

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA**

**DETECÇÃO DO ESTADO DE
SONOLÊNCIA VIA UM ÚNICO CANAL
DE ELETROENCEFALOGRAFIA
ATRAVÉS DA TRANSFORMADA
WAVELET DISCRETA**

DISSERTAÇÃO DE MESTRADO

Tiago da Silveira

Santa Maria, RS, Brasil

2012

**DETECÇÃO DO ESTADO DE SONOLÊNCIA VIA UM
ÚNICO CANAL DE ELETROENCEFALOGRAFIA
ATRAVÉS DA TRANSFORMADA WAVELET DISCRETA**

Tiago da Silveira

Dissertação apresentada ao Curso de Mestrado do Programa de Pós-Graduação
em Informática da Universidade Federal de Santa Maria (UFSM, RS), como
requisito parcial para obtenção do grau de
Mestre em Ciência da Computação

Orientador: Prof^a. Dra. Alice de Jesus Kozakevicius

Co-orientador: Prof. Dr. Cesar Ramos Rodrigues

Santa Maria, RS, Brasil

2012

Ficha catalográfica elaborada através do Programa de Geração Automática da Biblioteca Central da UFSM, com os dados fornecidos pelo(a) autor(a).

da Silveira, Tiago

DETECÇÃO DO ESTADO DE SONOLÊNCIA VIA UM ÚNICO CANAL DE ELETROENCEFALOGRAFIA ATRAVÉS DA TRANSFORMADA WAVELET DISCRETA / Tiago da Silveira.-2012.

140 p.; 30cm

Orientadora: Alice de Jesus Kozakevicius

Coorientador: Cesar Ramos Rodrigues

Dissertação (mestrado) - Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós-Graduação em Informática, RS, 2012

1. Sinal cerebral 2. Detecção de sonolência 3. Transformada de Fourier 4. Transformada Wavelet 5. Melhor aproximação por m-termos I. Kozakevicius, Alice de Jesus II. Rodrigues, Cesar Ramos III. Título.

**Universidade Federal de Santa Maria
Centro de Tecnologia
Programa de Pós-Graduação em Informática**

A Comissão Examinadora, abaixo assinada,
aprova a Dissertação de Mestrado

**DETECÇÃO DO ESTADO DE SONOLÊNCIA VIA UM ÚNICO CANAL
DE ELETROENCEFALOGRAFIA ATRAVÉS DA TRANSFORMADA
WAVELET DISCRETA**

elaborada por
Tiago da Silveira

como requisito parcial para obtenção do grau de
Mestre em Ciência da Computação

COMISSÃO EXAMINADORA:

Alice de Jesus Kozakevicius, Dra.
(Presidente/Orientador)

Cesar Ramos Rodrigues, Dr.
(Coorientador)

Luis Carlos de Castro Santos, Dr. (USP)

Giovani Baratto, Dr. (UFSM)

Santa Maria, 20 de Junho de 2012.

Ao benefício de todos...

AGRADECIMENTOS

Em especial, agradeço à minha família que, mesmo algumas vezes à distância, consegue sempre se fazer presente e me dar suporte, apoio e conforto.

Aos meus professores orientadores, Dra. Alice Kozakevicius e Dr. Cesar Rodrigues, agradeço imensamente tantas oportunidades de crescimento e aprendizagem. Pela confiança, paciência, incentivo, orientação, conselhos e, principalmente, pela amizade.

Aos professores Dr. José Manuel Fonseca e Dr. André Mora, da Universidade Nova de Lisboa, pela oportunidade de trabalharmos juntos e por ter sido tão bem recebido em Portugal. Ao Dr. Arnaldo Batista, por ceder gentilmente os sinais que foram utilizados no projeto e contribuir com materiais e softwares para esta pesquisa.

Aos amigos: Guilherme Perin, pelo incentivo a ingressar no PPGI; Taimur Rabuske, pelo companheirismo nas viagens e pelo coleguismo durante todo o curso; Deise Vasconcelos, pela partilha de todos os momentos acadêmicos; aos companheiros lusitanos Márcio Lopes, Rogério Rosa, Steffen Schuetz e a todos os Erasmus e moradores do RUFS, agradeço o convívio e os bons momentos de viagens e descontração.

Aos colegas do Serpro e RFB, em especial Leandro Viero, Grasiela Peccini, Gilberto Bitencourt e Edison Quaiatto, agradeço a amizade e o apoio constante em todas as etapas deste trabalho. Aos colegas José Volpatto e Clarice Araujo, pelo incentivo.

Ainda, à Profa. MSc. Alessandra Bertolazi pelos esclarecimentos sobre sinais de EEG e ao Coordenador do PPGI, Prof. Dr. Eduardo Piveta, pela disposição em resolver qualquer problema.

Aos colegas e professores do Gmicro, pelo convívio e trocas de experiências. Ao CNPq, pelo suporte financeiro durante o treinamento no exterior.

Agradeço aos muitos colegas, amigos e profissionais, não citados diretamente mas que estiveram comigo no decorrer deste trabalho e que, de uma forma ou de outra, colaboraram e tornaram possível este resultado. Por fim, aos pacientes que, graças ao seu sono, possibilitaram a realização deste estudo.

"If the human brain was simple enough for us to understand, we would still be so stupid that we couldn't understand it"
— JOSTEIN GAARDER, SOPHIE'S WORLD

RESUMO

Dissertação de Mestrado
Programa de Pós-Graduação em Informática
Universidade Federal de Santa Maria

DETECÇÃO DO ESTADO DE SONOLÊNCIA VIA UM ÚNICO CANAL DE ELETROENCEFALOGRAFIA ATRAVÉS DA TRANSFORMADA WAVELET DISCRETA

AUTOR: TIAGO DA SILVEIRA
ORIENTADOR: ALICE DE JESUS KOZAKEVICIUS
CO-ORIENTADOR: CESAR RAMOS RODRIGUES
Local da Defesa e Data: Santa Maria, 20 de Junho de 2012.

A sonolência diurna em motoristas, principal consequência da privação de sono, tem sido a causa de diversos acidentes graves de trânsito. Neste contexto, a utilização de dispositivos que alertem o condutor ao detectar automaticamente o estado de sonolência é uma alternativa para a minimização deste problema. Neste trabalho, duas novas metodologias para a detecção automática da sonolência são apresentadas, utilizando um único canal de eletroencefalografia para a obtenção do sinal: (i) detecção da sonolência via melhor aproximação por m-termos, aplicada aos coeficientes wavelets da expansão em série do sinal; e (ii) detecção da sonolência via distância de Mahalanobis e coeficientes wavelets. Os resultados de ambas as metodologias são comparados a uma implementação utilizando distância de Mahalanobis e coeficientes de Fourier. Para todas as metodologias, utiliza-se como referência a avaliação médica do sinal cerebral, dada pelo hipnograma.

Palavras-chave: Sinal cerebral, Sonolência, Transformada de Fourier, Transformada Wavelet, Detecção de sonolência, Melhor aproximação por m-termos, Distância de Mahalanobis.

ABSTRACT

Master's Dissertation
Post-Graduate Program in Informatics
Federal University of Santa Maria

DROWSINESS DETECTION FROM A SINGLE ELECTROENCEPHALOGRAPHY CHANNEL THROUGH DISCRETE WAVELET TRANSFORM

AUTHOR: TIAGO DA SILVEIRA

ADVISOR: ALICE DE JESUS KOZAKEVICIUS

COADVISOR: CESAR RAMOS RODRIGUES

Defense Place and Date: Santa Maria, Jun 20th, 2012.

Many fatal traffic accidents are caused by fatigued and drowsy drivers. In this context, automatic drowsiness detection devices are an alternative to minimize this issue. In this work, two new methodologies to drowsiness detection are presented, considering a signal obtained from a single electroencephalography channel: (i) drowsiness detection through best m-term approximation, applied to the wavelet expansion of the analysed signal; (ii) drowsiness detection through Mahalanobis distance with wavelet coefficients. The results of both methodologies are compared with a method which uses Mahalanobis distance and Fourier coefficients to drowsiness detection. All methodologies consider the medical evaluation of the brain signal, given by the hypnogram, as a reference.

Keywords: Brain signals, Drowsiness, Fourier Transform, Wavelet Transform, Drowsiness detection, Best m-term approximation, Mahalanobis Distance.

LISTA DE FIGURAS

2.1	Hidratação de íons. (a) Molécula de <i>NaCl</i> e sua polaridade; (b) Molécula de <i>H₂O</i> e sua polaridade; (c) Início do processo de hidratação; (d) Íons hidratados. (Fonte: http://educacao.uol.com.br)	26
2.2	Neurônio e suas sinapses (Fonte: http://marciocandiani.site.med.br).	28
2.3	Variação do potencial elétrico da membrana durante a ocorrência de um potencial de ação. Em (1) e (2), despolarização; (3) equilíbrio eletroquímico; (4) a (6) repolarização.	30
2.4	As principais camadas cerebrais e suas respectivas resistividades e espessuras. (Fonte: adaptado de (SANCI; CHAMBERS, 2007))	33
2.5	Principais ritmos cerebrais associados ao sono. Em (a), ritmo beta; (b) três diferentes sinais com ritmo alfa; (c) ritmo teta e (d) ritmo delta. Adaptado de (MALMIVUO; PLONSEY, 1995).	35
2.6	Diagrama do esquema 10-20 para posicionamento de eletrodos, incluindo as posições de referência (N_z , I_z , A_1 , A_2). Em (a) e (b), visão tridimensional para posicionamento de 21 eletrodos. Em (c), visão bidimensional do posicionamento de 75 eletrodos. (SANCI; CHAMBERS, 2007)	38
2.7	Impacto do artefato causado pelo piscar dos olhos, no intervalo entre as amostras 800 a 1200, em sinais de 4 canais de EEG distintos. Adaptado de (SANCI; CHAMBERS, 2007).	39
2.8	Sinal de EEG para diferentes fases do sono: (a) vigília com atividade de concentração; (b) vigília, relaxado e de olhos fechados; (c) estágio N1; (d) estágio N2; (e) estágio N3; (f) estágio N4; (g) estágio REM.....	44
3.1	Características das janelas de Hamming e Blackman. Em (a) as formas de onda das duas janelas, para um comprimento de 50 amostras; em (b) a resposta em frequência para cada janela em relação à frequência de amostragem. Adaptado de (SMITH, 2002).	52
3.2	Sinal de EEG de um indivíduo apresentando sonolência (PhysioNet, paciente sc4002, época 859, amostrado a 100Hz). (a) Representação do sinal no tempo; (b) Espectrograma do sinal via STFT, utilizando janela de Hamming de 512 pontos; (c) Escalograma do sinal via TWC utilizando a wavelet de Meyer (no eixo das ordenadas estão representadas as escalas na forma α^{-1}).	55
3.3	Exemplo de análise multirresolução: (a) representação de um sinal discreto em 4 níveis de resolução, considerando o nível mais refinado com 16 pontos e espaçamento $h = 1/8$, e o nível mais grosso com 2 pontos e espaçamento $h = 1$. (b) Representação das malhas diádicas de cada um dos níveis da multirresolução considerados. (c) Posições complementares entre os níveis 3,2,1 e 0 da multirresolução.	57
3.4	Estrutura em árvore da análise multirresolução. Do nível mais fino (J), à esquerda, ao nível mais grosso (J_0), à direita.	60
3.5	Wavelet DB2. (a) Função escala $\phi(t)$; (b) Função wavelet $\psi(t)$	62

3.6	TWD do sinal de EEG de um indivíduo apresentando sonolência (PhysioNet, paciente sc4002, época 859, amostrado a 100Hz). (a) Sinal EEG original com $N = 4096$ elementos; (b) a (h) coeficientes wavelets para os níveis $j = 11, 10, \dots, 5$; (i) coeficientes de escala do último nível, $J_0 = 6$.. .	65
3.7	Decomposição de um sinal f_i discreto em 3 níveis da TWD. A ilustração evidencia a convolução com os filtros e as operações de <i>downsampling</i> – decimação ou redução do tamanho do vetor à metade.	67
3.8	Plano de fase tempo-frequência, apresentando as caixas de Heisenberg com diferentes centros e resoluções.	68
3.9	Comparação entre resoluções tempo-frequência: (a) STFT; (b) TWD.....	70
3.10	Wavelet DB2 (em azul) e harmônica pura com a frequência central aproximada (em vermelho).	71
3.11	Especro de frequência da wavelet DB2, $f_s = 100$ Hz, para os níveis: j4 (vermelho), j5 (verde), j6 (azul), j7 (violeta), j8 (preto) e j9 (amarelo).	73
4.1	Visão geral de um processo de classificação.....	74
4.2	Melhor aproximação por m -termos aplicada a um sinal de componentes harmônicas de 5Hz e 20Hz. Em (a) $f(t)$ em preto, $p(t)$ em azul; (b) representação esparsa dos coeficientes significativos; (c) espectro de frequências de $f(t)$; (d) espectro de frequências de $p(t)$	77
4.3	Melhor aproximação por m -termos aplicada a um sinal EEG. Em (a) $f(t)$ em preto, $p(t)$ em azul; (b) representação esparsa dos coeficientes significativos.	78
4.4	Fluxograma do algoritmo para detecção de sonolência via melhor aproximação por m -termos.	81
4.5	Classificação da sonolência via melhor aproximação por m -termos ($m = 400$). Definição das classes ALERTA (vermelho) e SONOLÊNCIA (azul), conforme parâmetros representados nos eixos. Classificação do hipnograma: ALERTA (quadrados em vermelho) e SONOLÊNCIA (círculos em verde).	81
4.6	Representação gráfica da distância de Mahalanobis. Em (a) os círculos representam equidistâncias euclidianas em relação ao ponto central. Em (b) as elipses representam equidistâncias de Mahalanobis em relação ao ponto central (De Maesschalck; JOUAN-RIMBAUD; MASSART, 2000)....	84
4.7	Fluxograma do algoritmo para detecção de sonolência utilizando distância de Mahalanobis e coeficientes de Fourier (LIN et al., 2010).	85
4.8	Fluxograma do algoritmo para detecção de sonolência utilizando distância de Mahalanobis e coeficientes wavelets.	88
5.1	Detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 01. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.	94
5.2	Continuação: detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 01. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.	95

5.3	Detecção da sonolência via melhor aproximação por m -termos ($m=400$), aplicada às épocas distintas dos sinais do Paciente 01. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.....	96
5.4	Detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 02. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.	97
5.5	Detecção da sonolência via melhor aproximação por m -termos ($m=400$), aplicada às épocas distintas dos sinais do Paciente 02. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.....	98
5.6	Detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 03. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.	99
5.7	Detecção da sonolência via melhor aproximação por m -termos ($m=400$), aplicada às épocas distintas dos sinais do Paciente 03. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.....	100
5.8	Detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 04. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.	101
5.9	Continuação: detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 04. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.	102
5.10	Detecção da sonolência via melhor aproximação por m -termos ($m=400$), aplicada às épocas distintas dos sinais do Paciente 04. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.....	103
5.11	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 01. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada para cada época.	104
5.12	Continuação: detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 01. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada para cada época.	105
5.13	Continuação: detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 01. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada para cada época.	106
5.14	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 02. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada em cada época.	107

5.15	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 03. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada em cada época.	108
5.16	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 04. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada em cada época.	109
5.17	Continuação: detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 04. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada em cada época.	110
5.18	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 01. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.	112
5.19	Continuação: detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 01. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.	113
5.20	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 02. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.	115
5.21	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 03. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.	116
5.22	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 04. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.	118
5.23	Continuação: detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 04. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.	119
A.1	Wavelet de Meyer. Em (a) transformada de Fourier da função escala da base de Meyer; em (b) transformada de Fourier da wavelet de Meyer; em (c) forma de onda da wavelet de Meyer. Adaptado de (LEE; YAMAMOTO, 1994).	129
C.1	Interface gráfica desenvolvida em Matlab para seleção de épocas em um sinal cerebral no formato de arquivo EDF.	135
C.2	Base de treinamento: relação com as épocas da base PhysioNet.	136
C.3	Base de testes, Paciente 01: relação com as épocas da base PhysioNet.	137
C.4	Base de testes, Pacientes 02 e 03: relação com as épocas da base PhysioNet.	138
C.5	Base de testes, Paciente 04: relação com as épocas da base PhysioNet.	139

LISTA DE TABELAS

2.1	Concentração média dos principais íons inorgânicos nos meios intra e extracelular	29
3.1	Coeficientes de filtro da Wavelet DB2.	62
3.2	Relação entre escala e frequência na TWC: pseudo-frequências da wavelet de Meyer ($f_c = 0.6902$ Hz; $f_s = 100$ Hz).....	71
3.3	Relação entre escala, níveis de resolução e frequência na TWD: pseudo-frequências da wavelet DB2 ($f_c = 0.6667$ Hz; $f_s = 100$ Hz).....	72
4.1	Relação entre o ritmo cerebral e o nível da AMR (DB2, $f_s = 100$ Hz).	79
5.1	Banco de validação para a distância de Mahalanobis: número total de épocas em cada estado cognitivo, por paciente, considerando a ocorrência de uma mesma época em diferentes sinais.	91
5.2	Banco de validação para a melhor aproximação por m -termos: número de épocas distintas em cada estado cognitivo.....	91
5.3	Banco de validação contendo 32 segmentos de sinais, provenientes de 4 pacientes da base PhysioNet.	92
5.4	Resultado da detecção de sonolência via melhor aproximação por m -termos no Paciente 01: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pela melhor aproximação e a taxa de acerto do método.	96
5.5	Resultado da detecção de sonolência via melhor aproximação por m -termos no Paciente 02: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pela melhor aproximação e a taxa de acerto do método.	98
5.6	Resultado da detecção de sonolência via melhor aproximação por m -termos no Paciente 03: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pela melhor aproximação e a taxa de acerto do método.	100
5.7	Resultado da detecção de sonolência via melhor aproximação por m -termos no Paciente 04: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pela melhor aproximação e a taxa de acerto do método.	103
5.8	Detecção da sonolência via distância de Mahalanobis com coeficientes de Fourier no Paciente 02: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.	106
5.9	Detecção da sonolência via distância de Mahalanobis com coeficientes de Fourier no Paciente 02: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.	107

5.10	Detecção da sonolência via distância de Mahalanobis com coeficientes de Fourier no Paciente 03: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.	108
5.11	Resultado da detecção de sonolência via distância de Mahalanobis com coeficientes de Fourier, aplicada aos sinais do Paciente 04.	111
5.12	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets no Paciente 01: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.	114
5.13	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets no Paciente 02: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.	115
5.14	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets no Paciente 03: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.	117
5.15	Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets no Paciente 04: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.	119
5.16	Detecção da sonolência via melhor aproximação por m -termos. Para cada paciente, nos estados alerta e de sonolência, é apresentado o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.	120
5.17	Detecção da sonolência via distância de Mahalanobis com coeficientes de Fourier. Para cada paciente, nos estados alerta e de sonolência, é apresentado o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.	120
5.18	Detecção da sonolência via distância de Mahalanobis com coeficientes wavelets. Para cada paciente, nos estados alerta e de sonolência, é apresentado o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.	120
5.19	Percentual de épocas detectadas por grupo, de acordo com a metodologia utilizada.	121

LISTA DE ABREVIATURAS E SIGLAS

ADC	<i>Analog to Digital Converter</i>
AMR	Análise Multirresolução
ATP	Adenosina Tri-Fosfática
BCI	<i>Brain Computer Interface</i>
ECG	Eletrocardiograma
EDF	<i>European Data Format</i>
EEG	Eletroencefalograma, Eletroencefalografia
EOG	Eletro-oculograma
EMG	Eletromiograma
EPSP	<i>Excitatory PostSynaptic Potential</i>
FFT	<i>Fast Fourier Transform</i>
FIR	<i>Finite Impulse Response</i>
IPSP	<i>Inibitory PostSynaptic Potential</i>
MD	<i>Mahalanobis Distance</i>
NREM	<i>Non-Rapid Eye Moviment</i>
REM	<i>Rapid Eye Moviment</i>
STFT	<i>Short-Time Fourier Transform</i>
TWC	Transformada Wavelet Contínua
TWD	Transformada Wavelet Discreta
<td>Transformada Wavelet Inversa</td>	Transformada Wavelet Inversa

LISTA DE SÍMBOLOS

c_k	coeficiente de Fourier para frequência k , $k \in [0, \pi]$
$c_{j,l}$	coeficiente wavelet de aproximação ou escala
$d_{j,l}$	coeficiente wavelet de diferença
J	nível máximo da transformada wavelet multirresolução
J_0	nível mínimo da transformada wavelet multirresolução
i	raíz quadrada de (-1)
j	fator de escala discreto da função wavelet
k	fator de translação discreto da função wavelet
h_k	coeficiente de filtro da função escala
g_k	coeficiente de filtro da função wavelet
α	escala da wavelet contínua $\psi(t)$
τ	deslocamento (translação) da wavelet contínua $\psi(t)$
$W_{f(\alpha,\tau)}$	transformada wavelet contínua de $f(t)$ através da wavelet $\psi_{\alpha,\tau}(t)$
$\psi(t)$	wavelet geradora ou wavelet-mãe
$\psi_{\alpha,\tau}$	wavelet gerada através do escalonamento de $\psi(t)$ por um fator α e por uma translação τ
C_ψ	condição de admissibilidade da wavelet $\psi(t)$
$f(t)$	sinal contínuo no tempo
$\hat{f}(\omega)$	transformada de Fourier do sinal $f(t)$
$B_m(\cdot)$	operador para o <i>best m-term approximation</i> , com m coeficientes significativos

SUMÁRIO

1 INTRODUÇÃO	20
1.1 Motivação	20
1.2 Estado da arte e proposta do trabalho	21
1.3 Estrutura.....	23
2 SINAIS CEREBRAIS E SONOLÊNCIA	25
2.1 Bioeletricidade	25
2.2 Neurofisiologia	27
2.2.1 O neurônio	27
2.2.2 Potencial elétrico nas células	28
2.2.3 Potencial de ação	30
2.2.4 Sinapses	31
2.3 Eletroencefalografia - EEG	32
2.3.1 Ritmos de atividade cerebral	34
2.3.2 Aquisição e gravação do EEG	36
2.4 Fisiologia do sono.....	41
2.4.1 Detecção da sonolência	44
3 REPRESENTAÇÕES: TEMPO-FREQUÊNCIA E TEMPO-ESCALA	46
3.1 Representação e transformadas de sinais	47
3.2 Transformada de Fourier	50
3.2.1 STFT - Short Time Fourier Transform	51
3.3 Transformada Wavelet Contínua - TWC	53
3.4 Transformada Wavelet Discreta - TWD.....	56
3.4.1 Análise multirresolução – AMR	56
3.4.2 Wavelets ortonormais de Daubechies: Db	59
3.4.3 Propriedades da família de wavelets Db	60
3.4.4 Transformada Wavelet Rápida.....	62
3.4.5 Implementação via bancos de filtros	65
3.5 Análise tempo-frequência	68
3.5.1 Princípio de Heisenberg	69
3.5.2 Relação entre escala e frequência	70
4 PROCESSAMENTO DE SINAIS CEREBRAIS	74
4.1 Visão geral do processo de detecção da sonolência	74
4.2 Melhor aproximação por m-termos	75
4.2.1 Caracterização da sonolência através da TWD	77
4.2.2 Detecção da sonolência via melhor aproximação por m-termos.....	79
4.3 Distância de Mahalanobis (MD)	82
4.3.1 Detecção da sonolência via MD e coeficientes de Fourier	84
4.3.2 Detecção de sonolência via MD e coeficientes wavelet	87

5 DISCUSSÃO E RESULTADOS	90
5.1 Descrição da base de dados utilizada e classificação médica	90
5.2 Detecção via melhor aproximação por <i>m</i>-termos	93
5.2.1 Paciente 01.....	93
5.2.2 Paciente 02.....	97
5.2.3 Paciente 03.....	98
5.2.4 Paciente 04.....	101
5.3 Distância de Mahalanobis utilizando coeficientes de Fourier	104
5.3.1 Paciente 01.....	104
5.3.2 Paciente 02.....	106
5.3.3 Paciente 03.....	108
5.3.4 Paciente 04.....	109
5.4 Distância de Mahalanobis utilizando coeficientes wavelet	111
5.4.1 Paciente 01.....	112
5.4.2 Paciente 02.....	114
5.4.3 Paciente 03.....	116
5.4.4 Paciente 04.....	117
5.5 Análise comparativa	120
6 CONCLUSÃO	122
6.1 Contribuições ao tema estudado	123
6.2 Trabalhos futuros	123
REFERÊNCIAS	124
APÊNDICE A WAVELET DE MEYER	129
APÊNDICE B CÓDIGOS FONTE	130
B.1 Biblioteca para Transformada Wavelet Discreta: tsDWT	130
B.2 Bancos de filtros	133
B.2.1 Wavelet DB1 (Haar)	133
B.2.2 Wavelet DB2	133
B.2.3 Wavelet DB3	133
B.2.4 Wavelet DB4	134
APÊNDICE C SELEÇÃO DOS SINAIS DA BASE DE DADOS PHYSIONET	135
APÊNDICE D RESUMOS ACEITOS PARA PUBLICAÇÃO	140

1 INTRODUÇÃO

No Brasil, de acordo com os dados publicados pelo Departamento de Polícia Rodoviária Federal (DPRF, 2011), a sonolência foi causa direta de 3.367 acidentes de trânsito apenas em rodovias federais, no ano de 2007. No panorama mundial a situação não é diferente: de acordo com o relatório de 2005 da Fundação Nacional do Sono, dos Estados Unidos, 60% dos motoristas afirmaram já terem sentido sonolência enquanto dirigiam, enquanto 37% afirmaram terem realmente dormido na direção do veículo (NSF, 2012).

A Administração Nacional de Segurança no Trânsito (*National Highway Traffic Safety Administration*, Estados Unidos), estima que 100.000 ocorrências policiais envolvendo acidentes de trânsito sejam registradas, por ano, decorrente de sonolência em motoristas. Segundo (JOHNSON et al., 2011), estudos indicam que até 30% dos acidentes de trânsito envolvendo vítimas fatais são ocasionados por motoristas sonolentos.

É difícil estimar com precisão o número de acidentes de trânsito decorrentes de fadiga e sonolência em motoristas: ao contrário de acidentes envolvendo drogas ou álcool, onde há sinais fisiológicos no indivíduo para embasar a perícia, após um acidente causado por sonolência a vítima geralmente encontra-se agitada, eliminando qualquer vestígio da provável causa do acidente (NHTSA, 2012).

Estudos mostram que acidentes de tráfego ocasionados por sonolência possuem as seguintes características (NHTSA, 2012): (i) ocorre geralmente em períodos noturnos, após a meia-noite, ou após o meio-dia, em menor número; (ii) possuem uma alta taxa de mortalidade; (iii) o veículo abandona a rodovia e o condutor não apresenta sinais de embriaguez; (iv) o condutor não demonstra tentativas de ter evitado o acidente; (v) o condutor está sozinho no veículo.

Segundo (FOURNIER; MONTREUIL; BRUN, 2007), a sonolência deve ser encarada como um problema de saúde pública e métodos devem ser desenvolvidos para evitá-la. Neste contexto, este trabalho busca apresentar alternativas para a detecção automática da sonolência em motoristas, de maneira a contribuir com a investigação e solução deste problema.

1.1 Motivação

De acordo com (PICOT; CHARBONNIER; CAPLIER, 2011), sistemas automáticos para detecção de sonolência em motoristas podem ser construídos através de duas abordagens: (i) orientado ao veículo, quando medidas tais como a posição do automóvel na estrada e sua ve-

locidade, movimentos e força aplicada à direção, entre outras, são utilizadas para avaliar o comportamento do motorista; (ii) orientado ao condutor, quando a sonolência é detectada através de informações fisiológicas do próprio motorista, obtidas por sensores.

A indústria automobilística tem interesse em desenvolver dispositivos de bordo que buscam detectar sinais de sonolência em motoristas, alertando-os através de avisos sonoros ou visuais. Entre as estratégias já utilizadas, destacam-se o monitoramento do desvio de rota do veículo, pressão das mãos no volante e nos pedais, frequência do piscar de olhos e o grau de inclinação da cabeça do condutor.

Embora comercialmente a abordagem orientada ao veículo seja mais comum, (PICOT; CHARBONNIER; CAPLIER, 2011) afirma que dispositivos orientados ao condutor são mais confiáveis, uma vez que a variação de sinais fisiológicos entre indivíduos é menor que a variação de comportamentos subjetivos – tais como as medidas orientadas ao veículo e relacionadas à preferência de cada motorista.

Considerando-se que o processo de sonolência dá-se através do córtex cerebral, supõe-se que o fenômeno possa ser melhor detectado através de sinais cerebrais. No estado da arte atual, a eletroencefalografia mostra-se como uma ferramenta de melhor custo-benefício, avaliando-se a disponibilidade do equipamento, a característica não-invasiva e a precisão de suas medidas. Contudo, a sonolência ainda não é um processo fisiológico compreendido em sua totalidade e a medição de sinais cerebrais é sujeita a ruídos e interferências que devem ser tratados adequadamente na implementação de sistemas deste tipo.

1.2 Estado da arte e proposta do trabalho

Embora o método tradicional de análise de sinais cerebrais seja a inspeção visual do eletro-encefalograma, nas últimas décadas técnicas de processamento de sinais vêm contribuindo cada vez mais para a melhoria de diagnósticos e análises envolvendo o estudo do sono, epilepsia, influência de drogas e demais patologias neurológicas (BLINOWSKA; DURKA, 2006).

No contexto da sonolência, vários trabalhos têm sido desenvolvidos com o objetivo de identificá-la e caracterizá-la. Entretanto, algumas propostas tornam-se evasivas e ou ineficientes, uma vez que a sonolência está relacionada a complexos fenômenos fisiológicos e psicofisiológicos, tais como motivação, nível de estresse, atividades desenvolvidas, entre outros.

De acordo com (JOHNSON et al., 2011), os principais motivos pela ineficácia de alguns métodos são: falta de generalização nos modelos propostos; falha ao desconsiderar a vari-

abilidade de cada indivíduo na proposta de modelos generalizados; e falta de portabilidade no algoritmo desenvolvido.

Referindo-se aos projetos desenvolvidos com o intuito de identificar automaticamente a sonolência via eletroencefalografia (EEG), (JOHNSON et al., 2011) destaca como pontos fracos: (a) tamanho reduzido de amostras; (b) inexistência de avaliação da variância individual, possível através de validação cruzada de dados, por exemplo; (c) dependência à tarefa executada, especificidade; (d) complexidade no algoritmo.

Segundo (JOHNSON et al., 2011), o EEG é comumente aplicado como o padrão de referência na identificação dos estados cognitivos, em especial da transição entre o estado de vigília e sonolência, quando comparado com sinais EOG, EMG, aquisição de imagens do indivíduo, entre outros.

Do sinal EEG, são extraídas características que por sua vez são classificadas através de diversas estratégias. (BABILONI et al., 2001) apresenta uma metodologia utilizando 4 canais de EEG: os atributos são extraídos através do espectro de Fourier e a classificação é realizada através da distância de Mahalanobis. Trabalho semelhante é realizado em (PAL et al., 2008) e (LIN et al., 2010), que por sua vez utilizam apenas um único canal para o reconhecimento da sonolência. Neste estudo, esta metodologia é implementada utilizando um único canal de EEG, sendo utilizada como referência na comparação dos resultados com as duas novas metodologias propostas.

A distância de Mahalanobis é também utilizada na detecção da sonolência na proposta apresentada por (JOHNSON et al., 2011), onde características comportamentais do indivíduo são utilizadas, juntamente com características extraídas do espectro de Fourier do sinal do EEG,.

Em (PICOT; CHARBONNIER; CAPLIER, 2011), utilizam-se as características dos ritmos alfa e beta de um único canal de EEG de um indivíduo, juntamente com características do sinal EOG, como parâmetros de entrada de um classificador por lógica difusa – uma extensão da lógica booleana que admite valores intermediários entre verdadeiro e falso. Em (PAPADELIS et al., 2006), o espectro de Fourier do sinal EEG, referente aos ritmos cerebrais alfa e gama, é utilizado juntamente com a entropia do sinal medido.

O espectro de Fourier é também utilizado em (EOH; CHUNG; KIM, 2005), onde uma relação entre as componentes nos ritmos alfa, beta e teta é construída de modo a detectar a sonolência. Em (YEO et al., 2009), utilizam-se os coeficientes de Fourier dos ritmos cerebrais alfa, beta, teta e delta como características de entrada de uma máquina de vetores de suporte

para classificação.

Além do espectro de Fourier, as transformadas wavelets têm sido utilizadas como meio de extração de características de um sinal de EEG em aplicações para detecção de sonolência. Em (SUBASI, 2005), a wavelet ortonormal DB2 é utilizada para extrair características do sinal de 8 canais de EEG, classificadas através de uma rede neural. Em (Garces Correa; Laciari Leber, 2010), novamente uma rede neural é treinada para classificar a sonolência através das características extraídas via decomposição wavelet do sinal de 2 canais de EEG, juntamente com características do espectro de Fourier.

Segundo (BLINOWSKA; DURKA, 2006), o estudo de ritmos cerebrais, a identificação de interrupções no sono e o estudo de potenciais relacionados a eventos, são algumas das aplicações nas quais as transformadas wavelets têm sido utilizadas.

Neste estudo, são apresentadas duas novas propostas para a detecção da sonolência, ambas via um único canal de EEG: (i) utilizando a melhor representação por m -termos, onde através da transformada wavelet de um sinal cerebral são selecionados os coeficientes que melhor representam a sonolência; (ii) utilizando a distância de Mahalanobis para classificar os coeficientes da transformada wavelet do sinal cerebral.

As duas metodologias propostas são então comparadas com uma implementação utilizando distância de Mahalanobis e coeficientes de Fourier, também via um único canal de EEG. Todas as metodologias empregadas neste estudo utilizam como referência a classificação do sono dada por especialistas através do hipnograma, uma vez que este é o critério básico para aceitação de um método automático na análise de EEG (BLINOWSKA; DURKA, 2006).

1.3 Estrutura

A revisão teórica sobre os sinais cerebrais e o processo de sonolência é dada no Capítulo 2. Primeiramente, apresenta-se o processo de geração da bioeletricidade, na Seção 2.1. Em seguida, alguns conceitos de neurofisiologia são abordados na Seção 2.2, permitindo a compreensão da geração dos sinais cerebrais. A medição e o registro desses sinais é discutida na Seção 2.3, onde são apresentados os ritmos cerebrais e a padronização para o posicionamento dos eletrodos. O Capítulo 2 é finalizado detalhando-se o processo do sono, na Seção 2.4, com destaque às considerações necessárias à detecção da sonolência, na Seção 2.4.1.

O Capítulo 3 mostra as representações de Fourier e wavelet de um sinal cerebral. A Seção 3.1, apresenta as definições necessárias à representação e expansão de sinais em séries de

funções. Na Seção 3.2, define-se a transformada de Fourier na forma a qual é utilizada neste estudo. A transformada wavelet é apresentada nas formas contínua e discreta nas Seções 3.3 e 3.4, respectivamente. A análise tempo-frequência e sua relação com as escalas são discutidas na Seção 3.5, de fundamental importância para este trabalho.

No Capítulo 4 são apresentadas duas novas propostas para a detecção de sonolência, juntamente com a implementação de uma metodologia de comparação. A Seção 4.2 apresenta a melhor aproximação por m -termos, um dos métodos propostos neste estudo para caracterização e detecção da sonolência. A distância de Mahalanobis é vista na Seção 4.3, onde descreve-se sua implementação para detecção da sonolência através de coeficientes de Fourier e propõe-se sua utilização com coeficientes wavelets.

Os resultados obtidos com os algoritmos desenvolvidos no Capítulo 4 são apresentados e discutidos no Capítulo 5. Os dados da base PhysioNet são utilizados e a seleção destes sinais é descrita na Seção 5.1. Os melhores resultados são evidenciados em uma análise comparativa dos métodos, na Seção 5.5, utilizando como referência o hipnograma de cada sinal.

Por fim, no Capítulo 6, são apresentadas as considerações quanto ao desempenho de cada metodologia proposta, salientando-se as contribuições desta dissertação para o tema da pesquisa e as perspectivas de trabalhos futuros.

2 SINAIS CEREBRAIS E SONOLÊNCIA

A observação e interpretação de sinais biológicos remonta ao início da medicina. Entretanto, foi a partir do início do século XIX que passou-se a considerar alguns sinais de origem eletroquímica, na mesma época em que outras ciências começavam a ser desenvolvidas. O conceito de neurofisiologia foi estabelecido pelos médicos e pesquisadores Carlo Matteucci e Emil Du Bois-Reymond, pioneiros no estudo da bioeletricidade. Mais tarde, em 1875, o inglês Richard Caton faria o primeiro registro de sinais elétricos provenientes da atividade cerebral. Em seguida, o século XX foi marcado por grandes avanços da matemática, física, química, biologia, medicina e engenharia, possibilitando a compreensão desses sinais e o desenvolvimento de equipamentos para medi-los ([SACI; CHAMBERS, 2007](#)).

No que tange aos sinais cerebrais, hoje existem diversos métodos de registro e análise. Eletroencefalogramas (EEG) são obtidos através da medida do campo elétrico na região cerebral por sistemas computadorizados, seja de forma invasiva ou não. Além do EEG, os sinais cerebrais são também comumente mensurados pela magnetoencefalografia ou por ressonância magnética, técnicas estas baseadas em medidas do campo magnético cerebral.

Neste capítulo, alguns conceitos básicos de neurofisiologia são discutidos de modo a contextualizar a ferramenta para análise de sinais EEG a ser desenvolvida. Inicialmente, apresenta-se o processo de geração de sinais bioelétricos por organismos vivos. Aborda-se então a técnica de eletroencefalografia, relatando-se os padrões utilizados na comunidade biomédica para a medida de sinais cerebrais. Por fim, alguns aspectos da fisiologia do sono são apresentados de maneira a dar o aporte necessário ao desenvolvimento de uma ferramenta para detecção de sonolência.

2.1 Bioeletricidade

De acordo com ([MALMIVUO; PLONSEY, 1995](#)), a bioeletricidade pode ser definida como o campo elétrico proveniente de diferentes concentrações de íons entre o interior e o exterior de uma célula. Através deste campo elétrico, uma diferença de potencial é mantida na membrana citoplasmática e a variação do mesmo pode ser propagada na forma de um pulso elétrico: o sinal bioelétrico. A denominação desses sinais é dada de acordo com a região do corpo onde ocorrem, sendo denominado sinal cerebral todo o sinal bioelétrico proveniente de atividade neuronal no encéfalo humano.

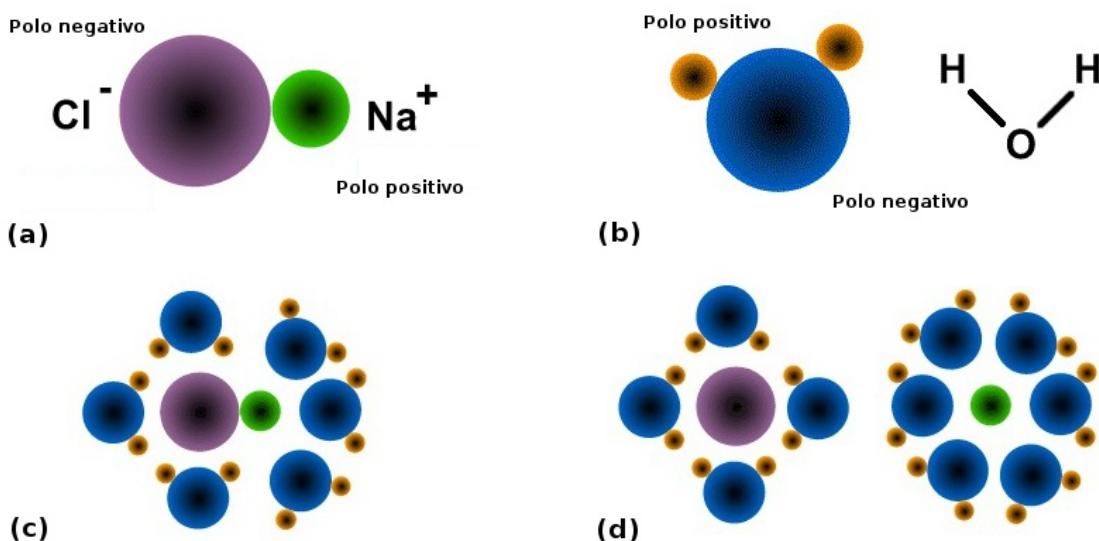


Figura 2.1: Hidratação de íons. (a) Molécula de $NaCl$ e sua polaridade; (b) Molécula de H_2O e sua polaridade; (c) Início do processo de hidratação; (d) Íons hidratados. (Fonte: <http://educacao.uol.com.br>)

Este fenômeno é melhor compreendido analisando-se o processo físico-químico da geração de bioeletricidade em um nível atômico.

Um modelo aceitável de estrutura atômica é aquele em que o átomo de um elemento é composto por um núcleo (prótons e nêutrons) circundado por elétrons organizados em camadas. A teoria do octeto, inspirada no fato de que somente os gases nobres encontram-se isolados na natureza, dita que um átomo sempre tenderá a completar a sua última camada de valência com 8 elétrons, de modo a garantir sua estabilidade assim como os gases nobres.

Esta estabilidade pode ser obtida através de ligações iônicas entre os átomos, quando elétrons da última camada são transferidos de modo que ambos os átomos satisfaçam a teoria do octeto. Ao ceder ou ganhar elétrons, um átomo torna-se um íon e sua carga elétrica passa a ser positiva ou negativa, respectivamente. Contudo, a molécula formada pela ligação iônica ainda possui carga elétrica neutra, embora polarizada.

A condução de corrente elétrica em elementos de ligação iônica somente é possível após a hidratação da molécula – processo onde a substância é separada em diferentes íons. A Figura 2.1 ilustra o processo de hidratação para uma molécula de cloreto de sódio ($NaCl$): ao ser diluída em água (H_2O), devido à polaridade de cada molécula (Fig. 2.1(a),(b)) os átomos de cloro são atraídos aos átomos de hidrogênio (H), e os átomos de oxigênio (O) são atraídos aos átomos de sódio (Na), conforme Fig. 2.1(c). O processo de hidratação é concluído com a dissolução completa dos íons (Fig. 2.1(d)).

Em uma solução química, uma vez que o número de cátions (íons positivos) e ânions (íons negativos) é igual, a sua carga elétrica média é nula. Nos organismos vivos, porém, a distribuição de íons nos espaços intra e extracelular é desigual, gerando assim a bioeletricidade, que é mantida e processada através da difusão de íons pela membrana citoplasmática.

Simplificadamente, pode-se dizer que a membrana citoplasmática é semi-permeável, ou seja, possui pequenos poros em sua superfície que permitem a passagem seletiva de determinados íons. Para cada tipo de íon existem canais específicos, sendo os mais comuns para os íons de sódio, cloro e potássio. A taxa de passagem é regulada pelo número e tamanho dos poros.

A difusão iônica através dos canais das células pode se dar através de transporte ativo, quando os íons de sódio são transportados para o exterior da célula enquanto os íons de potássio são transportados para o seu interior através das bombas de sódio-potássio. Estas são proteínas localizadas na membrana celular e que utilizam energia metabólica (extraída da glicose) para transportar os íons. Este processo será detalhado na Seção 2.2.2.

Outra forma de difusão iônica, denominada transporte passivo, ocorre devido à tendência natural em atingir-se um equilíbrio na difusão de íons entre os meios intra e extracelular. Isto deve-se: (1) à temperatura, a agitação térmica das moléculas acelera a difusão; (2) ao gradiente químico, íons tendem a mover-se do espaço de maior concentração para o de menor concentração; (3) ao gradiente elétrico, devido à atração ou repulsão das cargas iônicas, os íons tendem a distribuir-se de modo a haver o equilíbrio elétrico.

2.2 Neurofisiologia

Uma vez compreendido como a bioeletricidade é gerada através de diferentes concentrações de íons, esta seção abordará o processo pelo qual as células mantêm um potencial elétrico em suas membranas e a forma como ocorre a propagação do sinal bioelétrico entre as células.

2.2.1 O neurônio

Os neurônios, também denominados células nervosas, constituem o principal tipo de célula presente no cérebro humano. Além da composição básica de uma célula – núcleo, membrana e citoplasma – os neurônios possuem algumas organelas próprias, podendo ser divididos em três partes principais: o corpo celular, o axônio e os terminais pré-sinápticos.

O corpo celular contém o núcleo, as principais organelas citoplasmáticas e, externamente, inúmeros dendritos que são ramificações às quais os outros neurônios conectam-se. O axônio

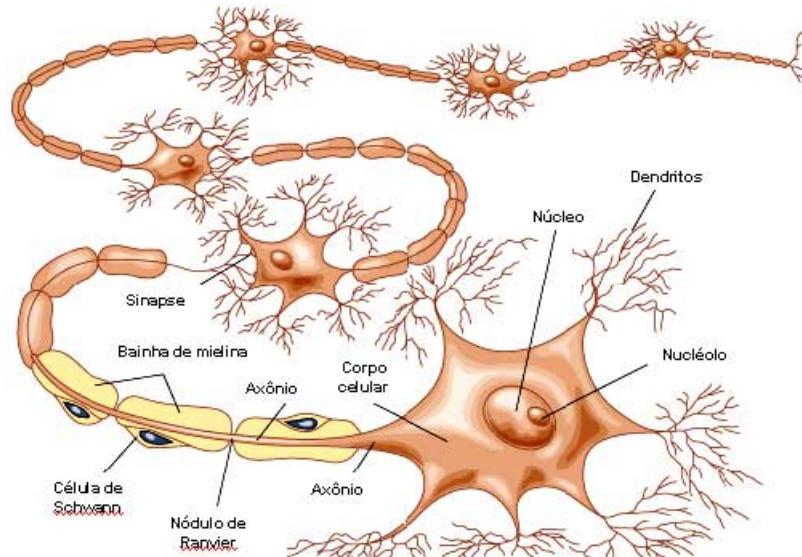


Figura 2.2: Neurônio e suas sinapses (Fonte: <http://marciocandiani.site.med.br>).

é uma extensão do corpo celular cuja função principal é a transmissão do sinal nervoso. O axônio é revestido quase que em sua totalidade por mielina – substância lipídica que funciona como um isolante na condução do sinal, evitando interferências e garantindo a velocidade na transmissão. Na extremidade do axônio, encontra-se o terminal pré-sináptico responsável por realizar a conexão – denominada sinapse – com os dendritos de outros neurônios. A Figura 2.2 representa um esquema simplificado de uma célula neuronal em conexão sináptica com outros neurônios. É importante observar que nos dendritos de cada neurônio há inúmeros outros conectados, formando assim uma rede neural ou neuronal.

2.2.2 Potencial elétrico nas células

A membrana citoplasmática das células humanas possui uma diferença de potencial denominada *polarização elétrica da membrana* e o interior da célula apresenta uma carga elétrica negativa em relação ao seu exterior, chamado *potencial de repouso da membrana*.

Este potencial surge devido às diferentes concentrações de íons de sódio (Na^+), cloro (Cl^-) e potássio (K^+) nos espaços intra e extracelular. Em condições normais, há mais Na^+ e Cl^- no exterior da célula e maior concentração de K^+ no seu interior.

Essas diferenças de concentração surgem do gradiente químico e são mantidas pelo fato da membrana celular possuir uma permeabilidade diferente para cada tipo de íon – daí ser declarada semi-permeável. No início, os íons atravessam a membrana seguindo o seu gradiente químico. Aos poucos, ocorre um gradiente elétrico que passa a repelir estes íons. Este processo continua até que haja um *equilíbrio eletroquímico*, isto é, existe uma diferença de concentração

química equilibrada por uma diferença de potencial elétrico.

O cientista alemão Walter Nernst formulou uma lei que expressa o equilíbrio eletroquímico para um determinado tipo de íon: um potencial elétrico é associado a cada íon, proporcional ao logaritmo das concentrações iônicas de cada lado da membrana. Considerando estes valores, o cientista David E. Goldman formulou uma equação para o potencial de equilíbrio de uma membrana, levando em consideração todos os íons permeáveis a ela (Clark Jr., 2010).

A Tabela 2.1 mostra a concentração média dos principais íons inorgânicos encontrados nos meios intra e extracelular, com seus respectivos potenciais elétricos de equilíbrio (MALMIVUO; PLONSEY, 1995). Pela lei de Nernst-Goldman, considerando-se também os demais íons e os ânions orgânicos, o potencial de repouso da membrana celular é de -60mV . Esta é a amplitude média de um sinal cerebral. Contudo, equipamentos para aquisição e processamento destes sinais devem considerar grandezas ainda inferiores, devido a atenuações em suas medições, conforme será discutido na Seção 2.3.

Tabela 2.1: Concentração média dos principais íons inorgânicos nos meios intra e extracelular.

Íon	Concentração extracelular (mol/m ³)	Concentração intracelular (mol/m ³)	Potencial elétrico de equilíbrio (mV)
Na^+	150	15	+61
K^+	5.5	150	-88
Cl^-	125	9	-70

Com o decorrer do tempo, estes potenciais elétrico e químico tenderiam a equilibrar-se. Entretanto, é preciso considerar que existem ânions orgânicos no interior da célula – cujo gradiente químico é alto, porém com permeabilidade da membrana nula. Ainda, conforme mencionado anteriormente, há o transporte ativo de íons através das bombas de sódio-potássio.

Uma bomba de sódio-potássio consiste em uma proteína específica localizada na membrana celular¹. Em cada ciclo, 3 íons de sódio são lançados para o exterior da célula – junto com uma molécula de água, para evitar a estumefação da célula – e 2 íons de potássio são transportados para o seu interior. Isto é realizado através de um complexo processo químico e consome uma molécula de ATP (adenosina tri-fosfática), molécula na qual o organismo armazena a energia proveniente da glicose.

