 55 – Diagrama da rede neural MLP implementada com 19 entradas, 89 neurônios e 3 saídas.

Fonte: MATLAB®, 2007

A composição do vetor que alimenta a entrada da rede neural é formada por 19 variáveis que representa as informações dos diversos níveis dos coeficientes de aproximação selecionadas com seus respectivos valores características conforme comentado anteriormente. A figura 56 representa o diagrama deste vetor com as características de cada nível.

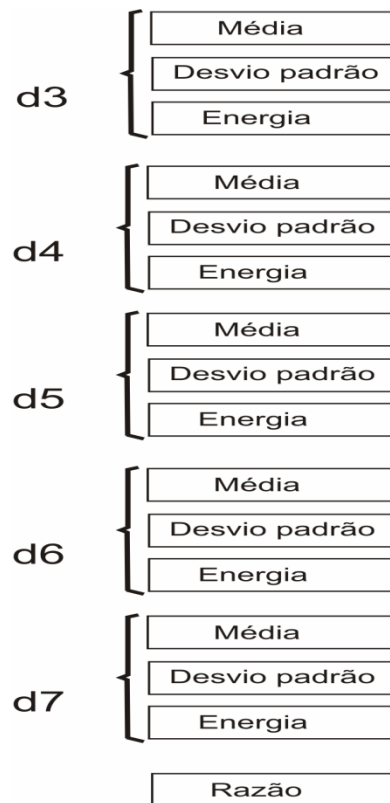


Figura 56 – Representação dos vetores de entrada da RNA.
Fonte: Autor, 2010

Computados os dados estatísticos descritos para cada nível de decomposição considerado (d3-d7) dos sinais analisados $S_n, n = 1, 2, \dots, N$, um conjunto de vetores $X_n, n = 1, 2, \dots, N$, formado pela representação estatística de cada nível da decomposição e relação entre variáveis de níveis adjacentes foi construído para apresentação à rede com a respectiva saída Y_n , correspondendo a categoria de X_n . Um conjunto de pares $P1 = \{X_n, Y_n | n = 1, 2, \dots, Nt\}$, para treinamento e um conjunto $Ps = \{X_n | n = 1, 2, \dots, Ns\}$ para teste, foram construídos.

Com as variáveis consideradas para classificação, 19 para cada vetor representando as características dos sinais e 90 sinais para treinamento (30 para cada categoria – crepito, normal e sibilo), 90 pares X_n, Y_n , têm-se: $P1 = \{X_n, Y_n | n = 1, 2, \dots, 90\}$ e para teste da

rede 45 sinais (15 de cada categoria): $P_s = \{X_n | n = 1, 2, \dots, 45\}$. Outros 30 sinais foram usados para validação da rede.

5.2 Resultado e discussão

5.2.1 Análise dos dados

Após o processamento do sinal e sua conversão para o domínio da frequência verificou-se a frequência de pico de cada amostra. Na tabela 4 são apresentados os resultados para os pacientes com crepitação.

Tabela 4 – Picos de frequências em pacientes com crepitação

Amostra	Frequência de maior amplitude (Hz)
1	161
2	95
3	133
4	170
5	131
6	136
7	196
8	187
9	323
10	147
11	164
12	175
13	310
14	168
15	96

Fonte: Autor, 2010

Analisando os resultados contidos na tabela 4 observa-se que para os pacientes com crepitação as frequências ficaram em um intervalo entre 95 e 323 Hz, com média de 173 Hz e desvio padrão 65,3 Hz. Considerando que essa amostra é uma amostra aleatória simples e que foi extraída de uma população normalmente distribuída, foi determinado um intervalo de confiança para estimar a média populacional. Como σ (desvio padrão populacional) é desconhecido adota-se a distribuição t de Student, dada por:

$$t = \frac{\bar{x} - \mu}{\frac{s}{\sqrt{n}}} \quad (6.3)$$

A distribuição t de *Student* é usada para achar valores críticos denotados por $t_{\alpha/2}$. Estes valores dependem do número de graus de liberdade (gl) e do nível de confiança. O número de graus de liberdade é o tamanho da amostra menos 1, ou seja, $gl = n - 1$.

Assim, para estimar a média das freqüências máximas para a população de pacientes com crepitação, usam-se os dados da tabela 5.1. Considerando $n = 15$ e um nível de confiança de 95%, pode-se calcular a margem de erro do intervalo (E).

$$E = t_{\alpha/2} \cdot \frac{s}{\sqrt{n}} \quad (6.4)$$

$$E = 2,145 \cdot \frac{65,3}{\sqrt{15}}$$

$$E = 36$$

Calculada a margem de erro, tem-se o intervalo de confiança.

$$\bar{x} - E < \mu < \bar{x} + E$$

$$137 < \mu < 209$$

Baseado neste resultado, observa-se uma confiança de 95% de que a média populacional dos picos de freqüência dos pacientes com crepitação esteja entre 137 e 209 Hz.

De maneira análoga podemos analisar os picos de freqüência correspondentes aos pacientes com sibilo. Tais dados estão contidos na tabela 5.

Tabela 5 - Pico de frequência em pacientes com sibilo

Amostra	Frequência de maior amplitude (Hz)
1	321
2	209
3	177
4	252
5	312
6	317
7	275
8	280
9	233
10	226
11	248
12	257
13	232
14	208
15	300

Fonte: Autor, 2010

Os dados da tabela 5 mostram que para os pacientes sibilante os picos de frequência ficaram em um intervalo entre 177 e 321 Hz, com média de 256 Hz e desvio padrão 43,7 Hz. Considerando que essa amostra é uma amostra aleatória simples e que foi extraída de uma população normalmente distribuída, foi determinado um intervalo de confiança para estimar a média populacional. Adota-se a distribuição t de Student.

Considerando $n = 15$ e um nível de confiança de 95%, pode-se calcular a margem de erro do intervalo (E).

$$E = t_{\alpha/2} \cdot \frac{s}{\sqrt{n}} \quad (6.4)$$

$$E = 2,145 \cdot \frac{43,7}{\sqrt{15}}$$

$$E = 24$$

Calculada a margem de erro, tem-se o intervalo de confiança.

$$\bar{x} - E < \mu < \bar{x} + E$$

$$232 < \mu < 280$$

Baseado neste resultado, pode-se dizer que existe 95% de confiança que a média populacional dos picos de frequência dos pacientes sibilante esteja entre 232 e 280 Hz.

A distribuição t de Student foi utilizada para fazer uma estimativa sobre a média dos picos de frequência das populações com crepitação e sibilos. O resultado dessa estimativa

mostrou que essa média populacional está contida em certo intervalo para cada uma das populações.

Propõe-se a aplicação de um teste para verificar se a média populacional para cada tipo de sinal (crepitação e sibilo) é maior que a mediana correspondente. Nesse teste será usada a distribuição t de Student, com um nível de significância de 0,05. A análise será feita utilizando os dados das tabelas 5.1 e 5.2.

