

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
INSTITUTO DE MATEMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM MATEMÁTICA APLICADA

# **Detecção de Apneia através de Wavelets e Redes Neurais**

por

Cristina Zaniol

Dissertação submetida como requisito parcial  
para a obtenção do grau de  
Mestre em Matemática Aplicada

Profa. Dra. Maria Cristina Varriale  
Orientadora

Porto Alegre, Março de 2016.

## CIP - CATALOGAÇÃO NA PUBLICAÇÃO

Zaniol, Cristina

Detecção de Apneia através de Wavelets e Redes Neurais /  
Cristina Zaniol.—Porto Alegre: PPGMAp da UFRGS, 2016.

108 p.: il.

Dissertação (mestrado) —Universidade Federal do Rio  
Grande do Sul, Programa de Pós-Graduação em Matemática  
Aplicada, Porto Alegre, 2016.

Orientadora: Varriale, Maria Cristina

Dissertação: Matemática Aplicada,  
Transformada Wavelet, Redes Neurais, Doenças do Sono, Ap-  
neia

# Detecção de Apneia através de Wavelets e Redes Neurais

por

Cristina Zaniol

Dissertação submetida ao Programa de Pós-Graduação em  
Matemática Aplicada do Instituto de Matemática da Universidade  
Federal do Rio Grande do Sul, como requisito parcial para a  
obtenção do grau de

## Mestre em Matemática Aplicada

Linha de Pesquisa: Sistemas Não Lineares e Aplicações

Orientadora: Profa. Dra. Maria Cristina Varriale

Banca examinadora:

Adriane Parraga  
UERGS

Denis Martinez  
PPGCM-UFRGS

Jean Carlo Pech de Moraes  
PPGMAp-UFRGS

Dissertação apresentada e aprovada em  
Março de 2016.

Prof. Dr. Carlos Hoppen  
Coordenador

*"E umas das coisas que aprendi é que  
se deve viver apesar de.  
Apesar de, se deve comer.  
Apesar de, se deve amar.  
Apesar de, se deve morrer.  
Inclusive muitas vezes é o próprio apesar de  
que nos empurra para frente.  
Foi o apesar de que me deu uma angústia  
que insatisfeita foi criadora de  
minha própria vida."*

*Clarice Lispector.*

# Sumário

LISTA DE FIGURAS . . . . .	viii
LISTA DE TABELAS . . . . .	xii
LISTA DE SIGLAS E SÍMBOLOS . . . . .	xiii
RESUMO . . . . .	xvii
ABSTRACT . . . . .	xviii
<b>1 INTRODUÇÃO . . . . .</b>	<b>1</b>
<b>2 A TRANSFORMADA WAVELET . . . . .</b>	<b>7</b>
2.1 Da Transformada de Fourier à Transformada Wavelet . . . . .	7
2.2 Transformada Wavelet Contínua: Definição e Propriedades . .	11
2.3 Transformada Wavelet Discreta . . . . .	14
2.3.1 Definição e Propriedades . . . . .	15
2.3.2 Transformada Wavelet Diádica . . . . .	16
2.4 Transformada Rápida Wavelet ( <i>Fast Wavelet Transform</i> ) . .	20
2.4.1 Determinação dos Coeficientes e Algoritmo Pirâmide . . . . .	20
2.4.2 Família de Wavelets Daubechies (db) . . . . .	22
<b>3 REDES NEURAIS . . . . .</b>	<b>26</b>
3.1 O Neurônio . . . . .	27
3.2 Topologia das Redes Neurais . . . . .	29
3.3 O Processo de Aprendizagem . . . . .	31
3.3.1 Método do Gradiente Conjugado Escalado . . . . .	33
<b>4 APNEIA: DEFINIÇÕES E MÉTODO . . . . .</b>	<b>36</b>
4.1 A Apneia . . . . .	37

<b>4.2 A Polissonografia</b> . . . . .	<b>39</b>
4.2.1 Eletrocardiograma . . . . .	41
4.2.2 Oximetria . . . . .	43
4.2.3 Fluxo e Esforço Respiratório . . . . .	44
<b>4.3 Classificação dos Dados</b> . . . . .	<b>45</b>
4.3.1 Pré-processamento . . . . .	46
4.3.2 Extração de Características . . . . .	48
4.3.3 Treinamento e Classificação . . . . .	52
<b>5 IMPLEMENTAÇÃO E RESULTADOS</b> . . . . .	<b>54</b>
<b>5.1 Caracterização da Base de Dados</b> . . . . .	<b>54</b>
<b>5.2 Implementação no MATLAB</b> . . . . .	<b>58</b>
5.2.1 Wavelet Toolbox . . . . .	58
5.2.2 Neural Network Toolbox . . . . .	60
5.2.3 Representação Gráfica . . . . .	62
<b>5.3 Resultados</b> . . . . .	<b>63</b>
5.3.1 Resultados: Eletrocardiograma . . . . .	65
5.3.2 Resultados: SpO <sub>2</sub> . . . . .	71
5.3.3 Resultados: Fluxo Respiratório . . . . .	74
5.3.4 Resultados: Esforço Respiratório . . . . .	77
5.3.5 Determinação dos Intervalos de Apneia e o Cálculo do AHI . . . . .	78
<b>6 CONCLUSÃO</b> . . . . .	<b>80</b>
<b>6.1 Trabalhos Futuros</b> . . . . .	<b>81</b>
<b>Referências Bibliográficas</b> . . . . .	<b>82</b>
<b>APÊNDICES</b> . . . . .	<b>99</b>

A	DESCRIÇÃO DO BANCO DE DADOS . . . . .	101
B	INTERFACE DO NEURAL NETWORK TOOLBOX . . . . .	103

## Lista de Figuras

2.1	Base $h_n(t)$ , $n = 2^j + k$ , da Equação (2.4). . . . .	9
2.2	Base clássica de Haar, da Equação (2.6). . . . .	9
2.3	Aproximação do sinal do tipo senoide com ruídos, utilizando as bases de Haar da Equação (2.3), e particionando o intervalo total em $2^j$ subintervalos: (a) $j = 2$ , (b) $j = 3$ , (c) $j = 4$ e (d) $j = 5$ . .	10
2.4	$\psi_{a,b}$ para diversos valores de $a$ e $b$ para a wavelet Chapéu Mexicano: (a) Dilatação de $\psi$ , gerado pela Equação (2.10) e (b) Translação de $\psi$ , gerado pela Equação (2.11). . . . .	13
2.5	Aproximação $f_m(t)$ , na escala $m$ , do sinal $f(t)$ (curva azul) utilizando Daubechies 4: (a) $m = 4$ , (b) $m = 3$ , (c) $m = 2$ , (d) $m = 1$ . . . . .	17
2.6	<i>Downsampling</i> , baseado em Radunovic (2009). . . . .	18
2.7	Coeficientes de uma decomposição wavelet em diversas escalas, baseada em Addison (2002). . . . .	19
2.8	Decomposição do sinal $f(t)$ com o Algoritmo Pirâmide, baseado em Mallat (2008). . . . .	22
2.9	Na primeira linha estão as funções escala $\phi(t)$ (pai) e, na segunda, as funções wavelet $\psi(t)$ (mãe), respectivamente, para as wavelets: (a) Haar, (b) db4 e (c) db8. . . . .	23
2.10	Decomposição de $f(t)$ usando Daubechies 4 com $m = 3$ . . . . .	25
3.1	Modelo matemático de um neurônio $k$ , baseado em Haykin (2009). . . . .	28
3.2	Rede Neural <i>Feedforward</i> com topologia 4-3-2, baseado em Haykin (2009). . . . .	30
3.3	Configuração do Problema de Aprendizagem, baseado em Abu-Mostafa <i>et al.</i> (2012). . . . .	32
4.1	PSG de paciente com Apneia Obstrutiva. Fonte: Kryger (2010). . . . .	40
4.2	Segmento de ECG apresentando um complexo QRS. . . . .	41
4.3	(a) Intervalo entre batimentos cardíacos (RR), baseado em Mendez <i>et al.</i> (2009); (b) Padrão bradi-taquicardia. . . . .	42



4.4	Saturação de oxigênio no sangue ( $SpO_2$ ) no intervalo de 1 minuto, em um segmento retirado de PSG do banco de dados UCDDDB (2008). . . . .	43
4.5	Segmento representando: (a) Fluxo Respiratório e (b) Esforço Respiratório, de PSG do banco de dados UCDDDB (2008). . . . .	44
4.6	Procedimento utilizado no processamento de sinais. . . . .	45
4.7	Segmento de 60 segundos de ECG do banco de dados UCDDDB (2008): em azul contínuo, sinal original e, em vermelho tracejado, o sinal pré-processado. . . . .	47
4.8	Saturação de oxigênio $SpO_2$ : (a) original e (b) com filtro de média, do segmento retirado de PSG do banco de dados UCDDDB (2008). . . . .	48
5.1	Exemplo de anotações da PSG, retirado de UCDDDB (2008). . . . .	56
5.2	Exemplo de dados de entrada ( <i>Input</i> ) e da classificação ( <i>Target</i> ) para um sinal constituído por 7 intervalos de um minuto cada, utilizando três características do Intervalo RR: o número de ondas R, a amplitude média das ondas R e a média do Intervalo R. . . . .	57
5.3	Estrutura de decomposição realizada pelo MATLAB. . . . .	59
5.4	Decomposição do ECG com Daubechies 4 com MATLAB (intervalo de 10 segundos, com 1280 observações representadas nos eixos horizontais): (a) ECG original, mensurado em <i>mV</i> , (b) Coeficientes das 3 decomposições, diferenciadas por cores, a saber: $cA_3$ em azul, $cD_3$ em vermelho, $cD_2$ em roxo, e $cD_1$ em verde. . . . .	60
5.5	Exemplo de saída da NN para um intervalo de 6 minutos. . . . .	61
5.6	Diagrama de Caixas: modelo. . . . .	62
5.7	Esquematização do resultado obtido para acurácia para cada número de neurônio no diagrama de caixas. . . . .	63
5.8	Classificação através do Intervalo RR: resultado para a acurácia utilizando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios com o método <i>leave-one-out</i> . . . . .	65
5.9	Classificação através da TW: resultado para a acurácia dos testes utilizando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios com o método <i>leave-one-out</i> . . . . .	67

5.10	Classificação do Intervalo RR e da TW: resultado para a acurácia dos testes utilizando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios com o método <i>leave-one-out</i> . . . . .	69
5.11	Acurácia do teste <i>leave-one-out</i> para SpO <sub>2</sub> usando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios. . . . .	72
5.12	Acurácia do teste <i>leave-one-out</i> para o Fluxo Respiratório usando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios. . . . .	74
5.13	Acurácia do teste <i>leave-one-out</i> para o Esforço Respiratório usando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios. . . . .	77
B.1	Tela inicial do <i>Neural Network Toolbox</i> : <code>nnstart</code> . . . . .	103
B.2	Janela de entrada de dados para reconhecimento de padrões utilizando treinamento supervisionado, onde <i>Input</i> é a matriz de características extraídas do sinal e <i>Target</i> , a respectiva classificação correta. . . . .	104
B.3	Definição do percentual de dados que servirão para compor o conjunto de treinamento, validação e teste estabelecidos aleatoriamente ( <i>Random data division</i> ): neste caso, escolhemos 15% para validação e 15% para os testes, restando 70% para o treinamento. Observe, no lado direito, o número de amostras correspondentes, calculado pelo MATLAB. . . . .	104
B.4	Topologia da Rede Neural: definição do número de neurônios utilizados na Camada Escondida ( <i>Hidden Layer</i> ). Neste caso, escolhemos 10 neurônios na camada escondida. . . . .	105
B.5	Janela de treinamento da Rede Neural, utilizando o algoritmo <i>default</i> <code>trainscg</code> , baseado na Subseção 3.3.1. . . . .	105
B.6	Janela de treinamento dos dados <code>nntraintool</code> : na parte superior mostra a topologia da Rede Neural, seguido pelos algoritmos de treinamento e parâmetros de parada que evitam o <i>overfitting</i> . Na parte inferior há possibilidade de acompanhar, durante o treinamento, os gráficos de performance, treinamento, histograma do erro, matriz de confusão e ROC ( <i>Receiver Operating Characteristic</i> ). . . . .	106

B.7	Matriz de confusão ( <code>plotconfusion</code> ): mostra o resultado do treinamento, validação, teste e todos os resultados em quantidade de dados e percentuais. É possível observar as estatísticas de performance do algoritmo na linha inferior e na coluna mais a direita de cada matriz, onde as posições (3,1), (3,2) e (3,3) fornecem a especificidade, a sensibilidade e a acurácia. . . . .	106
B.8	Janela de avaliação e tentativa de melhora da performance: no lado esquerdo, possibilidade de realizar novo treinamento, mudar a topologia da Rede Neural ou importar um banco de dados maior; no lado direito, possibilidade de realizar testes adicionais. . . .	107

## Lista de Tabelas

4.1	Resumo de Características para 4 sinais distintos de uma PSG.	51
5.1	Idade, IMC e AHI das PSGs analisadas. . . . .	55
5.2	Organização da PSG. . . . .	55
5.3	Estatísticas para a classificação utilizando o intervalo RR para diversos números de neurônios (valores em %). . . . .	66
5.4	Estatísticas para a classificação utilizando a TW para diversos números de neurônios (valores em %). . . . .	68
5.5	Comparativo das estatísticas de performance com Khandoker <i>et al.</i> (2009a) e Xie & Minn (2012) (valores em %). . . . .	68
5.6	Estatísticas para a classificação utilizando o Intervalo RR e a TW para diversos números de neurônios (valores em %). . . . .	70
5.7	Comparação das estatísticas de performance entre a nossa abordagem e aquelas de Erazo & Ríos (2014) e de Chazal <i>et al.</i> (2015) (valores em %). . . . .	71
5.8	Estatísticas para a classificação utilizando características da SpO <sub>2</sub> para diversos números de neurônios (valores em %). . . . .	72
5.9	Comparação das estatísticas de performance entre a nossa abordagem e a desenvolvida por de Chazal <i>et al.</i> (2015) para SpO <sub>2</sub> (valores em %). . . . .	73
5.10	Estatísticas para a classificação utilizando características do Fluxo Respiratório para diversos números de neurônios (valores em %). . . . .	75
5.11	Comparação das estatísticas de performance entre a nossa abordagem e as estatísticas obtidas por Erazo & Ríos (2014) para o Fluxo Respiratório (valores em %). . . . .	76
5.12	Estatísticas para a classificação utilizando características do Esforço Respiratório para diversos números de neurônios (valores em %). . . . .	78
A.1	Pacientes do <i>St Vincent's University Hospital</i> , Dublin. . . . .	102

# LISTA DE SIGLAS E SÍMBOLOS

## Lista de Siglas

<i>AHI</i>	Índice Apneia-Hipoapneia
<i>dbN</i>	Daubechies de ordem N
<i>ECG</i>	Eletrocardiograma
<i>EDF</i>	<i>European Data Format</i>
<i>EEG</i>	Eletroencefalograma
<i>EOG</i>	Eletro-oculograma
<i>EMG</i>	Elegro-miograma
<i>FN</i>	Falso Negativo ( <i>False Negative</i> )
<i>FP</i>	Falso Positivo ( <i>False Positive</i> )
<i>IMC</i>	Índice de Massa Corporal
<i>NN</i>	Rede Neural
<i>PSG</i>	Polissonografia
<i>SDB</i>	Distúrbio Respiratório do Sono
<i>SVM</i>	<i>Support Vector Machine</i>
<i>TF</i>	Transformada de Fourier
<i>TN</i>	Negativo Verdadeiro ( <i>True Negative</i> )
<i>TP</i>	Positivo Verdadeiro ( <i>True Positive</i> )
<i>TW</i>	Transformada Wavelet

## Lista de Símbolos

$\psi(t)$	Função Wavelet ou Wavelet Mãe
$a$	parâmetro de escala ou dilatação de $\psi_{a,b}(t)$
$b$	parâmetro de localização ou translação de $\psi_{a,b}(t)$
$C_\psi$	Constante de Admissibilidade
$T(a,b)$	coeficientes da Transformada Wavelet
$E$	Energia
$T_{m,n}$	Coefficiente de Detalhes na escala $m$
$S_{m,n}$	Coefficiente de Aproximação na escala $m$
$\phi(t)$	Função Escala ou Wavelet Pai
$d_m$	Detalhes da escala $m$
$h_k$	Coefficiente da wavelet passa-alta
$g_k$	Coefficiente da wavelet passa-baixa
$w_{kj}$	peso sináptico $j$ do neurônio $k$
$b_k$	Erro ou viés do neurônio $k$
$y_k$	Resposta do neurônio $k$
$\varphi(\cdot)$	Função de ativação da Rede Neural
$e(w)$	Função erro
$e_{reg}(w)$	Função de erro regularizada
$w$	vetor de pesos $w_{kj}$

$t_n$	Respostas corretas da Rede Neural
$\rho$	performance da Rede Neural
$w_*$	ponto crítico
$\tilde{x}$	sinal $x(t)$ padronizado, $\tilde{x} \sim N(0,1)$
$\bar{x}(t)$	Média de $x(t)$
$\sigma$	Desvio padrão de $x(t)$
$\mu_n$	Média do intervalo $\tilde{x}_n(t)$
$\sigma_n$	Desvio padrão do intervalo $\tilde{x}_n(t)$
$E_n$	Entropia do intervalo $\tilde{x}_n(t)$
$\alpha_n$	Assimetria do intervalo $\tilde{x}_n(t)$
$\kappa_n$	Curtose do intervalo $\tilde{x}_n(t)$
$\tau_i$	Classificação $i$ relacionada a apneia
$cA_n$	Coefficientes de aproximação do <i>Wavelet Toolbox</i>
$cD_n$	Coefficientes de detalhes do <i>Wavelet Toolbox</i>

# AGRADECIMENTOS

Muitas pessoas fizeram parte desta jornada, e agradecer a todas elas ocuparia mais que as páginas desta dissertação. Peço desculpa antecipadamente se, nestas breves palavras, não puder expressar todo o meu agradecimento às pessoas que trouxeram um pouco de brilho aos dias que precederam este trabalho.

Agradeço aos meus pais, Alice e Omar, por todo o amor dedicado e os anos de paciência, e principalmente por me ensinar que não há tesouro maior que a curiosidade e o saber.

Agradeço a minha falecida tia-avó, Olympia, por ter me incentivado nos meus primeiros passos na matemática.

Agradeço ao meu amor, Cássio, por todo carinho e pelo companheirismo, e, enfim, por cuidar de mim mais do que eu mesmo cuido.

Agradeço à minha irmã, Kak, por todas as risadas e brincadeiras, mas também por todas as brigas e discussões que, com certeza serviram para mostrar que a nossa amizade sempre será uma das maiores bênçãos.

Agradeço ao professor Evandro, pela inspiração e pelo exemplo.

Não tenho palavras e nem agradecimentos suficientes à professora Maria Cristina, pela dedicação e pelo apoio quando eu mais precisei e, que sem dúvidas, tornaram este trabalho possível.

Agradecimentos especiais para: Elisabeth Drumm e Michelli Guillen, por fazer parte do início da minha vida acadêmica; Patrícia Coronas Só e Êrika Junchem, pelos conselhos que tanto me ajudaram.

Agradeço ao PPGMAp e à UFRGS pela infraestrutura oferecida, assim como à Capes pela concessão de bolsa.



## RESUMO

A apneia é um Distúrbio Respiratório do Sono com grande incidência, estimando-se que esteja presente em 13% dos homens e 6% das mulheres nos Estados Unidos. Correlacionados com a apneia, estão a obesidade, a diabete *mellitus* e, principalmente, algumas doenças cardíacas. No Brasil ainda há poucas pesquisas, possivelmente pelo difícil acesso e pelo alto custo das Polissonografias. Neste trabalho são analisados alguns sinais de Polissonografia, como o Eletrocardiograma, a Saturação do Oxigênio no Sangue, o Fluxo Respiratório e o Esforço Respiratório. Mostramos como a Transformada Wavelet Discreta e as Redes Neurais constituem ferramentas matemáticas computacionais que possibilitam a extração de características e a classificação, servindo de suporte ao diagnóstico utilizado atualmente.

# ABSTRACT

Apnea is a highly incident Sleep-Disordered Breathing, which afflicts roughly 13% of men and 6% of the women in the *USA*. It is also found a few correlations with other diseases, like obesity, diabetes *mellitus* and, especially, certain cardiac diseases. In Brazil, there are few studies, possibly due to the difficult access and the cost of Polysomnography. In this study, we analyzed some signals of Polysomnography, as the electrocardiogram, the oxygen saturation, the respiratory flow and respiratory effort. We show how the Discrete Wavelet Transform and Neural Network may be applied as computational mathematical tools that enable feature extraction and classification, serving to support the diagnosis currently used.

# 1 INTRODUÇÃO

Ao longo da história, o sono já foi objeto de interesse da mitologia, da arte e da religião. Dormir é descansar, é uma cura dos males do dia, mas também pode ser considerado um momento de fraqueza em que o indivíduo não está consciente de seu estado e de sua segurança. Dormir é uma experiência individual, o que fascinou e fascina artistas, pintores e escritores (Chokroverty & Billiard, 2015; Kryger, 2010). O sono pode ser visto de diversas formas, como por exemplo um estado de vulnerabilidade, povoada por sonhos desconcertantes e, algumas vezes, aterrorizantes em que combinam elementos que normalmente não compartilham o mesmo espaço. Outra forma de tratar o sono é como uma morte reversível, e a morte como um sono eterno. O único consenso é que o sono é um mecanismo de sobrevivência, essencial para a vida e para a sociedade.

O sono é uma função humana básica que objetiva a manutenção das atividades cognitivas e metabólicas, estando ligada ao ciclo circadiano e à produção de hormônios, como a melatonina, o cortisol e a adrenalina (Kryger, 2010). Não apenas a privação, mas também a curta duração do sono, são fatores que contribuem para o desenvolvimento de doenças crônicas, cooperando para o aumento do risco de obesidade e de doenças cardíacas, bem como para o desenvolvimento de resistência à insulina, e para o aumento da incidência de hipertensão, trazendo prejuízos inclusive na capacidade de socialização, o que pode culminar em doenças de cunho depressivo (Khandoker *et al.*, 2009a; Lauderdale *et al.*, 2008; Mullington *et al.*, 2009; Ronzhina *et al.*, 2012; Tagluk & Sezgin, 2011).

Alguns preceitos sobre o sono foram discutidos desde a Grécia Antiga; entretanto, conceitos envolvendo química e fisiologia foram introduzidos no Século XIX. O grande avanço decorreu do uso do Eletroencefalograma, pela primeira vez, em 1929. Apenas em 1969 surgiu o primeiro manual de avaliação do sono e, em

1975 foi utilizada pela primeira vez a denominação apneia - do grego *ápnoia*, sem respiração (Kryger, 2010; Moody *et al.*, 2000).

Os distúrbios do sono e, da mesma forma, a apneia, são doenças com grandes impactos para o indivíduo e para a saúde pública. O indivíduo tem um decréscimo na qualidade de vida, decorrente da falta de concentração, sonolência, fadiga, entre outros, restringindo o convívio com a família e com os amigos, o que reduz o desempenho nas tarefas diárias; por outro lado, o risco de acidentes e de doenças crônicas decorrente dos distúrbios do sono oneram cada vez mais o sistema de saúde direta e indiretamente. Estima-se que, nos Estados Unidos, 13% dos homens e 6% das mulheres possuam algum distúrbio moderado do sono, chegando a números entre 50 e 70 milhões, sendo que esta taxa de incidência aumenta proporcionalmente com a idade (Espiritu & Metsis, 2015; Kryger, 2010; Lado *et al.*, 2011; Peppard *et al.*, 2013). No Brasil ainda há poucos estudos epidemiológicos sobre a apneia. Lemos *et al.* (2009) estudaram 209 motoristas da cidade de São Paulo, dos quais 11,5% apresentavam indícios de apneia. Já Tufik *et al.* (2010) selecionaram uma amostra representativa com a população da cidade de São Paulo conforme o Censo de 2000, com 1042 voluntários, demonstrando que 16,9% possuem apneia moderada ou severa.

Uma das dificuldades da avaliação da incidência de distúrbios do sono na população é decorrente do método de diagnóstico: tradicionalmente é realizado através de Polissonografia, um exame que armazena uma série de sinais biológicos como o Eletroencefalograma (EEG), Eletrocardiograma (ECG), Saturação de Oxigênio no Sangue (SpO<sub>2</sub>), Fluxo Respiratório, Esforço Respiratório, Posição Corporal, entre outros. Normalmente a avaliação é realizada por um especialista que percorre o sinal fazendo uma classificação visual, o que torna a tarefa tediosa e, além disso, com grande quantidade de subjetividade. Um especialista pode ocupar de 2 a 4 horas para gerar pareceres de um exame de 8 horas (Karmakar *et al.*, 2008; Martis *et al.*, 2014; Ronzhina *et al.*, 2012; Tian & Liu, 2005), tempo este muito maior do que os

0,129375 segundos que nós dedicamos para a classificação de uma Polissonografia de 6,2 horas, adotando os métodos que apresentaremos ao longo deste trabalho. Outro inconveniente está relacionado com o desconforto do paciente que, além de ter que dormir fora do local habitual, o faz conectado a uma grande quantidade de fios e eletrodos (Karmakar *et al.*, 2008).

Ao longo das últimas décadas, a evolução da instrumentação médica e dos sistemas computacionais propiciou uma melhoria no processo de diagnóstico; por outro lado, acarretou em um acréscimo da quantidade de dados a serem processados (Dimitrovski *et al.*, 2015; Fernández *et al.*, 2015; Goldberger *et al.*, 2000). Nestes sinais é possível encontrar indícios de “informações escondidas” que não podem ser definidas visualmente ou através de métodos de avaliação tradicionais (Goldberger *et al.*, 2000). A fim de gerar informações relevantes de maneira eficiente, são necessárias novas abordagens estatísticas e computacionais para a análise dos dados.