¹Uma abordagem detalhada sobre o funcionamento das bombas de sódio-potássio é encontrada em (MALMIVUO; PLONSEY, 1995).

2.2.3 Potencial de ação

Para compreender como um sinal bioelétrico é propagado a partir do potencial de repouso da membrana, tomemos como exemplo uma pessoa tocando algum objeto. A fricção das fibras nervosas da pele com o objeto faz com que alguns canais de Na^+ se abram. Assim, os íons de sódio entram na célula alterando o potencial de repouso. Em humanos, o potencial de ação compreende as amplitudes de $-60mV$ a $+10mV$ (SANCI; CHAMBERS, 2007). Um potencial de ação desencadeado tem suas etapas indicadas na Figura 2.3, conforme a descrição a seguir:

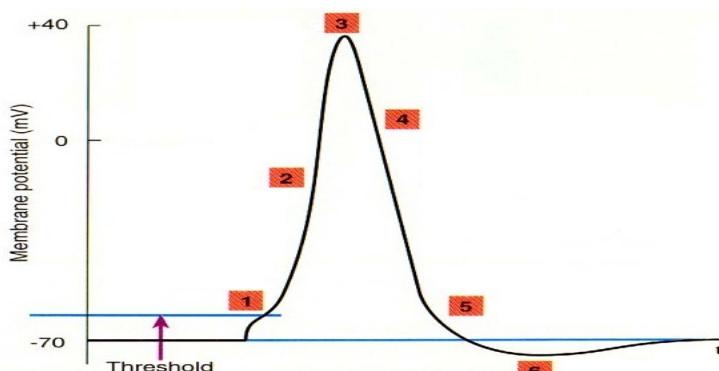


Figura 2.3: Variação do potencial elétrico da membrana durante a ocorrência de um potencial de ação. Em (1) e (2), despolarização; (3) equilíbrio eletroquímico; (4) a (6) repolarização.

1. Nem sempre um potencial de ação é desencadeado. Os íons Na^+ podem entrar na célula em quantidade equilibrável pelas bombas de sódio-potássio. Ainda, conforme descrito na Seção 2.2.4, existem sinapses excitatórias e inibitórias que alteram o potencial de membrana. De um modo geral, um potencial de ação será desencadeado apenas se for ultrapassado um limiar ou *threshold* de aproximadamente $-55mV$. Uma vez atingido o limiar, o potencial de ação é iniciado e um pulso elétrico será transmitido inevitavelmente. A partir deste potencial, os canais de sódio são abertos devido à despolarização e os íons Na^+ passam a entrar na célula, aumentando seu potencial elétrico.
2. Nesta etapa, também devido à despolarização, os canais de potássio são também abertos e permitem que os íons K^+ deixem o interior da célula, porém a passagem dos íons de potássio é muito mais lenta, o que evita a neutralização e possibilita a continuação do potencial de ação.
3. O equilíbrio eletroquímico determina o ápice da despolarização (com potencial elétrico entre $+10mV$ e $+30mV$). Devido a este equilíbrio, os canais de sódio são então fechados.

4. Como os canais de potássio continuam abertos (são mais lentos para abrir e fechar), os íons K^+ continuam a deixar a célula. Esta passa então a sofrer uma repolarização.
5. Neste estágio os canais de potássio começam a fechar-se e os canais de sódio voltam ao estado normal. Entretanto, uma vez que ainda há entrada de íons K^+ , há uma *hiperpolarização* da célula e o potencial de repouso alcança valores de até $-90mV$. Esta etapa é fundamental pois evita que o neurônio receba um novo estímulo enquanto processa o potencial de ação anterior ou, ao menos, eleva o seu valor de limiar.
6. Quando os canais de íons retornam ao estado normal, as bombas de sódio-potássio passam então a restabelecer o potencial de repouso da membrana.

Pela propagação do campo eletromagnético, a alteração do potencial de membrana de uma célula influencia o potencial de membrana das células vizinhas. Nos neurônios, o potencial de ação é conduzido pelo axônio e dendritos, estabelecendo assim a propagação do sinal cerebral.

2.2.4 Sinapses

O sinal cerebral é gerado e transmitido através dos potenciais de ação. Contudo, o processamento biológico deste sinal ocorre principalmente através das sinapses: conexões entre as células nervosas e que determinam o desencadeamento de um potencial de ação ([MALMIVUO; PLONSEY, 1995](#)). As sinapses podem ser classificadas basicamente em dois tipos:

- Sinapses elétricas: ocorrem através do estabelecimento de contato direto entre um dos dendritos com o corpo celular de outro neurônio. Nesta sinapse, os canais de ambas as células são acoplados e os íons trocados diretamente. É uma transmissão muito rápida e sincronizada, ocorrendo em células do músculo cardíaco liso e em células epiteliais.
- Sinapses químicas: são as principais sinapses que ocorrem no sistema nervoso. O neurônio pré-sináptico libera neurotransmissores na fenda sináptica que por sua vez, gera um potencial de ação no neurônio pós-sináptico. Observando este processo detalhadamente: o potencial de ação é gerado no corpo celular e transmitido pelo axônio; ao chegar no terminal pré-sináptico, estimula a entrada dos íons de cálcio Ca^{2+} que causam a adesão das vesículas sinápticas aos locais de liberação; estas vesículas fundem-se com a membrana e liberam os neurotransmissores que se difundem na fenda sináptica. Os neurotransmissores ligam-se a proteínas receptoras na membrana da célula pós-sináptica. Após este

processo, o neurotransmissor é destruído por uma enzima ou reabsorvido na terminação pré-sináptica. Cada neurônio produz somente um tipo de neurotransmissor. O efeito destes no neurônio pós-sináptico caracteriza dois tipos de sinapses químicas:

Sinapses excitatórias – EPSP: despolariza a membrana pós-sináptica, levando-a a um valor mais próximo do limiar elétrico para o potencial de ação.

Sinapses inibitórias – IPSP: ao contrário da anterior, estes neurotransmissores causam uma hiperpolarização, geralmente através da abertura de canais de íons de cloro (Cl^-) ou potássio. Torna-se mais difícil atingir o limiar elétrico.

Uma única célula nervosa normalmente tem centenas ou milhares de sinapses químicas excitatórias ou inibitórias que chegam as suas terminações. O que define se a célula pós-sináptica disparará ou não o potencial de ação será a combinação de todos os EPSP e IPSP.

A ocorrência das sinapses está associada a diversos eventos neurofisiológicos de um indivíduo, incluindo-se os estados cognitivos de vigília, sonolência e sono. O potencial de ação disparado por um conjunto de sinapses, através de uma rede de neurônios, gera um campo elétrico mensurável através do escâlpo, conforme detalhado a seguir, na Seção 2.3.

2.3 Eletroencefalografia - EEG

Um sinal cerebral – embora esta nomenclatura possa designar qualquer sinal bioelétrico que ocorra no cérebro, obtido por meio de diversas técnicas – geralmente faz referência ao sinal obtido via eletroencefalografia.

A primeira medida de potenciais elétricos cerebrais foi apresentada por Richard Caton em 1875, cientista inglês que realizou estudos em cérebros expostos de animais utilizando um galvanômetro. Em 1890, o médico polonês Adolf Beck constatou a atividade cerebral rítmica, observando também que as oscilações cerebrais desapareciam quando os olhos eram estimulados com luz – efeito hoje conhecido como bloqueio das ondas alfa. O primeiro registro de eletroencefalograma, obtido na superfície de um escâlpo humano, foi realizado em 1929 pelo alemão Hans Berger. Em seguida, o ano de 1935 foi marcado por grandes avanços da eletroencefalografia clínica, com descobertas de aplicações no diagnóstico da epilepsia e no estudo de padrões do sono. A partir deste período, iniciou-se o que se considera a época contemporânea da eletroencefalografia (BRAZIER, 1961).

Hoje, a eletroencefalografia é amplamente utilizada e consiste na medida do campo elétrico resultante das sinapses nos neurônios. Este campo elétrico, porém, é perceptível somente

quando proveniente de um grande grupo de neurônios ativos. Isto deve-se às diferentes camadas estruturais da cabeça humana, cada qual com sua respectiva resistividade elétrica, conforme mostrado na Figura 2.4. O crânio – densa camada óssea necessária à proteção do cérebro – é a camada que apresenta maior resistividade elétrica e, portanto, a que causa maior atenuação do sinal cerebral.

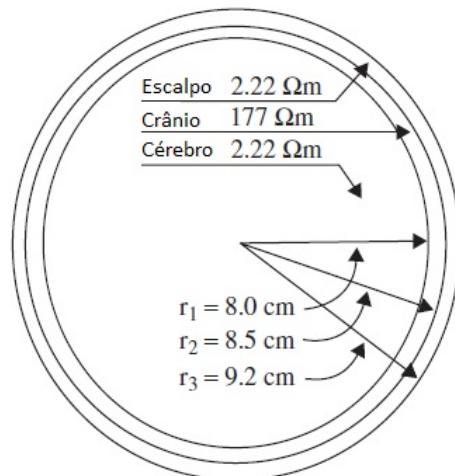


Figura 2.4: As principais camadas cerebrais e suas respectivas resistividades e espessuras. (Fonte: adaptado de ([SANCI; CHAMBERS, 2007](#)))

De acordo com ([SANCI; CHAMBERS, 2007](#)), o estudo e a análise dos sinais de EEG permitem o diagnóstico e pesquisa, dentre outros, dos seguintes temas clínicos, destacados aqueles de interesse a este estudo:

- **Monitoração do estado de alerta, coma e morte cerebral;**
- **Monitoração da cognição através do ritmo alfa;**
- Controle da profundidade da anestesia;
- Epilepsia e localização da origem das crises epilépticas;
- Teste do efeito de psicoativos;
- **Investigação da fisiologia do sono;**
- **Investigação de distúrbios do sono;**
- Investigação de distúrbios mentais.

Contudo, a medição do EEG fornece uma resolução espacial limitada à posição dos eletrodos. Ou seja, sabe-se que determinado potencial ocorre entre os dois eletrodos do canal (ou entre um eletrodo e a referência), porém não se sabe exatamente quais neurônios correspondem àquela atividade medida. Dessa forma, a electroencefalografia tem aplicabilidade maior quando deseja-se obter informações dos ritmos cerebrais, tal como é no estudo da sonolência.

2.3.1 Ritmos de atividade cerebral

As sinapses ocorrem de maneira sincronizada e ritmada no cérebro de todos os mamíferos, indicando determinadas atividades ou distúrbios de acordo com a frequência e amplitude do sinal gerado. Em humanos, embora essas medidas sofram variações de indivíduo para indivíduo, as ondas cerebrais podem ser agrupadas de acordo com sua faixa de frequência, indicando alguma atividade cerebral específica. Os principais ritmos cerebrais e aqueles relacionados aos processos do sono são descritos a seguir ([BLINOWSKA; DURKA, 2006](#)):

- Ritmo delta (δ): faixa de **0.5 a 4Hz**. Está associado ao sono profundo e pode estar presente no estado de vigília (acordado). Devido à baixa frequência, é fácil de ser confundido com artefatos (sinais falsos provenientes de imperfeições no método ou aparelhagem).
- Ritmo teta (θ): faixa de **4 a 8Hz**. Estas ondas surgem na transição do estado consciente para o de sonolência. São também associados ao acesso de informações do inconsciente, bem como em processos de inspiração criativa e meditação profunda.
- Ritmo alfa (α): faixa de **8 a 13Hz**. Comumente são bem descritas como um sinal senoidal. São conhecidas por indicar um estado de consciência em que o indivíduo está acordado porém relaxado, isto é, sem nenhuma atenção ou concentração. Sua amplitude normalmente é abaixo de $50\mu V$ e evidencia-se quando o indivíduo está com os olhos fechados. Este ritmo é bloqueado ou atenuado em atividades de atenção, principalmente na ocorrência de atenção visual.
- Ritmo beta (β): faixa de **13 a 30Hz**. Indica o estado de um indivíduo acordado e com alguma atividade cerebral de concentração, tal como pensamentos, foco em atividades e soluções de problemas. É encontrado em adultos normais. Um alto nível de ondas beta pode indicar o estado de pânico em humanos. A amplitude dessas ondas normalmente está abaixo de $30\mu V$.

- Ritmo gama (γ): faixa de frequências **acima de 30Hz**, também considerada de 30 a 45Hz. São ondas de amplitude baixíssima e geralmente estão associadas a distúrbios mentais.
- Ritmo sigma (σ): são formas de ondas denominadas fusos do sono (*sleep spindles*) e ocorrem na faixa de **11 a 15Hz**.
- Ritmo phi (ϕ): ondas de frequência **abaixo de 4Hz**, ocorrendo dentro de 2s após os olhos serem fechados.
- Ritmo *kappa* (κ): ritmo relacionado ao movimento dos globos oculares, é considerado um artefato.

A identificação dos ritmos cerebrais não é trivial e geralmente é efetuada visualmente por especialistas, analisando-se o EEG no domínio do tempo. Na Figura 2.5 estão dispostos alguns dos ritmos cerebrais comumente associados ao sono, compreendendo desde as baixas (δ) às altas (β) frequências.

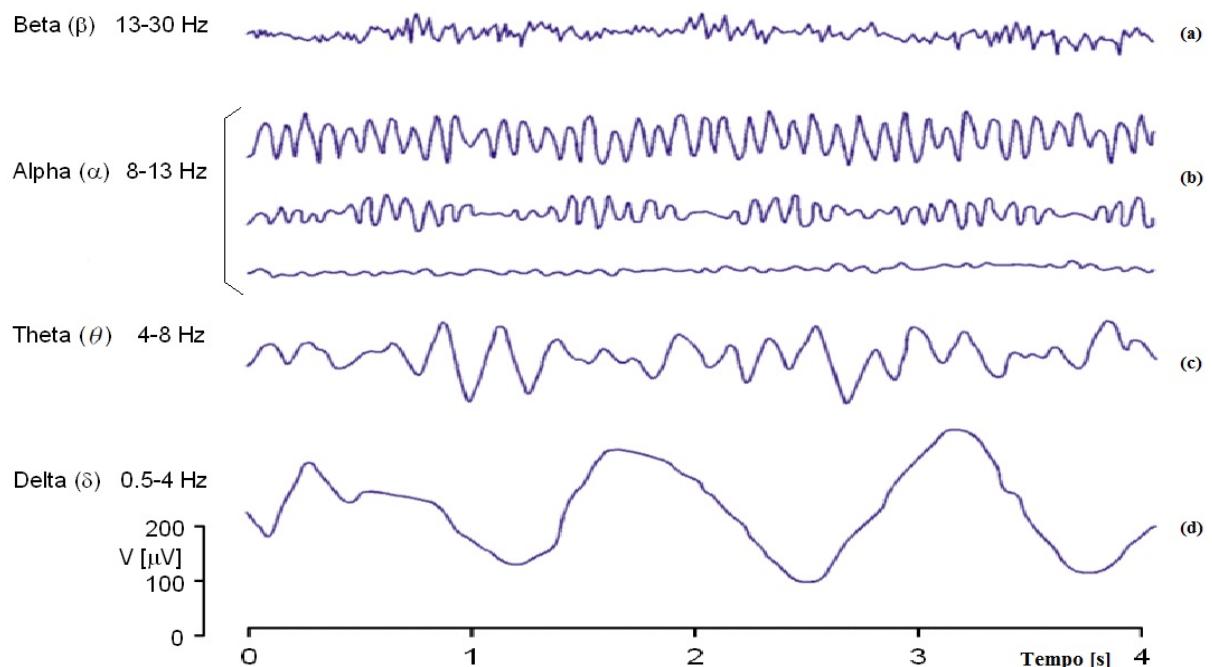


Figura 2.5: Principais ritmos cerebrais associados ao sono. Em (a), ritmo beta; (b) três diferentes sinais com ritmo alfa; (c) ritmo teta e (d) ritmo delta. Adaptado de (MALMIVUO; PLONSEY, 1995).

2.3.2 Aquisição e gravação do EEG

Através de eletrodos dispostos no escopo, o sinal cerebral é medido, amplificado e então digitalizado por um conversor analógico-digital (ADC) de modo que possa ser analisado e processado por computadores. O sinal de EEG consiste na medida da diferença de potencial elétrico entre dois eletrodos. Um canal de EEG é formado por dois eletrodos e pode ser construído utilizando-se (i) montagem diferencial ou (ii) montagem referencial.

A montagem diferencial consiste em amplificar a diferença de potencial entre dois eletrodos dispostos simetricamente no escopo. Já a montagem referencial, também chamada unipolar, amplifica o sinal do canal constituído por um eletrodo posicionado na região de interesse e por um eletrodo de referência posicionado no lóbulo da orelha, nariz, face, pescoço ou na região central do escopo.

Em um exame de eletroencefalografia clínico, utilizam-se montagens com 6, 8, 21 e até 75 canais. O mesmo ocorre em polissonografias – registro de diversos sinais fisiológicos de um paciente (cardíacos, neurológicos, respiratórios, musculares e oculares), com duração média de 8 horas, de modo a verificar as fases do sono e diagnosticar eventuais distúrbios.

Neste estudo, apenas um único canal de EEG é utilizado para a detecção da sonolência. Esta escolha tem como objetivo reduzir os custos computacionais relativos ao processamento de vários canais EEG. Além disso, o desenvolvimento de algoritmos utilizando um único canal de EEG torna viável a implementação de dispositivos embarcados para a detecção da sonolência em motoristas.

O sono é um processo que tem início no tronco cerebral e atinge todas as regiões do cérebro ([SANCI; CHAMBERS, 2007](#)). Assim, há redundância de informação na utilização de vários canais de EEG. Propõe-se, neste estudo, a detecção da sonolência extraindo-se características do sinal proveniente de um único canal de EEG. Esta proposta baseia-se também na topologia desenvolvida por ([LIN et al., 2010](#)), na qual a sonolência é detectada também via um único canal de EEG.

Para estudos relacionados ao sono, raramente a frequência de interesse ultrapassará 50Hz . Considerando o critério de Nyquist, de que a taxa de amostragem deve ser no mínimo duas vezes a frequência máxima do sinal, **determina-se a frequência de amostragem mínima de 100Hz** . Em geral, a taxa de amostragem utilizada em equipamentos clínicos é mais alta, chegando a alcançar a ordem de $k\text{Hz}$ (10^3 Hz), uma vez que são também analisados casos de epilepsia e demais eventos de alta frequência. No entanto, uma taxa de amostragem alta necessita mais

recursos de processamento e armazenamento.

Em vista disto, no estudo em questão foram utilizados sinais amostrados a $100Hz$ e $200Hz$, provenientes de: (i) base de dados do Hospital Pulido Valente, de Lisboa, obtidos por leitura referencial (auricular) do canal F_{pz} do sistema de posições 10-20; (ii) base de dados PhysioNet, disponível em <http://www.physionet.org>.

A digitalização do sinal ocorre após a amplificação e alguns processos de filtragem (ver Seção 2.3.2.2). No processo de quantização, são utilizadas resolução de 12 a 16 bits, mantendo-se a regra de quanto maior a precisão, maior a capacidade de armazenamento exigida (**SANCI; CHAMBERS, 2007**).

2.3.2.1 Tipos de eletrodos e posicionamento

As características do eletrodo utilizado, assim como o seu correto posicionamento, têm grande influência na qualidade do sinal medido. Entre os diversos tipos de eletrodos utilizados pelos sistemas de EEG, podemos citar:

- Descartáveis, pré-preparados ou sem necessidade de gel-condutor;
- Eletrodos de disco reutilizáveis, podendo ser de ouro, prata ou aço inoxidável;
- Toucas ou malhas de eletrodos;
- Eletrodos agulha, para medições mais precisas porém invasivas.

Deve-se observar que a alta impedância entre o córtex e os eletrodos, bem como o uso de eletrodos de alta impedância, podem levar a distorções no sinal. Segundo (**SANCI; CHAMBERS, 2007**), é recomendado que a impedância entre cada eletrodo e o escalpo seja menor que $5k\Omega$ e que a impedância entre os dois eletrodos do canal seja de $1k\Omega$.

Embora o cérebro seja estruturado em regiões disformes, o que dificulta a localização da fonte do sinal de EEG, o conhecimento das posições dos eletrodos é fundamental nas atividades de diagnóstico e pesquisa. Para aplicações BCI (*Brain-Computer Interface* ou interface homem-máquina, em português), normalmente busca-se a utilização de um número reduzido de canais, sendo portanto de fundamental importância o correto posicionamento dos eletrodos.

A disposição dos eletrodos comumente utiliza um esquema recomendado pela Federação Internacional das Sociedades de EEG e Neurofisiologia Clínica. Na Figura 2.6(a-b) está disposta a padronização de 21 eletrodos, denominada 10-20. Esta nomenclatura refere-se à disposição

dos eletrodos em equidistâncias de 10% e 20% da distância total entre as posições de referência *nasion* (N_z), *inion* (I_z) e os lóbulos das orelhas (A_1, A_2), conforme indicado na Figura 2.6.

Cada posição recebe uma nomenclatura que indica sua localização: *Fp* para a região pré-frontal; *F* para a região frontal; *C* para a região central; *P* para a região parietal; *O* para a região occipital e *T* para a região temporal. A segunda coordenada é dada por um caracter: 0 ou *z* para a linha central da cabeça; números pares para o lado direito da cabeça; números ímpares para o lado esquerdo da cabeça. Quanto maior a numeração, mais afastado da linha central. A Figura 2.6(c) mostra uma versão estendida do esquema 10-20, com 75 eletrodos.

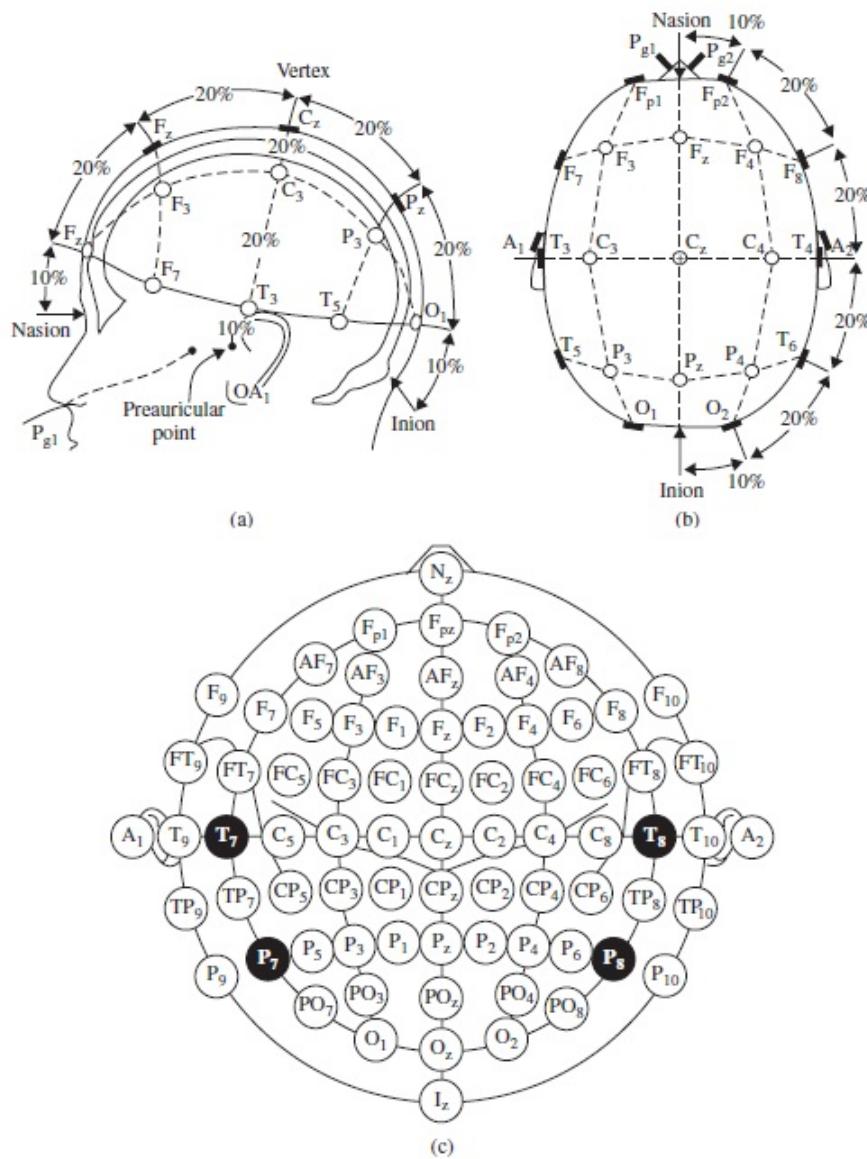


Figura 2.6: Diagrama do esquema 10-20 para posicionamento de eletrodos, incluindo as posições de referência (N_z , I_z , A_1 , A_2). Em (a) e (b), visão tridimensional para posicionamento de 21 eletrodos. Em (c), visão bidimensional do posicionamento de 75 eletrodos. (SANCI; CHAMBERS, 2007)

2.3.2.2 Tratamento e análise do sinal

Antes do sinal medido ser convertido pelo ADC, aplicam-se as etapas de amplificação e filtragem, muito embora em algumas topologias a filtragem do sinal ocorra após a sua conversão. Na filtragem, são removidas as componentes menores de 0.5Hz , de modo a remover o ruído causado pela respiração e por movimentos musculares. Ainda, um filtro passa-baixa com frequência de corte em 50Hz é utilizado de modo a eliminar a interferência da rede elétrica de 50Hz ou 60Hz .

Outros artefatos podem ter causas fisiológicas, relacionadas ao paciente, tal como o piscar de olhos, contração muscular e movimentos que possam deslocar os eletrodos; ou causas técnicas, também chamados artefatos de sistema, tal como interferências, flutuação de impedância, defeitos no equipamento, entre outros ([SANCI; CHAMBERS, 2007](#)). A filtragem desses artefatos deve ser considerada na etapa de pré-processamento do sinal, escolhendo-se o método de filtragem de acordo com a aplicação.

Um artefato gerado pelo piscar dos olhos é observado na Figura 2.7, entre as amostras 800 e 1200 do sinal de EEG medido em 4 canais distintos. Verifica-se também que o impacto do artefato varia de acordo com o canal, isto é, com a posição dos eletrodos. Alguns artefatos, tais como os causados por movimentações dos eletrodos, são identificáveis por gerar grandes amplitudes e representarem segmentos contínuos.

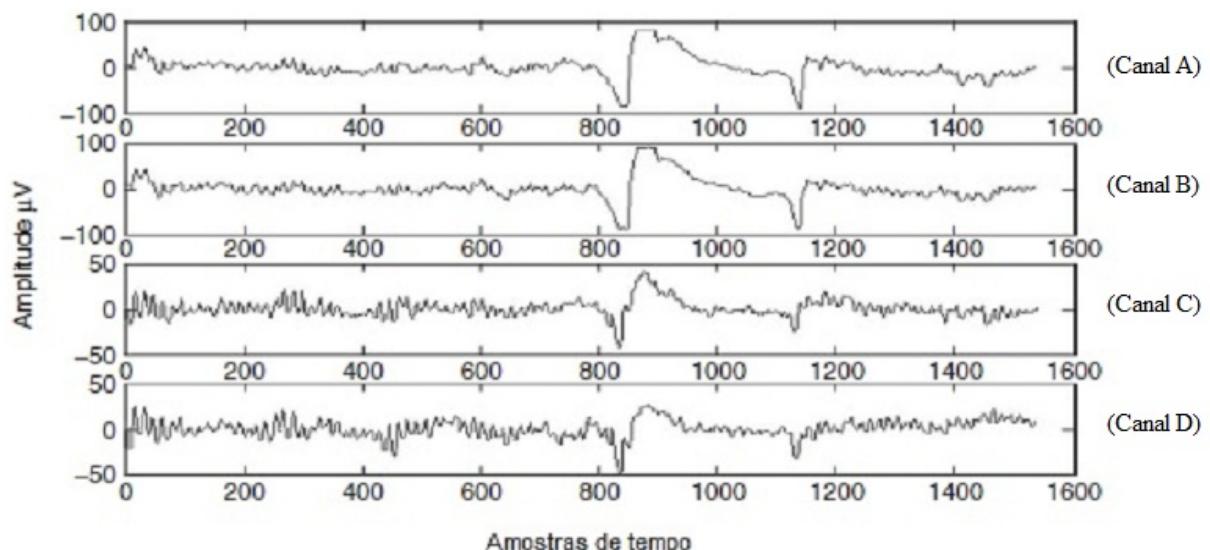


Figura 2.7: Impacto do artefato causado pelo piscar dos olhos, no intervalo entre as amostras 800 a 1200, em sinais de 4 canais de EEG distintos. Adaptado de ([SANCI; CHAMBERS, 2007](#)).

Na interpretação visual, os sinais de EEG são divididos em épocas – termo utilizado para designar intervalos de análise do EEG, que correspondem geralmente a segmentos de 30 segundos. Durante a análise visual, os especialistas costumam substituir a época em que encontra-se o artefato pela época anterior. Em sistemas embarcados, os artefatos devem ser considerados filtrados e ou tratados adequadamente, de modo a não interferir na aplicação desenvolvida.

2.3.2.3 European Data Format – EDF

O EDF – formato europeu de dados, em tradução livre – é um padrão de formato de arquivos simples e flexível, proposto em 1992, destinado à transmissão e armazenagem de sinais biológicos ([EDF+, 2011](#)). Não há restrições quanto às dimensões físicas e à frequência de amostragem do sinal medido, fazendo com que este padrão de arquivos seja utilizado extensamente em equipamentos e softwares para EEG e polissonografia.

Um novo padrão EDF+, desenvolvido em 2002 e compatível com o anterior, permite a gravação de sequências de dados com interrupções e anotações textuais. É utilizado para a gravação de sinais de EEG juntamente com eletrocardiogramas, potenciais evocados, entre outros sinais biofísicos. Atualmente, a nomenclatura EDF pode ser utilizada para designar tanto o padrão EDF quanto o padrão EDF+.

Um arquivo EDF possui a seguinte estrutura: um cabeçalho, de tamanho variável, onde são especificados os dados do paciente e as características técnicas do sinal; e uma seção de dados, cujos valores são dispostos de modo consecutivo de acordo com a duração pré-estipulada para cada época do sinal.

Os primeiros 256 bytes do cabeçalho indicam a versão do formato, a identificação do paciente, a duração do sinal, o número de registros e o número de sinais (ns) em cada registro. Para cada canal utilizado, são designados mais 256 bytes para a especificação de: tipo de sinal (EEG, ECG, temperatura entre outros); amplitude de calibração; e número de amostras em cada registro – informação também utilizada para o cálculo da taxa de amostragem. O tamanho final do cabeçalho, em bytes, é dado pela relação $256 + (ns * 256)$. Após o cabeçalho, são dispostos os dados, cujo tamanho está relacionado ao número de amostras e ao número de sinais.

No sítio da Internet do grupo mantenedor do projeto ([EDF+, 2011](#)), são encontradas as especificações completas para os padrões EDF (1992) e EDF+ (2003). No mesmo sítio são dadas algumas diretrizes e orientações para o desenvolvimento de softwares utilizando o padrão EDF, bem como disponibilizados softwares e bibliotecas para manipulação destes arquivos.

Neste estudo, para as bases de dados cujo hipnograma foi fornecido separadamente em arquivo de texto ou de imagem, utilizou-se para visualização e extração dos dados a ferramenta *ViewEDF*, componente da *toolbox BioSig* para o MATLAB®. Já para as bases de dados que possuem o hipnograma em EDF, este foi visualizado através do aplicativo *SleepExplorer - Statistic Module*.

2.4 Fisiologia do sono

Segundo ([SANCI; CHAMBERS, 2007](#)), o sono é um estado natural de descanso observado em humanos e em diversos animais, mas que no entanto ainda é um fenômeno fisiológico não totalmente compreendido. É caracterizado pela redução dos movimentos voluntários do corpo e pela diminuição da reação a estímulos externos. Em relação ao metabolismo celular, durante o sono ocorre um aumento do anabolismo (síntese de estruturas celulares) e uma diminuição do catabolismo (quebra de estruturas orgânicas com liberação de energia).

Ainda segundo ([SANCI; CHAMBERS, 2007](#)), estudos recentes mostram que o sono é um processo dinâmico e que envolve atividade mental, contrariando a ideia histórica de que o sono era considerado um estado passivo e inativo do organismo humano. O processo de sono tem início a partir do tronco cerebral, onde certos neurotransmissores causam sinapses inibitórias nas regiões do cérebro que mantêm uma pessoa acordada.

O sono tem um papel fundamental na manutenção da saúde humana. Estudos comprovam que a privação de sono causa um decréscimo na temperatura do corpo, uma redução no número de glóbulos brancos – o que diminui a imunidade do organismo, e em jovens, um decréscimo na produção do hormônio do crescimento. Além disso, a privação de sono causa sonolência, fadiga, e diminuição do estado de alerta ([ELMENHORST et al., 2008](#)).

Em ([BLINOWSKA; DURKA, 2006](#)), os estágios do sono são apresentados seguindo a classificação original definida por Rechtschaffen e Kales (R&K) em 1968, ainda hoje amplamente utilizada pela comunidade científica e médica. Na classificação R&K o sono é dividido nos seguintes estágios: (a) Estágio I (sonolência); (b) Estágio II (sono leve); (c) Estágio III (sono profundo); (d) Estágio IV (sono muito profundo) e (e) Estágio REM, período com intensa atividade cerebral, quando podem ocorrer os sonhos e movimento dos olhos, cuja nomenclatura provém do inglês *Rapid Eye Movement*. Os estágios I, II, III e IV podem também ser classificados como sono NREM (*Nonrapid Eye Movement*) ([SANCI; CHAMBERS, 2007](#)). Durante uma noite normal de sono, os estágios NREM e REM alternam-se em ciclos completos com duração

de aproximadamente 1.5 hora.

Na polissonografia, a diferenciação entre os estágios do sono utiliza não somente a informação do EEG, mas também medidas do eletro-oculograma (EOG, mede o potencial elétrico da retina) e eletromiograma (EMG, mede a atividade elétrica muscular). Alguns clínicos também avaliam os batimentos cardíacos através de eletrocardiogramas (ECG) e a respiração. A utilização cruzada destas informações, na análise visual, possibilita a rejeição das épocas contaminadas por artefatos (BLINOWSKA; DURKA, 2006).

A Figura 2.8 apresenta as formas de onda de um sinal de EEG² para os diferentes estágios do sono. A caracterização de cada estágio baseia-se principalmente nos ritmos cerebrais e na ocorrência de transientes (CARSKADON; RECHTSCHAFFEN, 2000), conforme detalhado a seguir:

- Vigília: o estado relaxado de vigília é caracterizado por atividade cerebral em diferentes ritmos, conforme abordado na Seção 2.3.1. A atividade alfa (α) é atenuada quando o indivíduo está de olhos abertos ou desenvolvendo atividade de atenção. Com os olhos fechados, a atividade no ritmo alfa torna-se evidenciada. Em segundos ou minutos que precedem o estágio I, verificam-se movimentos circulares e vagarosos dos olhos; Na Figura 2.8(a) é representado o estado de vigília onde o paciente desenvolve atividade de concentração, enquanto na Figura 2.8(b) ocorre o estado de vigília com o indivíduo relaxado e de olhos fechados.
- Estágio I: está associado com o decréscimo da atividade no ritmo alfa (α) e apresenta atividade de baixa amplitude principalmente no ritmo teta (θ). Conforme a sonolência é aprofundada, o ritmo cerebral torna-se ainda mais lento e verifica-se a ocorrência de vértece – onda de potencial composta, onde ocorre uma pequena descarga de pico de polaridade positiva seguida por uma grande onda negativa, caracterizando uma onda de descarga. A transição do estado alerta para a sonolência é visualizada claramente quando há atividade alfa (α) bem definida no padrão EEG do indivíduo acordado. Desta maneira, para a obtenção do EEG as derivações frontal ou occipital tornam-se as mais indicadas, uma vez que o ritmo alfa é proeminente nestas regiões do córtex. De acordo com a classificação R&K, o estágio I é marcado quando menos de 20% da época contém atividade alfa (α), o sinal é de média amplitude e possui frequências mistas, com atividade maior

²Sinal do paciente sc4002 da base de dados PhysioNet. Para os sinais de (a) a (g) da Figura 2.8 foram representadas as épocas 806, 859, 871, 877, 894, 903 e 1008, respectivamente.

no ritmo teta (θ). Um sinal de EEG deste estágio é representado na Figura 2.8(c).

- Estágio II: é caracterizado pela presença de fusos do sono (*spindles*) – oscilações de curta duração (máximo de 0.5s) e frequência de 11 a 15Hz – e complexos K – ondas com uma componente negativa de alta amplitude seguida imediatamente por um componente positivo mais lento. Neste estágio, o ritmo delta (δ) pode ocorrer em menos de 20% da época. Na Figura 2.8(d), no intervalo de 8s a 9s, observa-se a ocorrência de fusos do sono.
- Estágio III: pela classificação R&K, é marcado quando ondas delta (δ) de 0.5 a 2.5Hz correspondem a 20% ou 30% do total da época. A amplitude pico a pico do sinal pode ser maior de $75\mu V$, conforme observado na Figura 2.8(e).
- Estágio IV: é marcado quando 50% da época contém atividade delta (δ), com ondas lentas e de alta amplitude. Neste estágio podem aparecer complexos-K. A Figura 2.8(f) mostra uma onda característica deste estágio.
- Estágio REM: caracterizado por uma diminuição na amplitude do EEG, rápido movimento dos olhos, perda da atividade muscular e ocorrência de ritmos rápidos. Sendo uma atividade polirrítmica, a utilização apenas do EEG torna difícil sua distinção do estágio I e do estado acordado, conforme pode ser constatado comparando-se as Figuras 2.8(g), referente ao estágio REM, com as Figuras 2.8(a-c), referentes à vigília e ao estágio I do sono.

A sequência de estágios de sono é usualmente representada por hipnogramas. Estes são diagramas que representam os diferentes estágios do sono de um paciente, elaborados por um especialista ao atribuir um estágio para cada época. A *American Academy of Sleep Medicine* define a seguinte nomenclatura: **W**, acordado; **N1**, estágio NREM-1; **N2**, estágio NREM-2; **N3**, estágio NREM-3; **N4**, estágio NREM-4 e **REM**, que simboliza o estágio de mesmo nome.

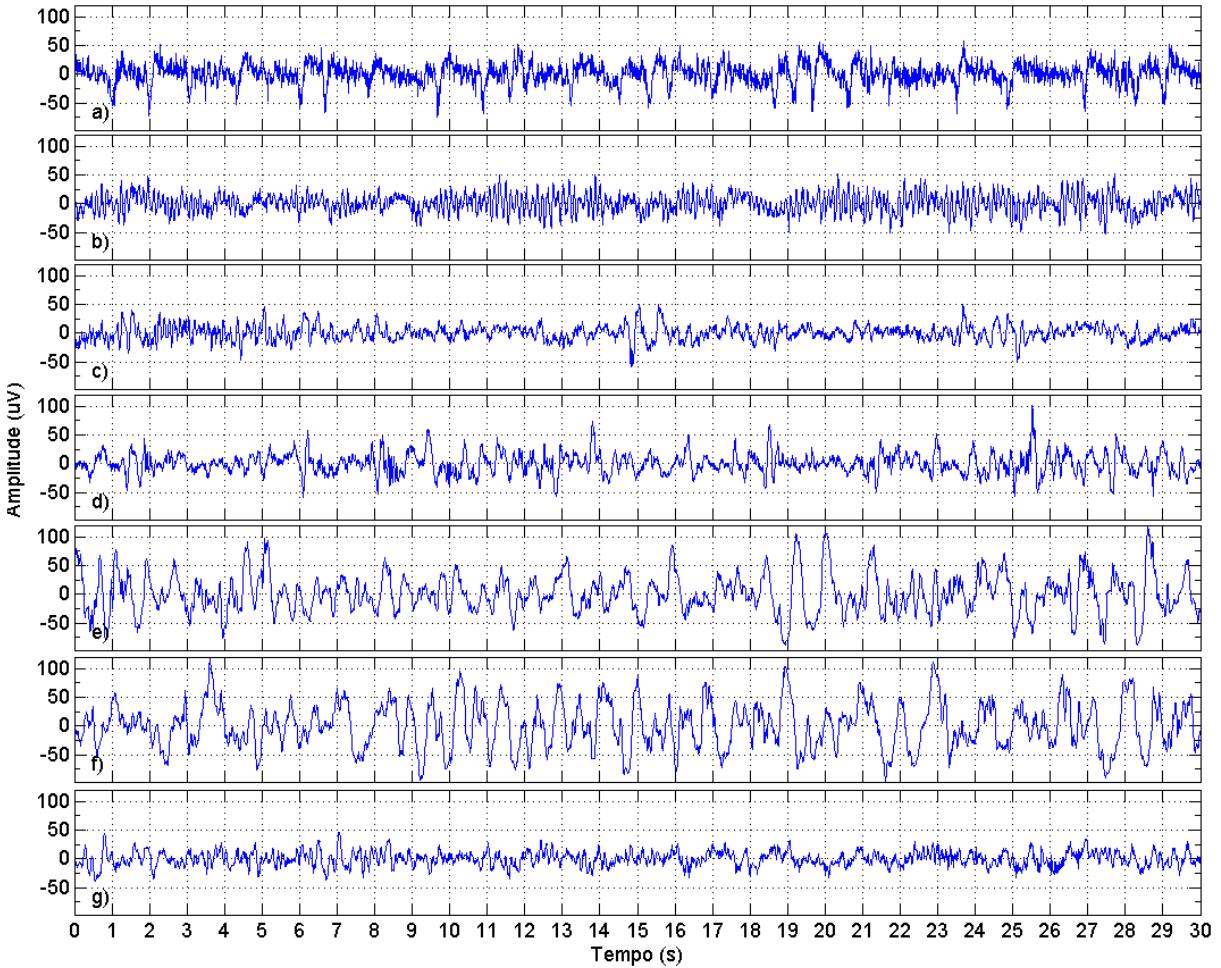


Figura 2.8: Sinal de EEG para diferentes fases do sono: (a) vigília com atividade de concentração; (b) vigília, relaxado e de olhos fechados; (c) estágio N1; (d) estágio N2; (e) estágio N3; (f) estágio N4; (g) estágio REM.

2.4.1 Detecção da sonolência

Nos sistemas de detecção da sonolência, há o pressuposto inicial de que o indivíduo estará invariavelmente acordado. Além disso, presume-se que a transição do estado alerta para a sonolência ocorrerá de maneira usual, isto é, do estado de vigília para o estágio I do sono, antecedido de piscar de olhos demorados e ou olhos fechados. Os transientes cerebrais (*spindles*, complexos K e vértext) não serão considerados no escopo deste estudo, sendo o algoritmo de detecção proposto baseado apenas nos ritmos cerebrais.

Neste estudo, a utilização de um único canal de eletroencefalografia também é baseada na **condição inicial de vigília do indivíduo**. Considerando-se um sistema com apenas três estados – a saber: (i) acordado; (ii) acordado e de olhos fechados; (iii) estado N1 – elimina-se a necessidade das demais medidas utilizadas na polissonografia, utilizadas principalmente na

diferenciação entre o estado alerta e o estágio REM, cujos ritmos cerebrais são pouco distintos.

Quanto à escolha do canal a ser utilizado, há na literatura pouca referência ao assunto. Segundo ([CARSKADON; RECHTSCHAFFEN, 2000](#)), o estagiamento do sono (termo utilizado para referir-se à construção do hipnograma pelo especialista) pode ser feito utilizando-se apenas o canal C3 ou C4 de um paciente. Para a detecção da sonolência, ([PAL et al., 2008](#)) afirma que a utilização do canal O_z (ver Figura 2.6) tem um desempenho superior em relação aos outros canais. Já ([BABILONI et al., 2001](#)) sugere a utilização dos canais C_3 , P_3 , C_4 e P_4 . Neste estudo, optou-se por utilizar o canal F_{pz} por (i) melhor representar os ritmos alfa e teta; (ii) apresentar menor número de artefatos, em relação aos outros canais disponíveis nas bases de dados utilizadas; (iii) ser adequado à utilização em um sistema embarcado, sob a perspectiva de produto.

3 REPRESENTAÇÕES: TEMPO-FREQUÊNCIA E TEMPO-ESCALA

Segundo ([MALLAT, 1998](#)), no processamento de sinais é desejável a utilização de uma base de funções que represente adequadamente o sinal estudado e que ressalte algumas propriedades particulares deste sinal. Neste capítulo, serão revisados alguns conceitos básicos de álgebra linear, na Seção [3.1](#), necessários para compreender a representação de um sinal através da expansão em série, bem como a transformada que determina os coeficientes desta série.

Contudo, reescrever um sinal através de uma nova base pode resultar em perda de informações ou limitações relacionadas à escolha dessa base e sua dimensão. No caso da análise de Fourier, por exemplo, a informação no domínio do tempo e de descontinuidades são perdidas devido à utilização de funções trigonométricas periódicas como base da expansão do sinal.

De acordo com ([FARGE, 1992](#)), um erro muito comum ao se utilizar qualquer tipo de transformada é esquecer-se da influência das funções da base no domínio da transformada. Graves erros de interpretação são incorridos ao considerar-se a estrutura das funções que compõem a base da expansão como sendo parte do fenômeno em observação. Para reduzir este risco, deve-se optar pela representação do sinal em uma base de funções que esteja de acordo com a estrutura intrínseca do sinal em estudo.

Um sinal cerebral é o registro, no tempo, da amplitude do campo elétrico gerado pela corrente que flui através de um grupo de neurônios ([HAYKIN; Van Veen, 2001](#)). De acordo com ([SANCI; CHAMBERS, 2007](#)), diferentes estados cognitivos, entre eles a sonolência, podem ser detectados através de ritmos cerebrais. Assim, é desejável representar o sinal cerebral em uma base de funções que evidencie os ritmos cerebrais (através da frequência ou escala), juntamente com sua localização no tempo.

Neste contexto, na Seção [3.2](#) são definidas a transformada de Fourier – que utiliza como base funções senos e cossenos, representando o sinal no domínio da frequência – e a transformada janelada de Fourier – que possibilita a análise tempo-frequência em uma resolução fixa. Essas técnicas são utilizadas no Capítulo [4](#) para a extração de características e para a determinação do espectro de frequências de um sinal cerebral.

As funções wavelets são utilizadas como principal ferramenta de análise no desenvolvimento deste estudo e, assim como as funções seno e cosseno, também formarão uma base para a representação de outras funções. Nos exemplos utilizados, essas funções representadas por expansões em séries com base wavelet serão os sinais cerebrais a serem analisados.

Integrando conceitos multidisciplinares da matemática, física e engenharia, a denominação *wavelet* (onda pequena, originalmente do francês *ondelette*) foi proposta na década de 1980 por Jean Morlet e seu grupo. Desde então, atraiu a atenção de muitos pesquisadores e possui aplicações nas mais variadas áreas, dentre elas a estatística, física, computação, engenharia elétrica, análise matemática e matemática aplicada (MOHLENKAMP; PEREYRA, 2008).

As principais contribuições que impulsionaram a criação e o desenvolvimento da Teoria das Wavelets podem ser sintetizadas cronologicamente (DAUBECHIES, 1996):

- (1981) Jean Morlet cria o conceito de transformada wavelet;
- (1985) Yves Meyer tem conhecimento do trabalho de J. Morlet, faz associações com a teoria de análise harmônica e desenvolve as primeiras bases wavelets ortonormais;
- (1988) Stephane Mallat e Yves Meyer desenvolvem a teoria de análise multirresolução;
- (1988) Ingrid Daubechies cria uma família de wavelets ortogonais de suporte compacto;
- (1989) Stephane Mallat desenvolve o algoritmo para a transformada wavelet rápida;
- (1990) A partir desta data, é cada vez maior o número de aplicações e metodologias wavelets desenvolvidas.

Daubechies refere-se às wavelets como uma ferramenta que "fatia os dados", funções ou operadores em diferentes componentes de frequência e então, estuda cada componente com uma resolução associada a sua escala. A transformada wavelet de um sinal variando no tempo depende de dois parâmetros: escala (relacionada à frequência) e translação (relacionada ao tempo). Dessa forma, considerando-se a relação entre escalas e frequências, as wavelets fornecem uma ferramenta para a localização e análise tempo-frequência de um sinal (DAUBECHIES, 1992).

Na Seção 3.3, as wavelets são introduzidas através da formulação da transformada wavelet contínua. Após, a transformada wavelet discreta será desenvolvida para a família de wavelets ortonormais de Daubechies, na Seção 3.4. Por fim, na Seção 3.5, será apresentada a relação entre escalas e frequências.

3.1 Representação e transformadas de sinais

Para compreender a representação de um sinal f através de uma série (série de Fourier ou série wavelet, por exemplo), é necessário considerar este sinal como um elemento de algum espaço vetorial V . Neste estudo, assumimos $V = L^2(\mathbb{R})$ o espaço das funções de quadrado integrável. A representação de f em série nada mais é do que a expansão de f na base de V .

As wavelets são funções que podem gerar uma base ortonormal do $L^2(\mathbb{R})$, assim como fazem as funções trigonométricas, entre outras. Sendo assim, qualquer função $f \in L^2(\mathbb{R})$ pode ser representada em função de uma base wavelet ou trigonométrica.

O número de vetores da base determina a dimensão do espaço: \mathbb{R}^n é um espaço de dimensão n , enquanto $L^2(\mathbb{R})$ é um espaço de dimensão infinita. As funções de $L^2(\mathbb{R})$ correspondem a vetores de dimensão infinita e a vetores de dimensão finita, quando discretizadas e truncadas – o que ocorre na prática em processamento e análise de sinais.