Considerando os dados da tabela 5.1, ou seja, os picos de frequência dos pacientes com crepitação, têm-se os seguintes parâmetros:

- Média amostral: $\bar{x} = 173$
- Mediana: $\tilde{x} = 164$
- Desvio padrão amostral: $s = 65,3$
- Tamanho da amostra: $n = 15$

O teste consiste em verificar se a média populacional dos picos de frequência dos pacientes com crepitação é maior que a mediana. Assim, o teste se baseia nas seguintes hipóteses:

$H_0: \mu = 164$ (a média populacional é igual a mediana)

$H_1: \mu > 164$ (a média populacional é maior que a mediana)

Aplicando a distribuição t de Student, tem-se:

$$t = \frac{\bar{x} - \mu}{\frac{s}{\sqrt{n}}} = \frac{173 - 164}{\frac{65,3}{\sqrt{15}}} = 0,5338$$

Para o nível de significância desejado, $\alpha = 0,05$, e $gl = n - 1 = 14$, o valor crítico é $t_{\alpha/2} = 1,761$ (TRIOLA, 2008). Como a estatística de teste ($t = 0,5338$) não está na região crítica, como mostra a figura 5.4, deixa-se de rejeitar a hipótese nula. Assim, com base nos dados amostrais disponíveis, não há evidência suficiente para afirmar que a média populacional dos picos de frequência de pacientes com crepitação é maior que 164.




Figura 57 – Teste de hipótese para pacientes com crepitação.

Fonte: Autor, 2010

Analogamente, pode-se aplicar o teste para os dados da tabela 5.2, picos de frequência de pacientes sibilante. Neste caso, os parâmetros são:

- Média amostral: $\bar{x} = 256$
- Mediana: $\tilde{x} = 252$
- Desvio padrão amostral: $s = 43,7$
- Tamanho da amostra: $n = 15$

Como o objetivo do teste é o mesmo que no aplicado para os pacientes com crepitação, as hipóteses a serem testadas são:

$H_0: \mu = 252$ (a média populacional é igual a mediana)

$H_1: \mu > 252$ (a média populacional é maior que a mediana)

Aplicando a distribuição t de Student, tem-se:

$$t = \frac{\bar{x} - \mu}{\frac{s}{\sqrt{n}}} = \frac{256 - 252}{\frac{43,7}{\sqrt{15}}} = 0,3545$$

Para o nível de significância desejado, $\alpha = 0,05$, e $gl = n - 1 = 14$, o valor crítico é $t_{\alpha/2} = 1,761$ (TRIOLA, 2008). Como a estatística de teste ($t = 0,3545$) não está na região crítica, como mostra a figura 58, deixa-se de rejeitar a hipótese nula. Assim, com base nos dados amostrais disponíveis, não temos evidência suficiente para afirmar que a média populacional dos picos de frequência de pacientes sibilante é maior que 252.




Figura 58 – Teste de hipótese para pacientes com sibilos.
Fonte: Autor, 2010

5.2.2 Decomposição e extração das características do sinal

Para a proposta deste trabalho, a decomposição ocorre até o 7º nível de detalhamento, onde se obtém os coeficientes mais significativos de detalhes 5º e 6º nível (d_5 , d_6). Já os coeficientes d_1 , d_2 , e a_7 apresentam níveis de energia mínimos, o que implica em uma distribuição dos sons pulmonares predominantemente na faixa de 100 a 400 Hz.

Para esta aplicação a taxa de amostragem dos sinais é de 12.800Hz, portanto a máxima frequência do sinal de entrada conforme Nyquist é de 6400 Hz. A tabela 6 representa a relação entre o nível de decomposição e as respectivas bandas de frequência.

Tabela 6- Relação entre os coeficientes e a faixa de frequência

Nível dos coeficientes	Faixa de Frequência (Hz)
d1	3.200 – 6.400
d2	1.600 - 3.200
d3	800 - 1.600
d4	400 - 800
d5	200 - 400
d6	100 - 200
d7	50 - 100
a7	0 - 50

Fonte: Autor, 2010

Considerando que as informações mais relevantes foram encontradas nos níveis de decomposição do detalhamento d5 e d6 e com o intuito de otimizar a performance computacional deste trabalho, reduzindo o número de vetores sem comprometer a qualidade dos resultados, arbitrou-se em considerar como elemento significativo para a análise dos sinais pulmonares, os níveis d4, d5, d6 e d7, o que corresponde a faixa de 50 a 800 Hz, descartando-se os coeficientes correspondentes às demais bandas de decomposição, reduzindo-se assim, o número de vetores que representam o sinal.

Os coeficientes obtidos através da utilização da TW e AMR apresentam variações para cada nível. Assim, é necessário quantificar estas variações contidas em cada nível de resolução. A figura 59 representa a decomposição por AMR de uma amostra de um sinal que contém anomalia de sibilo. Nesta figura nota-se claramente que a densidade dos coeficientes de detalhamento d5 apresenta uma maior concentração de energia temporal do sinal original *s*. Conforme a decomposição mostrada, este nível corresponde à faixa de frequência de 200 a 400 Hz. Este comportamento é compatível com as características espectrais do sinal sibilante que se encontram majoritariamente acima de 200 Hz.




Figura 59 - Sinais resultantes da decomposição *wavelet* de um ciclo respiratório sibilante.
 Fonte: Autor, 2010

A figura 60 representa a decomposição de um sinal pulmonar contendo crepitação em que fica evidente a maior concentração de energia temporal no sexto nível (d_6) de decomposição da AMR, compatível com as frequências fundamentais de patologias relacionadas a crepitação as quais estão na maioria localizadas na faixa de 100 a 200Hz.




Figura 60- Sinais resultantes da decomposição *wavelet* de um ciclo respiratório contendo crepitação.
 Fonte: Autor, 2010

Outra forma de se verificar as características do sinal analisado é através da decomposição da árvore dos coeficientes conforme figura 61 onde é possível observar as componentes de energia em cada nível. A figura 61 representa a decomposição de um sinal pulmonar com característica sibilante, o qual está compatível com a faixa de frequência do quinto nível de decomposição de detalhamento, correspondente a banda acima de 200 Hz.




Figura 61 - Representação da árvore de decomposição de um sinal sibilante.
Fonte: Autor, 2010

A figura 62 representa a decomposição em árvore de um sinal com crepitação, onde o coeficiente de maior energia encontra-se no 6º nível (d6) de detalhamento da decomposição que corresponde a faixa de frequência abaixo de 200 Hz.




Figura 62 - Representação da árvore de decomposição de um sinal crepitante.
Fonte: Autor, 2010

A figura 63 representa a média de distribuição de energia por nível para cada tipo de sinal. Este gráfico foi obtido com a análise de todos os 165 sinais utilizados nesta metodologia e pode-se observar a predominância do sibilo na faixa de 200 a 400 Hz (nível 5) e crepitação na faixa de 100 a 200 Hz (nível 6).




Figura 63 - Representação da distribuição de energia: (a) crepitação e (b) sibilo
Fonte: Autor, 2010

5.2.3 Classificação dos sinais via Rede Neural

A análise quantitativa dos resultados dos níveis mais significativo através da decomposição *wavelet* e AMR juntamente com a classificação via rede neural artificial, apresenta resultados significativamente sólidos para justificar a utilização desta técnica como uma ferramenta auxiliar de classificação para sons pulmonares. Isto se deve aos índices de acerto obtido de 93% para os sinais analisados com a *wavelet* db8, rede neural MLP e o algoritmo *backpropagation resiliente*.

Conforme subitem 5.1.3 a saída da rede neural esta configurada de acordo com a tabela 7.

Tabela 7 - Configuração de saída da rede neural

Crepitação	Normal	Sibilo
1	0	0
0	1	0
0	0	1

Fonte: Autor, 2010

Os resultados da classificação para os 45 sinais analisados são mostrados nas tabelas seguinte (8, 9 e 10) onde o percentual de acerto foi calculado considerando o conjunto total de sinais para cada categoria.