A análise computacional de dados médicos tem ganhado grande importância, com aplicações em diversos sinais biomédicos: Eletroencefalograma (Schiff *et al.*, 1994; Hazarika *et al.*, 1997; Zhou *et al.*, 2015), Eletrocardiograma (Chen *et al.*, 2015; de Chazal *et al.*, 2002a; de Jesus Kozakevicius *et al.*, 2005; Güler & Übeyli, 2005; Khandoker *et al.*, 2009a,b; Nakayama *et al.*, 2015; Weems *et al.*, 2016), Sons Pulmonares (Tocchetto *et al.*, 2014), Ressonância Magnética (Jin *et al.*, 2005; Lai *et al.*, 2016; Saritha *et al.*, 2013; Shah & Chauhan, 2015), Tomografia (Dubey *et al.*, 2015; Mala *et al.*, 2015; Parraga *et al.*, 2007; Zhong *et al.*, 2004), entre outros. Todas estas técnicas geram uma grande quantidade de dados, muitas vezes repletos de ruídos, provenientes do equipamento ou da interação entre as funções fisiológicas do paciente, e de difícil processamento. A avaliação tradicional dos dados pode incorrer na subutilização dos dados, além de trazer erros de diagnósticos decorrente da subjetividade.

Neste trabalho concentramos esforços no diagnóstico automático da apneia, caracterizada pela ausência ou redução do fluxo respiratório por 10 segundos

ou mais, trazendo abordagens alternativas para a avaliação dos sinais da Polissonografia, em especial a análise dos sinais separadamente. O primeiro passo para a automatização do diagnóstico da apneia foi dado por Guilleminault *et al.* (1984), que indicaram uma correlação entre a frequência cardíaca e a apneia; entretanto, maiores avanços foram possíveis apenas a partir de 2000, impulsionados pelo evento *Challenge from PhysioNet and Computers in Cardiology 2000*. O objetivo desta categoria de desafios é estimular a pesquisa em problemas clínicos significativos e, neste em especial, verificar a possibilidade de utilizar Eletrocardiograma no diagnóstico da apneia, técnica que traria vantagens tais como a redução na interferência na qualidade do sono do paciente e que, ainda, reduziria os custos de uma avaliação preliminar (Goldberger *et al.*, 2000; Penzel *et al.*, 2002). O maior obstáculo do desenvolvimento de ferramentas para o reconhecimento automático da apneia era a comparação da acurácia entre os métodos convencionais e estas proposições, uma vez que não haviam estudos publicados até então. Vários estudos são decorrente destes esforços, utilizando os diversos sinais: Eletrocardiograma (Acharya *et al.*, 2011; Chen *et al.*, 2015; de Chazal *et al.*, 2002b, 2004; Drinnan *et al.*, 2000; Gubbi *et al.*, 2009, 2012; Hassan, 2015; Karmakar *et al.*, 2008; Khandoker *et al.*, 2009b,a; Lado *et al.*, 2011; Mendez *et al.*, 2009, 2010; Mietus *et al.*, 2000; Moody *et al.*, 2000; Penzel *et al.*, 2002; Shinar *et al.*, 2000), Saturação de Oxigênio (Almazaydeh *et al.*, 2012; del Campo *et al.*, 2006), Eletrocardiograma e Saturação do Oxigênio (de Chazal *et al.*, 2015; Erazo & Ríos, 2014; Xie & Minn, 2012), Esforço e Fluxo Respiratório (Fontenla-Romero *et al.*, 2005; Sezgin & Tagluk, 2009; Várady *et al.*, 2002; Tagluk *et al.*, 2010; Tian & Liu, 2005).

Normalmente, a análise e reconhecimento de padrões em sinais biomédicos envolvem três etapas principais: o *pré-processamento*, para remover ruídos e padronizar os sinais a fim de realizar comparações entre pacientes; a *extração de características*, onde são escolhidos parâmetros com capacidade de caracterizar o comportamento de determinado padrão; e a *classificação*, onde normalmente são utilizados algoritmos de aprendizagem de máquina.

Uma abordagem recorrente é a decomposição espectral com a Transformada de Fourier ou em bandas de frequência, com a Transformada Wavelet. Se os eventos de apneia fossem suaves, com sinais biomédicos e frequência cardíaca relativamente estáveis, a Transformada de Fourier proporcionaria uma identificação clara; entretanto, na prática, a apneia não é regular o suficiente para uma aplicação eficaz de um método baseado nesta Transformada (Drinnan *et al.*, 2000). A Transformada Wavelet, que começou a ser desenvolvida já na década de 90, apresenta vantagens ao tratar de sinais aperiódicos e com ruídos, e foi previamente aplicada ao Eletroencefalograma (Schiff *et al.*, 1994; Zhou *et al.*, 2015) e ao Eletrocardiograma (Hazarika *et al.*, 1997). A Transformada Wavelet, ao contrário da Transformada de Fourier, é capaz de identificar singularidades e descontinuidades dos sinais biomédicos, gerando, ainda, uma transformação com representação no tempo e na frequência. Desta forma, adota-se a Transformada Wavelet como abordagem principal na extração de características, resguardando às Redes Neurais a tarefa de aprender com os sinais, realizando o reconhecimento de padrões da apneia.

A proposta deste trabalho é analisar sinais individualmente para determinar se, com a abordagem adotada, é possível desenvolver ferramentas computacionais que possam auxiliar no diagnóstico de apneia. Em outras palavras, o objetivo é determinar a capacidade de reconhecimento da apneia a partir de alguns sinais da Polissonografia, a saber: Eletrocardiograma, Saturação de Oxigênio no Sangue, Esforço Respiratório e Fluxo Respiratório. Este é um passo importante, não apenas para tornar o diagnóstico preventivo mais acessível, como também para o desenvolvimento de equipamentos portáteis, que possibilitariam um aprimoramento no tratamento de pacientes que sofrem com a apneia.

O presente trabalho está organizado da seguinte forma: no Capítulo 2, é apresentado um breve histórico sobre a Teoria das Wavelets, discorrendo sobre a Transformada Wavelet, Contínua e Discreta, e, posteriormente, a Transformada Rápida Wavelet, em particular a wavelet *Daubechies* de ordem 4; o Capítulo 3

trata das Redes Neurais, apresentando a topologia e o processo de aprendizagem; o Capítulo 4 apresenta a apneia, a Polissonografia e alguns dos sinais utilizados para a abordagem adotada, especificando como é realizado o processo de extração e de classificação dos dados; no Capítulo 5 descreve-se o banco de dados que utilizado, assim como as aplicações realizadas; por fim, o Capítulo 6 contém considerações finais e propostas de trabalhos futuros.



## 2 A TRANSFORMADA WAVELET

O principal objetivo quando sinais (ou séries temporais) são objetos de estudo é transformá-los em números que possam ser manipulados, gravados, transmitidos, analisados e, muitas vezes, usados na reconstrução do sinal. Assim, a Transformada Wavelet (TW) tem sido de grande valia, principalmente para sinais aperiódicos, com ruído, intermitentes, transientes, entre outros. As pequenas ondas, o que lhe rendeu a denominação *ondelette* (em francês) e *wavelet* (em inglês), permitem detectar eventos singulares isolados, e serem utilizados como uma alternativa à Transformada de Fourier.

Neste capítulo serão apresentadas as definições e as características da TW contínua e da TW discreta. O algoritmo Pirâmide, fundamental para a implementação computacional da Transformada Rápida Wavelet, será tratado na Seção 2.4, assim como a família de wavelets Daubechies.

### 2.1 Da Transformada de Fourier à Transformada Wavelet

A Transformada de Fourier (TF) é, provavelmente, uma das ferramentas mais utilizadas para o processamento de sinais. Proposta por Jean-Baptiste Joseph Fourier, em 1807, baseia-se no fato de que, dado um sinal  $f(t)$  quadrado integrável<sup>1</sup> no domínio tempo  $t$ , pode-se escrever (Bultheel & Huybrechs, 2011):

$$f(t) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} \hat{f}(\omega) e^{i\omega t} d\omega, \quad (2.1)$$

---

<sup>1</sup>Quadrado integrável, ou  $f(t) \in L^2$ , é definida através da condição  $\int_{\mathbb{R}} |f(t)|^2 dt < \infty$ .

onde a função  $\hat{f}(\omega)$ , no domínio frequência  $\omega$ , denominada Transformada de Fourier de  $f(t)$ , é dada por

$$\hat{f}(\omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt. \quad (2.2)$$

Quando  $f(t)$  não for periódica, torna-se difícil distinguir variações de frequências menores que um certo  $\Delta f$ , denominada *resolução de frequência*, que corresponde a um intervalo de tempo  $T$ , tal que  $\Delta f = 1/T$ . Por esta razão, a TF é considerada uma transformação não localizada no tempo, principalmente por não ser capaz de representar sinais com oscilações abruptas (Chui & Jiang, 2013; Radunovic, 2009).

Para superar estas limitações, Alfred Haar, em 1909, construiu o prelúdio da Teoria de Wavelets (Cohen, 2003; Gao & Yan, 2011; Nievergelt, 1999; Radunovic, 2009). A busca foi guiada pela necessidade de uma outra base ortogonal de funções, como a das trigonométricas da TF, que pudessem representar as oscilações do sinal  $f(t)$ . A formulação de Haar utiliza as bases compostas por  $h_n$ , onde

$$f(t) \simeq \sum_{n=1}^{\infty} a_n h_n(t), \quad (2.3)$$

nos intervalos diádicos  $I_n = [2^{-j}k, 2^{-j}(k+1))$ , todos de *tamanho*  $2^{-j}$ , tal que, para  $n = 2^j + k$ ,

$$h_n(t) = \begin{cases} 1 & \text{se } t \in I_n \\ 0 & \text{caso contrário,} \end{cases} \quad (2.4)$$

como ilustrado na Figura 2.1. Da ortogonalidade da base, tem-se que os coeficientes da Equação (2.3),  $a_n$ , são obtidos através da razão de produtos internos, a saber

$$a_n = \frac{\langle f(t), h_n(t) \rangle}{\langle h_n(t), h_n(t) \rangle}. \quad (2.5)$$

Os parâmetros  $j$  e  $k$  definem, sobre o eixo  $t$ , uma *escala* e uma *translação*, respectivamente.




Figura 2.1: Base  $h_n(t)$ ,  $n = 2^j + k$ , da Equação (2.4).

A definição clássica, da Figura 2.2, é facilmente obtida da composição de funções

$$g = h_2 - h_3 = \begin{cases} 1 & \text{se } t \in [0, \frac{1}{2}) \\ -1 & \text{se } t \in [\frac{1}{2}, 1) \\ 0 & \text{caso contrário,} \end{cases} \quad (2.6)$$

com  $h_2$  definida em  $I_2 = [0, \frac{1}{2})$  e  $h_3$ , em  $I_3 = [\frac{1}{2}, 1)$ , conforme a Equação (2.4). Os intervalos  $I_2$  e  $I_3$  correspondem a  $(j, k) = (1, 0)$  e  $(1, 1)$ , respectivamente, de  $n = 2^j + k$ .




Figura 2.2: Base clássica de Haar, da Equação (2.6).

A Figura 2.3 mostra várias aproximações de um sinal  $f(t)$ , curva azul, do tipo senoide com ruído aleatório dividido em  $2^6$  subintervalos de tamanho  $2^{-6}$ ,

no intervalo  $[0,1]$ , utilizando bases de Haar (Equação (2.3)). Para aproximações do sinal, segmentos horizontais em vermelho, o intervalo total foi dividido em  $2^j$  subintervalos, correspondendo a  $j = 2, 3, 4$  e  $5$  em (a), (b), (c), (d), respectivamente. Note que quanto maior o valor de  $j$ , maior o número de intervalos utilizados na aproximação e melhor é a reconstrução do sinal. Entretanto, ainda que possa gerar uma boa reconstrução, a base de Haar não é adequada no tratamento de sinais contínuos.

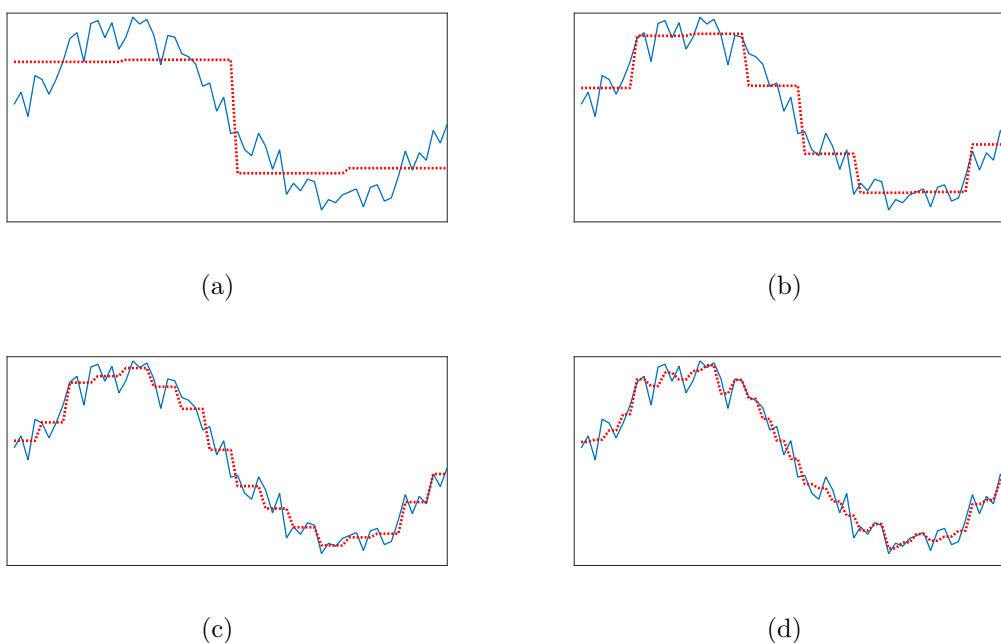


Figura 2.3: Aproximação do sinal do tipo senoide com ruídos, utilizando as bases de Haar da Equação (2.3), e particionando o intervalo total em  $2^j$  subintervalos: (a)  $j = 2$ , (b)  $j = 3$ , (c)  $j = 4$  e (d)  $j = 5$ .

As wavelets foram utilizadas durante o Século XX com outras denominações e com pouca formalização. Após várias contribuições ao estudo da aplicação das wavelets, estas tomaram grandes proporções apenas na década de 80, com Grossmann & Morlet (1984), incorporando transformações de translação e dilatação à função de Haar na análise de dados sísmicos. Influenciados por este

trabalho, outros pesquisadores investiram no desenvolvimento da teoria das Transformadas Wavelets (Gao & Yan, 2011), dos quais Stephane Mallat (Mallat, 2008) se destaca pela construção da *análise em multiresolução*, possibilitando a criação de outras famílias de wavelets, como as Daubechies, Symlets, Coiflets, entre outras (Bultheel & Huybrechs, 2011; Daubechies *et al.*, 1992).

Em comparação com a Transformada de Fourier, as wavelets possuem vantagens pela infinidade de bases que podem ser criadas desde que satisfaçam certas propriedades que serão discutidas na Seção 2.2. Nas próximas seções serão apresentadas a Transformada Wavelet, suas propriedades e, mais especificamente, a família de Wavelets Daubechies.

## 2.2 Transformada Wavelet Contínua: Definição e Propriedades

A TW é uma transformada integral <sup>2</sup> no domínio tempo-frequência, cujo objetivo é obter uma decomposição em várias escalas expandindo um sinal contínuo  $f(t)$ , de acordo com (Addison, 2002; Chan, 1995)

$$f(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_0^{\infty} T(a,b) \psi_{a,b}(t) \frac{da db}{a^2}, \quad (2.7)$$

onde  $C_\psi$ , denominado Coeficiente de Admissibilidade, será definido na Equação (2.13), e os coeficientes  $T(a,b)$  são dados por

$$T(a,b) = \int_{-\infty}^{\infty} f(t) \psi_{a,b}(t) dt. \quad (2.8)$$

As funções  $\psi_{a,b}$ , denominadas wavelets, são obtidas a partir de uma *wavelet mãe*  $\psi(t)$  através de (Addison, 2002; Chui & Jiang, 2013; Nievergelt, 1999):

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi \left( \frac{t-b}{a} \right), \quad a > 0, \quad (2.9)$$

---

<sup>2</sup>Transformada integral da função  $f(x)$  definida em  $a \leq x \leq b$  é descrita por qualquer transformação linear do tipo  $(Tf)(k) = \int_a^b f(x)K(x,k)dx$  (Debnath, 1995).

em que  $a$  é um parâmetro de escala ou dilatação, e  $b$ , de localização ou translação. Observamos que o caso particular  $a = 1$  e  $b = 0$  recai na wavelet mãe, isto é,  $\psi_{1,0}(t) = \psi(t)$  (Addison, 2002; Chan, 1995). Observe ainda que  $1/\sqrt{a}$  é um fator de normalização que preserva a norma  $L_2(\mathbb{R})$ , isto é, invariante em relação aos parâmetros  $a$  e  $b$  e  $\|\psi_{a,b}(t)\|_2 = \|\psi(t)\|_2$  para  $a > 0$  e  $b \in \mathbb{R}$  (Chui & Jiang, 2013). A importância da preservação da norma reside na possibilidade de preservar características do sinal na decomposição, como será vista mais adiante.


Na Figura 2.4 é ilustrada a influência dos parâmetros  $a$  e  $b$  em  $\psi_{a,b}(t)$  do tipo Chapéu Mexicano. Na Figura 2.4(a) tem-se  $b = 0$  fixo e, portanto,

$$\psi_{a,0} = \frac{1}{\sqrt{a}}\psi\left(\frac{t}{a}\right), \quad (2.10)$$


para três valores distintos de  $a$ , de onde é observado o efeito de dilatação do parâmetro  $a$ . Para  $a < 1$ , observa-se o efeito de compressão do sinal, enquanto para  $a > 1$ , de dilatação. Na Figura 2.4(b), tem-se  $a = 1$  fixo e, portanto,

$$\psi_{1,b} = \psi(t - b), \quad (2.11)$$

para três valores distintos de  $b$ , de onde é observado o efeito de translação do parâmetro  $b$ . Para  $b < 0$ , a  $\psi_{1,b}$  é obtida a partir de  $\psi$ , através de um deslocamento por  $|b|$  à esquerda; para  $b > 0$ , o deslocamento é para direita. Utilizando a dilatação  $a$  e a translação  $b$  para representar os sinais em bandas de frequências altas e baixas, é possível fazer com que  $\psi_{a,b}(t)$  se adapte da melhor forma para representar diferentes componentes de um sinal  $f(t)$ . Para que  $\psi_{a,b}(t)$  represente um pico em  $f(t) = b$ , por exemplo, basta que  $a \rightarrow 0$  (Chui & Jiang, 2013; Mallat, 2008).



(a)



(b)

Figura 2.4:  $\psi_{a,b}$  para diversos valores de  $a$  e  $b$  para a wavelet Chapéu Mexicano: (a) Dilatação de  $\psi$ , gerado pela Equação (2.10) e (b) Translação de  $\psi$ , gerado pela Equação (2.11).

Finalmente, as wavelets  $\psi(t)$ , e conseqüentemente  $\psi_{a,b}(t)$ , devem satisfazer algumas propriedades de forma a garantir que não haja perda de informações e possibilitar, posteriormente, a reconstrução do sinal (Addison, 2002; Bachmann *et al.*, 2012; Chan, 1995; Chui, 1997; Kaiser, 2010; Mallat, 2008; Nievergelt, 1999)

- A função  $\psi(t) \in L^2(\mathbb{R})$  é quadrado integrável e, portanto, possui energia  $E$  finita, isto é,

$$E = \int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty. \quad (2.12)$$

Esta condição garante a estabilidade da wavelet, ou em outras palavras, uma pequena variação na  $f(t)$  gera apenas uma pequena variação na TW.

- A Condição de Admissibilidade é caracterizada por um fator  $\frac{1}{C_\psi}$  que traduz um comportamento de filtro passa-banda. Se  $\hat{\psi}(\omega)$  é a Transformada de Fourier de  $\psi(t)$ , dada pela Equação (2.2), a condição de admissibilidade é escrita como

$$C_\psi = \int_0^\infty \frac{|\hat{\psi}(\omega)|^2}{\omega} d\omega < \infty, \quad (2.13)$$

de forma que a wavelet  $\psi(t)$  tenha média zero,

$$\int_{-\infty}^\infty \psi(t) dt = 0. \quad (2.14)$$

A TW contínua, embora importante para o desenvolvimento desta área de estudos, tem limitações que incluem a natureza discreta e a extensão finita dos sinais normalmente coletados. Desta forma, se faz necessária uma abordagem discreta, que será tratada na próxima subseção.

## 2.3 Transformada Wavelet Discreta

A TW discreta dispõe de vantagens em relação à TW contínua, como a velocidade computacional e o procedimento mais simples para obter a reconstrução do sinal. Ainda, com exceção da wavelet de Haar, as TW discretas não possuem expressão analítica e são expressas como matrizes de coeficientes (Chui & Jiang, 2013; Hramov *et al.*, 2014). Nesta seção serão apresentadas definições e propriedades, bem como a TW diádica.



### 2.3.1 Definição e Propriedades

Assim como para a TW contínua, deseja-se escrever um sinal  $f(t)$  como combinação linear de wavelets,  $\psi_{a,b}(t)$ , cada uma com respectivo coeficiente,  $T(a,b)$ . Uma forma natural de discretizar a Equação (2.9) é atribuindo valores discretos para  $a$  e  $b$ , onde  $a = a_0^m$ ,  $m \in \mathbb{Z}$  e  $a_0 \neq 1$ ; e  $b = nb_0a_0^m$ , com  $n \in \mathbb{Z}$ . Desta discretização, resulta a wavelet discreta (Addison, 2002; Chan, 1995)

$$\psi_{m,n}(t) = \frac{1}{a_0^{m/2}} \psi(a_0^{-m}t - nb_0), \quad (2.15)$$

onde  $m$  e  $n$  atribuem as dimensões escala e localização do sinal na decomposição, respectivamente. Por conveniência, é escolhido  $a_0 > 1$  e  $b_0 > 0$  (Addison, 2002; Daubechies *et al.*, 1992). Da mesma forma que na Equação (2.8), a TW discreta é descrita por (Addison, 2002)

$$T_{m,n} = \int_{-\infty}^{\infty} f(t)\psi_{m,n}(t)dt. \quad (2.16)$$

Os valores  $T_{m,n}$  são, no caso discreto, denominados *coeficientes da wavelet* ou *coeficientes de detalhes*. Estes são limitados pela energia original  $E$  do sinal, no qual (Addison, 2002; Chui & Jiang, 2013; Daubechies *et al.*, 1992)

$$AE \leq \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} |T_{m,n}|^2 \leq BE, \quad (2.17)$$

onde  $E$  é dado como na Equação (2.12), e os valores de  $A > 0$  e  $B < \infty$  dependem dos parâmetros  $a_0$  e  $b_0$ . Desta forma, o sinal  $f(t)$  pode ser reconstruído por uma série infinita  $\tilde{f}(t)$ , tal que

$$f(t) \simeq \tilde{f}(t) = \frac{2}{A+B} \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} T_{m,n}\psi_{m,n}(t). \quad (2.18)$$

Se  $A = B = 1$ , a família wavelet é formada por uma base ortonormal, isto é,

$$\int_{-\infty}^{\infty} \psi_{m,n}(t)\psi_{m',n'}(t)dt = \begin{cases} 1 & \text{se } m = m' \text{ e } n = n', \\ 0 & \text{caso contrário,} \end{cases} \quad (2.19)$$

permitindo que o sinal  $f(t)$  seja completamente definido por  $\psi_{m,n}(t)$  (Addison, 2002). Esta premissa garante uma implementação mais fácil e maior eficiência computacional, como será discutido nas próximas subseções.

### 2.3.2 Transformada Wavelet Diádica

Outra forma de representar um sinal  $f(t)$ , denominada TW diádica, consiste na expansão em série dos coeficientes de aproximação,  $S_{m_0,n}$ , e dos coeficientes de detalhe,  $T_{m,n}$ , (Addison, 2002; Chui & Jiang, 2013; Daubechies *et al.*, 1992)

$$f(t) = \sum_{n=-\infty}^{\infty} S_{m_0,n} \phi_{m_0,n}(t) + \sum_{m=-\infty}^{m_0} \sum_{n=-\infty}^{\infty} T_{m,n} \psi_{m,n}(t), \quad (2.20)$$

onde  $\psi_{m,n}(t)$  é definida pela Equação (2.15) e  $T_{m,n}$ , pela Equação (2.16), com  $a_0 = 2$  e  $b_0 = 1$ , isto é,

$$\psi_{m,n}(t) = \frac{1}{2^{m/2}} \psi(2^{-m}t - n). \quad (2.21)$$

Esta discretização é mais usual por simplificar os cálculos numéricos (Mallat, 2008).

Resta, portanto, determinar uma expressão para os coeficientes de aproximação,  $S_{m,n}$ , bem como a função de escala,  $\phi(t)$ , de modo a satisfazer a Equação (2.20). A função de escala  $\phi(t)$  é associada com a suavidade do sinal, isto é, com o número de derivadas contínuas do sinal. Esta função tem a sua construção de forma semelhante à da função wavelet  $\psi(t)$  na Equação (2.21), dada por (Addison, 2002; Kaiser, 2010)

$$\phi_{m,n}(t) = \frac{1}{2^{m/2}} \phi(2^{-m}t - n). \quad (2.22)$$

Diferentemente da wavelet mãe  $\psi(t)$  que tem média zero, a função  $\phi(t)$ , denominada *wavelet pai*, tem média igual a um,

$$\int_{-\infty}^{\infty} \phi(t) dt = 1. \quad (2.23)$$

O coeficiente de aproximação será, portanto, obtido por (Addison, 2002; Bultheel & Huybrechs, 2011)

$$S_{m,n} = \int_{-\infty}^{\infty} f(t) \phi_{m,n}(t) dt. \quad (2.24)$$

A combinação linear (Addison, 2002)

$$f_m(t) = \sum_{n=-\infty}^{\infty} S_{m,n} \phi_{m,n}(t), \quad (2.25)$$

é denominada *aproximação do sinal na escala  $m$* , onde a função de escala  $\phi_{m,n}(t)$  é definida na Equação (2.22). Esta será uma suavização do sinal original  $f(t)$ , como é possível ver na Figura 2.5, a qual foi construída usando as wavelets da família Daubechies de ordem 4, em várias escalas  $m$ , que serão apresentadas na Seção 2.4.2. O sinal original (em azul) é a mesma senoide com ruído aleatório da Figura 2.3. As curvas em vermelho em (a), (b), (c) e (d) são as diferentes aproximações  $f_m(t)$ , para  $m = 4, 3, 2, 1$ , respectivamente. A medida que diminui  $m$ , aumenta o número de pontos da aproximação, representando melhor o sinal original.