Nos conceitos e definições a seguir¹, um paralelo é traçado entre os vetores do espaço \mathbb{R}^n e as funções do espaço $L^2(\mathbb{R})$:

O produto interno de um espaço vetorial é uma generalização do conceito de ortogonalidade do \mathbb{R}^3 , utilizada de maneira a permitir uma métrica deste espaço. Em espaços \mathbb{R}^n , o produto interno possibilita a medida de comprimentos e ângulos entre vetores; no espaço $L^2(\mathbb{R})$, o produto interno permite mensurar a correlação entre funções. O produto interno usual em \mathbb{R}^n e $L^2(\mathbb{R})$ é dado por:

$$(\cdot, \cdot) : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R} \quad (3.1)$$

$$(u, v) \mapsto \langle u, v \rangle = \sum_{i=1}^n u_i v_i. \quad (3.2)$$

$$\langle \cdot, \cdot \rangle : L^2(\mathbb{R}) \times L^2(\mathbb{R}) \rightarrow \mathbb{R} \quad (3.3)$$

$$(f, g) \mapsto \langle f, g \rangle = \int_{-\infty}^{+\infty} f(t) \overline{g(t)} dt = \int_{-\infty}^{+\infty} f(t) g(t) dt, \quad (3.4)$$

sendo \bar{g} o conjugado complexo de g .

A norma (comprimento ou módulo de um vetor $\mathbf{u} \in \mathbb{R}^n$) é dada por:

$$\|\mathbf{u}\| = \sqrt{\langle \mathbf{u}, \mathbf{u} \rangle}, \quad \mathbf{u} \in \mathbb{R}^n, \quad (3.5)$$

$$\|f\| = \sqrt{\langle f, f \rangle}, \quad f \in L^2(\mathbb{R}). \quad (3.6)$$

$$(3.7)$$

A condição de ortogonalidade, inspirada no que ocorre em \mathbb{R}^2 e \mathbb{R}^3 , quando $\mathbf{u} \perp \mathbf{v}$, é definida como:

$$(\mathbf{u}, \mathbf{v}) = 0, \quad \mathbf{u} \in \mathbb{R}^n, \quad (3.8)$$

$$\langle f, g \rangle = 0, \quad f \in L^2(\mathbb{R}). \quad (3.9)$$

¹O desenvolvimento completo das definições aqui apresentadas são encontradas em ([BOLDRINI et al., 1980](#)), para \mathbb{R}^n , e em ([REED; SIMON, 1980](#)) para $L^2(\mathbb{R})$.

Definição 3.1.1 Um conjunto de vetores $\{\mathbf{v}_i\}$ em um espaço vetorial V , com produto interno $\langle \cdot, \cdot \rangle$ definido, será ortonormal se

$$\langle \mathbf{v}_i, \mathbf{v}_j \rangle_V = \delta_{i,j}, \quad \forall i, j, \quad (3.10)$$

sendo

$$\delta_{i,j} = \begin{cases} 1, & \text{se } i = j \\ 0, & \text{se } i \neq j \end{cases} \quad (3.11)$$

Definição 3.1.2 Uma base de um espaço vetorial V é um conjunto de vetores linearmente independentes que geram o espaço.

São exemplos de base:

$\{\mathbf{e}_j\}_{j=1,2,\dots,n} | \mathbf{e}_j = (x_1, \dots, x_n), x_i = 0 \text{ se } i \neq j, x_i = 1 \text{ se } i = j\}$ é uma base ortonormal de \mathbb{R}^n , denominada Base Canônica;

$\{a_\omega = \cos(\omega t), b_\omega = \sin(\omega t)\}_{\omega \in \mathbb{Z}}$ é uma base ortonormal para $L^2(\mathbb{R})$.

É possível representar qualquer vetor $\mathbf{v} \in \mathbb{R}^n$ através de uma combinação linear dos elementos da base escolhida para o espaço:

$$\mathbf{v} = \sum_{j=1}^n b_j \mathbf{e}_j. \quad (3.12)$$

Considerando-se a propriedade de linearidade do produto interno e a ortonormalidade da base canônica ($\mathbf{e}_i \in \{\mathbf{e}_j\}$), calcula-se o produto interno de \mathbf{e}_i com cada membro da equação (3.12):

$$\langle \mathbf{v}, \mathbf{e}_i \rangle = \left\langle \sum_{j=1}^n b_j \mathbf{e}_j, \mathbf{e}_i \right\rangle = \sum_{j=1}^n b_j \langle \mathbf{e}_j, \mathbf{e}_i \rangle = \sum_{j=1}^n b_j \delta_{i,j} = b_i, \quad (3.13)$$

logo, $b_i = \langle \mathbf{v}, \mathbf{e}_i \rangle$.

Seja $G = \{g_j\}_{j \in \mathbb{Z}}$ uma base ortonormal do espaço $L^2(\mathbb{R})$, é possível escrever cada um de seus vetores f , que são funções ou sinais, como uma combinação linear dos elementos da base G . Essa combinação linear é na verdade uma expansão em série de funções, sendo $c_j = \langle f, g_j \rangle$ os coeficientes desta expansão:

$$f = \sum_{j \in \mathbb{Z}} c_j g_j. \quad (3.14)$$

A expansão do sinal f em série de funções da base $G = \{g_j\}_{j \in \mathbb{Z}}$ é uma projeção deste sinal no espaço vetorial $L^2(\mathbb{R})$ e trata-se, portanto, de uma transformação linear. O processo de

obtenção dos coeficientes c_j desta transformação é geralmente denominado de transformada, como no caso das transformadas rápidas de Fourier ou transformada rápida wavelet, cujas expressões serão detalhadas nas próximas seções.

Devido a limitações computacionais, o cálculo da expansão em série (3.14) geralmente é truncado em N termos, ou seja, escolhe-se uma representação utilizando apenas N funções da base. Seja $P_{G_N}f$ a projeção de f no subespaço $G_N = \{g_1, \dots, g_N\}$, $G_N \subset G$:

$$P_{G_N}f = f^N = \sum_{j=1}^N \langle f, g_j \rangle g_j. \quad (3.15)$$

O erro entre o sinal original f e sua representação é dado por $\|f - f^N\|$ e deve ser sempre minimizado de modo a garantir a melhor representação do sinal.

3.2 Transformada de Fourier

A transformada de Fourier é uma importante ferramenta analítica no domínio da frequência e recebe esta denominação em homenagem ao matemático francês Joseph Fourier (1768 – 1830), dada sua grande contribuição à teoria de representação e análise de funções.

Fourier provou ser possível expandir um grande número de funções em séries de funções harmônicas puras (senos e cossenos)². Pela fórmula de Euler, as funções harmônicas podem ser representadas por uma exponencial complexa:

$$e^{i\omega t} = \cos(\omega t) + i \sin(\omega t). \quad (3.16)$$

Segundo (FIGUEIREDO, 1987), a transformada de Fourier é a maneira com a qual se determina os coeficientes b_j da expansão (3.14) de um sinal quando g_j é uma base formada por senos e cossenos, dada por (3.16) para $\omega \in \mathbb{R}$.

Os coeficientes de Fourier são obtidos através do produto interno entre o sinal analisado e cada uma das funções harmônicas de frequência ω :

$$c_\omega = \langle f(t), e^{i\omega t} \rangle \quad (3.17)$$

$$c_\omega = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} f(t) \overline{e^{i\omega t}} dt. \quad (3.18)$$

A expansão em série de Fourier de uma função $f(t)$ é dada pela transformada inversa de Fourier, na qual cada função $e^{i\omega t}$ da base representa uma frequência ω :

$$f(t) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} c_\omega e^{i\omega t} d\omega. \quad (3.19)$$

²A convergência da série de Fourier é demonstrada em (REED; SIMON, 1980). No escopo deste trabalho, considera-se que a série de Fourier converge para a quase totalidade dos sinais físicos contínuos (HAYKIN; Van Veen, 2001).

O conteúdo médio harmônico de frequência ω , para toda a função $f(t)$, é representado pelo coeficiente c_ω . Considerando-se que um sinal contínuo não varia no tempo, isto é, possui frequência de 0 Hz, a média do sinal é representada pelo coeficiente c_0 , também denominado *termo contínuo*.

Uma vez que as funções da base utilizada são de natureza periódica e duração infinita, a transformada de Fourier é melhor empregada na representação de sinais periódicos e harmônicos, não sendo a mais adequada para representar sinais com descontinuidades ou os quais deseja-se também a localização no tempo ou espaço (NIELSEN, 1998).

3.2.1 STFT - Short Time Fourier Transform

A STFT, também denominada *transformada de Fourier janelada* ou *transformada breve de Fourier*, é uma extensão da transformada de Fourier, aplicável a sinais não-estacionários ou para obtenção da localização tempo-frequência.

A estratégia utilizada consiste em multiplicar cada senoide da base da transformada por uma função janela $w(t)$ (função não-nula em apenas um intervalo limitado de tempo). Assim, tem-se uma nova base para a STFT, cujas funções são definidas pelos parâmetros ω (frequência) e τ (posição):

$$G = \{w(t - \tau)e^{i\omega t}\}_{\omega \in \mathbb{R}, \tau \in \mathbb{Z}} \quad (3.20)$$

A STFT é dada pelo cálculo dos coeficientes $F(\tau, \omega)$, determinados pela relação:

$$F(\tau, \omega) = \int_{-\infty}^{\infty} f(t)\overline{w(t - \tau)e^{i\omega t}} dt. \quad (3.21)$$

A transformada inversa da STFT, para um determinado valor de τ , é dada por:

$$f(t)w(t - \tau) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(\tau, \omega)e^{i\omega t} d\omega. \quad (3.22)$$

A escolha do formato e comprimento da janela tem um forte impacto na decomposição do sinal. O primeiro varia de acordo com a função escolhida para gerá-la e determina sua capacidade de resolução em frequência. Já o comprimento define o intervalo da janela e, portanto, sua resolução temporal. Isto é verificado na Figura 3.1, onde são apresentadas as características das janelas de Hamming e Blackman, definidas pelas Equações (3.24) e (3.23), respectivamente.

As janelas de Hamming e Blackman são definidas, em sua forma discreta e considerando

um intervalo de M amostras, por (SMITH, 2002):

$$w_h(t) = 0.54 - 0.46 \cos(2\pi t/M), \quad \text{Janela de Hamming}; \quad (3.23)$$

$$w_b(t) = 0.42 - 0.5 \cos(2\pi t/M) + 0.08 \cos(4\pi t/M), \quad \text{Janela de Blackman}; \quad (3.24)$$

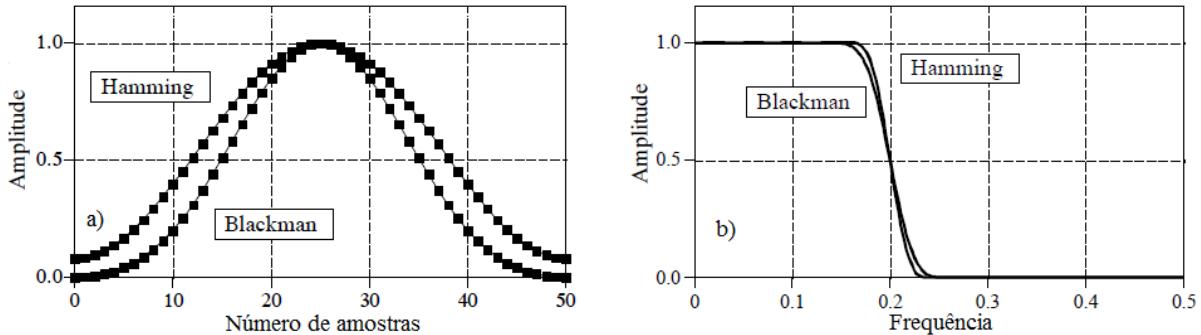


Figura 3.1: Características das janelas de Hamming e Blackman. Em (a) as formas de onda das duas janelas, para um comprimento de 50 amostras; em (b) a resposta em frequência para cada janela em relação à frequência de amostragem. Adaptado de (SMITH, 2002).

Uma vez definidos a forma e o comprimento da janela da STFT, estes serão fixos para toda a transformada. A alteração desses parâmetros resulta em bases de funções diferentes e, portanto, em transformadas diferentes (ROCHA et al., 2008). Adiante, na Seção 3.5.1, a relação entre a resolução de tempo e a resolução de frequência será discutida com maiores detalhes.

Neste estudo, a STFT foi aplicada na análise espectral do sinal cerebral, utilizando o algoritmo disponível no software MATLAB®, *Signal Processing Toolbox*. Foi utilizada a janela de Hamming, com 512 pontos, e sobreposição de 500 pontos. A janela de Hamming foi escolhida pela simplicidade de implementação e por oferecer resoluções de tempo e frequência adequadas aos sinais deste estudo.

O quadrado do módulo da STFT de um sinal é denominado *espectrograma*, sendo amplamente utilizado por fornecer a medida da energia de um sinal no plano tempo-frequência (HAYKIN; Van Veen, 2001). A Figura 3.2(b) apresenta o espectrograma de um sinal cerebral característico de sonolência, calculado para o sinal mostrado na Figura 3.2(a) e correspondente ao intervalo 10-20s da época 859 do paciente *sc4002*, obtido da base PhysioNet. Pela análise da STFT, observa-se a presença do ritmo alfa em todo o intervalo do sinal, com a ocorrência do ritmo delta no intervalo de 14-19s do sinal.

3.3 Transformada Wavelet Contínua - TWC

Através de dilatações e translações de uma função principal $\psi(t)$, é possível construir um conjunto de funções geradoras do espaço $L^2(\mathbb{R})$, denominadas funções *wavelets* (DAUBECHIES, 1992). Na forma contínua, embora gerem o espaço $L^2(\mathbb{R})$, estas funções não são linearmente independentes e portanto, não formam uma base de acordo com a Definição 3.1.2 – há mais funções wavelets do que o mínimo necessário para gerar o espaço.

Mesmo assim, a representação de um sinal através das wavelets contínuas é uma ferramenta muito utilizada para a análise de séries temporais em diferentes escalas de tempo, com transitórios e variações, sendo amplamente utilizada na análise de sinais meteorológicos (TORRENCE C., 1998), análise de sinais geofísicos, entre outros (MALLAT, 1998).

Para dar origem a uma família de funções wavelets, as seguintes propriedades devem ser satisfeitas pela wavelet geradora $\psi(t)$:

(i) A função wavelet é absolutamente integrável:

$$\int_{-\infty}^{+\infty} |\psi(t)| dt < \infty. \quad (3.25)$$

(ii) A função wavelet possui energia finita:

$$\int_{-\infty}^{+\infty} |\psi(t)|^2 dt < \infty. \quad (3.26)$$

(iii) É satisfeita a condição de **admissibilidade**.

Esta propriedade merece destaque uma vez que possibilita a existência desta classe de funções e carrega intrinsecamente outras propriedades. A condição de admissibilidade – provada pelo matemático argentino Calderón em 1964, e em seguida provada também por Grossmann e Morlet (MALLAT, 1998) – é dada pela seguinte expressão, onde $\hat{\psi}(\omega)$ é a transformada de Fourier de $\psi(t)$:

$$C_\psi = \int_0^{+\infty} \frac{|\hat{\psi}(\omega)|^2}{\omega} d\omega < +\infty. \quad (3.27)$$

A existência desta condição implica em algumas outras propriedades das wavelets: para que a condição de admissibilidade seja verdadeira, é necessário que $\hat{\psi}(0) = 0$. Isto implica que a média da função wavelet deve ser nula no domínio do tempo, o que a caracteriza como uma função oscilatória. Ainda, $\hat{\psi}(0) = 0$ identifica $\hat{\psi}$ como sendo a função de transferência de um filtro passa-faixas (MALLAT, 1998). De uma maneira

geral, a condição de admissibilidade determina o comportamento da família wavelet no domínio da frequência.

Segundo (TORRENCE C., 1998), a escolha da wavelet $\psi(t)$ é determinada pela aplicação e deve considerar: (i) se a wavelet é ortogonal ou não; (ii) se a wavelet é complexa ou real; (iii) a largura da wavelet, que influencia na resolução de tempo ou frequência; (iv) a forma da wavelet, devendo ser procurada aquela cuja forma de onda melhor se ajuste ao sinal estudado. Ainda, segundo o mesmo autor, na maioria dos casos a escolha da wavelet é realizada de maneira arbitrária. Neste estudo, para a análise de sinais cerebrais através da TWC foi utilizada a wavelet de Meyer, definida no Apêndice A.

Através da transformada wavelet contínua, os coeficientes wavelets de f são determinados pela seguinte relação:

$$Wf(\alpha, \tau) = \langle f, \psi_{\alpha, \tau} \rangle = \int_{-\infty}^{+\infty} f(t) \overline{\psi_{\alpha, \tau}(t)} dt, \quad (3.28)$$

onde $\psi_{\alpha, \tau}$, $\alpha, \tau \in \mathbb{R}$ é a wavelet $\psi(t)$ nas diferentes escalas (α) e respectivos deslocamentos (τ).

A reconstrução do sinal $f(t)$ é dada pela TWC inversa:

$$f(t) = \frac{1}{C_\psi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} Wf(\alpha, \tau) \psi_{\alpha, \tau} \frac{d\tau d\alpha}{\alpha^2}, \quad (3.29)$$

sendo C_ψ denominado *fator de reconstrução da wavelet* (TORRENCE C., 1998) e depende somente da wavelet $\psi(t)$ utilizada (DAUBECHIES, 1992). Para wavelets cuja função explícita é conhecida, o valor de C_ψ é calculado através do primeiro termo da Relação (3.27).

A disposição gráfica dos coeficientes wavelets obtidos através da TWC é denominada *escalograma*. A Figura 3.2(c) apresenta o escalograma de um sinal cerebral característico de sonolência³, obtido através da TWC utilizando a wavelet de Meyer, com variação da escala de 0.1 no intervalo [0,50]. Nas Figuras 3.2(a) e 3.2(b) estão a representação no tempo e o spectrograma, obtido via STFT, deste mesmo sinal. Da análise da figura, observa-se a coerência entre o spectrograma e o escalograma na representação dos ritmos cerebrais. A diferença na resolução tempo-frequência entre as duas técnicas de análise será abordada com detalhes na Seção 3.5.

Uma vez que a TWC possui informação redundante nas diferentes escalas, alguns aspectos devem ser considerados na interpretação e análise do escalograma (MISITI; POGGI, 2010):

- Cone de influência: cada coeficiente wavelet influencia coeficientes wavelets vizinhos de escalas mais grosseiras. Esta influência fica mais acentuada em regiões onde o próprio

³Sinal correspondente ao intervalo 10-20s da época 859 do paciente sc4002, da base de dados PhysioNet.

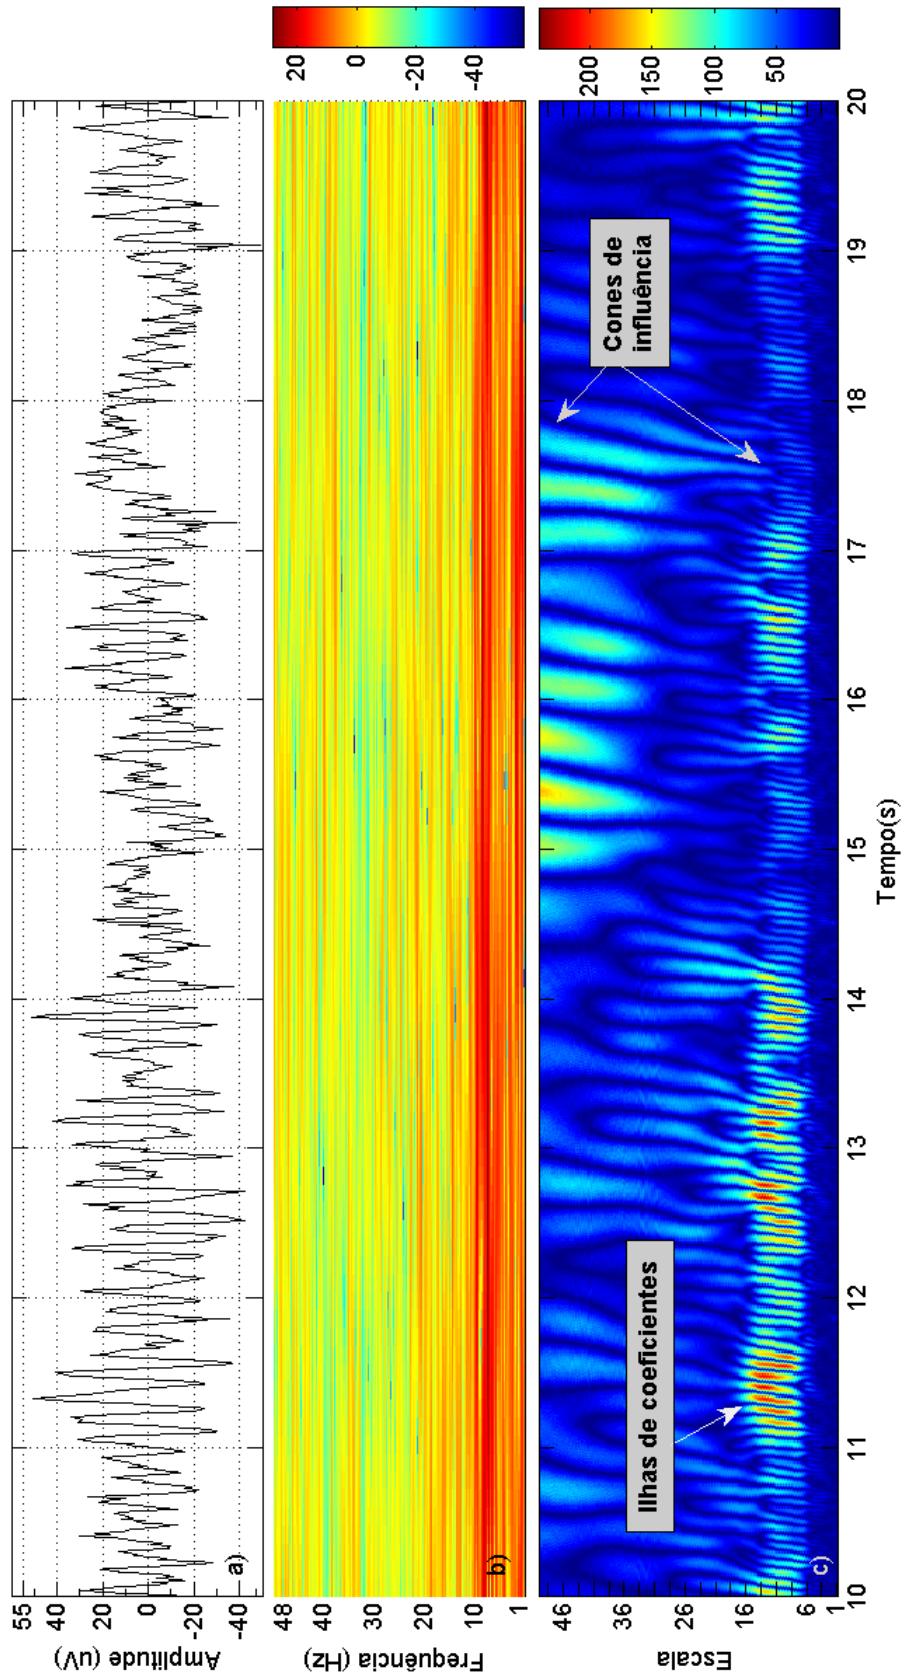


Figura 3.2: Sinal de EEG de um indivíduo apresentando sonolência (PhysioNet, paciente sc4002, época 859, amostrado a 100Hz). (a) Representação do sinal no tempo; (b) Espectrograma do sinal via STFT, utilizando janela de Hamming de 512 pontos; (c) Escalograma do sinal via TWC utilizando a wavelet de Meyer (no eixo das ordenadas estão representadas as escalas na forma α^{-1}).

sinal apresenta grandes variações. Como as malhas em questão são diádicas e a relação de distância entre os pontos destas malhas possui um fator de escala de 2, ao diminuirmos a resolução, a região de influência abrange cada vez vizinhos mais distantes da posição inicialmente considerada, formando ao longo dos níveis um cone. Esse comportamento está relacionado ao suporte da wavelet e justifica a forma cônica da representação gráfica dos valores dos coeficientes, conforme destacado na Figura 3.2(c).

- Detecção de transitórios: mudanças abruptas ou descontinuidades no sinal geram coeficientes wavelets com valores altos. Devido à propriedade anterior, transitórios são melhor localizados em baixas escalas. Na análise de sinais cerebrais, esta propriedade permite a identificação de artefatos ou transição de ritmos. Na Figura 3.2(c) observa-se a transição do ritmo delta para alfa no tempo 18s e 19s.
- Detecção de características dos sinais: coeficientes com valores altos indicam grande correlação entre o sinal avaliado e a wavelet de análise naquela escala. Assim, um evento no sinal causa a formação de ilhas no escalograma, isto é, um grupo de coeficientes representando o mesmo evento, em razão da redundância da base de funções wavelets contínuas. Estão apontadas na Figura 3.2(c) as ilhas de coeficientes representando a ocorrência do ritmo alfa.

3.4 Transformada Wavelet Discreta - TWD

Uma vez que os sinais cerebrais utilizados neste estudo são discretizados, a transformada wavelet discreta apresenta-se como uma ferramenta adequada ao processamento destes sinais. A análise multirresolução, apresentada na Seção 3.4.1, é o fundamento necessário para a compreensão da TWD – definida neste estudo utilizando a família de wavelets ortonormais de suporte compacto de Daubechies (DAUBECHIES, 1992).

3.4.1 Análise multirresolução – AMR

Dado o espaço de funções $L^2(\mathbb{R})$, este pode ser decomposto em uma cadeia de subespaços aninhados, de diferentes resoluções (NIELSEN, 1998):

$$\{0\} \subset \cdots \subset V_{-2} \subset V_{-1} \subset V_0 \subset V_1 \subset V_2 \subset \cdots \subset L^2(\mathbb{R}).$$

V_0 é identificado como sendo o espaço das funções discretizadas sobre uma malha com espaçamento unitário, ou seja, sobre o conjunto dos números inteiros \mathbb{Z} . O espaço V_1 , além de

conter toda a informação dada em V_0 , ainda contém informação representada nos pontos médios entre os valores inteiros. Desta forma, o espaçamento h entre os pontos das malhas em V_1 é de $1/2$. Assim, conforme o sub-índice j dos espaços V_j aumenta, menor é o espaçamento entre os pontos da malha associada ao espaço ($h_j = 1/2^j$) e naturalmente, maior é a quantidade de pontos considerada em cada malha.

Na Figura 3.3 é apresentado um exemplo de análise multirresolução, assumindo-se V_3 como o espaço de representação mais refinado no qual um sinal discreto é considerado. Nesta figura os valores da função são interpolados linearmente apenas para facilitar a compreensão do efeito da perda de resolução quando se passa de um nível mais refinado para um mais grosso. Na Figura 3.3(a) o mesmo sinal é representado em três níveis menores de resolução, ou seja, é dada sua representação no espaço V_2 , no qual apenas metade dos pontos são considerados; em V_1 contendo $1/4$ dos pontos iniciais; e no nível mais grosso considerado, V_0 . Na Figura 3.3(b) são representadas as malhas correspondentes associadas a cada espaço V_j , $j = 3, 2, 1, 0$.

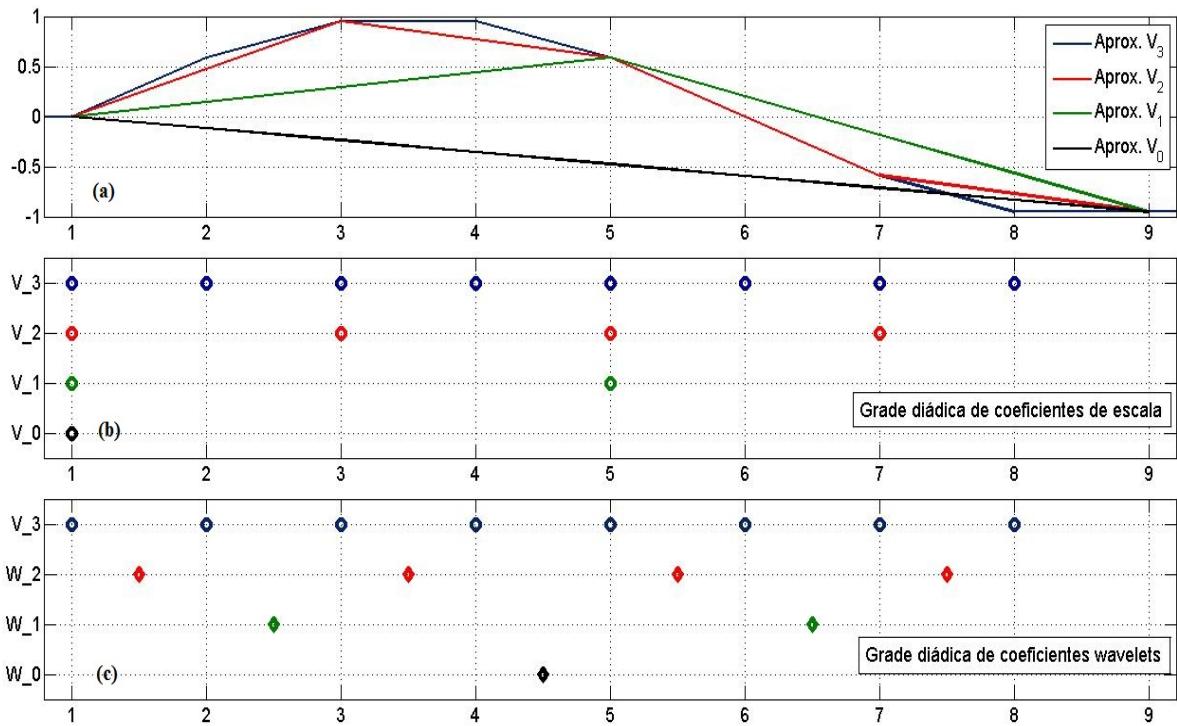


Figura 3.3: Exemplo de análise multirresolução: (a) representação de um sinal discreto em 4 níveis de resolução, considerando o nível mais refinado com 16 pontos e espaçamento $h = 1/8$, e o nível mais grosso com 2 pontos e espaçamento $h = 1$. (b) Representação das malhas diádicas de cada um dos níveis da multirresolução considerados. (c) Posições complementares entre os níveis 3,2,1 e 0 da multirresolução.

A análise multirresolução é definida através de axiomas que estabelecem as relações entre os subespaços encadeados que fatoram $L^2(\mathbb{R})$ em diferentes resoluções (MOHLENKAMP;

(PEREYRA, 2008; STRANG; NGUYEN, 1996; NIELSEN, 1998):

$$(i) \quad \bigcap_{j \in Z} V_j = \{0\} \text{ e } \overline{\bigcup_{j \in Z} V_j} = L^2(\mathbb{R});$$

Este axioma estabelece a *completude* do sistema multirresolução, uma vez que a união de todos os subespaços representa o espaço $L^2(\mathbb{R})$. Além disso, a intersecção entre todos os espaços V_j é apenas a função nula.

$$(ii) \quad f(t) \in V_j \iff f(2t) \in V_{j+1};$$

Indica a invariância de escala.

$$(iii) \quad f(t) \in V_0 \iff f(t - k) \in V_0 \quad \forall k \in \mathbb{Z};$$

Indica a invariância ao deslocamento dentro de cada escala fixada.

$$(iv) \quad \text{Existe uma } \text{função escala } \phi \in V_0 \text{ tal que } \{\phi(t - k)\}_{k \in \mathbb{Z}} \text{ é uma base ortonormal de } V_0.$$

Do axioma (iv), tem-se que uma base $\{\phi(t - k)\}_{k \in \mathbb{Z}}$ é gerada através de translações da função $\phi \in V_0$. Do axioma (ii), tem-se que é possível criar, via dilatação de $\phi(t)$ e suas translações $\phi(t - k), \forall k$, bases para os subespaços nas demais escalas: $\{\phi(t - k)\}_{k \in \mathbb{Z}}$.

As funções escalas que formam a base ortonormal de V_j , para cada nível j , são então denotadas por:

$$\phi_{j,k}(t) = 2^{j/2} \phi(2^j t - k), \quad (3.30)$$

sendo k o parâmetro que define a posição em cada nível.

Para cada V_j , é então definido um complemento ortogonal W_j de modo que a soma direta entre ambos subespaços gere V_{j+1} :

$$V_{j+1} = V_j \oplus W_j. \quad (3.31)$$

Pertencentes aos espaços W_j , definem-se as funções wavelets, para cada nível j e posições k em cada nível:

$$\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k). \quad (3.32)$$

Considerando-se os espaços V_{J_0} , de aproximação grosseira, e V_J , de aproximação refinada, onde $J_0 < J$, e aplicando-se a Relação (3.31) recursivamente, obtem-se:

$$V_J = V_{J_0} \oplus \left(\bigoplus_{j=J_0}^{J-1} W_j \right). \quad (3.33)$$

O axioma (ii) define a base do espaço de aproximação V_j , formada pela família de funções escalas:

$$\phi(t - k) \in V_j \leftrightarrow \phi(2(t - k)) \in V_{j+1}. \quad (3.34)$$

De maneira análoga, a base do espaço de detalhes W_j é formada pela família de funções wavelets:

$$\psi(t - k) \in W_j \leftrightarrow \psi(2(t - k)) \in W_{j+1}. \quad (3.35)$$

Uma função $f(t) \in L^2(\mathbb{R})$ pode ser representada por uma expansão em série de funções escalas, através da projeção de f em V_j :

$$f(t) \approx P_{V_j} f = \sum_{l=-\infty}^{\infty} c_{j,l} \phi_{j,l}(t), \quad t \in \mathbb{R}, \quad (3.36)$$

onde

$$c_{j,l} = \int_{-\infty}^{\infty} f(t) \phi_{j,l}(t) dt, \quad j = J, J-1, \dots, J_0. \quad (3.37)$$

3.4.2 Wavelets ortonormais de Daubechies: Db

Considerando que o espaço $V_0 \subset V_1$, a função $\phi(t) = \phi_{0,0}(t) \in V_0$ pode ser escrita através da *equação de dilatação*:

$$\phi(t) = 2^{1/2} \sum_{k=0}^{D-1} h_k \phi(2t - k), \quad (3.38)$$

onde:

$$h_k = \langle \phi(t), \phi_{1,k} \rangle = \int_{-\infty}^{\infty} \phi(t) \overline{\phi_{1,k}(t)} dt. \quad (3.39)$$

Do mesmo modo, considerando que o espaço $W_0 \subset V_1$, a função $\psi(t) = \psi_{0,0}(t) \in W_0$ pode ser escrita em função de $\phi_{1,k}(t)$, através da *equação wavelet*:

$$\psi(t) = 2^{1/2} \sum_{k=0}^{D-1} g_k \phi(2t - k), \quad (3.40)$$

onde:

$$g_k = \langle \psi(t), \phi_{1,k} \rangle = \int_{-\infty}^{\infty} \psi(t) \overline{\phi_{1,k}(t)} dt = (-1)^k h_{D-1-k}, \quad k = 0, 1, \dots, D-1.. \quad (3.41)$$

Nas Equações (3.38) e (3.40), D é um inteiro positivo, denominado *gênero da wavelet*. Os coeficientes de filtro h_k e g_k , embora sejam definidos formalmente pelas Equações (3.39) e (3.41), são obtidos indiretamente através de propriedades de ϕ e ψ (NIELSEN, 1998; DAUBECHIES, 1992).

Considerando a propriedade dada por (3.31), a expansão de uma função f em V_j , dada pela expressão (3.36) pode ser reescrita envolvendo então as projeções de f em V_{j-1} e W_{j-1} , uma vez que W_{j-1} também possui base ortonormal dada por $\psi_{J-1,k}$. No entanto, como o número de fatorações em uma análise multirresolução é arbitrário, vale a decomposição dada por (3.33) para quaisquer escolhas de níveis grosseiro J_0 e mais refinado J . Assim, a expansão em série wavelet discreta é dada por:

$$f(t) \approx P_{V_J} f = \sum_{l=0}^{2^{J_0}-1} c_{J_0,l} \phi_{J_0,l}(t) + \sum_{j=J_0}^{J-1} \sum_{l=0}^{2^j-1} d_{j,l} \psi_{j,l}(t). \quad (3.42)$$

onde

$$c_{J_0,l} = \int_{-\infty}^{\infty} f(t) \phi_{J_0,l}(t) dt, \text{ são os coeficientes de escala,} \quad (3.43)$$

$$d_{j,l} = \int_{-\infty}^{\infty} f(t) \psi_{j,l}(t) dt, \text{ são os coeficientes wavelets.} \quad (3.44)$$

A Figura 3.4 exibe uma representação em árvore dos subespaços V_j e W_j em uma profundidade de 3 níveis. A movimentação entre os diferentes níveis de resolução dá-se através da Equação de Dilatação ((3.39)) e da Equação Wavelet ((3.41)) (NIELSEN, 1998).

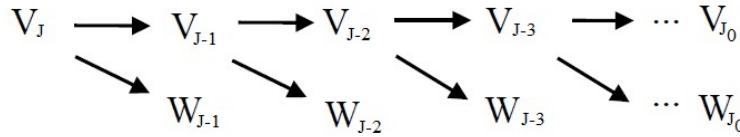


Figura 3.4: Estrutura em árvore da análise multirresolução. Do nível mais fino (J), à esquerda, ao nível mais grosseiro (J_0), à direita.

Considerando-se a projeção $P_{V_j} f$ de f no espaço V_j , o espaço W_j contém os detalhes que complementam as aproximações de f naquele nível, de modo a formar uma aproximação de maior resolução V_{j+1} . A informação contida nos espaços V_j é redundante, uma vez que $V_{j-1} \subset V_j$, enquanto que os espaços W_j são ortogonais entre si.

Na Figura 3.3(c) são apresentadas as malhas associadas aos espaços $W_j, j = 3, 2, 1$ do exemplo simplificado com apenas 16 pontos iniciais. Na verdade, a relação entre as malhas é válida para todos os níveis e para qualquer quantidade de pontos considerada, uma vez que os espaços W_j são considerados os espaços contendo os complementos de informação entre os espaços V_j e V_{j+1} .

3.4.3 Propriedades da família de wavelets Db

Um grande número de famílias wavelets, adaptáveis às mais diversas aplicações, podem ser encontradas na literatura. Segundo MOHLENKAMP; PEREYRA (2008), deve-se pensar em

construir uma nova família wavelet somente se houver um grande motivo para fazê-lo.

Neste trabalho a transformada wavelet discreta é implementada através da família de wavelets ortonormais de Daubechies, expressas pelos coeficientes de filtro de escala e wavelet, h_k e g_k , respectivamente.

As principais vantagens na utilização das wavelets de Daubechies devem-se às seguintes propriedades: (i) são wavelets ortogonais; (ii) possuem suporte compacto, podendo ser implementadas via filtros FIR; (iii) apresentam a propriedade de momentos nulos e (iv) permitem identificar descontinuidades através do decaimento de seus coeficientes.

- (i) **Conservação da área:** do axioma (iv) da análise multirresolução (ver Seção 3.4.1), para que a função escala $\phi(t)$ seja ortonormal, é requerido que possua área unitária:

$$\int_{-\infty}^{\infty} \phi(t) dt = 1. \quad (3.45)$$

Integrando-se os dois termos da Equação 3.38 e substituindo-se (3.45), tem-se que:

$$\sum_{k=0}^{D-1} h_k = \sqrt{2}. \quad (3.46)$$

- (ii) **Suporte compacto:** de forma simplificada, uma wavelet com suporte compacto significa ser não-nula apenas em um intervalo fechado e limitado da reta. Tal característica torna-se importante na implementação de transformadas discretas através de filtros FIR (*Finite Impulse Response*), conforme abordado na Seção 3.4.5. Além disso, ao se utilizar uma wavelet de suporte compacto, apenas uma quantidade finita de termos da série será perturbada ao ocorrer alguma perturbação local no sinal.
- (iii) **Momentos nulos:** de forma concisa, uma wavelet cuja função escala possui M momentos nulos consegue representar polinômios de grau até $M - 1$ através apenas dos coeficientes da função escala. Isto é, o polinômio $p(t)$ de grau m é totalmente representado pelos coeficientes de escala e, portanto,

$$\int_{-\infty}^{\infty} \psi(t) t^m dt = 0, \quad m = 0, 1, \dots, M - 1. \quad (3.47)$$

O tamanho do suporte D das wavelets de Daubechies é dado em função do número de momentos nulos, através da relação $D = 2M$. Ainda, a denominação das wavelets de Daubechies é dada em função de D: para a família de wavelets com 2 momentos nulos, denomina-se DB2 e assim por diante.

(iv) **Decaimento dos coeficientes wavelets:** em uma abordagem simples, quando a função analisada apresentar alguma descontinuidade (na própria função ou em uma de suas derivadas), o decaimento dos coeficientes na região de descontinuidade será mais lento ou não decairá ([NIELSEN, 1998](#)). No entanto, coeficientes distantes desta descontinuidade não são afetados (existem $D - 1$ coeficientes afetados para cada nível da transformada). Sendo assim, os coeficientes em uma expansão em série wavelet refletem também as propriedades locais do sinal analisado.

No desenvolvimento deste estudo, optou-se por utilizar a família de wavelets ortonormais e de suporte compacto de Daubechies com dois momentos nulos (DB2), cujos coeficientes de filtro são apresentados na Tabela 3.1.

Tabela 3.1: Coeficientes de filtro da Wavelet DB2.

Filtro passa-baixa	Filtro passa-alta
$h_0 = 0.4829629131445341$	$g_0 = -0.1294095225512603$
$h_1 = 0.8365163037378077$	$g_1 = -0.2241438680420134$
$h_2 = 0.2241438680420134$	$g_2 = 0.8365163037378077$
$h_3 = -0.1294095225512603$	$g_3 = -0.4829629131445341$

A função escala da wavelet DB2 está representada na Figura 3.5(a) e a forma de onda da wavelet é mostrada na Figura 3.5(b).

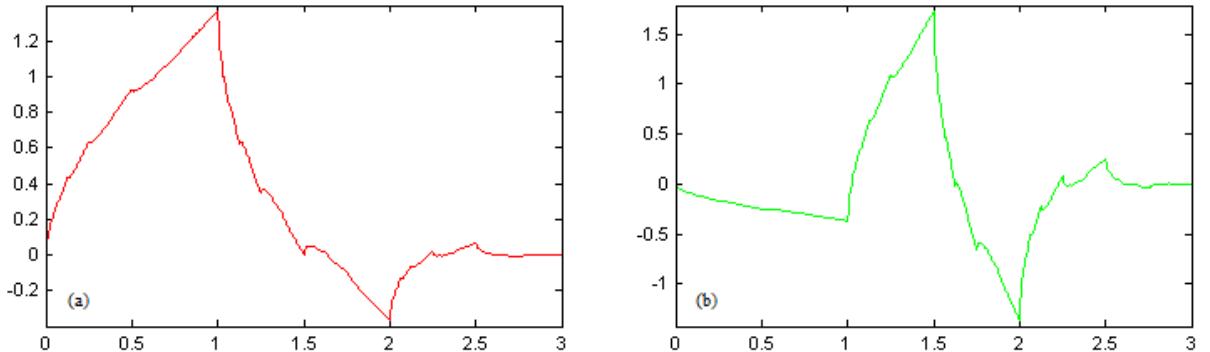


Figura 3.5: Wavelet DB2. (a) Função escala $\phi(t)$; (b) Função wavelet $\psi(t)$.

3.4.4 Transformada Wavelet Rápida

Na equação de dilatação (3.38) e na equação wavelet (3.40), utilizam-se os filtros tabelados da função escala, h_k (os filtros da wavelet DB2 estão na Tabela 3.1 da Seção 3.4.3; para as wavelets de Daubechies até 4 momentos nulos, ver o Apêndice B.2; para as demais, ver ([DAUBECHIES, 1992](#))). Os filtros da função wavelet, g_k , são obtidos através da Relação (3.41).

Seja um sinal $f(t) \in L^2(\mathbb{R})$, discretizado em $N = 2^J$ amostras. Tomando-se a sequência de amostras do sinal de entrada nos pontos da malha V_j como sendo o conjunto de coeficientes de escala do nível mais refinado J , $c_{J,l} = f(t_J, l)$, um sinal f pode então ser representado por sua projeção:

$$f(t) \approx \sum_{k=0}^{2^J-1} c_{J,l} \phi_{J,l}(t). \quad (3.48)$$

O sinal é então decomposto em níveis de menores de resolução, $J_0 \leq j \leq J$, sendo J_0 o nível mais grosso, através da transformada wavelet direta. Os coeficientes de escala e coeficientes wavelets nos diferentes níveis, $j = J - 1, \dots, J_0$, são calculados por:

$$c_{j-1,l} = \sum_{k=0}^{D-1} c_{j,2l+k} h_k, \quad (3.49)$$

$$d_{j-1,l} = \sum_{k=0}^{D-1} c_{j,2l+k} g_k. \quad (3.50)$$

A variação do parâmetro l , em cada nível, é dada pela relação $\sup(\phi_{j,l}) = \sup(\psi_{j,l}) = I_{j,l}$, sendo

$$I_{j,l} = \left[\frac{l}{2^j}, \frac{l+D-1}{2^j} \right]. \quad (3.51)$$

O processo inverso, isto é, a obtenção da aproximação da função original através dos coeficientes de escala e coeficientes wavelets calculados na transformada direta, é obtido através da Equação (3.42) (NIELSEN, 1998):

$$f(t) \approx P_{V_J} f = \sum_{l=0}^{2^{J_0}-1} c_{J_0,l} \phi_{J_0,l}(t) + \sum_{j=J_0}^{J-1} \sum_{l=0}^{2^j-1} d_{j,l} \psi_{j,l}(t).$$

Na reconstrução do sinal, para $J_0 \leq j \leq J$, sendo J o nível mais refinado, os coeficientes de escala do nível de maior resolução são obtidos pela relação:

$$c_{j,l} = \sum_{n=n_1(l)}^{n_2(l)} c_{j-1,n} h_{l-2n} + d_{j-1,n} g_{l-2n}, \quad (3.52)$$

sendo os limites $n_1(l)$ e $n_2(l)$ dados por:

$$\left\lceil \frac{l-(D-1)}{2} \right\rceil \equiv n_1(l) \leq n \leq n_2(l) \equiv \left\lfloor \frac{l}{2} \right\rfloor. \quad (3.53)$$

3.4.4.1 TWD periodizada

A implementação da TWD deve também considerar o impacto das fronteiras do sinal. Para um conjunto de coeficientes de escala $c_{j,l}$, $l \in [0, N-1]$, utilizando as wavelets de Daubechies

com suporte compacto não-periodizadas, ao serem aplicadas as Equações (3.49) e (3.50) o algoritmo incorrerá em um erro quando solicitar os coeficientes $c_{j,N}, \dots, c_{j,N+D-1}$, inexistentes na sequência de entrada.

Para solucionar este problema, dois métodos são comumente utilizados: (i) periodização dos dados de entrada ou (ii) extensão do conjunto de dados, conforme o tamanho do suporte da wavelet utilizada (preenchimento com zeros, réplica do sinal, entre outros). Neste estudo, utiliza-se a periodização proposta por ([NIELSEN, 1998](#)) no cálculo da TWD. Assim, as Equações (3.49) e (3.50) tornam-se:

$$c_{j-1,l} = \sum_{k=0}^{D-1} c_{j,\langle 2l+k \rangle_{2^j}} h_k, \quad (3.54)$$

$$d_{j-1,l} = \sum_{k=0}^{D-1} c_{j,\langle 2l+k \rangle_{2^j}} g_k, \quad (3.55)$$

onde $l = 0, 1, \dots, 2^{-1} - 1$; e $\langle x \rangle_z$ é o congruente de x pelo módulo z .

Utilizando-se a periodização, o algoritmo dado pela Equação (3.52) torna-se:

$$c_{j,l} = \sum_{n=n_1(l)}^{n_2(l)} c_{j-1,\langle n \rangle_{2^{j-1}}} h_{l-2n} + d_{j-1,\langle n \rangle_{2^{j-1}}} g_{l-2n}, \quad (3.56)$$

sendo os limites $n_1(l)$ e $n_2(l)$ dados pela Relação (3.53) e $l = 0, 1, \dots, 2^j - 1$.

3.4.4.2 Considerações sobre a implementação e análise da TWD

Para minimizar o impacto causado pelas bordas do sinal, é importante, além da utilização do algoritmo periodizado para a TWD, definir um nível mínimo de resolução adequado. Neste estudo, o nível mínimo da TWD foi estipulado $J_0 = 4$, considerando a utilização dos filtros da Wavelet DB2 (com suporte $D = 4$).

Outro aspecto a ser observado é que na literatura são apresentadas diferentes formas de indexação dos níveis da TWD, em uma análise multirresolução. Neste estudo, optou-se por indexar o nível mais refinado da TWD como $J = \log_2 N$, onde N é o comprimento do sinal de entrada expresso em potência de base 2. Assim, $J > J_0, \quad J, J_0 \in \mathbb{N}$. Cada nível j possui $N_j = 2^j$ coeficientes wavelets.

Na nomenclatura adotada neste estudo, cada nível da TWD está associado a uma escala através da relação:

$$\alpha^{-1} = 2^{J-j}, \quad (3.57)$$

onde J é o nível máximo da TWD; j é o nível atual da TWD e α^{-1} é a escala correspondente ao nível j .

A Figura 3.6 mostra a decomposição via TWD de um sinal cerebral característico de sonolência⁴ (Wavelet DB2, $J = 12$, $J_0 = 5$). Na indexação utilizada, quanto maior o nível da TWD, menor a escala e, portanto, a representação de frequências mais altas.