Tabela 8 - Resultado da classificação dos sinais com crepitação (C)

C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15
1	1	1	1	0,02	1	1	1	1	1	1	1	1	1	1
0	0	0	0	0,64	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Fonte: Autor, 2010

Tabela 9 - Resultado da classificação dos sinais normais (N)

N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12	N13	N14	N15
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Fonte: Autor, 2010

Tabela 10 - Resultado da classificação dos sinais sibilante (S)

S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	1	0	0	0	0	1	0	0
0,95	1	1	1	1	1	1	0	1	0,94	1	1	0	1	1

Fonte: Autor, 2010

A tabela 11 representa o resultado de desempenho da rede neural com quatro configurações de número de neurônios da camada oculta, onde se verificou que com a redução de até 19 neurônios o índice de acerto apresenta pouca variação.

Tabela 11 – Desempenho das redes consideradas.

RNA	Nº de passagens	% Treinamento	% Teste
19-89-3	14	100	94,6
19-28-3	47	100	93,7
19-19-3	107	100	93,7
19-15-3	135	100	71,3

Fonte: Autor, 2010

Desta forma, a classificação de sons pulmonares por decomposição DWT, e utilização de variáveis estatísticas dos coeficientes como caracterização do sinal, demonstrou ser um simples e eficiente método com reduzido volume de dados para reconhecimento por RNA. A RNA 19-19-3 apresentou desempenho satisfatório em acertos e reduzido número de neurônios. As implementações foram realizadas utilizando a ferramenta computacional

MATLAB®. As representações para as características dos sinais utilizadas aqui gerou um vetor de representação de sons pulmonares com reduzida quantidades de dados com sem perda de informação. Não foi considerado o desempenho de outros conjuntos de dados representativos do sinal, outras configurações podem ser testadas e seu desempenho avaliado.

6 CONCLUSÕES

A meta deste trabalho foi o desenvolvimento de um método computacional para ajudar no melhor entendimento das características dos diferentes sons respiratórios, analisando os sinais normais e os patológicos que apresentam sibilo e crepito. A ausculta de sons pulmonares através do estetoscópio é uma prática médica relevante, entretanto devido à limitação de resposta em determinadas bandas de frequência somadas às limitações auditivas do ouvido humano não é possível identificar e registrar todas as informações. Sistemas capazes de digitalizar e armazenar sons proporcionam a troca de informações entre especialistas podendo ainda auxiliar o monitoramento e diagnósticos em pacientes com doenças respiratórias em uma ampla faixa de frequência. Desta forma pode-se reduzir a dependência da subjetividade e acuidade auditiva do especialista.

A realização deste trabalho possibilitou a obtenção de resultados relativos à análise de sons pulmonares patológicos, utilizando como base as características espectrais no domínio tempo frequência. Esta análise teve como objetivo a identificação e classificação de sons com características de crepito e sibilo, os quais estão relacionados com patologias pulmonares.

Para o desenvolvimento deste trabalho, foi proposta e avaliada uma metodologia a qual cumpre o objetivo de classificar os sinais pulmonares em; normal, crepitante e sibilante. A técnica utilizada para a identificação e classificação destes sons foi baseada na transformada *wavelet* discreta como técnica de processamento, e como classificador utilizou-se a rede neural MLP. Esta metodologia apresentou índices de acerto comparáveis aos melhores índices disponibilizados na literatura que tem propostas semelhantes. Este trabalho mostrou-se eficaz para toda gama de ciclos respiratórios testados no estudo de caso dos sinais disponibilizados pela Faculdade de Ciências Biológicas e da Saúde.

6.1 Contribuições

Resumidamente, as principais contribuições deste estudo são:

- Revisão das principais técnicas com possíveis aplicações em análise de sons pulmonares;

- Apresentação das limitações das ferramentas para identificação de sinais pulmonares; adotando-se técnica complementar em análise espectral no domínio da frequência como critério de uma nova abordagem de identificação de sinais;
- Proposição de um novo modelo de investigação de sinais pulmonares em ambiente Matlab com resultados promissores no auxílio de diagnóstico em patologias pulmonares.

6.2 Extensões

Uma perspectiva futura para a análise computadorizada de som pulmonar pode ser adquirida por considerar o seu potencial para essas aplicações tais como o mapeamento acústico da superfície da parede torácica capaz de verificar a ventilação regional e obstrução do fluxo de ar dentro dos pulmões. Esta perspectiva é de particular importância no tratamento de crianças e na avaliação da função pulmonar de pacientes em ambientes de cuidados críticos.

Monitoramento remoto e supervisão de sinais biomédicos de paciente em casa ou no trabalho é uma atividade em expansão no campo da medicina, proporcionando consideráveis benefícios econômicos e sociais. A aquisição de dados referente a sinais respiratórios tem muitos usos possíveis através da Internet, via telefonia fixo ou móvel com custo de transmissão relativamente viável. O uso mais extensivo de monitoração de sons respiratórios, especialmente em paciente crítico tornar-se mais provável com um maior entendimento das informações dentro desses sons.

Outro potencial promissor desta área é a utilização de dados de sons pulmonares na educação de estudantes de medicina e na área de saúde em geral, proporcionando o desenvolvimento de aprendizagem com alta qualidade com ambientes de apoio, no qual os alunos terão disponibilidade de instalações multi-mídia para aprender e demonstrar os princípios da ausculta respiratória. Comparado com o estetoscópio acústico onipresente, um computador como sistema de aquisição de som oferece resultados quantitativos em forma gráfica, a longo prazo, via armazenamento, comunicações instantâneas e muitas outras vantagens. Esta análise é ideal para o acompanhamento a longo prazo de doentes, quer no

hospital ou na comunidade, e deve também ser de grande valor em países menos desenvolvidos e comunidades remotas.

6.3 Comentários finais

A prática clínica aponta como prioritárias as técnicas de diagnóstico e tratamento não invasivas, devido a sua simplicidade e o menor risco de exposição do paciente.

Desta forma, a metodologia propostas foi desenvolvida com a intenção de criar não somente técnicas de reconhecimento automático de sons adventícios pulmonares, bem como o desenvolvimento de algoritmos eficazes que possam auxiliar os profissionais de saúde em diagnóstico de doenças pulmonares, além de gerar dados que estes possam facilitar a conclusão dos resultados. Conclui-se que a técnica proposta é robusta e confiável o suficiente para ser utilizada como auxílio na detecção dos sons adventícios nos sons pulmonares.