Figura 2.5: Aproximação  $f_m(t)$ , na escala  $m$ , do sinal  $f(t)$  (curva azul) utilizando Daubechies 4: (a)  $m = 4$ , (b)  $m = 3$ , (c)  $m = 2$ , (d)  $m = 1$ .

Outra característica da TW diádica é o *downsampling* (compressão do sinal); a aproximação da Figura 2.5(d), que corresponde a  $m = 1$ , tem um número de pontos igual à metade do número de pontos do sinal original; a da Figura 2.5(c), que corresponde a  $m = 2$ , tem a metade do número de pontos da escala anterior, e

assim por diante. Neste caso, como pode ser visto na Figura 2.6, um sinal discreto que é escrito como  $(f(1), f(2), \dots, f(N))$ , neste caso  $N = 32$  na escala  $m = 0$  (sinal original), passa a ser descrito na escala  $m$  por um vetor de tamanho  $1/2^m$  do original, onde  $(f_m(1), f_m(2), \dots, f_m(N/2^m))$  é a aproximação do sinal com  $f_m(t) = S_{m,n} \phi_{m,n}(t)$ . Pode-se concluir que  $m$  assume  $l$  valores, tal que  $N = 2^l$ , com  $m = 0, 1, 2, \dots, l - 1$ . Um exemplo deste fato será apresentado na Subseção 2.4.2 para  $N = 8$  e as decomposições possíveis,  $m = 0, 1, 2$ .




Figura 2.6: *Downsampling*, baseado em Radunovic (2009).

Um fato interessante que advém da decomposição de um sinal é a possibilidade de reescrever a Equação (2.20) como

$$f(t) = f_{m_0}(t) + \sum_{m=-\infty}^{m_0} d_m(t) \quad (2.26)$$

para uma escala arbitrária  $m_0$ , onde

$$d_m(t) = \sum_{n=-\infty}^{\infty} T_{m,n} \psi_{m,n}(t). \quad (2.27)$$

Da Equação (2.26) pode ser visto que, ao adicionar detalhes na escala  $m_0$ , isto é, aumentando uma unidade ao  $m_0$  da Equação (2.26), obtém-se (Addison, 2002)

$$f_{m_0}(t) = f_{m_0+1}(t) + d_{m_0+1}(t). \quad (2.28)$$

Fazendo a troca de índices, a aproximação na escala  $m - 1$  pode ser escrita em função da aproximação da escala  $m$  e do detalhe na escala  $m$ , através de

$$f_{m-1}(t) = f_m(t) + d_m(t). \quad (2.29)$$

Esta propriedade é denominada de *Representação de Multiresolução*, representada diagramaticamente na Figura 2.7, com escalas  $m = 0, 1, 2$  e  $3$  (Addison, 2002; Chui & Jiang, 2013; Daubechies *et al.*, 1992; Mallat, 2008; Radunovic, 2009). A escala  $m = 0$  descreve o sinal original, no qual não é aplicada nenhuma decomposição; a escala  $m = 1$  decompõe o sinal em  $S_{1n}$  com metade do original e  $T_{1n}$  com o mesmo tamanho de  $S_{1n}$ . A próxima decomposição,  $m = 2$ , representa  $S_{1n}$  através de  $S_{2n}$  e  $T_{2n}$ , cada um com metade do tamanho de  $S_{1n}$ , mantendo  $T_{1n}$  inalterado. É interessante perceber que o tamanho do vetor que representa o sinal decomposto é o mesmo do original, sendo possível excluir determinadas bandas de frequência, por exemplo, ruídos que normalmente estão concentrados em componentes com maior frequência.

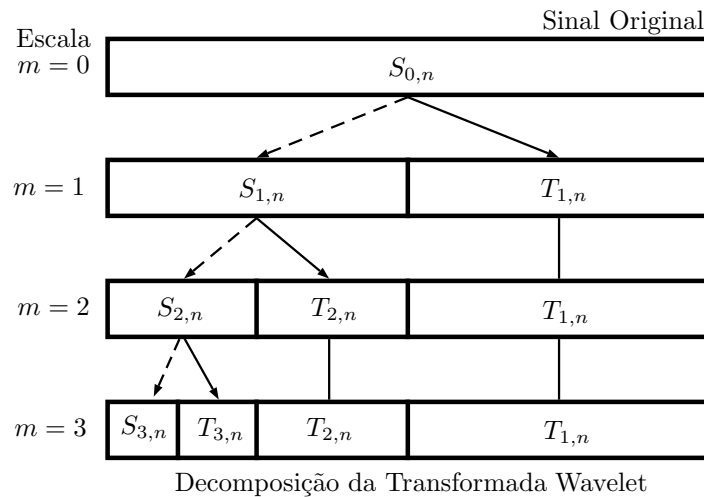


Figura 2.7: Coeficientes de uma decomposição wavelet em diversas escalas, baseada em Addison (2002).

Considerando que  $d_m$  é relacionado com componentes de alta frequência e  $f_m$  com componentes de baixa frequência (ver Seção 2.4), temos que a transformação do sinal utilizando os parâmetros  $m$  e  $n$  permite decompor o sinal  $f(t)$  tanto em sequências de componentes de baixa frequência, como de alta frequência (Chui & Jiang, 2013; Mallat, 2008). Essas decomposições possuem diferente tama-

nho e resolução, discriminando detalhes em uma escala cada vez mais fina (Radu-  
novic, 2009; Walker, 2008). Esta propriedade é que concede às wavelets a carac-  
terística de microscópio matemático, no qual é possível isolar determinadas bandas  
de frequências e olhar mais detalhadamente para algumas características (Daube-  
chies *et al.*, 1992; Nievergelt, 1999). Na próxima seção será tratado o algoritmo  
desenvolvido inicialmente por Mallat (Mallat, 2008) e que possibilitou o uso mas-  
sivo das wavelets computacionalmente.

## 2.4 Transformada Rápida Wavelet (*Fast Wavelet Transform*)

Analogamente à Transformada Rápida de Fourier, a Transformada Rápi-  
da Wavelet é um método de computar a TW discreta utilizando-se de matrizes es-  
parsas. Nesta seção será mostrado como o sinal é iterativamente filtrado por um  
filtro passa-baixa e um passa-alta, assim como as wavelets da família Daubechies,  
utilizadas nos próximos capítulos.

### 2.4.1 Determinação dos Coeficientes e Algoritmo Pirâmide

Para a obtenção dos coeficientes da Transformada Rápida Wavelet, con-  
sideremos as funções  $\phi(t)$  e  $\psi(t)$ , cuja relação obtida é descrita por (Hramov *et al.*,  
2014)

$$\phi(t) = \sum_{k=0}^{2M-1} g_k \phi(2t - k), \quad (2.30)$$

$$\psi(t) = \sum_{k=0}^{2M-1} h_k \phi(2t - k), \quad (2.31)$$

cujos coeficientes  $h_k$  e  $g_k$  são relacionados com a família de wavelets adotada (ver  
Subseção 2.4.2). Os coeficientes  $g_k$  podem ser escritos em função de  $h_k$ , através de

(Dremin *et al.*, 2001; Hramov *et al.*, 2014):

$$g_k = (-1)^k h_{2M-k-1}, \quad (2.32)$$

onde  $M$  se refere ao tamanho da wavelet  $\psi$ , por exemplo, Haar possui  $M = 1$  e a Daubechies 4,  $M = 2$ . Escrevendo as Equações (2.30) e (2.31) de forma mais compacta, têm-se (Addison, 2002)

$$\phi_{m+1,n}(t) = \sum_{k=0}^{2M-1} g_k \phi_{m,2n+k}(t), \quad (2.33)$$

$$\psi_{m+1,n}(t) = \sum_{k=0}^{2M-1} h_k \phi_{m,2n+k}(t). \quad (2.34)$$

Esta forma compacta será utilizada na construção dos coeficientes da Transformada Rápida Wavelet. A partir da Equação (2.24), é possível calcular os coeficientes de aproximação na escala  $m + 1$  (Addison, 2002)

$$S_{m+1,n} = \int_{-\infty}^{\infty} f(t) \phi_{m+1,n}(t) dt. \quad (2.35)$$

A Equação (2.35) pode ser reescrita, incorporando a Equação (2.33), como (Addison, 2002)

$$S_{m+1,n} = \sum_{k=0}^{2M-1} g_k \left[ \int_{-\infty}^{\infty} f(t) \phi_{m,2n+k}(t) dt \right]. \quad (2.36)$$

A mudança de índices na Equação (2.36),

$$S_{m+1,n} = \sum_{k=0}^{2M-1} g_k S_{m,2n+k} = \frac{1}{\sqrt{2}} \sum_g h_{k-2n} S_{m,k}, \quad (2.37)$$

evidencia a possibilidade de gerar os coeficientes de aproximação de uma escala  $m + 1$  usando os coeficientes da escala  $m$ . Da mesma forma, os coeficientes de detalhes na escala  $m + 1$  podem ser obtidos usando os coeficientes  $S_{m,n}$  da escala anterior (Addison, 2002)

$$T_{m+1,n} = \sum_k h_k S_{m,2n+k} = \sum_k h_{k-2n} S_{m,k}. \quad (2.38)$$

As Equações (2.37) e (2.38) representam o algoritmo em multiresolução, executando respectivamente a filtragem passa-baixa e passa-alta (Addison, 2002; Bultheel &

Huybrechs, 2011; Hramov *et al.*, 2014; Mallat, 2008; Teolis, 2012). O *filtro passa-baixa* é uma função que preserva os componentes de baixa frequência, enquanto atenua os de alta frequência; de forma similar, o *filtro passa-alta* conserva frequências altas, e reduz a influência das frequências baixas (Addison, 2002; Chan, 1995; Daubechies *et al.*, 1992; Mallat, 2008; Percival & Walden, 2006). Este processo é esquematizado na Figura 2.8, e é denominado *Algoritmo Cascata* ou *Pirâmide*, fornecendo a aproximação  $f_m(t)$  (Equação (2.25)) e os detalhes  $d_m$  (Equação (2.27)) em uma determinada escala  $m$ .

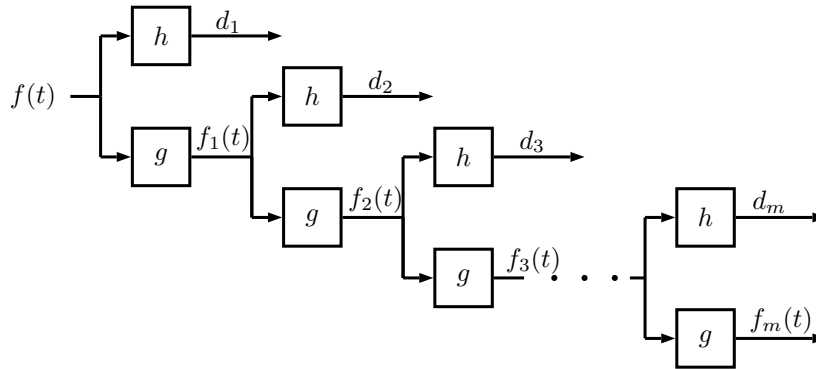


Figura 2.8: Decomposição do sinal  $f(t)$  com o Algoritmo Pirâmide, baseado em Mallat (2008).

O objetivo é obter uma forma eficiente para realizar a decomposição do sinal em aproximação e detalhes usando uma interpretação matricial, podendo ser tratado como a multiplicação de matrizes esparsas (Bultheel & Huybrechs, 2011; Hramov *et al.*, 2014; Mallat, 2008; Radunovic, 2009; Teolis, 2012; Walker, 2008). O algoritmo será discutido para o caso particular das Daubechies na próxima subseção.

### 2.4.2 Família de Wavelets Daubechies (db)

A decisão sobre qual família de wavelets será utilizada depende da natureza do sinal e de quais características devem ser enfatizadas, além, é claro, da



habilidade de aproximar eficientemente o sinal desejado (Addison, 2002; Mallat, 2008; Nievergelt, 1999).

As wavelets Daubechies são uma família de wavelets ortogonais e de suporte compacto desenvolvidas por Ingrid Daubechies, as quais não possuem forma explícita, isto é, são definidas recursivamente com exceção da db1 (Haar) (Addison, 2002; Kaiser, 2010; Radunovic, 2009). Na Figura 2.9 são apresentados elementos de três Daubechies distintas, a saber, a Haar (db1), a db4 e a db8.

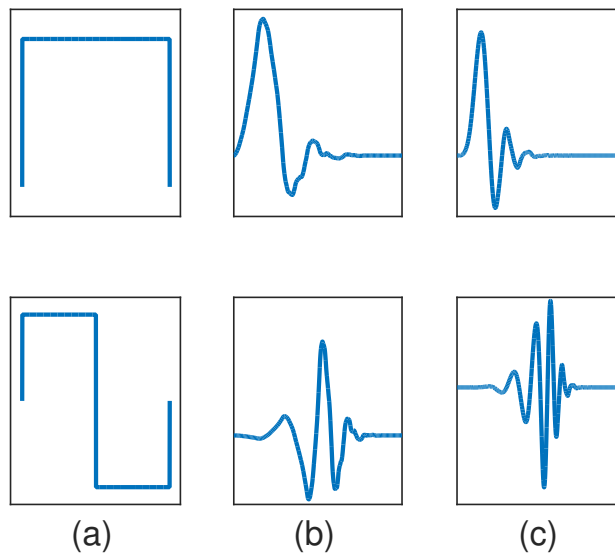


Figura 2.9: Na primeira linha estão as funções escala  $\phi(t)$  (pai) e, na segunda, as funções wavelet  $\psi(t)$  (mãe), respectivamente, para as wavelets: (a) Haar, (b) db4 e (c) db8.

O procedimento realizado pelo algoritmo pirâmide, da Figura 2.8, no caso das Daubechies 4, é um procedimento iterativo descrito como segue. A primeira aproximação na escala  $m = 1$  é obtida através do produto de  $D_N \cdot f[t]$ , onde  $f[t]$  é o vetor discreto de dados (sinal) e  $D_N$ , matriz dos coeficientes de ordem  $N \times N$ ,



dando origem à decomposição

$$\left[ \begin{array}{cc|cc|cccc} S_{21} & S_{22} & T_{21} & T_{22} & T_{11} & T_{12} & T_{13} & T_{14} \end{array} \right]^T. \quad (2.44)$$

Para este caso, esta é a última decomposição possível, e os valores que  $m$  pode assumir são  $m = 0,1,2$  (ver Seção 2.3.2), onde  $m = 0$  representa os dados originais em (2.41).

A Figura 2.10 ilustra a decomposição para  $m = 3$  de um segmento  $f[t]$  de  $N$  pontos de um sinal, retirado de uma PSG (UCDDB, 2008) usando Daubechies 4. Na primeira linha apresenta-se o gráfico do sinal original  $f[t]$ . Na segunda linha, tem-se a parte que corresponde aos coeficientes de aproximação  $S_{3n}$ ,  $n = 1, \dots, N/8$ , e nas três últimas linhas, as partes que correspondem aos coeficientes de detalhe  $T_{3n}$ ,  $n = 1, \dots, N/8$ ;  $T_{2n}$ ,  $n = 1, \dots, N/4$ ; e  $T_{1n}$ ,  $n = 1, \dots, N/2$ .




Figura 2.10: Decomposição de  $f(t)$  usando Daubechies 4 com  $m = 3$ .

As wavelets da família Daubechies tem sido largamente utilizadas em diversos sinais biomédicos, inclusive em ECG, EEG e outros, e compõem parte fundamental para análise e geração dos resultados no reconhecimento de padrões de apneia, como será descrito nos Capítulos 4 e 5.

### 3 REDES NEURAIS

O funcionamento do cérebro foi um importante ponto de partida para a construção das *Redes Neurais*. A grande complexidade aliada à sua eficiência no processamento de informação pode auxiliar no desenvolvimento de sistemas computacionais capazes de atuarem no reconhecimento de padrões. Composto por mais de 85 bilhões de neurônios interconectados uns aos outros e estes por milhares de conexões, o cérebro, além de garantir funções vitais, é responsável pelas percepções e pelo reconhecimento de padrões (Gurney, 1997; Haykin, 2009; Herculano-Houzel, 2009; Kriesel, 2007).

Os neurônios se comunicam através de sinais elétricos mediados pelas sinapses, cuja função é determinar qual impulso deve ou não deve ser transmitido. Cada neurônio recebe uma infinidade de sinais que, quando agrupados, podem exceder um limite e liberar substâncias que se propagam através de junções sinápticas aos demais neurônios, excitando-os; do contrário, quando não há propagação do sinal elétrico, diz-se que houve um efeito inibitório (Gurney, 1997; Haykin, 2009).

Para incorporar essa estrutura de processamento em uma Rede Neural (NN<sup>1</sup>) artificial, enfatizando as conexões entre neurônios, é necessário realizar uma série de simplificações. Para lidar com problemas complexos, é necessário decompor o problema em um número relativamente simples de tarefas (Haykin, 1999, 2009). Por exemplo, enquanto o cérebro humano, utilizando-se de inúmeras informações previamente aprendidas, é capaz de identificar um gato doméstico quase instantaneamente, a NN necessita decompor as informações sobre o animal em um conjunto menor de características para tentar realizar a mesma tarefa (peso, tamanho, pelagem, entre outras características). Em uma espécie de engenharia reversa, pode-se extrair algoritmos e representações que possibilitem uma computação mais barata,

---

<sup>1</sup>A sigla NN vem do inglês, *Neural Network*.

rápida e acurada, isto é, de forma mais limitada, busca-se adaptar da biologia a capacidade de auto-organização, de aprendizagem, de generalização e a tolerância a erros (Alpaydin, 2014; Kriesel, 2007). Nesta seção apresentaremos as NNs, assim como critérios necessários para a sua implementação.

### 3.1 O Neurônio

Na NN, um neurônio  $k$  pode ser matematicamente representado por (Haykin, 2009)

$$u_k = \sum_{j=1}^m w_{kj}x_j, \quad (3.1)$$

onde  $w_{kj}$  é o peso sináptico utilizado pelo neurônio  $k$  para uma entrada  $x_j$ , que normalmente é retratado por um conjunto de características que descrevem um sinal no reconhecimento de padrões. Esse conjunto de características, por sua vez, é transformado por uma *função de ativação*, com funcionamento análogo às sinapses: inibir ou excitar a transmissão da informação. As funções de ativação  $\varphi(\cdot)$ , também denominadas funções de transferência, são o resultado da transformação de uma combinação linear de entradas,  $x_j$ , e dos respectivos pesos,  $w_{kj}$  com um erro ou viés de classificação,  $b_k$ , fornecendo a saída (Fine, 2006; Haykin, 2009; Kriesel, 2007; Sapuan & Mujtaba, 2009)

$$y_k = \varphi(v_k), \quad (3.2)$$

onde

$$v_k = u_k + b_k. \quad (3.3)$$

A esquematização das entradas  $x_j$  e da saída  $y_k$  do neurônio  $k$  pode ser visualizada na Figura 3.1. Nela, é possível identificar alguns elementos, como um conjunto de sinapses ou conexões  $j$  que ligam o sinal  $x_j$  ao peso correspondente,  $w_{kj}$ ; uma soma ( $\Sigma$ ) que une o resultado da ponderação dos sinais com o respectivo peso; e a função de ativação,  $\varphi(\cdot)$ , que será discutida a seguir. Normalmente também é incluído o erro  $b_k$  na soma com a finalidade de aumentar ou diminuir a saída do neurônio, per-

mitindo o ajuste dos dados com a saída esperada, isto é, melhorando a eficiência do treinamento (Sapuan & Mujtaba, 2009). Na abordagem mais moderna,  $b_k$  é descrito como uma entrada, um vetor unitário do tamanho do vetor de características, que é transformado com uma combinação linear com os pesos  $w_{0j}$ ,  $j = 1, \dots, n$  e o limiar que se deseja ultrapassar é transladado segundo a função de ativação utilizada.

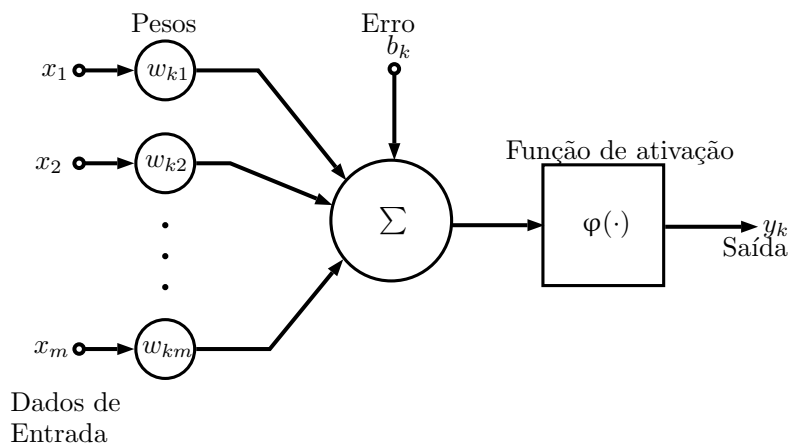


Figura 3.1: Modelo matemático de um neurônio  $k$ , baseado em Haykin (2009).

A função de ativação é utilizada para limitar a amplitude da saída do neurônio, compactando-o dentro de um intervalo e servindo como um interruptor para a transmissão da informação (Haykin, 1999; Sapuan & Mujtaba, 2009). Note que se a função de ativação não fosse limitada, não seria possível garantir a existência de pontos de equilíbrio, tornando mais difícil a tarefa de otimizar a função de custo associada com os pesos (Wang *et al.*, 2015), conforme será visto no final deste capítulo. Dentre as funções de ativação, podem ser citadas a função de Heaviside ou função degrau unitário, as funções lineares e as funções sigmóides (Bishop, 2006; Hastie *et al.*, 2009; Haykin, 2009; Kriesel, 2007; Sapuan & Mujtaba, 2009).

A função de Heaviside é utilizada no processamento de informações simples e ficou conhecida como Modelo de McCulloch-Pitts. Esta função de ativação permite uma resposta binária, 0 ou 1, realizando apenas operações lógicas elementares como “OR”, “AND”, “NOR” e “NAND”, onde seja possível uma separação

linear das categorias (Haykin, 2009; Konar, 2006). Para processos mais complexos, é necessário utilizar funções com maior flexibilidade.

A função de ativação sigmoide possui um gráfico em formato de S, sendo a mais utilizada para a construção da NN (Bishop, 2006; Hastie *et al.*, 2009; Haykin, 2009; Kriesel, 2007). Diferentemente da função de Heaviside, a função sigmoide é contínua; as mais utilizadas são a função logística,

$$\varphi(v_k) = \frac{1}{1 + e^{-\lambda v_k}}, \quad (3.4)$$

que assume todos os valores no intervalo (0,1), onde  $\lambda$  é um fator de declividade; e a função tangente hiperbólica,

$$\varphi(v_k) = \tanh(v_k), \quad (3.5)$$

que assume valores no intervalo (-1,1).

A próxima seção discorre sobre a topologia das NNs, que permeia o processamento dos dados de entrada até a geração dos dados de saída.

## 3.2 Topologia das Redes Neurais

Um único neurônio não é capaz de aprender todos os conjuntos de treinos eficientemente. Disto origina-se a necessidade de considerar uma estrutura com interconexões entre neurônios a fim de aumentar a quantidade de tarefas que possam ser executadas (Fine, 2006). A maneira com a qual os neurônios estão estruturados está relacionada com a forma de aprendizagem utilizada pelo algoritmo de treinamento da rede, que será discutida mais adiante.

As NNs são descritas através de diversas topologias: as *Feedforward*, de uma ou de múltiplas camadas e de base radial; as *Recorrentes* ou *Feedback*, classificadas em competitivas, de Hopfield, no modelo de ART (*Adaptive Resonance Theory*) e nos mapas de Kohonen (Jain *et al.*, 1996; Haykin, 2009). Neste trabalho

serão adotadas as NNs *Feedforward* com múltiplas camadas (Figura 3.2). Nesta estrutura, cada neurônio de uma das camadas está conectado em uma única direção com todos os neurônios da próxima camada, isto é, a ligação entre os neurônios pode ser definida por um fluxo direcionado e acíclico (Fine, 2006).




Figura 3.2: Rede Neural *Feedforward* com topologia 4-3-2, baseado em Haykin (2009).

A NN *Feedforward* é composta por uma camada de entrada, uma de saída e uma ou mais camadas escondidas (Fine, 2006; Hastie *et al.*, 2009; Haykin, 2009). A primeira camada recebe dados provenientes da extração de características do sinal (que será estudada no Capítulo 4), enquanto que a última camada fornece a classificação dos dados de entrada após o processamento. A camada intermediária, composta por uma ou mais camadas, é denominada camada escondida ou camada oculta (em inglês, *hidden layer*), e é onde ocorre o processamento das informações. O nome decorre do fato dos valores não serem diretamente observados, como no caso dos dados de saída. Quando combinadas várias camadas escondidas, a Equação (3.2) assume a forma (Bishop, 2006)

$$y_k = \varphi_1 \left( \sum_{j=1}^M w_{kj} z_j + b_k \right), \quad (3.6)$$



com

$$z_j = \varphi_2 \left( \sum_{i=1}^D w_{ji} x_i + b_j \right), \quad (3.7)$$

onde  $w_{kj}$  e  $w_{ji}$  são os pesos para cada uma das duas camadas,  $b_k$  e  $b_j$  são os erros, e  $\varphi_1(\cdot)$  e  $\varphi_2(\cdot)$  as funções de ativação para cada camada. Seguindo a terminologia de Bishop (2006), a rede é denominada *Rede de Duas Camadas* quando há duas camadas escondidas, cada uma com seus pesos, e que determina propriedades importantes da NN. Neste trabalho serão utilizadas as *Redes de Uma Camada*. Resta, agora, discorrer sobre o processo de aprendizagem da NN; que será apresentado na próxima seção.