A análise do sinal dá-se de maneira diferente entre a TWC e a TWD: o ritmo alfa do sinal – evidente nos intervalos de 11-14s e 15,5-17s – é representado pela TWC através das ilhas de coeficientes, conforme a Figura 3.2(c); na TWD este ritmo é representado majoritariamente pelos coeficientes do nível $j = 9$, conforme a Figura 3.6(d), no qual observam-se os coeficientes de maior magnitude de toda a decomposição. Na Seção 4.2.1, a representação dos ritmos cerebrais através dos níveis da TWD será abordada com detalhes.

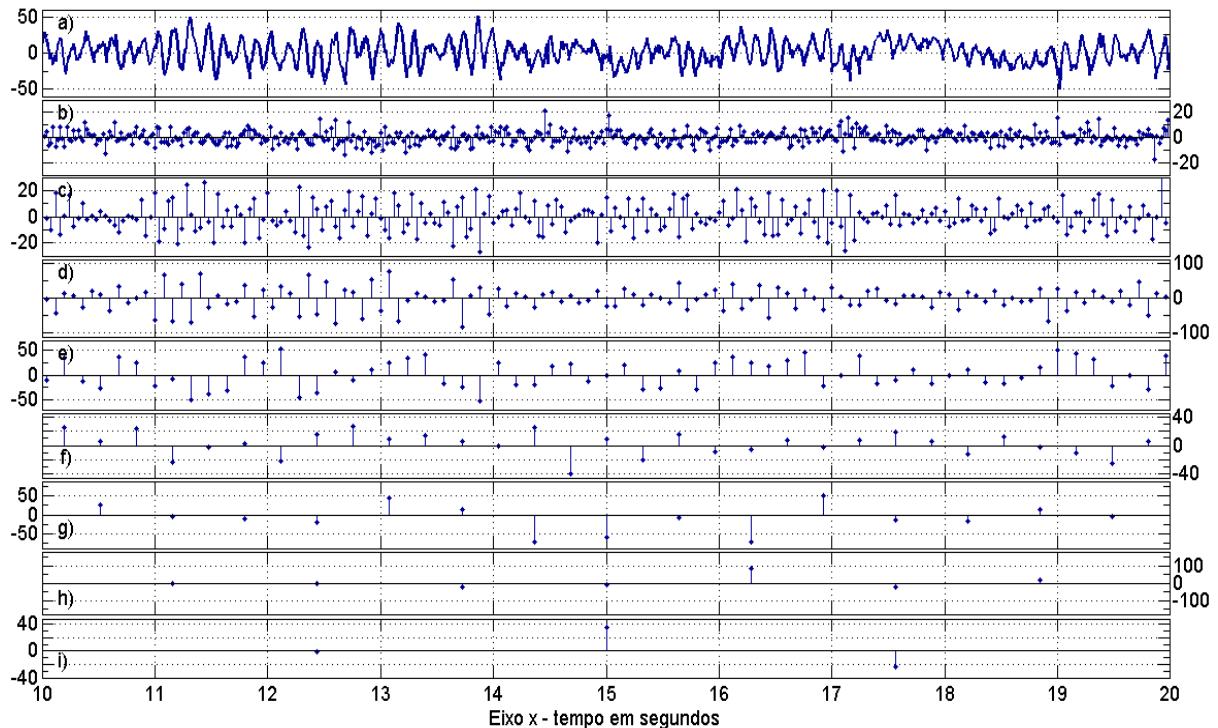


Figura 3.6: TWD do sinal de EEG de um indivíduo apresentando sonolência (PhysioNet, paciente sc4002, época 859, amostrado a 100Hz). (a) Sinal EEG original com $N = 4096$ elementos; (b) a (h) coeficientes wavelets para os níveis $j = 11, 10, \dots, 5$; (i) coeficientes de escala do último nível, $J_0 = 6$.

3.4.5 Implementação via bancos de filtros

Proposto inicialmente para a compressão de sinais de voz e imagens (RIOUL; VETTERLI, 1991), a teoria de *subband coding* possibilita a decomposição de um sinal em diferentes subbandas de frequências através de um banco de filtros de análise, e sua posterior reconstrução através de um banco de filtros de síntese. A associação deste método à análise multirresolução

⁴Sinal correspondente ao intervalo 10-20s da época 859 do paciente sc4002, da base de dados PhysioNet.

possibilita calcular a transformada wavelet de um sinal discreto $f(t), t \in \mathbb{Z}$, e garantir sua reconstrução exata.

Um filtro pode ser definido como um operador linear e invariante no tempo, caracterizado por sua resposta ao impulso, resposta de passo e resposta em frequência (STRANG; NGUYEN, 1996; SMITH, 2002). A resposta ao impulso corresponde à saída do filtro ao ter como função de entrada um impulso unitário. O comportamento do filtro ao longo do tempo é determinado pela resposta de passo e, por fim, a resposta em frequência é determinada pela transformada de Fourier da resposta ao impulso.

Em geral, apenas a resposta ao impulso é utilizada para caracterizar o filtro e, em um filtro digital, é definida pelo conjunto de coeficientes $h(k), k \in \mathbb{Z}$. Assim, a filtragem de um sinal de entrada discreto $x(t)$ ocorre ao fazermos sua convolução com os coeficientes de filtro $h(k)$, obtendo como saída o sinal filtrado $y(t)$:

$$y(t) = \sum_k h(k) * y(t - k). \quad (3.58)$$

Esta implementação é denominada *FIR – Finite Impulse Response*, e corresponde à convolução do sinal a um número finito de elementos. Na transformada wavelet discreta utilizando filtros FIR, o número finito de elementos só é atingido quando escolhidas wavelets de suporte compacto.

Outra forma usual de se implementar filtros digitais faz uso de recursividade, gerando filtros denominados *IIR – Infinite Impulse Response*. Transformadas wavelet discretas podem também ser implementadas através de filtros IIR. Neste estudo, porém, serão utilizadas apenas as wavelets ortonormais de suporte compacto de Daubechies, implementadas via filtros FIR.

A relação entre as wavelets de uma análise multirresolução e o *subband coding* pode ser compreendida da seguinte forma: filtros passa-baixa – associados aos filtros h_k da função escala (Eq.(3.38)) – mantêm apenas a componente de baixa frequência do sinal. Isto é, informações mais suaves e com menos variações, correspondendo à média ou aproximação do sinal em um determinado nível. Já os filtros passa-alta – associados aos filtros g_k da função wavelet (Eq.(3.40)) – mantêm apenas a componente de alta frequência do sinal, carregando a informação de variação do sinal e, portanto, dos detalhes ou diferenças em cada nível de resolução.

A Figura 3.7 apresenta o diagrama da análise multirresolução utilizando um banco de filtros. Os coeficientes do filtro passa-baixa H estão associados aos coeficientes de filtro da função escala. Já os coeficientes do filtro passa-alta G estão associados aos coeficientes de filtro da

função wavelet. O termo ($\downarrow 2$) corresponde à etapa de subamostragem ou decimação, onde o número de coeficientes da sequência de entrada é reduzido pela metade e a escala é dobrada.

A cada iteração, conforme visto na Seção 3.4.4, o sinal aproximado pelo conjunto de coeficientes $c_{j,l}$ é decomposto em um conjunto de *coeficientes de escala* ou *coeficientes de aproximação*, $c_{j-1,l}$, através do filtro H . Da mesma maneira, através do filtro G o sinal é decomposto em um conjunto de *coeficientes wavelet* ou *coeficientes de detalhe*, $d_{j-1,l}$. Este processo é repetido até atingir-se o nível mínimo J_0 da TWD. Na síntese do sinal, que corresponde à TWD inversa, cada conjunto de coeficientes $c_{j,l}$ e $d_{j,l}$ são superamostrados ($\uparrow 2$) e reconstruídos como o conjunto de coeficientes $c_{j+1,l}$, através dos filtros de síntese \bar{H} e \bar{G} . As wavelets de Daubechies, por serem ortogonais, utilizam o mesmo banco de filtros tanto para análise quanto para síntese do sinal.

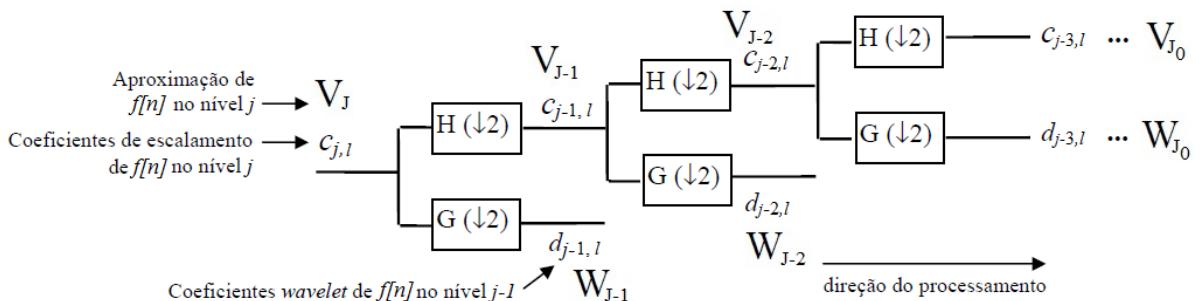


Figura 3.7: Decomposição de um sinal f_i discreto em 3 níveis da TWD. A ilustração evidencia a convolução com os filtros e as operações de *downsampling* – decimação ou redução do tamanho do vetor à metade.

Os bancos de filtros wavelets são construídos ao estabelecer-se alguns parâmetros, tais como simetria, ortonormalidade e número de momentos nulos, aplicados a algum método de construção⁵. Na literatura são comumente encontrados dois métodos para geração destes filtros: (i) *Quadrature Mirror Filters – QMF* e (ii) *Conjugate Mirror Filters – CMF*.

O QMF, desenvolvido em 1976, permite filtros com reconstrução perfeita apenas para casos simples como a wavelet de Haar. Em 1984 foi estabelecida a teoria do CMF, método que fornece as condições necessárias para se obter filtros FIR ortogonais e com reconstrução perfeita (MALLAT, 1998). Atualmente, a estrutura QMF é utilizada como uma abordagem inicial no desenvolvimento de filtros CMF, embora vários autores utilizem ambas nomenclaturas para referir-se à estrutura CMF.

⁵ A construção de bancos de filtros wavelets é complexa e não será abordada neste estudo. Um desenvolvimento completo é encontrado em (MALLAT, 1998; DAUBECHIES, 1992; STRANG; NGUYEN, 1996; VETTERLI; KOVACEVIC, 1995).

3.5 Análise tempo-frequênci

Seja um plano de fase tempo-frequência, tal como disposto na Figura 3.8. Denomina-se *caixa de Heisenberg* o retângulo centrado no ponto $(\bar{t}(f), \bar{\omega}(f))$ e de área $\sigma_t(f) \cdot \sigma_\omega(f)$. O termo $\sigma_t(f)$ é o espalhamento no tempo de uma função $f(t)$, determinado por (MOHLENKAMP; PEREYRA, 2008):

$$\sigma_t(f) = \left(\int_{\mathbb{R}} (t - \bar{t})^2 |f(t)|^2 dt \right)^{1/2}, \quad (3.59)$$

onde \bar{t} é o centro da função $f(t)$, calculado por:

$$\bar{t}(f) = \int_{\mathbb{R}} t |f(t)|^2 dt. \quad (3.60)$$

No domínio da frequência, o espalhamento $\sigma_\omega(f)$ é definido de maneira análoga. O centro da função no domínio da frequência é dado por:

$$\bar{\omega}(f) = \int_{\mathbb{R}} \omega |\hat{f}(\omega)|^2 d\omega. \quad (3.61)$$

Assim, o espalhamento em frequência é obtido:

$$\sigma_\omega(f) = \left(\int_{\mathbb{R}} (\omega - \bar{\omega})^2 |\hat{f}(\omega)|^2 d\omega \right)^{1/2}, \quad (3.62)$$

onde $\hat{f}(\omega)$ é a transformada de Fourier da função $f(t)$.

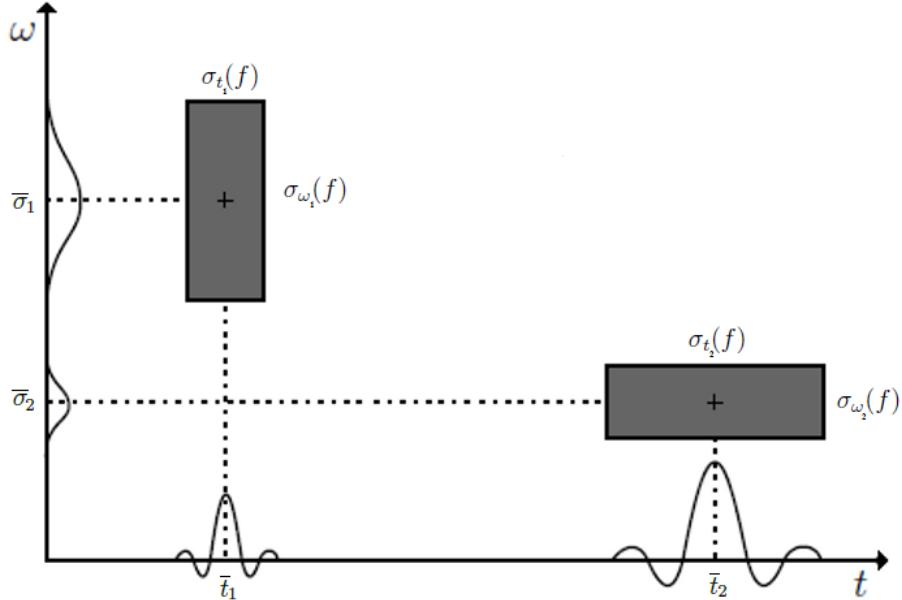


Figura 3.8: Plano de fase tempo-frequência, apresentando as caixas de Heisenberg com diferentes centros e resoluções.

Segundo (MOHLENKAMP; PEREYRA, 2008), ao analisar-se uma função localizada no tempo e ou na frequência – isto é, de suporte compacto tal como as wavelets – a caixa de

Heisenberg indica, para uma determinada localização, qual será a resolução tempo-frequência da análise. Nesta interpretação, deve-se considerar que quanto menor o espalhamento σ (em tempo ou frequência), maior a capacidade de resolução da função.

3.5.1 Princípio de Heisenberg

Idealmente, seria desejável uma função de análise cuja área $\sigma_t(f) \cdot \sigma_\omega(f)$ fosse a menor possível, maximizando a resolução tanto em tempo quanto em frequência. Contudo, a escolha dos parâmetros σ_t e σ_ω não é arbitrada: ela deve satisfazer o *princípio da incerteza de Heisenberg* ([MOHLENKAMP; PEREYRA, 2008](#)).

Em 1926 o físico quântico Werner Heisenberg observou que quanto mais precisa fosse a informação de velocidade de uma partícula, menos precisa seria a informação de sua localização ([HAWKING; MLODINOW, 2010](#)). Assim, postulou que a incerteza sobre a posição de uma partícula, multiplicada pela incerteza do momento da partícula (produto entre massa e velocidade), nunca poderá ser menor do que a constante de Planck ($6.62 \times 10^{-34} m^2 kg / s$).

O princípio de Heisenberg foi postulado considerando-se a posição e a velocidade de partículas quânticas. Entretanto, o mesmo princípio pode ser aplicado à diversas áreas ao se considerar a analogia entre a posição e uma determinada medida; e entre a velocidade e a taxa de variação desta medida ([HAWKING; MLODINOW, 2010](#)).

Dessa forma, o princípio de Heisenberg é aplicado também às análises tempo-frequência. Seja uma função f de norma $\|f\| = 1$, o princípio da incerteza é definido pela inequação ([MOHLENKAMP; PEREYRA, 2008](#)):

$$\sigma_t^2(f) \sigma_\omega^2(f) \geq \frac{1}{16\pi^2}. \quad (3.63)$$

É portanto impossível a existência de uma função que seja perfeitamente localizada em tempo e frequência, simultaneamente. Ou seja, se uma wavelet $\psi(t)$ possui suporte compacto, ela não poderá ser limitada em banda (suporte compacto em frequência). O teorema desta afirmação é desenvolvido e provado em ([MALLAT, 1998](#)).

Na Figura 3.9 pode-se comparar os planos de fase da STFT e da Transformada Wavelet. Na STFT (Figura 3.9(a)), a resolução tempo-frequência é ajustada ao definir-se a janela da transformada. Uma vez definida, esta resolução é única durante toda a análise. Na TWD (Figura 3.9(b)), a resolução tempo-frequência varia de acordo com o nível (ou escala) da transformada: no nível mais grosso, perde-se a resolução no tempo ao ter-se uma aproximação de todo o sinal através de um único coeficiente escala do espaço V_0 . Em escalas menores (α^{-1} menor

significa um nível W_j maior), a resolução no tempo torna-se mais refinada. As diferentes resoluções são consideradas como uma das principais vantagens da análise wavelet em relação à análise de Fourier.

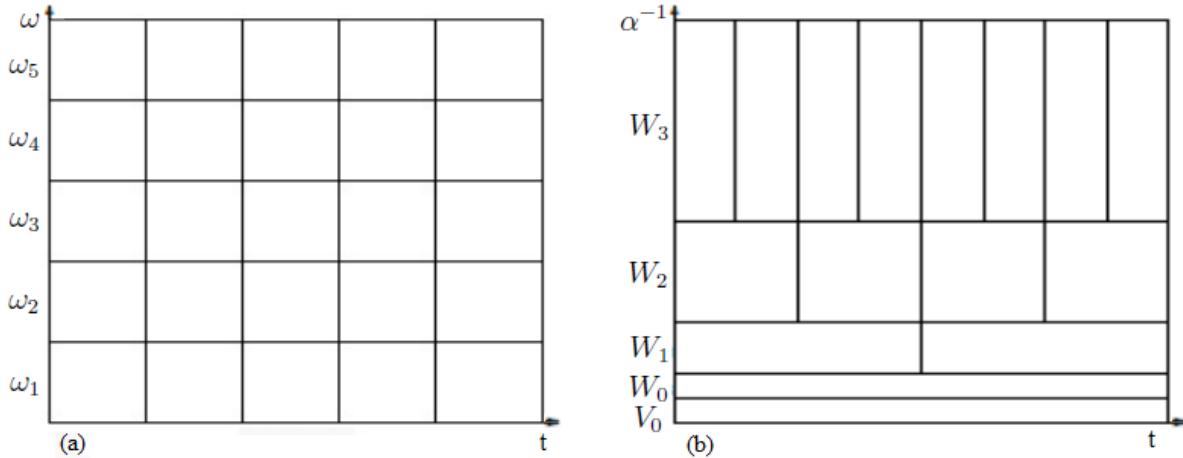


Figura 3.9: Comparação entre resoluções tempo-frequência: (a) STFT; (b) TWD.

3.5.2 Relação entre escala e frequência

Uma vez que os sinais cerebrais são caracterizados através de ritmos de frequência, é de fundamental importância para este estudo estabelecer alguma relação entre escalas wavelets e frequências.

[MISITI; POGGI \(2010\)](#) propõem a determinação de frequências equivalentes para cada escala α , de acordo com a wavelet, denominando-as *pseudo-frequências* f_α :

$$f_\alpha = (f_c \cdot f_s) \cdot \alpha, \quad (3.64)$$

sendo f_s a frequência de amostragem, em hertz, do sinal de entrada; f_c é a frequência central da wavelet.

Dada a wavelet $\psi(t) = \psi_{0,0}(t)$, sua frequência central f_c é aquela que corresponde à frequência da função harmônica pura que melhor se aproxima à forma de onda de $\psi(t)$, conforme representado na Figura 3.10 para a wavelet DB2 ($f_c = 0.6667$ Hz). Na prática, calcula-se a transformada de Fourier da wavelet e escolhe-se $f_c = \omega_c$, tal que $\hat{\psi}(\omega_c)$ seja a componente de maior módulo.

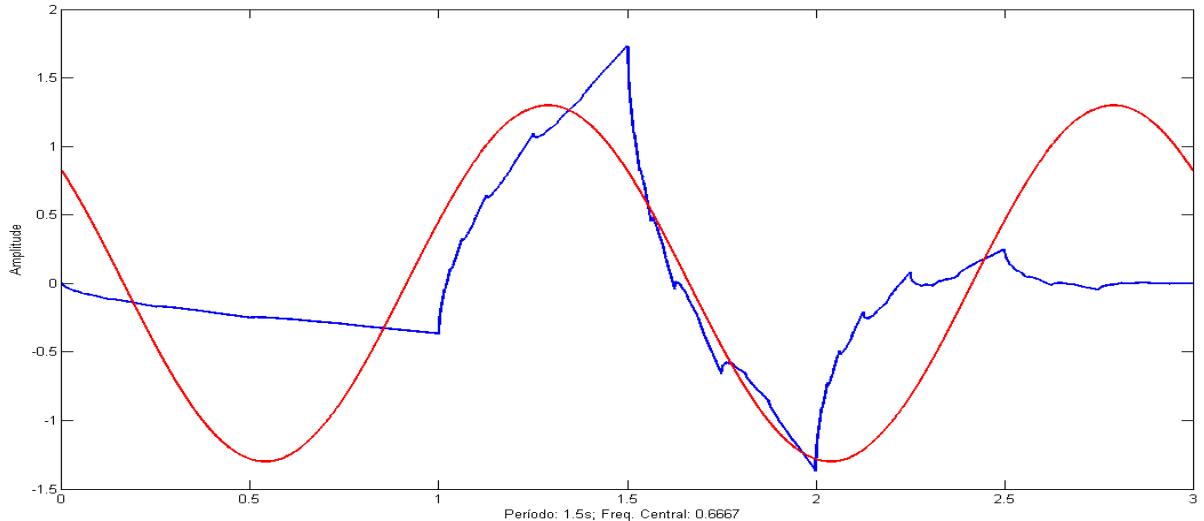


Figura 3.10: Wavelet DB2 (em azul) e harmônica pura com a frequência central aproximada (em vermelho).

3.5.2.1 Interpretação da frequência via TWC (escalogramas)

A Tabela 3.2 apresenta algumas escalas e suas respectivas pseudo-frequências, considerando-se a wavelet de Meyer utilizada neste estudo. A interpretação do escalograma dá-se de maneira direta, associando cada escala a sua referida pseudo-frequência, obtida através da Equação (3.64).

Tabela 3.2: Relação entre escala e frequência na TWC: pseudo-frequências da wavelet de Meyer ($f_c = 0.6902 \text{ Hz}$; $f_s = 100 \text{ Hz}$).

Escala (α^{-1})	$f_\alpha(\text{Hz})$	Escala (α^{-1})	$f_\alpha(\text{Hz})$
1	69.02	10	6.9
2	34.51	15	4.6
3	23	20	3.45
4	17.25	25	2.76
5	13.8	30	2.3
6	11.5	35	1.97
7	9.86	40	1.72
8	8.62	45	1.53
9	7.66	50	1.38
10	6.9	100	0.69

3.5.2.2 Interpretação da frequência via TWD (análise multirresolução)

A informação de frequência através da TWD não se dá de maneira direta: deve-se atentar que cada nível j da TWD representa uma faixa de frequências, correspondente a $\sigma_\omega(\psi_{j,0})$, e

não uma única componente. Sendo assim, a pseudo-frequência relacionada ao nível j deve ser utilizada apenas como uma referência na determinação desta faixa.

A Tabela 3.3 apresenta os níveis multirresolução associados a suas respectivas pseudo-frequências (coluna (a), em escala diádica). As colunas (b), (c) e (d) mostram os possíveis níveis de resolução para um sinal de entrada com 4096, 1024 e 512 amostras, respectivamente. Para os três casos, o nível mínimo da TWD é $J_0 = j0$. A pseudo-frequência relacionada a cada nível é encontrada na coluna (e).

O comprimento do sinal de entrada têm grande impacto na relação *nível – frequência* da análise TWD. Mantendo-se f_s e f_c constantes, o aumento do número de amostras do sinal de entrada deslocará uma mesma pseudo-frequência para um nível mais refinado. Já o aumento da frequência de amostragem, f_s , deslocará uma mesma pseudo-frequência para um nível mais grosso da transformada.

Tabela 3.3: Relação entre escala, níveis de resolução e frequência na TWD: pseudo-frequências da wavelet DB2 ($f_c = 0.6667 \text{ Hz}$; $f_s = 100 \text{ Hz}$).

(a) Escala (1/α)	(b) Nível (J = 12)	(c) Nível (J = 10)	(d) Nível (J = 9)	(e) $f_\alpha(\text{Hz})$
2	j11	j9	j8	33.33
4	j10	j8	j7	16.67
8	j9	j7	j6	8.33
16	j8	j6	j5	4.16
32	j7	j5	j4	2.08
64	j6	j4	j3	1.04
128	j5	j3	j2	0.52
256	j4	j2	j1	0.26
512	j3	j1	j0	0.13
1024	j2	j0	-	0.06
2048	j1	-	-	0.03
4096	j0	-	-	0.01

Uma vez que as wavelets utilizadas na AMR possuem suporte compacto, sua banda em frequência não é limitada (STRANG; NGUYEN, 1996), implicando em um espectro de frequências espalhado e com sobreposição entre os níveis, conforme observado na Figura 3.11 para o espectro de frequências da wavelet DB2 ($f_c = 0.6667 \text{ Hz}$; $f_s = 100 \text{ Hz}$). Contudo, esta resposta em frequência possibilita diferenciar os principais ritmos cerebrais, sendo adequada às necessidades deste estudo.

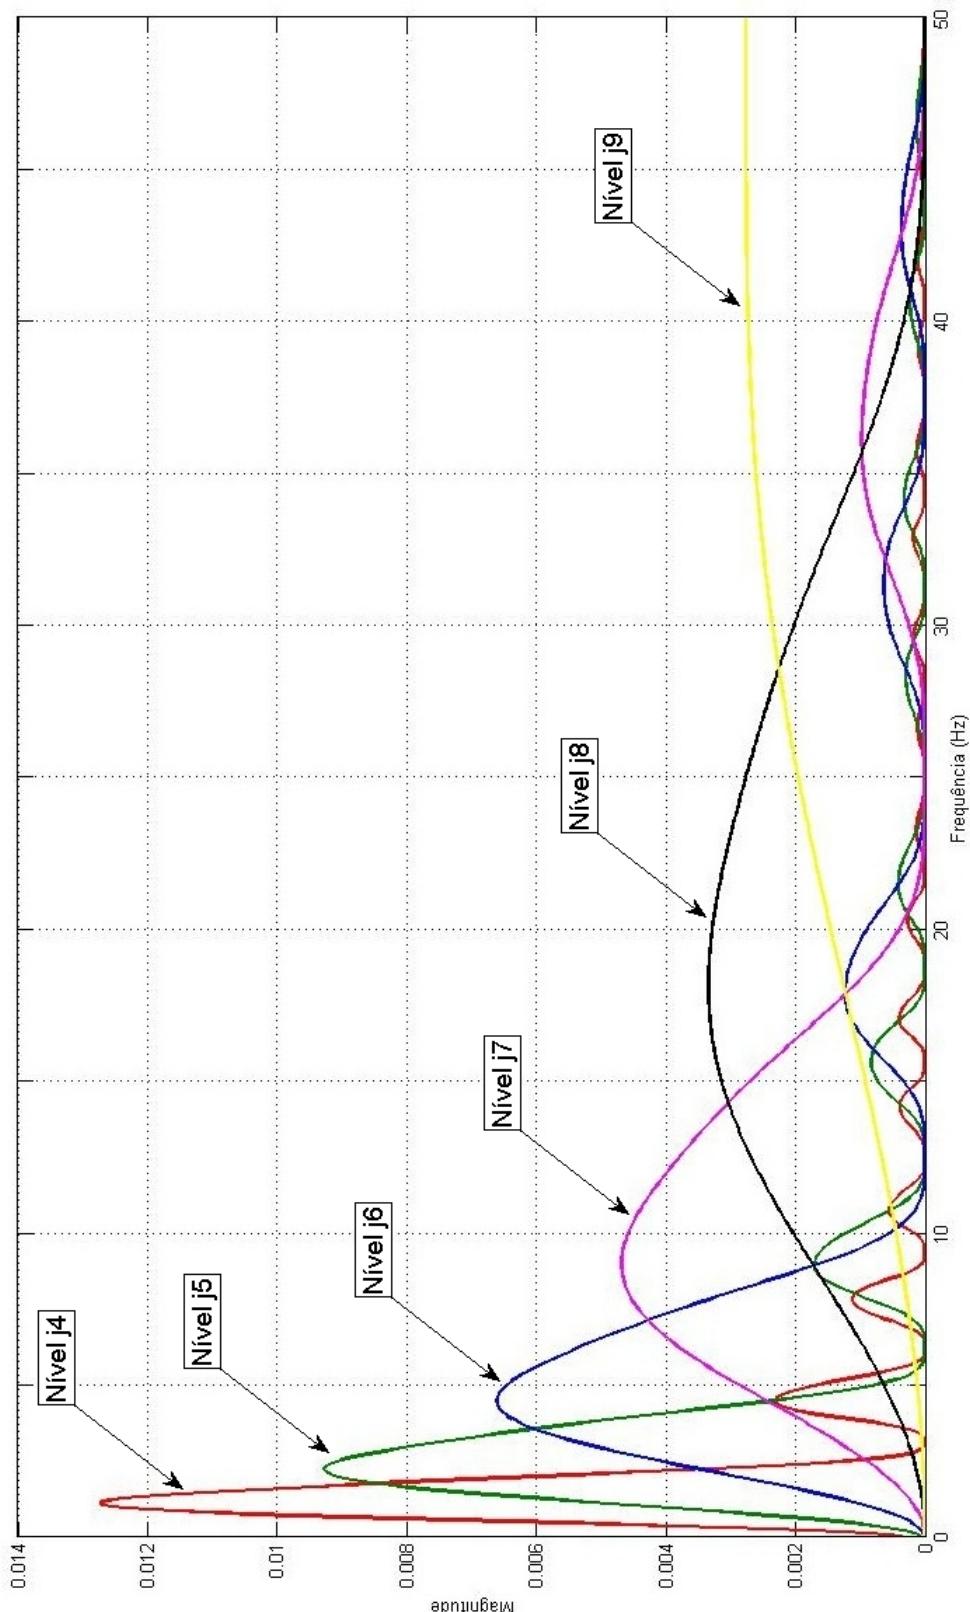


Figura 3.11: Espectro de frequência da wavelet DB2, $f_s = 100$ Hz, para os níveis: j4 (vermelho), j5 (verde), j6 (azul), j7 (violeta), j8 (preto) e j9 (amarelo).

4 PROCESSAMENTO DE SINAIS CEREBRAIS

Neste capítulo, uma visão geral do processo de detecção de sonolência é apresentada, abordando a topologia geralmente utilizada no reconhecimento de padrões. São apresentadas, então, duas novas propostas para a detecção de sonolência: (i) classificação baseada na técnica *melhor aproximação por m-termos*; (ii) classificação dos coeficientes wavelets através da distância de Mahalanobis. Ambas as propostas buscam considerar algoritmos de complexidade reduzida e cujo funcionamento dá-se de modo independente ao indivíduo e à tarefa realizada.

4.1 Visão geral do processo de detecção da sonolência

O processo de identificação da sonolência pode ser generalizado, com base nas diferentes técnicas e implementações, através da topologia representada na Figura 4.1: (i) aquisição do sinal, envolvendo os processos de conversão e amostragem; (ii) pré-processamento do sinal, onde a região de interesse selecionada é preparada para a etapa de processamento; (iii) processamento do sinal, contendo as etapas de extração de características e classificação, através do reconhecimento de padrões; resultando na (iv) saída, que contém o sinal processado ou o resultado da classificação.

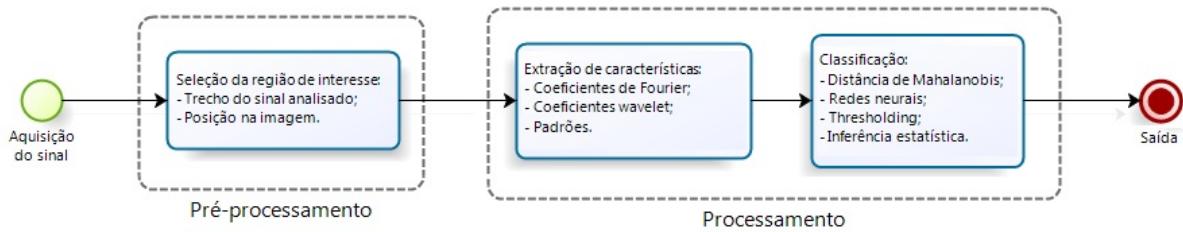


Figura 4.1: Visão geral de um processo de classificação.

Na primeira proposta apresentada neste estudo, a detecção de sonolência através da melhor aproximação por m -termos, o pré-processamento consiste na seleção de épocas de 30s do sinal; em seguida, a extração de características é realizada através de dois índices obtidos pela melhor aproximação – peso no nível j_α e peso no nível j_β – que por sua vez são classificados via processo de limiarização (*threshold*). Esta metodologia é detalhada na Seção 4.2.2.

As técnicas empregando distância de Mahalanobis selecionam trechos de 2 segundos na etapa de pré-processamento. Em seguida, as características são extraídas com base na transformada de Fourier, para a metodologia de comparação, ou através da transformada wavelet, na segunda metodologia proposta neste estudo. As características extraídas são então classificadas

pela distância de Mahalanobis. Estas metodologias são detalhadas na Seção 4.3.

4.2 Melhor aproximação por m -termos

Conforme disposto na Seção 3.4.4, as N amostras discretizadas de um sinal $f(t)$ podem ser consideradas como os coeficientes de aproximação do nível mais refinado J da expansão em série wavelet de $f(t)$:

$$f(t) \approx C_J = (c_{J,0}, c_{J,1}, \dots, c_{J,N-1}). \quad (4.1)$$

Aplicando-se a TWD à sequência de coeficientes C_J , a expansão de $f(t)$, dada pela Equação (3.42), pode então ser representada pela sequência de coeficientes

$$f(t) \approx TWD(C_J) = \{C_{J_0}, D_{J_0}, D_{J_0-1}, \dots, D_{J-1}\}, \quad (4.2)$$

onde $TWD(\cdot)$ é o operador da transformada wavelet discreta; C_{J_0} é a sequência de coeficientes de escala do último nível da transformada e D_j , com $j = [J_0, J[$, representa as sequências de coeficientes wavelets nos demais $L = J - J_0$ níveis de resolução.

Os coeficientes wavelets têm a propriedade de serem mais significativos (terem maior módulo) em regiões de maior variação dos sinais, em razão da propriedade de decaimento dos coeficientes wavelets, apresentada na Seção 3.4.3. Isso motiva a criação de várias estratégias de seleção desses coeficientes. Uma delas é denominada **melhor aproximação por m -termos** (*best m -term approximation*) (DEVORE, 1998; TEMLYAKOV, 2003), que consiste na escolha dos m primeiros coeficientes wavelets de maior magnitude (módulo).

Para isso, os coeficientes são ordenados em forma decrescente independente do nível j , $j = J_0, \dots, J - 1$:

$$d_1 > d_2 > \dots d_m > \dots d_s > \dots d_{N-N_{J_0}}. \quad (4.3)$$

Os primeiros m coeficientes mantêm-se inalterados e os demais são substituídos por zero.

Assim, uma nova sequência

$$\tilde{F} = (C_{J_0}, \tilde{D}_{J_0}, \tilde{D}_{J_0+1}, \dots \tilde{D}_{J-1}) \quad \text{é obtida, sendo} \quad (4.4)$$

$$\tilde{D}_j = (\tilde{d}_{j,0}, \dots \tilde{d}_{j,N_j-1}), \text{ com } \tilde{d}_{j,k} = \begin{cases} d_{j,k}, & \text{se } d_{j,k} \in \{d_1, \dots, d_m\} \\ 0, & \text{caso contrário} \end{cases} \quad (4.5)$$

Dessa forma, o sinal $p = \tilde{f}$ é obtido através da $TWI((C_{J_0}, \tilde{D}_{J_0}, \tilde{D}_{J_0+1}, \dots \tilde{D}_{J-1}))$.

Na verdade, pode-se determinar m tal que o erro entre f e \tilde{f} seja ϵ , com ϵ escolhido arbitrariamente pequeno. Assim, a nova aproximação $p(t)$ da função $f(t)$ apresenta o erro

$\epsilon^2 = \|p(t) - f(t)\|^2$, o qual é medido através da distância entre a função original $f(t)$ e sua aproximação $p(t)$ (STOLLNITZ; DEROSE; SALESIN, 1995):

$$\epsilon^2 = \|p(t) - f(t)\|^2 = \sqrt{\frac{\sum_{i=0}^{N-1} |p(t_i) - f(t_i)|^2}{N}}. \quad (4.6)$$

Devido à ortonormalidade da base wavelet de Daubechies, o erro para o método da melhor aproximação por m -termos pode ser obtido como segue, na norma do espaço $L^2(\mathbb{R})$:

Seja $\sigma(i) = (j, k)$, $i = 1, 2, \dots, m$, a correspondência ao nível e à posição originais dos m coeficientes wavelets selecionados pelo processo de ordenação. $S = N_J - N_{J_0}$ é o número de coeficientes wavelets de toda a transformada. Da mesma maneira, há uma correspondência $\rho(i) = (j, k)$ para os coeficientes não significativos, isto é, que foram substituídos por zero, onde j é o nível e k a posição do coeficiente no nível.

O erro quadrático desta aproximação, na norma do espaço $L^2(\mathbb{R})$, pode ser escrito apenas em função dos coeficientes substituídos por zero:

$$\|f(t) - p(t)\|^2 = \left\| \sum_{i=1}^{S-m} d_{\rho(i)} \psi_{\rho(i)}(t) \right\|^2 = \sum_{i=1}^{S-m} d_{\rho(i)}. \quad (4.7)$$

De acordo com os experimentos numéricos realizados neste estudo, esta operação preserva o espectro de frequências do sinal original, até mesmo para escolhas de $m \ll N_{max}$. Além disso, embora a representação com m -termos seja uma aproximação não-linear, a linearidade da TWD é mantida e, portanto, a operação é invariante em relação à amplitude do sinal.

A representação esparsa (HOLMSTROM, 1999) dos coeficientes significativos resultantes da estratégia de melhor aproximação por m -termos consiste em marcá-los em uma grade diádica, de tal forma que a posição no tempo e na escala de cada coeficiente wavelet significativo fique evidenciada.

Seja um sinal de teste $f(t)$, de comprimento N , constituído por componentes harmônicas puras de 5 Hz e 20 Hz e definido por:

$$f(t) = \begin{cases} \sin(2\pi 5t), & t \in [0, N/2] \\ \sin(2\pi 20t), & t \in [N/2 + 1, N] \end{cases} \quad (4.8)$$

A Figura 4.2 mostra o resultado da aplicação da melhor aproximação por m -termos a $f(t)$, mantendo-se apenas 25% dos coeficientes wavelets ($m = 256$; $N = 1024$). Em (a), são mostradas as formas de onda do sinal original $f(t)$, em preto, e de sua aproximação $p(t)$, em azul, no intervalo $[4s, 6s]$. Em (b), estão dispostos em uma grade diádica, por nível, os coeficientes significativos resultantes da operação. Os espectros de frequências do sinal original $f(t)$ e do sinal aproximado $p(t)$ são mostrados em (c) e (d), respectivamente.

Comparando-se as Figuras 4.2(c) e 4.2(d), verifica-se que as componentes de frequência são mantidas. A existência de outras componentes no espectro do sinal reconstruído, $p(t)$, é decorrente do *efeito de Gibbs* na aproximação do sinal. Além disso, a resolução de tempo da STFT extrapola o intervalo mostrado, enquanto que a representação esparsa dos coeficientes significativos permite uma boa resolução de tempo-frequência, por níveis.

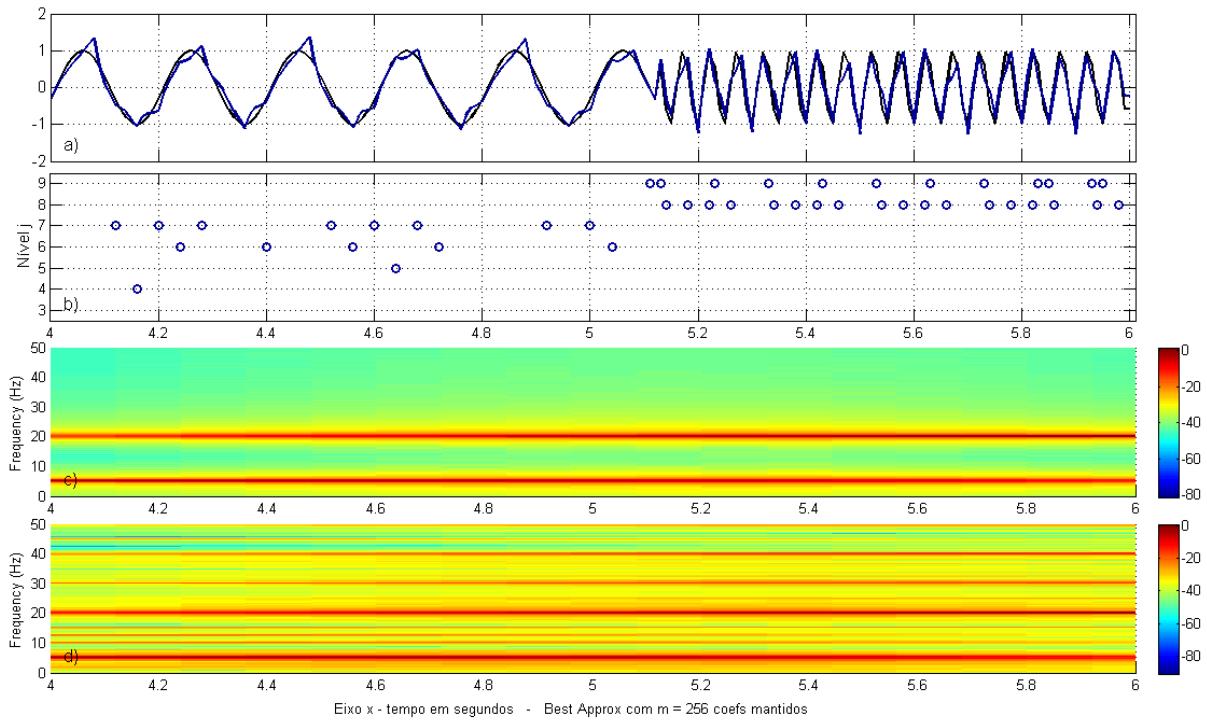


Figura 4.2: Melhor aproximação por m -termos aplicada a um sinal de componentes harmônicas de 5Hz e 20Hz. Em (a) $f(t)$ em preto, $p(t)$ em azul; (b) representação esparsa dos coeficientes significativos; (c) espectro de frequências de $f(t)$; (d) espectro de frequências de $p(t)$.

4.2.1 Caracterização da sonolência através da TWD

De acordo com o exposto na Seção 2.4, para este estudo a sonolência será considerada como o seguinte processo neurofisiológico:

- (1) Inicialmente, o indivíduo encontra-se no estado alerta, sendo o ritmo beta predominante no EEG;
- (2) O processo de sonolência tem início quando o indivíduo apresenta sinais externos de fadiga ou sonolência, tais como piscar de olhos demorados e ou olhos fechados. No EEG, há a predominância do ritmo alfa;
- (3) A sonolência ocorre quando o indivíduo passa ao estado N1, apresentando externamente

características de torpor. No EEG há predominância do ritmo teta e diminuição de atividade nos ritmos alfa e beta.

É desejável, portanto, estabelecer uma relação entre os ritmos cerebrais envolvidos no processo de sonolência e a capacidade de representação de frequências via análise wavelet multiresolução (detalhada na Seção 3.5).

Esta relação pode ser determinada através da análise da Tabela 3.3, conjuntamente com a Figura 3.11. De maneira complementar, foi aplicada a melhor aproximação por m -termos a um conjunto de sinais, cujo estado cognitivo já era conhecido, permitindo assim validar a representação de cada ritmo cerebral por determinados níveis da decomposição wavelet.

A análise de um sinal cerebral através da melhor aproximação por m -termos é exemplificada na Figura 4.3, onde ocorre a transição do estado alerta (indivíduo acordado e de olhos fechados no intervalo 5s a 20s) para o estado de sonolência (intervalo de 20s a 35s).

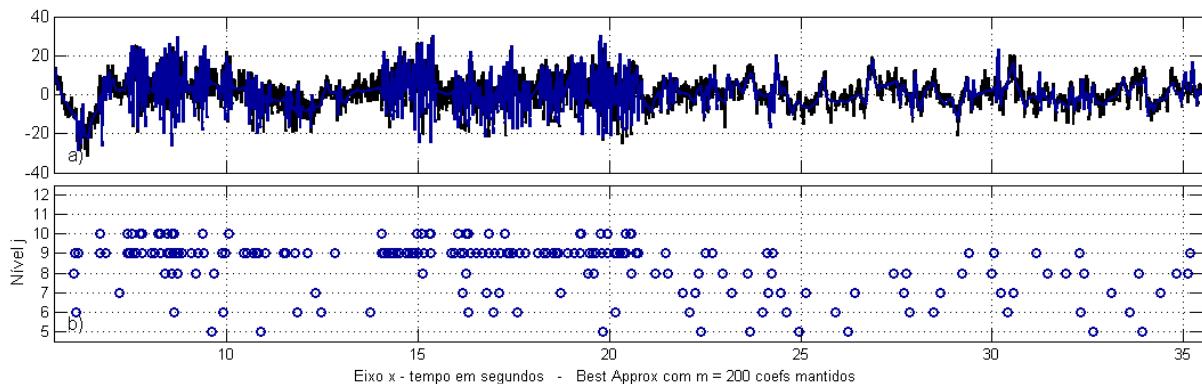


Figura 4.3: Melhor aproximação por m -termos aplicada a um sinal EEG. Em (a) $f(t)$ em preto, $p(t)$ em azul; (b) representação esparsa dos coeficientes significativos.

Neste estudo, a seleção de trechos dos sinais para aplicação das metodologias desenvolvidas dá-se através de duas propostas: (a) análise de épocas de 30s de duração, em consonância com a classificação do hipnograma realizada pelo especialista médico; (b) análise de épocas de 3s de duração (com sobreposição de 1s), visando aplicações em tempo real.

Com o objetivo de validar a caracterização da sonolência através da TWD, foram utilizados os sinais cerebrais provenientes da base de dados do Hospital Pulido Valente, de Lisboa. Contudo, esta base de dados não possui épocas em estado alerta suficientes para aplicação dos algoritmos de detecção de sonolência, de modo que para esta etapa do estudo foi utilizada apenas a base de dados PhysioNet.

A Tabela 4.1 mostra o nível que melhor representa cada ritmo cerebral de acordo com a época de análise utilizada, de 2s ou 30s. Deve-se considerar que os sinais de EEG utilizados

neste estudo foram amostrados a $f_s = 100$ Hz e, portanto, devem ser completados com zeros de modo a atingir um número de base 2 no intervalo considerado (*zero-padding*).

Tabela 4.1: Relação entre o ritmo cerebral e o nível da AMR (DB2, $f_s = 100$ Hz).

Ritmo cerebral	Análise 2s (N=512)	Análise 30s (N=4096)	f_α (DB2)
Ritmo Beta [13-30Hz]	$j_\beta = 8$	$j_\beta = 11$	33Hz
Ritmo Alfa [8-13Hz]	$j_\alpha = 6$	$j_\alpha = 9$	8.33Hz
Ritmo Teta [4-8Hz]	$j_\theta < 5$	$j_\theta < 8$	< 4.16Hz

Considerando-se um indivíduo inicialmente em estado alerta, a sonolência pode ser então caracterizada (i) pela ausência de coeficientes significativos nos níveis que representam o ritmo beta; (ii) concentração e posterior redução de coeficientes significativos nos níveis que indicam a atividade alfa, associados ao indivíduo de olhos fechados em momentos que precedem a sonolência.

Nas metodologias para a detecção de sonolência, desenvolvidas neste capítulo, os níveis que possuem representatividade em dois ou mais ritmos não serão considerados, uma vez que não proveem características adequadas ao reconhecimento de padrões.

4.2.2 Detecção da sonolência via melhor aproximação por m -termos

A estratégia de melhor aproximação por m -termos – geralmente empregada como ferramenta para compressão de sinais e imagens (ALANI; AVERBUCH; DEKEL, 2007; STOLLNITZ; DEROSE; SALESIN, 1995) – tem dois usos distintos neste estudo: (i) como ferramenta de análise, aplicada na seção anterior para a verificação dos coeficientes wavelets significativos do sinal cerebral; (ii) como estratégia de classificação – na primeira proposta de detecção de sonolência – ao fornecer características que permitem discriminar entre o estado de vigília e a sonolência de um indivíduo.

O fluxograma da Figura 4.4 apresenta as etapas necessárias à detecção da sonolência através da melhor aproximação por m -termos, onde j_α e j_β correspondem aos níveis AMR que melhor representam o ritmo alfa e beta, respectivamente, e são encontrados na Tabela 4.1.

Inicialmente, o sinal de entrada é decomposto através da TWD, utilizando a wavelet DB2, e a melhor aproximação por m -termos é aplicada ao conjunto de coeficientes wavelets gerado. Em seguida, calcula-se o percentual de coeficientes significativos em relação ao número máximo de

coeficientes possíveis por nível, dados pelo *peso no nível alfa* e pelo *peso no nível beta*:

$$P_\alpha = \frac{m_{j_\alpha}}{N_{j_\alpha}} * 100, \quad P_\beta = \frac{m_{j_\beta}}{N_{j_\beta}} * 100, \quad (4.9)$$

onde m_j é o número de coeficientes significativos no nível j .

