

GEORGE ARAÚJO MENDONÇA

**ESTUDO COMPARATIVO DE TÉCNICAS DE
REDES NEURAIS E ANÁLISE DE VARIÁVEIS
CANÔNICAS PARA DETECÇÃO AUTOMÁTICA DE
COMPLEXOS K E FUSOS DO SONO EM EEG**

**FLORIANÓPOLIS
2007**

UNIVERSIDADE FEDERAL DE SANTA CATARINA

**PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA**

**ESTUDO COMPARATIVO DE TÉCNICAS DE
REDES NEURAIS E ANÁLISE DE VARIÁVEIS
CANÔNICAS PARA DETECÇÃO AUTOMÁTICA DE
COMPLEXOS K E FUSOS DO SONO EM EEG**

Dissertação submetida à
Universidade Federal de Santa Catarina
como parte dos requisitos para a
obtenção do grau de Mestre em Engenharia Elétrica.

GEORGE ARAÚJO MENDONÇA

Florianópolis, Junho de 2007.

ESTUDO COMPARATIVO DE TÉCNICAS DE REDES NEURAIS E ANÁLISE DE VARIÁVEIS CANÔNICAS PARA DETECÇÃO AUTOMÁTICA DE COMPLEXOS K E FUSOS DO SONO EM EEG

George Araújo Mendonça

‘Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Engenharia Elétrica, Área de Concentração em *Processamento de Sinais Biomédicos*, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina.’

Prof. Fernando Mendes de Azevedo, D. Sc.
Orientador

Prof^a. Kátia Campos de Almeida, Ph.D.
Coordenadora do Programa de Pós-Graduação em Engenharia Elétrica

Banca Examinadora:

Prof. Fernando Mendes de Azevedo, D. Sc.
Presidente

Prof^a. Fernanda Isabel Marques Argoud, Dr. Eng.

Prof. José Marino Neto, D. Sc.

Prof^a. Ana Paula Soares Fernandes, Dr. Eng.

Prof^a. Anita Maria da Rocha Fernandes, Dr. Eng.

Prof^a. Maria Nazaré Munari Angeloni Hahne, Dr. Eng.

Dedico este trabalho à minha família (meu pai, minha mãe, meus irmãos e minha namorada), meus colegas de trabalho, amigos e a toda comunidade científica.

Agradecimentos

Aos meus pais, por todo suporte emocional, financeiro, por toda paciência que tiveram comigo durante todos esses anos de vida, pelos conselhos e todos os ensinamentos que me passaram.

A minha namorada, Mônica, pelo apoio, suporte emocional, paciência e compreensão.

Aos meus orientadores Prof. Fernando Mendes de Azevedo e Prof^a. Fernanda Isabel Argoud e aos professores do IEB pelo conhecimento transmitido.

À Dra. Vânia Maria Abreu Andriani pelos ensinamentos, dicas, paciência e, principalmente, pela ajuda indispensável à conclusão deste trabalho.

A todos os professores responsáveis pela minha educação profissional e pessoal. Em especial a Prof^a. Fátima Sombra, pelos conselhos, conhecimentos transmitidos, pelas dicas, pela oportunidade, etc.

Aos meus colegas de mestrado, que proporcionaram muitas alegrias durante esses dois anos, pela amizade, companheirismo, contribuições ao trabalho e por tudo que me ensinaram.

Aos meus amigos, por todos os momentos bons e ruins que passamos juntos, pela amizade e conselhos.

À Bia e à Aline Grezele, pelas conversas, conselhos, pelo apoio dado nos momentos difíceis, pela ajuda e dedicação fundamentais para conclusão deste trabalho.

Ao CNPq pelo apoio financeiro.

Resumo da Dissertação apresentada à UFSC como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica.

ESTUDO COMPARATIVO DE TÉCNICAS DE REDES NEURAIS E ANÁLISE DE VARIÁVEIS CANÔNICAS PARA DETECÇÃO AUTOMÁTICA DE COMPLEXOS K E FUSOS DO SONO EM EEG

George Araújo Mendonça

Junho / 2007

Orientador: Fernando Mendes de Azevedo, D. Sc.

Área de Concentração: Processamento de Sinais Biomédicos.

Palavras-chave: Complexo K, Fusos do Sono, EEG, Sono, Transformada Wavelet, Redes Neurais Artificiais, Análise de Variáveis Canônicas.

Número de Páginas: 133.

O estagiamento do sono é uma tarefa fundamental no diagnóstico de vários distúrbios relacionados ao sono. Sua execução, no entanto, é um trabalho que requer um grande dispêndio temporal por parte do especialista. Para contornar este problema, vários sistemas de estagiamento automático do sono têm sido propostos. A detecção de padrões específicos de certos estágios do sono é uma etapa fundamental nesses sistemas. Desta forma, este trabalho apresenta a comparação de duas metodologias propostas para detecção de complexos K e fusos do sono em sinais de EEG, com o intuito de auxiliar o estagiamento automático do sono em humanos. A primeira abordagem diz respeito à detecção desses padrões por meio de redes neurais artificiais (RNA), enquanto que a segunda trata de identificar tais padrões por meio da análise de variáveis canônicas (AVC). As duas metodologias, no entanto, são bastante similares e ambas fazem uso da transformada de Fourier e da transformada *wavelet* durante a extração dos parâmetros que compõem o vetor de características dos sinais de EEG, os quais servem de entrada para as RNA e AVC. Para averiguar qual a metodologia mais adequada em se tratando de discriminar complexos K e fusos do sono arquitetou-se um procedimento de testes para cada método utilizado. O método baseado em RNA obteve uma sensibilidade de 78,94%, e especificidade de 98,28%. Já a metodologia fundamentada em AVC alcançou valores de 66,79% e 98,33% para sensibilidade e especificidade, respectivamente.

Abstract of Dissertation presented to UFSC as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering.

COMPARISON BETWEEN NEURAL NETWORK AND CANONICAL VARIATE ANALYSIS TECHNIQUES FOR K COMPLEXES AND SLEEP SPINDLES DETECTION IN EEG

George Araújo Mendonça

June / 2007

Advisor: Fernando Mendes de Azevedo, D. Sc.

Área of Concentration: Biomedical Signal Processing.

Keywords: K-Complexes, Sleep Spindles, Sleep, EEG, Wavelet Transform, Artificial Neural Network, Canonical Analysis.

Number of Pages: 133.

Sleep staging is a primordial task in diagnosing several sleep disturbances. The staging of sleep, however, is an assignment that requires a large temporal effort. So, to solve this problem, several automatic sleep staging systems have been proposed. The detection of some patterns, peculiar from certain sleep stages, is an essential step in those systems. Then this work introduces a comparison of two methodologies, proposed here, for detection of K complexes and sleep spindles, in order to assist the automatization of sleep staging in humans being. The first methodology relies on the detection of these patterns by using artificial neural networks (ANN), whereas the second one deals with the problem using canonical variate analysis (CVA). Both methodologies, nevertheless, are very similar and make use of signal processing techniques, such as Fourier and wavelet transforms during the extraction of measures that compose the feature vector of EEG signals patterns, which are the input of the ANN and CVA. To investigate which is the more appropriate methodology in detecting k complexes and sleep spindles, one builds a test procedure that analyses each method. The system based on ANN reached a sensibility of 78.94% and a specificity of 98.28%. In the other hand, the method based on CVA presented values of 66.79% and 98.33%, for sensibility and specificity, respectively.

Sumário

Lista de Figuras	xvii
Lista de Tabelas	xxiii
Lista de Abreviaturas.....	xxv
Publicações	xxvii
Capítulo 1 Introdução	1
1.1. Motivação	5
1.2. Justificativas	5
1.3. Objetivo Geral	6
1.4. Objetivos Específicos	6
1.5. Organização do Documento	7
Capítulo 2 O Sono.....	9
2.1. O Ciclo do Sono	10
2.1.1. Estágio <i>W</i> (acordado).....	12
2.1.2. Estágio <i>I</i> do Sono NREM (Sonolência)	13
2.1.3. Estágio <i>II</i> do Sono NREM (Sono Leve)	15
2.1.4. Estágio <i>III</i> do Sono NREM.....	19
2.1.5. Estágio <i>IV</i> do Sono NREM (Sono Profundo)	20
2.1.6. Sono REM.....	22
2.2. Funções do Sono.....	24
2.2.1. Teorias Somáticas x Teorias Neurais.....	24
Capítulo 3 Fundamentação Teórica.....	27
3.1. Redes Neurais	27
3.1.1. Neurônio Biológico x Neurônio Artificial.....	28
3.1.2. Topologias de Rede	30
3.1.3. Algoritmo de Retropropagação do Erro	32
3.2. Wavelets	35
3.2.1. Transformada de Fourier de Tempo Curto	36

3.2.2. Transformada Wavelet	39
3.2.3. Escalonamento e Deslocamento de Funções	40
3.2.4. Funções Wavelets	41
3.2.5. Transformada Wavelet Contínua (TWC)	43
3.2.6. Discretização dos Parâmetros Tempo-Escala	45
3.2.7. Transformada Wavelet Discreta (TWD)	45
3.3. Análise das Variáveis Canônicas	49
3.4. Estudo Estatístico Para Validação de Testes	53
Capítulo 4 Metodologia.....	55
4.1. Base de Dados	55
4.2. Esboço Geral das Metodologias	59
4.3. Detecção de Padrões.....	60
4.3.1. Análise de Variáveis Canônicas.....	65
4.3.2. Rede Neural Artificial	67
4.3.3. Transformada Wavelet	70
4.4. Escolha da Função Wavelet	74
4.5. Sistema de Controle	75
Capítulo 5 Software Desenvolvido	79
5.1. Módulo de Visualização e Inspeção dos Sinais (MVIS).....	79
5.2. Módulo de Treinamento	82
5.2.1. Opções de Menu	85
5.2.2. Opções de Visualização	86
Capítulo 6 Resultados e Discussões.....	91
6.1. Escolha das Funções Wavelets.....	91
6.1.1. Redes Neurais Artificiais.....	91
6.1.2. Análise das Variáveis Canônicas.....	95
6.2. Teste nos Registros Polissonográficos	98
6.2.1. Redes Neurais Artificiais.....	98
6.2.2. Análise de Variáveis Canônicas.....	104
6.3. Testes Finais	109
Capítulo 7 Conclusões e Trabalhos Futuros	113
7.1. Trabalhos Futuros.....	115

Apêndice A Eletroencefalografia	117
A.1. Aspectos Fisiológicos do EEG	119
A.2. Posicionamento de Eletrodos	122
Referências Bibliográficas	125

Lista de Figuras

Figura 2.1 - Ciclo sono-vigília (hipnograma). Adaptado de (Rama et al., 2006).....	10
Figura 2.2 - Registro polissonográfico durante a vigília.....	13
Figura 2.3 - Espectro normalizado das derivações O1 (esquerda) e O2 (direita) dos sinais de EEG mostrados na Figura 2.2. A FFT da derivação O1 é calculada no instante entre 12 e 16 segundos, enquanto a da derivação O2 é calculada entre 10 e 14 segundos.....	13
Figura 2.4 – Registro polissonográfico durante o estágio I (sonolência) do sono NREM.....	14
Figura 2.5 - Espectro normalizado das derivações C3 (esquerda) e C4 (direita) do sinal de EEG mostrado na Figura 2.4. A frequência predominante está em torno de 3 Hz, porém podemos encontrar ondas na faixa de até 25 Hz. A FFT da derivação é calculada no intervalo de tempo entre 0 e 4 segundos, enquanto que a da derivação C4 é calculada entre 8 e 12 segundos.....	14
Figura 2.6 - Registro polissonográfico durante o estágio II do sono NREM com aparições de complexos K e fusos do sono.....	16
Figura 2.7 - Espectro normalizado do EEG durante o estágio II do sono NREM. À esquerda temos a FFT do sinal na derivação C3 nos instantes entre 16 e 20 segundos. À direita, a FFT da derivação C4 no intervalo entre 18 e 22 segundos, onde ocorre um complexo K. As derivações mencionadas referem-se ao registro de EEG da Figura 2.6.....	16
Figura 2.8 - Exemplos de morfologia de alguns complexos K. Estes podem variar muito, até mesmo num mesmo indivíduo. A duração de cada janela é de aproximadamente 1 segundo. A amplitude está normalizada, de modo que o valor mínimo seja -1 o e o máximo seja igual a 1.....	17
Figura 2.9 - Fusos do sono. Todas as três janelas estão com suas amplitudes normalizadas e a escala de tempo é de um segundo, aproximadamente, para cada janela.....	18
Figura 2.10 – Registro polissonográfico durante o início do sono profundo (estágio III do sono NREM). As ondas delta ocupam entre 20 e 50% de uma época.....	19
Figura 2.11 - Transformada de Fourier da derivação C3 entre 0 e 4 segundos (à esquerda) e da derivação C4 entre 12 e 16 segundos (à direita). As derivações citadas são referente à Figura 2.10.....	20
Figura 2.12 – Registro polissonográfico típico do sono profundo (estágio IV do sono NREM) com predominância de altas amplitudes e baixas frequências durante a maior parte de uma época.....	21
Figura 2.13 – Espectro normalizado da derivação C3 entre 8 e 12 segundos (à esquerda) e da derivação C4 entre 10 e 14 segundos (à direita). As derivações citadas são referentes à Figura 2.12.....	21