REFERÊNCIAS

- ARAÚJO G. J. M., **Transformada Wavelet aplicada à detecção de vazamentos em oleodutos**. Trabalho de Conclusão de Curso apresentado ao Programa de Graduação em Engenharia de Computação da Universidade Federal do Rio Grande do Norte. 2009.
- Avaliação da função respiratória; **fisiopatologia das doenças respiratórias**. Disponível em: <http://www.uff.br/fisio6/PDF/sistema_respiratorio/avaliacao_doencas.pdf>. Acesso : 15 abr 2010
- BAUGHMAN R. P., LOUDON R. G. - **Quantization of wheezing in acute asthma**. Chest Journal American College of Chest Physicians. ISSN:0012-3692. 1984.
- BIANCHINI, A. R. **Arquitetura de Redes Neurais para o Reconhecimento Facial Baseado no Neocognitron**. Dissertação - Universidade Federal de São Carlos – 2001.
- CHURCHILAND, P. S., SEJNOWSKI T. J., **The Computational Brain**, Cambridge, Ma MIT Press, 1992.
- DALMAY F, ANTONINI M.T., **Acoustic properties of normal chest**. Eur Respir J. SERIES 'CHEST PHYSICAL EXAMINATION'-1995;8:1761-9.
- DELMONT F. O., **Utilização da transformada wavelet para caracterização de distúrbios na qualidade de energia elétrica**. São Carlos, 2003. 103p. Dissertação (Mestrado em Engenharia Elétrica). Escola de Engenharia de São Carlos, USP.
- DAUBECHIES, I. **Ten lectures on wavelets**. Philadelphia, SIAM, 1992. (CBMS-NSF Regional.
- Doenças Respiratórias crônica no Brasil**. 33º Congresso Brasileiro de Pediatria. Outubro 2006.”. Disponível em : www.sppt.org.br/wp/?p=291/ Acesso em: 04/2010
- FORGACS P. **Crackles and wheezes**. Lancet 1967; 2:203-5.
- GINA A. A. **software Toolkit for acoustic Respiratory Analysis**. Massachusetts Institute technology. 2004
- GABOR D. ‘**Theory of communication**’, Journal of the Institute of Electrical Engineers . 1946.
- GRAPS, A. **An Introduction to Wavelets**, IEEE Computational Science and Engineering. 1995. vol 2, no 2. Pages: 50-61.
- GOSWAMI J.C., CHAN A.K. **Fundamentals of Wavelets: Theory, Algorithms, and Applications**. 1999
- HAYKING S. **Neural Networks: a comprehensive foundation**. New York, 2nd edition, Bookman, 2004.

HAYKING S. **Neural Network and Learning Machine**. New York, 3rd edition Prentice Hall; 2008

KANITPANYACHAROEN, W., PREMRUDEEPREECHACHARN, S. **Power Quality problem Classification Using Wavelet Transform and Artificial Neural Networks**. IEEE PES Power Systems Conference and Exposition, vol 13, p.1946-1501, 2004.

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

LISBOA P.J.G., **A review of evidence of health benet from artificial neural networks in medical intervention**, Neural Networks 15 (1) (2002) 11–39.

LISBOA P.J.G., **Artificial Neural Networks in Biomedicine**. Springer, London, 282pp, 2000

LINHARES, S.; GEWANDSZNAJDER, F. **Biologia Hoje**. Ed.Ática, 1997.

LEHRER, S. **Ausculata pulmonar: entendendo os sons pulmonares**.- São Paulo. Editora Roca. 2004 .

MAJUMDER A.K.. **Computer Analysis of Frequency Spectrum of the**

Phonopulmogram. Proc Annu Symp Comput Appl Med Care. 1980 November 5; 1: 266–271.

Manual Merck Saúde para a Família - Capítulo 37 Distúrbios dos Pulmões e das vias Aéreas. Disponível em:
http://mmspf.msdonline.com.br/pacientes/manual_merck/secao_03/cap_021.html

MARCIA A. **Doenças Pulmonar obstrutivas crônicas é a quinta doença que mais mata no Brasil**. Globo online. 2007. Disponível em :
<http://oglobo.globo.com/vivermelhor/mat/2007/08/22/297375407.asp>

MAZIC I., S.S. MAGJIAVERIC, R.R. **Analysis of Respiratory Sounds in Asthmatic Infants**. Polytechnic of Dubrovnik, Dubrovnik, Croatia Faculty of Electrical Engineering and Computing, University of Zagreb, Zagreb, Croatia.

MENDEL, J.M., MCLAREN, R., W. **Adaptative Learning and Pattern Recognition Systems; Theory and Applications**, vol.66, New York, Academic Press, 1970.

MORETINN P. A. **Ondas e Ondaletas: da análise de Fourier a à analise de Ondaletas**. São Paulo: EdUSP, 1999.

MURPHY R. L. **Auscultation of the lung: past lessons, future possibilities**. Pulmonary Service, Lemuel Shlattuck and Faulkner Hospitals, Boston, Massachusetts, USA. Thorax, 1981, 36, 99-107

National Vital Statistic Report, Deaths, Percents of Total Dead Rates, and Death No.11, October 2001.

NASCIMENTO J. C. L., YONEYAMA, T. **Inteligência Artificial em Controle e Automação**, 1ª Edição, São Paulo, 2004.

OLIVEIRA, H. M. **Wavelets Entrando na Onda**, Editora Manole. 2003.

PIRILLA P., SOVIJARVI A.R.A. ,**Crackles: recording, analysis and clinical significance**. Eur Respir J. 1995;8: 2139- 48.

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.

PONTE, D. F., Hizume D., MORAES R. **Sistema para captação de sons respiratórios**. In: 21º Congresso Brasileiro de Engenharia Biomédica. Florianópolis,2008. Artigo. Disponível em: < www.sbeb.org.br/cbeb2008/.../o_0946.pdf>. Acesso: 22 abr 2010.

PORTO C. C., **Semiologia médica. 5. Ed** – Rio de Janeiro:Guanabara. Koogan,2005

RABELLO, T. N. **Wavelets e Redes Neurais**. Anais da V Escola de Redes Neurais. IV CBRN, São José dos Campos, julho de 1999, pp. c001-c027.

RIELLA, R. J., **Proposta de Metodologia para Caracterização e Reconhecimento de Sibilos em Sons Pulmonares**, Tese de Doutorado (Curso de Pós-Graduação em

Engenharia Elétrica e Informática Industrial – CPGEI). Curitiba, CEFET-PR, 2008.

ROMAY M. G S., TERESA G. M.. **Hybrid Artificial Intelligent Systems**. 5th International Conference, HAIS 2010, San Sebastian, Spain, June 23-25, 2010. ISBN: 978-3-642-13768-6

RUMELHAART, D. E., CLELLAND, J. L.; **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**. 1986.

SANDBERG F.; **Time-Frequency Analysis of Atrial Fibrillation**. Thesis for degree of Licentiate in Engineering. Lund 2007.

STANLEY W. J., CLARICE A. F., **Anatomia e Fisiologia Humana**.

STEWART G.W. ;**Problems suggested by an uncertainty principle in acoustics**. *J Acoust Soc Am* 1931; 3: 325–329.

SILVA, C. Y. V. W. , **Extração de Características de Imagens Médicas Utilizando wavelets para Mineração de Imagens e Auxílio ao Diagnóstico**. Dissertação - Universidade Federal de São Carlos. 2007.

TAFNER. A. M.; **Redes Neurais Artificiais: Aprendizado e Plasticidade**, Universidade Estadual de campinas Núcleo de Informática Biomédica, Campinas, 1998.

TAPLIDOU S. A , **Wheeze detection based on time-frequency analysis of breath Sounds.** Computers in Biology and Medicine 37 (2007) 1073 – 1083

TASWELL, C. MCGILL, K.C., **Algorithm 735: Wavelet Transform Algorithms for Finite-Duration Discrete-Time Signals,** Transactions on Mathematical Software,

TRIOLA, M. F. **Introdução à Estatística,** 10 ed., Rio de Janeiro: LTC, 2008. Vol. 20, No. 3, pp. 398 – 412, 1994.

VETTERLI, M.; HERLEY, C. **Wavelet and Filter Banks: Theory and Design.** IEEE Transactions on Signal Processing, New York, v. 40, n. 9, p. 2007-2232, September 1992.