Os pesos nos níveis alfa e beta são comparados, então, com os valores de limiar λ_α e λ_β , determinando assim o estado alerta ou de sonolência do indivíduo. O Algoritmo 1 apresenta, de um modo geral, as etapas necessárias à identificação da sonolência via melhor aproximação por m -termos.

Os parâmetros λ_α e λ_β são obtidos empiricamente através de uma base de treinamento, sendo o parâmetro λ_β escolhido em função de λ_α . Neste estudo, a base de treinamento é formada por sinais de 4 pacientes da base de dados PhysioNet, apresentada no Apêndice C. Esta base contém 200 épocas de 30s de sinais de EEG, cujo estado cognitivo é dado pelo respectivo hipnograma.

Para a definição das classes *alerta* e *sonolência*, foram aplicados à base de treinamento os passos (1) a (3) do Algoritmo 1. Montou-se, então, o diagrama disposto na Figura 4.5 com os respectivos valores P_α e P_β de cada época, onde os círculos em verde representam as épocas classificadas pelo hipnograma como sonolência e os quadrados em vermelho representam as épocas classificadas pelo hipnograma como estado alerta.

Analisando-se a disposição dos pontos na Figura 4.5, distinguem-se duas nuvens de características referentes ao estado alerta (em vermelho) e à sonolência (em azul). Os valores de limiarização são definidos ao se determinar um limite para a região de sonolência (linha verde, tracejada). Da análise da figura, fixa-se um limiar $\lambda_\alpha = 25$. Em seguida, interpolam-se os pontos ($P_\alpha = 25, P_\beta = 2$) e ($P_\alpha = 32, P_\beta = 5$) pela reta (em preto, na Figura 4.5) dada pela equação $\lambda_\beta = 0.429P_\alpha - 8.714$.

Assim, na execução do Algoritmo 1, primeiramente compara-se o valor de P_α com o limiar $\lambda_\alpha = 25$, determinado utilizando-se o resultado da base de treinamento. Caso $P_\alpha < \lambda_\alpha$, constata-se o estado de alerta. Caso contrário, o valor obtido para P_α é utilizado para determinar o limiar λ_β . Faz-se, então, a verificação $P_\beta < \lambda_\beta$ e constata-se a sonolência, caso verdadeiro.

Os resultados da aplicação desta metodologia a um conjunto de sinais da base PhysioNet, utilizando os parâmetros já calculados λ_α e λ_β , são mostrados e discutidos na Seção 5.2.

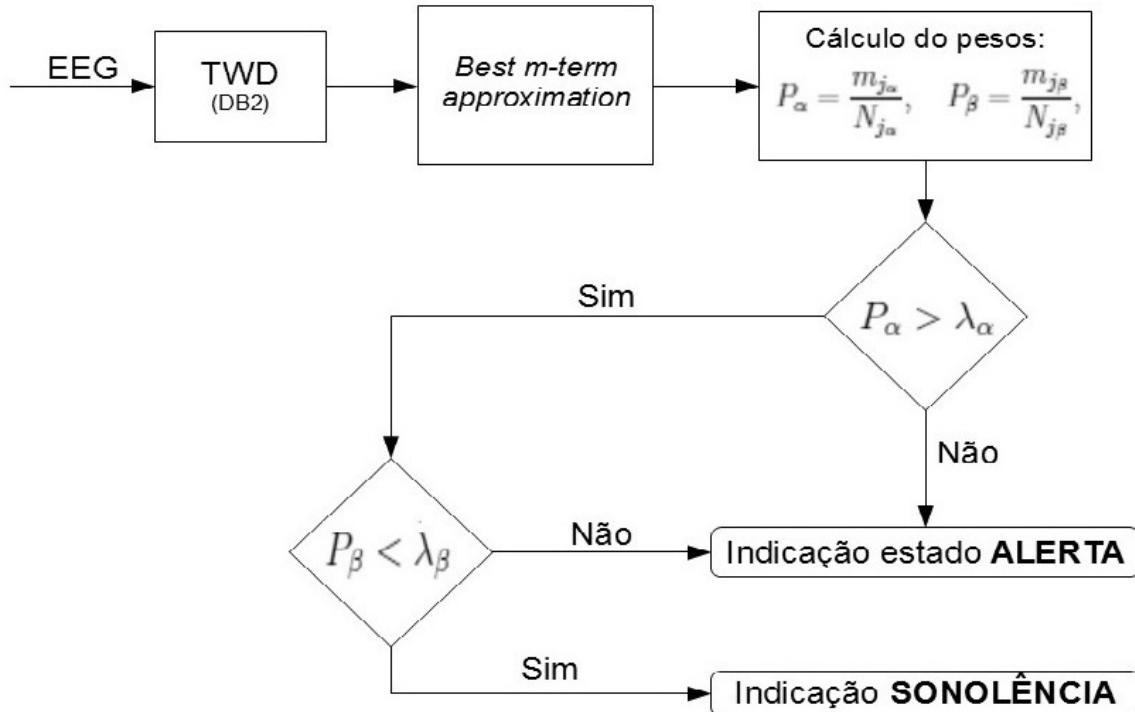


Figura 4.4: Fluxograma do algoritmo para detecção de sonolência via melhor aproximação por m -termos.

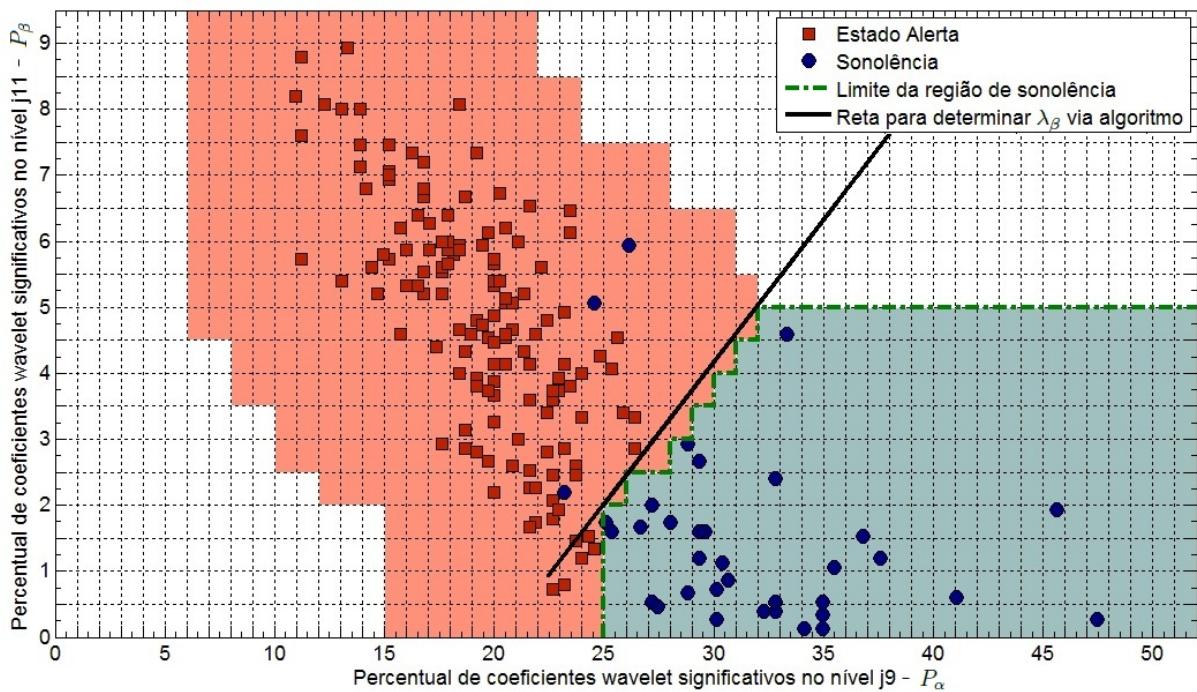


Figura 4.5: Classificação da sonolência via melhor aproximação por m -termos ($m = 400$). Definição das classes ALERTA (vermelho) e SONOLÊNCIA (azul), conforme parâmetros representados nos eixos. Classificação do hipnograma: ALERTA (quadrados em vermelho) e SONOLÊNCIA (círculos em verde).

Algoritmo 1: Detecção da sonolência via melhor aproximação por m -termos (Proposta I)

Dados: Banco de EEG ou sinal do paciente.

Entrada: Sinal $f(t)$ com N amostras;

Parâmetro m , indicando o número de coeficientes significativos.

Resultado: Estado = {ALERTA, SONOLÊNCIA}.

- 1) TWD(f), gera o conjunto de coeficientes wavelets \tilde{F} ;
 - 2) Melhor aproximação por m -termos no conjunto de coeficientes wavelet: $B_m(\tilde{F})$;
 - 3) Cálculo do *peso no nível alfa* P_α ;
 - 4) Cálculo do *peso no nível beta* P_β :
 - 5) se $P_\alpha > \lambda_\alpha$ então
 - calcula $\lambda_\beta(P_\alpha)$
 - se $P_\beta < \lambda_\beta$ então
 - Estado \leftarrow SONOLÊNCIA
 - senão
 - Estado \leftarrow ALERTA
 - senão
 - Estado \leftarrow ALERTA
-

4.3 Distância de Mahalanobis (MD)

Conforme referenciado na Seção 1.2, vários autores propõem a utilização da distância de Mahalanobis (MD, do inglês *Mahalanobis Distance*) como classificador na identificação de estados cognitivos, em específico na identificação da sonolência. Nesta seção, uma abordagem teórica dessa ferramenta é apresentada, seguida da proposta de classificação da sonolência utilizando coeficientes de Fourier e coeficientes wavelets.

A distância Euclidiana e a distância de Mahalanobis são comumente utilizadas no reconhecimento de padrões ([De Maesschalck; JOUAN-RIMBAUD; MASSART, 2000](#)). Enquanto a distância Euclidiana é calculada entre dois vetores, a distância de Mahalanobis é calculada entre um vetor e uma classe de vetores.

Em outras palavras, a distância de Mahalanobis avalia a correlação entre um vetor e uma classe de vetores com a qual se deseja compará-lo. Quanto menor a distância, maior a evidência de que este vetor também pertença à classe considerada ([MAHALANOBIS, 1936](#)). Para calcular a MD é necessário, portanto, determinar a matriz variância-covariância da classe utilizada como modelo. Contudo, a determinação desta matriz pode levar a singularidades, isto é, a matriz pode não ser invertível devido ao grande número de variáveis.

Diversas técnicas podem ser utilizadas de modo a se obter um espaço menor de variáveis, sendo comumente empregada a análise de componentes principais ([De Maesschalck; JOUAN-](#)

RIMBAUD; MASSART, 2000). Neste estudo, o número reduzido de variáveis é alcançado ao se considerar somente os coeficientes relacionados aos ritmos teta e alfa, obtidos pela expansão em série de Fourier ou expansão em série wavelet do sinal.

É importante observar que para o cálculo da distância de Mahalanobis, é necessário que os dados analisados sigam uma distribuição normal de probabilidade. Outra limitação na distância de Mahalanobis é de que o número de objetos no conjunto de dados deve ser maior do que o conjunto de variáveis.

Seja uma classe de dados representada pela matriz $\mathbf{S} = [s_{ij}]_{n \times p}$. As n linhas representam as amostras (vetores) contidas nessa classe, enquanto as p colunas representam as características ou dimensões consideradas. O vetor \bar{s} , de dimensão p , contém a média aritmética de cada coluna de \mathbf{S} .

Para se calcular a distância de Mahalanobis entre um vetor x e a classe \mathbf{S} , é necessário primeiramente obter a matriz variância-covariância (\mathbf{C}_S , de dimensão $p \times p$) da classe de dados \mathbf{S} , dada pela equação:

$$\mathbf{C}_S = \frac{1}{(n-1)} (\mathbf{S}_c)^T (\mathbf{S}_c). \quad (4.10)$$

Na equação acima, $\mathbf{S}_{cn \times p} = (\mathbf{S}_{n \times p} - \mathbf{I}_{n \times 1} \bar{s}_{1 \times p})$. Isto é, a matriz de dados deve ser centrada de acordo com a média do conjunto de dados.

Tomando-se como exemplo uma classe de vetores com apenas duas dimensões $S_{(n \times 2)}$, sendo s_1 e s_2 as dimensões representadas pelas colunas, a matriz variância-covariância da Equação (4.10) reduz-se a

$$\mathbf{C}_S = \begin{bmatrix} \sigma_1^2 & \rho_{12}\sigma_1\sigma_2 \\ \rho_{12}\sigma_1\sigma_2 & \sigma_2^2 \end{bmatrix}, \quad (4.11)$$

onde σ_1^2 e σ_2^2 são a variância de s_1 e s_2 , respectivamente; $\rho_{12}\sigma_1\sigma_2$ é a covariância entre s_1 e s_2 .

Considerando-se o modelo representado pela matriz \mathbf{C}_S , a distância de Mahalanobis de um vetor x , de dimensão p , à classe S é dada por:

$$MD_x = \sqrt{(x - \bar{s}) \mathbf{C}_S^{-1} (x - \bar{s})^T}. \quad (4.12)$$

O conceito apresentado é melhor compreendido através da análise gráfica da MD: a Figura 4.6 ilustra um conjunto de amostras $\mathbf{U} = [u_{ij}]_{20 \times 2}$ posicionadas em um plano cartesiano (j_1, j_2) . Os pontos são representados pelo valor do índice i . Na Figura 4.6(a), os círculos representam equidistâncias euclidianas em relação ao ponto central. Na Figura 4.6(b), as elipses representam equidistâncias de Mahalanobis em relação ao ponto central.

Verifica-se, então, que os pontos u_6 e u_{10} , pertencentes ao conjunto \mathbf{U} , são equidistantes pela análise euclidiana. Já pela MD, o ponto u_{10} tem uma distância menor em relação ao ponto central. Isto deve-se à medida da correlação entre as variáveis, realizada pela MD, identificando a probabilidade de uma variável pertencer a uma nuvem ou classe de dados.

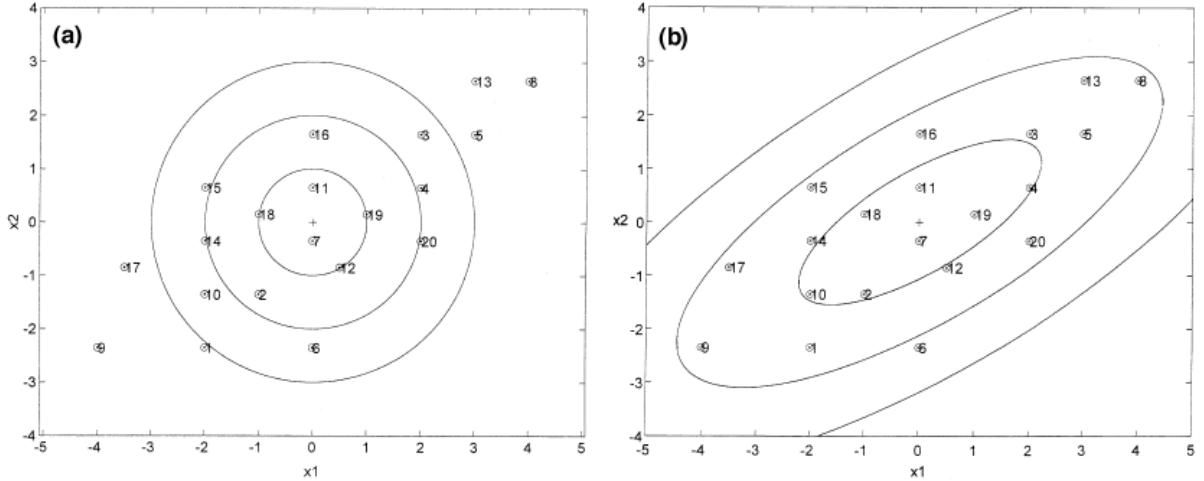


Figura 4.6: Representação gráfica da distância de Mahalanobis. Em (a) os círculos representam equidistâncias euclidianas em relação ao ponto central. Em (b) as elipses representam equidistâncias de Mahalanobis em relação ao ponto central ([De Maesschalck; JOUAN-RIMBAUD; MASSART, 2000](#)).

No contexto deste estudo, mais especificamente nos casos tratados nas Seções 4.3.1 e 5.3, a matriz $\mathbf{S} = [s_{ij}]_{n \times p}$ representa o conjunto de coeficientes da expansão em série de Fourier nas frequências que correspondem aos ritmos alfa e teta, sendo n o número de amostras e p o número de componentes de frequência considerado. Da mesma maneira, nos casos tratados nas Seções 4.3.2 e 5.4, a matriz $\mathbf{S} = [s_{ij}]_{n \times p}$ representa o conjunto de coeficientes da expansão em série wavelet: n é o número de amostras e p o número de características utilizadas, tais como a energia e a média dos coeficientes wavelets nos níveis representativos dos ritmos alfa e teta.

Em outras palavras, a matriz \mathbf{S} representa um modelo alerta do indivíduo que será então comparado com novas medidas: se a distância for suficientemente pequena, a medida pertencerá à classe de referência e portanto o indivíduo estará alerta; se a distância for suficientemente grande, o indivíduo apresentará sonolência.

4.3.1 Detecção da sonolência via MD e coeficientes de Fourier

Esta seção apresenta um modelo para identificação da sonolência baseado no trabalho desenvolvido por ([LIN et al., 2010](#); [BABILONI et al., 2001](#)). Utilizando os coeficientes de Fourier, um modelo alerta é construído analisando-se 3 minutos do sinal EEG. Em seguida, a distância

de Mahalanobis é utilizada como classificador ao medir a distância entre o sinal EEG atual e a classe criada pelo modelo.

A Figura 4.7 apresenta o fluxograma do Algoritmo 2 para a detecção de sonolência utilizando a distância de Mahalanobis aplicada a uma classe de coeficientes de Fourier. Primeiramente o sinal de entrada (*EEG*) é pré-processado, dividindo o sinal em subintervalos de n segundos. Neste estudo, são utilizados subintervalos de 3s com sobreposição de 1s, gerando assim $n = 90$ amostras.

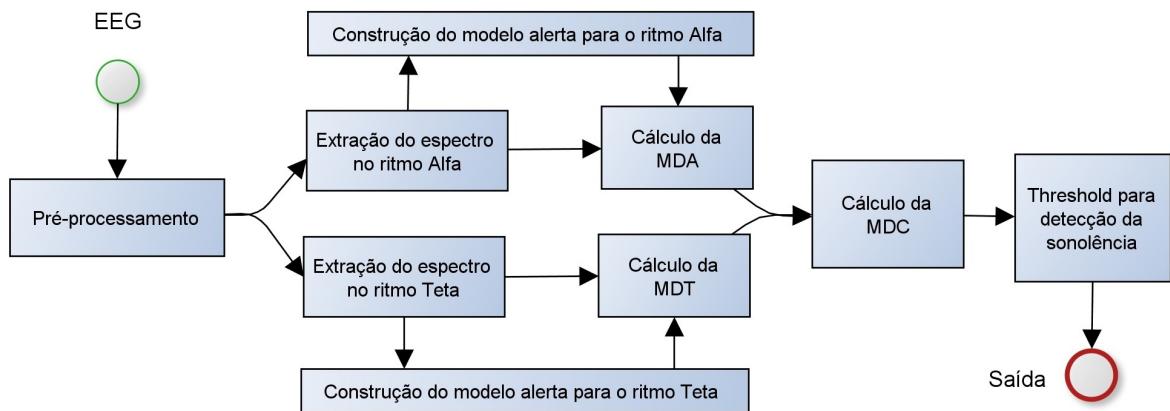


Figura 4.7: Fluxograma do algoritmo para detecção de sonolência utilizando distância de Mahalanobis e coeficientes de Fourier (LIN et al., 2010).

Para cada subintervalo são extraídas as informações de frequência dos ritmos alfa (8–12Hz) e teta (4–7Hz), através da FFT, obtendo-se os vetores x_A e x_T , respectivamente. O conjunto desses vetores, obtidos ao longo dos 3 minutos do sinal, forma uma matriz característica alfa \mathbf{X}_A , de dimensão $n \times p$, e uma matriz característica teta \mathbf{X}_T , de dimensão $n \times q$, para cada banco de sinais. As dimensões p e q estão relacionadas ao número de frequências inteiras escolhidas para os ritmos alfa e teta, respectivamente. Neste estudo $p = 5$ e $q = 4$.

Essas matrizes são utilizadas como modelos alerta, que por sua vez são representados por $(\mu, \Sigma^2)_A$ e $(\mu, \Sigma^2)_T$ para os modelos alfa e teta, respectivamente. Na representação anterior, μ é o vetor de médias e Σ^2 é a matriz covariância. Esses modelos são criados utilizando-se os três primeiros minutos do sinal que satisfaçam uma distribuição normal, condição esta verificada pelo teste de Mardia (MARDIA, 1975; TRUJILLO-ORTIZ; HERNANDEZ-WALLS, 2003).

Uma vez construído o modelo, para cada novo subintervalo x_i do sinal são calculados os vetores x_A e x_T , da mesma maneira como descrito anteriormente. As distâncias de Mahalanobis referentes ao espectro alfa (MDA) e teta (MDT) são dadas por:

$$MDA(x_A) = \sqrt{(x_A - \mu_A)(\Sigma_A^2)^{-1}(x_A - \mu_A)^T}, \quad (4.13)$$

$$MDT(x_T) = \sqrt{(x_T - \mu_T)(\Sigma_T^2)^{-1}(x_T - \mu_T)^T}. \quad (4.14)$$

O índice MDC relaciona as distâncias obtidas entre a medida x_i e os modelos alfa (MDA) e teta (MDT), sendo α constante:

$$MDC = \alpha * MDA + (1 - \alpha) * MDT. \quad (4.15)$$

O valor MDC obtido é então comparado a um valor de limiar (*threshold*) λ_{MD}^f arbitrado e a sonolência é caracterizada caso $MDC > \lambda_{MD}^f$.

Em (LIN et al., 2010), foram utilizados os parâmetros $\alpha = 0.9$ e $\lambda_{MD}^f = 7.5$. Para este estudo, os parâmetros $\alpha = 0.9$ e $\lambda_{MD}^f = 10$ foram escolhidos por apresentarem os melhores resultados ao variar-se α no intervalo $[0.1, 0.9]$ e ao variar-se λ_{MD}^f no intervalo $[5, 20]$.

Algoritmo 2: Detecção da sonolência via MD e coeficientes de Fourier (Algoritmo de comparação)

Dados: Banco de EEG ou sinal do paciente.

Entrada: Sinal $f(t)$ com N amostras; frequência de amostragem f_s .

Resultado: Estado = {ALERTA, SONOLÊNCIA}.

- 1) Divide-se o sinal de referência (para construção do modelo) em n subintervalos;
 - 2) Para cada subintervalo do sinal, aplica-se a FFT e extrai-se o espectro de frequências, selecionando-se p frequências correspondente ao ritmo alfa (vetor x_A) e q frequências correspondentes ao ritmo teta (vetor x_T);
 - 3) Cria-se a matriz característica alfa (X_A), de dimensão nXp , onde as linhas representam o ritmo alfa de cada subintervalo;
 - 4) Cria-se a matriz característica teta (X_T), de dimensão nXq , onde as linhas representam o ritmo teta de cada subintervalo;
 - 5) Caso haja distribuição normal dos dados das matrizes (X_A) e (X_T), verificado através do teste de Mardia, estas matrizes definem o modelo alerta do sinal;
 - 6) Para cada novo subintervalo x_i do sinal, calculam-se os vetores x_A e x_T da mesma maneira do passo (2);
 - 7) Calcula-se a distância de Mahalanobis (MDA) entre x_A e o modelo alerta alfa;
 - 8) Calcula-se a distância de Mahalanobis (MDT) entre x_T e o modelo alerta Teta;
 - 9) Calcula-se o índice MDC, dado pela Equação (4.15);
 - 10) Um valor de limiar λ_{MD}^f é arbitrado.
 - 11) se $MDC > \lambda_{MD}^f$ então
 - | Estado \leftarrow SONOLÊNCIA
 - senão
 - | Estado \leftarrow ALERTA
-

4.3.2 Detecção de sonolência via MD e coeficientes wavelet

A segunda contribuição deste estudo para a detecção da sonolência utiliza a transformada wavelet como metodologia para extração de características, que são então classificadas através da distância de Mahalanobis (MDW), conforme o Algoritmo 3. Esta proposta é uma adaptação do algoritmo desenvolvido na Seção 4.3.1. Novamente, partindo da premissa de que o indivíduo está inicialmente no estado alerta, um modelo é gerado através da decomposição wavelet de 3 minutos de seu sinal EEG. A distância de Mahalanobis permite calcular a correlação entre um vetor de parâmetros obtidos através do sinal EEG atual e daqueles contidos no modelo alerta. Se a distância for maior do que um determinado limiar, considera-se o indivíduo sonolento.

A Figura 4.8 apresenta o fluxograma da metodologia proposta. Inicialmente, o modelo alerta é construído utilizando-se 3 minutos do sinal de referência, dividido em n subintervalos. De modo a manter a coerência com a metodologia anterior, são utilizados subintervalos de 3s com sobreposição de 1s, gerando assim $n = 90$ amostras. Para cada subintervalo x_i calcula-se a TWD(x_i) utilizando DB2. O vetor x_W , de dimensão 4, é construído utilizando como parâmetros a energia e a média dos coeficientes wavelets nos níveis j_α e j_β . Ao longo dos 3 minutos do sinal de referência para criação do modelo, o vetor característica de cada subintervalo corresponde a uma linha da matriz de modelo alerta \mathbf{X}_W , de dimensão $n \times 4$, e representada por $(\mu, \Sigma^2)_W$, sendo μ o vetor de médias e Σ^2 , a matriz covariância.

Uma vez construído o modelo, para cada novo subintervalo x_i do sinal analisado, é calculado o vetor x_W , de maneira idêntica à descrita anteriormente. É calculada, então, a distância de Mahalanobis (MDW) entre o vetor de características wavelet do subintervalo e o modelo alerta wavelet::

$$MDW(\mathbf{x}_W) = \sqrt{(x_W - \mu_W)(\Sigma_W^2)^{-1}(x_W - \mu_W)^T}. \quad (4.16)$$

Após o cálculo da MDW para todos os subintervalos da época, aplica-se um filtro de mediana (largura de 7 amostras) ao resultado obtido de modo a filtrar eventuais distorções. Um valor de limiar λ_{MD}^w é arbitrado. Para este estudo, os melhores resultados foram obtidos com $\lambda_{MD}^w = 20$, avaliado em um intervalo de [5, 30].

A escolha dos parâmetros – isto é, do conjunto de características utilizadas para o cálculo da distância de Mahalanobis – foi baseada em trabalhos nos quais a TWD também é empregada na extração de características de sinais.

Em (SUBASI, 2005), a média dos valores absolutos dos coeficientes em cada nível da análise, bem como a potência média do conjunto de coeficientes wavelets por nível, são uti-

lizadas por representar a distribuição de frequência do sinal analisado.

Em (PETRANTONAKIS; HADJILEONTIADIS, 2010), dentre as metodologias utilizadas para o reconhecimento automático de emoções, a distância de Mahalanobis é aplicada a um vetor de características obtido pela estimativa da energia e entropia de cada nível de coeficientes wavelets.

Na implementação proposta, o vetor de características é construído calculando-se a energia e a média dos coeficientes wavelets nos níveis j_α e j_β . A distância de Mahalanobis, MDW, é então calculada e em seguida passa por um filtro de mediana (largura de 7 amostras), de modo a estabilizar a classificação.

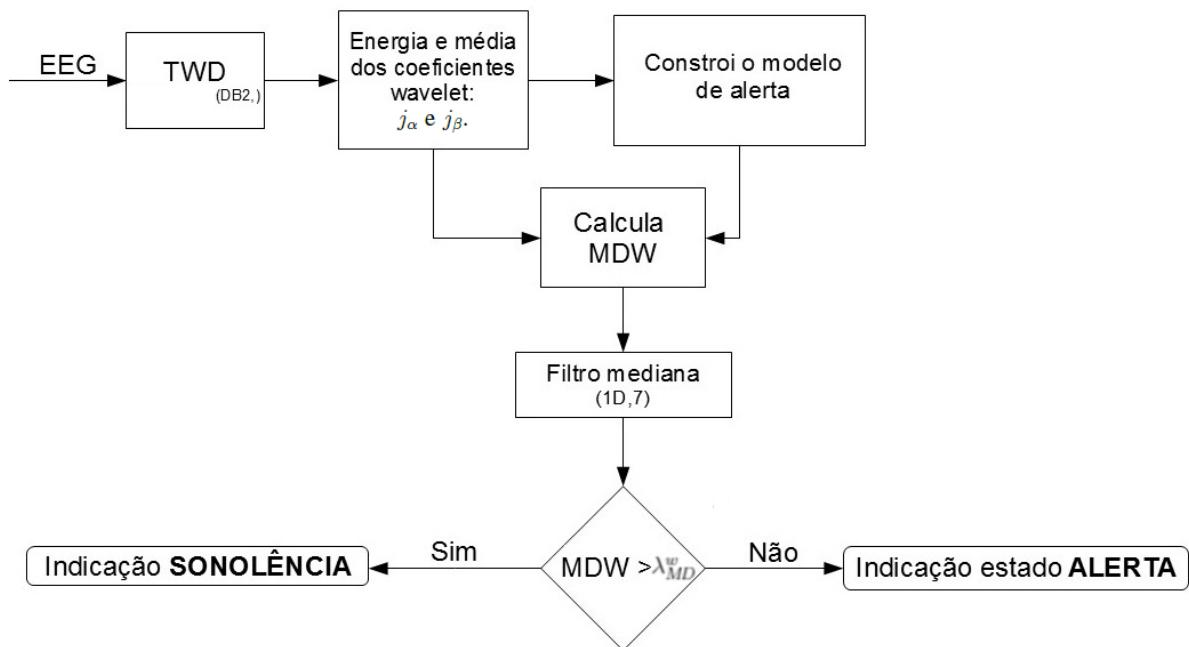


Figura 4.8: Fluxograma do algoritmo para detecção de sonolência utilizando distância de Mahalanobis e coeficientes wavelets.

Algoritmo 3: Detecção da sonolência via MD e coeficientes wavelets (Proposta II)

Dados: Banco de EEG ou sinal do paciente.

Entrada: Sinal $f(t)$ com N amostras.

Resultado: Estado = {ALERTA, SONOLÊNCIA}.

- 1) Divide-se o sinal de referência (para construção do modelo) em n subintervalos;
 - 2) Para cada subintervalo do sinal, cujas amostras são representadas no vetor de dados x_i , aplica-se a TWD(x_i) utilizando DB2;
 - 3) A partir do conjunto de coeficientes wavelets obtidos, calculam-se a energia e a média para os níveis j_α e j_β (vetor x_W de dimensão 4);
 - 4) Cria-se a matriz característica wavelet (X_W), de dimensão $n \times 4$, onde cada linha representa os parâmetros obtidos no passo (3) para cada subintervalo. Constrói-se assim o modelo alerta;
 - 5) Para cada novo subintervalo x_i do sinal, calcula-se o vetor x_W repetindo-se os passos (2) e (3);
 - 6) Calcula-se a distância de Mahalanobis (MDW) entre x_W e o modelo alerta wavelet;
 - 7) Aplica-se o filtro de mediana (largura de 7 amostras) ao resultado obtido;
 - 8) Um valor de limiar λ_{MD}^w é arbitrado;
 - 9) se $MDW > \lambda_{MD}^w$ então
 - | Estado \leftarrow SONOLÊNCIA
 - senão
 - | Estado \leftarrow ALERTA
-

5 DISCUSSÃO E RESULTADOS

Neste capítulo são discutidos os resultados obtidos através das metodologias propostas nos Algoritmos 1, 2 e 3, no Capítulo 4. Primeiramente, na Seção 5.1, a base de dados utilizada é apresentada, bem como o método utilizado para seleção das épocas. A detecção da sonolência via (i) melhor aproximação por m -termos (Algoritmo 1), (ii) distância de Mahalanobis com coeficientes de Fourier (Algoritmo 2) e (iii) distância de Mahalanobis com coeficientes wavelets (Algoritmo 3) é avaliada nas Seções 5.2, 5.3 e 5.4, respectivamente, utilizando como ambiente de teste as ferramentas desenvolvidas na plataforma MATLAB® e os algoritmos desenvolvidos na linguagem C. Por fim, na Seção 5.5, realiza-se uma análise comparativa de todos os métodos empregados, utilizando como referência a avaliação médica, dada pelo hipnograma.

5.1 Descrição da base de dados utilizada e classificação médica

Os sinais utilizados na validação dos algoritmos foram obtidos da base de dados PhysioNet, disponível em <http://www.physionet.org>, escolhendo os sinais provenientes do canal F_{pz} , amostrados a 100Hz. Foram selecionados 32 segmentos provenientes de 4 pacientes distintos, cada qual contendo 20 épocas de 30s, amostrados a 100Hz e com $N_J = 4096$ pontos. Assim, cada metodologia proposta é avaliada em um período equivalente a 5 horas e 20 minutos.

A seleção foi realizada de modo a evidenciar os seguintes estados cognitivos, utilizando como referência o hipnograma médico: (W) acordado, de olhos abertos e realizando atividade de concentração; (D) acordado porém de olhos fechados e relaxado, havendo no sinal predominância do ritmo alfa (alfa desbloqueado); (N1) classificação R&K para o primeiro estágio do sono.

De acordo com os estados contidos em cada seleção e visando facilitar a avaliação dos algoritmos, para cada paciente estipula-se os seguintes grupos de sinais:

- Grupo **A**: Acordado (W) em todo o período amostrado.
- Grupo **B**: Acordado (W) + Relaxado (D);
- Grupo **C**: Acordado (W) + Relaxado (D) + Sono (N1);

Considera-se sonolência as épocas classificadas nos estados (D) e (N1). Assim, os algoritmos empregados não devem identificar a sonolência nos sinais pertencentes ao grupo A. Nos sinais do grupo B, a sonolência deve ser acusada nas épocas em que o indivíduo encontra-se

relaxado. Já nos sinais do tipo C, a detecção da sonolência é esperada tanto nas épocas em que o paciente encontra-se relaxado quanto no primeiro estágio do sono (N1).

Além dos estados cognitivos, foi também utilizado como critério de seleção a distribuição normal das componentes de frequência das primeiras seis épocas selecionadas, satisfazendo a metodologia proposta no Algoritmo 2 e verificada através do teste de Mardia ([TRUJILLO-ORTIZ; HERNANDEZ-WALLS, 2003](#)).

Devido à escassez de épocas do sinal contendo componentes no ritmo alfa e ou no estado N1, estas épocas são repetidas em diferentes composições. Com esta estratégia é possível realizar um número maior de testes, uma vez que as classificações utilizando a distância de Mahalanobis são baseadas em um modelo alerta, construído com as seis primeiras épocas. O número total de épocas em um determinado estado, para cada paciente, é mostrado na Tabela 5.1.

Tabela 5.1: Banco de validação para a distância de Mahalanobis: número total de épocas em cada estado cognitivo, por paciente, considerando a ocorrência de uma mesma época em diferentes sinais.

Paciente	Número de épocas em estado alerta	Número de épocas em sonolência
01	185	55
02	61	19
03	69	11
04	205	35

Já a classificação utilizando a melhor aproximação por m -termos é baseada em parâmetros definidos por uma base de testes, não havendo a construção de um modelo para cada paciente. Para a validação deste método, a Tabela 5.2 apresenta o número de épocas distintas em um determinado estado cognitivo para cada paciente.

Tabela 5.2: Banco de validação para a melhor aproximação por m -termos: número de épocas distintas em cada estado cognitivo.

Paciente	Número de épocas em estado alerta	Número de épocas em sonolência
01	96	25
02	55	19
03	40	11
04	145	13

Na Tabela 5.3 estão dispostos todos os sinais utilizados na validação das metodologias propostas: definem-se a nomenclatura para os sinais de cada paciente e o número de épocas de determinado tipo contidas em cada seleção.

Tabela 5.3: Banco de validação contendo 32 segmentos de sinais, provenientes de 4 pacientes da base PhysioNet.

Paciente	Sinal (Tipo e numeração)	Épocas W	Épocas D	Épocas N1
01	A1	20	0	0
01	A2	20	0	0
01	A3	20	0	0
01	A4	20	0	0
01	B1	19	1	0
01	B2	17	3	0
01	B3	16	4	0
01	B4	7	13	0
01	C1	16	1	3
01	C2	8	11	1
01	C3	15	3	2
01	C4	7	7	6
02	A1	20	0	0
02	A2	20	0	0
02	C1	10	7	3
02	C2	11	6	3
03	A1	20	0	0
03	A2	20	0	0
03	C1	13	0	7
03	C2	16	0	4
04	A1	20	0	0
04	A2	20	0	0
04	A3	20	0	0
04	A4	20	0	0
04	B1	19	1	0
04	B2	13	7	0
04	B3	18	2	0
04	B4	18	2	0
04	C1	16	1	3
04	C2	10	7	3
04	C3	15	2	3
04	C4	16	2	2

A relação entre a nomenclatura de sinais utilizada neste estudo e os sinais originais do banco PhysioNet é apresentada no Apêndice C, juntamente com a ferramenta desenvolvida no ambiente MATLAB® para auxiliar a seleção destes sinais.

5.2 Detecção via melhor aproximação por m -termos

Para cada época dos sinais dispostos na Tabela 5.3, aplica-se a detecção de sonolência via melhor aproximação por m -termos, cujo algoritmo é detalhado na Seção 4.2.2. Primeiramente, uma vez que o sinal utilizado é amostrado a uma taxa de $f_s = 100$ Hz, gerando assim $N = 3000$ pontos para uma época de 30s, as fronteiras do sinal são completadas com zeros de modo a obter-se $N_J = 4096$ pontos iniciais.

Em seguida, calcula-se a TWD da época a ser analisada utilizando a wavelet DB2. O nível de parada da TWD é estipulado em $j = 5$. Assim, tem-se um conjunto de $N_w = 4064$ coeficientes wavelets. Os $m=400$ coeficientes significativos via melhor aproximação dos N_w pontos é determinada conforme o Algoritmo 1, proposto na Seção 4.2.2.

Uma vez determinados os coeficientes significativos da época em análise, calcula-se a porcentagem de coeficientes significativos nos níveis de interesse – que representam os ritmos alfa e beta, obtidos da Tabela 4.1.

A sonolência é então caracterizada através dos parâmetros $\lambda_\alpha = 25$ e $\lambda_\beta = 0.429P_\alpha - 8.714$, de acordo com as classes *alerta* e *sonolência* definidas na Fig. 4.5. Nas seções a seguir, é discutido o resultado obtido com a aplicação deste método para cada época da Tabela 5.3.

5.2.1 Paciente 01

As Figuras 5.1 e 5.2 apresentam os resultados da classificação via melhor aproximação por m -termos para cada sinal selecionado do Paciente 01. A Figura 5.3 exibe a classificação para o número total de épocas distintas, de acordo com a Tabela 5.2: verifica-se que as 25 épocas de sonolência são detectadas, como também as 96 épocas em estado alerta. Este resultado indica uma taxa de acerto do método de 100% para o Paciente 01. A Tabela 5.4 mostra a taxa de acerto do método para cada sinal selecionado do Paciente 01. Observa-se que os estados alerta e sonolência são identificados corretamente em todos os sinais dos grupos A, B e C.

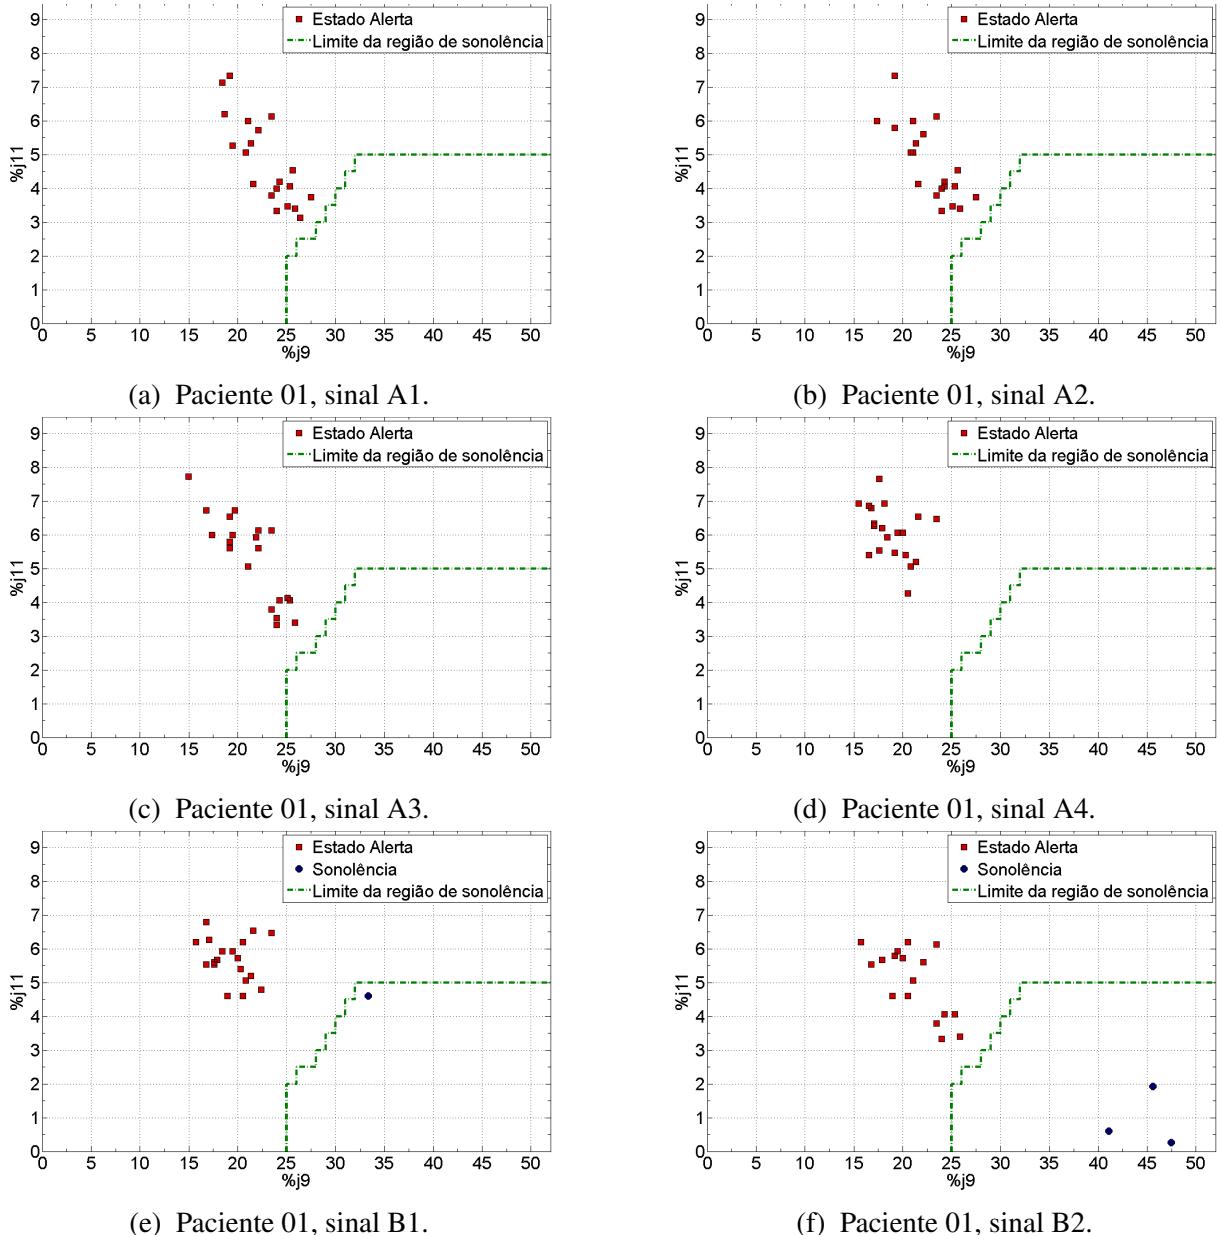


Figura 5.1: Detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 01. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.

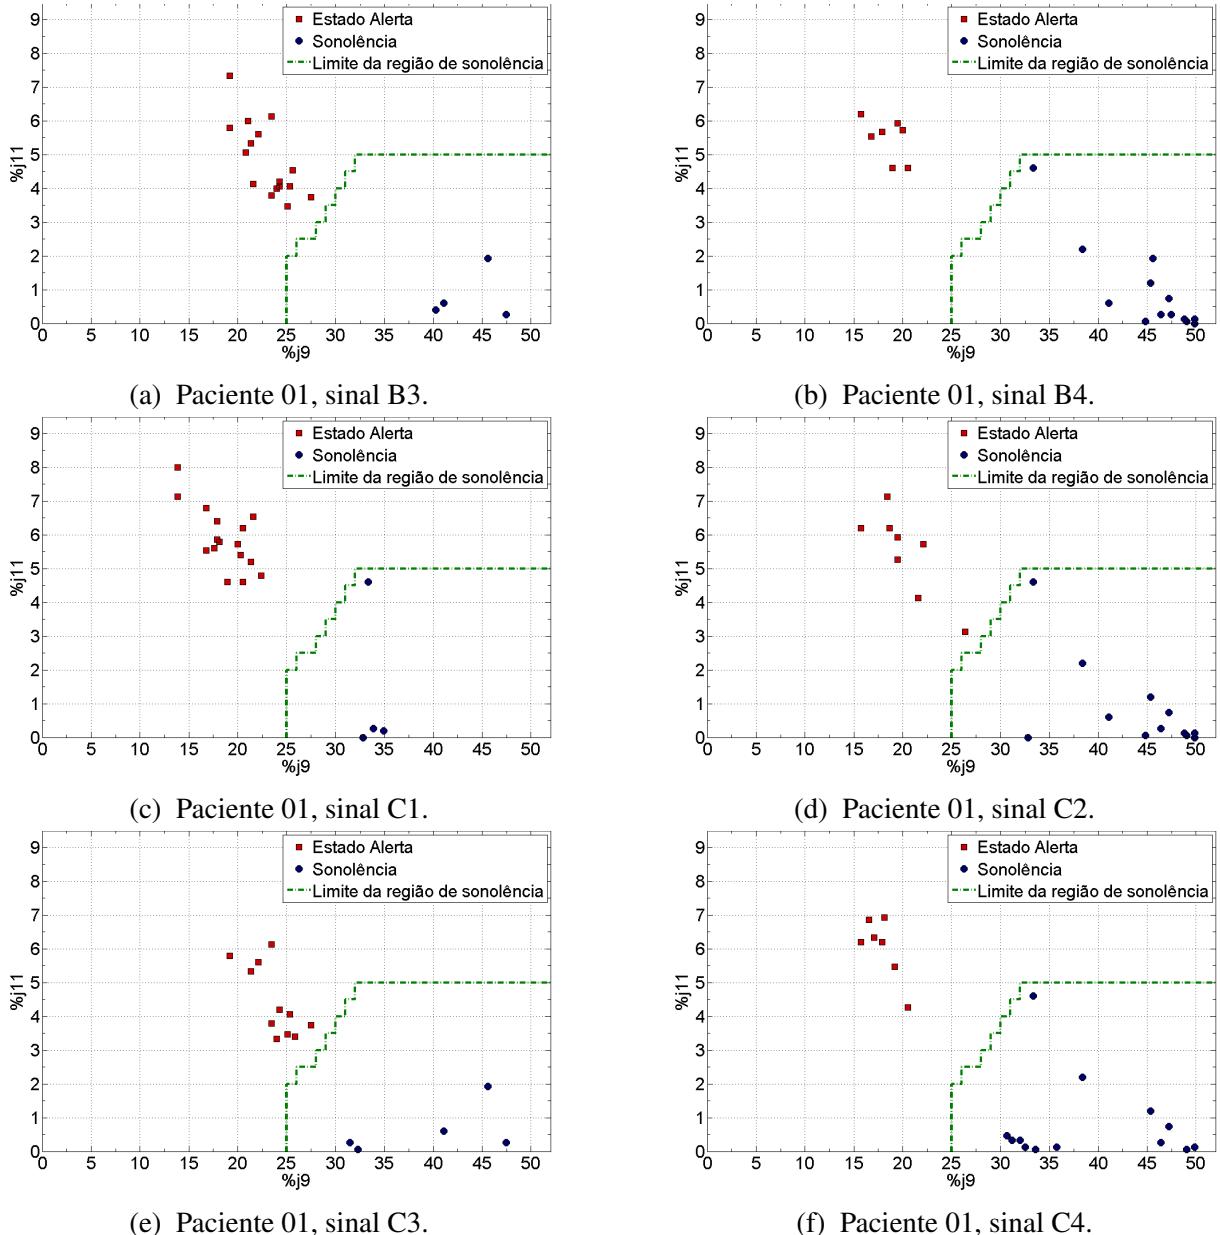


Figura 5.2: Continuação: detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 01. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.