Figura 2.14 - Registro polissonográfico durante o sono REM, com uma mistura de ondas alfa, na faixa de 1 a 2 Hz, e ondas teta.....	22
Figura 2.15 – Espectro normalizado da derivação C3 entre 4 e 8 segundos (à esquerda) e da derivação C4 entre 0 e 4 segundos (à direita). As derivações citadas são referentes à Figura 2.14.....	23
Figura 3.1 - Neurônio biológico.....	28
Figura 3.2 - Modelo não-linear de um neurônio artificial.....	29
Figura 3.3 - Rede feedforward com camada única.....	31
Figura 3.4 - Rede feedforward com múltiplas (três) camadas: uma de entrada, uma oculta e uma de saída.....	31
Figura 3.5 - Rede recorrente com a saída dos neurônios da camada de saída realimentando os neurônios da camada oculta.....	32
Figura 3.6 - Aprendizado de uma RNA feedforward com algoritmo de treinamento backpropagation. O erro na saída da rede neural tende a diminuir com o número de iterações. O aprendizado se dá através da correção dos valores dos pesos sinápticos dos neurônios.....	35
Figura 3.7 - Transformação do sinal no domínio do tempo para o domínio das frequências, através da transformada de Fourier. Como a TF tem uma visão geral do sinal, ela não consegue localizar (temporalmente ou espacialmente) a componente de 15 Hz do mesmo.....	36
Figura 3.8 - Transformação do sinal temporal para o plano bidimensional tempo-frequência, através da STFT. Do lado esquerdo, temos parte de um sinal, cuja frequência varia com o tempo. Na direita, temos o espectrograma deste sinal, que nos mostra o comportamento desta frequência ao longo do tempo.....	37
Figura 3.9 - Cobertura do espaço tempo-frequência através da STFT. Os valores de Δt e Δf são fixos para todo o plano. A largura Δf pode ser adequada para analisar o sinal em frequências próximas a f_1 , porém esta mesma largura pode ser insatisfatória para frequências próximas de f_2 . Da mesma forma, a resolução temporal, Δt , pode ser adequada para instantes de tempo próximos a τ_1 , no entanto pode ser inadequado para instantes de tempo próximos a τ_2	38
Figura 3.10 – Resolução tempo-frequência da transformada wavelet. As resoluções Δt e Δf dos quadros de Heisenberg são proporcionais à escala da função wavelet. A área dos quadros, no entanto, permanece fixa. Escalas menores ($s_0 < s_1$) diminuem o espalhamento da função $\psi(t)$ no tempo e aumentam a largura de banda do filtro passa-faixa.....	39
Figura 3.11 – Senóide com diferentes escalas. No topo, temos uma senóide com fator de escala $a = 1$, a função $f_1/2(t)$ possui $a = 1/2$ e em $f_2(t)$ o fator de escala é igual a 2.....	40
Figura 3.12 - Wavelet 'Chapéu Mexicano' e suas versões dilatadas e deslocadas. Em (a) temos a wavelet-mãe. Em (b) temos uma versão dilatada e deslocada, com $a = 0,2$ e $\tau =$	

6. Em (c) temos outra wavelet-filha, com $a = 2$ e $\tau = -3$. Os índices das funções correspondem aos fatores de deslocamento e escala.	41
Figura 3.13 - Divisão do espectro para a (a) transformada de Fourier janelada e para a (b) transformada wavelet. No caso da STFT, observa-se uma cobertura uniforme do espectro, enquanto que na análise através da TW, tem-se uma cobertura uniforme do mesmo.	43
Figura 3.14 – Em (a) temos a análise de Fourier, que decompõe o sinal em senóides com diferentes frequências. Em (b) temos a análise wavelet, que decompõe o sinal em versões deslocadas e escalonadas de uma função wavelet-mãe. Adaptado de (Misiti et al., 2006).	44
Figura 3.15 - Obtenção dos sinais de aproximação e detalhe a partir do sinal original. O sinal S passa por dois filtros complementares se decompondo em dois sinais.	46
Figura 3.16 - Processo de decomposição wavelet incluindo a sub-amostragem dos sinais filtrados. Os coeficientes de detalhe e aproximação possuem aproximadamente metade do número de amostras do sinal original.	46
Figura 3.17 - Árvore de decomposição wavelet. O sinal original é decomposto em componentes de detalhe e aproximação com resolução cada vez menor.	47
Figura 3.18 - Processo de reconstrução (síntese) wavelet a partir dos coeficientes da segunda escala. Primeiro, obtem-se o coeficiente de aproximação da primeira escala a partir dos coeficientes de aproximação e detalhe da 2ª escala. Em seguida, recupera-se o sinal a partir dos coeficientes da 1ª escala.	47
Figura 3.19 - Obtenção dos sinais de (a) aproximação e (b) detalhe da TW.	48
Figura 3.20 - Reconstrução do sinal através dos sinais de aproximação e detalhe multi-níveis.	49
Figura 4.1 - Janela de trinta segundos do registro polissonográfico contendo apenas os quatro canais de EEG.	56
Figura 4.2 - Hipnograma de um registro de polissonografia da base de dados.	57
Figura 4.3 - Estrutura para montagem do nome do arquivo onde será salvo o padrão de treinamento.	58
Figura 4.4 - Exemplos de padrões de treinamento selecionados por um especialista. À esquerda alguns exemplos de atividade de fundo de EEG durante o estágio 2 do sono NREM são ilustrados. No centro, têm-se exemplares de complexos K e à direita alguns fusos do sono. Observe que a amplitude dos padrões está normalizada entre -1 e 1 e que a duração de cada um deles é de aproximadamente 1 segundo.	58
Figura 4.5 – Escopo geral da metodologia para detecção dos padrões.	59
Figura 4.6 - Diagrama geral para metodologia de detecção dos padrões do EEG durante o sono. Primeiro, calcula-se a FFT e a FWT dos padrões do sono (AF, CK ou FS). Posteriormente, calculam-se alguns parâmetros desses padrões, os quais servirão de entrada para as RNAs e para as AVCs.	60

Figura 4.7 - Detalhe do módulo de extração de parâmetros. A saída deste módulo é um vetor de 16 posições (chamado de vetor de características do sinal) contendo todos os parâmetros extraídos, o qual servirá de entrada para as RNAs e as ACVs.....	62
Figura 4.8 - Sinal original (esquerda) e o quadrado de seu módulo (direita). A energia do sinal é numericamente igual à área sobre a curva direita.	63
Figura 4.9 - Espectro de um sinal e sua respectiva frequência média (linha vertical). O cálculo da frequência média se dá multiplicando cada amostra de frequência pela sua respectiva amplitude no espectro. A linha vertical representa a coordenada horizontal do centro de massa da área sob a curva.....	64
Figura 4.10 - Resultado das AVC-CK (esquerda) e AVC-FS (direita). A linha vertical indica o limiar de decisão entre os padrões.	66
Figura 4.11 - Exemplo de decisão de uma RNA. Em (a), tem-se o limiar de decisão (linha vertical), a saída da RNA para os padrões usados durante o treinamento, marcados com “O”, e para um padrão de teste, marcado com um “X”. Em (b), o erro na saída da rede para as duas classes: CK e \overline{CK}	69
Figura 4.12 - Exemplos de fusos do sono e seus sinais de detalhe nas escalas 2, 3, 4, 5 e 6. A primeira linha mostra alguns fusos do sono com sua amplitude normalizada, a 2ª linha mostra o sinal de detalhe da 2ª escala, a 3ª linha ilustra o sinal de detalhe da 3ª escala, e assim por diante. Os sinais de detalhe dos FS são mais proeminentes nas escalas 2 e 3 da TW.....	71
Figura 4.13 – Exemplos de complexos K e seus sinais de detalhe nas escalas 2, 3, 4, 5 e 6. A primeira linha mostra os complexos K com sua amplitude normalizada, a 2ª linha mostra os respectivos sinais de detalhe da 2ª escala, a 3ª linha ilustra os sinais de detalhe da 3ª escala, e assim por diante. Os sinais de detalhe dos CK são mais expressivos nas escalas 4 e 5 da TW.....	72
Figura 4.14 - Exemplos de atividade de fundo de EEG e seus respectivos sinais de detalhe nas escalas 2, 3, 4, 5 e 6. A primeira linha mostra algumas atividades de fundo de EEG com suas amplitudes normalizadas, a 2ª linha mostra os sinais de detalhe da 2ª escala, a 3ª linha ilustra os sinais de detalhe da 3ª escala, e assim por diante. Os sinais de detalhe das AF mostram-se bem distribuídos em todas as escalas da TW, dependendo do instante em que se calcula a transformada.	73
Figura 4.15 – Sistema de controle das RNAs. Esta parte do SC é responsável pela definição (identificação) do padrão apresentado pelo par de RNAs do sistema. O bloco “Limiar (·)”, calcula o limiar de decisão das RNAs baseado na sensibilidade de cada uma.	76
Figura 4.16 – Sistema de controle das ACVs. Esta parte do SC é responsável pela definição (identificação) do padrão apresentado pelo par de ACVs do sistema. O bloco “Side (·)” verifica se a saída da AVC, para o padrão teste, está dentro ou fora da região correspondente ao padrão P.	77
Figura 4.17 - Fluxograma para detecção da região dos padrões-alvo. AVC-P é uma análise canônica de variáveis especialista em identificar o padrão-alvo P (P = CK ou P = FS).	

Resumidamente, esta função investiga se os padrões da classe P estão à esquerda ou à direita do limiar de decisão da AVC-P.	78
Figura 5.1 - Interface do módulo de visualização e inspeção de sinais do software desenvolvido.	80
Figura 5.2 - Organização do menu principal do módulo de visualização do software desenvolvido.	81
Figura 5.3 - Detecção de complexos K e fusos do sono por meio da análise das variáveis canônicas, com $s = 0,8$ para a AVC-CK e $s = 0,5$ para a AVC-FS e wavelet = coif3.	81
Figura 5.4 - Análise espectral do módulo de visualização e inspeção de sinais. Esta janela exibe a transformada de Fourier dos canais de EEG do registro polissonográfico.	82
Figura 5.5 - Módulo de treinamento do sistema. Neste módulo o usuário pode visualizar os padrões salvos, extrair parâmetros destes, treinar e testar as RNAs e as AVCs do sistema de detecção de padrões.	83
Figura 5.6 - Bloco Base de Dados: grupo de componentes onde o usuário pode montar uma base de dados.	84
Figura 5.7 - Caixa de grupamento Parâmetros Extraídos. Este bloco exibe as medidas extraídas do padrão selecionado na lista da base de dados.	84
Figura 5.8 - Organização do menu do módulo de treinamento do software desenvolvido.	85
Figura 5.9 - Histórico de Comando durante a extração de parâmetros dos padrões da base de dados.	86
Figura 5.10 - Visualização de Padrões do menu de visualização, ilustrando um fuso do sono (esquerda) e sua FFT (direita).	87
Figura 5.11 - Histórico de Comando durante a análise das variáveis canônicas.	88
Figura 5.12 - Histórico de Comando exibindo o resultado de uma análise estatística de uma RNA-FS.	88
Figura 5.13 - Espaço Canônico do menu de visualização, onde são exibidos os resultados das duas AVCs: AVC-CK e ACV-FS.	89
Figura 5.14 - Saída das RNAs do menu de visualização. Do lado direito, a saída da RNA-CK e à esquerda a saída da RNA-FS.	89
Figura 5.15 - Erro das RNAs do menu de visualização.	90
Figura 6.1 - Desempenho das RNA-CK para as várias funções wavelets.	92
Figura 6.2 - Desempenho das RNA-FS para diversas funções wavelets.	93
Figura 6.3 – Saída da RNA-CK para o teste realizado com a wavelet db30 (à esquerda) e da RNA-FS para o teste realizado com a wavelet coif3 (à direita).	94
Figura 6.4 - Desempenho das AVC-CK para as várias funções wavelets.	95
Figura 6.5 - Desempenho das AVC-FS para as várias funções wavelets.	96

Figura 6.6 - Saída da AVC-CK para o teste realizado com a wavelet rbio3.1 (à esquerda) e da AVC-FS para o teste realizado com a wavelet bior3.1 (à direita).....	97
Figura 6.7 – Página 701 do registro 00603-1. Em destaque, os dois complexos K presentes na época.	101
Figura 6.8 - Página 219 do registro 00601-1. Os padrões destacados são aqueles que a RNA-CK identificou como um complexo K, utilizando a wavelet db30.	101
Figura 6.9 - Exemplo de uma época (página 24 do registro 0614-1.plg) utilizada no teste da RNA-FS. Os padrões destacados são aqueles que a RNA-FS identificou como um fuso do sono, utilizando a wavelet coif1. Os retângulos preenchidos representam os verdadeiros positivos. Os demais indicam os falsos positivos.....	104
Figura 6.10 - Página 138 do registro 00614-1, com os complexos K reconhecidos pela AVC-CK_rbio3.1. Os retângulos preenchidos representam os verdadeiros positivos. Os demais indicam os falsos positivos.	106
Figura 6.11 - Exemplo de uma época (página 19 do registro 0614-1.plg) utilizada no teste da AVC-FS. Os padrões destacados são aqueles que a AVC-FS identificou como fusos do sono, utilizando a wavelet bior3.1. Os retângulos preenchidos representam os verdadeiros positivos. Os demais indicam os falsos positivos.	108
Figura A.7.1 - Diferentes ondas cerebrais em um registro de EEG de uma pessoa normal. A amplitude e a morfologia variam de acordo com a excitação das partes do córtex (Guyton E HALL, 2006).	120
Figura A.7.2 - Reposição das ondas alfa, no início do registro, pelo ritmo beta, assíncrono, quando o indivíduo abre os olhos (Guyton E HALL, 2006).	120
Figura A.7.3 - Dependência entre o nível de consciência do indivíduo e a atividade elétrica no EEG. A morfologia do EEG muda de acordo com os diferentes estágios de vigília e sono (Guyton E HALL, 2006).....	121
Figura A.7.4 - Sistema internacional de 10-20 de colocação de eletrodos. Eletrodos com índices ímpares localizam-se no lado esquerdo, índices pares ficam no lado direito e índice Z ou 0 na linha central (Malmivuo E PLONSEY, 1995).	122
Figura A.7.5 - Montagem (a) unipolar e (b) bipolar de eletrodos (Malmivuo E PLONSEY, 1995).	123