VICTOR A. McKUSICK, OLIVER N. **Spectral Phonocardiograph studies in congenital disease.** Department of Medicine, The Johns Hopkins University School of Medicine and The Johns Hopkins Hospital, Baltimore, Maryland, U.S.A.* British Heart Journal 1956 July; 18(3): 403–416.

WEISS E.B., CARLSON C.J., **Recording of breath sounds.** Am Rev Respir Dis 1972; 105:835-9.

WORLD HEALTH ORGANIZATION, “Data and statistics
“<http://www.who.int/research/en/>, Acesso em 06/2010.

APÊNDICES

APÊNDICE A – CURVA DE TREINAMENTO DA REDE NEURAL MLP



Fonte: Autor, 2010.

APÊNDICE B - ALGORITMO DE CLASSIFICAÇÃO DOS SINAIS DECOMPOSTOS POR WAVELET

```

% Le os sinais c01-c30 calcula a decomposição wavelet db8 nível 7, extrai
% as características estatísticas dos níveis d3 a d7 e monta o vetor cr_in_19x30
% para treinamento da RNA.
%
load c01.mat;load c02.mat;load c03.mat;load c04.mat;load c05.mat;load c06.mat;
load c07.mat;load c08.mat;load c09.mat;load c10.mat;load c11.mat;load c12.mat;
load c13.mat;load c14.mat;load c15.mat;load c16.mat;load c17.mat;load c18.mat;
load c19.mat;load c20.mat;load c21.mat;load c22.mat;load c23.mat;load c24.mat;
load c25.mat;load c26.mat;load c27.mat;load c28.mat;load c29.mat;load c30.mat;
C={c01 c02 c03 c04 c05 c06 c07 c08 c09 c10 c11 c12 c13 c14 c15 c16 c17 c18 c19 ...
  c20 c21 c22 c23 c24 c25 c26 c27 c28 c29 c30};
%%%%%%%%%%%%%% Extração das características Crepito
%%%%%%%%%%%%%%
    for n = 1:30
Tr{n} = wpdec(C {n},7,'db5','shannon');    %Decomposição Ci,db8,nível 7
cf03 = wpcoef(Tr{n},[3 1]);                %Dataset Detalhe 3 D3 (wavelet tree)
    s03 = std(cf03);                        % desvio Padrão D3
    mx03 = mean(abs(cf03));                 % Média Val Abs Coeficientes
    e03_ = sum((abs(cf03)).^2);            % Energia
    e03 = e03_/length(cf03);              % Potencia Média
    cf04 = wpcoef(Tr{n},[4 1]);            %Dataset Detalhe 3 D3 (wavelet tree)
    s04 = std(cf04);
    mx04 = mean(abs(cf04));
    e04_ = sum((abs(cf04)).^2);
    e04 = e04_/length(cf04);
    cf05 = wpcoef(Tr{n},[5 1]);            %Dataset Detalhe 4 D4 (wavelet tree)
    s05 = std(cf05);
    mx05 = mean(abs(cf05));
    e05_ = sum((abs(cf05)).^2);
    e05 = e05_/length(cf05);

    cf06 = wpcoef(Tr{n},[6 1]);            %Dataset Detalhe 5 D5 (wavelet tree)
    s06 = std(cf06);
    mx06 = mean(abs(cf06));
    e06_ = sum((abs(cf06)).^2);
    e06 = e06_/length(cf06);
    cf07 = wpcoef(Tr{n},[7 1]);            %Dataset Detalhe 6 D6 (wavelet tree)
    s07 = std(cf07);
    mx07 = mean(abs(cf07));
    e07_ = sum((abs(cf07)).^2);
    e07 = e07_/length(cf07);
                                %razao entre os niveis

    r3_4 = mx03/mx04;
    r4_5 = mx04/mx05;
    r5_6 = mx05/mx06;
    r6_7 = mx06/mx07;

```

%vetor com as características de Cr(i)

```
cr{n} = [s03 mx03 e03 r3_4 s04 mx04 e04 r4_5 s05 mx05 e05 r5_6 s06 mx06 e06 r6_7
s07 mx07 e07]';
```

% Média dos coeficientes de cada nível

```
imx03{n} = mx03;
imx04{n} = mx04;
imx05{n} = mx05;
imx06{n} = mx06;
imx07{n} = mx07;
end
```

%Vetor vcr_19x30 para treinamento da RNA

```
in_cr = [cr{1} cr{2} cr{3} cr{4} cr{5} cr{6} cr{7} cr{8} cr{9} cr{10} cr{11} cr{12}
cr{13} cr{14} cr{15} ...
cr{16} cr{17} cr{18} cr{19} cr{20} cr{21} cr{22} cr{23} cr{24} cr{25} cr{26}
cr{27} cr{28} cr{29} cr{30}];
```

```
%%%%%%%%%%%%%% Valores Máximos dos Níveis
%%%%%%%%%%%%%%
```

```
tmx03_ = [imx03{1} imx03{2} imx03{3} imx03{4} imx03{5} imx03{6} imx03{7}
imx03{8} imx03{9} imx03{10} ...
imx03{11} imx03{12} imx03{13} imx03{14} imx03{15} imx03{16} imx03{17}
imx03{18} imx03{19} ...
imx03{20} imx03{21} imx03{22} imx03{23} imx03{24} imx03{25} imx03{26}
imx03{27} imx03{28}
```

```
imx03{29} imx03{30}];
tmx04_ = [imx04{1} imx04{2} imx04{3} imx04{4} imx04{5} imx04{6} imx04{7}
imx04{8} imx04{9} imx04{10} ...
imx04{11} imx04{12} imx04{13} imx04{14} imx04{15} imx04{16} imx04{17}
imx04{18} imx04{19} ...
imx04{20} imx04{21} imx04{22} imx04{23} imx04{24} imx04{25} imx04{26}
imx04{27} imx04{28}
imx04{29} imx04{30}];
```

```
tmx05_ = [imx05{1} imx05{2} imx05{3} imx05{4} imx05{5} imx05{6} imx05{7}
imx05{8} imx05{9} imx05{10} ...
imx05{11} imx05{12} imx05{13} imx05{14} imx05{15} imx05{16} imx05{17}
imx05{18} imx05{19} ...
imx05{20} imx05{21} imx05{22} imx05{23} imx05{24} imx05{25} imx05{26}
imx05{27} imx05{28}
imx05{29} imx05{30}];
```

```
tmx06_ = [imx06{1} imx06{2} imx06{3} imx06{4} imx06{5} imx06{6} imx06{7}
imx06{8} imx06{9} imx06{10} ...
imx06{11} imx06{12} imx06{13} imx06{14} imx06{15} imx06{16} imx06{17}
imx06{18} imx06{19} ...
imx06{20} imx06{21} imx06{22} imx06{23} imx06{24} imx06{25} imx06{26}
imx06{27} imx06{28}
imx06{29} imx06{30}];
```

```
tmx07_ = [imx07{1} imx07{2} imx07{3} imx07{4} imx07{5} imx07{6} imx07{7}
imx07{8} imx07{9}
imx07{10} ... imx07{11} imx07{12} imx07{13} imx07{14} imx07{15} imx07{16}
imx07{17} imx07{18}
```



```

    imx07{19} ... imx07{20} imx07{21} imx07{22} imx07{23} imx07{24} imx07{25}
    imx07{26} imx07{27}
    imx07{28} imx07{29} imx07{30}];

    tmx03m = mean(tmx03_);tmx04m = mean(tmx04_);tmx05m = mean(tmx05_);tmx06m =
    mean(tmx06_);tmx07m = mean(tmx07_);
    %%%%%%%%%%%
    amx03_cr = [tmx03m tmx04m tmx05m tmx06m tmx07m]           %Média dos
    Coeficientes Por nível
    clear c* s* v* m* e* r* t* n;
    % Le os sinais nm01-nm30 calcula a decomposicao wavelet db8 nivel 7, extrai
    % as caracteristicas estatisticas dos níveis d3 a d7 e monta o vetor nm_in_19x30
    % para treinamento da RNA.
    load nm01.mat;load nm02.mat;load nm03.mat;load nm04.mat;load nm05.mat;load nm06.mat;
    load nm07.mat;load nm08.mat;load nm09.mat;load nm10.mat;load nm11.mat;load nm12.mat;
    load nm13.mat;load nm14.mat;load nm15.mat;load nm16.mat;load nm17.mat;load nm18.mat;
    load nm19.mat;load nm20.mat;load nm21.mat;load nm22.mat;load nm23.mat;load nm24.mat;
    load nm25.mat;load nm26.mat;load nm27.mat;load nm28.mat;load nm29.mat;load nm30.mat;
    C={nm01 nm02 nm03 nm04 nm05 nm06 nm07 nm08 nm09 nm10 nm11 nm12 nm13 nm14
    nm15 nm16 nm17 ...
    nm18 nm19 nm20 nm21 nm22 nm23 nm24 nm25 nm26 nm27 nm28 nm29 nm30};
    for n = 1:30
        Tr{n} = wpdec(C {n},7,'db8','shannon');           %Decomposição Ci,db8,nível 7
    end

    % Decomposição dos 30 sinais
    %%%%%%%%%%%
    %%%%%%%%%%% Extração das
    %%%%%%%%%%% característica%%%%%%%%%%
    for n = 1:30
        cf03 = wpcoef(Tr{n},[3 1]);           %Dataset Detalhe 3 D3 (wavelet tree)
        s03 = std(cf03);
        v03 = var(cf03);
        mx03 = mean(abs(cf03));
        e03_ = sum((abs(cf03)).^2);
        e03 = e03_/length(cf03);
        cf04 = wpcoef(Tr{n},[4 1]);           %Dataset Detalhe 3 D3 (wavelet tree)
        s04 = std(cf04);
        v04 = var(cf04);
        mx04 = mean(abs(cf04));
        e04_ = sum((abs(cf04)).^2);
        e04 = e04_/length(cf04);
        cf05 = wpcoef(Tr{n},[5 1]);           %Dataset Detalhe 4 D4 (wavelet tree)
        s05 = std(cf05);
        v05 = var(cf05);
        mx05 = mean(abs(cf05));
        e05_ = sum((abs(cf05)).^2);
        e05 = e05_/length(cf05);
        cf06 = wpcoef(Tr{n},[6 1]);           %Dataset Detalhe 5 D5 (wavelet tree)
        s06 =std(cf06);
        v06 = var(cf06);
        mx06 = mean(abs(cf06));