### 3.3 O Processo de Aprendizagem

O procedimento usado para que a NN aprenda é denominado algoritmo de aprendizagem *Backpropagation*, onde o vetor  $w$  de pesos da Equação (3.6) são adaptados de forma a atingir o melhor resultado conforme o objeto de estudo (Haykin, 2009). O processo de aprendizagem pode ocorrer de duas formas: o supervisionado e o não-supervisionado. Na aprendizagem supervisionada, a rede recebe as respostas corretas,  $\{t_n\}$ ,  $n = 1, 2, \dots, N$ , e os pesos  $w_{kj}$  são determinados de forma a produzir a resposta mais próxima da correta; já para a não supervisionada, não é fornecida a resposta correta e o algoritmo necessita buscar estruturas ou correlações no próprio conjunto de dados de entrada que torne possível a organização em categorias (Jain *et al.*, 1996; Abu-Mostafa *et al.*, 2012). O método de aprendizagem da NN que adotaremos neste trabalho será o supervisionado, pois a classificação correta é conhecida (compõe o banco de dados utilizado, sendo obtida por especialista da área da saúde). Importante esclarecer, entretanto, que, uma vez que esta NN tenha aprendido a classificar, ela poderá ser usada para interpretar qualquer outro conjunto de dados advindos de Polissonografias que tenham sido coletados com os mesmos procedimentos.




Figura 3.3: Configuração do Problema de Aprendizagem, baseado em Abu-Mostafa *et al.* (2012).

No processo de aprendizagem supervisionado (Figura 3.3), a NN é projetada para produzir uma solução ótima  $y_*(x_n, w)$ , uma generalização dos dados de entrada conforme a resposta correta fornecida, sendo que os pesos  $w_{kj}$  da NN serão ajustados verificando a influência do vetor de treino,  $y(x_n, w)$ , e o erro do sinal,  $e(w)$ , que nada mais é que a diferença entre a resposta desejada e a dada pela NN. Então, dado um conjunto de entradas  $\{x_n\}$ ,  $n = 1, 2, \dots, N$  e a respectiva classificação,  $\{t_n\}$ , é necessário minimizar a função erro (Bishop, 1995, 2006; Hastie *et al.*, 2009; Zhang & Rajapakse, 2009)

$$e(w) = \frac{1}{N} \sum_{n=1}^N \|y(x_n, w) - t_n\|^2, \quad (3.8)$$

em que  $y(x_n, w)$  é o resultado obtido na classificação de  $x_n$  com os pesos  $w$ . Esse processo é feito iterativamente, buscando a formatação que garante o menor erro (Haykin, 2009). Uma dificuldade é a inexistência de procedimento predefinido para determinar qual a melhor NN para cada tipo de problema, sendo necessário realizar a busca empiricamente.

Como a NN recebe muitos dados de treinamento, devemos tomar cuidado em relação à quantidade e qualidade destes, de modo a evitar que, ao final, a NN acabe aprendendo inclusive o ruído do sinal - este fenômeno é denominado *overfit* (Abu-Mostafa *et al.*, 2012; Fine, 2006; Haykin, 2009). Para gerar uma resposta mais suave e menos propensa a *overfitting*, adota-se uma função erro regularizada,

dada por (Bishop, 1995; Zhang & Rajapakse, 2009)

$$e_{reg}(w) = \rho \frac{1}{N} \sum_{n=1}^N \|y(x_n, w) - t_n\|^2 + (1 - \rho) \frac{1}{N} \sum_{n=1}^N \|w_n\|^2, \quad (3.9)$$

onde  $\rho$  descreve a performance da NN (proporcional ao número de pontos classificados corretamente). Juntamente com o cálculo do erro regularizado, utiliza-se adicionalmente um método de parada, como descrito na subseção que segue.

### 3.3.1 Método do Gradiente Conjugado Escalado

O comportamento do erro frente a um conjunto independente, o *Conjunto de Validação*, normalmente mostra uma tendência decrescente seguida de uma crescente, quando a NN começa incorporar ruídos ao treinamento, ou seja, o *overfit* (Bishop, 2006). Muitos algoritmos de otimização podem ser utilizados no treinamento para encontrar o menor erro e possibilitar a parada em um ponto ótimo, como o Método do Gradiente Conjugado; entretanto, este método possui uma taxa de convergência baixa (o processo de aprendizagem é lento) e é muito influenciado pela escolha dos parâmetros. Møller (1993) desenvolveu um algoritmo para o Método do Gradiente Conjugado Escalado (*Scaled Conjugate Gradient*) para aumentar a velocidade de aprendizagem e, conseqüentemente, a eficiência da NN (Chel *et al.*, 2011; Møller, 1993; Sapuan & Mujtaba, 2009).

Seja o erro  $\tilde{e}(w)$  uma aproximação do erro  $e(w)$ , da Equação (3.9), escrita em série de Taylor (Chel *et al.*, 2011; Møller, 1993)

$$\tilde{e}(w + \Delta w) = e(w) + e'(w)^T \Delta w + \Delta w^T e''(w) \Delta w. \quad (3.10)$$

Neste caso,  $e''(w)$  é uma matriz hessiana. Se  $e''(w)$  for positiva definida e

$$p_k^T e''(w) p_i = 0, \quad \text{para } k \neq i, \quad (3.11)$$

onde  $p_1, p_2, \dots, p_n$  são bases quaisquer do  $\mathbb{R}^n$ , é possível escrever o vetor crítico de pesos  $w_*$  como combinação linear de  $p_i$  (Møller, 1993),

$$w_* - w_1 = \sum_{i=1}^n \alpha_i p_i, \quad \alpha_i \in \mathbb{R}, \quad (3.12)$$

sendo  $w_1$  o vetor de pesos iniciais. Para determinar  $\alpha_i$ , basta multiplicar a Equação (3.12) por  $p_j^T e''(w)$  e substituir, na Equação (3.10),  $e'(w)$  por  $-e''(w)w_*$ , de onde se obtém (Chel *et al.*, 2011; Møller, 1993)

$$\alpha_j = \frac{p_j^T (-e'(w) - e''(w)w_1)}{p_j^T e''(w)p_j} = \frac{-p_j^T e'(w_1)}{p_j^T e''(w)p_j}. \quad (3.13)$$

Desta forma, o ponto crítico  $w_*$  pode ser calculado utilizando as Equações (3.12) e (3.13), em que  $w_*$  é mínimo quando (Møller, 1993)

$$\frac{1}{2} (w - w_*)^T e''(w) (w - w_*) > 0, \quad (3.14)$$

desde que  $e''(w)$  seja positiva definida. Para melhorar a eficiência computacional, calcula-se uma aproximação  $s_k$  para  $e''(w_k)p_k$ , onde (Møller, 1993)

$$s_k = e''(w_k)p_k \simeq \frac{e'(w_k + \sigma_k p_k) - e'(w_k)}{\sigma_k} + \lambda_k p_k, \quad 0 < \sigma_k \ll 1, \quad (3.15)$$

com  $\lambda_k$  um parâmetro de ajuste para garantir que  $s_k$  seja positiva definida. Se  $s_k$  não for positiva definida, é atribuído um valor maior a  $\lambda_k$  e é redefinida  $s_k$ .

É necessário, ainda, determinar  $p_k$  da Equação (3.12). As bases  $p_k$  são definidas recursivamente, e a partir de  $p_1$  dado, obtém-se (Chel *et al.*, 2011; Møller, 1993)

$$p_{k+1} = r_{k+1} + \beta_k p_k, \quad (3.16)$$

e reescreve-se

$$a_k = \frac{-p_k^T r_k}{p_k^T s_k}, \quad (3.17)$$

onde

$$\begin{aligned} w_{k+1} &= w_k + \alpha_k p_k, \\ r_{k+1} &= -e'(w_{k+1}), \\ \beta_k &= \frac{|r_{k+1}|^2 - r_{k+1} r_k}{p_k^T r_k}. \end{aligned} \quad (3.18)$$

Finalmente, o método apresentado é, em síntese, composto por dois processos iterativos independentes: primeiro, a busca da direção  $p_k$  e, segundo, o tamanho do passo,  $\alpha_k$  (Møller, 1993). O pseudo-algoritmo resume esta subseção e pode ser escrito da seguinte forma, considerando um número máximo  $\mathcal{N}$  de iterações:

1. Escolha o vetor inicial  $w_1$  e os escalares  $\sigma > 0$  e  $\lambda_1 > 0$ . Faça  $p_1 = r_1 = -e'(w_1)$ .
2. Calcule  $s_k$ , da Equação (3.15).
3. Se  $s_k$  não for positiva definida, aumente  $\lambda_k$  e retorne a 2.
4. Calcule  $\alpha_k$ , da Equação (3.17).
5. Atualize o vetor  $w_{k+1}$  e  $r_{k+1}$ , conforme Equação (3.18).
6. Se  $k < \mathcal{N}$ , faça  $p_{k+1} = r_{k+1}$ .  
Senão, calcule  $\beta_k = \frac{|r_{k+1}|^2 - r_{k+1}^T r_k}{p_k^T r_k}$  e  $p_{k+1} = r_{k+1} + \beta_k p_k$ .
7. Se  $r_k \neq 0$  e  $k < \mathcal{N}$ ,  $k = k + 1$  e retorne à 2.  
Senão,  $w_{k+1}$  é mínimo.

No próximo capítulo será apresentado o problema de estudo e o modelo utilizado para a construção dos resultados.

## 4 APNEIA: DEFINIÇÕES E MÉTODO

A apneia, assim como os demais Distúrbios Respiratórios do Sono (SDB<sup>1</sup>), é uma doença com grandes impactos para o indivíduo e para a saúde pública. Estima-se que, nos Estados Unidos, 13% dos homens e 6% das mulheres possuem algum distúrbio moderado do sono; em números, representa entre 50 e 70 milhões de pessoas (Espiritu & Metsis, 2015; Kryger, 2010; Peppard *et al.*, 2013). Este número aumenta proporcionalmente com a idade, o que insere ainda mais custos com tratamentos de saúde. No Brasil há poucos estudos epidemiológicos abordando a apneia. O primeiro deles trata de motoristas da cidade de São Paulo, dos quais 11,5% dos 209 entrevistados apresentavam indícios de apneia (Lemos *et al.*, 2009). Um dos mais abrangentes, também realizado na cidade de São Paulo, compreende 1042 voluntários: seguindo a distribuição do Censo de 2000, descobriram uma incidência de apneia moderada ou severa de 16,9% (Tufik *et al.*, 2010). Este estudo traz, ainda, informações interessantes relacionadas com a prevalência da apneia dentre renda familiar, trabalho, idade, entre outros fatores.

Além de sintomas mais brandos, como sonolência e fadiga, a apneia está diretamente ligada com o aumento da obesidade, diabetes *mellitus* e doenças cardíacas (de Chazal *et al.*, 2004, 2015; Kryger, 2010; Peppard *et al.*, 2013). Pesquisadores vêm chamando atenção para a necessidade do diagnóstico e do tratamento precoce a fim de reduzir a prevalência de comorbidades, isto é, doenças associadas com a apneia, relacionadas a apneia; entretanto, o acesso às clínicas de estudo do sono ainda não é possível para grande parte da população (Bsoul *et al.*, 2011; Chen *et al.*, 2013, 2015; Drinnan *et al.*, 2000; Goldberger *et al.*, 2000; Karmakar *et al.*, 2008; Khandoker *et al.*, 2009a; Moody *et al.*, 2000; Penzel *et al.*, 2002; Saminu *et al.*, 2014; Shinar *et al.*, 2000; Tagluk *et al.*, 2010; Xie & Minn, 2012). Neste sentido, em 2000, foi lançado o *Challenge From Physionet and Computers in Cardiology 2000*,

---

<sup>1</sup>A sigla SDB vem do inglês, *Sleep Disordered Breathing*.

que disponibilizou dados de ECG para o estudo da classificação automática da apneia, e que buscava o desenvolvimento de abordagens alternativas de avaliação da apneia, mais simples que as técnicas convencionais utilizando Polissonografia (PSG) (Goldberger *et al.*, 2000). Desde então, uma série de dados e desafios foram lançados relacionados a diversas enfermidades, como o UCDDB (2008) que disponibiliza dados de PSG classificados por especialista da área da saúde, conforme será descrito no Capítulo 5, totalizando mais de 60 bancos de dados e mais de 4 terabytes de informações (Goldberger *et al.*, 2000).

Neste capítulo serão apresentadas características da apneia, assim como a PSG e os sinais que serão utilizados nos resultados, apresentados no Capítulo 5. Ademais, na Seção 4.3 serão apontadas características que possibilitarão a implementação do algoritmo para classificação da apneia.

## 4.1 A Apneia

A apneia é um distúrbio respiratório caracterizado pela interrupção do fluxo de ar por pelo menos 10 segundos; no caso mais brando, a hipopneia, há obstrução ou redução do fluxo de ar. Em ambos os casos, há uma redução na saturação do oxigênio no sangue em pelo menos de 2 a 4%. Dentre os tipos de apneia, podem ser elencados (de Chazal *et al.*, 2002a, 2004, 2015; del Campo *et al.*, 2006; Karmakar *et al.*, 2008; Várady *et al.*, 2002; Tagluk *et al.*, 2010):

- **Obstrutiva:** é caracterizada por pausas alternadas na respiração, causada por obstrução ou colapso das vias aéreas superiores, onde o esforço de respiração está presente. Normalmente é resultante do relaxamento das estruturas das vias aéreas superiores, que obstrui a passagem do ar. Esta é a causa mais frequente da apneia.

- Central: é uma condição neurológica que causa a perda do esforço respiratório durante o sono.
- Mista: combinação da apneia obstrutiva e da central, onde há uma pausa na respiração por um curto intervalo, seguido por um esforço respiratório para recuperar a oxigenação sanguínea.

Vários fatores de risco podem ser utilizados como indicativos para o diagnóstico da apneia. A *American Academy of Sleep Medicine* (AASM) sugere que sejam observados o histórico de sono do indivíduo, juntamente com características como circunferência do pescoço, Índice de Massa Corporal (IMC), entre outros (AASM, 1990, 2005; Berry *et al.*, 2012; Epstein *et al.*, 2009). Também são apontados como indicativos da apneia: o ronco, a fragmentação do sono ou a insônia, o sono não restaurador, a sonolência durante o dia, a fadiga crônica, as dores de cabeça matinais, o aumento de peso, as pequenas perdas de memória, o decréscimo da concentração, o decréscimo da libido e a irritabilidade (Chokroverty & Thomas, 2013; de Chazal *et al.*, 2004, 2015; Epstein *et al.*, 2009; Karmakar *et al.*, 2008; Kryger, 2010; Lado *et al.*, 2011; Mendez *et al.*, 2010; Penzel *et al.*, 2002; Tagluk *et al.*, 2010). Além disso, existem outras comorbidades que podem ser observadas como depressão, doenças cardíacas (arritmias, hipertensão, insuficiência cardíaca, isquemia, infarto), diabetes *mellitus*, e a própria obesidade (Khandoker *et al.*, 2009a,b; Lado *et al.*, 2011; Mendez *et al.*, 2010; Penzel *et al.*, 2002; Ronzhina *et al.*, 2012). Relatos indicam que o indivíduo que sofre com a apneia tende a restringir o convívio com a família e os amigos; além disso, o cansaço, a sonolência e as pequenas distrações estão correlacionadas com acidentes domésticos, de trabalho e de trânsito. Todos estes elementos resultam numa redução da qualidade de vida, tanto no âmbito pessoal quanto no profissional, tornando-se uma questão de saúde pública.

A métrica normalmente utilizada em relação à severidade da apneia é dada pelo número de eventos de apneias e de hipopneias em um dado intervalo de



tempo. O Índice de Apneia e Hipoapneia (*Apnea Hypopnea Index* - AHI) é calculado pelo número de apneias e hipopneias em um período de uma hora (AASM, 1990, 2005; Karmakar *et al.*, 2008; Kryger, 2010). Segundo o critério, os indivíduos com  $AHI < 5$  não possuem apneia; para valores entre  $5 \leq AHI < 15$ , é considerado apneia leve;  $15 \leq AHI \leq 30$ , moderada; e para  $AHI > 30$ , apneia severa (AASM, 1990, 2005; Bsoul *et al.*, 2011; Karmakar *et al.*, 2008; Khandoker *et al.*, 2008b, 2009a; Tagluk *et al.*, 2010). Um fato interessante é que pessoas com AHI mais alto tem uma probabilidade maior de morte (Marshall *et al.*, 2008).

A PSG é um dos métodos tradicionais e mais utilizados na avaliação da apneia, e será descrita na próxima seção.

## 4.2 A Polissonografia

A PSG é um exame médico composto por sinais bio-médicos, como eletroencefalograma (EEG), eletrocardiograma (ECG), eletro-ocu-lagrama (EOG), eletro-miograma (EMG), oximetria, esforço respiratório, e algumas vezes, registro da posição corporal (Chokroverty & Thomas, 2013; de Chazal *et al.*, 2004; Epstein *et al.*, 2009; Ronzhina *et al.*, 2012; Várady *et al.*, 2002). Este reúne uma série de informações que permite monitorar o indivíduo, possibilitando inferir sobre a fase do sono (REM e NREM), posição do corpo (dorsal, ventral ou lateral), além de eventos envolvidos com a interrupção da respiração, entre outros.




Figura 4.1: PSG de paciente com Apneia Obstrutiva. Fonte: Kryger (2010).

A Figura 4.1 exemplifica um conjunto de 16 sinais obtidos a partir de uma PSG, proveniente de um paciente portador de apneia obstrutiva, retirado de Kryger (2010). Os sinais presentes na figura acima são, de cima para baixo: 1. movimento do maxilar, 2-6. EEG, 7. ECG, 8. movimento da perna, 9. saturação do oxigênio no sangue ( $SpO_2$ ), 10-11. esforço respiratório torácico e abdominal, 12. pulso, 13. gasometria arterial, ou seja, pressão parcial de  $CO_2$  no sangue, 14. posição, 15. Pressão Positiva Contínua nas Vias Aéreas (CPAP), que indica o funcionamento do dispositivo para regular a respiração em portadores de apneia, e 16. fluxo de ar.

Com objetivo de realizar a classificação automática de padrões, é necessário proceder com a extração de características representativas do sinal. Para tanto, é interessante conhecer um pouco sobre o procedimento de coleta e informações contidas na PSG. Neste trabalho trataremos apenas de alguns destes sinais, descritos nas subseções seguintes.

### 4.2.1 Eletrocardiograma

A PSG normalmente inclui um único sinal de ECG (análogo ao sinal 7 da Figura 4.1), em que um eletrodo é colocado sobre o esterno e outro, na lateral do peito (Chokroverty & Thomas, 2013). Durante o ciclo respiratório, os eletrodos responsáveis pela captação dos sinais do ECG são influenciados pelo movimento do coração e dos pulmões. Guilleminault *et al.* (1984) encontraram uma correlação entre a apneia e a variação cíclica da frequência cardíaca, em que o esforço respiratório dá origem a uma redução dos batimentos, bradicardia, seguida por um acréscimo dos batimentos, taquicardia. Este fenômeno é conhecido como padrão bradi-taquicardia (Guilleminault *et al.*, 1984; Khandoker *et al.*, 2009a,b, 2011; Hilton *et al.*, 1999; Mendez *et al.*, 2009; Mietus *et al.*, 2000; Penzel *et al.*, 2002). Esta descoberta propiciou estudos em diagnóstico da apneia utilizando, em alguns casos, apenas o ECG.

Estudos mostraram, ainda, que parâmetros baseados nos complexos QRS (definido a seguir) e na amplitude do ECG podem ser úteis na classificação da apneia (de Chazal *et al.*, 2002a; Khandoker *et al.*, 2008b; Mendez *et al.*, 2009, 2010).





Figura 4.2: Segmento de ECG apresentando um complexo QRS.

A Figura 4.2 apresenta um segmento de ECG que ilustra a estrutura de um complexo QRS, o qual é composto por: **onda P**, gerada pela despolarização

e contração atrial; complexo **QRS**, onde ocorre a despolarização dos ventrículos antes da contração; **onda Q**: deflexão negativa, **onda R**: deflexão positiva, **onda S**: deflexão negativa que segue a onda R; **onda T**, que possui uma duração maior que o complexo QRS, pois a repolarização ventricular é um processo mais lento que a despolarização (Rani *et al.*, 2015; Yildiz *et al.*, 2011).



(a)



(b)

Figura 4.3: (a) Intervalo entre batimentos cardíacos (RR), baseado em Mendez *et al.* (2009); (b) Padrão bradi-taquicardia.

Outro fator que pode ser utilizado para avaliação do ECG é o intervalo RR (intervalo entre batimentos cardíacos), ilustrado na Figura 4.3(a), presente no padrão bradi-taquicardia (Figura 4.3(b)), descrito anteriormente (Brown *et al.*, 1993; Khandoker *et al.*, 2009b; Lado *et al.*, 2011; Mendez *et al.*, 2009, 2010). Este parâmetro é calculado através da medida do intervalo entre dois batimentos consecutivos, que são mensurados do início da onda R do complexo QRS até a subsequente onda R. Nada impede que a medição seja realizada em outra onda, mas como a R

é a mais evidente, reduz o risco relacionado a erros no reconhecimento do complexo QRS.

#### 4.2.2 Oximetria

O Oxímetro é um dispositivo externo que é preso ao dedo, e estima a saturação de oxigênio nas hemoglobinas do paciente, gerando o sinal  $SpO_2$  na PSG - análogo ao sinal 9 da Figura 4.1 (Chokroverty & Thomas, 2013; Spriggs, 2014). Este é um parâmetro fundamental, uma vez que evidencia disfunções respiratórias e a respectiva severidade.

Os valores padrão para a oximetria de um indivíduo saudável são superiores a 90%, podendo chegar a níveis inferiores a 70% em eventos de apneia (Flemons & McNicholas, 1997). Desta forma, o grau de saturação do oxigênio é significativo para avaliar eventos de apneia e de hipopneia, uma vez que durante os eventos há decréscimo de 2 a 4% no nível de oxigênio no sangue (Álvarez-Estévez & Moret-Bonillo, 2009; Chokroverty & Thomas, 2013). A Figura 4.4 ilustra o sinal em um intervalo de 1 minuto referente ao banco de dados UCDDDB (2008).





Figura 4.4: Saturação de oxigênio no sangue ( $SpO_2$ ) no intervalo de 1 minuto, em um segmento retirado de PSG do banco de dados UCDDDB (2008).

No caso da apneia e hipopneia obstrutiva, este sinal seria suficiente para obter características para detecção do evento; entretanto, para a apneia central e para a mista, é necessário analisar alguns outros sinais, como o esforço respiratório.


### 4.2.3 Fluxo e Esforço Respiratório

O fluxo respiratório é medido por dispositivos, como o transdutor de pressão, os termistores, ou os termopares, e representado na PSG como o sinal 16 da Figura 4.1. A mensuração pode ser feita pelo volume de ar expirado ou, também, através da mudança de temperatura (Chokroverty & Thomas, 2013; Spriggs, 2014).

Já o esforço respiratório, sinais 10 e 11 da Figura 4.1, é monitorado por cintas que circundam o peito, e em algumas vezes o abdômen do paciente, consistindo em uma estrutura elástica que se expande com o movimento de inspiração e expiração (Chokroverty & Thomas, 2013; Spriggs, 2014). Este parâmetro é tradicionalmente mais qualitativo que quantitativo, uma vez que só evidencia que há ou não esforço respiratório, não indicando a força realizada pelo indivíduo; equipamentos mais modernos já conseguem indicar o esforço respiratório quantitativamente, mas o uso ainda não está difundido.



(a)



(b)

Figura 4.5: Segmento representando: (a) Fluxo Respiratório e (b) Esforço Respiratório, de PSG do banco de dados UCDDDB (2008).

A Figura 4.5(a) exemplifica sinais de fluxo respiratório, apresentando um decréscimo na parte central do intervalo. Já a Figura 4.5(b) mostra um esforço constante de respiração do indivíduo. Os dois sinais são retirados do banco de dados UCDDDB (2008).

### 4.3 Classificação dos Dados

O sinal biomédico, quando obtido originalmente, possui vários ruídos provenientes do equipamento. Em sinais biomédicos é necessário lidar com outros fatores que influem na coleta do sinal: a movimentação corporal e a respiração podem causar interferência em sinais como o EEG, ECG, esforço respiratório, entre outros. Por isso, a primeira etapa a ser realizada é a de reduzir tanto quanto possível os ruídos das interferências do meio através do pré-processamento. Em alguns sinais é desejável realizar padronização, de modo a possibilitar a comparação dos sinais entre os pacientes.

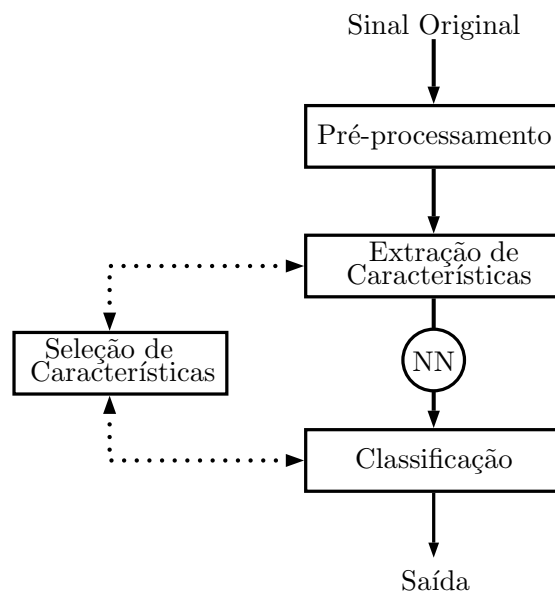


Figura 4.6: Procedimento utilizado no processamento de sinais.