Lista de Tabelas

Tabela 2.1 - Classificação do sono segundo Loomis (apud NIEDERMEYER E SILVA, 1993, p. 155).	11
Tabela 2.2 - Estágios do sono segundo Dement e Kleitman (apud NIEDERMEYER E SILVA, 1993, p. 155).	11
Tabela 3.1 - Organização dos dados para a análise das variáveis canônicas. Os elementos devem estar agrupados em classes que devem estar separadas em linhas e as diferentes variáveis medidas devem estar organizadas em colunas. Φ_i é a i -ésima classe, $P_{i,j}$ representa o j -ésimo padrão da i -ésima classe e $D_{i,j,k}$ representa a k -ésima variável do elemento j da classe i	50
Tabela 4.1 - Características dos pacientes utilizados na obtenção dos registros polissonográficos utilizados neste trabalho.	56
Tabela 4.2 - Funções wavelets utilizadas na análise comparativa empregada para verificação das wavelets mais adequadas à detecção dos complexos K e fusos do sono.	74
Tabela 6.1 - Resultado da análise estatística para as 10 melhores wavelets utilizadas na detecção de complexos K. Em destaque, a função wavelet que obteve o melhor desempenho.	93
Tabela 6.2 - Resultado do teste estatístico para as 10 melhores wavelets utilizadas na detecção de fusos do sono, por meio de RNA. Em destaque, a função wavelet que obteve o melhor desempenho.	94
Tabela 6.3 - Resultado do teste estatístico para as 10 melhores wavelets utilizadas na detecção de complexos K, por meio de AVC. Em destaque, a função wavelet que obteve o melhor desempenho.	96
Tabela 6.4 – Resultado do teste estatístico para as 11 melhores wavelets utilizadas na detecção de fusos do sono, por meio de AVC. Em destaque, a função wavelet que obteve o melhor desempenho.	97
Tabela 6.5 - Resultado do teste nos registros de EEG através da RNA-CK para detecção de complexos K, utilizando a wavelet db30.	99
Tabela 6.6 - Resultado do teste nos registros de EEG através da RNA-CK para detecção de complexos K, utilizando a wavelet dmey.	100
Tabela 6.7 - Resultado do teste nos registros de EEG através da RNA-CK para detecção de complexos K, utilizando a wavelet db40.	100
Tabela 6.8 – Resultado do teste nos registros de EEG através da RNA-FS, utilizando a wavelet coif1.	102

Tabela 6.9 – Resultado do teste nos registros de EEG através da RNA-FS, utilizando a wavelet db7.....	103
Tabela 6.10 – Resultado do teste nos registros de EEG através da RNA-FS, utilizando a wavelet db30.....	103
Tabela 6.11 - Resultado do teste nos registros de EEG através da AVC-CK para detecção de complexos K, utilizando a wavelet rbio3.1.....	105
Tabela 6.12 - Resultado do teste nos registros de EEG através da AVC-CK para detecção de complexos K, utilizando a wavelet db13.	105
Tabela 6.13 - Resultado do teste nos registros de EEG através da AVC-CK para detecção de complexos K, utilizando a wavelet db17.	106
Tabela 6.14 – Resultado do teste nos registros de EEG através da AVC-FS para detecção de fusos do sono, utilizando a wavelet bior3.1.	107
Tabela 6.15 – Resultado do teste nos registros de EEG através da AVC-FS para detecção de fusos do sono, utilizando a wavelet bior2.4.	107
Tabela 6.16 – Resultado do teste nos registros de EEG através da AVC-FS para detecção de fusos do sono, utilizando a wavelet bior4.4.	108
Tabela 6.17 – Resumo dos testes em registros polissonográficos realizados nas RNAs para detecção de complexos K e fusos do sono. As RNAs destacadas serão submetidas à etapa final de testes.	109
Tabela 6.18 - Resumo dos testes em registros polissonográficos realizados nas AVCs para detecção de complexos K e fusos do sono. As AVCs destacadas serão submetidas à etapa final de testes.	109
Tabela 6.19 – Resultado do teste final da RNA-CK_db30, com $s = 0,3$, na detecção de complexos K.	110
Tabela 6.20 – Resultado do teste final da AVC-CK_rbio3.1, com $s = 0,3$, na detecção de complexos K.	110
Tabela 6.22 – Resultado do teste final da RNA-FS_coif1, com $s = 0,3$, na detecção de fusos do sono.	111
Tabela 6.21 - Resultado do teste final da AVC-FS_bior3.1, com $s = 0,3$, na detecção de fusos do sono.	111
Tabela A.1 - Principais ritmos cerebrais e suas respectivas frequências.....	121

Lista de Abreviaturas

ACP:	Análise de componentes principais
AVC:	Análise de variáveis canônicas
AVC-CK:	Análise de variáveis canônicas especialista em complexos K
AVC-FS:	Análise de variáveis canônicas especialista em fusos do sono
AF:	Atividade de fundo do eletroencefalograma
CK:	Complexo K
$\overline{\text{CK}}$:	Padrão que não é um complexo K
ECG:	Eletrocardiograma
EEG:	Eletroencefalograma
Esp:	Especificidade de um teste
EOG:	Eletrooculograma
FFT:	Transformada rápida de Fourier
FP:	Falso positivo
FN:	Falso negativo
FS:	Fusos do sono
$\overline{\text{FS}}$:	Padrão que não é um fuso do sono
FWT:	Transformada rápida wavelet
HC:	Histórico de comando
IA:	Inteligência artificial
IEB:	Instituto de Engenharia Biomédica
IDWT:	Transformada wavelet discreta inversa
MTC:	Matriz de transformação canônica
MVE:	Máximo valor do espectro
MVIS:	Módulo de visualização e inspeção de sinais
NREM:	não-REM, fase do sono
REM:	<i>rapid eyes movement</i> , fase do sono

RNA:	Rede neural artificial
RNA-CK:	Rede neural artificial especialista em complexos K
RNA-FS:	Rede neural artificial especialista em fusos do sono
SC:	Sistema de controle
Sen:	Sensibilidade de um teste
SNC:	Sistema nervoso central
STFT:	Transformada de Fourier janelada (ou de curto tempo)
SWS:	Sono de ondas lentas (<i>slow wave sleep</i>)
TW:	Transformada <i>wavelet</i>
TWC:	Transformada wavelet contínua
TWD:	Transformada wavelet discreta
UFSC:	Universidade Federal de Santa Catarina
VC:	Variável canônica
VP:	Verdadeiro positivo
VPP:	Valor preditivo positivo
VPN:	Valor preditivo negativo
VN:	Verdadeiro negativo

Publicações

MENDONÇA, G.A., AZEVEDO, F.M. DE, JAHNECKE, C.A.N., SOVIERZOSKI, M.A.; 2007. Detecção de Complexos K e Fusos do Sono Utilizando Redes Neurais Artificiais, Wavelets e Análise Canônica. In: XVII CONGRESO DE LA ASOCIACIÓN CHILENA DE CONTROL AUTOMÁTICO. (Jan. 2007: Temuco, Chile). *Anais*. Chile, 2007. pp. 169-174.

G.A. MENDONÇA, F.M. DE AZEVEDO; 2007. Sistema de Identificação Automática de Complexos K e Fusos do Sono em Sinais de Eletroencefalograma. In: IV CONGRESO LATINOAMERICANO DE INGENIERÍA BIOMÉDICA. (Set. 2007: Nueva Esparta, Venezuela). *Anais*. Venezuela, 2007. (Aceito)

GEORGE A. MENDONÇA, FERNANDO M. DE AZEVEDO. 2007. Identificação Automática de Complexos K e Fusos do Sono em Sinais de EEG Utilizando Redes Neurais e Transformada Wavelet. In: VIII CONGRESSO BRASILEIRO DE REDES NEURAS. (Out. 2007: Florianópolis, SC). *Anais*. Santa Catarina, 2007. (Submetido).

Capítulo 1

Introdução

Durante o sono, o cérebro mantém-se em intensa atividade, que obedece a um ritmo próprio, abrange etapas bem definidas e é produto de um equilíbrio especial entre substâncias químicas e impulsos elétricos. Tal equilíbrio é a chave para manter uma boa saúde. Porém, se esse equilíbrio entrar em descompasso, por menor que seja o desajuste, o corpo padece. Sabe-se, hoje, que uma boa noite de sono ajuda a manter a silhueta alinhada, fortalece as defesas do organismo, protege o coração, facilita o aprendizado e a criatividade, aguça o raciocínio e até rejuvenesce (POWER, 2004; SUSMAKOVA, 2004; GOURINENI E ZEE, 2006; ROSENTHAL, 2006). Em contrapartida, uma sucessão de noites em claro aumenta a incidência de stress, depressão, problemas de memória, distúrbios cardio-respiratórios, entre outras anomalias (GILLIN, 1998; REETH *et al.*, 2000; SUSMAKOVA, 2004; FRANK, 2006; GOURINENI E ZEE, 2006).

A classificação visual do sono vem sendo feita desde a década de 70, através dos registros polissonográficos¹. Esta classificação, no entanto, é uma tarefa bastante dispendiosa e cansativa, uma vez que um registro de uma noite de sono pode durar até oito horas, ou mais. Uma solução interessante para solucionar esse problema foi a automatização desse processo. Desta forma, na tentativa de classificar o sono automaticamente em seus diversos estágios, diversas técnicas têm sido propostas.

Smith *et al.* (1969) utilizaram técnicas híbridas de computação para processar sinais de EEG de maneira similar àquela usada por especialistas, a fim de determinar automaticamente os estágios do sono. O sistema proposto no trabalho de Smith *et al.* (1969) combina a utilização de filtros analógicos, usados para identificação de ondas transientes especí-

¹Polissonografia é o registro contínuo e simultâneo de várias variáveis fisiológicas durante o sono; eletroencefalograma (EEG), eletrocardiograma (ECG), eletrooculograma (EOG) e eletromiograma (EMG) são as mais comuns (SILVA, 1995).

ficas do sono, e filtros passa-banda, utilizados para detectar padrões de ondas rítmicos. Foram monitoradas então quatro tipos de onda: atividade alfa, atividade delta, fusos do sono e complexos K. A detecção de complexos K e fusos do sono deu-se através de um esquema baseado em filtros casados. Hu e Knapp (1991) produziram um método de estagiamento de sono de seres humanos baseado em lógica *fuzzy*, onde informações de frequência e amplitude dos sinais de EEG foram extraídas para edificação de um vetor de características que era então comparado com vetores alvos que representavam cada um dos estágios do sono. Assim, o estágio com maior grau de semelhança com o vetor de características da época era assinalado e classificado. Roberts e Tarassenko (1992) utilizaram filtros de Kalman de décima ordem para parametrizar os sinais de EEG. Os coeficientes desses filtros foram usados como entrada de uma rede auto-organizável de Kohonen, com o objetivo de analisar a dinâmica do sono em seres humanos. Henry *et al.* (1994) fizeram uma análise comparativa de três métodos utilizados para detecção de complexos K: filtros casados, decomposição em grupos de funções ortonormais e decomposição *wavelet*. Pohl e Fahr (1995), por sua vez, propuseram uma nova metodologia para detecção de complexos K em sinais de EEG baseada em lógica fuzzy e redes neurais. Akin e Akgül (1998) utilizaram transformada *wavelet* discreta para detecção de fusos do sono em sinais de EEG durante o sono, utilizando a função *wavelet Daubechies 10*. A análise dos dados foi feita em duas etapas: análise wavelet e análise topográfica.