```

```

    e06_ = sum((abs(cf06)).^2);
    e06 = e06_/length(cf06);
    cf07 = wpccoef(Tr{n},[7 1]);    %Dataset Detalhe 6 D6 (wavelet tree)
    s07 = std(cf07);
    v07 = var(cf07);
    mx07 = mean(abs(cf07));
    e07_ = sum((abs(cf07)).^2);
    e07 = e07_/length(cf07);
% razao entre os niveis
    r3_4 = mx03/mx04;
    r4_5 = mx04/mx05;
    r5_6 = mx05/mx06;
    r6_7 = mx06/mx07;
% vetor com as características de nm(i)
    cr{n} = [s03 mx03 e03 r3_4 s04 mx04 e04 r4_5 s05 mx05 e05 r5_6 s06 mx06 e06 r6_7
s07 mx07 e07]';
    imx03{n} = mx03;
    imx04{n} = mx04;
    imx05{n} = mx05;
    imx06{n} = mx06;
    imx07{n} = mx07;
    end
% Vetor nm_19x30 para treinamento da RNA
    in_nm = [cr{1} cr{2} cr{3} cr{4} cr{5} cr{6} cr{7} cr{8} cr{9} cr{10} cr{11} cr{12}
cr{13} cr{14} ...
    cr{15} cr{16} cr{17} cr{18} cr{19} cr{20} cr{21} cr{22} cr{23} cr{24} cr{25} cr{26}
cr{27} cr{28} cr{29} cr{30}];

    tmx03_ = [imx03{1} imx03{2} imx03{3} imx03{4} imx03{5} imx03{6} imx03{7}
imx03{8} imx03{9} imx03{10}
    imx03{11} imx03{12} imx03{13} imx03{14} imx03{15} ...
    imx03{16} imx03{17} imx03{18} imx03{19} imx03{20} imx03{21}
imx03{22} imx03{23} imx03{24}
    imx03{25} imx03{26} imx03{27} imx03{28} imx03{28} imx03{30}];

    tmx04_ = [imx04{1} imx04{2} imx04{3} imx04{4} imx04{5} imx04{6} imx04{7}
imx04{8} imx04{9} imx04{10}
    imx04{11} imx04{12} imx04{13} imx04{14} imx04{15} ...
    imx04{16} imx04{17} imx04{18} imx04{19} imx04{20} imx04{21} imx04{22}
imx04{23} imx04{24} imx04{25}
    imx04{26} imx04{27} imx04{28} imx04{28} imx04{30}];
    tmx05_ = [imx05{1} imx05{2} imx05{3} imx05{4} imx05{5} imx05{6} imx05{7}
imx05{8} imx05{9} imx05{10}
    imx05{11} imx05{12} imx05{13} imx05{14} imx05{15} ...
    imx05{16} imx05{17} imx05{18} imx05{19} imx05{20} imx05{21} imx05{22}
imx05{23} imx05{24} imx05{25} imx05{26} imx05{27} imx05{28} imx05{28}
imx05{30}];
    tmx06_ = [imx06{1} imx06{2} imx06{3} imx06{4} imx06{5} imx06{6} imx06{7}
imx06{8} imx06{9} imx06{10} imx06{11} imx06{12} imx06{13} imx06{14} imx06{15}
...