A Figura 4.6 ilustra as etapas de processamento de um sinal. Após o pré-processamento, é realizada a extração de características, que descrevem médias, amplitudes, oscilações, distância entre picos (Subseção 4.3.2). Uma vez escolhido um conjunto de características, é utilizada a NN para o treinamento e a avaliação da acurácia do reconhecimento de padrões. Caso o resultado não seja satisfatório, é possível fazer uma seleção dentre as características escolhidas ou entre outras, visando a melhoria do modelo. Note que a cada modificação no conjunto de características, é necessário realizar um novo treinamento e, conseqüentemente, uma nova avaliação da acurácia obtida a partir do reconhecimento de padrões. Por isso, esta etapa é uma das mais importantes, sendo responsável pela precisão dos resultados. Nesta seção serão discutidas as etapas de pré-processamento, extração de características e classificação utilizadas no presente trabalho.

### 4.3.1 Pré-processamento

Os sinais biomédicos são únicos e possuem variações de um indivíduo para outro e, por isso, o pré-processamento é uma fase fundamental da análise. Neste processo, ocorre o tratamento dos dados originais para que seja possível tornar os sinais comparáveis e com isso, o reconhecimento de padrões mais fácil, e, também, a obtenção de resultados mais precisos com a TW e a NN (Bishop, 2006; Übeyli, 2009; Várady *et al.*, 2002).

Diferentes sinais necessitam diferentes tipos de pré-processamento. No caso do ECG, é possível verificar que a amplitude e a média são diferentes entre pacientes. O objetivo da padronização é reduzir a variabilidade dos dados (Bishop, 2006; Haykin, 1999, 2009), conforme descrito a seguir. Sendo  $x(t)$  o sinal original do ECG, cuja distribuição tem média  $\bar{x}(t)$  e desvio padrão  $\sigma$ , o processo de padronização é dado por (Fitz-Gibbon & Morris, 1987; Khandoker *et al.*, 2009a)

$$\tilde{x}(t) = \frac{x(t) - \bar{x}(t)}{\sigma}, \quad (4.1)$$



de modo que  $\tilde{x}(t)$  tenha uma Distribuição Normal Padrão, isto é,  $\tilde{x}(t) \sim N(0,1)$ . Desta forma, é possível garantir a representatividade da variabilidade do sinal em relação à média (Haykin, 1999, 2009), ou seja, independente da variância do sinal de um indivíduo, quando padronizado, é possível encontrar medidas comparáveis entre eles.




Figura 4.7: Segmento de 60 segundos de ECG do banco de dados UCDDB (2008): em azul contínuo, sinal original e, em vermelho tracejado, o sinal pré-processado.

A curva azul contínua da Figura 4.7 é um segmento de 60 segundos de um ECG, como o sinal da Figura 4.1; este é o sinal original que após pré-processado, leva ao sinal padronizado (curva vermelha tracejada), cuja amplitude tem distribuição normal padrão, e onde algumas características tornam-se mais claras. Note que mesmo pequenas alterações no complexo QRS do sinal original podem ser visualizados mais facilmente no sinal processado.

Para a oximetria, o pré-processamento envolve a exclusão de dados resultantes de falhas na obtenção do sinal, que geram picos. A ferramenta normalmente utilizada para eliminação de dados degenerados, ou erros de coleta, é o filtro de média (Ahmad & Sundararajan, 1987; Chen *et al.*, 2015; de Chazal *et al.*, 2004; Khandoker *et al.*, 2009a; Mietus *et al.*, 2000). Esse processo é realizado iterativamente, eliminando valores destoantes em um determinado segmento através da comparação entre valores vizinhos.

A Figura 4.8 é um segmento de  $\text{SpO}_2$  do mesmo estudo utilizado na Figura 4.7, onde a Figura 4.8(a) representa o sinal original e a Figura 4.8(b), o sinal obtido através do filtro de média; neste observa-se que o ruído ficou reduzido,

e assim minimizando o número de picos os quais posteriormente poderiam trazer maior complexidade à classificação.




Figura 4.8: Saturação de oxigênio  $SpO_2$ : (a) original e (b) com filtro de média, do segmento retirado de PSG do banco de dados UCDDDB (2008).

Tanto no processo de padronização, quando no filtro de média, é preciso tomar cuidado pois, muitas vezes, o pré-processamento pode eliminar informações de grande relevância para o problema, reduzindo a precisão do resultado (Bishop, 2006). Ressalta-se ainda a importância de realizar o mesmo pré-processamento nos dados de treinamento e nos que serão avaliados pela NN (Bishop, 2006; Haykin, 1999, 2009), buscando sempre formas de comparações apropriadas entre os sinais dos diversos indivíduos.

### 4.3.2 Extração de Características

As características dos sinais podem ser descritas através de parâmetros que englobam várias informações, permitindo evidenciar comportamentos (Hazarika *et al.*, 1997). Muitos destes parâmetros podem ser úteis no reconhecimento de padrões de apneia, mas muitas vezes é difícil determinar qual característica possui maior correlação com a enfermidade, sendo necessário utilizar um conjunto de características maiores para posterior redução (Flemons & McNicholas, 1997).

Nesta subseção serão descritos parâmetros utilizados na análise e na construção do modelo para cada um dos sinais e, no capítulo seguinte, serão apre-

sentados os resultados. Para a análise do ECG, serão utilizada a TW (Capítulo 2), com a finalidade de verificar o comportamento de diversas bandas de frequência (Khandoker *et al.*, 2009a,b; Rani *et al.*, 2015; Saminu *et al.*, 2014; Übeyli, 2008). A decomposição permite a construção de um vetor com as características mais relevantes para cada uma das frequências da decomposição, aumentando a eficiência da classificação em relação à análise do sinal original (Avci *et al.*, 2005; Inan *et al.*, 2006). Além disso, com menos dados a serem analisados pela NN, obtém-se um ganho devido à redução no tempo computacional em relação à análise de todos os dados do sinal original.

Alguns elementos são, normalmente, utilizados para análise de cada conjunto de coeficientes que compõem cada nível da decomposição (Chen & Pavlidis, 1979; Erazo & Ríos, 2014; Haralick *et al.*, 1973; Hassan, 2015; Khandoker *et al.*, 2009a; Ronzhina *et al.*, 2012; Saminu *et al.*, 2014; Übeyli, 2008, 2009). Seja  $\tilde{x}_n(t)$  um segmento do sinal padronizado, de tamanho  $N$ , e define-se sobre este segmento:

$$\begin{aligned}
\text{Média: } \mu_n &= \frac{1}{N} \sum_{i=1}^N \tilde{x}_{n_i}(t), \\
\text{Desvio Padrão: } \sigma_n &= \sqrt{\frac{1}{N} \sum_{i=1}^N (\tilde{x}_{n_i}(t) - \mu_n)^2}, \\
\text{Entropia: } E_n &= - \sum_{i=1}^N \tilde{x}_{n_i}(t) \log(\tilde{x}_{n_i}(t)), \\
\text{Assimetria: } \alpha_n &= \frac{1}{n} \sum_{i=1}^N \frac{(\tilde{x}_{n_i}(t) - \mu_n)^3}{\sigma_n^3} \\
\text{Curtose: } \kappa_n &= \frac{1}{n} \sum_{i=1}^N \frac{(\tilde{x}_{n_i}(t) - \mu_n)^4}{\sigma_n^4}.
\end{aligned} \tag{4.2}$$

Para cada conjunto de dados  $\tilde{x}_n(t)$  do ECG, são realizadas 8 níveis de decomposição e as estatísticas descritas na Equação (4.2) são calculadas sobre o sinal original padronizado e as decomposições, baseado no modelo proposto por Khandoker *et al.* (2009a). Portanto, são gerados 45 parâmetros ( $9 \times 5$ ) que alimentarão a NN. Similarmente, o fluxo e o esforço respiratório podem ser descritos pela decomposição

do sinal, em que, por sua vez, são realizadas 7 níveis de decomposição, conforme desenvolvido por Tagluk *et al.* (2010), e similarmente ao que foi usado para o ECG, resultará em 40 parâmetros ( $8 \times 5$ ) para cada intervalo analisado (Erazo & Ríos, 2014; Tagluk *et al.*, 2010).

Quanto ao padrão de bradi-taquicardia, este pode ser descrito pelo intervalo RR, da Figura 4.3(b), cujos parâmetros selecionados determinam: o número de picos, a distância entre picos (Chen *et al.*, 2015; Hilton *et al.*, 1999; Mendez *et al.*, 2009, 2010; Mietus *et al.*, 2000), a média, o desvio padrão e a amplitude do pico (de Chazal *et al.*, 2002a, 2004, 2015; Mietus *et al.*, 2000). Estes parâmetros foram selecionados para testes pois, além de apresentarem bons resultados na literatura, possuem fácil implementação.

Um último conjunto de características é adotado para a saturação de oxigênio no sangue ( $SpO_2$ ). Dentre os parâmetros apresentados na literatura, foram selecionados aqueles que parecem melhor representar o sinal em um intervalo de tempo, os quais: média e valor mínimo, o número de vezes em que a saturação foi menor que 92%, média da variação em valores absolutos, e, por último, a variação da saturação em relação a média do sinal (Erazo & Ríos, 2014; de Chazal *et al.*, 2015).

A Tabela 4.1 resume o que foi discutido nesta seção, contendo o conjunto de características para análise do ECG,  $SpO_2$ , Fluxo Respiratório e Esforço Respiratório.

Tabela 4.1: Resumo de Características para 4 sinais distintos de uma PSG.

ECG		SpO <sub>2</sub>	Fluxo Respiratório	Esforço Respiratório
A partir dos Coeficientes da TW em cada decomposição:	Média Desvio Padrão Entropia Curtose Assimetria	Média Valor Mínimo Número de SpO <sub>2</sub> < 92% Média da variação em valores absolutos Número de SpO <sub>2</sub> -Média(SpO <sub>2</sub> ) > 3% Número de SpO <sub>2</sub> -Média(SpO <sub>2</sub> ) < -3%	A partir dos Coeficientes da TW em cada decomposição: Média Desvio Padrão Entropia Curtose Assimetria	A partir dos Coeficientes da TW em cada decomposição: Média Desvio Padrão Entropia Curtose Assimetria
Do Intervalo RR:	Número de ondas R Amplitude média das ondas R Média Desvio Padrão			

### 4.3.3 Treinamento e Classificação

Nesta etapa serão relacionados os conceitos apresentados no Capítulo 3 sobre as NN com o conjunto de características obtido, estabelecido acima. A fim de realizar a classificação do sinal, é necessário particionar os dados em intervalos que possam caracterizar um evento de apneia ou um evento de não apneia, os quais normalmente não ultrapassam 60 segundos (de Chazal *et al.*, 2002a, 2004, 2015; Fontenla-Romero *et al.*, 2005; Khandoker *et al.*, 2009a,b, 2011; Mendez *et al.*, 2009; Tagluk *et al.*, 2010; Várady *et al.*, 2002). Então, para o treinamento de um conjunto de dados  $i$  cuja classificação é conhecida, tem-se um vetor de características  $\zeta_i$  de tamanho  $V$ , e um vetor de classificação,  $\tau_i$ , de tamanho 2, onde

$$\tau_i = \begin{cases} [1,0]^T, & \text{se o intervalo não representar uma apneia,} \\ [0,1]^T, & \text{se o intervalo representar uma apneia.} \end{cases} \quad (4.3)$$

Os dados  $(\zeta, \tau)$  formam o conjunto de treino, em que o padrão é aprendido pela NN utilizando o algoritmo de aprendizagem descrito na subseção 3.3.1.

Para avaliar o resultado do treinamento, e garantir que não haja *overfitting*, é utilizado o método de validação cruzada, mais especificamente o *leave-one-out*. Considere um conjunto de  $N$  pacientes, onde os dados dos  $N - 1$  pacientes são utilizados para o treinamento; para garantir um teste independente, o  $N$ -ésimo paciente é classificado com a NN proveniente do treinamento dos demais pacientes (de Chazal *et al.*, 2002a; Khandoker *et al.*, 2009a).

A performance do diagnóstico é dada pelo número de eventos classificados corretamente pelo algoritmo, isto é, que estão de acordo com a classificação do especialista, como será explanado na Seção 5.1. A sensibilidade, a especificidade

e a acurácia são medidas de precisão do algoritmo e são dadas por

$$\boxed{\text{Sensibilidade}} = \frac{TP}{TP + FN}, \quad (4.4)$$

$$\boxed{\text{Especificidade}} = \frac{TN}{TN + FP}, \quad (4.5)$$

$$\boxed{\text{Acurácia}} = \frac{TP + TN}{TP + FP + TN + FN}, \quad (4.6)$$

onde  $TP$  e  $TN$  descrevem o diagnóstico correto da apneia e da não apneia, respectivamente; por sua vez,  $FP$  e  $FN$ , o diagnóstico incorreto da apneia e da não apneia. Enquanto a especificidade é responsável pelo indicativo de quantos reconhecimentos de padrões de não apneia foram realizados corretamente, a sensibilidade indica qual o percentual de apneias e hipopneias que foram devidamente classificados.

Embora a acurácia seja uma medida de desempenho geral da classificação, esta estatística apenas não é suficiente para constatar que determinado teste tem resultado satisfatório. Como a acurácia considera todos os resultados corretos igualmente, é necessário incluir a análise da sensibilidade e da especificidade. Estas três estatísticas, quando utilizadas conjuntamente, permitem determinar melhorias potenciais no algoritmo, isto é, quando a especificidade é baixa, deve-se concentrar esforços sobre a detecção dos eventos que não contém apneia, e, da mesma forma, quando a sensibilidade é baixa, deve-se concentrar esforços para melhorar a detecção de eventos apneicos.

## 5 IMPLEMENTAÇÃO E RESULTADOS

Neste capítulo aplicaremos as diversas etapas para detecção da apneia descritas na Figura 4.6 para o ECG, SpO<sub>2</sub>, Fluxo e Esforço Respiratório das PSGs do banco de dados UCDDDB (2008), como definidas no Capítulo 4. A implementação será realizada em MATLAB, versão R2012b, através dos pacotes *Wavelet Toolbox*, para a decomposição do sinal usando a TW, e *Neural Network Toolbox*, para a NN. Quanto à configuração dos computadores, utilizamos a infraestrutura do Laboratório Integrado de Computação Científica (LICC, PPGMAp-UFRGS), com distribuição Linux Gentoo e equipado com processador Intel Core i7-4820, com frequência de 3,7 GHz e 4 GB de RAM.

Enfatizamos a troca do sujeito neste capítulo, do impessoal para o pessoal, com a finalidade de apropriação do trabalho realizado e, também, para evidenciar o que foi feito por nós. Este capítulo está dividido da seguinte forma: na Seção 5.1 apresentaremos o conjunto de PSGs que serão analisados e, após uma breve explicação, na Seção 5.2, sobre o funcionamento dos pacotes do MATLAB que utilizamos, dedicamos a Seção 5.3 para a apresentação dos resultados que obtivemos, de acordo com o conjunto de características descritas na Subseção 4.3.2.

### 5.1 Caracterização da Base de Dados

A base de dados UCDDDB (2008) é composta por 25 PSGs, cujos indivíduos eram pacientes do *St Vincent's University Hospital*, Dublin, com suspeita de Distúrbio Respiratório do Sono (SDB) (Goldberger *et al.*, 2000; UCDDDB, 2008). Os pacientes cujos PSGs integram o banco de dados possuem entre 28 e 68 anos, sendo 4 mulheres e 21 homens e, em média, acima do peso ideal<sup>1</sup>, conforme Ta-

---

<sup>1</sup>O IMC Índice de Massa Corporal (IMC) considerado saudável está entre 18,5 e 25 (Gallagher *et al.*, 2000).



bela 5.1. Além disso, nenhum dos pacientes possui doenças cardíacas conhecidas, disfunção autonômica, que causa redução do fluxo sanguíneo nos tecidos muscular e conjuntivo, e também não é administrado medicamentos que interfiram na frequência cardíaca. Outras informações sobre os pacientes podem ser encontradas no Apêndice A.

Tabela 5.1: Idade, IMC e AHI das PSGs analisadas.

Idade			IMC			AHI		
Média	Mínima	Máximo	Médio	Mínimo	Máximo	Médio	Mínimo	Máximo
50	28	68	31,6	25,1	42,5	24,24	2	91

As PSGs foram realizadas no período da noite e com duração entre 5 e 8 horas, obtidas utilizando o sistema Jaeger-Roennies, e registrando: EEG, EOG, EMG, ECG, Fluxo Respiratório Nasal, Esforço Abdominal e da Caixa Torácica, Saturação do Oxigênio ( $SpO_2$ ), Ronco e Posição corporal. Os sinais foram armazenados no formato EDF (*European Data Format*), padrão para armazenamento de sinais médicos (UCDDB, 2008). A organização dos dados é mostrada na Tabela 5.2.

Tabela 5.2: Organização da PSG.

Sinal	Taxa de Amostragem	Mínimo	Máximo	Unidade
EOG - Olho esquerdo	64 Hz	0	1	mV
EOG - Olho direito	64 Hz	0	1	mV
EMG	64 Hz	0	1	mV
EEG: C3-A2	128 Hz	0	1	mV
EEG: C4-A1	128 Hz	0	1	mV
ECG	128 Hz	0	1	mV
$SpO_2$	8 Hz	0	97	n/a
Som	8 Hz	-1	1	n/a
Fluxo Respiratório	8 Hz	-5	5	$L \cdot min^{-1}$
EMG Submentoniano	8 Hz	-1	1	n/a
Esforço Respiratório - Tórax	8 Hz	-1	1	n/a
Esforço Respiratório - Abdômen	8 Hz	-1	1	n/a
Posição Corporal	8 Hz	1	4	n/a
Pulso	8 Hz	0	80	$min^{-1}$

Unidades: mV (milivolts),  $L \cdot min^{-1}$  (litros por minuto), n/a (não aplicável).

Todas as 25 PSGs foram avaliadas por um especialista, e armazenadas em arquivos de anotação em formato “.txt”, assim como exemplificamos na Figura 5.1. Cada evento foi classificado como apneia (APNEA) e hipopneia (HYP), e além disso, foi identificada a sua natureza (central, C, obstrutiva, O, ou mista, M). A inscrição Type PB/CS refere-se à *Periodic Breathing* ou *Cheyne-Stokes Respiration*, que caracterizam padrões de respiração em eventos de apneia. Ainda que disponível para fins de classificação, apneia e hipopneia serão tratados como apneia apenas. Também não serão consideradas as classificações de natureza neste momento.

Respiratory Event List									
Time	Respiratory Event			Desaturation		Snore Arousal		B/T	
	Type	PB/CS	Duration	Low	%Drop			Rate	Change
00:29:13	HYP-C		16	89.9	4.1	-	-	64.7	-5.7
01:35:47	HYP-O		22	88.1	5.9	-	+	63	-4.1
01:40:48	APNEA-O		15	90.8	5.2	-	-	66.9	-7.1
02:02:25	HYP-C		13			-	-		
02:49:44	HYP-M		21	90.8	5.2	-	+	65.1	-9.4
02:59:17	APNEA-M		22	91	5.1	-	+	69	-15.7
03:58:10	APNEA-C		14	90.6	6	-	-	65.3	-12.4

Figura 5.1: Exemplo de anotações da PSG, retirado de UCDDDB (2008).

Após a realização do pré-processamento, como descrito na Subseção 4.3.1, segmentamos cada PSG em intervalos de *um minuto*, e então realizamos o cálculo das características, sintetizadas na Tabela 4.1. O processo de extração de características dá origem a duas matrizes, uma com os dados de entrada (*Input*) da NN e outra com a classificação (*Target*), como o exemplo ilustrado na Figura 5.2 para um sinal de duração de 7 minutos, onde cada coluna das matrizes corresponde a 1 minuto.

```

Input=[ 63.0000    64.0000    70.0000    60.0000    62.0000    62.0000    61.0000;
        122.8548  120.4127  108.9710  127.5763  124.1967  123.6230  126.2333;
        15.1299   14.3467   16.0550   10.3511   16.0227    6.6712    7.8856]

Target=[ 0          0          1          1          1          1          1;
         1          1          0          0          0          0          0];

```

Figura 5.2: Exemplo de dados de entrada (*Input*) e da classificação (*Target*) para um sinal constituído por 7 intervalos de um minuto cada, utilizando três características do Intervalo RR: o número de ondas R, a amplitude média das ondas R e a média do Intervalo R.

A matriz *Input*, da Figura 5.2, exemplifica que a matriz para um intervalo de 7 minutos possui 7 colunas e três características que escolhemos arbitrariamente, exemplificadas por características do Intervalo RR no ECG: o número de ondas R, a amplitude média das ondas R e a média do Intervalo R. Se escolhêssemos características a partir dos coeficientes da TW, obteríamos outra matriz de *Input*. Note ainda que cada matriz é escrita entre colchetes e cada linha possui término no ponto e vírgula, como na sintaxe do MATLAB.

Da mesma forma que a anterior, a matriz *Target* possui 7 colunas com a classificação, a coluna  $[0,1]^T$  indica a presença de apneia e, para  $[1,0]^T$ , a ausência de apneia no intervalo. Note que os eventos descritos pela matriz *Target* são exclusivos, isto é, se na primeira linha é atribuído o valor 1, a segunda linha receberá, necessariamente, o valor 0, e vice-versa. Na Figura 5.2, as duas primeiras colunas representam apneias, e os demais são classificados como padrões normais de sono.

A forma de geração e utilização destas duas matrizes, no MATLAB, será apresentada na próxima seção.

## 5.2 Implementação no MATLAB

O algoritmo para análise e classificação dos sinais da PSG que analisamos (ver Tabela 4.1) foi implementado em MATLAB, e nesta seção descreveremos alguns detalhes dos pacotes *Wavelet Toolbox* e *Neural Network Toolbox* que utilizamos no estudo.

### 5.2.1 Wavelet Toolbox

O pacote *Wavelet Toolbox* disponibiliza funções e um aplicativo baseado na teoria das wavelets que possibilita a decomposição, bem como a síntese, a retirada de ruídos e a compressão de imagens e de sinais. Os sinais que utilizamos constituem dados de entrada  $X$ , onde é necessário realizar a transformação do arquivo de sinais do formato EDF para o “.mat” pelo MATLAB. Uma vez que escolhemos a família de wavelets específicas, **wname** com  $N$  decomposições, utilizamos a função **wavedec**, que compõe este pacote, e cuja sintaxe é dada por  $[C,L]=\text{wavedec}(X,N,'wname')$ . Esta função nos fornecerá as saídas  $C$ , que são os coeficientes  $cA_n$  (similarmente à aproximação  $f_m(t)$  na Equação (2.25)) ou  $cD_n$  (como  $d_m$  da Equação (2.27)), e  $L$  é o tamanho do vetor de coeficientes,  $\#cA_n$  e  $\#cD_n$ . A decomposição é ilustrada conforme a Figura 5.3, semelhante à Figura 2.8, para uma decomposição em 3 níveis.

Neste trabalho optamos pela wavelet Daubechies de ordem 4, no MATLAB 'db4', discutida na Subseção 2.4.2, após termos feito implementações com outras wavelets (Haar; Daubechies 2,6,8; Coiflets 1,2,4,5; Symlet 1,3,6; Biortogonal 1.5, 2.4, 3.5, 4.4, 5.5, 6.8; e Meyer), e verificando que a *db4* reproduzia melhor os resultados da literatura (Erazo & Ríos, 2014; Saminu *et al.*, 2014; Übeyli, 2009).

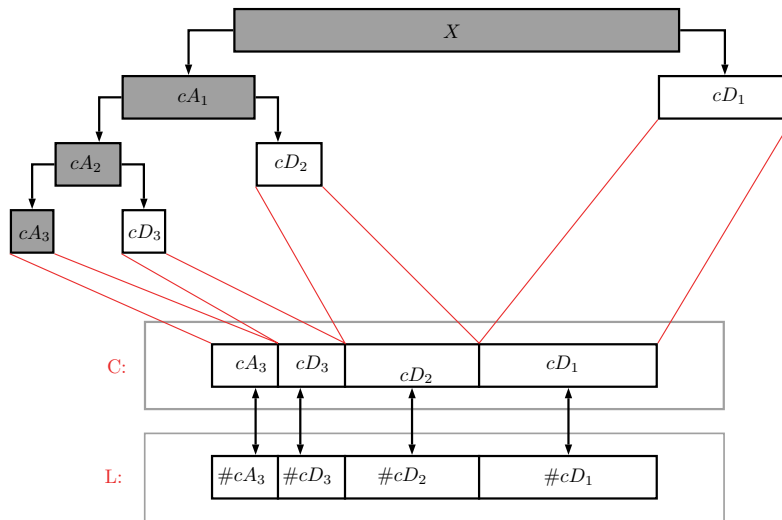


Figura 5.3: Estrutura de decomposição realizada pelo MATLAB.

A Figura 5.4 apresenta um exemplo utilizando um fragmento de ECG, do banco de dados UCDDDB (2008), empregando a Daubechies de ordem 4 com três decomposições, obtidas com o comando `[C,L]=wavedec(X,3,'db4')` do MATLAB. Observe que as decomposições na Figura 5.4(b) estão representadas por:  $cA_3$  em azul,  $cD_3$  em vermelho,  $cD_2$  em roxo, e  $cD_1$  em verde.




Figura 5.4: Decomposição do ECG com Daubechies 4 com MATLAB (intervalo de 10 segundos, com 1280 observações representadas nos eixos horizontais): (a) ECG original, mensurado em  $mV$ , (b) Coeficientes das 3 decomposições, diferenciadas por cores, a saber:  $cA_3$  em azul,  $cD_3$  em vermelho,  $cD_2$  em roxo, e  $cD_1$  em verde.

Após o procedimento de decomposição, são calculadas as estatísticas relacionadas ao sinal original, conforme Equação (4.2), para o sinal original, para os coeficientes de aproximação (da Figura 5.4,  $cA_n$ ) e para os coeficientes de detalhes ( $cD_n$ ). Este novo vetor será a entrada da NN, cujo pacote será descrito na próxima subseção.