Akgül *et al.* (2000) caracterizaram a dinâmica dos fusos do sono utilizando métodos baseados no domínio do tempo e da frequência. Os métodos baseados no domínio do tempo combinaram o uso da correlação de 2ª e 3ª ordem para revelar informação da estacionaridade de fusos periódicos rítmicos, a fim de detectar transição entre múltiplas atividades. O método baseado no domínio da frequência, fundamentado em espectro normalizado e análise biespectral, descreveu interações de frequência associadas com não-linearidades que ocorreram no EEG observado. Shimada *et al.* (2000) propuseram um novo tipo de rede neural que possibilita a detecção de diversos tipos de ondas características do sono, baseada na análise do plano bidimensional tempo-frequência das ondas características. A arquitetura de tal RNA reconhece as propriedades esporádicas das ondas transientes e realiza um processamento invariante ao deslocamento. Ou seja, a RNA detecta as ondas transientes, independente de suas localizações (SHIMADA *et al.*, 2000). Kim e Park (2000)

desenvolveram um sistema híbrido de estagiamento automático do sono utilizando um canal de EEG. Tal sistema fez uso de algoritmos genéticos para encontrar uma topologia “ótima” da rede neural *feedforward* utilizada na detecção dos padrões de onda do EEG. Hese *et al.* (2001) fizeram uma detecção automática dos estágios do sono por meio de uma metodologia que consistia de quatro etapas: segmentação, extração de parâmetros, análise de clusterização e classificação. Os parâmetros usados por Hese *et al.* (2001) foram os parâmetros de *Hjorth*, parâmetros harmônicos e a energia relativa da banda do sinal e o algoritmo usado na análise de clusterização foi uma versão modificada do *K-Média*. Millán *et al.* (2002) desenvolveram um classificador neural local inédito para distinção de cinco tarefas mentais: relaxação; imaginação de movimentos da mão direita e da mão esquerda; rotação de um cubo; e subtração. Eles utilizaram tanto classificadores lineares, como o discriminante linear de Fisher e um algoritmo de projeção espacial do sinal, como classificadores não-lineares, tais como redes de múltiplas camadas (MLP) e redes de função de base radial (RBF). A taxa de acerto alcançada neste trabalho foi de aproximadamente 70%, com uma pequena taxa de decisões erradas (< 5%) e rápidas respostas (a cada 0,5 segundos). Gorur *et al.* (2002) combinaram o uso da transformada de Fourier janelada (*Short-Time Fourier Transform*) com redes MLP e máquinas de vetor de suporte para reconhecimento de fusos do sono. Huang *et al.* (2003) desenvolveram um método original para estagiamento do sono utilizando informação mútua do córtex cerebral juntamente com redes neurais e medidas de complexidade. Natajara *et al.* (2004) analisaram o sinal de EEG em diferentes estados mentais utilizando parâmetros não-lineares, tais como dimensão de correlação, maior expoente de Lyapunov, expoente de Hursts e entropia aproximada. Kam *et al.* (2004) apresentaram um novo método para detecção de complexos K utilizando modelos ocultos de Markov de densidade contínua. Held *et al.* (2004) combinaram dois métodos para detecção de fusos do sono em um único sistema. O primeiro método utiliza um filtro passa-banda de 10 a 15 Hz, um algoritmo de regressão linear e um limiar fuzzy de amplitude. O segundo método, por sua vez, preserva as componentes de baixa frequência utilizando filtros FIR de décima ordem, com frequência de corte em 17 Hz, além de fazer uso de algoritmos de regressão linear e um conjunto de regras de decisão. Li *et al.* (2005) realizaram uma análise tempo-frequência utilizando transformada wavelet em épocas de 16 segundos a fim de distinguir os diferentes estágios do sono em seres humanos. He *et al.* (2005) utilizaram parâmetros não-lineares para caracterizar as diversas fases do sono. Os

parâmetros usados no trabalho de He *et al.* (2005) foram: entropia espectral, entropia aproximada e complexidade de Lem-Ziv. Os autores então, baseados em informações de eficiência e eficácia de cada parâmetro, concluíram que a entropia espectral mostrou ser mais adequada que os demais parâmetros utilizados. Estrada *et al.* (2005) realizaram uma estimação espectral dos sinais de EEG utilizando modelagem autoregressiva (AR) e, então, usaram a distância de Itakura para medir o grau de similaridade entre os sinais de EEG e EOG, com o intuito de contribuir à automatização do estagiamento do sono. Glavinovitch *et al.* (2005) propuseram um procedimento computadorizado de detecção de micro-despertares baseado em transformada wavelet e segmentação. Neste trabalho, o sinal primeiro é decomposto até a 4ª escala da transformada wavelet, utilizando-se a wavelet discreta de Meyer. Em seguida, os sinais de detalhe são particionados em segmentos menores através de diferentes métodos de segmentação: função de autocorrelação; operador não-linear de energia e a razão de vizinhança generalizada. Os resultados mostraram que a inclusão da transformada wavelet melhorou a correta detecção dos micro-despertares. Tian e Liu (2005) combinaram mapas de características auto-organizáveis com um classificador de raciocínio baseado em lógica fuzzy, utilizando tanto informação de frequência como de amplitude dos sinais de EEG, conseguindo, desta forma, uma ferramenta confiável para o estagiamento automático do sono. Vivaldi e Bassi (2006) apresentaram um método *on-line* de extração de características baseado em análise espectral e análise de componentes principais (ACP) para visualização e automatização dos estágios do sono.

O Instituto de Engenharia Biomédica (IEB) da Universidade Federal de Santa Catarina (UFSC), especificamente, possui uma linha de pesquisa voltada para a análise e processamento de sinais bioelétricos, dentre os quais se encontra o EEG. Desde a fundação do instituto, antigo Grupo de Pesquisas em Engenharia Biomédica (GPEB), várias dissertações de mestrado e teses de doutorado foram concluídas, dentre as quais podemos destacar alguns estudos relacionados ao reconhecimento de padrões em sinais de EEG. Em 2001, por exemplo, Argoud (2001) desenvolveu um sistema (SADE3) para processamento de sinais de EEG com o intuito de realizar a detecção e o reconhecimento de descargas epileptiformes do tipo Espícula-Onda (*spikes*), possivelmente presentes no sinal. Para tal, utilizaram-se ferramentas como redes neurais artificiais e transformada *wavelet*. Rodrigues (2002), por sua vez, desenvolveu um sistema de detecção e classificação de apnéias do

sono fundamentado em redes neurais dinâmicas, utilizadas na detecção de complexos K e fusos do sono nos sinais de EEG. Iaione (2003) desenvolveu um aparelho portátil para registro do sinal de EEG, bem como uma metodologia, utilizando técnicas de processamento digital de sinais e redes neurais artificiais, para detectar o estado hipoglicêmico, em tempo real, a partir do registro e análise de uma única derivação do EEG. Sala (2005) utilizou mapas auto-organizáveis de Kohonen com a finalidade realizar uma detecção automática de eventos epileptogênicos (espículas e ondas agudas) em sinais de EEG. Travessa (2006) realizou uma análise do desempenho das redes neurais complexas de múltiplas camadas (CMLP) na discriminação das espículas e piscadas em sinais de EEG.

1.1. Motivação

Sabe-se hoje que uma grande parcela da população mundial sofre de distúrbios do sono (WORLD HEALTH ORGANIZATION, 2004; OHAYON E GUILLEMINAULT, 2006). Tais distúrbios, caso não sejam tratados, podem acarretar diversos problemas à saúde do indivíduo portador, como disfunções sexuais, alterações no sistema respiratório e cardiovascular, disfunções no sistema nervoso, estresse, entre outros (GILLIN, 1998; REETH *et al.*, 2000; SUSMAKOVA, 2004; GOURINENI E ZEE, 2006). Desta forma, é notória a contribuição do sono para manutenção de uma boa saúde.

Os complexos K e os fusos do sono são padrões característicos do estágio II do sono NREM e são de fundamental importância no estagiamento do sono, visto que este estágio ocupa cerca de 44 a 55% do sono total em indivíduos normais (RAMA *et al.*, 2006). A detecção destes padrões, no entanto, é uma tarefa bastante complexa e é, em geral, a etapa mais crítica do estagiamento do sono. A motivação deste trabalho, então, encontra-se na perspectiva de auxiliar o diagnóstico de doenças relacionadas ao sono, bem como no próprio processo de classificação deste em vários estágios.

1.2. Justificativas

Uma das formas de analisar a qualidade do sono de um indivíduo é através do exame polissonográfico. Tal exame consiste em registrar várias variáveis fisiológicas do paciente, enquanto este dorme. A análise desses registros, no entanto, é uma tarefa bastante

cansativa que consome muito tempo por parte do especialista. Uma automatização deste processo, então, foi naturalmente sendo discutida. Desta forma, a diminuição do tempo de análise dos registros polissonográficos, assim como a busca por um método eficiente e estável justificam o desenvolvimento deste trabalho.

O uso de redes neurais artificiais e análise de variáveis canônicas justificam-se pela habilidade destas em: resolver problemas não-lineares; processar paralelamente as informações; generalizar; fornecer uma descrição das diferenças entre grupos especificados a priori em um conjunto de dados multivariados; dentre outras. A utilização da transformada wavelet como ferramenta do sistema desenvolvido, por sua vez, deveu-se à sua competência em analisar sinais não-estacionários, remover ruídos, detectar discontinuidades, identificar frequências puras, analisar a informação contida no sinal em diferentes escalas, entre outras vantagens. Além disso a transformada wavelet, assim como a transformada de Fourier, possui um algoritmo rápido, *Fast Wavelet Transform* (FWT), que possibilita um rápido processamento dos sinais de EEG.

1.3. Objetivo Geral

Este trabalho tem como objetivo principal desenvolver e comparar duas metodologias para classificação de complexos K e fusos do sono, a fim de contribuir com os sistemas já existentes para estagiamento do sono.

1.4. Objetivos Específicos

Para alcançar o objetivo geral mencionado anteriormente, julgou-se necessário a realização das seguintes tarefas:

1. Desenvolver uma metodologia para detecção dos padrões específicos do estágio II do sono NREM em sinais de eletroencefalograma utilizando redes neurais artificiais (RNA);
2. Desenvolver uma metodologia para detecção dos padrões específicos do estágio II do sono NREM em sinais de eletroencefalograma utilizando análise de variáveis canônicas (AVC);

3. Extrair parâmetros dos sinais de eletroencefalografia que possibilite a discriminação dos padrões específicos do sono;
4. Desenvolver um software que proporcione a detecção de complexos K e fusos do sono, utilizando cada uma das duas metodologias propostas;
5. Comparar o desempenho da metodologia baseada em RNA com o da metodologia baseada em AVC.

1.5. Organização do Documento

O conteúdo didático deste trabalho está dividido em sete capítulos e um apêndice, além das referências bibliográficas. O Capítulo 2, a seguir, descreve uma revisão sobre o sono em seres humanos. Em seguida, o Capítulo 3, introduz uma revisão sobre as ferramentas matemático-computacionais utilizadas neste trabalho. O Capítulo 4, por sua vez, trata da explanação da metodologia proposta. Já o Capítulo 5 detalha o funcionamento do software desenvolvido ao longo deste trabalho. O Capítulo 6 apresenta, então, os procedimentos utilizados nos testes das metodologias, bem como os resultados de cada uma destas. Por fim, as conclusões deste trabalho e as sugestões para trabalhos futuros são apresentadas no Capítulo 7. O Apêndice A apresenta uma introdução ao estudo da eletroencefalografia, fazendo uma revisão do tema e apresentando o padrão internacional 10-20 de posicionamento de eletrodos.

Capítulo 2

O Sono

Durante séculos, o sono foi considerado uma espécie de tempo perdido e servia apenas para repor as energias gastas durante o dia. Essa concepção, no entanto, começou a ser desmontada na primeira metade do século XX, mas foi somente nos últimos dez anos, com os avanços nos estudos da genética, da biologia molecular e da neuroquímica, que a maioria dos médicos teve a atenção despertada para a fisiologia e o real papel do repouso noturno na preservação da saúde.

O sono é um estado fisiológico especial que ocorre de maneira cíclica em uma grande variedade de seres vivos do reino animal. Nos seres humanos, o sono é caracterizado por cinco estágios fundamentais, que se diferenciam de acordo com o padrão do eletroencefalograma (EEG) e a presença, ou ausência, de movimentos oculares rápidos (*rapid eye movements*: REM), além de mudanças em outras variáveis fisiológicas, como o tônus muscular e o padrão cardio-respiratório.

Os estudos relacionados ao sono começaram na década de 30 e estão fortemente relacionados à invenção da eletroencefalografia. Em 1937, Loomis (*apud* RODRIGUES, 2002, p. 1), um fisiologista americano, foi o primeiro a observar que o sono não é um estado homogêneo durante toda noite e descreveu, portanto, diferentes estágios de sono baseado nos diferentes níveis de atividade do EEG. Em 1953, Aserinsky e Kleitman (*apud* FERNANDES, 2006, p. 158) observaram um estado especial do sono, no qual o padrão do EEG era similar ao estado de vigília, porém o eletrooculograma (EOG) apresentava um padrão de rápidos movimentos oculares (*rapid eye movements* - REM), além de haver um aumento nas taxas respiratória e cardíaca (RECHTSCHAFFEN E KALES, 1968), ao contrário dos outros estágios do sono. Seus estudos mostraram que a maioria das pessoas quando acordadas durante o sono REM lembravam-se de seus sonhos, enquanto que boa parte dos indivíduos acorda-

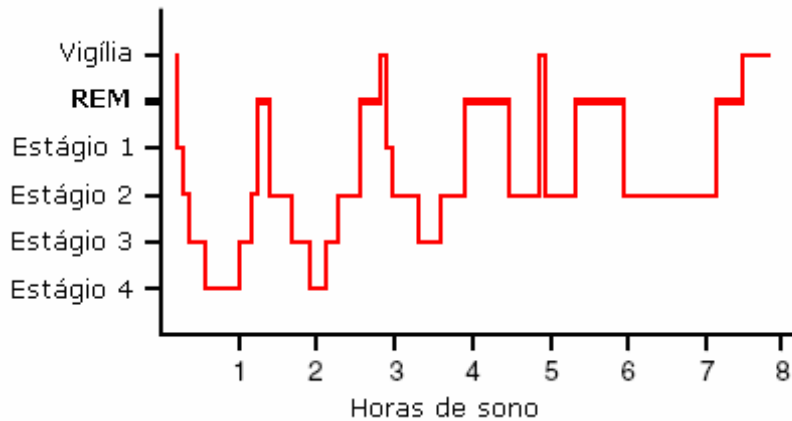


Figura 2.1 - Ciclo sono-vigília (hipnograma). Adaptado de (RAMA *et al.*, 2006)

dos durante o sono não-REM (NREM) eram desprovidos de atividade onírica¹. Com isso, concluiu-se que os sonhos aconteciam principalmente durante o sono REM. Em 1953, Aserinsky e Kleitman (*apud* SUSMAKOVA, 2004, p. 59) também dividiram o sono NREM em quatro estágios que vão do 1 ao 4 a medida que o sono vai se tornando mais profundo. Posteriormente, em 1957, Dement e Kleitman (*apud* HIMANEM E HASAN, 2000, p. 150) especificaram o padrão cíclico do sono REM-NREM.