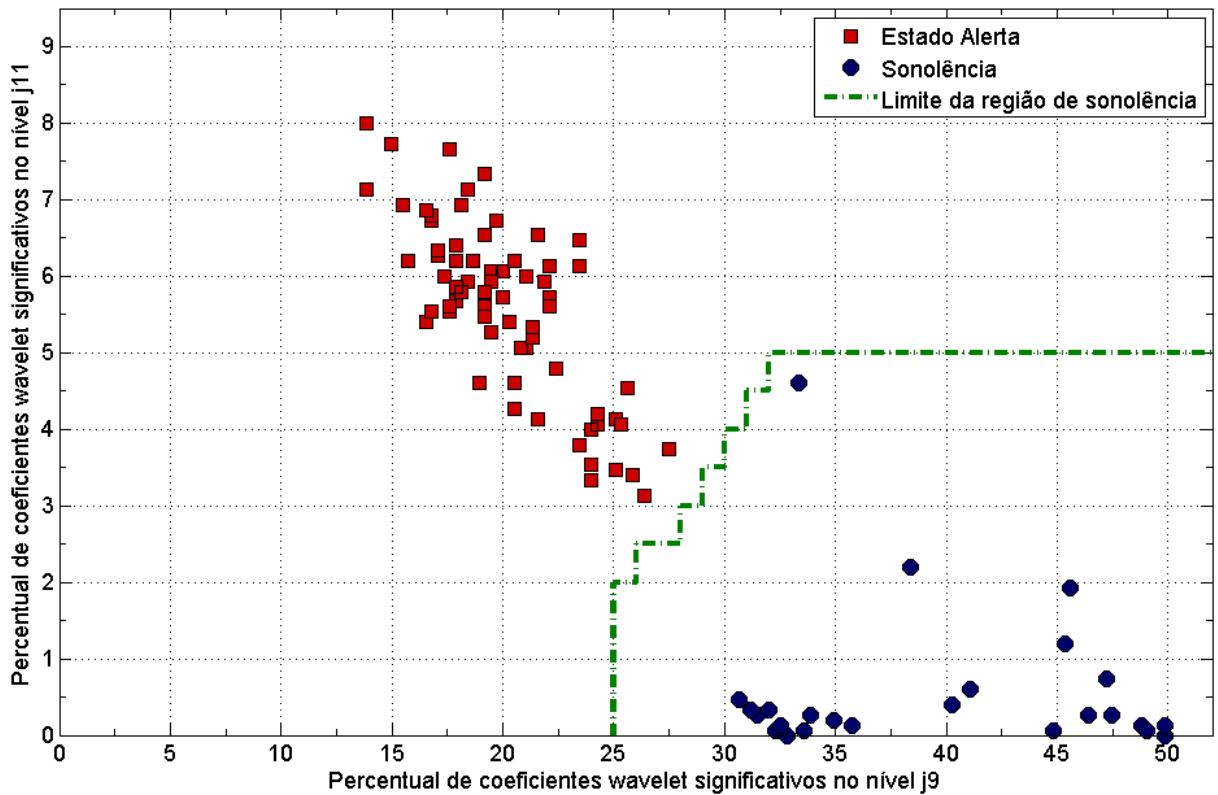


Figura 5.3: Detecção da sonolência via melhor aproximação por m -termos ($m=400$), aplicada às épocas distintas dos sinais do Paciente 01. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.

Tabela 5.4: Resultado da detecção de sonolência via melhor aproximação por m -termos no Paciente 01: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pela melhor aproximação e a taxa de acerto do método.

Paciente 01	Estado Alerta			Sonolência			
	Sinal	Hipnog.	Melhor Aprox.	%	Hipnog.	Melhor Aprox.	%
A1	20	20	20	100%	0	0	-
A2	20	20	20	100%	0	0	-
A3	20	20	20	100%	0	0	-
A4	20	20	20	100%	0	0	-
B1	19	19	19	100%	1	1	100%
B2	17	17	17	100%	3	3	100%
B3	16	16	16	100%	4	4	100%
B4	7	7	7	100%	13	13	100%
C1	16	16	16	100%	4	4	100%
C2	8	8	8	100%	12	12	100%
C3	15	15	15	100%	5	5	100%
C4	7	7	7	100%	13	13	100%
Total	185	185	185	100%	55	55	100%

5.2.2 Paciente 02

O sinal de EEG disponível na base de dados para o Paciente 02 possui poucas épocas características em estado alerta (desenvolvendo atividades de concentração) e que satisfaçam as condições impostas pelos algoritmos. Assim, são selecionadas 61 épocas em estado alerta e 19 épocas em sonolência, divididas em 4 sinais conforme disposto na Tabela 5.3.

A Figura 5.4 apresenta os resultados da classificação via melhor aproximação por m -termos para cada sinal do Paciente 02. A Figura 5.5 sintetiza todos os resultados obtidos para o Paciente 02, considerando-se apenas as épocas distintas. Em análise conjunta com a Tabela 5.2, verifica-se que há um acerto de 100% na detecção da sonolência. Das 55 épocas em estado alerta, 9 são classificadas como sonolência (falso-positivo), indicando um acerto de 84% na classificação de épocas em estado alerta.

A Tabela 5.5 exibe a taxa de acerto do método para cada sinal selecionado do Paciente 02. Considerando-se a repetição de algumas épocas, a taxa de acerto na detecção do estado alerta é de 79% e a detecção da sonolência mantém-se em 100%.

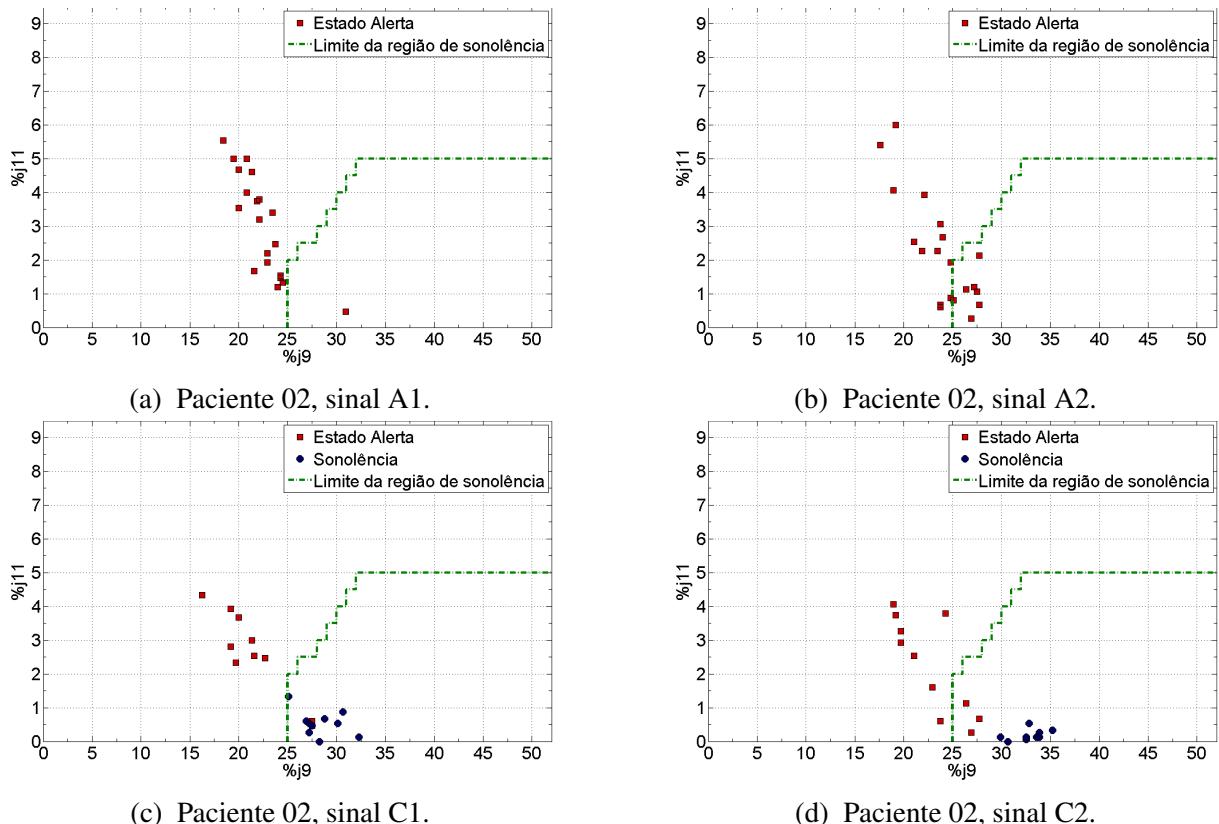


Figura 5.4: Detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 02. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.

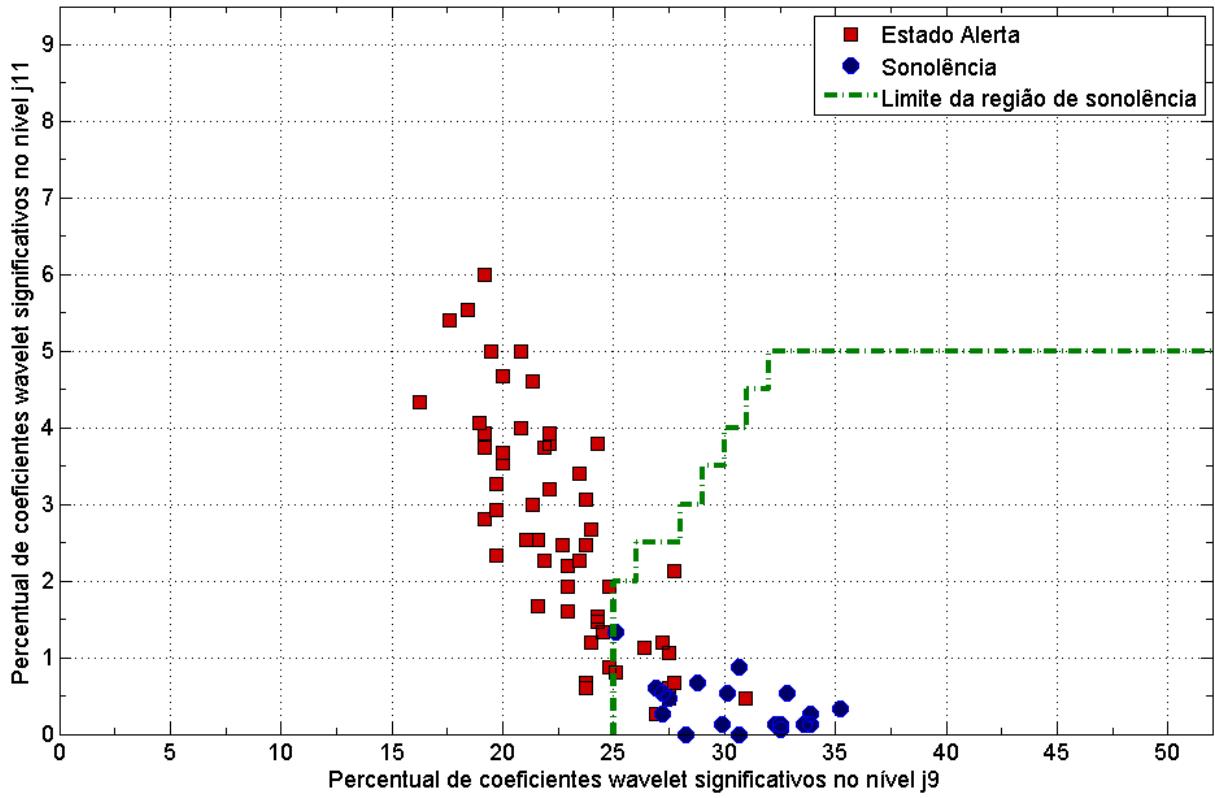


Figura 5.5: Detecção da sonolência via melhor aproximação por m -termos ($m=400$), aplicada às épocas distintas dos sinais do Paciente 02. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.

Tabela 5.5: Resultado da detecção de sonolência via melhor aproximação por m -termos no Paciente 02: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pela melhor aproximação e a taxa de acerto do método.

Paciente 02	Estado Alerta				Sonolência		
	Sinal	Hipnog.	Melhor Aprox.	%	Hipnog.	Melhor Aprox.	%
A1	20	19	95%		0	0	-
A2	20	13	65%		0	0	-
C1	10	8	80%		10	10	100%
C2	11	8	73%		9	9	100%
Total	61	48	79%		19	19	100%

5.2.3 Paciente 03

O sinal de EEG do Paciente 03 tem como peculiaridade a ausência de atividade alfa, efeito denominado *supressão ou bloqueio de alfa* e que é associado tanto a funções cognitivas quanto a características particulares do indivíduo (WILLIAMSON et al., 1997; Del Percio et al., 2011). Assim, são selecionadas 40 épocas em estado alerta e 11 épocas no estado N1 (sonolência

determinada principalmente pelo ritmo teta), combinadas em 4 sinais conforme disposto na Tabela 5.3.

Na Figura 5.6 os resultados da classificação via melhor aproximação por m -termos são apresentados para cada sinal do Paciente 03. A Figura 5.7 agrupa todos os resultados obtidos para o Paciente 03, sem considerar a repetição de épocas. Há um acerto de 100% na identificação do estado alerta para todos os sinais. Mesmo sem componente alfa no sinal, a sonolência (N1) é identificada com a ocorrência de apenas 2 falso-negativos, resultando em uma detecção correta da sonolência de 82%.

O mesmo resultado é obtido ao analisar-se a taxa de acerto da melhor aproximação por m -termos para cada sinal separado do Paciente 03, conforme a Tabela 5.6, indicando uma taxa de acerto de 100% e 82% para a detecção dos estados alerta e sonolência, respectivamente.

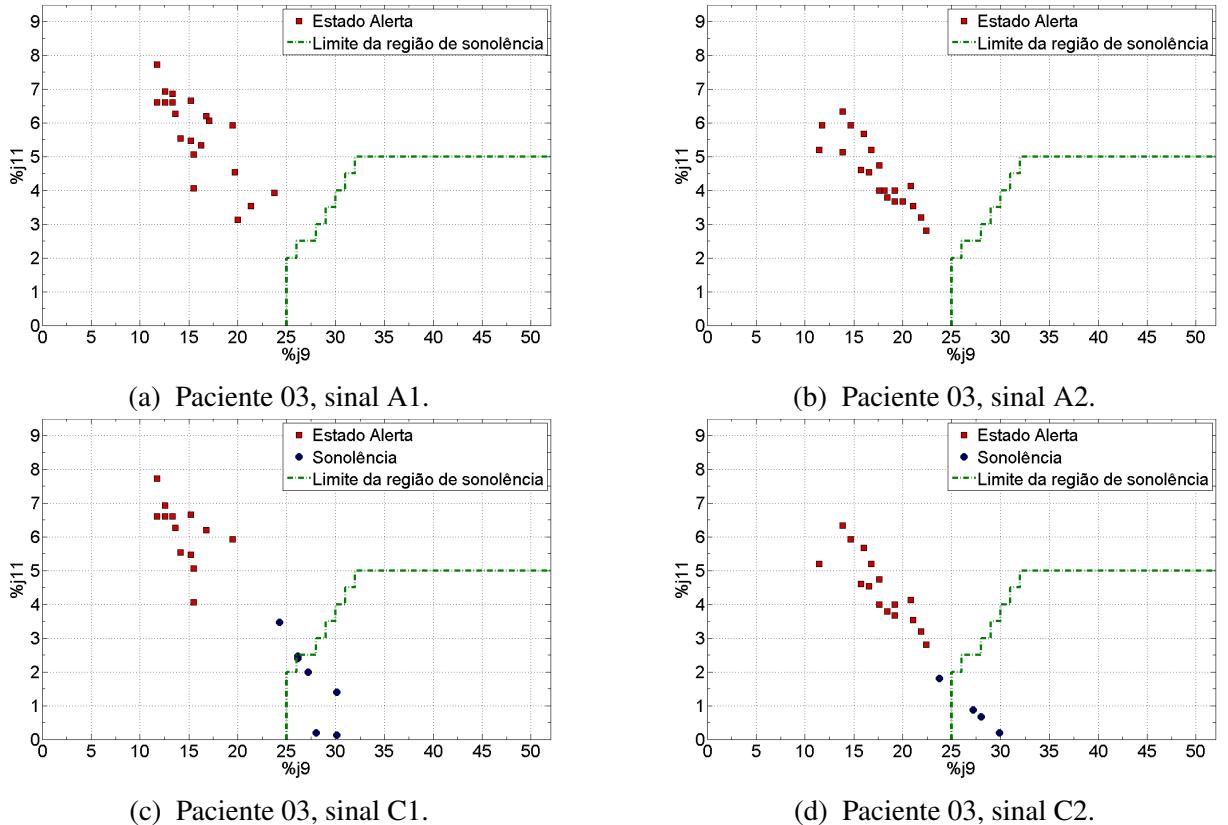


Figura 5.6: Detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 03. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.

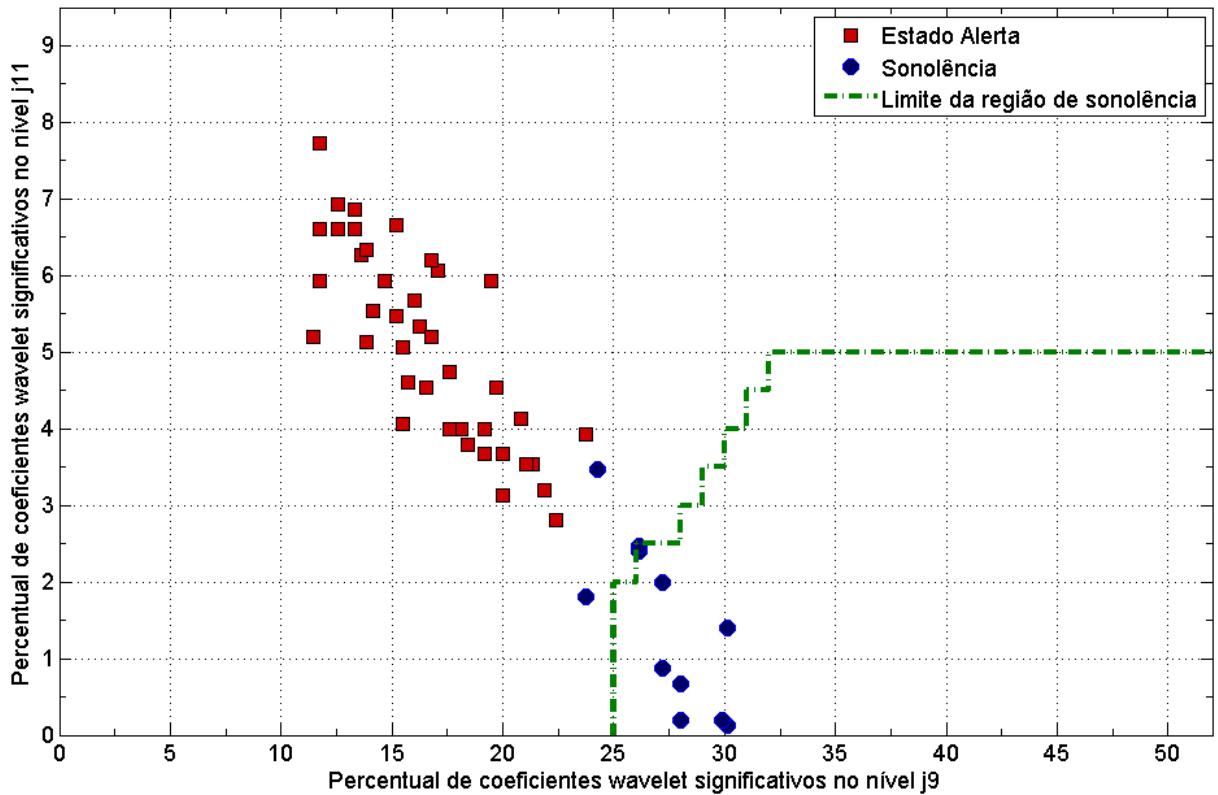


Figura 5.7: Detecção da sonolência via melhor aproximação por m -termos ($m=400$), aplicada às épocas distintas dos sinais do Paciente 03. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.

Tabela 5.6: Resultado da detecção de sonolência via melhor aproximação por m -termos no Paciente 03: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pela melhor aproximação e a taxa de acerto do método.

Paciente 03	Estado Alerta				Sonolência		
	Sinal	Hipnog.	Melhor Aprox.	%	Hipnog.	Melhor Aprox.	%
A1	20	20	20	100%	0	0	-
A2	20	20	20	100%	0	0	-
C1	13	13	13	100%	7	6	86%
C2	16	16	16	100%	4	3	75%
Total	69	69	69	100%	11	9	82%

5.2.4 Paciente 04

As Figuras 5.8 e 5.9 apresentam os resultados da classificação via melhor aproximação por m -termos para cada sinal selecionado do Paciente 04, divididos nos grupos A, B e C conforme disposto na Tabela 5.3.

A Tabela 5.7 mostra a taxa de acerto do método para cada sinal selecionado do Paciente 04. Para a detecção do estado alerta, verifica-se uma taxa de acerto de 100% para todos os sinais. A detecção da sonolência tem acerto de 100% em 3 sinais do grupo B e em apenas 1 sinal do grupo C, totalizando um acerto de 83%.

Considerando-se apenas as épocas distintas, a Figura 5.10 exibe o resultado da classificação, de acordo com o número de épocas dado na Tabela 5.2. A detecção da sonolência ocorre com 77% de acerto e a detecção do estado alerta ocorre com 100% de acerto.

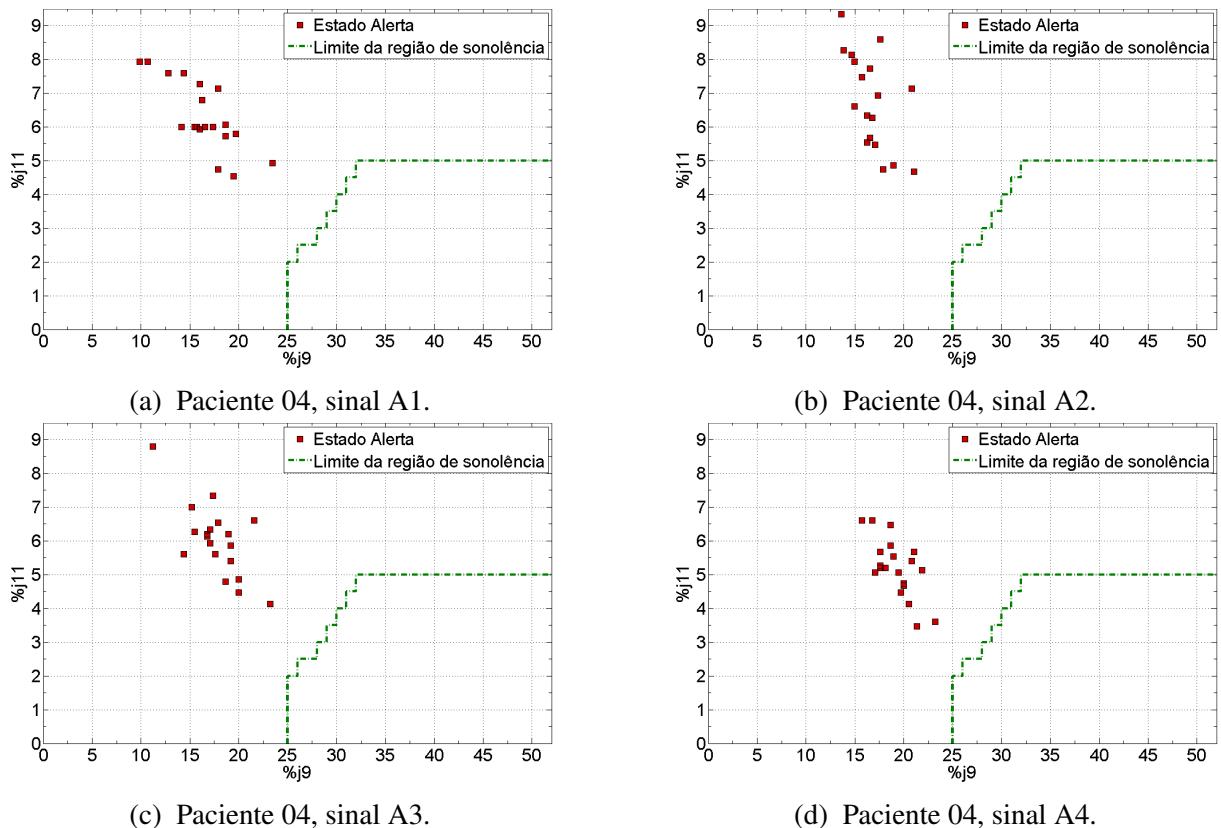


Figura 5.8: Detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 04. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.

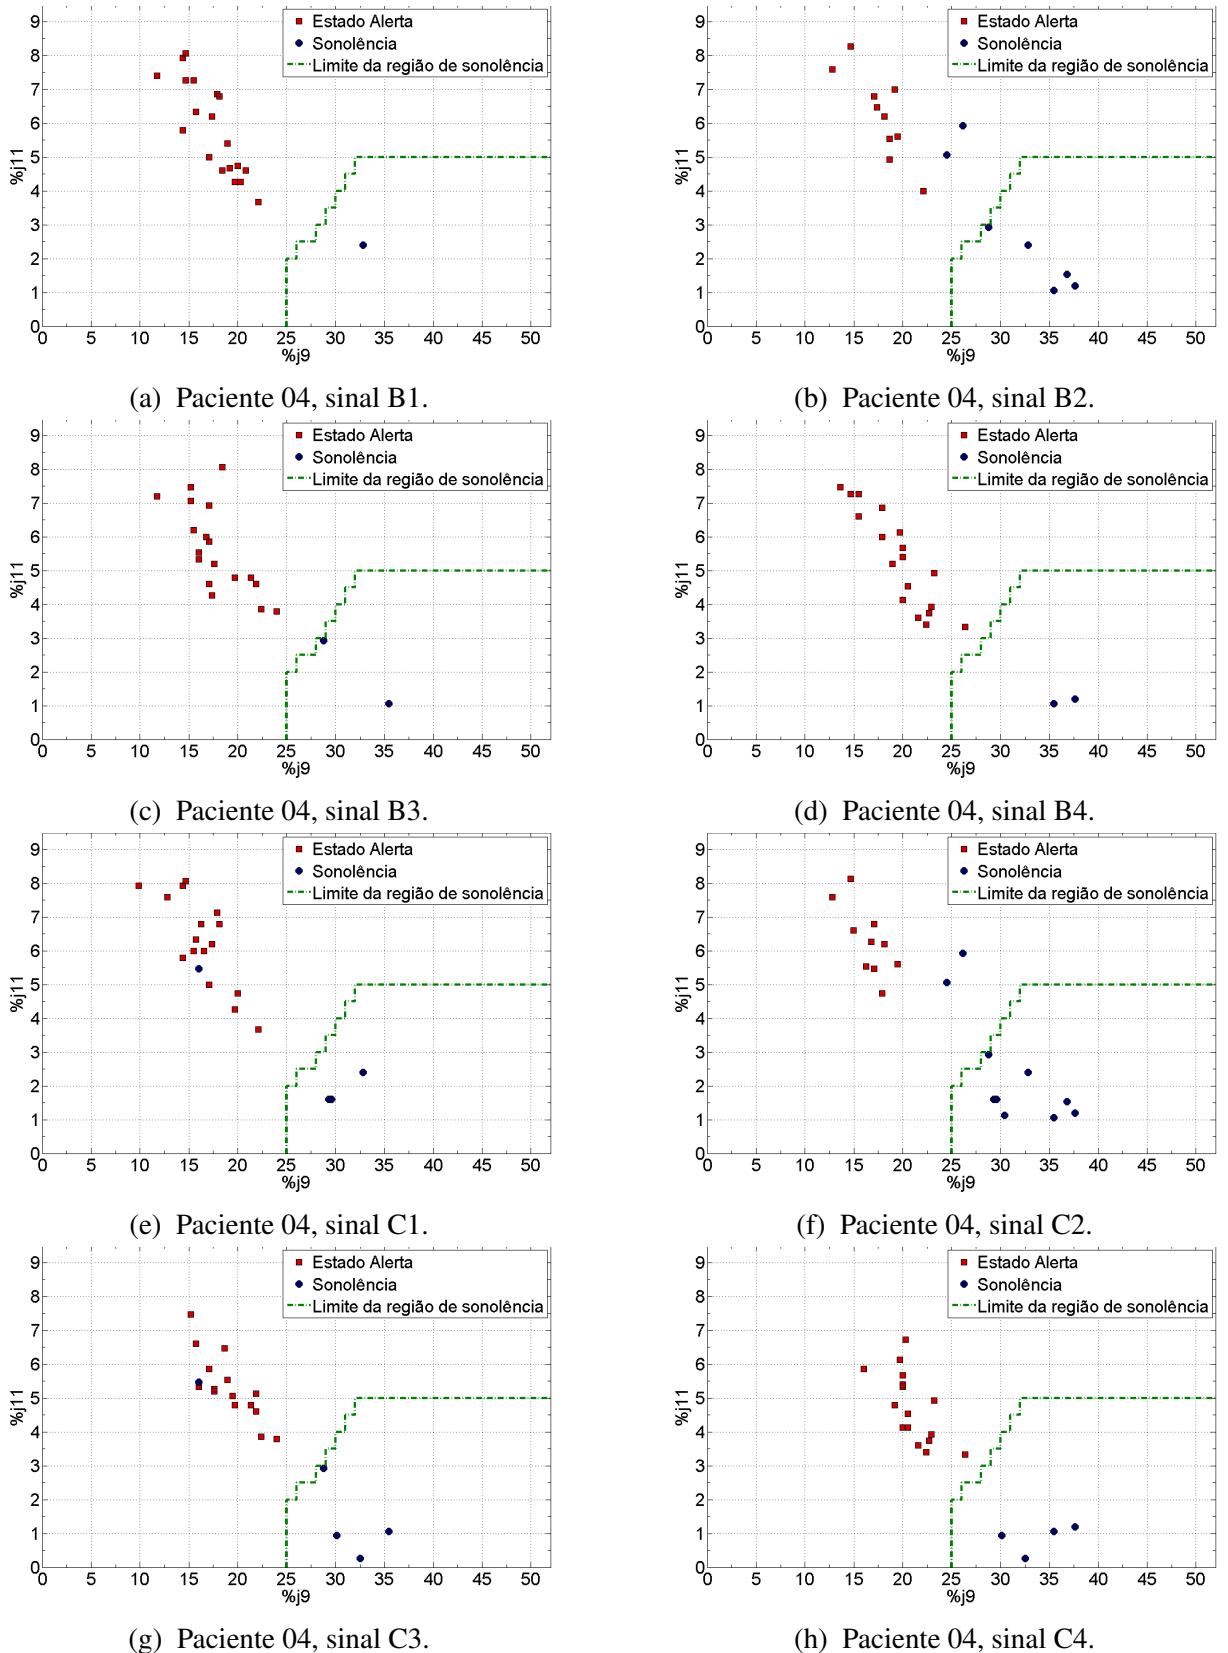


Figura 5.9: Continuação: detecção da sonolência via melhor aproximação por m -termos ($m=400$), para cada sinal selecionado do Paciente 04. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.

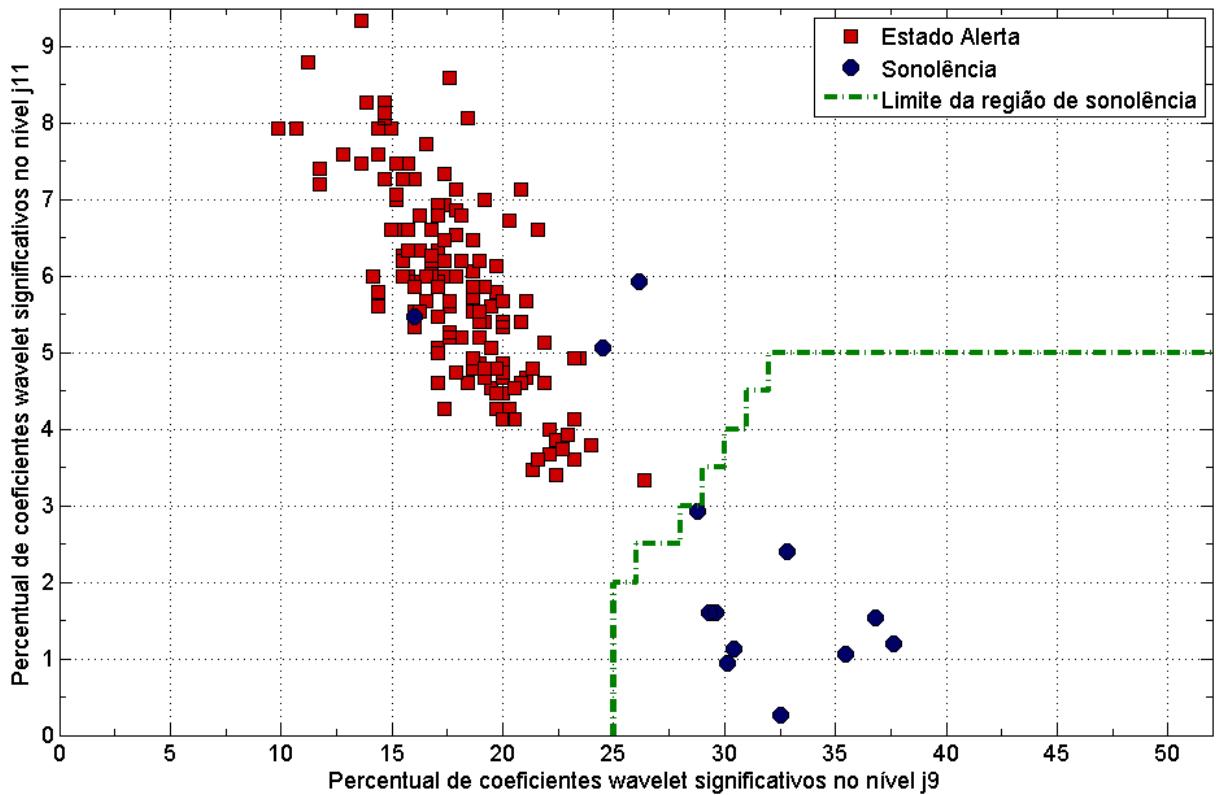


Figura 5.10: Detecção da sonolência via melhor aproximação por m -termos ($m=400$), aplicada às épocas distintas dos sinais do Paciente 04. A forma dos pontos indica a classificação pelo hipnograma e a posição no gráfico indica a classificação pela melhor aproximação.

Tabela 5.7: Resultado da detecção de sonolência via melhor aproximação por m -termos no Paciente 04: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pela melhor aproximação e a taxa de acerto do método.

Paciente 04		Estado Alerta			Sonolência		
Sinal	Hipnog.	Melhor Aprox.	%	Hipnog.	Melhor Aprox.	%	
A1	20	20	100%	0	0	-	
A2	20	20	100%	0	0	-	
A3	20	20	100%	0	0	-	
A4	20	20	100%	0	0	-	
B1	19	19	100%	1	1	100%	
B2	13	13	100%	7	5	72%	
B3	18	18	100%	2	2	100%	
B4	18	18	100%	2	2	100%	
C1	16	16	100%	4	3	75%	
C2	10	10	100%	10	8	80%	
C3	15	15	100%	5	4	80%	
C4	16	16	100%	4	4	100%	
Total	205	205	100%	35	29	83%	

5.3 Distância de Mahalanobis utilizando coeficientes de Fourier

Nesta seção são apresentados os resultados para o método de detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, apresentado na Seção 4.3.1. Neste método, para cada sinal apresentado na Tabela 5.3, gera-se um *modelo alerta* utilizando-se as seis primeiras épocas do sinal, baseada nos coeficientes da transformada de Fourier. A detecção da sonolência nas demais épocas do sinal dá-se através da distância de Mahalanobis entre os parâmetros atuais e o modelo construído. Considera-se a ocorrência de sonolência quando o valor desta distância (MDC) ultrapassa o valor de *threshold* $\lambda_{MD}^f = 10$.

O resultado deste método é apresentado nas subseções a seguir. A validação é realizada com referência aos estados determinados pelo hipnograma, representados nos gráficos através de símbolos distintos para os estados (i) alerta; (ii) relaxado, com componente alfa; e (iii) estágio N1 do sono.

5.3.1 Paciente 01

As Figuras 5.11, 5.12 e 5.13 apresentam os resultados da classificação via distância de Mahalanobis utilizando coeficientes de Fourier para os diferentes sinais do Paciente 01.

A Tabela 5.8 expõe a taxa de acerto para cada sinal classificado através do método proposto. O estado alerta é detectado satisfatoriamente em 99% dos casos. A taxa de acerto na detecção da sonolência é de 91%, tendo um acerto de 100% para sinais pertencentes ao grupo A (sonolência caracterizada somente pela componente alfa) e acerto médio de 82% para sinais pertencentes ao grupo B (sonolência caracterizada também pelo estágio N1 do sono).

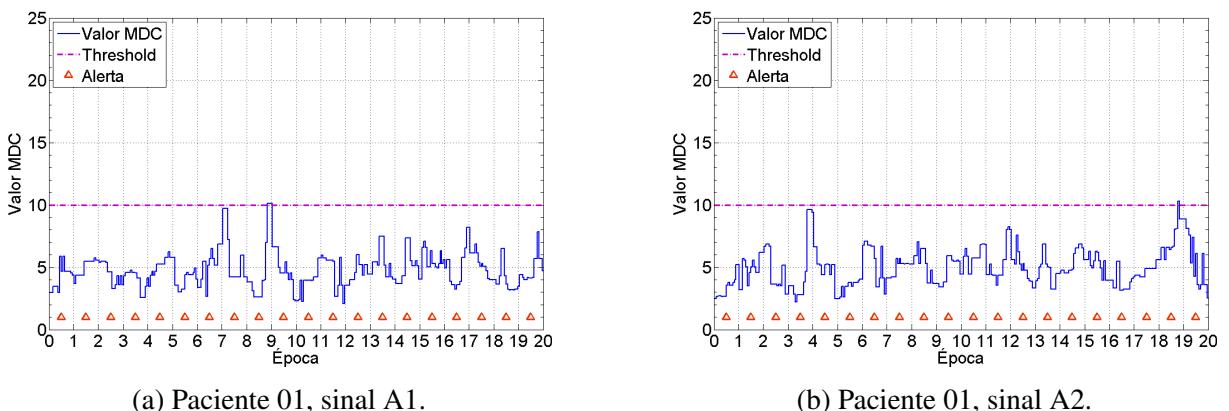


Figura 5.11: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 01. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada para cada época.

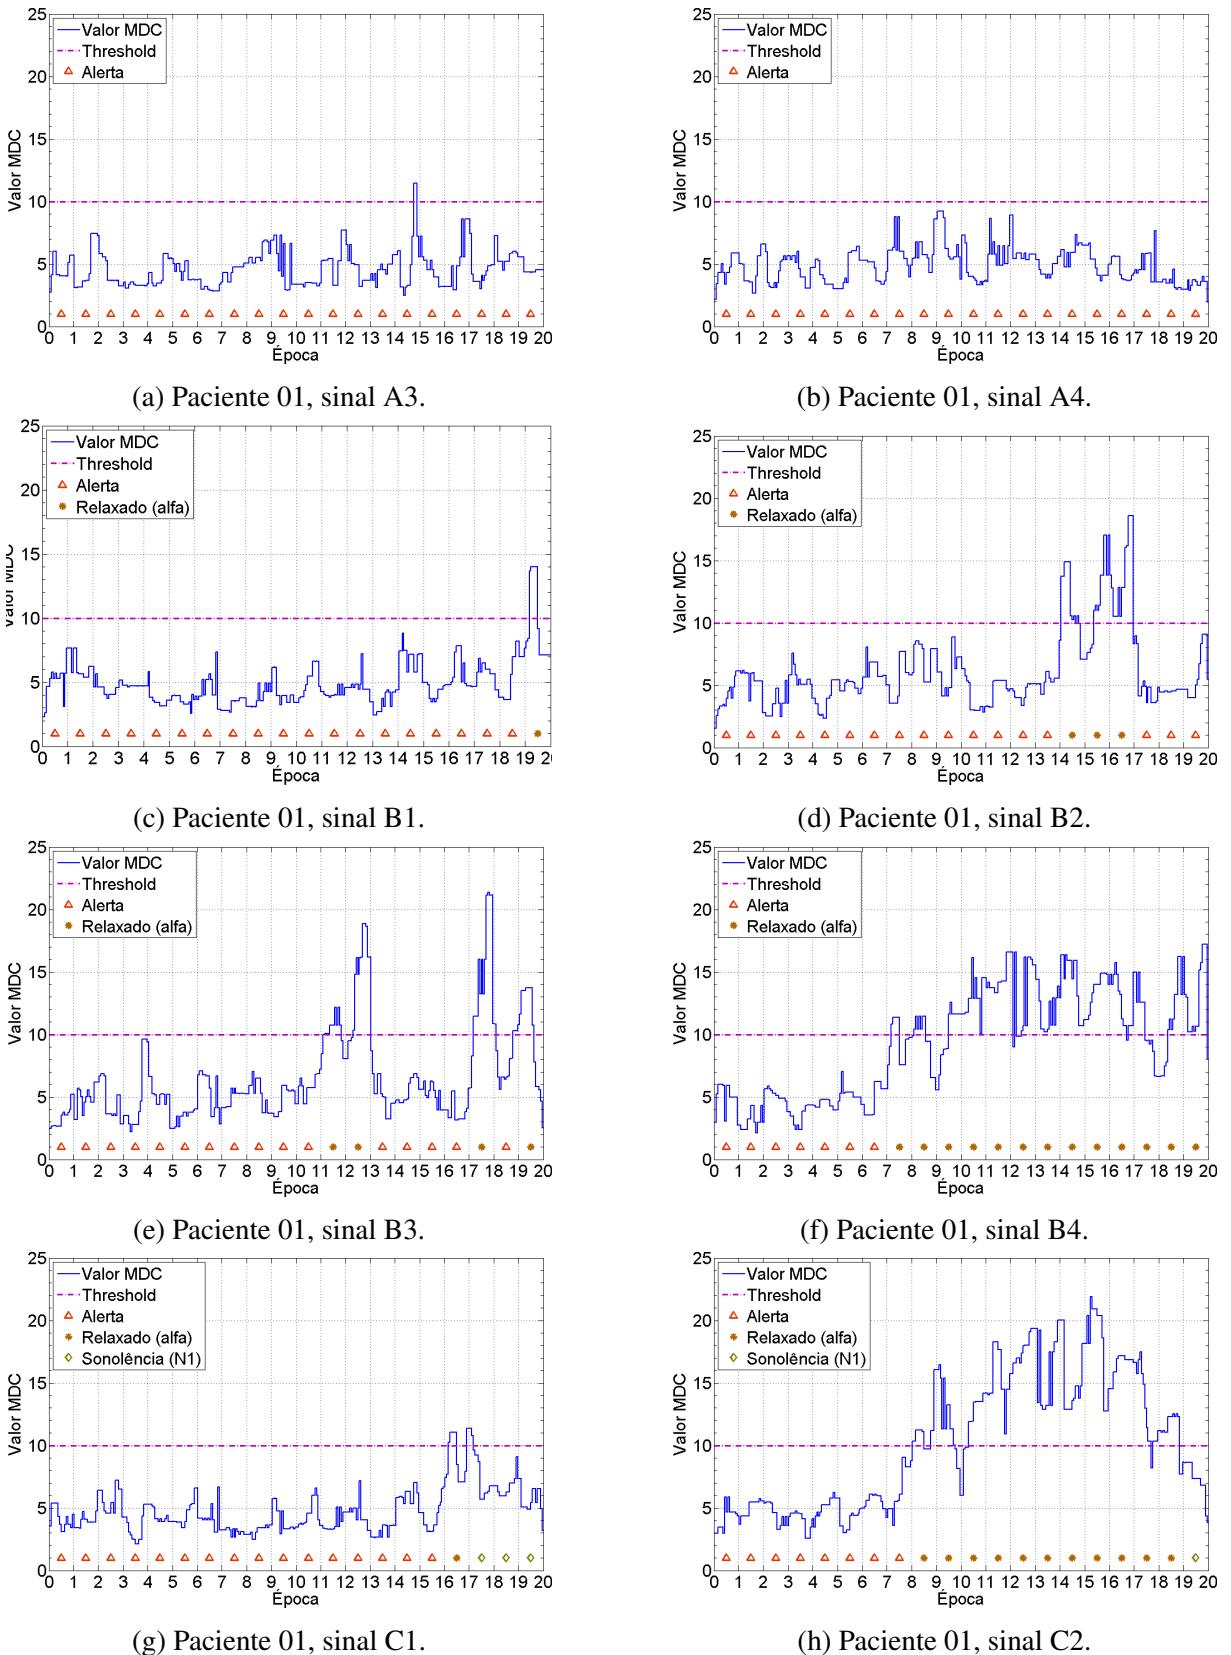


Figura 5.12: Continuação: detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 01. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada para cada época.

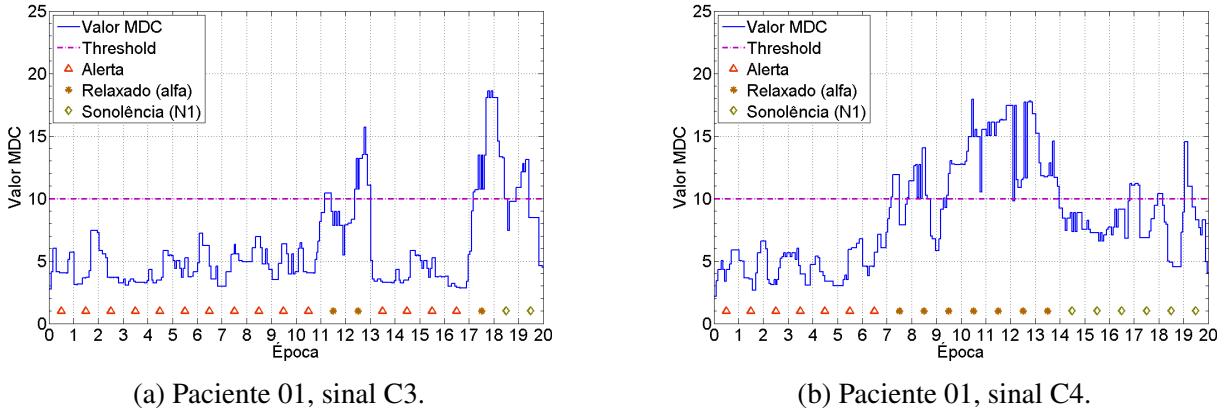


Figura 5.13: Continuação: detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 01. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada para cada época.

Tabela 5.8: Detecção da sonolência via distância de Mahalanobis com coeficientes de Fourier no Paciente 02: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.

Paciente 01	Estado Alerta				Sonolência		
	Sinal	Hipnograma	MDC	%	Hipnograma	MDC	%
A1	20	19	95%	0	0	-	-
A2	20	19	95%	0	0	-	-
A3	20	19	95%	0	0	-	-
A4	20	20	100%	0	0	-	-
B1	19	19	100%	1	1	100%	
B2	17	17	100%	3	3	100%	
B3	16	16	100%	4	4	100%	
B4	7	7	100%	13	13	100%	
C1	16	16	100%	4	2	50%	
C2	8	8	100%	12	11	92%	
C3	15	15	100%	5	5	100%	
C4	7	7	100%	13	11	85%	
Total	185	182	99%	55	50	91%	

5.3.2 Paciente 02

Conforme apresentado na Seção 5.2.2, para o Paciente 02 são utilizadas 61 épocas em estado alerta e 19 épocas em sonolência, divididas em 2 sinais pertencentes ao grupo A e 2 sinais pertencentes ao grupo C. A Figura 5.14 apresenta os resultados da classificação via distância de Mahalanobis para estes sinais.

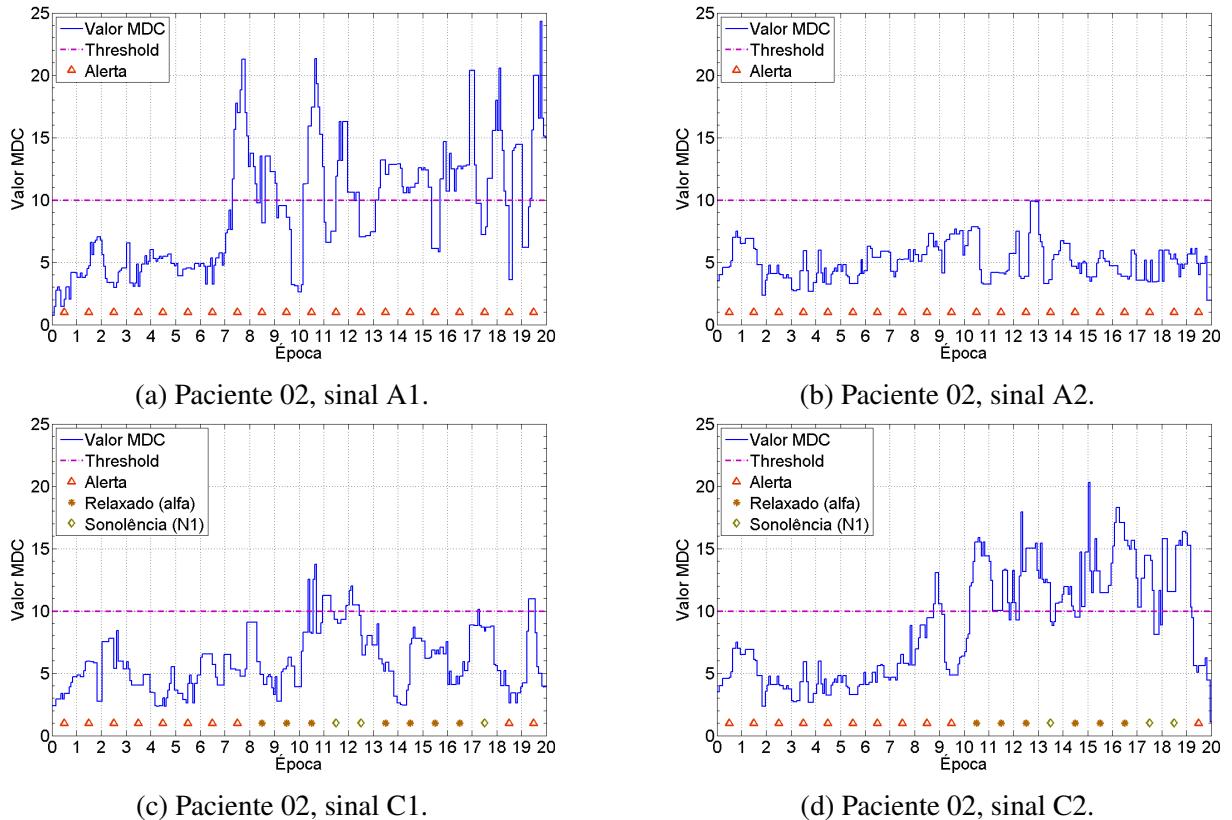


Figura 5.14: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 02. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada em cada época.