### 5.2.2 Neural Network Toolbox

O pacote *Neural Network Toolbox* é um conjunto de funções e aplicativos utilizados como ferramentas de aprendizagem supervisionada e não supervisionada, tal como descrito no Capítulo 3. Entre os aplicativos disponíveis, temos o ajuste de dados, o reconhecimento de padrões, o agrupamento de dados (*clustering*), a

predição de séries temporais e a modelagem de sistemas dinâmicos. Uma visão geral do aplicativo de Reconhecimento de Padrões é ilustrado no Apêndice B.

Os dados, dispostos na matriz *Input*, como mostradas na Figura 5.2, são utilizadas para o treinamento da NN, cujo objetivo é a geração de uma matriz de mesmo tamanho da *Target* (Figura 5.5). Essa nova matriz, *Output*, será utilizada para comparação com a classificação fornecida ao software (Figura B.2) e propiciará a geração da matriz de confusão (Figura B.7), onde são obtidas estatísticas de precisão do resultado (Equações (4.4),(4.5) e (4.6)). Adotamos a função sigmoide para a função de ativação, Equação (3.4), o que gera valores no intervalo (0,1) para a matriz *Output*, como ilustrado na figura abaixo.

```
Output = [ 0.8892    0.9034    0.3683    0.6191    0.6883    0.8250;
           0.1156    0.1021    0.6295    0.3745    0.3056    0.1765];

Target = [    1        1        0        0        1        1;
           0        0        1        1        0        0];
```

Figura 5.5: Exemplo de saída da NN para um intervalo de 6 minutos.

O treinamento e a classificação foram realizados usando o teste *leave-one-out*, descrito na Subseção 4.3.3. Para as 25 PSGs, foram realizados testes para 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios. A verificação do número de neurônios necessários é determinado experimentalmente, uma vez que não existe uma forma de calcular o número ótimo. Note que, enquanto um problema mais complexo precisa de um número maior de neurônios para gerar uma NN que descreva adequadamente o padrão desejado, problemas mais simples necessitam de poucos neurônios (Zhang & Rajapakse, 2009). Se o número de neurônios for inadequado, poderá incorrer em erros, onde um número muito grande de neurônios pode gerar *overfit*, e um número muito pequeno pode não ser suficiente para descrever o padrão. Os resultados de

acurácia foram representados com o uso de diagrama de caixas, como será discutido na próxima subseção.

### 5.2.3 Representação Gráfica

O diagrama de caixas é um gráfico que expressa a distribuição dos dados, tornando possível comparar conjuntos de dados. No caso da acurácia, seguimos os moldes apresentados por Fontenla-Romero *et al.* (2005), Gubbi *et al.* (2012) e Khandoker *et al.* (2009a) para a comparação dos testes com diversos números de neurônios. O gráfico foi gerado com o MATLAB, através da função `boxplot`, incorporando informações adicionais que tornam mais fácil a análise da acurácia, como ilustrado na Figura 5.6.




Figura 5.6: Diagrama de Caixas: modelo.

Em cada caixa estão representadas a maior parte dos dados<sup>2</sup>, e o restante dos dados é representado pelas linhas tracejadas, com exceção do círculo isolado que representa os *outliers* (valores destoantes dos demais, que podem indicar um erro experimental). Os segmentos em vermelho na caixa representam a mediana<sup>3</sup>, valor que separa o resultado das acurácias ao meio: 50% das acurácias está abaixo do valor representado pelo segmento em vermelho e, o restante, acima. Na Figura 5.6 visualizamos, ainda, o valor para as acurácias resultantes para cada treinamento e classificação, os quais representamos por pequenos círculos.

---

<sup>2</sup>As arestas da caixa demarcam o 25° e o 75° percentis.

<sup>3</sup>A mediana é representada pelo 50° percentil.






Figura 5.7: Esquematisação do resultado obtido para acurácia para cada número de neurônio no diagrama de caixas.

A Figura 5.7 ilustra um diagrama de caixas e os eixos. No eixo horizontal estão representadas as acurácias em valores entre 0 e 1, em taxa unitária, e no eixo vertical, o número de neurônios utilizado no teste. Observe que, em uma situação ideal, a caixa teria uma largura pequena, assim como o comprimento das linhas tracejadas, e estaria situada próxima ao 1, indicando que a classificação de dados independentes podem ser realizadas com um nível de precisão alto.

### 5.3 Resultados

Nesta seção serão apresentados resultados que obtivemos ao classificar os dados das 25 PSGs do banco de dados UCDDDB (2008), visando reconhecer apneia. Para tanto, utilizamos os pacotes do MATLAB descritos nas Subseções 5.2.1 e 5.2.2, assim como a representação gráfica, conforme a Subseção 5.2.3. Apresentaremos também a comparação dos nossos resultados com os seguintes estudos sobre reconhecimento da apneia:

- Khandoker *et al.* (2009a): classificação de 17 PSGs a partir do ECG do banco de dados do *Institute of Breathing and Sleep*, Austin Hospital na Austrália. A extração de características deu-se pela TW, utilizando wavelets da família Symlet, ordem 3, e a NN foi utilizada para a classificação, adotando-se o método *leave-one-out*.

- Xie & Minn (2012): classificação de 25 PSGs a partir do ECG e SpO<sub>2</sub> do banco de dados UCDDDB (2008). Os resultados foram obtidos com o método de aprendizagem *Supported Vector Machine* (SVM), adotando o método de validação cruzada da seguinte forma: divide-se o banco de dados em 10 conjuntos, onde 9 são utilizados para o treinamento e 1 para o teste. Ressalta-se que neste estudo não foi utilizado TW, nem NN.
- Erazo & Ríos (2014): classificação de 21 PSGs de crianças a partir do ECG, SpO<sub>2</sub> e Fluxo Respiratório do banco de dados obtidos pelo *Sleep Study Center* do *Clinical Hospital of Catholic Universidade of Chile*. Obteve resultados utilizando TW (Daubechies de ordem 4) e NNs, adotando o método de validação cruzada da seguinte forma: 70% dos dados são usados no treinamento, e os 30% restantes no teste.
- de Chazal *et al.* (2015): classificação de 25 PSGs a partir do ECG e SpO<sub>2</sub> do banco de dados UCDDDB (2008). A função discriminante logística foi utilizada na classificação, adotando-se o método *leave-one-out* para validação. Ressalta-se que neste estudo não foi utilizado TW, nem NN.

Note que a base de dados adotada por Xie & Minn (2012) e de Chazal *et al.* (2015) são as mesmas utilizadas na nossa investigação; entretanto, as técnicas e abordagens são diferentes. As comparações dos resultados obtidos com outros bancos de dados tem por objetivo analisar os resultados dos métodos ou abordagens adotadas.

Esta seção está organizada da seguinte forma: Subseção 5.3.1, resultados provenientes da análise do ECG; Subseção 5.3.2, da análise do SpO<sub>2</sub>; Subseção 5.3.3, da análise do Fluxo Respiratório; e por fim, Subseção 5.3.4, da análise do

Esforço Respiratório. Por fim, na Subseção 5.3.5, fazemos algumas algumas considerações sobre o cálculo do AHI.

### 5.3.1 Resultados: Eletrocardiograma

Como primeiro teste, desejamos verificar o quanto a classificação da apneia através dos **Intervalos RR** presentes no ECG é eficiente. A Figura 5.8 mostra, utilizando o diagrama de caixa (Seção 5.2.3), o resultado para a acurácia nas 25 PSGs, utilizando o método de validação cruzada *leave-one-out*, e diferentes valores para o número de neurônios.




Figura 5.8: Classificação através do Intervalo RR: resultado para a acurácia utilizando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios com o método *leave-one-out*.

Observamos, na Figura 5.8, que a mediana da acurácia se concentram abaixo dos 80% (isto é, 0,8) para todos os números de neurônios, com exceção do teste utilizando 5 neurônios, para o qual situa-se próximo a 0,81. Conforme são acrescentados neurônios à NN, a acurácia tende a diminuir, e aparentemente da mesma forma a variação da acurácia parece aumentar para números maiores de neurônios. Por exemplo, para 40 neurônios se estende desde valores maiores de 10% até 95% e mediana em torno dos 65%, enquanto para 5 neurônios, varia entre valores

próximos a 50 e 98%, com mediana com valor superior a 80%. Observamos, ainda, a presença de *outliers* com acurácia próxima a 10% para quase todos os testes com diferentes números de neurônios.

Tabela 5.3: Estatísticas para a classificação utilizando o intervalo RR para diversos números de neurônios (valores em %).

Neurônios	05	10	15	20	25	30	35	40	45	50
Sensibilidade	0,00	0,00	0,00	0,00	1,47	9,46	7,98	5,11	11,78	16,59
Especificidade	100	100	99,58	99,68	97,71	85,25	91,88	97,14	88,71	88,33
Acurácia	81,13	74,93	70,26	68,13	67,21	65,39	64,76	63,58	61,14	60,15
Erros de classificação	18,87	25,07	29,74	31,87	32,79	34,65	35,28	36,46	38,94	40,00

A Tabela 5.3 apresenta as estatísticas que descrevem o resultado da classificação da apneia para os diversos números de neurônios, onde para cada número de neurônio, apresentamos sensibilidade, especificidade, acurácia e a quantidade de erros de classificação. Os percentuais apresentados para cada uma das estatísticas são calculados através da média de todos os resultados dos 25 testes, desconsiderando *outliers*.

Primeiramente, vamos analisar a capacidade de classificação, que está relacionada com a quantidade de erros de classificação. Para o nosso melhor resultado, 5 neurônios, a NN consegue classificar mais de 80% de todos os intervalos e, destes, 81,13% corretamente. Quando usamos 50 neurônios, a NN consegue realizar a classificação de apenas 60% dos intervalos.

Enquanto a especificidade apresentou valores ideais para neurônios entre 5 e 25 neurônios (pelo menos 97%, em média), a sensibilidade mostra que a NN é incapaz de classificar a apneia a partir das características do Intervalo RR, cujo maior valor para a sensibilidade é de 16,59% para 50 neurônios. A partir das estatísticas concluímos que apenas a análise das características do intervalo RR parecem não ser bons candidatos para determinar a classificação da apneia.

Quando aplicada a **decomposição em 8 níveis através TW**, gerando as 45 características, obtivemos os resultados para a acurácia apresentados na Figura 5.9. Embora haja um conjunto de *outliers*, a acurácia ficou concentrada entre 70 e 80% na maioria dos casos. Os melhores resultados foram para 5 e 40 neurônios, com a mediana da acurácia em torno de 80%; além disso, o 25° percentil está acima de 65% e 75° percentil está abaixo de 85%, isto é, metade dos dados se concentram entre 65% e 85% para 5 e 40 neurônios. Observamos que, quanto a NN é construída com 30 neurônios, obtivemos uma acurácia similar à NN com 5 e 40 neurônios, apresentando uma variabilidade maior em relação às anteriores, entre 60 e 80%. Além disso, exceto pelos *outliers*, grande parte das NNs com diferentes números de neurônios alcançou acurácia superior a 50%.




Figura 5.9: Classificação através da TW: resultado para a acurácia dos testes utilizando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios com o método *leave-one-out*.

Na Tabela 5.4 são apresentadas as estatísticas relacionadas com o desempenho do reconhecimento dos padrões realizado pela NN.

Note que, segundo a Tabela 5.4, houve um decréscimo no número de amostras não classificadas corretamente em comparação com o Intervalo RR, cujo maior valor é de 28,33% para 15 neurônios. Para os melhores resultados em acurácia, os números de amostras não classificadas corretamente foram os menores: 21,24% para 5 neurônios, 20,16% para 30 neurônios e 19,60% para 40 neurônios; ainda

Tabela 5.4: Estatísticas para a classificação utilizando a TW para diversos números de neurônios (valores em %).

Neurônios	05	10	15	20	25	30	35	40	45	50
Sensibilidade	0,00	0,31	0,00	0,23	0,00	0,00	0,00	0,00	0,00	0,00
Especificidade	100	97,18	100	98,75	99,45	99,79	99,68	100	100	99,52
Acurácia	78,76	74,18	71,67	72,90	71,71	79,84	73,20	80,40	76,31	74,13
Erros de classificação	21,24	25,89	28,33	27,10	28,29	20,16	26,80	19,60	23,69	25,87

assim, a sensibilidade indica que a NN não possui capacidade adequada de identificar intervalos que contenham apneia.

Na Tabela 5.5 é realizada a comparação entre os resultados apresentados acima e aqueles obtidos por Khandoker *et al.* (2009a) e Xie & Minn (2012), onde o primeiro usou uma abordagem semelhante à nossa através da TW (Symlet de ordem 3) e NN, e o segundo, com a utilização do mesmo banco de dados que o utilizado no nosso trabalho, mas um conjunto de características diferentes.

Tabela 5.5: Comparativo das estatísticas de performance com Khandoker *et al.* (2009a) e Xie & Minn (2012) (valores em %).

	40 Neurônios	Khandoker <i>et al.</i> (2009a)	Xie & Minn (2012)
Sensibilidade	0,00	91,68	0,00
Especificidade	100	98,87	100
Acurácia	80,40	98,48	75,66

Obtivemos valores similares àqueles de Xie & Minn (2012) para a identificação da apneia; entretanto, os nossos resultados e os de Xie & Minn (2012) são discrepantes quando postos lado a lado com os resultados obtidos por Khandoker *et al.* (2009a). Note que a especificidade, para os três estudos, são consonantes, ficando próximo ao 100%.

Uma dificuldade para realizar comparativos de desempenho nos métodos de reconhecimento da apneia é a falta de uniformidade nas estatísticas utilizadas. Por exemplo, alguns estudos se utilizam dos dados de treinamento para expressar os

resultados (de Chazal *et al.*, 2002a), ou apenas o número total de diagnósticos realizados corretamente, considerando a acurácia maior que 85% ou, ainda, a acurácia geral (Drinnan *et al.*, 2000; Fontenla-Romero *et al.*, 2005; Hassan, 2015; Mietus *et al.*, 2000).

O último teste realizado com o ECG é uma combinação dos dois anteriores, isto é, **utilizando o conjunto das características do intervalo RR e da TW**. Resultaram 49 características que descrevem o intervalo: as 45 utilizadas pela TW e as 4 do Intervalo RR. O objetivo é garantir um aprendizado em que as deficiências de uma sejam compensadas pelas vantagens da outra, e, assim, aumentando as possibilidades de classificação correta. Na Figura 5.10 são apresentadas as acurácias obtidas para diversos números de neurônios.




Figura 5.10: Classificação do Intervalo RR e da TW: resultado para a acurácia dos testes utilizando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios com o método *leave-one-out*.

Na figura acima, é possível visualizar melhoras em relação às análises anteriores - por exemplo, não há *outliers* - onde o pior resultado tem acurácia de 44,88% e o melhor, 94,53%. Com 10 neurônios é obtida a melhor acurácia dentre todos os testes, com resultados concentrados entre 70 e 85%, e mediana superior a 80%.

Na Tabela 5.6 são apresentadas as estatísticas de performance para características combinadas do Intervalo RR e da TW. Os valores são gerados através da média de todas as estatísticas para cada número de neurônios, excluindo os *outliers*, como realizado anteriormente.

Tabela 5.6: Estatísticas para a classificação utilizando o Intervalo RR e a TW para diversos números de neurônios (valores em %).

Neurônios	05	10	15	20	25	30	35	40	45	50
Sensibilidade	48,04	28,58	55,66	36,01	36,32	28,44	31,44	27,29	25,99	38,37
Especificidade	84,14	90,35	81,29	86,91	88,90	90,66	89,70	89,93	92,67	85,17
Acurácia	78,29	80,87	76,78	75,31	80,63	78,90	80,22	79,53	80,23	76,48
Erros de classificação	23,20	21,40	24,34	25,69	21,30	22,58	21,92	22,32	21,55	25,51

Em relação à especificidade, o resultado permaneceu próximo aos 90%; já em relação à sensibilidade, houve uma melhora considerável em relação aos casos anteriores, com a melhor especificidade obtida em 96,44%, e a média, em 55,66%. Em relação à capacidade de classificação, houve uma redução em 1,04% em média, quando comparado com a classificação utilizando apenas a TW, e um acréscimo, se considerado com as características do intervalo RR. Neste caso, a utilização de mais características garantiu uma melhora na especificidade, trazendo vantagens em relação aos testes anteriores, mesmo que a acurácia não tenha apresentado grande variação.

Na Tabela 5.7 apresentamos uma comparação entre as estatísticas de performance obtidas com o uso do Intervalo RR e da TW e aqueles resultados obtidos por Erazo & Ríos (2014) e de Chazal *et al.* (2015). Os nossos resultados são apresentados nas duas primeiras colunas, classificados pela menor e pela maior acurácia obtidas, isto é, para 20 e 10 neurônios, respectivamente. Note que a escolha da acurácia não implica em valores proporcionais para a sensibilidade e especificidade; por exemplo, a menor acurácia possui uma sensibilidade maior que o caso com maior acurácia.



Tabela 5.7: Comparação das estatísticas de performance entre a nossa abordagem e aquelas de Erazo & Ríos (2014) e de Chazal *et al.* (2015) (valores em %).

	Mínimo	Máximo	Erazo & Ríos (2014)	de Chazal <i>et al.</i> (2015)
Sensibilidade	36,01	28,58	36,33	40,0
Especificidade	86,91	90,35	63,85	65,0
Acurácia	75,31	80,87	51,88	60,1

O resultado obtido com a utilização do Intervalo RR e da TW é comparável com o encontrado por de Chazal *et al.* (2015) para sinais do ECG, que obteve 65% de especificidade e 40% de sensibilidade, totalizando 60,1% de acurácia. Em comparação com Erazo & Ríos (2014), que utilizou TW da família Daubechies de ordem 4 e NN para classificação de apneia em crianças, os resultados que encontramos são melhores em relação à acurácia e especificidade, e equiparável para a sensibilidade.

Ainda que a combinação entre as características do Intervalo RR e da TW tenha proporcionado um resultado melhor que a utilização de cada um dos conjuntos de características separadamente, não é possível afirmar que a realização de diagnósticos com esta abordagem seja adequada. Apesar disso, dado o resultado da especificidade, este teste pode ser utilizado inicialmente e como coadjuvante para descartar o diagnóstico de apneia em graus mais severos (Flemons & McNicholas, 1997; Hilton *et al.*, 1999; de Chazal *et al.*, 2015).

### 5.3.2 Resultados: SpO<sub>2</sub>

As características que descrevem a saturação de oxigênio no sangue SpO<sub>2</sub> foram calculadas conforme a Tabela 4.1, ressaltando que não foi utilizada a TW na decomposição deste sinal.




Figura 5.11: Acurácia do teste *leave-one-out* para  $\text{SpO}_2$  usando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios.

Na Figura 5.11 são apresentadas as acurácias obtidas para este conjunto de testes. Para as características que utilizamos para descrever o  $\text{SpO}_2$ , o número de neurônios não trouxe grande influência, onde a acurácia ficou distribuída entre 65 e 98%, concentrando maior parte dos resultados entre 75 e 88%; o melhor resultado foi alcançado com 40 neurônios. Além disso, não há presença de *outliers*. Outros resultados relacionados às estatísticas de performance são apresentados na Tabela 5.8, cujos valores percentuais representam a média de todos os testes para determinado número de neurônio utilizado na NN, desconsiderando *outliers*.

Tabela 5.8: Estatísticas para a classificação utilizando características da  $\text{SpO}_2$  para diversos números de neurônios (valores em %).

Neurônios	05	10	15	20	25	30	35	40	45	50
Sensibilidade	33,12	35,32	38,63	37,48	37,92	36,16	37,48	36,75	37,99	38,06
Especificidade	94,06	93,90	92,80	92,56	92,76	92,67	92,75	92,66	93,26	91,99
Acurácia	81,55	82,20	82,19	82,62	81,99	82,33	82,44	82,82	82,28	82,28
Erros de classificação	18,48	17,88	17,93	17,46	18,13	17,79	17,68	17,30	17,84	17,84

Para este conjunto de testes, obtivemos uma sensibilidade entre 30 e 40%, com uma melhora significativa em relação aos testes apresentados anterior-

mente, com o uso do sinal ECG. Ainda podemos observar que a especificidade permanece superior a 90%, assim como a capacidade de classificação da NN, que consegue reconhecer mais de 80% dos intervalos. Como os valores da acurácia são bem próximos uns dos outros, podemos revisar nossa escolha do melhor teste: escolhendo a partir da maior sensibilidade, a NN gerada com 15 neurônios apresenta o melhor resultado dentre os testes, seguido por 50, 45 e 25 neurônios.

A Tabela 5.9 apresenta uma comparação com os nossos resultados, a menor e a maior acurácia, com os resultados obtidos por Erazo & Ríos (2014) e de Chazal *et al.* (2015). Observe que as estatísticas para sensibilidade e especificidade não são, necessariamente, as menores e as maiores encontradas dentre as estatísticas. Ressalta-se que de Chazal *et al.* (2015) utilizam o mesmo banco de dados utilizado no nosso estudo, assim como a mesma caracterização do SpO<sub>2</sub>, escolhendo uma abordagem diferenciada quanto ao algoritmo de classificação (Função Discriminante Logística); Erazo & Ríos (2014) utilizam uma abordagem semelhante à que utilizamos para os demais sinais, com TW da família Daubechies de ordem 4 e NN.

Tabela 5.9: Comparação das estatísticas de performance entre a nossa abordagem e a desenvolvida por de Chazal *et al.* (2015) para SpO<sub>2</sub> (valores em %).

	Mínimo	Máximo	Erazo & Ríos (2014)	de Chazal <i>et al.</i> (2015)
Sensibilidade	33,12	38,63	19,67	37,50
Especificidade	91,99	94,06	77,69	79,00
Acurácia	81,55	82,82	52,46	70,60

Em comparação com de Chazal *et al.* (2015), cujo método foi replicado no nosso estudo, os resultados da sensibilidade, em média, foram um pouco inferiores; entretanto, para a especificidade, foi possível obter um resultado melhor, como é visto na Tabela 5.9. É possível ver, ainda, que a NN utilizando o algoritmo de aprendizagem baseado na SCG apresentou melhores resultados para a especificidade que a Função Discriminante Logística. Já em comparação com Erazo & Ríos (2014), que utilizou outras características para a avaliação do sinal da saturação do oxigênio,

há uma melhora significativa tanto em relação a sensibilidade, como a especificidade, cuja acurácia difere em pelo menos 29%.

Ainda que a acurácia seja superior a 80%, é a especificidade que permite que os resultados possam ser utilizados como ferramenta de auxílio no diagnóstico para verificar a presença da apneia. Embora não seja possível diagnosticar um paciente e identificar a severidade da apneia, esta abordagem permite determinar se o paciente não tem apneia (Flemons & McNicholas, 1997; Hilton *et al.*, 1999; de Chazal *et al.*, 2015).

### 5.3.3 Resultados: Fluxo Respiratório

Nesta subseção, apresentaremos os resultados obtidos para a análise do sinal do Fluxo Respiratório através da TW, Daubechies ordem 4 com 7 decomposições, cujo conjunto de característica é apresentado na Tabela 4.1. A Figura 5.12 mostra as acurácias obtidas para este conjunto de testes.




Figura 5.12: Acurácia do teste *leave-one-out* para o Fluxo Respiratório usando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios.

As acurácias estão distribuídas entre 60 e 95%, com exceção dos testes realizados com 15, 45 e 50 neurônios; ainda é possível observar que a mediana (seg-

mento em vermelho) das acurácias para os diversos testes estão localizadas próximo a 80%, com melhores resultados obtidos para 5 e 35 neurônios, não apresentando grandes diferenças em relação à distribuição ao longo do diagrama de caixas, isto é, a acurácia para os dois casos está concentrada entre 70 e 85%. Como o tempo computacional é relativamente menor para os testes realizados com 5 neurônios, aplicar uma NN com este número de neurônios poderia ser mais indicado.

Outras estatísticas de desempenho podem ser visualizadas na Tabela 5.10, gerada a partir da média dos resultados obtidos para cada número de neurônios, excluindo *outliers*.

Tabela 5.10: Estatísticas para a classificação utilizando características do Fluxo Respiratório para diversos números de neurônios (valores em %).

Neurônios	05	10	15	20	25	30	35	40	45	50
Sensibilidade	17,75	21,04	9,87	18,95	17,37	17,17	18,06	19,63	18,09	11,12
Especificidade	93,99	93,51	96,13	94,03	93,13	94,06	94,26	93,91	93,12	96,88
Acurácia	80,20	79,16	79,77	79,13	78,81	78,97	80,08	79,51	79,23	79,55
Erros de classificação	19,89	20,92	20,31	20,99	21,27	21,12	19,95	20,62	20,86	20,53

Enquanto a especificidade média para todos os números de neurônios, acima de 93%, apresenta valores razoáveis, a sensibilidade não ultrapassa 20%, o que contribui para a redução da acurácia dos testes. A quantidade de erros de classificação, em torno de 20%, apresentou-se condizente com os testes anteriores. A partir da Tabela 5.10 é possível visualizar, ainda, que as estatísticas de performance não apresentam grande diferença entre os melhores resultados, com 5 e 35 neurônios, corroborando com o que foi discutido em relação à Figura 5.12 na escolha da aplicação de uma NN com 5 neurônios.

A Tabela 5.11 apresenta uma comparação dos resultados utilizando uma abordagem semelhante aplicada por Erazo & Ríos (2014), TW da família Daubechies 4 e NN, em um banco de dados diferente. As primeiras duas colunas apresentam nossos melhores resultados classificados pela acurácia e, a terceira, os resultados

obtidos por Erazo & Ríos (2014); tanto a sensibilidade, quanto a especificidade utilizadas para comparação não são, necessariamente, a menor e a maior dentre os resultados apresentados na Tabela 5.10.

Tabela 5.11: Comparação das estatísticas de performance entre a nossa abordagem e as estatísticas obtidas por Erazo & Ríos (2014) para o Fluxo Respiratório (valores em %).