Atualmente, o sono pode ser dividido em duas fases principais: o sono REM e o sono NREM. Este último pode, ainda, ser dividido em quatro sub-estágios, que vão desde o sono mais leve, no estágio I, até o sono mais profundo, no estágio IV. Os estágios III e IV são também conhecidos como sono de ondas lentas. Durante uma noite normal de sono, há uma alternância entre os estágios REM e NREM, como pode ser visto na Figura 2.1.

2.1. O Ciclo do Sono

O sono, ao contrário do que se pensava, não é um processo simples e monótono durante toda a noite. Hoje, sabe-se que, durante uma noite normal de sono, este pode se dividir em fases bem distintas entre si.

Loomis *et al.* (*apud* NIEDERMEYER E SILVA, 1993, p. 155), em seus experimentos, notaram que, durante o sono, os padrões morfológicos do EEG modificavam-se ao longo da noite e, adicionalmente, havia certa periodicidade nesses padrões. Com isso, Loomis

¹ Relativo a, ou próprio de sonhos.

Tabela 2.1 - Classificação do sono segundo Loomis (*apud* NIEDERMEYER E SILVA, 1993, p. 155).

ESTÁGIO	ESTADO DE CONSCIÊNCIA	RESUMO DAS CARACTERÍSTICAS DO EEG
A	Acordado	Predominância das ondas alfa
B ₁	Leve Sonolência	Desaparecimento das ondas alfa
B ₂	Sonolência Profunda	Ocorrência de ondas do tipo <i>vertex</i>
C	Sono Leve	Aparição de complexos K e fusos do sono
D	Sono Profundo	Ondas lentas, com surgimento de complexos K e alguns fusos do sono
E	Sono Muito Profundo	Ondas muito lentas e ocorrência de alguns complexos K

tornou-se um dos pioneiros no estagiamento do sono. De acordo com sua terminologia, o sono poderia ser classificado conforme a Tabela 2.1.

Essa classificação, no entanto, foi feita antes da descoberta do sono REM e, devido à falta de informação, havia certos intervalos de tempo onde o sono era catalogado como “estágio nulo”. Após a descoberta do sono REM, em 1957, Dement e Kleitman (*apud* NIEDERMEYER E SILVA, 1993, p. 155) dividiram os diferentes estágios do sono de acordo com a Tabela 2.2, cuja terminologia ainda é usada atualmente.

Os cinco estágios do sono ocorrem ciclicamente e o primeiro ciclo, que dura cerca de 90 minutos, termina após o fim do primeiro episódio de sono REM, o qual, a cada ciclo subsequente, tende a demorar um pouco mais (FERNANDES, 2006). De modo inverso, os episódios de sono REM vão se prolongando à medida que o sono prossegue durante a noite, como demonstra a Figura 2.1.

Tabela 2.2 - Estágios do sono segundo Dement e Kleitman (*apud* NIEDERMEYER E SILVA, 1993, p. 155).

ESTÁGIO	ESTADO DE CONSCIÊNCIA	RESUMO DAS CARACTERÍSTICAS DO EEG
W	Acordado	Predominância das ondas alfa e baixos níveis de amplitude
1	Sonolência	Desaparecimento das ondas alfa e surgimento de ondas do tipo <i>vertex</i>
2	Sono Leve	Ocorrência de fusos do sono, complexos K e ondas <i>vertex</i>
3	Sono Profundo	Ondas lentas com complexos K e alguns fusos do sono
4	Sono Muito Profundo	Ondas bastante lentas com alguns complexos K
REM	Sono REM	Assincronia com altas frequências, semelhante a vigília

Em condições normais, um indivíduo inicia o sono noturno pelo estágio I após um tempo de latência de dez minutos. Depois de permanecer alguns minutos no estágio I, o sono aprofunda-se para o estágio II, tornando o despertar do indivíduo mais difícil. Posteriormente, 30 a 60 minutos após o início do sono, instala-se o sono de ondas lentas (estágios III e IV, respectivamente) com interpenetrações de ambos no decorrer desta etapa mais profunda do sono NREM. Passados 90 minutos após o início do sono, em geral, acontece o primeiro episódio do sono REM, que costuma ter curta duração no início da noite (FERNANDES, 2006).

No sono NREM há um relaxamento muscular acentuado comparado com a vigília e o EEG exhibe um aumento progressivo de ondas lentas, conforme o sono avança do estágio I para o estágio IV do sono NREM. Os estágios III e IV do sono NREM, por sua vez, aparecem principalmente na primeira metade do sono e vão desaparecendo à medida que este avança durante a noite, como mostra a Figura 2.1.

Durante o sono, os indivíduos apresentam-se com um repertório limitado de movimentos, os quais são de natureza involuntária, automática e sem propósitos definidos. O indivíduo também permanece de olhos fechados, ou entreabertos, e não mostra interação produtiva com o meio ambiente (FERNANDES, 2006). Ademais, a reatividade a estímulos auditivos, visuais ou tácteis é reduzida, ou até mesmo abolida, com relação à vigília.

2.1.1. Estágio W (acordado)

Quando uma pessoa está acordada, geralmente, o cérebro está ocupado com alguma tarefa. Os padrões vistos no EEG, então, indicam alta atividade cerebral, com predominância do ritmo alfa e baixas amplitudes, como mostra a Figura 2.2². Além disso, o eletrooculograma indica movimentos amplos dos olhos.

Não está claro, no entanto, se períodos de onda alfa durante o sono são exclusivamente sinais de vigília. Segundo Kubicki *et al.* (1985) há pelo menos dois diferentes tipos de atividade alfa que possuem diferentes frequências e topografia. Uma é o ritmo alfa occipital de 8 a 12 Hz relacionado à vigília e o outro é um ritmo alfa com frequência inferior

² As figuras de registros polissonográficos ilustradas neste trabalho foram obtidas por meio de um software desenvolvido ao longo do trabalho. Tais registros consistem em quatro canais de eletroencefalograma (C3-A1, C4-A2, O1-A1 e O2-A2), dois canais de eletrooculograma (direito e esquerdo) e um canal de eletromiograma (mento).




Figura 2.2 - Registro polissonográfico durante a vigília.

(cerca de 2 Hz mais lenta) localizado na região centro-frontal, que está presente na sonolência e no sono profundo (HIMANEN E HASAN, 2000). A Figura 2.3 ilustra o espectro dos sinais de EEG da Figura 2.2 nas derivações O1 e O2.

Este estágio é geralmente, porém não necessariamente, acompanhado por uma tonicidade relativamente alta no registro de eletromiograma (EMG), além da presença de episódios de REM e piscada dos olhos no registro de EOG.

2.1.2. Estágio I do Sono NREM (Sonolência)

O sono NREM dura cerca de 75 a 80% do sono total. O estágio I do sono NREM, por sua vez, ocupa apenas de 3 a 8% e ocorre mais frequentemente como transição da vigília para outros estágios mais profundos, ou então surge em resposta a estímulos durante o sono (RAMA *et al.*, 2006).

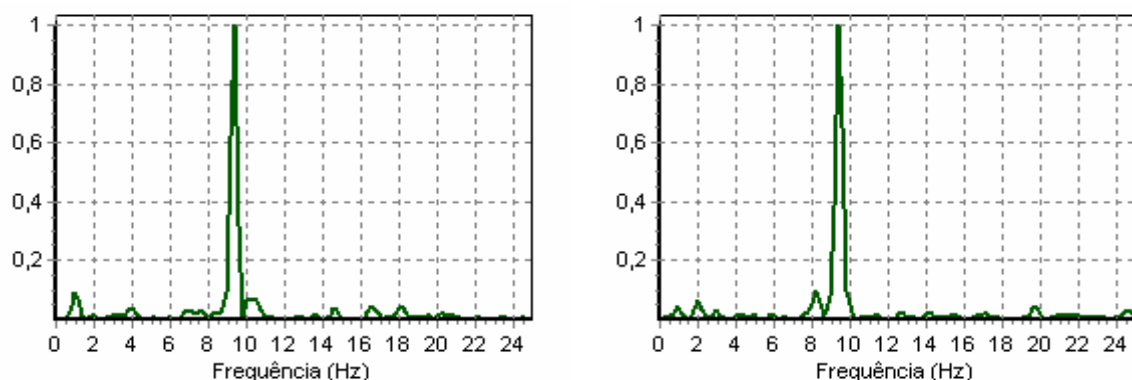


Figura 2.3 - Espectro normalizado das derivações O1 (esquerda) e O2 (direita) dos sinais de EEG mostrados na Figura 2.2. A FFT da derivação O1 é calculada no instante entre 12 e 16 segundos, enquanto a da derivação O2 é calculada entre 10 e 14 segundos.




Figura 2.4 – Registro polissonográfico durante o estágio I (sonolência) do sono NREM.

Em adultos, o estado de sonolência é caracterizado pela gradativa diminuição do ritmo alfa, que é substituído por ondas de baixa voltagem e baixa frequência (principalmente na faixa de 2 a 7 Hz), juntamente com ondas de baixa amplitude na faixa de 15 a 25 Hz, como mostra a Figura 2.4. A profundidade do estado de sonolência é associada a um realce de baixas frequências. Um exemplo do espectro do sinal de EEG desta fase do sono é mostrado na Figura 2.5.

Durante esse estágio, os olhos do indivíduo estão fechados, sua respiração se torna mais regular e os movimentos circulares dos olhos tornam-se mais lentos e suaves. Pessoas nesse estágio também estão menos cientes de seus arredores que durante o estágio da vigília, porém são facilmente despertadas de volta à total consciência. A sonolência pode ocorrer quando a pessoa está adormecendo, enquanto assiste TV, lê ou escuta alguma leitura




Figura 2.5 - Espectro normalizado das derivações C3 (esquerda) e C4 (direita) do sinal de EEG mostrado na Figura 2.4. A frequência predominante está em torno de 3 Hz, porém podemos encontrar ondas na faixa de até 25 Hz. A FFT da derivação é calculada no intervalo de tempo entre 0 e 4 segundos, enquanto que a da derivação C4 é calculada entre 8 e 12 segundos.

desagradável. O estágio I começa cerca de 5 a 10 minutos após o começo do sono e, como já mencionado outrora, ocupa uma pequena percentagem do tempo total do sono (cerca de 5%) em adultos saudáveis. Durante o sono noturno, este estágio tende a ser bastante curto, durando cerca de 1 a 7 minutos.

Uma característica marcante da sonolência é o aparecimento das *ondas vertex*, que surgem durante os momentos finais deste estágio, geralmente em conjunto com uma atividade entre 2 e 7 Hz de alta amplitude (RECHTSCHAFFEN E KALES, 1968). Essas ondas indicam um estado alterado da capacidade de resposta cerebral e representam um evento evocado, assim como o complexo K, discutido posteriormente (NIEDERMEYER E SILVA, 1993).

A onda *vertex*, também conhecida como onda V, é composta de um pico de descarga positiva seguido de uma larga descarga de onda negativa, a qual é geralmente a característica mais proeminente da descarga. Sua larga amplitude quase sempre se diferencia do resto do registro de EEG e podem aparecer como um evento isolado ou em rajadas com frequência de aproximadamente 1,0 Hz (NIEDERMEYER E SILVA, 2003).

Para que uma época seja definida como estágio I do sono, é necessário uma ausência total de complexos K e fusos do sono. Ademais, a sonolência é caracterizada pela presença de movimentos lentos dos olhos no registro de EOG e uma tonicidade no EMG geralmente menor se comparado à vigília (RECHTSCHAFFEN E KALES, 1968).

2.1.3. Estágio II do Sono NREM (Sono Leve)

Nesse estágio a pessoa já está dormindo de fato, ainda que não profundamente. O estágio II tem uma duração aproximada de 5 a 15 minutos e caracteriza-se por um EEG com frequências de ondas mais lentas, com episódios de fusos do sono e complexos K. Despertares por estimulação tátil, fala ou movimentos corporais são mais difíceis do que no estágio anterior. Nesta fase do sono a atividade onírica já pode surgir sob a forma de sonhos com uma história integrada.

Esse estágio caracteriza-se principalmente pelo aparecimento de potenciais evocados como as ondas *vertex*, os complexos K e os fusos do sono. A atividade de fundo do EEG mostra uma considerável variação, com baixas frequências que vão de 0,75 até 4 Hz, com amplitudes moderadas, e altas frequências que estão entre 15 e 30 Hz. A Figura 2.6 mostra um registro polissonográfico típico da segunda fase do sono, com aparições de




Figura 2.6 - Registro polissonográfico durante o estágio II do sono NREM com aparições de complexos K e fusos do sono.

complexos K e fusos do sono. A Figura 2.7, por sua vez, ilustra o espectro das derivações C3 e C4 dos sinais de EEG, mostrados na Figura 2.6, em determinados instantes de tempo.

O começo do estágio II do sono NREM é definido pela primeira aparição de um fuso do sono (FS), com freqüência entre 13 e 14 Hz, ou um complexo K (CK) imerso em uma atividade de fundo de EEG de baixa voltagem (HIMANEM E HASAN, 2000).

Complexos K

Os CKs, primeiramente descritos por Loomis (1938), aparecem principalmente durante o estágio II do sono NREM e constituem uma resposta a estímulos excitatórios. O CK é um padrão de onda do EEG que reflete uma seqüência de potenciais de repolarização




Figura 2.7 - Espectro normalizado do EEG durante o estágio II do sono NREM. À esquerda temos a FFT do sinal na derivação C3 nos instantes entre 16 e 20 segundos. À direita, a FFT da derivação C4 no intervalo entre 18 e 22 segundos, onde ocorre um complexo K. As derivações mencionadas referem-se ao registro de EEG da Figura 2.6.

e hiperpolarização da membrana dos neurônios corticais, onde ele é gerado como parte de uma lenta oscilação ($<1,0$ Hz) do sono (AMZICA E STERIADE, 2002).