```

```

    imx06{16} imx06{17} imx06{18} imx06{19} imx06{20} imx06{21} imx06{22}
imx06{23} imx06{24} imx06{25} imx06{26} imx06{27} imx06{28} imx06{28}
imx06{30}];
    tmx07_ = [imx07{1} imx07{2} imx07{3} imx07{4} imx07{5} imx07{6} imx07{7}
imx07{8} imx07{9} imx07{10} imx07{11} imx07{12} imx07{13} imx07{14} imx07{15}
...
    imx07{16} imx07{17} imx07{18} imx07{19} imx07{20} imx07{21} imx07{22}
imx07{23} imx07{24} imx07{25} imx07{26} imx07{27} imx07{28} imx07{28}
imx07{30}];
    tmx03m = mean(tmx03_);tmx04m = mean(tmx04_);tmx05m = mean(tmx05_);tmx06m =
mean(tmx06_);tmx07m = mean(tmx07_);
    amx03_nm = [tmx03m tmx04m tmx05m tmx06m tmx07m]
    clear c* s* v* m* e* r* t* n*;
    %% Le os sinais sb01-sb30 calcula a decomposição wavelet db8 nível 7, extrai
% as características estatísticas dos níveis d3 a d7 e monta o vetor sb_in_19x30
% para treinamento da RNA.
%
load s01.mat;load s02.mat;load s03.mat;load s04.mat;load s05.mat;load s06.mat;
load s07.mat;load s08.mat;load s09.mat;load s10.mat;load s11.mat;load s12.mat;
load s13.mat;load s14.mat;load s15.mat;load s16.mat;load s17.mat;load s18.mat;
load s19.mat;load s20.mat;load s21.mat;load s22.mat;load s23.mat;load s24.mat;
load s25.mat;load s26.mat;load s27.mat;load s28.mat;load s29.mat;load s30.mat;
C={s01 s02 s03 s04 s05 s06 s07 s08 s09 s10 s11 s12 s13 s14 s15 s16 s17 s18 s19 ...
s20 s21 s22 s23 s24 s25 s26 s27 s28 s29 s30};
    for n = 1:30
        Tr{n} = wpdec(C {n},7,'db8','shannon');    %Decomposição Ci,db8,nível 7
    end
%Tr;                                % Decomposição dos 30 sinais
                                    % Extração das características
    for n = 1:30
cf03 = wpcoef(Tr{n},[3 1]);    %Dataset Detalhe 3 D3 (wavelet tree)
    s03 = std(cf03);
    v03 = var(cf03);
    mx03 =mean(abs(cf03));
    e03_ = sum((abs(cf03)).^2);
    e03 = e03_/length(cf03);
cf04 = wpcoef(Tr{n},[4 1]);    %Dataset Detalhe 3 D3 (wavelet tree)
    s04 = std(cf04);
    v04 = var(cf04);
    mx04 = mean(abs(cf04));
    e04_ = sum((abs(cf04)).^2);
    e04 = e04_/length(cf04);
cf05 = wpcoef(Tr{n},[5 1]);    %Dataset Detalhe 4 D4 (wavelet tree)
    s05=std(cf05);
    v05=var(cf05);
    mx05=mean(abs(cf05));
    e05_ =sum((abs(cf05)).^2);
    e05=e05_/length(cf05);
cf06 = wpcoef(Tr{n},[6 1]);    %Dataset Detalhe 5 D5 (wavelet tree)
    s06 = std(cf06);

```

```

v06 = var(cf06);
mx06 = mean(abs(cf06));
e06_ = sum((abs(cf06)).^2);
e06 = e06_/length(cf06);
cf07 = wpcoef(Tr{n},[7 1]);           %Dataset Detalhe 6 D6 (wavelet tree)
s07 = std(cf07);
v07 = var(cf07);
mx07 = mean(abs(cf07));
e07_ = sum((abs(cf07)).^2);
e07 = e07_/length(cf07);
% razao entre os niveis
r3_4 = mx03/mx04;
r4_5 = mx04/mx05;
r5_6 = mx05/mx06;
r6_7 = mx06/mx07;
%vetor com as características de sb(i)
cr{n} = [s03 mx03 e03 r3_4 s04 mx04 e04 r4_5 s05 mx05 e05 r5_6 s06 mx06 e06 r6_7
s07 mx07 e07]';
imx03{n} = mx03;
imx04{n} = mx04;
imx05{n} = mx05;
imx06{n} = mx06;
imx07{n} = mx07;
end
% Vetor sb_19x30 para treinamento da RNA
in_sb = [cr{1} cr{2} cr{3} cr{4} cr{5} cr{6} cr{7} cr{8} cr{9} cr{10} cr{11} cr{12}
cr{13} cr{14} cr{15} ...
cr{16} cr{17} cr{18} cr{19} cr{20} cr{21} cr{22} cr{23} cr{24} cr{25} cr{26}
cr{27} cr{28} cr{29} cr{30}];
tmx03_ = [imx03{1} imx03{2} imx03{3} imx03{4} imx03{5} imx03{6} imx03{7}
imx03{8} imx03{9} imx03{10} imx03{11} imx03{12} imx03{13} imx03{14} imx03{15}
...
imx03{16} imx03{17} imx03{18} imx03{19} imx03{20} imx03{21} imx03{22}
imx03{23} imx03{24} imx03{25} imx03{26} imx03{27} imx03{28} imx03{28}
imx03{30}];
tmx04_ = [imx04{1} imx04{2} imx04{3} imx04{4} imx04{5} imx04{6} imx04{7}
imx04{8} imx04{9} imx04{10} imx04{11} imx04{12} imx04{13} imx04{14} imx04{15}
...
imx04{16} imx04{17} imx04{18} imx04{19} imx04{20} imx04{21} imx04{22}
imx04{23} imx04{24} imx04{25} imx04{26} imx04{27} imx04{28} imx04{28}
imx04{30}];
tmx05_ = [imx05{1} imx05{2} imx05{3} imx05{4} imx05{5} imx05{6} imx05{7}
imx05{8} imx05{9} imx05{10} imx05{11} imx05{12} imx05{13} imx05{14} imx05{15}
...
imx05{16} imx05{17} imx05{18} imx05{19} imx05{20} imx05{21} imx05{22}
imx05{23} imx05{24} imx05{25} imx05{26} imx05{27} imx05{28} imx05{28}
imx05{30}];
tmx06_ = [imx06{1} imx06{2} imx06{3} imx06{4} imx06{5} imx06{6} imx06{7}
imx06{8} imx06{9} imx06{10} imx06{11} imx06{12} imx06{13} imx06{14} imx06{15}
...


```

```


    imx06{16} imx06{17} imx06{18} imx06{19} imx06{20} imx06{21} imx06{22}
imx06{23} imx06{24} imx06{25} imx06{26} imx06{27} imx06{28} imx06{28}
imx06{30}];
    tmx07_ = [imx07{1} imx07{2} imx07{3} imx07{4} imx07{5} imx07{6} imx07{7}
imx07{8} imx07{9} imx07{10} imx07{11} imx07{12} imx07{13} imx07{14} imx07{15}
...
    imx07{16} imx07{17} imx07{18} imx07{19} imx07{20} imx07{21} imx07{22}
imx07{23} imx07{24} imx07{25} imx07{26} imx07{27} imx07{28} imx07{28}
imx07{30}];
    tmx03m = mean(tmx03_);tmx04m = mean(tmx04_);tmx05m = mean(tmx05_);tmx06m =
mean(tmx06_);tmx07m = mean(tmx07_);
    amx03_sb = [tmx03m tmx04m tmx05m tmx06m tmx07m]
clear c* s* v* m* e* r* t* n;
    tg=[1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0; ...
    1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0;1 0 0; ...
    1 0 0;1 0 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0; ...
    0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0;0 1 0; ...
    0 1 0;0 1 0;0 1 0;0 1 0;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1; ...
    0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1;0 0 1; ...
    0 0 1;0 0 1;0 0 1;0 0 1;0 0 1];
    Vec_Train = [in_cr in_nm in_sb];           %Vetor p/ treinamento da rede
clear i*;

```

APÊNDICE C – ÁRVORE DE DECOMPOSIÇÃO DE SINAIS CREPITANTE (C1-C15)




Fonte: Autor, 2010.




Fonte: Autor, 2010.

C3




Fonte: Autor, 2010

C4




Fonte: Autor, 2010.

C5




Fonte: Autor, 2010.

C6




Fonte: Autor, 2010.

C7




Fonte: Autor, 2010.