	Mínimo	Máximo	Erazo & Ríos (2014)
Sensibilidade	17,37	17,75	80,51
Especificidade	93,13	93,99	21,67
Acurácia	78,81	80,20	54,93

Relacionando os nossos resultados com os obtidos por Erazo & Ríos (2014), há uma disparidade nas estatísticas: nos nossos testes é possível classificar os casos de não apneia com boa eficiência, enquanto que Erazo & Ríos (2014) conseguem identificar melhor os casos de apneia. Um dos fatores que pode estar relacionado com este resultado é a idade dos pacientes, crianças, cujos fluxos respiratórios são diferentes daqueles dos adultos (Várady *et al.*, 2002).

O nosso algoritmo, assim como nos testes realizados com o ECG e a SpO<sub>2</sub>, permite que sejam descartados o diagnóstico de apneia em alguns pacientes. Note, ainda, que a disparidade entre os resultados da acurácia encontrados pelo nosso algoritmo e o de Erazo & Ríos (2014) pode representar um indicativo que a decomposição TW em 7 escalas e 5 estatísticas, no caso do Fluxo Respiratório, gera resultados melhores que a decomposição em 14 escalas e 3 estatísticas (média, desvio padrão e entropia), com a mesma wavelet, Db4. Ressalta-se que a abordagem desenvolvida por Erazo & Ríos (2014) possibilita uma classificação com maior sensibilidade, indicando que possa haver algum componente de frequência não considerado no nosso estudo e que possa representar uma alternativa para compor um resultado mais preciso.

### 5.3.4 Resultados: Esforço Respiratório

O Esforço Respiratório, caracterizado pela movimentação do abdômen e da caixa torácica, tem acurácias representada na Figura 5.13, geradas a partir das características da Tabela 4.1.




Figura 5.13: Acurácia do teste *leave-one-out* para o Esforço Respiratório usando 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 neurônios.

Assim como para o Fluxo Respiratório, o Esforço gerou acurácias com medianas (segmento em vermelho) de valores semelhantes para os diversos números de neurônios. Uma diferença que pode ser claramente visualizada é que as acurácias apresentam uma distribuição maior ao longo do eixo horizontal, como no caso da NN gerada com 30 neurônios que a acurácia se estende para valores em torno de 55 até 98%. Ainda que o resultado da mediana para 30 neurônios seja o melhor, a variabilidade das acurácias nos leva a escolher outra NN, a gerada com 20 neurônios, parecendo mais promissora na caracterização da apneia.

A Tabela 5.12 apresenta as estatísticas do teste realizado para o Esforço Respiratório com NN gerada a partir de diferentes números de neurônios.

Tabela 5.12: Estatísticas para a classificação utilizando características do Esforço Respiratório para diversos números de neurônios (valores em %).

Neurônios	05	10	15	20	25	30	35	40	45	50
Sensibilidade	24,24	22,83	23,46	23,77	22,89	6,79	12,61	25,64	22,56	19,86
Especificidade	93,21	92,56	93,38	94,02	92,88	99,12	95,36	93,22	94,00	94,25
Acurácia	80,63	81,80	80,54	80,94	80,77	81,81	79,07	80,24	80,70	80,54
Erros de classificação	19,41	18,40	19,49	19,13	19,32	18,19	20,98	19,76	19,35	19,60

O melhor resultado, assim como discutido para a Figura 5.13, foi alcançado com 30 neurônios; entretanto, é possível notar maior variabilidade na acurácia, variando de 54,01 a 98,05%. Desta forma, ainda que proporcione uma acurácia média menor, 80,94%, o resultado com 20 neurônios parece mais promissor na caracterização da apneia. Mesmo sendo considerado um dado mais qualitativo que quantitativo, o esforço respiratório apresentou uma capacidade de classificação média superior a 80%, assim como a especificidade média, acima de 90%. Em relação à sensibilidade, observa-se valores médios entre 6,79 a 25,64%.

Os resultados dos nossos testes com o Esforço Respiratórios são comparáveis com os do Fluxo Respiratório (Subseção 5.3.3), apresentando uma pequena melhora em relação à sensibilidade. Contudo, por ser composto por dois sinais, esforço abdominal e torácico, gera um número maior de características por intervalo e, conseqüentemente, um tempo computacional relativamente maior. Isto, juntamente com a necessidade de dois mecanismos de captação de sinais diferentes, pode explicar a preferência pelo uso do Fluxo Respiratório em detrimento do Esforço Respiratório.

### 5.3.5 Determinação dos Intervalos de Apneia e o Cálculo do AHI

Uma vez realizado o treinamento da NN, obtém-se uma estrutura capaz de avaliar outras PSGs, deste que sejam utilizados os mesmos métodos de obtenção dos dados utilizados na aprendizagem. Os resultados gerados pela NN, na forma da



matriz *Output* da Figura 5.5, podem ser utilizados para a produção de relatórios, informando o intervalo em que foi detectada a apneia, bem como o índice AHI.

Na nossa abordagem, a determinação dos intervalos em que foram encontrados indícios de apneia, à semelhança da tabela construída por especialistas da área da saúde e ilustrada na Figura 5.1, apresentaria a respectiva classificação para cada intervalo de 60 segundos.

O AHI, por sua vez, pode ser obtido através da divisão do número total de apneias detectadas pelo tempo total da duração da PSG, em horas. Este cálculo fornece uma estimativa semelhante às estimativas da Tabela A.1.

## 6 CONCLUSÃO

O principal objetivo deste trabalho foi o desenvolvimento de uma ferramenta de auxílio ao diagnóstico da apneia, que permitisse uma automatização da análise da PSG através de ferramentas matemáticas computacionais. A decomposição de alguns dos sinais da PSG com a TW discreta propiciou uma metodologia para analisar várias frequências separadamente, de modo que cada decomposição do sinal fosse descrito por um conjunto de estatísticas. Neste trabalho adotou-se uma abordagem de decomposição dos sinais da PSG utilizando a wavelet Daubechies de ordem 4, por apresentar melhores resultados em testes preliminares, além de haver implementações na literatura que permitam comparações.

Para a caracterização e para a classificação dos dados tornou necessário o uso de ferramentas de aprendizagem, e para isso, adotou-se as NNs. Uma das razões desta escolha deve-se a grande possibilidade de gerar novas topologias que permitem lidar com problemas de complexidade diversa, não sendo necessário o conhecimento prévio do modelo de classificação.

Utilizando intervalos de 60 segundos, foram analisados separadamente alguns sinais que compõem a PSG: o ECG, o SpO<sub>2</sub>, o Fluxo Respiratório e o Esforço Respiratório. A escolha destes sinais contribui com a necessidade de simplificação e desoneração do diagnóstico da apneia, assim como fornecem ferramentas que possibilitariam a proposição de um exame em formatação distinta da utilizada atualmente. Espera-se que, mesmo para o diagnóstico tradicional, o uso de ferramentas matemáticas possibilite uma redução no tempo de análise da PSG, assim como propicie uma redução de erros.

Para os resultados obtidos neste trabalho, há indicativos de que o modelo utilizado pode ser apenas para o descarte do diagnóstico da apneia em determinados pacientes. Observou-se que os melhores resultados de classificação, em relação

à acurácia, estão relacionados com a saturação do oxigênio no sangue ( $\text{SpO}_2$ ), ainda que a diferença não seja significativa para escolhê-lo em detrimento dos demais. Quanto à especificidade, capacidade de identificar intervalos que não contém apneia, em todos os testes obtivemos resultados superiores a 80%, o que mostra que as características utilizadas possibilitam a identificação do padrão não apneico com precisão. Todavia, a sensibilidade, capacidade de identificar intervalos que contém apneia, não ultrapassou 60%, tornando-se um indicativo que o modelo proposto não consegue classificar apropriadamente a apneia, sendo necessária a revisão das características a fim de tentar melhorar os resultados.

Algumas limitações no modelo podem ser elencadas, e são inerentes ao sinal, como o atraso de alguns segundos na manifestação da apneia em sinais como o ECG e o  $\text{SpO}_2$ , ou como a diferença entre esforço e fluxo respiratório entre indivíduos. Para esta última limitação, ainda que os dados sejam submetidos ao pré-processamento, nem todas as características inerentes ao indivíduo podem ser anuladas, mas simplesmente atenuadas de forma que possa ser utilizado na generalização com os algoritmos de aprendizagem.

## 6.1 Trabalhos Futuros

A detecção de enfermidade através de sinais biomédicos é uma área em desenvolvimento, e ainda há muitos a ser estudado. Tanto a TW, quanto a NN são ferramentas de grande potencial, com capacidade de contribuir para o diagnóstico da apneia, e também de outras doenças. Algumas sugestões de trabalhos futuros são discutidos a seguir.

Uma primeira etapa seria testar como a combinação das características utilizadas nos testes seriam afetados. Um indício que poderiam produzir melhores resultados reside no aumento da acurácia quando utilizado o Intervalo RR e a TW simultaneamente, para o ECG, em relação aos testes realizados separadamente. O

conjunto de características que descrevem os sinais da PSG necessitam ser revistos, a fim de verificar a contribuição de cada uma das características utilizadas na classificação da apneia. Sugere-se, também, a inclusão de características provenientes do EEG, relacionando com o estado do sono do paciente (REM e NREM). Dados qualitativos provenientes do histórico médico, dos hábitos diários e da Escala de Sonolência *Epworth*, além de parâmetros fisiológicos podem ser utilizados na tentativa de melhorar a precisão do modelo.

Em relação à TW, há estudos que utilizam outras famílias de wavelets. Propõe-se, então, analisar diversas wavelets para estabelecer um comparativo em relação à performance destas quanto à classificação da apneia após determinado o melhor conjunto de características. Ainda podem ser utilizados outras escalas de decomposição, assim como o uso de uma escala isolada que contenha a banda de frequência desejada, aquela que evidencia a enfermidade.

O intervalo de análise também é um fator que pode auxiliar na composição de resultados diferentes dos obtidos, visto que a duração da apneia tem pelo menos 10 segundos. Propõe-se a segmentação da PSG em diversos tamanhos a fim de comparação, com intervalos podendo variar de 5 a 60 segundos.

A diferenciação entre apneia e hipopneia, além da natureza dos eventos (obstrutiva, central ou mista) pode contribuir para o diagnóstico e para a determinação do tratamento. Para tanto, a utilização de um banco de dados maior torna-se fundamental, principalmente pela quantidade de amostras que contribuiria com exemplos de aprendizagem.

Por fim, em relação às NNs, a grande flexibilidade traz possibilidades de testar outras topologias que possam trazer melhores resultados. Não obstante, as NNs podem ser comparadas com o emprego de outros algoritmos de aprendizagem, como o SVM, Algoritmo Genético, entre outros.

## Referências Bibliográficas

- AASM. *The International Classification of Sleep Disorders: Diagnostic and Coding Manual*. American Sleep Disorders Association, 1990.
- AASM. *International Classification of Sleep Disorders: Diagnostic and Coding Manual*. American Sleep Disorders Association, 2nd edition, 2005.
- Abu-Mostafa, Y., Magdon-Ismail, M., & Lin, H. *Learning from Data: A Short Course*. AMLBook Berlin, 2012.
- Acharya, U. R., Chua, E. C.-P., Faust, O., Lim, T.-C., & Lim, L. F. B. Automated detection of sleep apnea from electrocardiogram signals using nonlinear parameters. *Physiological measurement*, 32(3):287, 2011.
- Addison, P. S. *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. CRC press, 2002.
- Ahmad, M. O. & Sundararajan, D. A fast algorithm for two dimensional median filtering. *Circuits and Systems, IEEE Transactions on*, 34(11):1364–1374, 1987.
- Almazaydeh, L., Faezipour, M., & Elleithy, K. A neural network system for detection of obstructive sleep apnea through spo2 signal features. 2012.
- Alpaydin, E. *Introduction to Machine Learning*. Adaptive Computation and Machine Learning. MIT Press, 2014.
- Álvarez-Estévez, D. & Moret-Bonillo, V. Fuzzy reasoning used to detect apneic events in the sleep apnea-hypopnea syndrome. *Expert Systems with Applications*, 36(4):7778–7785, 2009.
- Avci, E., Turkoglu, I., & Poyraz, M. Intelligent target recognition based on wavelet packet neural network. *Expert Systems with Applications*, 29(1):175–182, 2005.

- Bachmann, G., Narici, L., & Beckenstein, E. *Fourier and wavelet analysis*. Springer Science & Business Media, 2012.
- Berry, R. B., Brooks, R., Gamaldo, C. E., Harding, S., Marcus, C., & Vaughn, B. The aasm manual for the scoring of sleep and associated events. *Rules, Terminology and Technical Specifications, Darien, Illinois, American Academy of Sleep Medicine*, 2012.
- Bishop, C. M. *Neural networks for pattern recognition*. Oxford University Press, 1995.
- Bishop, C. M. *Pattern Recognition and Machine Learning*. Springer, 2006.
- Brown, T. E., Beightol, L. A., Koh, J., & Eckberg, D. L. Important influence of respiration on human r-r interval power spectra is largely ignored. *Journal of Applied Physiology*, 75(5):2310–2317, 1993.
- Bsoul, M., Minn, H., & Tamil, L. Apnea medassist: real-time sleep apnea monitor using single-lead ECG. *Information Technology in Biomedicine, IEEE Transactions on*, 15(3):416–427, 2011.
- Bultheel, A. & Huybrechs, D. *Wavelets with applications in signal and image processing*. Notas de Aula. Katholieke Universiteit Leuven, Bélgica, 2011.
- Chan, Y. *Wavelet Basics*. Kluwer Academic Publishers, 1995.
- Chel, H., Majumder, A., & Nandi, D. Scaled conjugate gradient algorithm in neural network based approach for handwritten text recognition. In Nagamalai, D., Renault, E., & Dhanuskodi, M., editors, *Trends in Computer Science, Engineering and Information Technology*, volume 204 of *Communications in Computer and Information Science*, pages 196–210. Springer Berlin Heidelberg, 2011.
- Chen, L., Zhang, X., & Song, C. A severity measurement system for obstructive sleep apnea discrimination using a single ECG signal. In *Automation Science and*

- Engineering (CASE)*, 2013 IEEE International Conference on, pages 1–6. IEEE, 2013.
- Chen, L., Zhang, X., & Song, C. An automatic screening approach for obstructive sleep apnea diagnosis based on single-lead electrocardiogram. *Automation Science and Engineering, IEEE Transactions on*, 12(1):106–115, 2015.
- Chen, P. C. & Pavlidis, T. Segmentation by texture using a co-occurrence matrix and a split-and-merge algorithm. *Computer graphics and image processing*, 10(2): 172–182, 1979.
- Chokroverty, S. & Billiard, M. *Sleep Medicine: A Comprehensive Guide to Its Development, Clinical Milestones, and Advances in Treatment*. Springer New York, 2015.
- Chokroverty, S. & Thomas, R. *Atlas of Sleep Medicine*. ClinicalKey 2012. Elsevier Science Health Science Division, 2013.
- Chui, C. K. *Wavelets: a mathematical tool for signal analysis*, volume 1. SIAM, 1997.
- Chui, C. & Jiang, Q. *Applied Mathematics: Data Compression, Spectral Methods, Fourier Analysis, Wavelets, and Applications*. Mathematics Textbooks for Science and Engineering. Atlantis Press, 2013.
- Cohen, A. *Numerical analysis of wavelet methods*, volume 32. Elsevier, 2003.
- Daubechies, I. *et al. Ten lectures on wavelets*, volume 61. SIAM, 1992.
- de Chazal, P., Reilly, R., & Heneghan, C. Automatic sleep apnoea detection using measures of amplitude and heart rate variability from the electrocardiogram. In *Pattern Recognition, 2002. Proceedings. 16th International Conference on*, volume 1, pages 775–778. IEEE, 2002a.

- de Chazal, P., Reilly, R., & Heneghan, C. Automatic sleep apnoea detection using measures of amplitude and heart rate variability from the electrocardiogram. In *Pattern Recognition, 2002. Proceedings. 16th International Conference on*, volume 1, pages 775–778. IEEE, 2002b.
- de Chazal, P., Penzel, T., & Heneghan, C. Automated detection of obstructive sleep apnoea at different time scales using the electrocardiogram. *Physiological measurement*, 25(4):967, 2004.
- de Chazal, P., Sadr, N., & Jayawardhana, M. An ECG oximetry system for identifying obstructive and central apnoea events. In *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, pages 7671–7674. IEEE, 2015.
- de Jesus Kozakevicius, A., Rodrigues, C. R., Nunes, R. C., & Guerra Filho, R. Adaptive ECG filtering and QRS detection using orthogonal wavelet transform. *Biomedical Engineering, Innsbruck, Austria*, 2005.
- Debnath, L. *Integral Transforms and Their Applications*. Taylor & Francis, 1995.
- del Campo, F., Hornero, R., Zamarrón, C., Abasolo, D. E., & Álvarez, D. Oxygen saturation regularity analysis in the diagnosis of obstructive sleep apnea. *Artificial intelligence in medicine*, 37(2):111–118, 2006.
- Dimitrovski, I., Kocev, D., Kitanovski, I., Loskovska, S., & Džeroski, S. Improved medical image modality classification using a combination of visual and textual features. *Computerized Medical Imaging and Graphics*, 39:14–26, 2015.
- Dremin, I., Ivanov, O., & Nechitailo, V. Wavelets and their use. *arXiv:hep-ph/0101182*, 2001.
- Drinnan, M., Allen, J., Langley, P., & Murray, A. Detection of sleep apnoea from frequency analysis of heart rate variability. In *Computers in Cardiology 2000*, pages 259–262. IEEE, 2000.



- Dubey, S. R., Singh, S. K., & Singh, R. K. Local wavelet pattern: A new feature descriptor for image retrieval in medical CT databases. *Image Processing, IEEE Transactions on*, 24(12):5892–5903, 2015.
- Epstein, L. J., Kristo, D., Strollo Jr, P. J., Friedman, N., Malhotra, A., Patil, S. P., Ramar, K., Rogers, R., Schwab, R. J., Weaver, E. M., *et al.* Clinical guideline for the evaluation, management and long-term care of obstructive sleep apnea in adults. *J Clin Sleep Med*, 5(3):263–276, 2009.
- Erazo, L. & Ríos, S. A. A benchmark on automatic obstructive sleep apnea screening algorithms in children. *Procedia Computer Science*, 35:739–746, 2014.
- Espiritu, H. & Metsis, V. Automated detection of sleep disorder-related events from polysomnographic data. In *Healthcare Informatics (ICHI), 2015 International Conference on*, pages 562–569. IEEE, 2015.
- Fernández, A., Gómez, Á., Lecumberry, F., Pardo, Á., & Ramírez, I. Pattern recognition in latin america in the “big data”era. *Pattern Recognition*, 48(4): 1185–1196, 2015.
- Fine, T. *Feedforward Neural Network Methodology*. Information Science and Statistics. Springer New York, 2006.
- Fitz-Gibbon, C. & Morris, L. *How to Analyze Data*. 2. SAGE Publications, 1987.
- Flemons, W. W. & McNicholas, W. T. Clinical prediction of the sleep apnea syndrome. *Sleep medicine reviews*, 1(1):19–32, 1997.
- Fontenla-Romero, O., Guijarro-Berdiñas, B., Alonso-Betanzos, A., & Moret-Bonillo, V. A new method for sleep apnea classification using wavelets and feedforward neural networks. *Artificial Intelligence in Medicine*, 34(1):65–76, 2005.
- Gallagher, D., Heymsfield, S. B., Heo, M., Jebb, S. A., Murgatroyd, P. R., & Sakamoto, Y. Healthy percentage body fat ranges: An approach for developing

- guidelines based on body mass index. *The American journal of clinical nutrition*, 72(3):694–701, 2000.
- Gao, R. & Yan, R. From fourier transform to wavelet transform: A historical perspective. In *Wavelets*, pages 17–32. Springer US, 2011.
- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K., & Stanley, H. E. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation*, 101(23):215–220, 2000.
- Grossmann, A. & Morlet, J. Decomposition of hardy functions into square integrable wavelets of constant shape. *SIAM journal on mathematical analysis*, 15(4):723–736, 1984.
- Gubbi, J., Khandoker, A., & Palaniswami, M. Classification of obstructive and central sleep apnea using wavelet packet analysis of ECG signals. In *Computers in Cardiology, 2009*, pages 733–736. IEEE, 2009.
- Gubbi, J., Khandoker, A., & Palaniswami, M. Classification of sleep apnea types using wavelet packet analysis of short-term ECG signals. *Journal of clinical monitoring and computing*, 26(1):1–11, 2012.
- Guilleminault, C., Winkle, R., Connolly, S., Melvin, K., & Tilkian, A. Cyclical variation of the heart rate in sleep apnoea syndrome: Mechanisms, and usefulness of 24 h electrocardiography as a screening technique. *The Lancet*, 323(8369):126–131, 1984.
- Güler, İ. & Übeyli, E. D. ECG beat classifier designed by combined neural network model. *Pattern recognition*, 38(2):199–208, 2005.
- Gurney, K. *An Introduction to Neural Networks*. Taylor & Francis, 1997.

- Haralick, R. M., Shanmugam, K., & Dinstein, I. H. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on*, (6):610–621, 1973.
- Hassan, A. R. A comparative study of various classifiers for automated sleep apnea screening based on single-lead electrocardiogram. In *Electrical and Electronic Engineering (ICEEE), 2015 International Conference on*, pages 1–4, 2015.
- Hastie, T., Tibshirani, R., & Friedman, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition*. Springer Series in Statistics. Springer, 2009.
- Haykin, S. *Neural Networks: A Comprehensive Foundation*. International edition. Prentice Hall, 1999.
- Haykin, S. *Neural Networks and Learning Machines*, volume 10. Prentice Hall, 2009.
- Hazarika, N., Chen, J. Z., Tsoi, A. C., & Sergejew, A. Classification of EEG signals using the wavelet transform. In *Digital Signal Processing Proceedings, 1997. DSP 97., 1997 13th International Conference on*, volume 1, pages 89–92. IEEE, 1997.
- Herculano-Houzel, S. The human brain in numbers: a linearly scaled-up primate brain. *Frontiers in human neuroscience*, 3:31, 2009.
- Hilton, M., Bates, R., Godfrey, K., Chappell, M., & Cayton, R. Evaluation of frequency and time-frequency spectral analysis of heart rate variability as a diagnostic marker of the sleep apnoea syndrome. *Medical & biological engineering & computing*, 37(6):760–769, 1999.
- Hramov, A., Koronovskii, A., Makarov, V., Pavlov, A., & Sitnikova, E. *Wavelets in Neuroscience*. Springer Series in Synergetics. Springer Berlin Heidelberg, 2014.
- Inan, O. T., Giovangrandi, L., & Kovacs, G. T. Robust neural-network-based classification of premature ventricular contractions using wavelet transform and timing

- interval features. *Biomedical Engineering, IEEE Transactions on*, 53(12):2507–2515, 2006.
- Jain, A. K., Mao, J., & Mohiuddin, K. Artificial neural networks: A tutorial. *Computer*, (3):31–44, 1996.
- Jin, Y., Angelini, E., & Laine, A. Wavelets in medical image processing: denoising, segmentation, and registration. In *Handbook of biomedical image analysis*, pages 305–358. Springer, 2005.
- Kaiser, G. *A friendly guide to wavelets*. Springer Science & Business Media, 2010.
- Karmakar, C. K., Khandoker, A. H., & Palaniswami, M. Identification of onset, maximum and termination of obstructive sleep apnoea events in single lead ECG recordings. In *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, pages 1072–1075. IEEE, 2008.
- Khandoker, A., Karmakar, C., & Palaniswami, M. Interaction between sleep EEG and ECG signals during and after obstructive sleep apnea events with or without arousals. In *Computers in Cardiology, 2008*, pages 685–688. IEEE, 2008a.
- Khandoker, A. H., Karmakar, C. K., & Palaniswami, M. Analysis of coherence between sleep EEG and ECG signals during and after obstructive sleep apnea events. In *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, pages 3876–3879. IEEE, 2008b.
- Khandoker, A. H., Gubbi, J., & Palaniswami, M. Automated scoring of obstructive sleep apnea and hypopnea events using short-term electrocardiogram recordings. *Information Technology in Biomedicine, IEEE Transactions on*, 13(6):1057–1067, 2009a.
- Khandoker, A. H., Palaniswami, M., & Karmakar, C. K. Support vector machines for automated recognition of obstructive sleep apnea syndrome from ECG

- recordings. *Information Technology in Biomedicine, IEEE Transactions on*, 13 (1):37–48, 2009b.
- Khandoker, A. H., Karmakar, C. K., & Palaniswami, M. Comparison of pulse rate variability with heart rate variability during obstructive sleep apnea. *Medical engineering & physics*, 33(2):204–209, 2011.
- Konar, A. *Computational Intelligence: Principles, Techniques and Applications*. Springer Berlin Heidelberg, 2006.
- Kriesel, D. *A Brief Introduction to Neural Networks*. 2007. Url: <http://www.dkriesel.com>.
- Kryger, M. H. *Atlas of Clinical Sleep Medicine: Expert Consult-Online*. Elsevier Health Sciences, 2010.
- Lado, M. J., Vila, X. A., Rodríguez-Liñares, L., Méndez, A. J., Olivieri, D. N., & Félix, P. Detecting sleep apnea by heart rate variability analysis: assessing the validity of databases and algorithms. *Journal of medical systems*, 35(4):473–481, 2011.
- Lai, Z., Qu, X., Liu, Y., Guo, D., Ye, J., Zhan, Z., & Chen, Z. Image reconstruction of compressed sensing MRI using graph-based redundant wavelet transform. *Medical image analysis*, 27:93–104, 2016.
- Lauderdale, D. S., Knutson, K. L., Yan, L. L., Liu, K., & Rathouz, P. J. Sleep duration: how well do self-reports reflect objective measures? the cardia sleep study. *Epidemiology (Cambridge, Mass.)*, 19(6):838, 2008.
- Lemos, L. C., Marqueze, E. C., Sachi, F., Lorenzi-Filho, G., & Moreno, C. R. d. C. Síndrome da apnéia obstrutiva do sono em motoristas de caminhão. *J Bras Pneumologia*, 35(6):500–6, 2009.