Tabela 5.9: Detecção da sonolência via distância de Mahalanobis com coeficientes de Fourier no Paciente 02: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.

Paciente 02	Estado Alerta			Sonolência		
	Sinal	Hipnograma	MDC	%	Hipnograma	MDC
A1	20	7	35%	0	0	-
A2	20	20	100%	0	0	-
C1	10	9	90%	10	4	40%
C2	11	9	82%	9	9	100%
Total	61	45	74%	19	13	68%

5.3.3 Paciente 03

Para o Paciente 03 são avaliadas 69 épocas em estado alerta e 11 épocas no estágio de sono N1, distribuídas em 4 diferentes sinais. A Figura 5.15 apresenta os resultados da classificação via distância de Mahalanobis para estes sinais. Pela Tabela 5.10, verifica-se que o acerto na identificação do estado alerta é de 97%, enquanto a detecção da sonolência tem acerto de 73%.

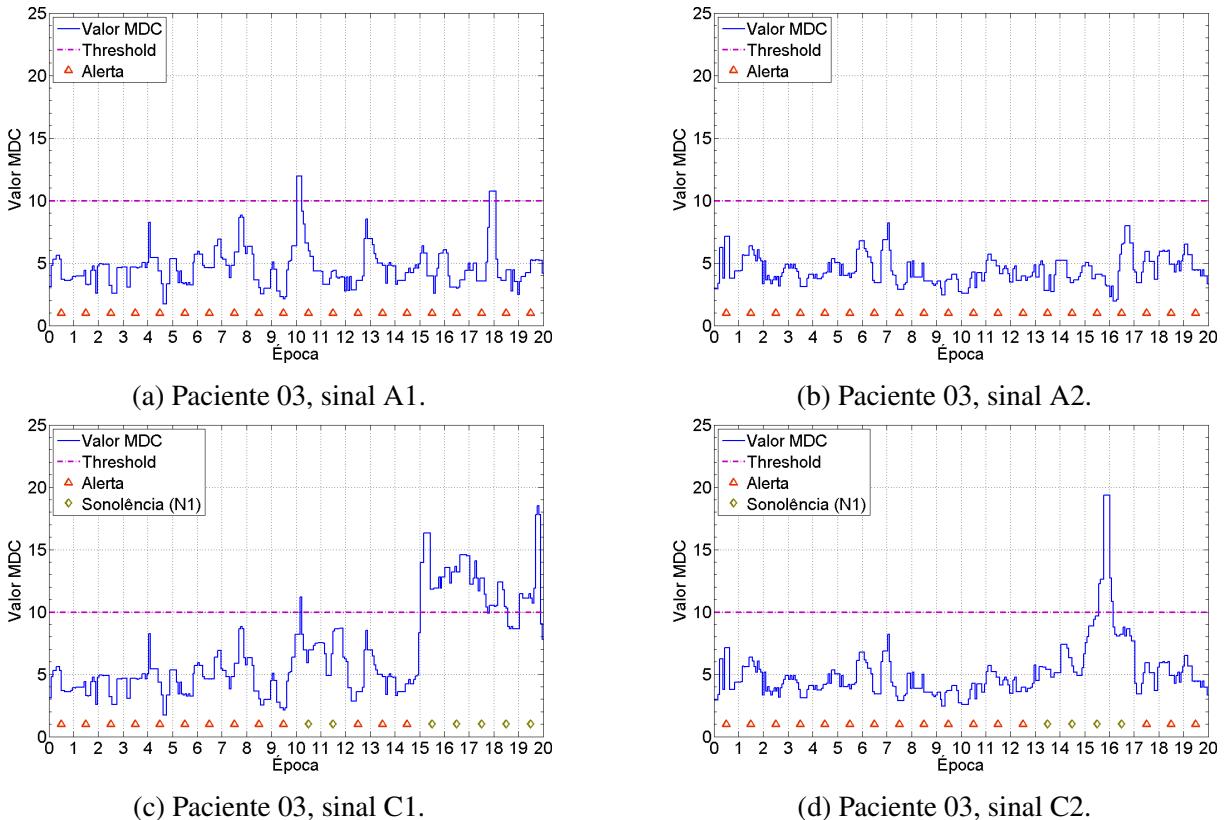


Figura 5.15: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 03. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada em cada época.

Tabela 5.10: Detecção da sonolência via distância de Mahalanobis com coeficientes de Fourier no Paciente 03: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.

Paciente 03	Estado Alerta			Sonolência			
	Sinal	Hipnograma	MDC	%	Hipnograma	MDC	%
A1	20	18	90%	0	0	-	
A2	20	20	100%	0	0	-	
C1	13	13	100%	7	6	86%	
C2	16	16	100%	4	2	50%	
Total	69	67	97%	11	8	73%	

5.3.4 Paciente 04

As Figuras 5.16 e 5.17 apresentam os resultados da classificação via distância de Mahalanobis com coeficientes de Fourier para os sinais do Paciente 04, divididos nos grupos A, B e C, conforme a Tabela 5.3.

A taxa de acerto na identificação do estado alerta e na detecção da sonolência é mostrado na Tabela 5.11. Para os sinais do grupo A, o estado alerta é identificado em 100% dos casos. Esta taxa de acerto decai para 85% nos sinais do grupo B e mantém-se em 97% para os sinais do grupo C. A detecção da sonolência é dada com uma taxa de acerto de 94% para os sinais do Paciente 04.

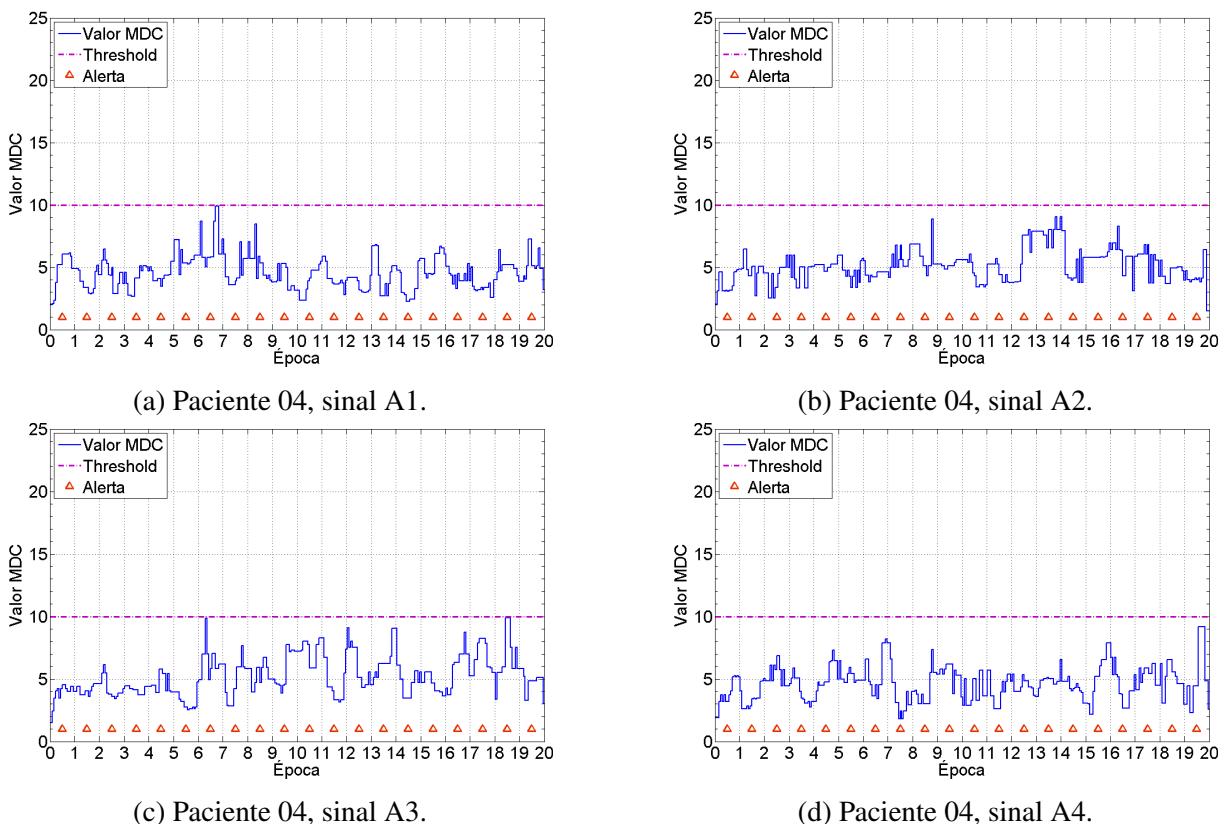


Figura 5.16: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 04. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada em cada época.

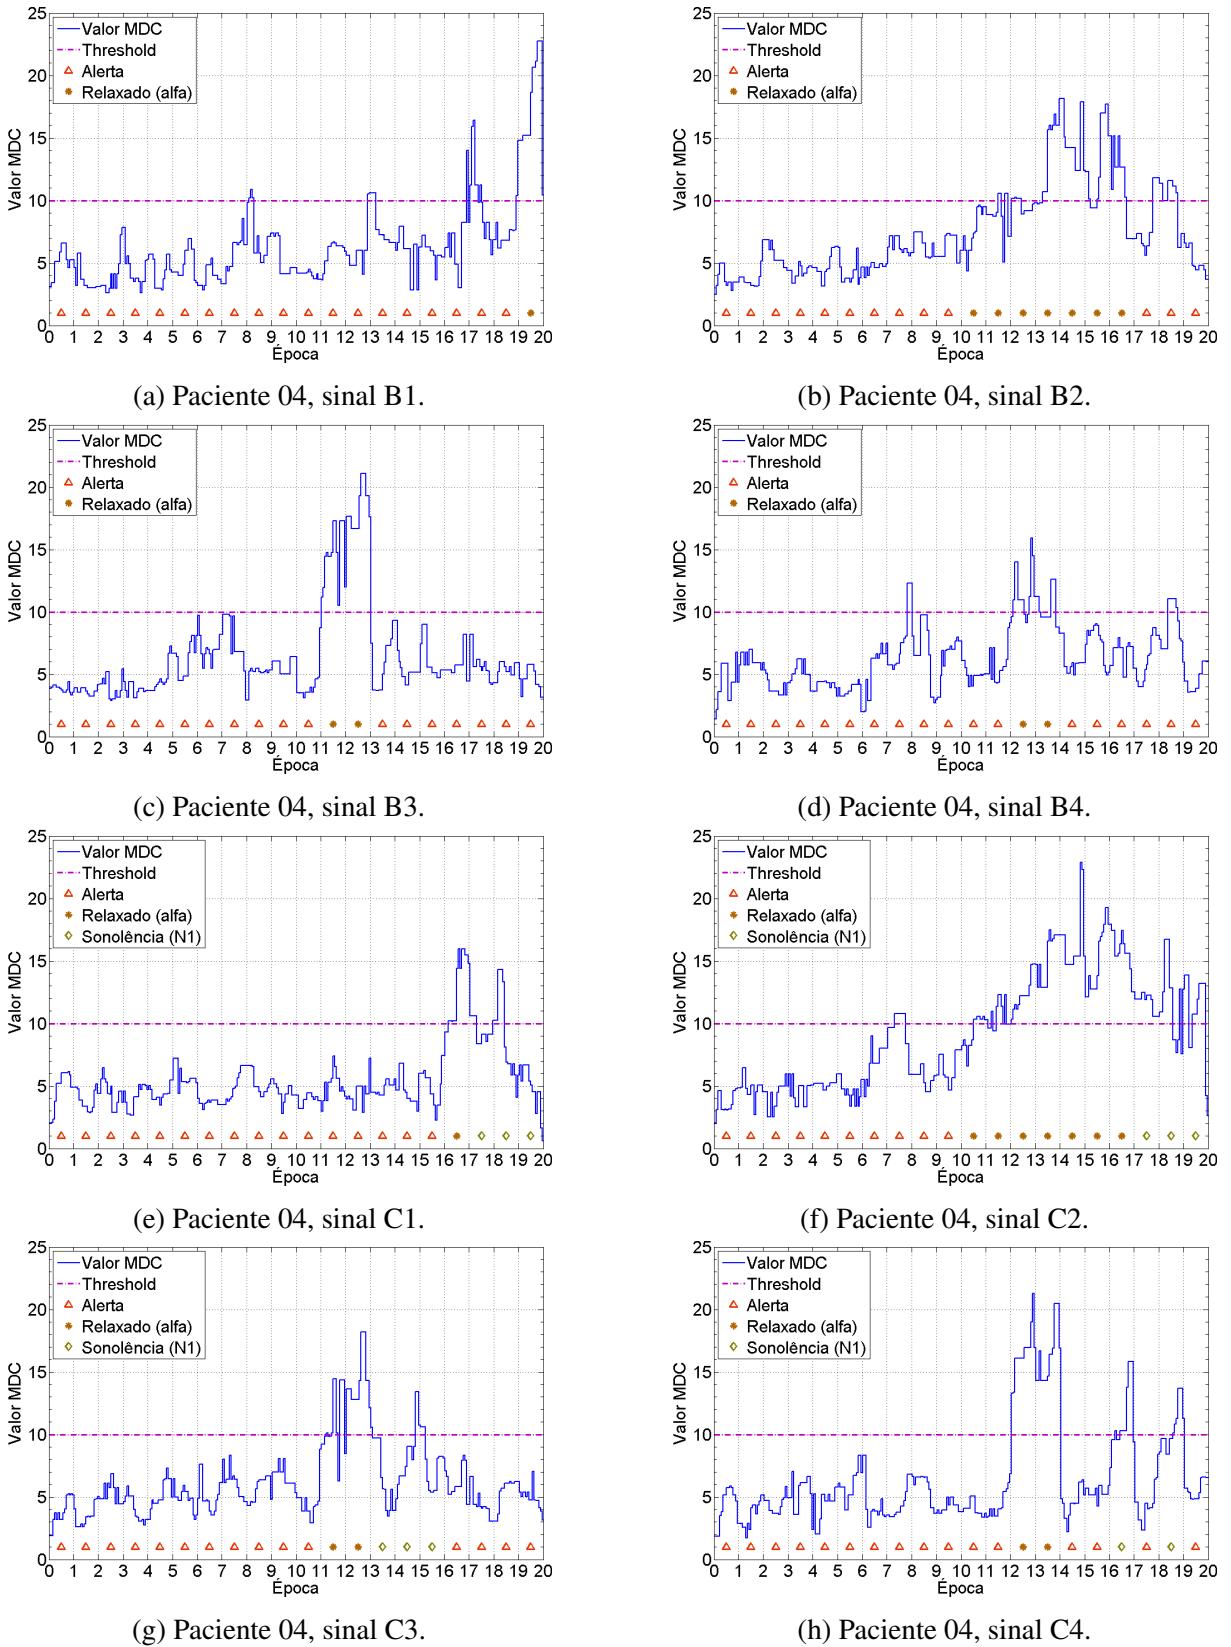


Figura 5.17: Continuação: detecção da sonolência via distância de Mahalanobis utilizando coeficientes de Fourier, para cada sinal selecionado do Paciente 04. A sonolência ocorre quando $MDC > threshold$. A classificação do hipnograma é indicada em cada época.

Tabela 5.11: Resultado da detecção de sonolência via distância de Mahalanobis com coeficientes de Fourier, aplicada aos sinais do Paciente 04.

Paciente 04	Estado Alerta			Sonolência		
	Sinal	Hipnograma	MDC	%	Hipnograma	MDC
A1	20	20	100%	0	0	-
A2	20	20	100%	0	0	-
A3	20	20	100%	0	0	-
A4	20	20	100%	0	0	-
B1	19	13	68%	1	1	100%
B2	13	11	85%	7	6	86%
B3	18	18	100%	2	2	100%
B4	18	16	89%	2	2	100%
C1	16	16	100%	4	3	75%
C2	10	9	90%	10	10	100%
C3	15	15	100%	5	5	100%
C4	16	16	100%	4	4	100%
Total	205	194	95%	35	33	94%

5.4 Distância de Mahalanobis utilizando coeficientes wavelet

Esta metodologia, proposta na Seção 4.3.2, consiste em uma adaptação da detecção de sonolência via distância de Mahalanobis e coeficientes de Fourier, onde os coeficientes wavelets são utilizados para extração de características. Contudo, nesta análise o teste de Mardia não foi utilizado para verificar a distribuição normal dos coeficientes wavelet.

Para cada sinal apresentado na Tabela 5.3, gera-se um *modelo alerta* utilizando-se as seis primeiras épocas do sinal, baseada em parâmetros estatísticos dos coeficientes da transformada wavelet. A detecção da sonolência nas demais épocas do sinal dá-se através da distância de Mahalanobis entre os parâmetros atuais e o modelo construído. Considera-se a ocorrência de sonolência quando o valor desta distância (MDW) ultrapassa o valor de $threshold \lambda_{MD}^w = 20$.

Nas subseções a seguir são apresentados os resultados desta metodologia para os 4 pacientes analisados. A validação é realizada tendo como referência os estados determinados pelo hipnograma, representados nos gráficos através de símbolos distintos para os estados (i) alerta; (ii) relaxado, com componente alfa; e (iii) estágio N1 do sono. Na Seção 5.5 o resultado desta metodologia será comparado aos das outras duas já apresentadas.

5.4.1 Paciente 01

As Figuras 5.18 e 5.19 apresentam os resultados da detecção de sonolência via distância de Mahalanobis utilizando coeficientes wavelets para os sinais do Paciente 01. A taxa de acerto para cada sinal classificado é apresentada na Tabela 5.12.

Analizando-se os resultados, verifica-se um aumento na ocorrência de falso-positivos, isto é, da identificação de épocas em estado alerta como evento de sonolência. Ainda assim, a taxa de acerto na identificação do estado alerta é de 91%. A detecção da sonolência é realizada com uma taxa de acerto de 98%.

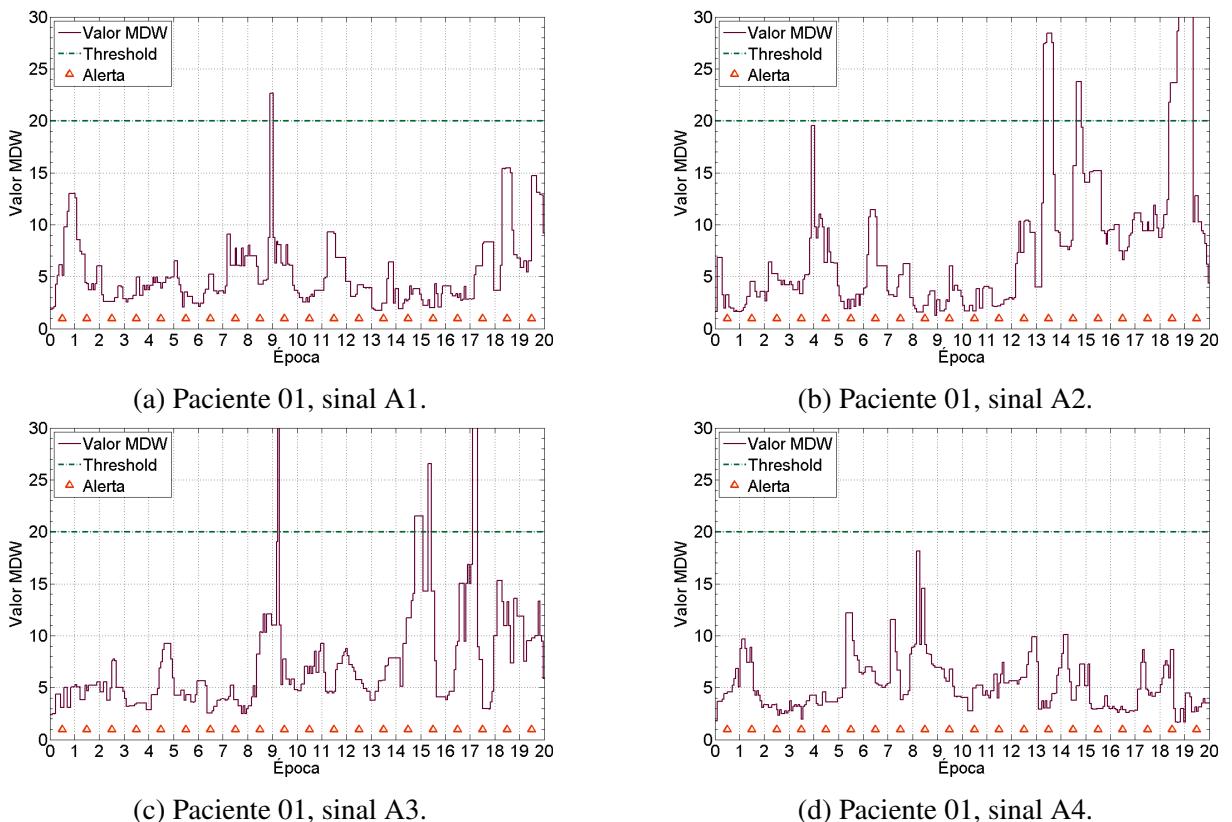


Figura 5.18: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 01. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.

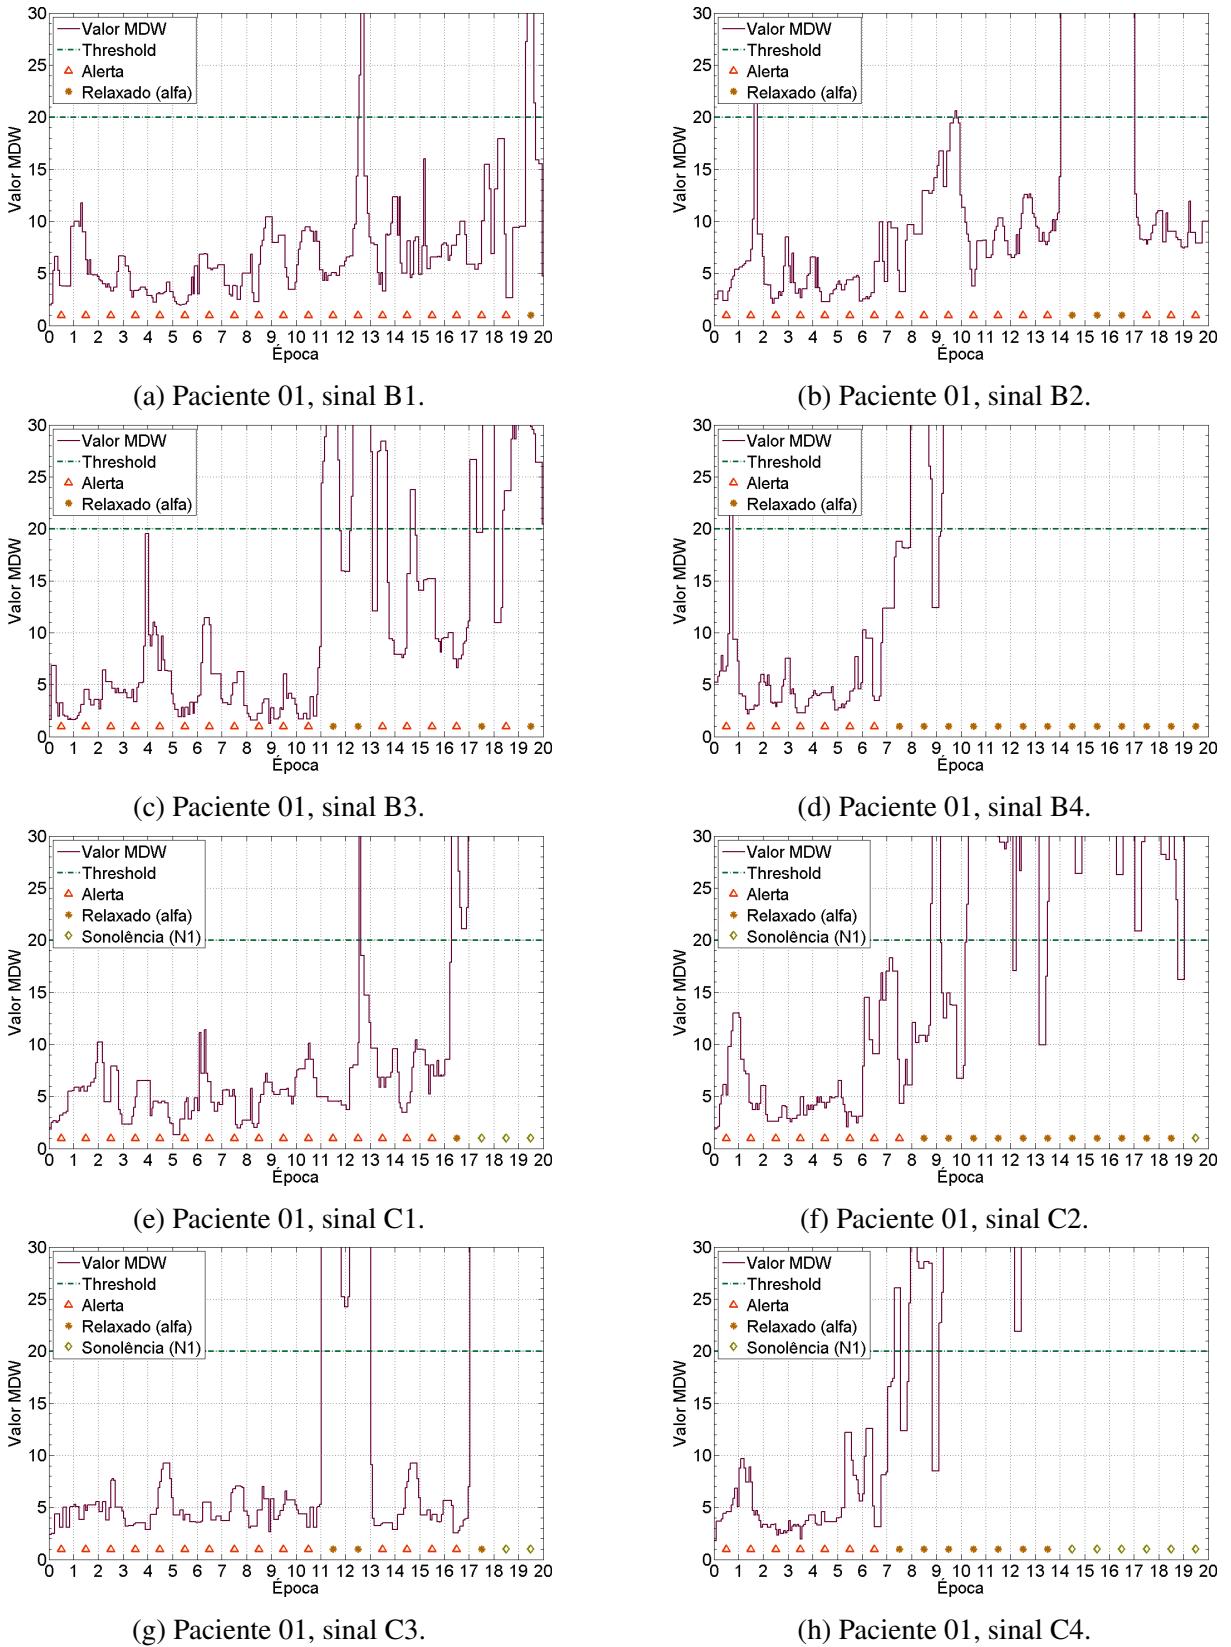


Figura 5.19: Continuação: detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 01. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.

Tabela 5.12: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets no Paciente 01: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.

Paciente 01	Estado Alerta			Sonolência		
	Sinal	Hipnograma	MDW	%	Hipnograma	MDW
A1	20	19	95%	0	0	-
A2	20	16	80%	0	0	-
A3	20	16	80%	0	0	-
A4	20	20	100%	0	0	-
B1	19	18	95%	1	1	100%
B2	17	15	88%	3	3	100%
B3	16	13	81%	4	4	100%
B4	7	6	86%	13	12	92%
C1	16	15	94%	4	4	100%
C2	8	8	100%	12	12	100%
C3	15	15	100%	5	5	100%
C4	7	7	100%	13	13	100%
Total	185	168	91%	55	54	98%

5.4.2 Paciente 02

A classificação da sonolência utilizando a distância de Mahalanobis com coeficientes wavelets, aplicada aos sinais do Paciente 02, tem uma taxa de acerto de 62% para a identificação do estado alerta e de 63% para a detecção da sonolência.

Analisando-se os resultados apresentados na Figura 5.20, para cada sinal, juntamente com os dados expostos na Tabela 5.13, verifica-se um grande número de falso-positivos para o sinal A1 e de falso-negativos para o sinal C1. Contudo, a detecção dos estados alerta e sonolência no sinal C2 ocorre de forma bastante satisfatória, com taxa de acerto de 91% para o estado alerta e de 100% para a sonolência.

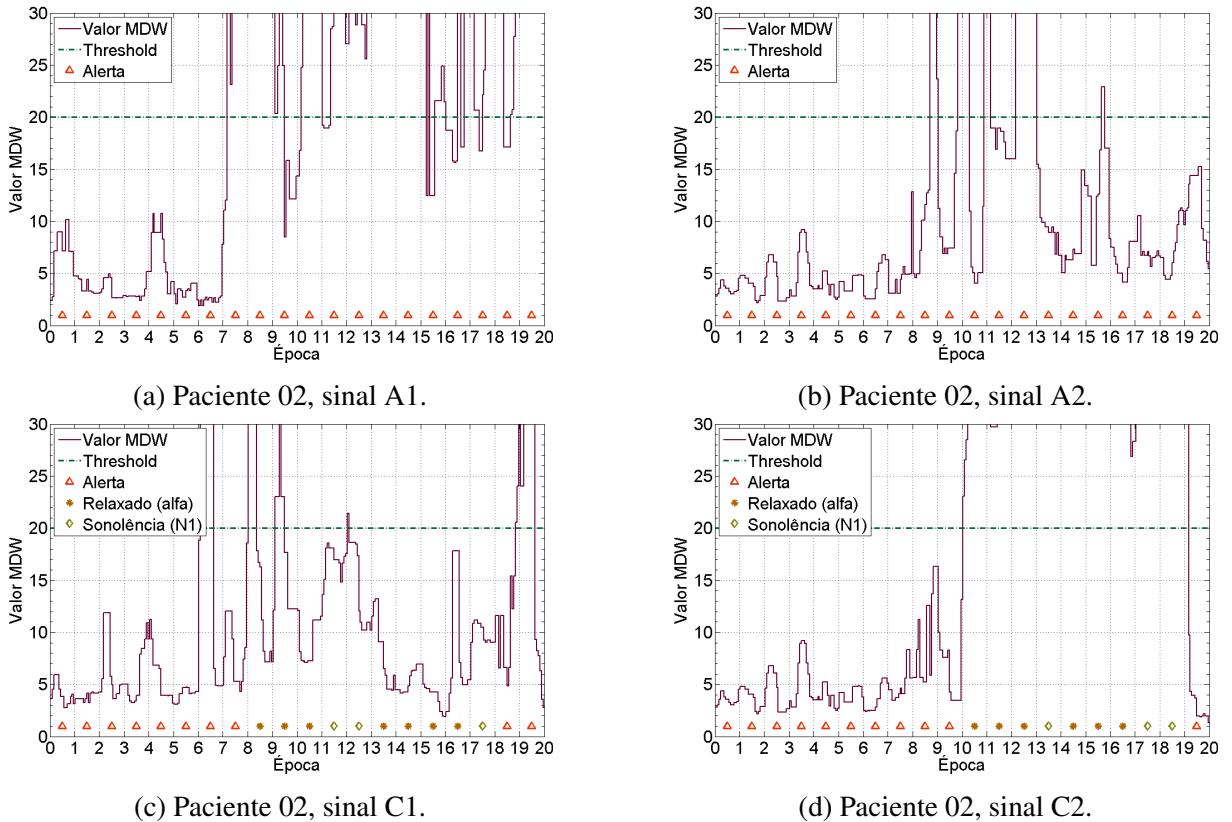


Figura 5.20: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 02. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.

Tabela 5.13: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets no Paciente 02: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.

Paciente 02	Estado Alerta				Sonolência		
	Sinal	Hipnograma	MDW	%	Hipnograma	MDW	%
A1	20	7	35%	0	0	-	
A2	20	14	70%	0	0	-	
C1	10	7	70%	10	3	30%	
C2	11	10	91%	9	9	100%	
Total	61	38	62%	19	12	63%	

5.4.3 Paciente 03

A Figura 5.21 apresenta os resultados da classificação via distância de Mahalanobis para os sinais do Paciente 03. Da Tabela 5.14, verifica-se que o acerto na identificação do estado alerta é de 85%, embora de apenas 36% na detecção da sonolência.

Observa-se, na Figura 5.21(c), que o valor MDW para as épocas correspondentes à sonolência (N1) é distante dos valores correspondentes às épocas em estado alerta. Entretanto, não ultrapassam o valor de *threshold* pré-definido.

Situação semelhante é observada na Figura 5.21(d): embora seja possível diferenciar o valor MDW das épocas 14 a 17, referentes à sonolência, o modelo deve ser ajustado de modo a suprimir os falso-positivos nas épocas em estado alerta.

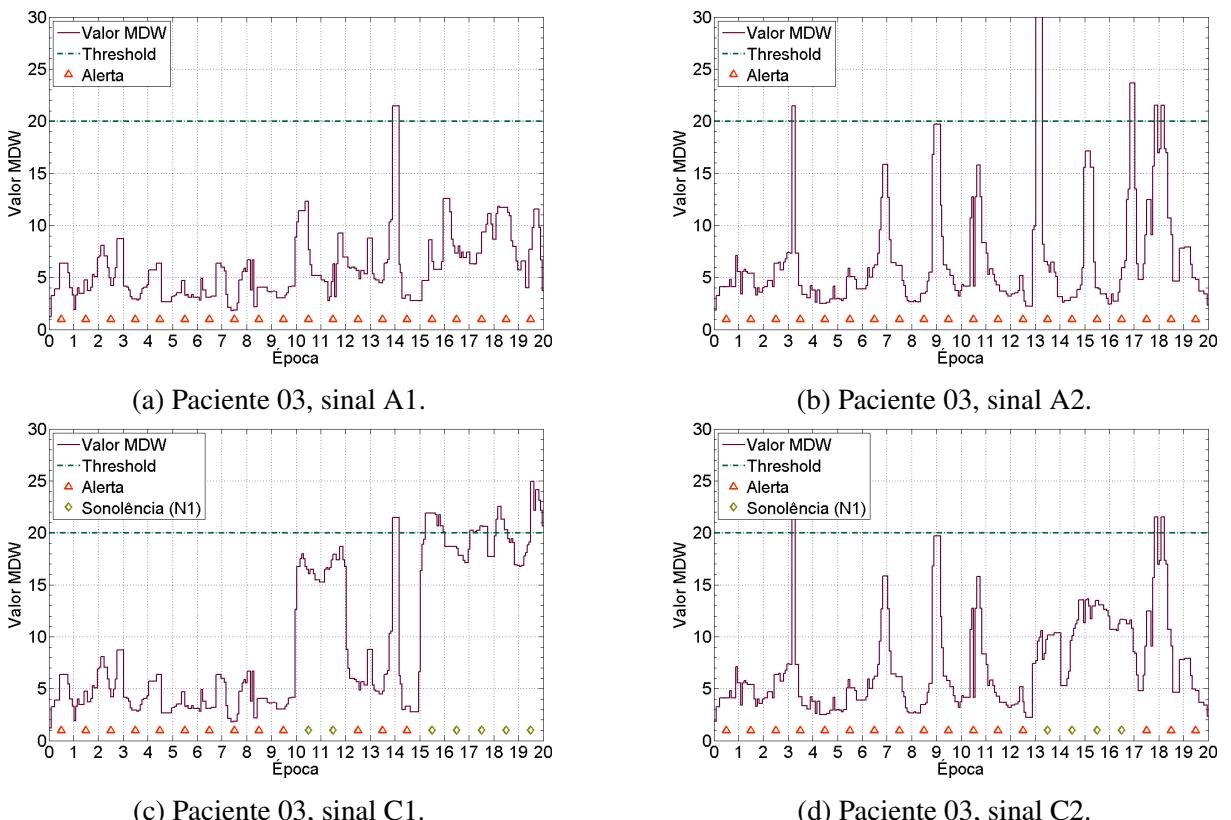


Figura 5.21: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 03. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.

Tabela 5.14: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets no Paciente 03: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.

Paciente 03	Estado Alerta			Sonolência		
	Sinal	Hipnograma	MDW	%	Hipnograma	MDW
A1	20	19	95%	0	0	-
A2	20	15	75%	0	0	-
C1	13	12	92%	7	4	57%
C2	16	13	81%	4	0	0%
Total	69	59	85%	11	4	36%

5.4.4 Paciente 04

As Figuras 5.22 e 5.23 apresentam os resultados da classificação via distância de Mahalanobis utilizando coeficientes wavelets para os diferentes sinais do Paciente 04, divididos nos grupos A, B e C, conforme detalhado na Tabela 5.3.

O resultado desta classificação é sintetizado na Tabela 5.15. Para os sinais do grupo A, o estado alerta é identificado em 96% dos casos. No grupo B, o estado alerta é identificado em 74% das épocas analisadas. Para os sinais do grupo C, o estado alerta é identificado com sucesso em 92% dos casos.

Há, entretanto, um grande número de falso-negativos na detecção da sonolência: no grupo B, apenas o sinal B1 é identificado adequadamente, havendo uma taxa de detecção de 0% para os sinais B2, B3 e B4. O mesmo ocorre para os sinais C1 e C2, do grupo C, onde 0% das épocas de sonolência são identificadas.

Observando-se as Figuras 5.22(f),(g) e 5.23(b), correspondentes aos sinais B2, B3 e C2, respectivamente, é possível distinguir o valor MDW das épocas de sonolência em relação às seis primeiras épocas de cada sinal, embora estes valores não ultrapassem o valor de *threshold* estipulado. Tais resultados, portanto, não inviabilizam o método apresentado, mas sugerem a necessidade de ajustes na extração de características e construção do modelo.

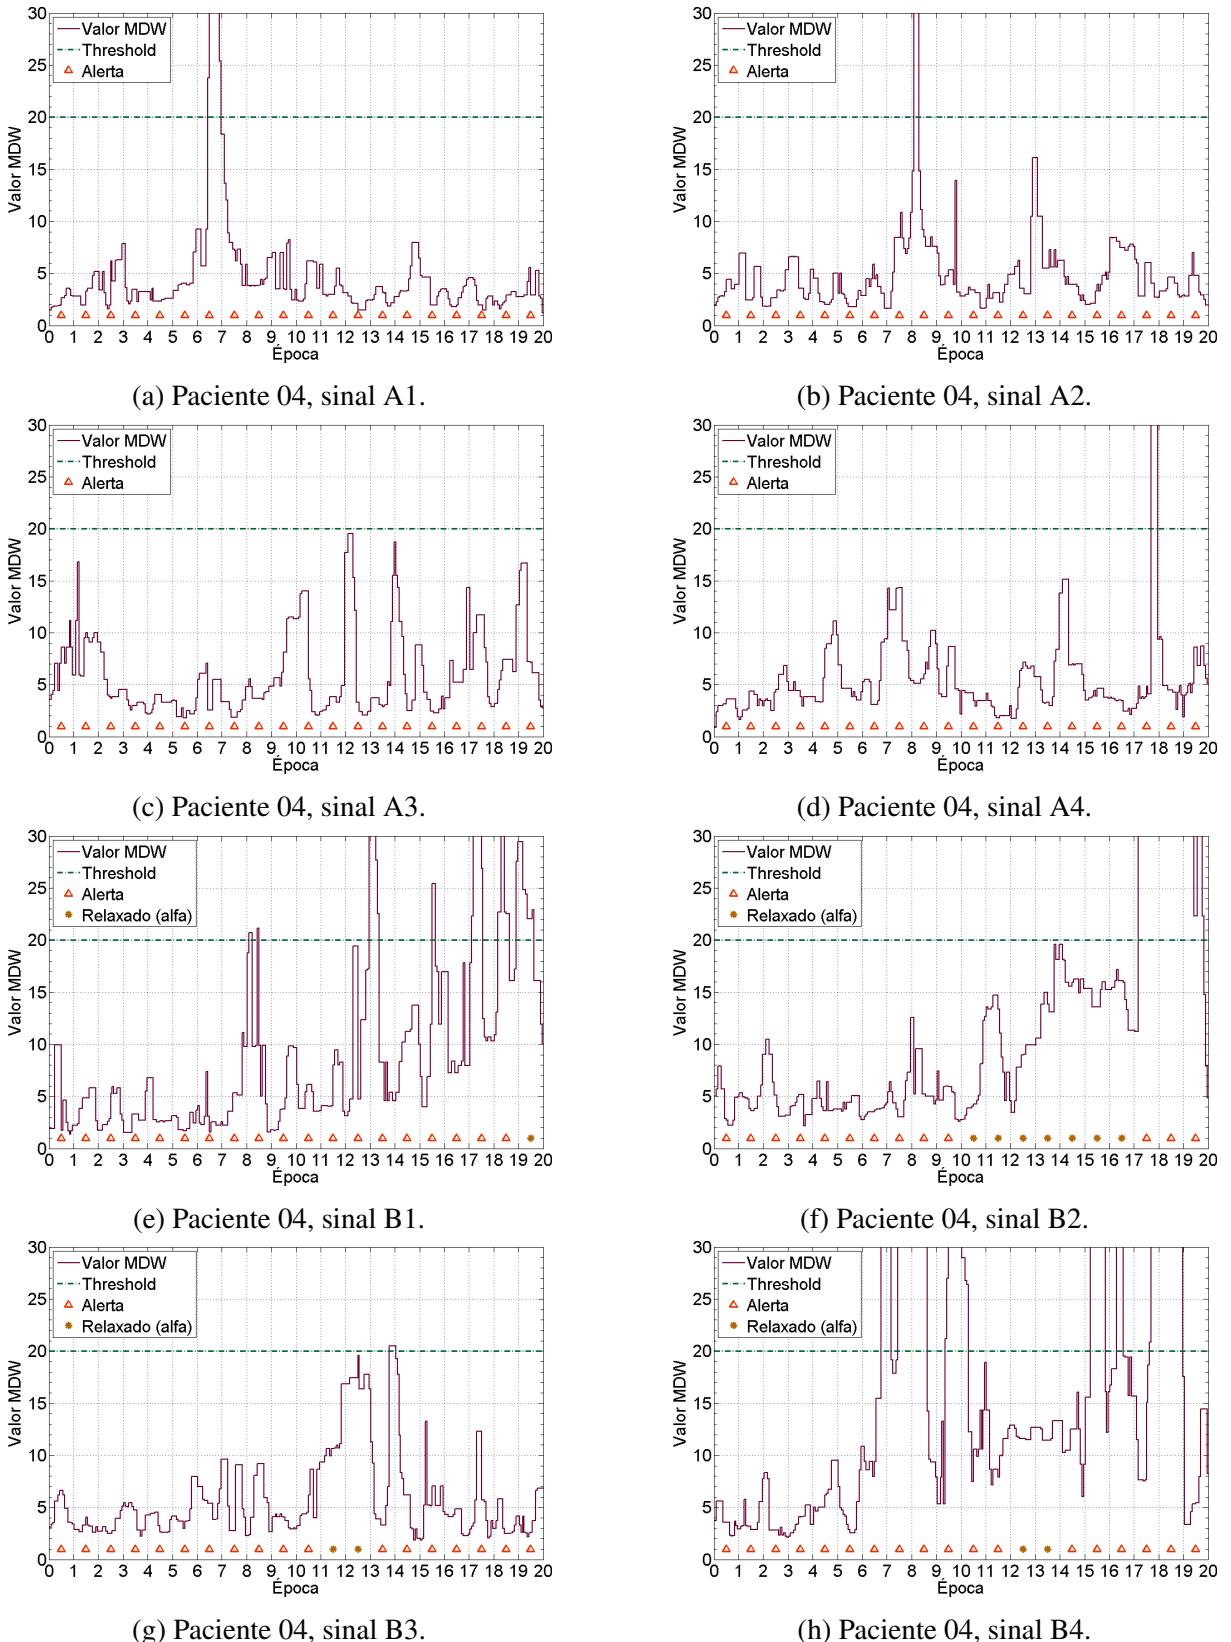


Figura 5.22: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 04. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.

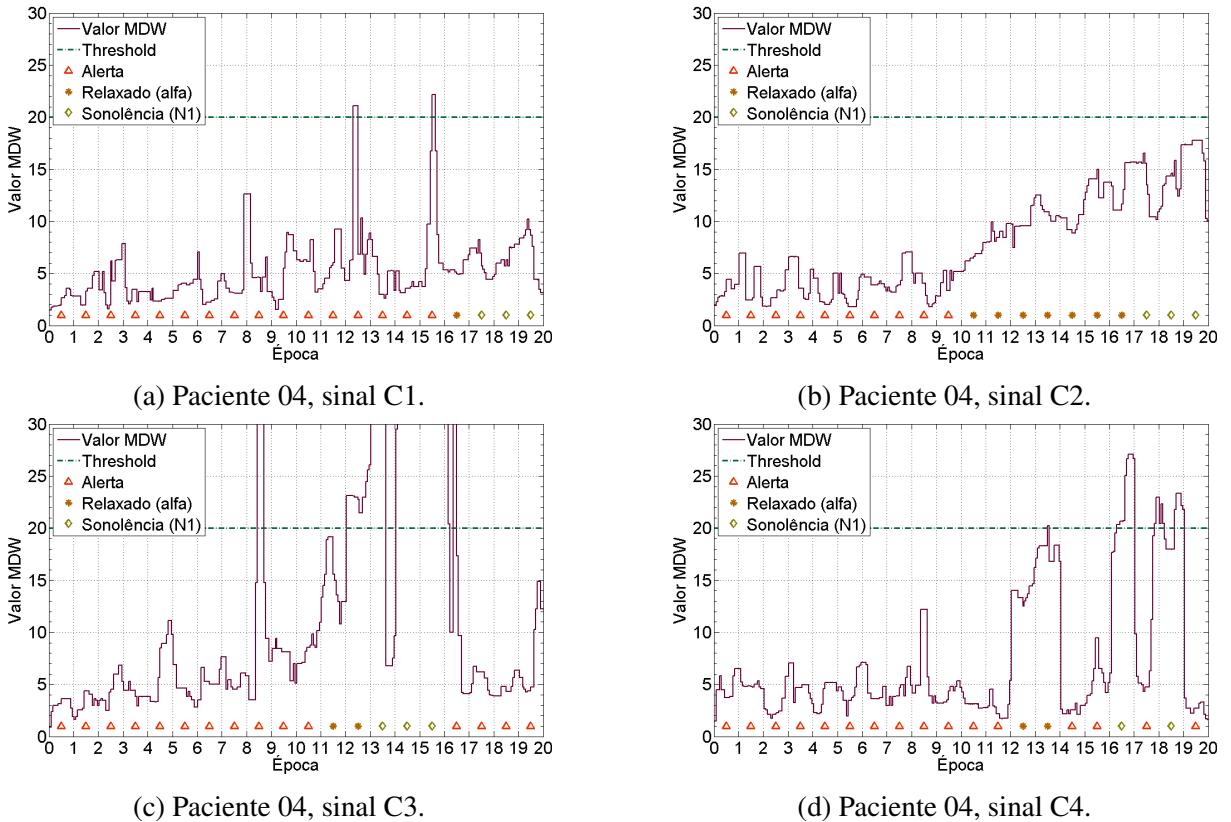


Figura 5.23: Continuação: detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets, para cada sinal selecionado do Paciente 04. A sonolência ocorre quando $MDW > threshold$. A classificação do hipnograma é indicada em cada época.

Tabela 5.15: Detecção da sonolência via distância de Mahalanobis utilizando coeficientes wavelets no Paciente 04: para cada estado e sinal, apresenta-se o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.

Paciente 04	Estado Alerta				Sonolência		
	Sinal	Hipnograma	MDW	%	Hipnograma	MDW	%
A1	20	19	95%	0	0	-	
A2	20	19	95%	0	0	-	
A3	20	20	100%	0	0	-	
A4	20	19	95%	0	0	-	
B1	19	14	74%	1	1	100%	
B2	13	10	77%	7	0	0%	
B3	18	17	94%	2	0	0%	
B4	18	9	50%	2	0	0%	
C1	16	14	87%	4	0	0%	
C2	10	10	100%	10	0	0%	
C3	15	13	87%	5	4	80%	
C4	16	15	94%	4	3	75%	
Total	205	179	87%	35	8	23%	

5.5 Análise comparativa

No decorrer deste capítulo foram apresentados os resultados da detecção de sonolência utilizando as metodologias (i) melhor aproximação por m -termos, (ii) distância de Mahalanobis utilizando coeficientes de Fourier e (iii) distância de Mahalanobis utilizando coeficientes wavelets, aplicadas aos sinais cerebrais de quatro pacientes distintos. Estes resultados estão sintetizados nas Tabelas 5.16, 5.17 e 5.18 para os métodos (i), (ii) e (iii), respectivamente.

Tabela 5.16: Detecção da sonolência via melhor aproximação por m -termos. Para cada paciente, nos estados alerta e de sonolência, é apresentado o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.