C8




Fonte: Autor, 2010.

C9




Fonte: Autor, 2010.

C 10




Fonte: Autor, 2010.

C11



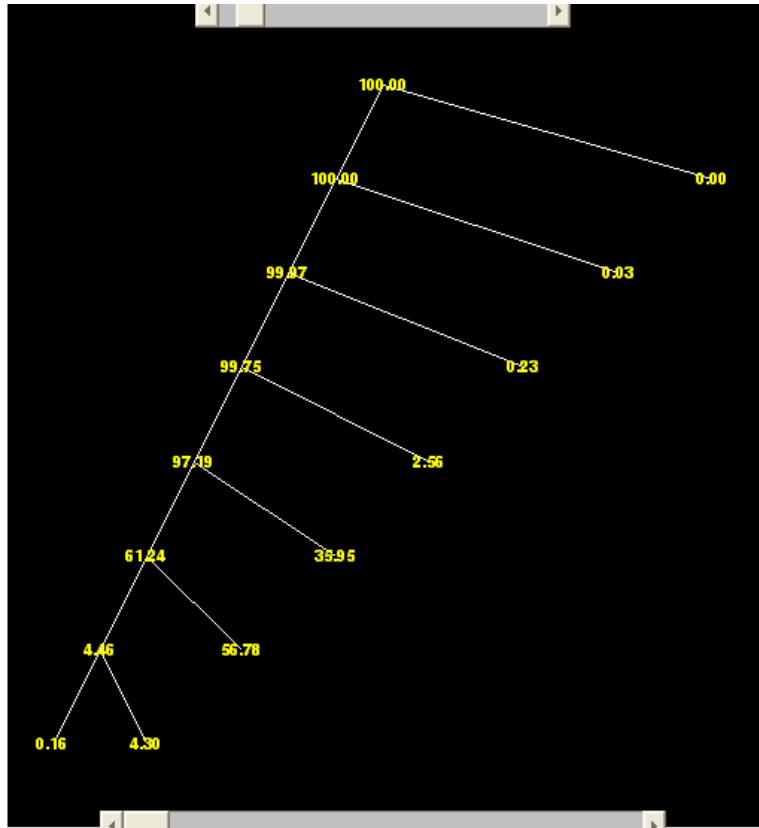
Fonte: Autor, 2010.

C12




Fonte: Autor, 2010.

C13




Fonte: Autor, 2010.

C14




Fonte: Autor, 2010.



Fonte: Autor, 2010.


APÊNDICE D – ÁRVORE DE DECOMPOSIÇÃO DE SINAIS SIBILO (S1 - S15)

S 1



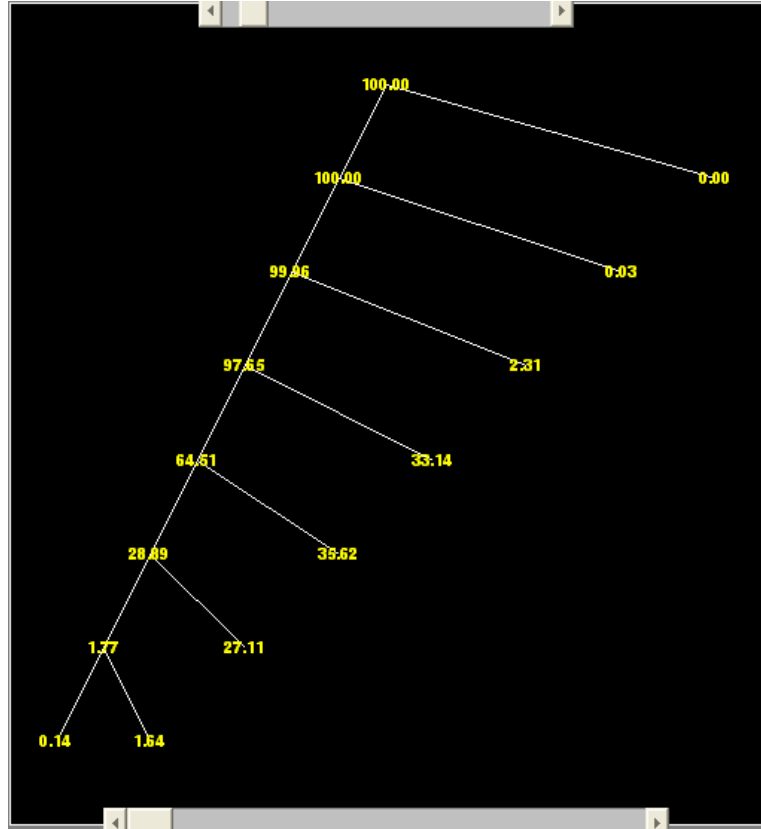
Fonte: Autor, 2010.

S 2




Fonte: Autor, 2010.

S 3




Fonte: Autor, 2010.

S 4




Fonte: Autor, 2010.

S 5




Fonte: Autor, 2010.

S 6




Fonte: Autor, 2010.

S7




Fonte: Autor, 2010.

S 8




Fonte: Autor, 2010.

S 9




Fonte: Autor, 2010.

S 10




Fonte: Autor, 2010.

S 11




Fonte: autor, 2010.

S 12




Fonte: Autor, 2010.

S 13



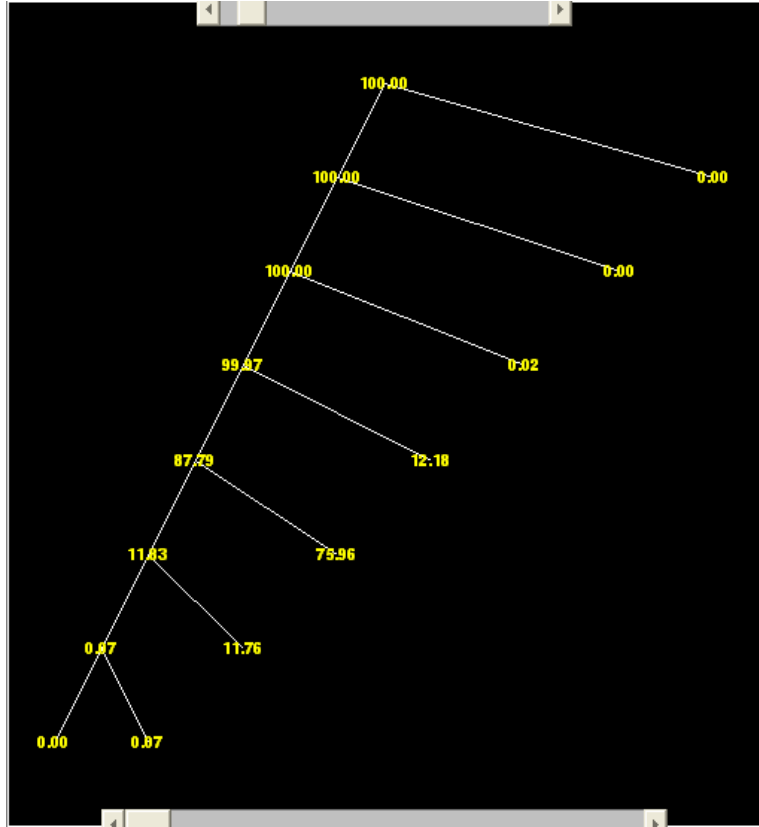
Fonte: Autor, 2010.

S 14



Fonte: Autor, 2010.

S 15



Fonte: Autor, 2010.