Com respeito à morfologia da onda, o complexo K consiste, como mostra a Figura 2.8, em uma onda inicial aguda, seguida de uma componente lenta que pode, ou não, se sobrepor a uma componente rápida. A componente aguda do complexo é bifásica e não raramente multifásica. Sua forma assemelha-se a uma onda *vertex* isolada, no entanto as componentes agudas dos complexos K mostram mais complexidade e maior variabilidade entre complexos. A componente lenta do complexo K é representada por uma onda que pode exceder até um segundo (1 seg) de duração, sobreposta a feixes de 12 a 14 Hz, que representam a componente rápida do complexo (NIEDERMEYER E SILVA, 1993).

Os primeiros estágios do sono são caracterizados por CKs pouco regulares, uma vez que oscilações lentas aparecem menos organizadas e sincronizadas. No entanto, com o aprofundamento do sono, a oscilação lenta torna-se mais regular e rápida (frequência perto de 1,0 Hz). Durante os últimos estágios do sono, a maioria dos CKs podem ser confundidos com as ondas delta (AMZICA E STERIADE, 2002). Adicionalmente, os CKs duram cerca de 250ms nos primeiros momentos do sono e chegam a durar mais de um segundo nos estágios mais avançados (AMZICA E STERIADE, 1997). Nota-se, portanto, que existe uma dependência morfológica, espacial e temporal do CK com o nível de profundidade do sono do indivíduo. A densidade de CKs, no entanto, é maior durante o estágio II do sono NREM (PAIVA E ROSA, 1991).

O complexo K também muda sua morfologia à medida que o indivíduo torna-se mais velho. O CK é mais largo em crianças e em pré-adolescentes: a componente aguda é




Figura 2.8 - Exemplos de morfologia de alguns complexos K. Estes podem variar muito, até mesmo num mesmo indivíduo. A duração de cada janela é de aproximadamente 1 segundo. A amplitude está normalizada, de modo que o valor mínimo seja -1 e o máximo seja igual a 1.

particularmente muito larga nessa época. Por outro lado, com o avanço da idade do indivíduo o complexo K mostra uma diminuição em sua amplitude e geralmente evolui para um insignificante potencial lento com ondas parecidas com fusos sobrepostas (NIEDERMEYER E SILVA, 1993).

Fusos do Sono

A ocorrência de fusos do sono geralmente é sinal de sonolência ou sono leve e marcam a transição da vigília, com baixa amplitude e altas frequências, para o sono de ondas lentas ou inconsciência, com amplitudes elevadas. Assim, o começo do sono está relacionado com a aparição de fusos do sono no estágio I, que intensificam-se durante o estágio II e, à medida que o sono torna-se mais profundo (estágios III e IV), tornam-se cada vez mais escassos, reduzindo sua amplitude e sua frequência interna. Além disso, a quantidade de FS é reduzida em indivíduos com privação de sono (ZYGIEREVICZ, 2000).

Embora possa aparecer em outros estágios, o fuso do sono é um padrão de onda característico do estágio II do sono NREM em humanos e é também um dos poucos eventos transientes do EEG que ocorrem somente durante o sono (GENNARO E FERRARA, 2003). Por estas razões, o FS tem sido usado no famoso método de escoreamento padrão de Rechtschaffen e Kales (1968).

Primeiramente descrito por Berger, em 1929, e posteriormente por Loomis, em 1938, o FS teve sua primeira definição amplamente aceita dada por Rechtschaffen e Kales (1968), definindo-os como oscilações de 12 a 14 Hz, cuja amplitude primeiro intensificasse, atenuando-se logo em seguida. Possui, também, uma duração mínima de 0,5 segundos. A Figura 2.9 mostra alguns exemplos de fusos do sono.




Figura 2.9 - Fusos do sono. Todas as três janelas estão com suas amplitudes normalizadas e a escala de tempo é de um segundo, aproximadamente, para cada janela.

Os fusos do sono são gerados por oscilações síncronas dos neurônios talâmicos e são distribuídos pelo córtex através dos axônios talamocorticais (GENNARO E FERRARA, 2003; GORUR *et al.*, 2002). Seus potenciais de campo combinados produzem um sinal que pode ser detectado via sinal de EEG. Essa atividade é gerada como uma consequência tanto das propriedades intrínsecas da membrana dos neurônios envolvidos como de suas interações sinápticas (STERIADE *et al.*, 1993). Os fusos do sono também refletem a atividade do sistema de controle sono-vigília (ZYGIEREVICZ, 2000).

Várias mudanças nos parâmetros dos FS ocorrem com o avanço da idade. Comparações entre indivíduos jovens, de meia idade e idosos mostraram que geralmente ocorre uma diminuição na frequência, densidade e amplitude do fuso com o envelhecimento do indivíduo. (GUAZZELLI *et al.*, 1986; NICOLAS *et al.*, 2001; GENARRO E FERRARA, 2003). Distúrbios neurológicos também têm influência nas características dos fusos do sono. A frequência dos FS, por exemplo, é significativamente menor em pacientes com epilepsia generalizada do que em pacientes com crises parciais. Os mecanismos responsáveis por essas mudanças morfológicas nos FS, entretanto, ainda não são conhecidos (ZYGIEREVICZ, 2000).

2.1.4. Estágio III do Sono NREM

Juntamente com o estágio IV do sono NREM, esta etapa é conhecida como sono de ondas lentas (*Slow Wave Sleep - SWS*) e ocorre com maior frequência na primeira metade do sono. A Figura 2.10 apresenta uma época de um registro polissonográfico durante a fase




Figura 2.10 – Registro polissonográfico durante o início do sono profundo (estágio III do sono NREM). As ondas delta ocupam entre 20 e 50% de uma época.




Figura 2.11 - Transformada de Fourier da derivação C3 entre 0 e 4 segundos (à esquerda) e da derivação C4 entre 12 e 16 segundos (à direita). As derivações citadas são referente à Figura 2.10.

III do sono NREM. O espectro das derivações C3 e C4 dos sinais de EEG, para certos instantes de tempo, podem ser observados na Figura 2.11.

Esse estágio é o começo do sono profundo: uma transição do estágio II para o estágio IV. Nele, a lenta atividade de fundo começa a dominar os traços do EEG. Frequências delta, na faixa de 0,75 até 3 Hz, com amplitudes maiores que $75 \mu\text{V}$, de pico a pico, ocupam cerca de 20 até, no máximo, 50% do tempo total de uma época³. Fusos do sono ainda aparecem esporadicamente, embora estejam camuflados pela grande amplitude das ondas delta (NIEDERMEYER E SILVA, 1993). Os sinais de EOG mostram imperceptíveis movimentos oculares e o sinal de EMG apresenta tonicidade quase nula (RAMA *et. al.*, 2006).

2.1.5. Estágio IV do Sono NREM (Sono Profundo)

É extremamente difícil acordar alguém nessa fase de sono. Este estágio NREM do sono caracteriza-se pela secreção do hormônio do crescimento em grandes quantidades promovendo a síntese protéica, o crescimento e reparação tecidular, inibindo, assim, o catabolismo. O sono NREM desempenha, desta forma, um papel anabólico, sendo essencialmente um período de conservação e recuperação de energia física.

O estágio IV do sono NREM tem os mesmos atributos do estágio III, porém as ondas deltas, com baixa frequência (entre 0,5 e 3 Hz) e altas amplitudes (maior que $75 \mu\text{V}$ de pico a pico) aparecem em mais de 50% da época. Assim como no estágio III, percebe-se uma tonicidade quase nula no sinal de EMG e os movimentos dos olhos, registrados no

³ Uma época é considerada uma janela do registro do EEG. Neste trabalho, as janelas têm duração de trinta segundos (30 s), portanto uma época equivale a trinta segundos do registro.




Figura 2.12 – Registro polissonográfico típico do sono profundo (estágio IV do sono NREM) com predominância de altas amplitudes e baixas frequências durante a maior parte de uma época.

sinal de EOG, são quase imperceptíveis (RAMA *et. al.*, 2006). A Figura 2.12 mostra uma época de um registro polissonográfico durante o estágio IV da fase NREM de um sono normal. A Figura 2.13, por sua vez ilustra os espectros das derivações C3 e C4 dos sinais de EEG desta época.

Este estágio ocorre principalmente durante o primeiro terço da noite e ocupa cerca de 10 a 15% do sono total. O registro de eletromiograma mostra pouca, ou quase nenhuma, atividade muscular, assim como os registros de eletrooculograma indicam imperceptíveis movimentos oculares⁴.




Figura 2.13 – Espectro normalizado da derivação C3 entre 8 e 12 segundos (à esquerda) e da derivação C4 entre 10 e 14 segundos (à direita). As derivações citadas são referentes à Figura 2.12.

⁴ A atividade registrada nos canais de EOG da Figura 2.10 e da Figura 2.12 são devido à interferência da atividade nos canais de EEG e não devido aos movimentos oculares, uma vez que estes se caracterizam por registros anti-simétricos nos dois canais de EOG.

2.1.6. Sono REM

O sono REM ocupa cerca de 20 a 25 % do sono total. O primeiro episódio de sono REM ocorre 60-90 minutos após o começo do sono NREM e dura aproximadamente dez minutos. Os episódios seguintes vão ficando cada vez mais demorados até chegar ao último, que dura cerca de uma hora. O padrão do EEG durante esta fase é caracterizado por uma baixa voltagem e uma atividade mista de frequência, com ondas alfa (1 a 2 Hz mais lentas que as ondas alfa da vigília) e teta (RAMA *et al.*, 2006), como mostra a Figura 2.14. O espectro de duas derivações desta pode ser visto na Figura 2.15.

O nome REM, como já dito anteriormente, vem de “*Rapid Eye Movements*”, que em português significa movimento rápido dos olhos, ou seja, esta fase do sono caracteriza-se principalmente pelo aparecimento de rápidos movimentos oculares no registro de EOG. O sinal de EMG, por sua vez, apresenta a tonicidade mínima registrada durante a noite.

O padrão do EEG durante o sono REM assemelha-se àquele descrito para o estágio I do sono NREM, exceto pelo fato de as ondas *vertex* não estarem presentes na fase REM. Adicionalmente, no estágio REM, ondas do tipo “dente-de-serra” aparecem nas regiões frontal e central, juntamente com rajadas de REM no sinal de EOG. A atividade alfa do sono REM é mais proeminente que no estágio I e sua frequência é geralmente de 1 a 2 Hz mais lenta se comparada com a vigília (RECHTSCHAFFEN E KALES, 1968). Assim como no EEG do estágio I, é necessária a total ausência de complexos K e fusos do sono para que uma época seja marcada como pertencente ao estágio REM do sono.




Figura 2.14 - Registro polissonográfico durante o sono REM, com uma mistura de ondas alfa, na faixa de 1 a 2 Hz, e ondas teta.




Figura 2.15 – Espectro normalizado da derivação C3 entre 4 e 8 segundos (à esquerda) e da derivação C4 entre 0 e 4 segundos (à direita). As derivações citadas são referentes à Figura 2.14.

O sinal de EEG de uma pessoa durante o sono REM apresenta um padrão que mostra intensa atividade cerebral. Adicionalmente, se uma pessoa for acordada durante esta fase, ela dirá que estava sonhando justamente na hora em que foi acordada, pois nesta fase do sono a atividade onírica é intensa. Deste modo, devido à intensa atividade do cérebro e ao fato da pessoa estar sonhando, o sono REM é também denominado por vários autores como sono paradoxal, podendo até mesmo falar-se em estado dissociativo.

O sono REM é distinguível do sono NREM por mudanças nos estados fisiológicos, incluindo seu característico movimento rápido dos olhos. Considerando-se uma noite de sono normal, ou seja, em pessoas sem distúrbios do sono, as taxas cardíaca e respiratória aceleram-se e tornam-se irregulares durante o sono REM, enquanto que os músculos do rosto, dos dedos e das pernas contraem-se. Os sonhos ocorrem com maior intensidade como um resultado de uma intensificação da atividade cerebral, no entanto paralisia ocorre simultaneamente na maior parte dos grupos musculares voluntários, incluindo os músculos submentais (músculos do queixo e do pescoço). Essa atonia muscular pode ser associada ao fato de manter o corpo incapacitado de atuar durante os sonhos, que ocorrem durante intensa atividade cerebral.

Baseado nas características do EEG, EMG e do EOG, o sono REM pode ser dividido em 2 estágios: tônico e fásico (MARKS, 2006). As características do estágio tônico incluem assincronia do EEG, atonia dos grupos musculares esqueléticos e supressão dos reflexos monossinápticos e polisinápticos. O sono REM fásico caracteriza-se pelo movimento rápido dos olhos em todas as direções, assim como oscilações transientes na pressão san-

guínea, mudanças na frequência cardíaca, respiração irregular, movimentos da língua e contrações dos músculos do queixo e dos membros (MARKS, 2006; RAMA *et al.*, 2006).

2.2. Funções do Sono

Nos últimos cinquenta anos, os estudos relacionados ao sono contaram com importantes progressos relativos à neurobiologia, regulação e genética do sono. Os mecanismos responsáveis pela inicialização do sono e da vigília (SAKAI E CROCHET, 2003) e pela geração do sono REM e NREM (REINOSO-SUÁRES *et al.*, 2001), por exemplo, foram identificados, assim como os processos por trás da geração de ondas como o complexo K e o fuso do sono (AMZICA E STERIADE, 2002; GENNARO E FERRARA, 2003). Além disso, genes e substâncias químicas fundamentais no processo do sono vêm sendo descobertos (FRANK, 2006). Por outro lado, apesar de todos esses avanços, ainda não se sabe, de fato, porque dormimos.