Estado	Alerta			Sonolência			
	Paciente	Hipnog.	Melhor Aprox.	%	Hipnog.	Melhor Aprox.	%
01	185	185		100%	55	55	100%
02	61	48		79%	19	19	100%
03	69	69		100%	11	9	82%
04	205	205		100%	35	29	83%
Total	520	507		97.5%	120	112	93%

Tabela 5.17: Detecção da sonolência via distância de Mahalanobis com coeficientes de Fourier. Para cada paciente, nos estados alerta e de sonolência, é apresentado o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.

Estado	Alerta			Sonolência			
	Paciente	Hipnograma	MDC	%	Hipnograma	MDC	%
01	185	182		99%	55	50	91%
02	61	45		74%	19	13	68%
03	69	67		97%	11	8	73%
04	205	194		95%	35	33	94%
Total	520	488		94%	120	104	87%

Tabela 5.18: Detecção da sonolência via distância de Mahalanobis com coeficientes wavelets. Para cada paciente, nos estados alerta e de sonolência, é apresentado o número de épocas identificadas pelo hipnograma, pelo método e a sua respectiva taxa de acerto.

Estado	Alerta			Sonolência			
	Paciente	Hipnograma	MDW	%	Hipnograma	MDW	%
01	185	168		91%	55	54	98%
02	61	38		62%	19	12	63%
03	69	59		85%	11	4	36%
04	205	179		87%	35	8	23%
Total	520	444		85%	120	78	65%

Da análise das Tabelas 5.16, 5.17 e 5.18, observa-se que a metodologia (i) foi a que apresentou o melhor resultado tanto na identificação do estado alerta (97.5%) quanto na detecção da sonolência (93%). Utilizando-se a metodologia (ii), 94% das épocas referentes ao estado alerta foram identificadas, juntamente com 87% das épocas referentes à sonolência. Através da metodologia (iii), este índice foi de 85% na identificação do estado alerta e de 65% na identificação da sonolência.

Através da Tabela 5.19 pode-se analisar o desempenho de cada metodologia na identificação de diferentes tipos de sinais – o Grupo A contém apenas épocas do indivíduo em estado alerta desenvolvendo atividades de concentração; o Grupo B contém épocas do indivíduo em estado alerta, desenvolvendo atividade de concentração, e também relaxado, com componentes no ritmo alfa; o Grupo C contém, além das épocas em estado alerta, épocas caracterizadas como o primeiro estágio do sono, N1.

Da análise conjunta da Tabela 5.19 com os testes realizados na Seção 5.4, verifica-se a capacidade da metodologia (iii) em detectar a sonolência, embora com necessidade de ajustes na etapa de extração de características (para reduzir o número de falsos-positivos) e na determinação do valor de *threshold* (para reduzir o número de falsos-negativos).

Tabela 5.19: Percentual de épocas detectadas por grupo, de acordo com a metodologia utilizada.

Estado	Alerta			Sonolência		
	Método	Grupo A	Grupo B	Grupo C	Grupo A	Grupo B
Melhor aprox.	97%	100%	97%	-	94%	93%
MD + Fourier	92.5%	92%	97%	-	97%	83%
MD + Wavelets	85%	80%	91%	-	64%	65.5%

6 CONCLUSÃO

Este trabalho apresentou a implementação de três metodologias para a detecção da sonolência através do sinal obtido por um único canal de eletroencefalografia: (i) detecção via melhor aproximação por m -termos; (ii) detecção via distância de Mahalanobis utilizando coeficientes de Fourier; e (iii) detecção via distância de Mahalanobis utilizando coeficientes wavelets. As estratégias utilizadas em (i) e (iii) foram originalmente propostas neste estudo. Todas as metodologias foram implementadas através de algoritmos e aplicações desenvolvidos na linguagem C e no ambiente MATLAB®.

Cada uma das metodologias apresentadas foi testada em uma base de dados, tendo como referência o hipnograma classificado por um especialista. Segundo (BLINOWSKA; DURKA, 2006), o critério básico para a aceitação de um método automático na análise de EEG é de que este concorde com a inspeção visual do especialista, demarcada no hipnograma. De acordo com a mesma autora, a concordância entre as classificações realizadas por especialistas é de 87.5%.

Os resultados apresentados no Capítulo 5 demonstram a eficácia das metodologias propostas. Em uma análise qualitativa – utilizando como referência o valor de 87.5%, admitindo-se a divergência de classificações entre os próprios especialistas – a estratégia (i) apresentou o melhor resultado tanto na identificação do estado alerta (97.5%) quanto na identificação da sonolência (93%). A estratégia (ii) apresentou 94% de acerto na identificação do estado alerta e 87% de acerto na identificação da sonolência. A estratégia (iii) não obteve resultados ótimos, identificando 85% das épocas em estado alerta e 65% das épocas de sonolência.

Em relação ao tipo de sinal, as metodologias foram testadas em dois grupos de sinais apresentando sonolência quando: o indivíduo está de olhos fechados e relaxado (sinais do grupo B); o indivíduo está no primeiro estágio do sono (sinais do grupo C). A metodologia (ii) apresentou uma taxa de acerto menor para os sinais do grupo C. As metodologias (i) e (iii) apresentaram taxas de acerto constantes para os sinais dos dois grupos.

De um modo geral, todas as metodologias apresentadas neste estudo mostraram-se capazes de detectar a sonolência. A metodologia (i) obteve uma taxa de acerto maior de 87.5% para todos os tipos de sinais; a metodologia (ii) apresentou melhor taxa de acerto para sinais do grupo B (sonolência caracterizada principalmente pelo ritmo alfa); e a metodologia (iii), que embora não tenha ultrapassado a referência de 87.5% na detecção da sonolência, mostrou-se aplicável ao problema.

6.1 Contribuições ao tema estudado

Vivemos em uma sociedade cujo modo de vida obriga as pessoas a diminuirem cada vez mais sua dedicação ao sono. Segundo (JOHNSON et al., 2011), estudos têm mostrado que determinados níveis de privação de sono, e consequentemente de sonolência diurna, são causas de graves acidentes e têm efeito comparável ao uso abusivo de álcool. Ainda segundo o autor, mesmo tendo conhecimento das consequências da privação de sono na saúde pública e na sociedade em geral, faltam aos governos ferramentas precisas e confiáveis para a medida da sonolência, bem como a determinação exata de quais níveis e condições que apresentam riscos reais para acidentes. Neste contexto, este trabalho deixa sua contribuição ao tema ao introduzir o assunto e propor dois novos métodos para a detecção da sonolência em indivíduos.

6.2 Trabalhos futuros

Como continuação deste estudo, propõe-se:

- Obtenção de uma base de dados com um maior número de sinais característicos, através de convênios com clínicas e institutos de medicina do sono;
- Avaliação dos parâmetros de precisão e sensibilidade das metodologias propostas;
- Ajustes na metodologia utilizando distância de Mahalanobis e coeficientes wavelets, de modo a obter uma heurística com maior precisão na determinação de valores de *threshold*;
- Associação das técnicas apresentadas, visando uma metodologia mais robusta e eficiente;
- Utilização dos algoritmos propostos em sistemas embarcados capazes de detectar a sonolência em motoristas.

REFERÊNCIAS

- ALANI, D.; AVERBUCH, A.; DEKEL, S. Image coding with geometric wavelets. **IEEE transactions on image processing : a publication of the IEEE Signal Processing Society**, [S.l.], v.16, n.1, p.69–77, Jan. 2007.
- BABILONI, F. et al. Mahalanobis distance-based classifiers are able to recognize EEG patterns by using few EEG electrodes. In: ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 2001. PROCEEDINGS OF THE 23RD ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE. Anais... IEEE, 2001. v.1, p.651–654.
- BLINOWSKA, K.; DURKA, P. Electroencephalography (eeg). In: AKAY, M. (Ed.). **Wiley Encyclopedia of Biomedical Engineering**. [S.l.]: John Wiley & Sons, 2006. n.5.
- BOLDRINI, J. L. et al. **Álgebra Linear**. São Paulo: Harbra, 1980.
- BRAZIER, M. A. B. **A History of the Electrical Activity of the Brain. The first Half-Century**. London: Pitman, 1961.
- CARSKADON, M.; RECHTSCHAFFEN, A. Monitoring and staging human sleep. **Principles and practice of sleep medicine**, [S.l.], v.3, p.1359–1377, 2000.
- Clark Jr., J. W. The Origin of Biopotentials. In: WEBSTER, J. G. (Ed.). **Medical Instrumentation**. [S.l.: s.n.], 2010.
- DAUBECHIES, I. **Ten lectures on wavelets**. [S.l.]: Society for industrial and applied mathematics, 1992.
- DAUBECHIES, I. Where do wavelets come from? A personal point of view. **Proceedings of the IEEE**, [S.l.], v.84, n.4, p.510–513, 1996.
- De Maesschalck, R.; JOUAN-RIMBAUD, D.; MASSART, D. The Mahalanobis distance. **Chemometrics and Intelligent Laboratory Systems**, [S.l.], v.50, n.1, p.1–18, Jan. 2000.
- Del Percio, C. et al. Reactivity of alpha rhythms to eyes opening is lower in athletes than non-athletes: a high-resolution eeg study. **International journal of psychophysiology : official journal of the International Organization of Psychophysiology**, [S.l.], v.82, n.3, p.240–7, Dec. 2011.

- DEVORE, R. a. Nonlinear approximation. **Acta Numerica**, [S.l.], v.7, p.51, Nov. 1998.
- DPRF. Departamento da Polícia Rodoviária Federal. <http://www.dprf.gov.br>, [S.l.], 2011.
- EDF+. European Data Format. <http://www.edfplus.info/index.html>, [S.l.], 2011.
- ELMENHORST, E.-M. et al. Partial sleep deprivation: impact on the architecture and quality of sleep. **Sleep medicine**, [S.l.], v.9, n.8, p.840–50, Dec. 2008.
- EOH, H.; CHUNG, M.; KIM, S. Electroencephalographic study of drowsiness in simulated driving with sleep deprivation. **International Journal of Industrial Ergonomics**, [S.l.], v.35, n.4, p.307–320, Apr. 2005.
- FARGE, M. WAVELET TRANSFORMS AND THEIR APPLICATIONS TO TURBULENCE. **Ann. Rev. Fluid Mech.**, [S.l.], n.Holschneider 1991, p.395–457, 1992.
- FIGUEIREDO, D. G. de. **Análise de Fourier e equações diferenciais parciais**. Rio de Janeiro: impa - CNPq, 1987.
- FOURNIER, P.-S.; MONTREUIL, S.; BRUN, J.-P. Fatigue management by truck drivers in real life situations: some suggestions to improve training. **Work Reading Mass**, [S.l.], v.29, n.3, p.213–224, 2007.
- Garces Correa, A.; Laciár Leber, E. An automatic detector of drowsiness based on spectral analysis and wavelet decomposition of EEG records. **Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference**, [S.l.], v.2010, p.1405–8, Jan. 2010.
- HAWKING, S.; MLODINOW, L. **The Grand Design**. [S.l.]: Bantam Books, 2010. 324p. v.46, n.1.
- HAYKIN, S.; Van Veen, B. **Sinais e Sistemas**. [S.l.]: Bookman, 2001. v.2004.
- HOLMSTROM, M. Solving Hyperbolic PDEs Using Interpolating Wavelets. **SIAM Journal on Scientific Computing**, [S.l.], v.21, n.2, p.405, 1999.
- JOHNSON, R. R. et al. Drowsiness/alertness algorithm development and validation using synchronized EEG and cognitive performance to individualize a generalized model. **Biological psychology**, [S.l.], v.87, n.2, p.241–50, May 2011.

- LEE, D.; YAMAMOTO, A. Wavelet analysis: theory and applications. **Hewlett Packard journal**, [S.l.], n.December, p.44–52, 1994.
- LIN, C. et al. A Real-Time Wireless Brain-Computer Interface System for Drowsiness Detection. **and Systems, IEEE**, [S.l.], v.4, n.4, p.214–222, 2010.
- MAHALANOBIS, P. On the generalized distance in statistics. **Proceedings of the National Institute of Sciences of**, [S.l.], 1936.
- MALLAT, S. **A wavelet tour of signal processing**. [S.l.: s.n.], 1998.
- MALMIVUO, J.; PLONSEY, R. **Bioelectromagnetism - Principles and Applications of Bioelectric and Biomagnetic Fields**. New York: Oxford University Press, 1995.
- MARDIA, K. V. Assessment of Multinormality and the Robustness of Hotelling's T2 Test. **Journal of the Royal Statistical Society**, [S.l.], v.24, n.2, p.163–171, 1975.
- MISITI, M.; POGGI, J.-m. **Wavelet Toolbox 4 User s Guide**. 2010.
- MOHLENKAMP, M.; PEREYRA, M. **Wavelets, their friends, and what they can do for you**. [S.l.]: European Mathematical Society, 2008.
- NHTSA. Drowsy Driving and Automobile Crashes. <http://www.nhtsa.gov>, [S.l.], 2012.
- NIELSEN, O. **Wavelets in scientific computing**. 1998. Tese (Doutorado em Ciência da Computação) — Technical University of Denmark.
- NSF. National Sleep Foundation. [DrowsyDriving.org: facts and stats](http://drowsydriving.org/about/facts-and-stats/). <http://drowsydriving.org/about/facts-and-stats/>, [S.l.], 2012.
- PAL, N. R. et al. An EEG-based subject- and session-independent drowsiness detection. **2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)**, [S.l.], n.1, p.3448–3454, June 2008.
- PAPADELIS, C. et al. Indicators of sleepiness in an ambulatory EEG study of night driving. **Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference**, [S.l.], v.1, p.6201–4, Jan. 2006.

- PETRANTONAKIS, P.; HADJILEONTIADIS, L. Emotion recognition from EEG using higher order crossings. **Information Technology in Biomedicine**, [S.l.], v.14, n.2, p.186–197, 2010.
- PICOT, A.; CHARBONNIER, S.; CAPLIER, A. On-Line Detection of Drowsiness Using Brain and Visual Information. **IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans**, [S.l.], p.1–12, 2011.
- REED, M.; SIMON, B. **Functional Analysis**. [S.l.]: Academic Press, 1980.
- RIOUL, O.; VETTERLI, M. Wavelets and signal processing. **Signal Processing Magazine, IEEE**, [S.l.], 1991.
- ROCHA, A. da et al. Processamento de Sinais Biológicos. In: **Informática em Saúde**. Taguatinga: Universa, 2008. p.381–416.
- SANCI, S.; CHAMBERS, J. **EEG Signal Processing**. [S.l.]: John Wiley & Sons, 2007.
- SMITH, S. **Digital Signal Processing: a practical guide for engineers and scientistssmith, s. digital signal processing: a practical guide for engineers and scientists**. [s.l.]: newnes, 2002. p. xiv, 650 p. st - **digital signal processing : a pr.** [S.l.]: Newnes, 2002. xiv, 650 p. ST – Digital signal processing : a prp.
- STOLLNITZ, E. J.; DEROSE, T. D.; SALESIN, D. H. Wavelets for Computer Graphics : a primer. **Computer**, [S.l.], v.15, n.July, 1995.
- STRANG, G.; NGUYEN, T. **Wavelets and filter banks**. [S.l.]: Wellesley-Cambridge, 1996.
- SUBASI, a. Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients. **Expert Systems with Applications**, [S.l.], v.28, n.4, p.701–711, May 2005.
- TEMLYAKOV, V. N. **Nonlinear Methods of Approximation**. [S.l.: s.n.], 2003. 33–107p. v.3, n.1.
- TORRENCE C., C. G. A Practical Guide to Wavelet Analysis. **Bulletin of the American Meteorological Society**, [S.l.], 1998.
- TRUJILLO-ORTIZ, A.; HERNANDEZ-WALLS, R. **Mskekur: mardia's multivariate skewness and kurtosis coefficients and its hypothesis testing. a matlab file**. 2003.

VETTERLI, M.; KOVACEVIC, J. **Wavelets and Subband Coding.** [S.l.]: Prentice Hall, 1995. 981p. n.1987. (Signal Processing Series, v.18).

WILLIAMSON, S. J. et al. Study of human occipital alpha rhythm: the alphon hypothesis and alpha suppression. **International journal of psychophysiology : official journal of the International Organization of Psychophysiology**, [S.l.], v.26, n.1-3, p.63–76, June 1997.

YEO, M. et al. Can SVM be used for automatic EEG detection of drowsiness during car driving? **Safety Science**, [S.l.], v.47, n.1, p.115–124, Jan. 2009.

APÊNDICE A WAVELET DE MEYER

A família de wavelets de Meyer é uma base de funções wavelets ortonormais suaves construídas por Yves Meyer ([LEE; YAMAMOTO, 1994](#)). Primeiramente, define-se a transformada de Fourier $\Phi(\omega)$ da função escala $\phi(t)$:

$$\Phi(\omega) = \begin{cases} 1, & \text{se } |\omega| \leq \frac{2}{3}\pi \\ \cos \left[\frac{\pi}{2}v \left(\frac{3}{4\pi}|\omega| - 1 \right) \right], & \text{se } \frac{2}{3}\pi \leq |\omega| \leq \frac{4}{3}, \\ 0, & \text{caso contrário} \end{cases} \quad (\text{A.1})$$

onde v é uma função suave que satisfaz as seguintes condições:

$$v(t) = \begin{cases} 1, & \text{se } t \geq 1 \\ 0, & \text{se } t \leq 0 \end{cases}. \quad (\text{A.2})$$

A função $v(t)$ possui ainda a seguinte propriedade:

$$v(t) + v(1-t) = 1. \quad (\text{A.3})$$

A função escala $\Phi(\omega)$ está representada na Figura [A.1\(a\)](#). A função wavelet $\psi(t)$ é então obtida a partir de $\Phi(\omega)$. Primeiramente, aplica-se a transformada de Fourier de modo a obter $\Psi(\omega)$:

$$\Psi(\omega) = e^{i\omega/2}[\Phi(\omega + 2\pi) + \Phi(\omega - 2\pi)]\Phi(\omega/2). \quad (\text{A.4})$$

A função $\Psi(\omega)$ está representada na Figura [A.1\(b\)](#). A função $\psi(t)$ está representada na Figura [A.1\(c\)](#).

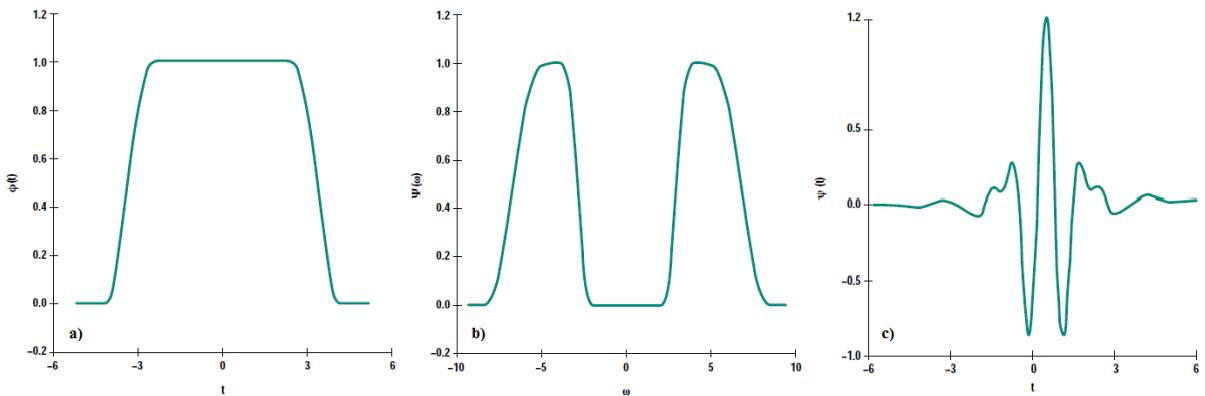


Figura A.1: Wavelet de Meyer. Em (a) transformada de Fourier da função escala da base de Meyer; em (b) transformada de Fourier da wavelet de Meyer; em (c) forma de onda da wavelet de Meyer. Adaptado de ([LEE; YAMAMOTO, 1994](#)).

APÊNDICE B CÓDIGOS FONTE

B.1 Biblioteca para Transformada Wavelet Discreta: tsDWT

Desenvolvida na Linguagem C, implementa as funções necessárias para a decomposição de um sinal através da transformada wavelet discreta, utilizando o algoritmo da transformada wavelet rápida periodizada (Seção 3.4.4). O sinal de entrada deve ser fornecido em um arquivo de texto, onde cada linha representa o valor de uma amostra.

A decomposição da TWD é armazenada em dois vetores de dados distintos: um para os coeficientes de escala e outro para os coeficientes wavelet.

```

/*
UFSM - PPGI - Grupo de Microeletrônica
Autor: Tiago da Silveira
Descrição: Biblioteca de funções em C para operações com transformadas wavelets.

Histórico de versões:
v1.0 - (2010-12-01) Utiliza as funções e estruturas de códigos anteriores para a TWD.
v2.0 - (2011-09-19) Estruturação do arquivo de cabeçalho (ts_dwt.h) e do módulo de
        funções (ts_dwt-impl.h).
*/

int congruente(int div1, int div2){
    return div1 \%div2;
}

void calc_TWD(int nnivel, double *det, double *med){
    /* Calcula a TWD utilizando algoritmo periodizado. (Ver "NIELSEN, O. Wavelets in
       Scientific Computing".
       nnivel = numero de níveis da TWD;
       *det e *med = ponteiros para os vetores de coeficientes de detalhes e medias,
       respectivamente.
    */
    int j;                      // Índice do nível atual, utilizando a notação C_(j,i);
    int i;                      // Índice de translação, utilizando a notação C_j,i
    int k;                      // Índice de filtro;
    int potA, potB;             // Variáveis auxiliares para o cálculo de potência.
    int congr;                  // Variável para o cálculo do congruente

    for (j=nnivel-1;j>=0;j--){
        // Limites para o índice dos coeficiente C_j,i
        // 2^j para localizar os coefs do nível atual
        potA = (int) pow(2,j);
        // 2^(j+1) para localizar os coefs do nível acima e calcular a TWD
        potB = (int) pow(2,j+1);
        for (i=0;i<=(potA-1);i++){
            // Inicializa as posicoes de media e detalhe do nível atual
            med[potA-1+i] = 0;
            det[pota-1+i] = 0;
            for (k=0;k<=(D-1);k++){
                // Congruente para o cálculo de C_j,<2i+k>2^j periodizado.
                congr = congruente((2*i+k+potB),potB);
                med[potA-1+i] = (double) med[potA-1+i] + h[k]*med[potB-1+congr];
                det[potA-1+i] = (double) det[potA-1+i] + g[k]*med[potB-1+congr];
            }
        }
    }
}

void copia_coef(int nnivel,double *coefA, double *coefB){
    /* Função para realizar a cópia de todos os coeficientes C[j,i] do vetor coefA para o
       vetor coefB. */
    int i, imax;                 // Variáveis auxiliares.

```

```

// Número de coeficientes em cada vetor de médias ou detalhes.
imax = (int) (pow(2,nnivel)-2);
for (i=0;i<=imax;i++) {
    coefB[i] = coefA[i];
}
}

void calc_inv(int nnivel, int invNivel, double *det, double *med, char *titulo){
/* Ver algoritmo da TW Inversa na tese de Nielsen, p.54 */
int j;                                // Índice do nível atual, utilizando a notação C_(j,i);
int i;                                // Índice de translação, utilizando a notação C_(j,i)
int n, n1, n2;                          // Índices do somatório do cálculo da inversa
int potA;                             // Número de elementos em cada nível, potA = 2^j
int potB;                             // Número de elementos em um nível anterior, potB = 2^(j-1)

// Verifica se invNivel é menor que o número de níveis possíveis
if ((nnivel<=invNivel)|(invNivel<0)) {
    printf("\nNível para iniciar a TWI maior que o numero de niveis existente ou
menor que zero!");
    //return NULL;
    exit(1);
}
// Inversa a partir do nível escolhido (invNivel) até o nível máximo (nnivel)
for (j=invNivel+1;j<=nnivel;j++){
    // Cálculo de 2^j, necessário à indexação dos elementos de cada nível
    potA = (int) pow(2,j);
    // Cálculo de 2^(j-1), necessário ao cálculo dos coeficientes
    potB = (int) pow(2,j-1);
    for (i=0;i<=(potA-1);i++){ // Cálculo dos coeficientes C_(j,i), onde i = [0,potA-1]
        med[potA-1+i] = 0;      // Inicialização do valor da inversa
        // Limites do somatório para determinação dos coeficientes C_(j,i)
        // A função ceil(double arg) retorna o menor inteiro MAIOR que arg
        n1 = ceil((i-D+1)/2.0);
        // A função floor(double arg) retorna o maior inteiro MENOR que arg
        n2 = floor((i/2.0));
        for (n=n1;n<=n2;n++){
            med[potA-1+i] = (double) med[potA-1+i] +
            med[potB-1+congruente(n+potB,potB)]*h[i-2*n] +
            det[potB-1+congruente(n+potB,potB)]*g[i-2*n];
        }
    }
}
}

void grava_nivel(int nnivel, double *det, double *med, char *prefixo){
/* Grava os valores intermediarios de cada nível em arquivos ASCII na forma
"prefixo_nivel.med" e "prefixo_nivel.dif" */
FILE *saidaDet, *saidaMed;
char bufferDet[99], bufferMed[99];
int lim1, lim2;                         // Variáveis auxiliares para o cálculo de potência.
int i,j;                                // Variável auxiliar para o cálculo do coeficiente C_j,i

for (j=nnivel-1;j>=0;j--){
    // Gravação dos arquivos de saída para o knivel.
    sprintf(bufferDet, "%s_\%d.dif",prefixo,j);
    sprintf(bufferMed, "%s_\%d.med",prefixo,j);
    //sprintf(bufferMed, "%d.med",j);
    if ((saidaDet = fopen(bufferDet,"w")) == NULL) {
        printf("Erro na abertura do arquivo de saída para diferenças.");
        exit(1);
    }
    if ((saidaMed = fopen(bufferMed,"w")) == NULL) {
        printf("Erro na abertura do arquivo de saída para médias.");
        exit(1);
    }
    lim1 = (int) (pow(2,j)-1);
    lim2 = (int) (pow(2,j+1)-2);
    for (i=lim1;i<=lim2;i++) {
        fprintf(saidaDet,"%e\n",det[i]);
        fprintf(saidaMed,"%e\n",med[i]);
    }
    fclose(saidaDet);
    fclose(saidaMed);
}

```

```

    }

}

void grava_saida(int nnivel, double *det, double *med, char *prefixo){
/* Grava todos os valores dos coeficientes em arquivos ASCII na forma:
   "prefixo_result.med", "prefixo_result.dif" e "prefixo_inversa.txt".
   Este último contendo o sinal recuperado.
*/
FILE *saidaDet, *saidaMed, *saidaInv;
/* Buffer para nome dos arquivos de saída. Desabilitar função quando utilizar
   em sistemas embarcados. */
char bufferDet[99], bufferMed[99], bufferInv[99];
int i, imax; // Variáveis auxiliares.
// Variáveis para localizar a inversa do último nível para gravá-lo na saída de dados.
int lim1, lim2;

sprintf(bufferDet, "%s_result.dif", prefixo);
sprintf(bufferMed, "%s_result.med", prefixo);
sprintf(bufferInv, "%s_inversa.txt", prefixo);
// Gravação dos valores no arquivo de saída
if ((saidaDet = fopen(bufferDet, "w")) == NULL) {
    printf("Erro na abertura do arquivo de saída final para detalhes.");
    exit(1);
}
if ((saidaMed = fopen(bufferMed, "w")) == NULL) {
    printf("Erro na abertura do arquivo de saída final para medias.");
    exit(1);
}
if ((saidaInv = fopen(bufferInv, "w")) == NULL) {
    printf("Erro na abertura do arquivo de saída para a inversa.");
    exit(1);
}

// Número de coeficientes em cada vetor de médias ou detalhes.
imax = (int) (pow(2, nnivel)-2);
for (i=0;i<=imax;i++) {
    fprintf(saidaDet, "%.16e\n", det[i]);
    fprintf(saidaMed, "%.16e\n", med[i]);
}
/* O tamanho do vetor inversa é igual ao número de amostras, portanto [0:2^nnivel-1].
   Assim, é adicionado 1 a imax. */
lim1 = (int) (pow(2, nnivel)-1);
lim2 = (int) (pow(2, nnivel+1)-2);
for (i=lim1;i<=lim2;i++) {
    fprintf(saidaInv, "%.16e\n", med[i]);
    // Para maior precisão na saída, utilizar "%.16e"
}
fclose(saidaDet);
fclose(saidaMed);
fclose(saidaInv);
}

void grava_saidaCoefs(int amostras, struct coeftw *coefs){
FILE *saidaCoefsValor, *saidaCoefsPos;
int i, imax; // Variáveis auxiliares.
int lim1, lim2;
// Gravação dos valores no arquivo de saída
if ((saidaCoefsValor = fopen("BestRepresent_valor.txt", "w")) == NULL) {
    printf("Erro na abertura do arquivo de saída final para Coefs_valor.");
    exit(1);
}
if ((saidaCoefsPos = fopen("BestRepresent_pos.txt", "w")) == NULL) {
    printf("Erro na abertura do arquivo de saída final para Coefs_pos.");
    exit(1);
}
for (i=0;i<amostras;i++) {
    fprintf(saidaCoefsValor, "%.16e\n", coefs[i].valor);
    fprintf(saidaCoefsPos, "%d\n", coefs[i].pos);
}
fclose(saidaCoefsValor);
fclose(saidaCoefsPos);
}

```

B.2 Bancos de filtros

Valores dos coeficientes de filtros para algumas wavelets ortonormais de suporte compacto de Daubechies ([DAUBECHIES, 1992](#)).

B.2.1 Wavelet DB1 (Haar)

```
/*
UFSM - PPGI - Grupo de Microeletrônica
Autor: Tiago da Silveira
Descrição: Biblioteca contendo os filtros wavelet Haar (ou DB1).
Arquivo: waveletDB1.h
*/

// Teste para inclusão do arquivo de cabeçalho na compilação uma única vez.
#ifndef WAVELETDB1_H
#define WAVELETDB1_H

#define D 2           // Número de filtros da função wavelet utilizada.

/* Filtros de Haar      */
static double h[2]={0.7071067811865475, 0.7071067811865475};
static double g[2]={0.7071067811865475,-0.7071067811865475};

#endif
```

B.2.2 Wavelet DB2

```
/*
UFSM - PPGI - Grupo de Microeletrônica
Autor: Tiago da Silveira
Descrição: Biblioteca contendo os filtros wavelet DB2.
Arquivo: waveletDB2.h
*/

#ifndef WAVELETDB2_H
#define WAVELETDB2_H

#define D 4           // Número de filtros da função wavelet utilizada.

/* Filtros da Wavelet Daubechies com 2 momentos nulos - DB2      */
static double h[4] = {0.4829629131445341, 0.8365163037378077,
0.2241438680420134, -0.1294095225512603};
static double g[4] = {-0.1294095225512603, -0.2241438680420134,
0.8365163037378077, -0.4829629131445341};

#endif
```

B.2.3 Wavelet DB3

```
/*
UFSM - PPGI - Grupo de Microeletrônica
Autor: Tiago da Silveira
Descrição: Biblioteca contendo os filtros wavelet DB3.
Arquivo: waveletDB3.h
*/

#ifndef WAVELETDB3_H
#define WAVELETDB3_H

#define D 6           // Número de filtros da função wavelet utilizada.

/* Filtros da Wavelet Daubechies com 3 momentos nulos - DB3      */
static double h[6] = {0.3326705529500825, 0.8068915093110924, 0.4598775021184914,
-0.1350110200102546,-0.0854412738820267, 0.0352262918857095};
static double g[6] = {0.0352262918857095, 0.0854412738820267, -0.1350110200102546,
-0.4598775021184914,0.8068915093110924, -0.3326705529500825};

#endif
```

B.2.4 Wavelet DB4

```
/*
UFSM - PPGI - Grupo de Microeletrônica
Autor: Tiago da Silveira
Descrição: Biblioteca contendo os filtros wavelet DB4.
Arquivo: waveletDB4.h
*/

#ifndef WAVELETDB4_H
#define WAVELETDB4_H

#define D 8           // Número de filtros da função wavelet utilizada.

/* Filtros da Wavelet Daubechies com 4 momentos nulos - DB4 */
static double h[8] = {0.2303778133088964, 0.7148465705529154, 0.6308807679398587,
-0.0279837694168599, -0.1870348117190931, 0.0308413818355607,
0.0328830116668852, -0.0105974017850690};
static double g[8] = {-0.0105974017850690, -0.0328830116668852, 0.0308413818355607,
0.1870348117190931, -0.0279837694168599, -0.6308807679398587,
0.7148465705529154, -0.2303778133088964};

#endif
```

APÊNDICE C SELEÇÃO DOS SINAIS DA BASE DE DADOS PHYSIONET

Os sinais de teste foram selecionados da base de dados PhysioNet através do aplicativo *HipnoWave* desenvolvido em Matlab, cuja interface gráfica é mostrada na Figura C.1. Através do aplicativo, é possível analisar todas as épocas de um sinal de EEG no formato EDF. Uma vez definidas a frequência de amostragem e a duração (em segundos) de cada época, visualiza-se na tela a forma de onda do sinal de EEG; o hipnograma correspondente às épocas mostradas e o respectivo espectrograma. Ainda, é possível aplicar o teste de Mardia às 6 primeiras épocas, verificando assim se a seleção é um modelo aplicável ao Algoritmo 2.

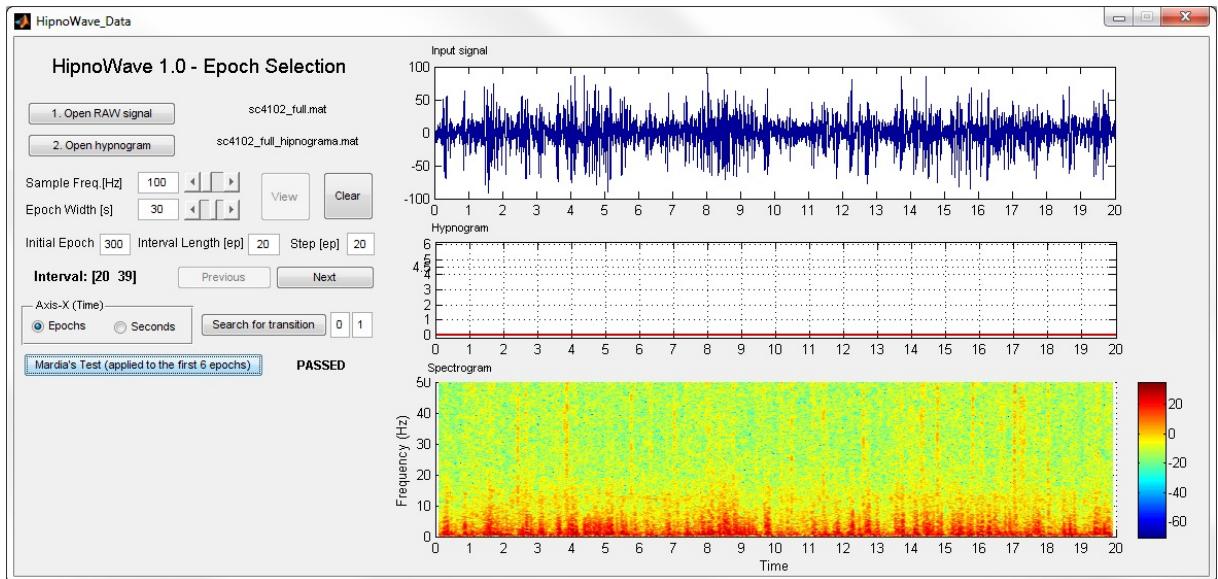


Figura C.1: Interface gráfica desenvolvida em Matlab para seleção de épocas em um sinal cerebral no formato de arquivo EDF.

As Figuras C.2 apresenta a relação entre a base de dados da PhysioNet e os sinais que compõem a base de treinamento, utilizada na Seção 4.2.2. A Figura C.3 apresenta as épocas que constituem a base de testes do Paciente 01, relacionado ao paciente *sc4002* da PhysioNet. A Figura C.4 apresenta as épocas que constituem a base de testes dos Pacientes 02 e 03, relativos aos pacientes *sc4012* e *sc4102*, respectivamente. A Figura C.5 apresenta as épocas que constituem a base de testes do Paciente 04, relacionado ao paciente *sc4112* da PhysioNet.

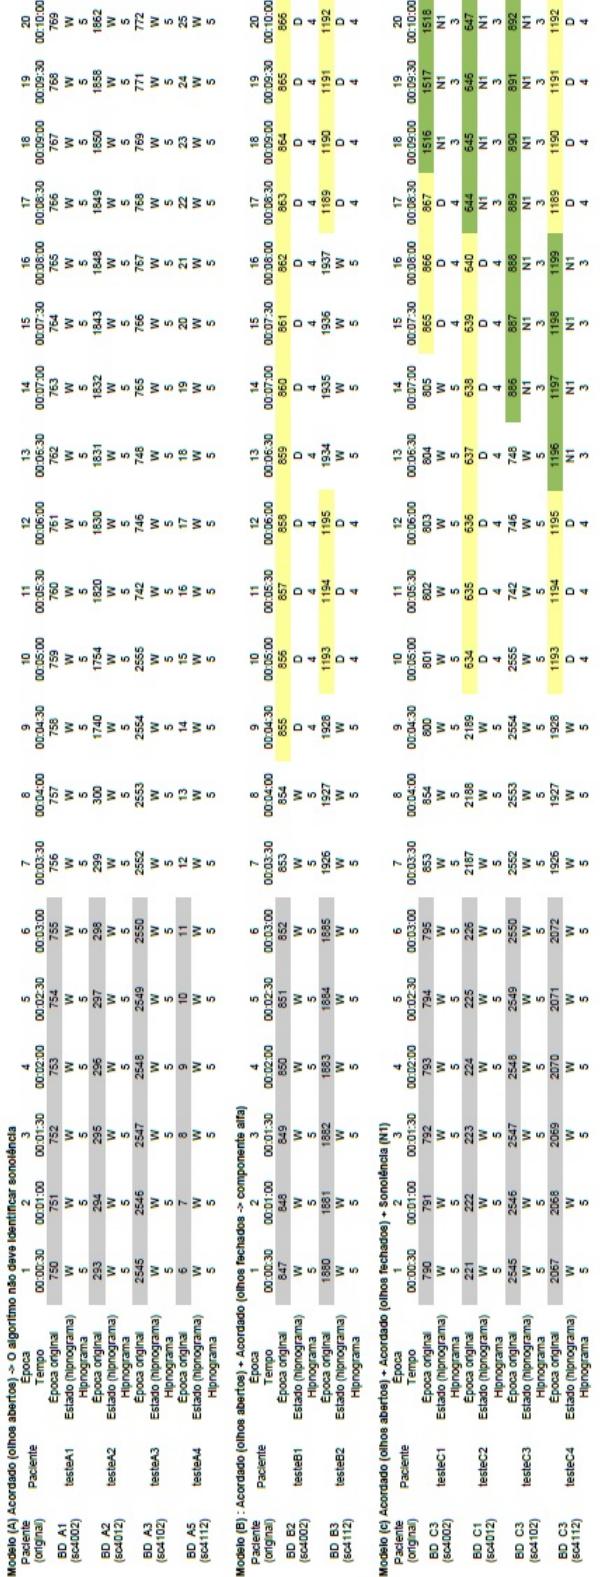


Figura C.2: Base de treinamento: relação com as épocas da base PhysioNet.

Modelo (A) Acordado (olhos abertos) -> O algoritmo não deve identificar sonolência																		
Paciente	sc04002	sc0022	BD_A2	01_A1	BD_A3	01_A2	BD_A4	01_A3	BD_A5	01_A4	BD_B1	01_B1	BD_B3	01_B2	BD_B4	01_B3	BD_B5	01_B4
Epoch	00:00:30	00:01:00	00:01:30	00:02:00	00:02:30	00:03:00	00:03:30	00:04:00	00:04:30	00:05:00	00:05:30	00:06:00	00:06:30	00:07:00	00:07:30	00:08:00	00:08:30	
Tempo	785	786	787	788	789	790	791	792	793	794	795	796	797	798	799	800	801	802
Histograma	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Estatística (Histograma)	790	791	792	793	794	795	796	797	798	799	800	801	802	803	804	805	806	807
Epoch original	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Histograma	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Epoch original	800	801	802	803	804	805	806	807	808	809	810	811	812	813	814	815	816	817
Estatística (Histograma)	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Histograma	805	806	807	808	809	810	811	812	813	814	815	816	817	818	819	820	821	822
Epoch original	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Estatística (Histograma)	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Epoch original	825	826	827	828	829	830	831	832	833	834	835	836	837	838	839	840	841	842
Histograma	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Estatística (Histograma)	843	844	845	846	847	848	849	850	851	852	853	854	855	856	857	858	859	860
Epoch original	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Histograma	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Epoch original	848	849	850	851	852	853	854	855	856	857	858	859	860	861	862	863	864	865
Estatística (Histograma)	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Histograma	865	866	867	868	869	870	871	872	873	874	875	876	877	878	879	880	881	882
Epoch original	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Estatística (Histograma)	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Epoch original	885	886	887	888	889	890	891	892	893	894	895	896	897	898	899	900	901	902
Histograma	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Histograma	905	906	907	908	909	910	911	912	913	914	915	916	917	918	919	920	921	922
Epoch original	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Estatística (Histograma)	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Epoch original	925	926	927	928	929	930	931	932	933	934	935	936	937	938	939	940	941	942
Histograma	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Histograma	945	946	947	948	949	950	951	952	953	954	955	956	957	958	959	960	961	962
Epoch original	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Estatística (Histograma)	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Epoch original	965	966	967	968	969	970	971	972	973	974	975	976	977	978	979	980	981	982
Histograma	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Histograma	985	986	987	988	989	990	991	992	993	994	995	996	997	998	999	1000	1001	1002

Modelo (B) Acordado (olhos abertos) + Acordado (olhos fechados -> componentealfa)																		
Paciente	sc04002	sc0022	BD_B1	01_B1	BD_B3	01_B2	BD_B4	01_B3	BD_B5	01_B4								
Epoch	00:00:30	00:01:00	00:01:30	00:02:00	00:02:30	00:03:00	00:03:30	00:04:00	00:04:30	00:05:00	00:05:30	00:06:00	00:06:30	00:07:00	00:07:30	00:08:00	00:08:30	00:09:00
Tempo	835	837	838	839	840	841	842	843	844	845	846	847	848	849	850	851	852	853
Histograma	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Estatística (Histograma)	845	846	847	848	849	850	851	852	853	854	855	856	857	858	859	860	861	862
Epoch original	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Histograma	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Epoch original	855	856	857	858	859	860	861	862	863	864	865	866	867	868	869	870	871	872
Histograma	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Histograma	875	876	877	878	879	880	881	882	883	884	885	886	887	888	889	890	891	892
Epoch original	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Estatística (Histograma)	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Epoch original	895	896	897	898	899	900	901	902	903	904	905	906	907	908	909	910	911	912
Histograma	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Histograma	915	916	917	918	919	920	921	922	923	924	925	926	927	928	929	930	931	932
Epoch original	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Estatística (Histograma)	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Epoch original	935	936	937	938	939	940	941	942	943	944	945	946	947	948	949	950	951	952
Histograma	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Histograma	955	956	957	958	959	960	961	962	963	964	965	966	967	968	969	970	971	972
Epoch original	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Estatística (Histograma)	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Epoch original	975	976	977	978	979	980	981	982	983	984	985	986	987	988	989	990	991	992
Histograma	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W	W
Epoch original	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Histograma	995	996	997	998	999	1000	1001	1002	1003	1004	1005	1006	1007	1008	1009	1010	1011	1012

Modelo (C) Acordado (olhos abertos) + Acordado (olhos fechados) + Sonolência (N1)														
Paciente	sc04002	sc0022	BD_C1	01_C1	BD_C2	01_C2	BD_C4	01_C3	BD_C5	01_C4				

<tbl_r cells="

Modelo (A) Acordado (olhos abertos) -> O algoritmo não deve identificar sonolência											
Paciente	Época	Tempo	00:00:30	00:01:00	00:01:30	00:02:00	00:02:30	00:03:00	00:03:30	00:04:00	00:04:30
sc012											
02_A1	Época original	W	221	222	223	224	225	226	227	1165	1166
	Estado (Hipnograma)									W	W
02_A2	Época original	W	2348	2349	2350	2351	2352	2353	2354	5	5
	Estado (Hipnograma)									W	W
	Hipnograma		5	5	5	5	5	5	5	5	5
Modelo (C) Acordado (olhos abertos) + Acordado (olhos fechados) - Sonolência (N1)											
Paciente	Época	Tempo	00:00:30	00:01:00	00:01:30	00:02:00	00:02:30	00:03:00	00:03:30	00:04:00	00:04:30
sc4012											
02_C1	Época original	W	2322	2323	2324	2325	2326	2327	2328	1910	1911
	Estado (Hipnograma)									W	W
02_C2	Época original	W	2348	2349	2350	2351	2352	2353	2354	5	5
	Estado (Hipnograma)									W	W
	Hipnograma		5	5	5	5	5	5	5	5	5
Modelo (A) Acordado (olhos abertos) -> O algoritmo não deve identificar sonolência											
Paciente	Época	Tempo	00:00:30	00:01:00	00:01:30	00:02:00	00:02:30	00:03:00	00:03:30	00:04:00	00:04:30
sc4102											
03_A1	Época original	W	293	294	295	296	297	298	299	300	301
	Estado (Hipnograma)									W	W
03_A2	Época original	W	2527	2528	2529	2530	2531	2532	2533	2534	2535
	Estado (Hipnograma)									W	W
	Hipnograma		5	5	5	5	5	5	5	5	5
Modelo (C) Acordado (olhos abertos) + Acordado (olhos fechados) - Sonolência (N1)											
Paciente	Época	Tempo	00:00:30	00:01:00	00:01:30	00:02:00	00:02:30	00:03:00	00:03:30	00:04:00	00:04:30
sc4102											
03_C1	Época original	W	293	294	295	296	297	298	299	300	301
	Estado (Hipnograma)									W	W
03_C2	Época original	W	2527	2528	2529	2530	2531	2532	2533	2534	2535
	Estado (Hipnograma)									W	W
	Hipnograma		5	5	5	5	5	5	5	5	5

Figura C.4: Base de testes, Pacientes 02 e 03: relação com as épocas da base PhysioNet.

Modelo (A) Acordado (olhos abertos) -> O algoritmo não deve identificar sono/sonolência											
Paciente	Época	1	2	3	4	5	6	7	8	9	10
564112	Tempo	00:00:30	00:01:00	00:01:30	00:02:00	00:02:30	00:03:00	00:03:30	00:04:00	00:04:30	00:05:00
BD A1	Época original	1970	1971	1972	1973	1974	1975	1976	1977	1978	1980
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	5	5
BD A2	Época original	1982	1983	1984	1985	1986	1987	1988	1989	1989	1989
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	5	5
BD A3	Época original	2007	2008	2009	2010	2011	2012	2013	2014	2015	2015
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	5	5
BD A4	Época original	2059	2100	2101	2102	2103	2104	2105	2106	2107	2108
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	5	5
Modelo (B) : Acordado (olhos fechados) -> componente alta											
Paciente	Época	1	2	3	4	5	6	7	8	9	10
564112	Tempo	00:00:30	00:01:00	00:01:30	00:02:00	00:02:30	00:03:00	00:03:30	00:04:00	00:04:30	00:05:00
BD B1	Época original	1124	1125	1126	1127	1128	1129	1130	1131	1132	1133
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	5	5
BD B2	Época original	1179	1180	1181	1182	1183	1184	1185	1186	1187	1188
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	4	4
BD B4	Época original	1920	1921	1922	1923	1924	1925	1926	1927	1928	1929
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	4	4
BD B5	Época original	1140	1141	1142	1143	1144	1145	12	13	14	15
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	5	5
Modelo (C) Acordado (olhos abertos) + Acordado (olhos fechados) -> Sonolência [N1]											
Paciente	Época	1	2	3	4	5	6	7	8	9	10
564112	Tempo	00:00:30	00:01:00	00:01:30	00:02:00	00:02:30	00:03:00	00:03:30	00:04:00	00:04:30	00:05:00
BD C1	Época original	1970	1971	1972	1973	1974	1975	1976	1977	1978	1980
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	5	5
BD C2	Época original	1982	1983	1984	1985	1986	1987	1988	1989	1990	1992
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	5	5
BD C4	Época original	2059	2100	2101	2102	2103	2104	2105	2106	2107	2108
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	5	5
BD C5	Época original	6	7	8	9	10	11	12	13	14	15
	Estado (hipnograma)	W	W	W	W	W	W	W	W	W	W
	Hipnograma	5	5	5	5	5	5	5	5	5	5

Figura C.5: Base de testes, Paciente 04: relação com as épocas da base PhysioNet.

APÊNDICE D RESUMOS ACEITOS PARA PUBLICAÇÃO

SILVEIRA, T.; FONSECA, J.M.; MORA, A.D.; KOZAKEVICIUS, A.J.. Uma proposta de segmentação de imagens de bactérias *Eschirichia Coli* obtidas por microscopia de fluorescência. In: CNMAC 2012 - XXXIV Congresso Nacional de Matemática Aplicada e Computacional, 2012. Águas de Lindóia - Brasil. Manuscrito aceito para publicação. 17-21 Setembro 2012.

SILVEIRA, T.; KOZAKEVICIUS, A.J.; RODRIGUES, C.R.. Uma caracterização da sonolência via um único canal de eletroencefalografia através da transformada wavelet discreta. In: CNMAC 2012 - XXXIV Congresso Nacional de Matemática Aplicada e Computacional, 2012. Águas de Lindóia - Brasil. Manuscrito aceito para publicação. 17-21 Setembro 2012.