- Mala, K., Sadasivam, V., & Alagappan, S. Neural network based texture analysis of CT images for fatty and cirrhosis liver classification. *Applied Soft Computing*, 32:80–86, 2015.
- Mallat, S. *A Wavelet Tour of Signal Processing, Third Edition: The Sparse Way*. Academic Press, 3rd edition, 2008.
- Marshall, N. S., Wong, K. K., Liu, P. Y., Cullen, S. R., Knuiiman, M. W., Grunstein, R. R., *et al.* Sleep apnea as an independent risk factor for all-cause mortality: the busselton health study. *Sleep*, 31(8):1079, 2008.
- Martis, R. J., Acharya, U. R., Adeli, H., Prasad, H., Tan, J. H., Chua, K. C., Too, C. L., Yeo, S. W. J., & Tong, L. Computer aided diagnosis of atrial arrhythmia using dimensionality reduction methods on transform domain representation. *Biomedical Signal Processing and Control*, 13(1):295–305, 2014.
- Mendez, M. O., Bianchi, A. M., Matteucci, M., Cerutti, S., & Penzel, T. Sleep apnea screening by autoregressive models from a single ECG lead. *Biomedical Engineering, IEEE Transactions on*, 56(12):2838–2850, 2009.
- Mendez, M., Corthout, J., Van Huffel, S., Matteucci, M., Penzel, T., Cerutti, S., & Bianchi, A. Automatic screening of obstructive sleep apnea from the ECG based on empirical mode decomposition and wavelet analysis. *Physiological measurement*, 31(3):273, 2010.
- Mietus, J., Peng, C., Ivanov, P. C., & Goldberger, A. Detection of obstructive sleep apnea from cardiac interbeat interval time series. In *Computers in Cardiology 2000*, pages 753–756. IEEE, 2000.
- Møller, M. F. A scaled conjugate gradient algorithm for fast supervised learning. *Neural networks*, 6(4):525–533, 1993.

- Moody, G., Mark, R., Goldberger, A., & Penzel, T. Stimulating rapid research advances via focused competition: the computers in cardiology challenge 2000. In *Computers in Cardiology 2000*, pages 207–210. IEEE, 2000.
- Mullington, J. M., Haack, M., Toth, M., Serrador, J. M., & Meier-Ewert, H. K. Cardiovascular, inflammatory, and metabolic consequences of sleep deprivation. *Progress in cardiovascular diseases*, 51(4):294–302, 2009.
- Nakayama, C., Fujiwara, K., Matsuo, M., Kano, M., & Kadotani, H. Development of sleep apnea syndrome screening algorithm by using heart rate variability analysis and support vector machine. In *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, pages 8165–8168. IEEE, 2015.
- Nievergelt, Y. *Wavelets Made Easy*. Birkhauser, 1999.
- Parraga, A., Pettersson, J., Susin, A., De Craene, M., & Macq, B. Non-rigid registration methods assessment of 3D CT images for head-neck radiotherapy. In *Medical Imaging*, pages 65121–65121. International Society for Optics and Photonics, 2007.
- Penzel, T., McNames, J., De Chazal, P., Raymond, B., Murray, A., & Moody, G. Systematic comparison of different algorithms for apnoea detection based on electrocardiogram recordings. *Medical and Biological Engineering and Computing*, 40(4):402–407, 2002.
- Peppard, P. E., Young, T., Barnet, J. H., Palta, M., Hagen, E. W., & Hla, K. M. Increased prevalence of sleep-disordered breathing in adults. *American journal of epidemiology*, 177(9):1006–1014, 2013.
- Percival, D. & Walden, A. *Wavelet Methods for Time Series Analysis*. Cambridge Series in Statistical and Probabilistic Mathematics. Cambridge University Press, 2006.

- Quiceno-Manrique, A., Alonso-Hernandez, J., Travieso-Gonzalez, C., Ferrer-Ballester, M., & Castellanos-Dominguez, G. Detection of obstructive sleep apnea in ECG recordings using time-frequency distributions and dynamic features. In *Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE*, pages 5559–5562. IEEE, 2009.
- Radunovic, D. P. *Wavelets: From Math to Practice*. Springer Publishing Company, 1st edition, 2009.
- Rani, R., Chouhan, V., & Sinha, H. Automated detection of qrs complex in ECG signal using wavelet transform. *International Journal of Computer Science and Network Security (IJCSNS)*, 15(1):1, 2015.
- Ronzhina, M., Janoušek, O., Kolářová, J., Nováková, M., Honzík, P., & Provazník, I. Sleep scoring using artificial neural networks. *Sleep medicine reviews*, 16(3): 251–263, 2012.
- Saminu, S., Ozkurt, N., & Karaye, I. A. Wavelet feature extraction for ECG beat classification. In *Adaptive Science & Technology (ICAST), 2014 IEEE 6th International Conference on*, pages 1–6. IEEE, 2014.
- Sapuan, S. & Mujtaba, I. *Composite Materials Technology: Neural Network Applications*. CRC Press, 2009.
- Saritha, M., Joseph, K. P., & Mathew, A. T. Classification of MRI brain images using combined wavelet entropy based spider web plots and probabilistic neural network. *Pattern Recognition Letters*, 34(16):2151–2156, 2013.
- Schiff, S. J., Aldroubi, A., Unser, M., & Sato, S. Fast wavelet transformation of EEG. *Electroencephalography and Clinical Neurophysiology*, 91(6):442–455, 1994.
- Sezgin, N. & Tagluk, M. E. Energy based feature extraction for classification of sleep apnea syndrome. *Computers in biology and medicine*, 39(11):1043–1050, 2009.



- Shah, S. & Chauhan, N. Classification of brain MRI images using computational intelligent techniques. *International Journal of Computer Applications*, 124(14), 2015.
- Shinar, Z., Baharav, A., & Akselrod, S. Obstructive sleep apnea detection based on electrocardiogram analysis. In *Computers in Cardiology 2000*, pages 757–760. IEEE, 2000.
- Spriggs, W. *Essentials of Polysomnography*. Jones & Bartlett Learning, LLC, 2014.
- Tagluk, M. E. & Sezgin, N. A new approach for estimation of obstructive sleep apnea syndrome. *Expert Systems with Applications*, 38(5):5346–5351, 2011.
- Tagluk, M. E., Akin, M., & Sezgin, N. Classification of sleep apnea by using wavelet transform and artificial neural networks. *Expert Systems with Applications*, 37(2): 1600–1607, 2010.
- Teolis, A. *Computational Signal Processing with Wavelets*. Applied and Numerical Harmonic Analysis. Birkhäuser Boston, 2012.
- Tian, J. & Liu, J. Apnea detection based on time delay neural network. In *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*, pages 2571–2574. IEEE, 2005.
- Tocchetto, M. A., Bazanella, A. S., Guimaraes, L., Fragoso, J., & Parraga, A. An embedded classifier of lung sounds based on the wavelet packet transform and ann. In *Proceed. 19th World Congress The International Federation of Automatic Control, Cape Town, South Africa, August*, pages 24–29, 2014.
- Tufik, S., Santos-Silva, R., Taddei, J. A., & Bittencourt, L. R. A. Obstructive sleep apnea syndrome in the sao paulo epidemiologic sleep study. *Sleep medicine*, 11 (5):441–446, 2010.
- Übeyli, E. D. Wavelet/mixture of experts network structure for EEG signals classification. *Expert systems with applications*, 34(3):1954–1962, 2008.

- Übeyli, E. D. Combined neural network model employing wavelet coefficients for EEG signals classification. *Digital Signal Processing*, 19(2):297–308, 2009.
- UCDDDB. St. Vincent’s University Hospital / University College Dublin Sleep Apnea Database, 2008. Url: <http://physionet.org/physiobank/database/ucddb/>.
- Várady, P., Micsik, T., Benedek, S., & Benyó, Z. A novel method for the detection of apnea and hypopnea events in respiration signals. *Biomedical Engineering, IEEE Transactions on*, 49(9):936–942, 2002.
- Walker, J. S. *A primer on wavelets and their scientific applications*. CRC press, 2008.
- Wang, Z., Liu, Z., & Zheng, C. *Qualitative Analysis and Control of Complex Neural Networks with Delays*. Studies in Systems, Decision and Control. Springer Berlin Heidelberg, 2015.
- Weems, A., Harding, M., & Choi, A. Classification of the eeg signal using artificial neural network. In *Proceedings of the 3rd International Conference on Intelligent Technologies and Engineering Systems (ICITES2014)*, pages 545–555. Springer, 2016.
- Xie, B. & Minn, H. Real-time sleep apnea detection by classifier combination. *Information Technology in Biomedicine, IEEE Transactions on*, 16(3):469–477, 2012.
- Yildiz, A., Akin, M., & Poyraz, M. An expert system for automated recognition of patients with obstructive sleep apnea using electrocardiogram recordings. *Expert Systems with Applications*, 38(10):12880–12890, 2011.
- Zhang, Y. & Rajapakse, J. *Machine Learning in Bioinformatics*. Wiley Series in Bioinformatics. John Wiley & Sons, 2009.

Zhong, J., Ning, R., & Conover, D. Image denoising based on multiscale singularity detection for cone beam CT breast imaging. *Medical Imaging, IEEE Transactions on*, 23(6):696–703, 2004.

Zhou, J., Wu, X.-m., & Zeng, W.-j. Automatic detection of sleep apnea based on EEG detrended fluctuation analysis and support vector machine. *Journal of clinical monitoring and computing*, 29(6):767–772, 2015.



# Apêndices



## **A DESCRIÇÃO DO BANCO DE DADOS**

Este apêndice é destinado a caracterização do banco de dados UCDDDB (2008), composto por 25 Polissonografias, de duração entre 5 e 8 horas, coletadas entre Setembro de 2002 e Fevereiro de 2003, e dispostas na Tabela A.1.

Os pacientes possuem idade entre 28 e 68 anos, sendo 4 mulheres e 21 homens e, em média, acima do peso ideal. Além disso, nenhum dos pacientes possuem doenças cardíacas conhecidas, disfunção autonômica, que causa redução do fluxo sanguíneo nos tecidos muscular e conjuntivo, e também não é administrado medicamentos que interfiram na frequência cardíaca.

Tabela A.1: Pacientes do *St Vincent's University Hospital*, Dublin.

Paciente	Altura (cm)	Peso (kg)	Gênero	Hora de Início	AHI	IMC	Idade	Escala de Sonolência de <i>Eppworth</i>	Duração da PSG (h)	Eficiência do Sono (%)
1	172	100,3	M	0:11:04	23	33,9	54	16	6,2	84
2	179	102	M	23:07:50	51	31,8	48	13	7,3	81
3	176	100,4	M	23:28:42	13	32,4	65	19	6,9	63
4	185	103,5	M	23:57:14	31	30,2	52	3	6,7	89
5	183	84	M	23:30:22	12	25,1	47	15	6,8	90
6	145	59,8	F	23:29:11	5	28,4	63	1	6,4	64
7	180	101,5	M	22:35:22	12	31,3	52	19	7,7	80
8	174	119	M	22:51:18	34	39,3	38	2	7,6	92
9	188	101	M	22:47:38	8	28,6	51	8	7,5	60
10	179	97,5	M	23:23:21	25	30,4	51	16	7,2	85
11	153	80	F	23:44:00	16	34,2	62	10	6,8	61
12	177	91	M	23:37:59	36	29	56	5	6,4	79
13	170	83,9	M	23:02:45	6	29	28	2	7,6	77
14	176	117	M	23:16:05	12	37,8	53	7	6,6	87
15	171	77	M	23:49:02	2	26,3	35	10	6,8	60
16	178	97,8	M	23:30:33	16	30,9	49	18	7,1	92
17	179	108,8	M	23:48:21	15	34	52	11	6,3	78
18	161	87	F	22:52:05	13	33,6	41	13	7,6	82
19	166	80,7	M	23:35:05	7	29,3	34	4	6,6	58
20	165	89	F	22:55:51	39	32,7	68	13	7,2	67
21	172	99,9	M	22:58:02	24	33,8	54	19	7,6	83
22	174	128,6	M	0:25:37	91	42,5	52	24	5,9	77
23	175	84	M	22:58:13	14	27,4	49	9	7	87
24	182	93	M	22:56:30	55	28,1	45	10	7,4	86
25	172	88,9	M	0:29:08	46	30,1	50	13	6	68



## B INTERFACE DO NEURAL NETWORK TOOLBOX

Este apêndice é destinado à apresentação da interface do *Neural Network Toolbox*, servindo de suporte ao conceitos desenvolvidos no Capítulo 3 e para a implementação e obtenção dos resultados, do Capítulo 5.

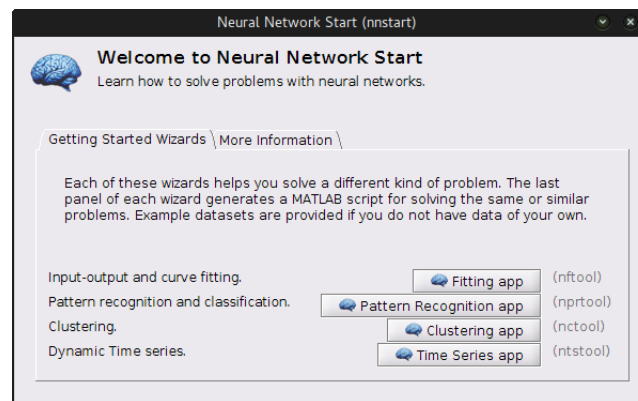


Figura B.1: Tela inicial do *Neural Network Toolbox*: `nnstart`.

No que segue, apresentaremos as diversas etapas do aplicativo para o Reconhecimento de Padrões (*Pattern Recognition app*, segundo aplicativo disponível na tela acima).

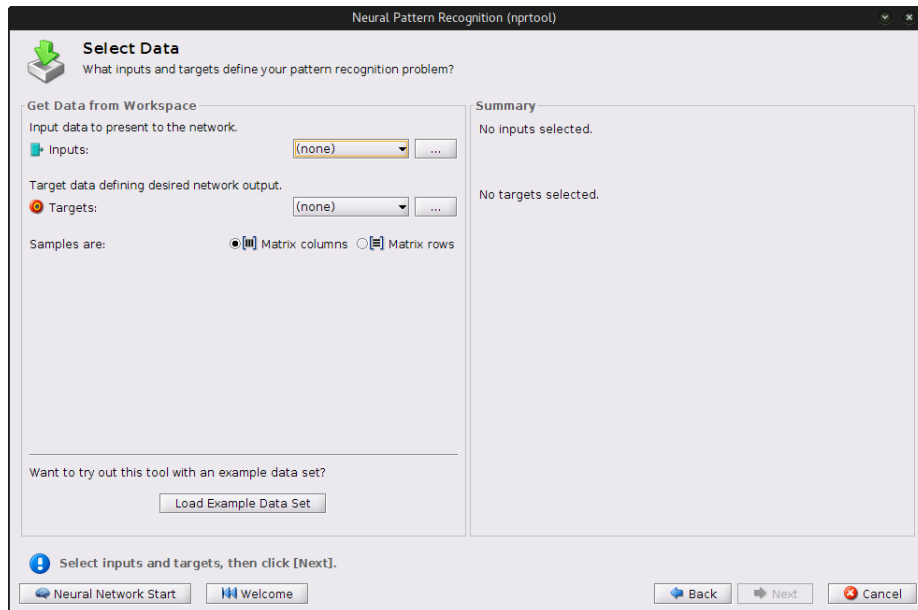


Figura B.2: Janela de entrada de dados para reconhecimento de padrões utilizando treinamento supervisionado, onde *Input* é a matriz de características extraídas do sinal e *Target*, a respectiva classificação correta.

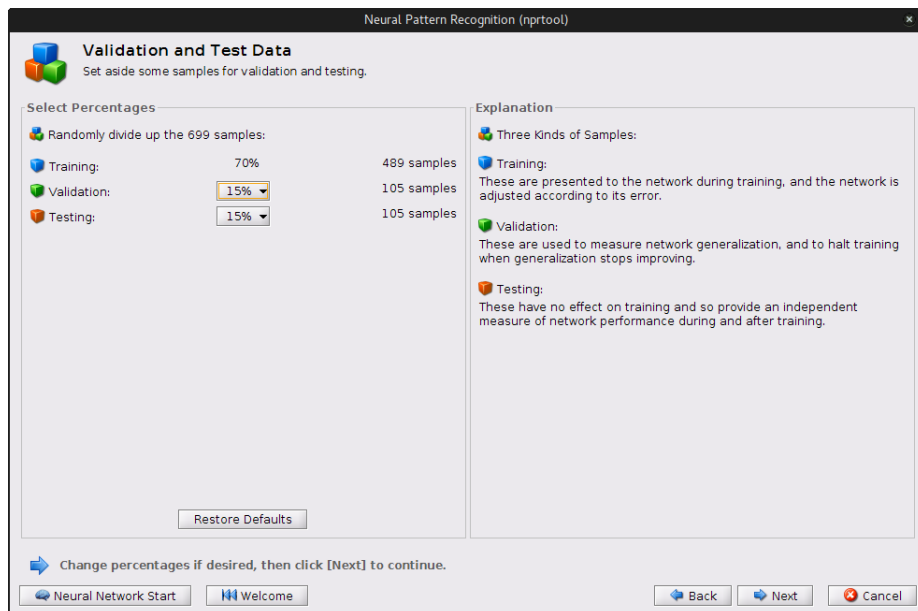


Figura B.3: Definição do percentual de dados que servirão para compor o conjunto de treinamento, validação e teste estabelecidos aleatoriamente (*Random data division*): neste caso, escolhemos 15% para validação e 15% para os testes, restando 70% para o treinamento. Observe, no lado direito, o número de amostras correspondentes, calculado pelo MATLAB.

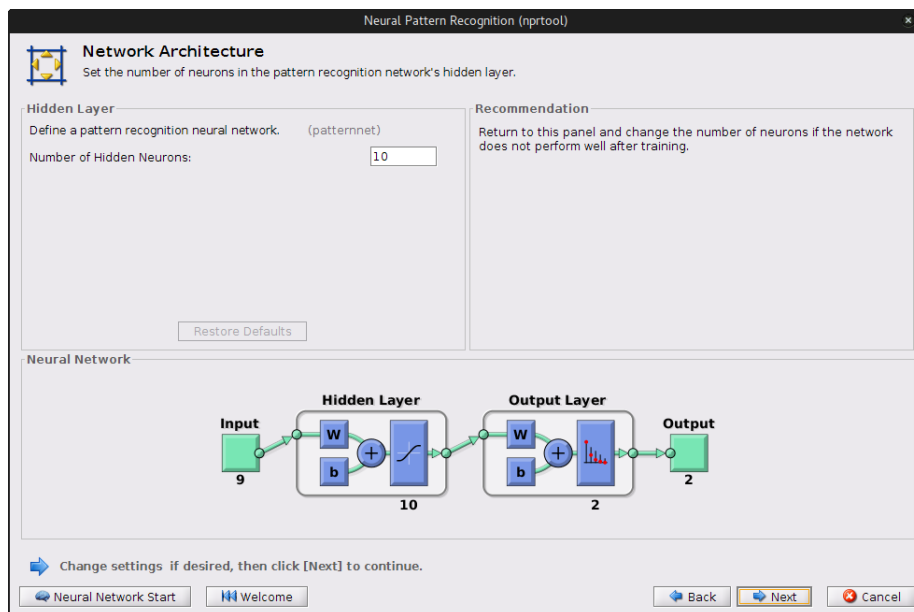


Figura B.4: Topologia da Rede Neural: definição do número de neurônios utilizados na Camada Escondida (*Hidden Layer*). Neste caso, escolhemos 10 neurônios na camada escondida.

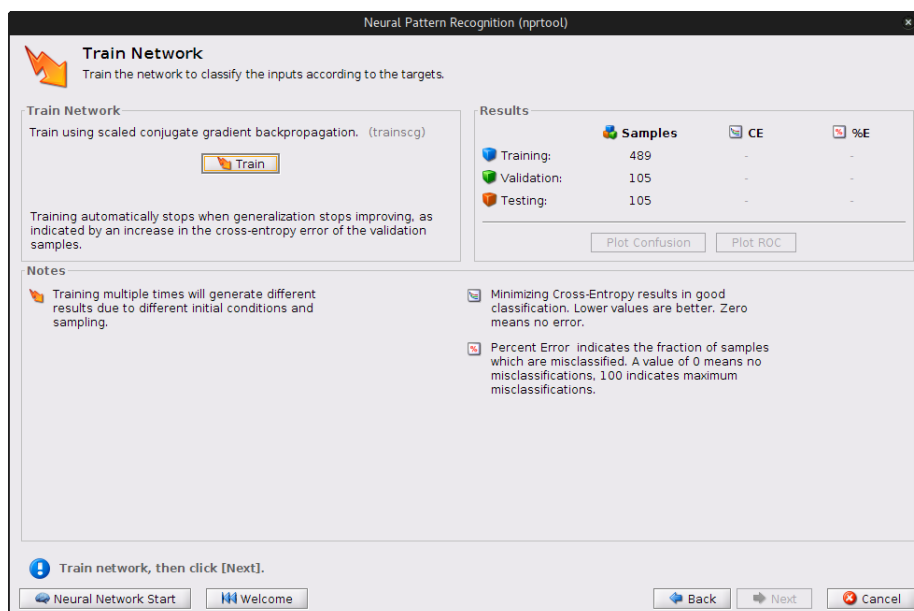


Figura B.5: Janela de treinamento da Rede Neural, utilizando o algoritmo *default trainscg*, baseado na Subseção 3.3.1.

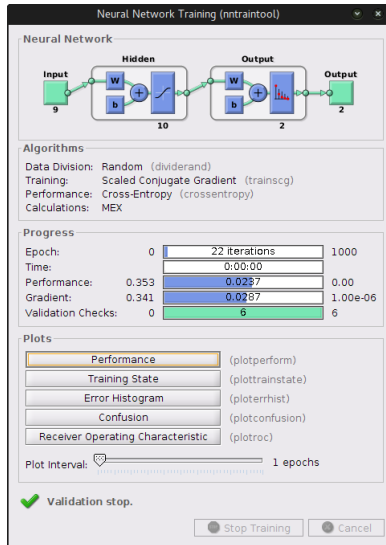


Figura B.6: Janela de treinamento dos dados `ntraintool`: na parte superior mostra a topologia da Rede Neural, seguido pelos algoritmos de treinamento e parâmetros de parada que evitam o *overfitting*. Na parte inferior há possibilidade de acompanhar, durante o treinamento, os gráficos de performance, treinamento, histograma do erro, matriz de confusão e ROC (*Receiver Operating Characteristic*).

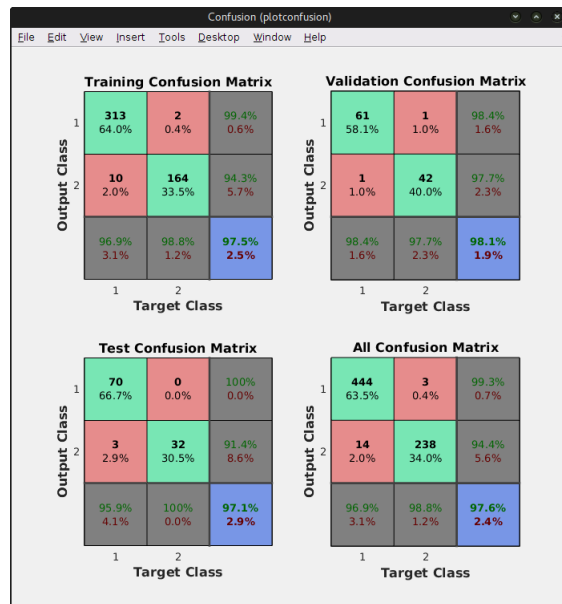


Figura B.7: Matriz de confusão (`plotconfusion`): mostra o resultado do treinamento, validação, teste e todos os resultados em quantidade de dados e percentuais. É possível observar as estatísticas de performance do algoritmo na linha inferior e na coluna mais a direita de cada matriz, onde as posições (3,1), (3,2) e (3,3) fornecem a especificidade, a sensibilidade e a acurácia.

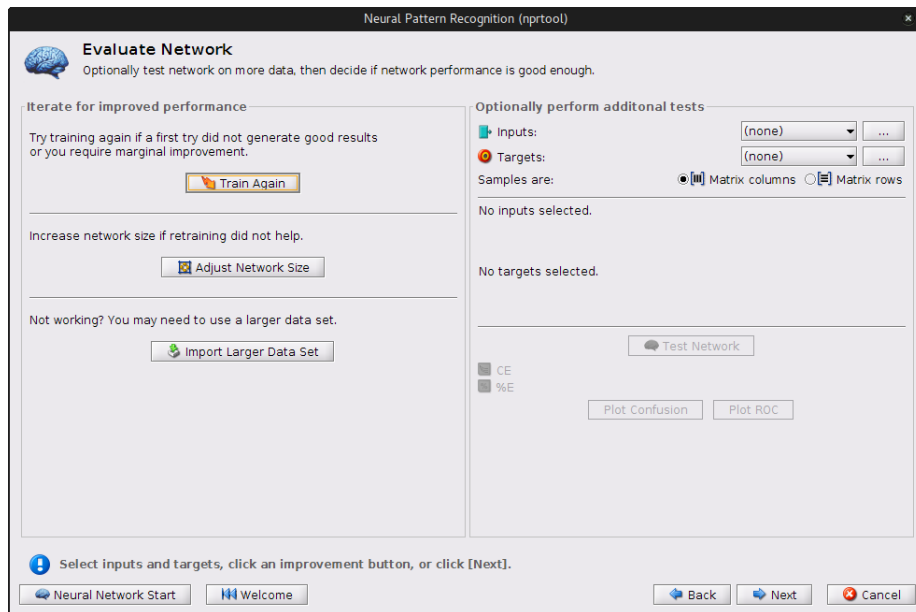


Figura B.8: Janela de avaliação e tentativa de melhora da performance: no lado esquerdo, possibilidade de realizar novo treinamento, mudar a topologia da Rede Neural ou importar um banco de dados maior; no lado direito, possibilidade de realizar testes adicionais.