Várias teorias têm sido propostas com o intuito de explicar a real funcionalidade do sono. Decerto, é impressionante a abundância de teorias concorrentes com respeito ao real papel desempenhado pelo sono. De acordo com tais teorias, o sono é importante para processos somáticos anabólicos, resfriamento do cérebro, restauração de moléculas do cérebro, remoção de toxinas, além de desempenhar funções de alta-ordem, tais como maturação cerebral e consolidação da memória (KRUEGER *et al.*, 1999; POWER, 2004; SUMASKOVA, 2004; FRANK, 2006).

2.2.1. Teorias Somáticas x Teorias Neurais

A princípio, nenhuma teoria referente à funcionalidade do sono é completa no sentido de esclarecer todos os mistérios acerca de tal assunto. No entanto, cada teoria representa uma contribuição para o entendimento do real papel do sono de um ponto de vista global.

Uma vez que são várias as teorias acerca da importância do sono, estas podem ser agrupadas em duas classes: as teorias somáticas e as teorias neurais. As teorias somáticas da funcionalidade do sono sugerem que o sono facilita os processos anabólicos ou restaura algumas funções corpóreas desgastadas durante a vigília (TAKAHASHI *et al.*, 1968; KRUEGER *et al.*, 1999; FRANK, 2006). As teorias neurais, por outro lado, afirmam que o sono é

fundamentalmente um processo de restauração cerebral e são subdivididas em duas categorias: metabólicas e cognitivas (FRANK, 2006).

As teorias metabólicas propõem que o sono desintoxica substâncias que são acumuladas durante a vigília, ou restaura e repara substratos neurais degradados pela vigília. As teorias cognitivas, por sua vez, sugerem que o sono tem propósitos de alta-ordem, como desenvolvimento neural ou consolidação da memória (SUSMAKOVA, 2004; POWER, 2004; FRANK, 2006).

Capítulo 3

Fundamentação Teórica

Antes de explicar o funcionamento do sistema propriamente dito, é necessária a revisão de algumas ferramentas matemático-computacionais aplicadas neste trabalho. Desta forma, este capítulo dedica-se a esclarecer os conceitos teóricos utilizados neste trabalho, de forma a deixar o leitor mais a parte dos processos que arquitetam o sistema desenvolvido. Basicamente, este capítulo trata de revisar três ferramentas matemáticas: as redes neurais artificiais (RNA), as transformadas *wavelets* (TW) e a análise de variáveis canônicas (AVC). Além disso, uma abordagem estatística para validação de testes será introduzida.

3.1. Redes Neurais

A estrutura do cérebro humano organiza os neurônios, sua unidade elementar, de forma a realizar processamentos complexos, tais como reconhecer objetos e sons, com uma velocidade que nem o mais rápido processador digital até hoje fabricado poderia ao menos chegar próximo (HAYKIN, 2001). O uso de redes neurais artificiais, também chamadas apenas de redes neurais, tem sido motivado pela esperança de se encontrar um sistema que processe informação semelhante ao cérebro humano, de forma complexa, não-linear e com processamento paralelo.

As redes neurais tentam modelar toda a complexidade do sistema nervoso central. Assim, sua procura como ferramenta no desenvolvimento de sistemas se dá pela sua habilidade de aprender e de generalizar. A generalização de um problema pode ser entendida como a capacidade da rede de produzir saídas adequadas a entradas que não estavam na etapa de aprendizagem da rede. Estas duas características das redes neurais tornam possível o seu uso na resolução de problemas complexos que são, de outra forma, intratáveis. Segundo Aleksander e Morton (1990), adaptado por Haykin (2001):

Uma rede neural é um processador maciçamente e paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

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

O processo de aprendizagem, citado acima, é modelado pelo que é chamado de algoritmo de aprendizagem da rede neural, cujo objetivo é atualizar (modificar) os valores dos pesos sinápticos entre os neurônios da rede, de modo que a rede se “adapte” ao problema e “evolua” para achar uma solução.

3.1.1. Neurônio Biológico x Neurônio Artificial

Um neurônio biológico, como ilustra a Figura 3.1, é uma célula composta de um corpo celular e de finos prolongamentos celulares denominados neuritos, que podem ser subdivididos em dendritos e axônios.




Figura 3.1 - Neurônio biológico.

Os dendritos são prolongamentos geralmente muito ramificados e que atuam como receptores de estímulos, funcionando, portanto, como "antenas" para o neurônio. Os axônios são prolongamentos longos que atuam como condutores dos impulsos nervosos, podendo ramificar-se em suas extremidades. Um neurônio se comunica com outros neurônios através de sinapses, que consistem na junção entre um axônio de um neurônio com o dendrito de outro.

O neurônio artificial, apresentado na Figura 3.2, constitui-se de três elementos básicos: um conjunto de sinapses, um somador e uma função de ativação.




Figura 3.2 - Modelo não-linear de um neurônio artificial.

Cada sinapse é representada por um peso específico ($w_{k0}, w_{k1}, \dots, w_{km}$), que conecta um sinal de entrada a um neurônio. Especificamente, a entrada da j -ésima sinapse do neurônio k é multiplicada pelo peso sináptico w_{kj} , onde o primeiro índice se refere ao neurônio e o segundo a sinapse. Geralmente, em cada neurônio, adiciona-se uma sinapse com entrada fixa em +1 e peso sináptico igual a b_k . Essa sinapse é geralmente conhecida como *bias*, ou polarização, do neurônio k . O *bias* tem a função de aumentar ou diminuir a entrada líquida da função de ativação, de modo que v_k fique num intervalo linear da função de ativação.

A junção aditiva do neurônio soma os sinais de entrada ponderados pelos seus respectivos pesos sinápticos e entrega o sinal resultante, o campo local induzido (v_k), para a função de ativação, que, por sua vez, irá restringir a amplitude do sinal de saída do neurônio. Geralmente a amplitude de saída de um neurônio é restrita entre 0 e 1 (saída unipolar), ou, alternativamente, entre -1 e 1 (saída bipolar).

Matematicamente, podemos representar um neurônio artificial pelo seguinte par de equações:

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (3.1)$$

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

onde x_j é o j -ésimo sinal de entrada; w_{kj} é o j -ésimo peso sináptico do neurônio k ; b_k é o bias; v_k é o campo local induzido, ou seja, a saída do combinador linear; $\varphi(\cdot)$ é a função de ativação; y_k é a saída do neurônio, também chamada de sinal funcional.

A equação (3.1) considera a existência do bias como sendo um parâmetro externo ao neurônio. Alternativamente, pode-se considerar o bias como sendo uma entrada adicional do neurônio e, assim, as equações (3.1) e (3.2), de acordo com a Figura 3.2, podem ser reescritas da seguinte forma:

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (3.3)$$

$$y_k = \varphi(v_k) \quad (3.4)$$

onde $x_0 = +1$ e $w_{k0} = b_k$.

3.1.2. Topologias de Rede

Existem várias topologias de redes neurais artificiais e podemos identificar três classes principais de arquiteturas de rede que são bem diferentes entre si:

1. Redes diretas (*feedforward*) de uma camada;
2. Redes diretas de múltiplas camadas;
3. Redes recorrentes;

A primeira, e a mais simples, classe de arquitetura é a que se refere às redes *feedforward* de única camada, exemplificada na Figura 3.3. Nesta topologia a rede é composta por uma camada de nós de entrada que está diretamente ligada a uma camada de saída, com nós computacionais¹. Neste tipo de rede sua alimentação somente é feita no sentido adiante, ou seja, os dados entram na camada de entrada e saem na camada de saída. Não existe fluxo no sentido inverso.

¹ Aqui, os nós computacionais são aqueles que efetuam alguma operação matemática no sinal de entrada. Nós não computacionais são aqueles em que a saída é igual à entrada.




Figura 3.3 - Rede *feedforward* com camada única.

A segunda classe de topologia refere-se às redes alimentadas diretamente com várias camadas, sendo uma, ou mais, ocultas. Nessa arquitetura, sempre existirá a camada de entrada, com nós não-computacionais, seguida de uma ou mais camadas ocultas, que, por sua vez, antecederão a camada de saída, como mostra a Figura 3.4. A única diferença entre essa topologia e a mostrada anteriormente são os neurônios ocultos, que tem a finalidade de tornar a rede capaz de extrair características de ordem elevada do sinal. Pode-se dizer que essa é a topologia mais difundida e, por isso, juntamente com o conceito de *backpropagation*, é confundida com o conceito de rede neural, embora existam várias outras topologias.

Na Figura 3.4, temos uma rede totalmente conectada, onde todos os neurônios de uma camada conectam-se com todos os neurônios da camada seguinte. No entanto, alterna-




Figura 3.4 - Rede *feedforward* com múltiplas (três) camadas: uma de entrada, uma oculta e uma de saída.

tivamente, existem as redes parcialmente conectadas, onde algumas conexões sinápticas são perdidas.

A última classe é aquela que diz respeito às redes que possuem realimentação. Essa realimentação consiste em alimentar a entrada de um neurônio com a saída de outro neurônio situado na camada posterior, como mostra a Figura 3.5. Cada laço de realimentação possui um elemento de atraso unitário que proporciona um comportamento dinâmico à rede neural.

As redes recorrentes, assim como as redes de alimentação direta, podem, ou não, conter camadas ocultas. Além das realimentações mostradas na Figura 3.5, podemos encontrar auto-realimentações, que ocorrem quando a saída de um neurônio serve de entrada para ele próprio.

3.1.3. Algoritmo de Retropropagação do Erro

O conhecimento das redes neurais artificiais (RNA) se dá através da ponderação que os pesos da conexão entre os neurônios de diferentes camadas trocam entre si. Ou seja, encontrar solução para um determinado problema utilizando RNA seria, a grosso modo, encontrar a melhor topologia de rede, bem como ajustar corretamente os pesos das conexões entre os neurônios. A forma de aprendizado das RNAs podem ser classificadas em dois tipos: supervisionado e não supervisionado.




Figura 3.5 - Rede recorrente com a saída dos neurônios da camada de saída realimentando os neurônios da camada oculta.

O aprendizado supervisionado insere em sua estrutura uma espécie de professor que confere o quanto a rede está próxima de uma solução aceitável, adaptando na concepção do treinamento os pesos entre os neurônios, de modo a prover uma menor diferença entre as saídas desejadas e as obtidas.

Este trabalho foca apenas o tipo de aprendizado supervisionado, apresentando o algoritmo de treinamento *backpropagation*, o qual é a alternativa mais utilizada para treinamento de redes neurais diretas. A essência desse algoritmo é apresentar um padrão à rede neural, propagar os sinais funcionais através das camadas da rede, verificar o erro na saída da mesma e, através da retropropagação deste erro, fazer os ajustes necessários nos pesos sinápticos de modo que este erro seja minimizado. Estas instruções devem ser feitas até que se atinja um erro aceitável na saída da rede para todos os padrões de entrada.

Segundo Haykin (2001), o treinamento de uma rede neural direta através do algoritmo de retropropagação, se dá através de várias etapas, como mostrado a seguir:

1. Inicialização: o primeiro passo é escolher a topologia da rede, e os parâmetros da rede, tais como taxa de aprendizado, constante de momento, função de ativação, entre outros. O valor inicial dos pesos sinápticos da rede deve ser escolhido, caso não haja uma informação prévia, com base em uma distribuição uniforme com média zero e uma variância de tal forma que o desvio padrão dos campos locais induzidos se encontre entre as partes linear e a saturada da função de ativação.
2. Apresentação dos Padrões: deve-se apresentar uma época² dos padrões de treinamento para a rede, apresentando-os, de preferência, aleatoriamente, para cada época.
3. Propagação dos Sinais Funcionais: considerando que um exemplo de treinamento da rede, composto pelo padrão de entrada e a saída desejada, seja representado por $(x(n), d(n))$, devem-se calcular os campos locais induzidos e os sinais funcionais de todos os neurônios da rede, começando pela camada de entrada e seguindo até a camada de saída. O campo local induzido $v_j^{(l)}(n)$ e o sinal de saída do neurônio j da camada l são dados pelas equações (3.5) e (3.6), respectivamente.

² Um passo computacional em que todos os padrões foram apresentados à rede é chamado de época de treinamento.

$$v_j^{(l)}(n) = \sum_{i=0}^{m_0} w_{ji}^{(l)}(n) y_i^{l-1}(n) \quad (3.5)$$

$$y_j^{(l)}(n) = \varphi_j(v_j^{(l)}(n)) \quad (3.6)$$

onde m_0 é o número de entradas do neurônio j da camada l , $w_{ji}^{(l)}$ é o peso sináptico do neurônio j da camada l , que é alimentado pelo neurônio i da camada $l-1$, cuja saída é dada por $y_i^{l-1}(n)$.

Dois casos particulares da equação (3.6) acontecem quando o neurônio está situado na camada de entrada ou na camada de saída. No primeiro caso, deve-se fazer:

$$y_j^{(0)}(n) = x_j(n) \quad (3.7)$$

Caso o neurônio esteja na camada de saída, segue-se a seguinte notação:

$$y_j^{(L)}(n) = o_j(n) \quad (3.8)$$

onde L é a profundidade da rede e $o_j(n)$ é a saída da mesma, para o neurônio j , durante a n -ésima iteração. O cálculo do sinal de erro na saída do neurônio j é dado a seguir:

$$e_j(n) = d_j(n) - o_j(n) \quad (3.9)$$

O valor instantâneo da energia total do erro na saída da rede neural é obtido somando-se as energias instantâneas de cada neurônio na camada de saída, ou seja:

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (3.10)$$

onde C inclui todos os neurônios na camada de saída da rede. A Figura 3.6 mostra a curva de aprendizado de uma rede neural, onde podemos notar que o erro na saída da rede diminui com o número de iterações.

4. Retropropagação do Erro: nesta etapa devemos fazer o cálculo dos gradientes locais da rede, que são definidos pela equação (3.11), caso o neurônio esteja na camada de saída, ou pela equação (3.12), caso o neurônio seja oculto.

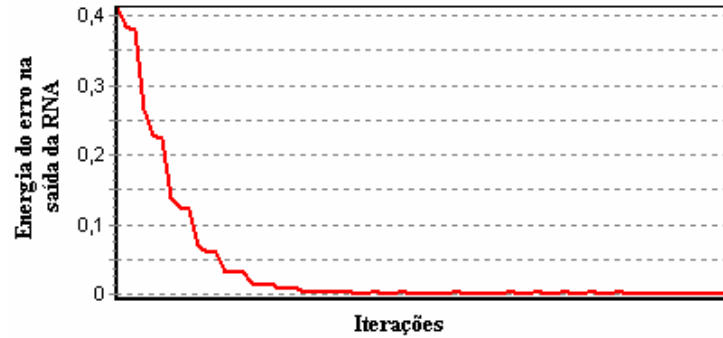


Figura 3.6 - Aprendizado de uma RNA *feedforward* com algoritmo de treinamento *backpropagation*. O erro na saída da rede neural tende a diminuir com o número de iterações. O aprendizado se dá através da correção dos valores dos pesos sinápticos dos neurônios.

$$\delta_j^{(l)}(n) = e_j(n) \cdot \varphi'_j(v_j^{(l)}(n)) \quad (3.11)$$

$$\delta_j^{(l)}(n) = \varphi'_j(v_j^{(l)}(n)) \cdot \sum_k \delta_k^{(l+1)}(n) \cdot w_{kj}^{(l+1)}(n) \quad (3.12)$$

onde $\varphi'(\cdot)$ indica a derivada de $\varphi(\cdot)$ com relação ao argumento. O ajuste dos pesos sinápticos da rede se dá baseado na regra delta e é definido segundo a equação (3.13).

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha \cdot w_{ji}^{(l)}(n-1) + \eta \cdot \delta_j^{(l)}(n) \cdot y_i^{(l-1)}(n) \quad (3.13)$$

onde η é a taxa de aprendizado da rede e α é a constante de momento.

3.2. Wavelets

A teoria *wavelet* fornece uma estrutura unificada para um grande número de técnicas que têm sido desenvolvidas independentemente para várias aplicações de processamento de sinais. Deste modo, levando em consideração sua natureza multidisciplinar, a transformada *wavelet* encontra aplicações bastante atrativas em diversas áreas, tais como filtragem não-linear, visão computacional, compressão de imagens e sinais, codificação de voz, matemática aplicada, entre tantas outras.

De fato, a teoria *wavelet* cobre uma área bastante vasta, uma vez que trata tanto do caso contínuo como do discreto e, além disso, fornece várias técnicas que podem ser aplicadas em diversos problemas em processamento de sinais e imagens. Em particular, a transformada *wavelet* (TW) é de interesse para a análise dos sinais, e imagens, não-

estacionários, uma vez que serve como alternativa à transformada de Fourier de tempo curto (STFT - *Short-Time Fourier Transform*), também conhecida como transformada de Fourier janelada (RIOUL E VETTERLI, 1991).

De um ponto de vista histórico, a análise *wavelet* é um novo método, apesar de suas raízes matemáticas estarem ligadas ao trabalho de Fourier, no século XIX. A atenção de pesquisadores, no entanto, vem se intensificando gradualmente, uma vez que tornou-se claro que um método que mede flutuações médias em diferentes escalas provou ser menos sensível a ruídos (MISITI *et al.*, 2006).

3.2.1. Transformada de Fourier de Tempo Curto

A transformada de Fourier (TF) demonstrou ser uma ferramenta muito poderosa na análise de sinais, no entanto ela tem tido bons resultados principalmente apenas em sinais estacionários, pois ao transformar o sinal para o domínio da frequência a informação temporal é perdida. Em alguns casos, essa perda de informação é bastante relevante e pode prejudicar o desempenho do sistema. Se as propriedades do sinal não variam muito com o tempo (sinal estacionário), não há tanta perda de informação. No entanto, a maioria dos sinais contém várias componentes transitórias ou não-estacionárias.

A Figura 3.7, por exemplo, ilustra um sinal com uma componente de aproximadamente 15 Hz entre 0,6 e 0,8 segundos. O espectro do sinal, no entanto, não nos fornece esse tipo de informação. O que o espectro do sinal revela é apenas que o sinal contém uma componente de 15 Hz, sem informar a localização temporal ou espacial desta.




Figura 3.7 - Transformação do sinal no domínio do tempo para o domínio das frequências, através da transformada de Fourier. Como a TF tem uma visão geral do sinal, ela não consegue localizar (temporalmente ou espacialmente) a componente de 15 Hz do mesmo.

Para tornar a análise do sinal mais eficaz seria necessário um método que considerasse a dependência da frequência em relação ao tempo. Em 1946, Dennis Gabor adaptou a transformada de Fourier para analisar somente uma pequena porção do sinal no tempo. Essa adaptação, chamada de Transformada de Fourier de Tempo Curto (*STFT - Short-Time Fourier Transform*), definida pela equação (3.14), mapeia um sinal em uma função que depende do tempo e da frequência. Com isso, temos a informação de quando, ou onde, uma determinada frequência do sinal ocorre. A Figura 3.8 ilustra essa característica da STFT, através do espectrograma³ do sinal. Todavia, essa informação tem uma resolução limitada que depende do tamanho da janela escolhida.

$$STFT(\tau, f) = \int_{-\infty}^{\infty} x(t)g^*(t - \tau) \cdot e^{-2j\pi ft} \cdot dt \quad (3.14)$$

Pode-se, então, interpretar a equação (3.14) de duas maneiras. Primeiramente, pode-se pensar na STFT como um banco de filtros modulados em diferentes frequências. Neste caso, cada janela, centrada em uma frequência f_i , se comporta como um filtro passa-banda que processa o sinal ao longo do tempo. A segunda interpretação da STFT dar-se-á quando se pensa em $g(t)$ como sendo uma janela móvel no eixo temporal, limitando o sinal a ser analisado, de tal maneira que este possa ser considerado estacionário para se fazer uma análise satisfatória através da transformada de Fourier.




Figura 3.8 - Transformação do sinal temporal para o plano bidimensional tempo-frequência, através da STFT. Do lado esquerdo, temos parte de um sinal, cuja frequência varia com o tempo. Na direita, temos o espectrograma deste sinal, que nos mostra o comportamento desta frequência ao longo do tempo.

³ O espectrograma é definido como sendo a raiz do módulo da STFT e é uma ferramenta muito comum na análise de sinais, pois mostra a distribuição da energia do sinal ao longo do plano tempo-frequência.

A relação entre as resoluções temporal, Δt , e espectral, Δf , é determinada pelo Princípio da Incerteza de Heisenberg (MALLAT, 1999), mostrado na equação (3.15).

$$\Delta t \cdot \Delta f \geq \frac{1}{4\pi} \quad (3.15)$$

Janelas gaussianas são preferencialmente usadas, pois minimizam a inequação (3.15). Como mostra a Figura 3.9, uma vez escolhida a janela a ser usada para calcular a STFT, a resolução no espaço tempo-freqüência é fixa para todo o plano. Adicionalmente, observa-se que quanto melhor a resolução temporal, pior a resolução espectral e vice-versa. Ao usar, desta forma, a STFT como ferramenta de análise de sinais, deve-se tomar cuidado na hora de escolher a janela a ser usada.

A partir da Figura 3.9, observe que o cálculo da STFT a um dado instante de tempo, u , equivale à computação da transformada de Fourier de uma porção sinal situado entre $u - \Delta t/2$ e $u + \Delta t/2$, calculando, desta forma, todas as freqüências existentes neste intervalo do sinal. Equivalentemente, o cálculo da STFT a uma dada freqüência, ξ , equivale à filtragem do sinal, durante todo o tempo, por um filtro passa-banda, cuja função de

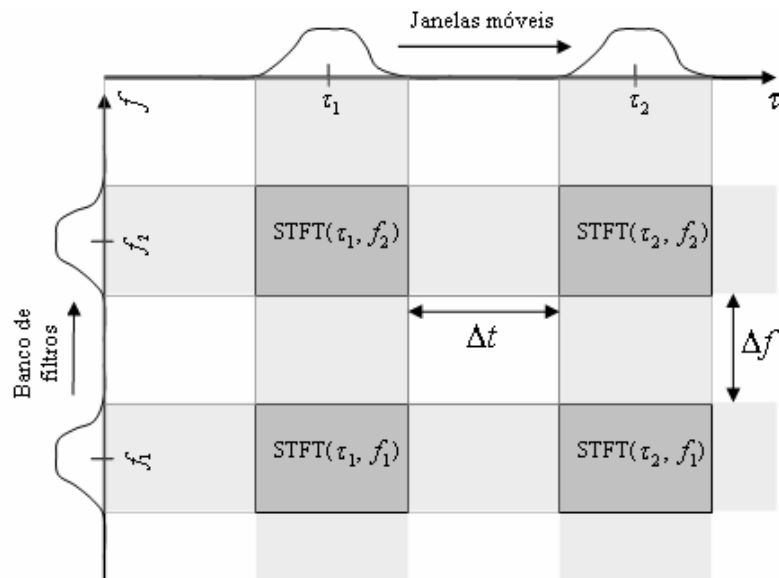


Figura 3.9 - Cobertura do espaço tempo-freqüência através da STFT. Os valores de Δt e Δf são fixos para todo o plano. A largura Δf pode ser adequada para analisar o sinal em freqüências próximas a f_1 , porém esta mesma largura pode ser insatisfatória para freqüências próximas de f_2 . Da mesma forma, a resolução temporal, Δt , pode ser adequada para instantes de tempo próximos a τ_1 , no entanto pode ser inadequado para instantes de tempo próximos a τ_2 .

transferência é a janela $\widehat{g}_{u,\xi}(\omega)$, dada pela equação (3.16). Essa janela é nada mais, nada menos, que a transformada de Fourier da janela temporal $g_{u,\xi}(t)$ e está modulada na frequência ξ , com uma largura de banda igual a $\Delta\omega = 2\pi \cdot \Delta f$.

$$\widehat{g}_{u,\xi}(\omega) = \widehat{g}(\omega - \xi) \cdot e^{-iu(\omega - \xi)} \tag{3.16}$$

3.2.2. Transformada Wavelet

Para solucionar o problema da resolução fixa da STFT, a transformada *wavelet* surgiu possibilitando variar os intervalos Δt e Δf no plano tempo-frequência, com o intuito de se obter uma análise multi-resolução do sinal. A Figura 3.10 ilustra a variação da resolução temporal e espectral da TW. Observe que, à medida que as escalas aumentam, a função $\psi_{u,s}(t)$ torna-se mais espalhada no tempo e seu espectro ocupa uma largura de banda cada vez menor. Ou seja, com o aumento da escala tem-se um decréscimo na resolução temporal e um incremento na resolução espectral. O inverso ocorre com a diminuição da escala.




Figura 3.10 – Resolução tempo-frequência da transformada *wavelet*. As resoluções Δt e Δf dos quadros de Heisenberg são proporcionais à escala da função *wavelet*. A área dos quadros, no entanto, permanece fixa. Escalas menores ($s_0 < s_1$) diminuem o espalhamento da função $\psi(t)$ no tempo e aumentam a largura de banda do filtro passa-faixa.

3.2.3. Escalonamento e Deslocamento de Funções

Como a análise através da transformada *wavelet* produz uma visão tempo-escala do sinal, torna-se necessário uma explanação dos conceitos de escalonamento (dilatação) e deslocamento (translação) do sinal.

Escalonar uma *wavelet*, ou uma função qualquer, significa simplesmente alongá-la ou comprimi-la. Mais formalmente, seja uma função $f(t)$. Escaloná-la por um fator a significa comprimir ou dilatar o eixo temporal de tal forma que $f_a = f(t/a)$. O resultado desta dilatação é exemplificado na Figura 3.11.

Observe que à medida que se aumenta a escala ($a_1 > a_2$) ocorre um decréscimo na frequência do sinal ($f_1 < f_2$). Conclui-se, então, que o fator de escala está relacionado (inversamente) com a frequência do sinal. A Figura 3.11 mostra o escalonamento de uma senóide, que é uma função não-limitada temporalmente. No entanto, o efeito é o mesmo para funções finitas, como as *wavelets*.

O deslocamento de funções consiste em transladá-las ao longo do eixo temporal. Matematicamente, deslocar uma função $f(t)$ consiste em adicionar um atraso τ , de modo que $f_\tau = f(t - \tau)$. Perceba, a partir da Figura 3.12, que valores positivos de τ deslocam a função para a direita, assim como valores negativos deslocam a função para a esquerda.




Figura 3.11 – Senóide com diferentes escalas. No topo, temos uma senóide com fator de escala $a = 1$, a função $f_{1/2}(t)$ possui $a = 1/2$ e em $f_2(t)$ o fator de escala é igual a 2.




Figura 3.12 - *Wavelet* 'Chapéu Mexicano' e suas versões dilatadas e deslocadas. Em (a) temos a *wavelet*-mãe. Em (b) temos uma versão dilatada e deslocada, com $a = 0,2$ e $\tau = 6$. Em (c) temos outra *wavelet*-filha, com $a = 2$ e $\tau = -3$. Os índices das funções correspondem aos fatores de deslocamento e escala.

Como vimos anteriormente, escalas maiores correspondem a *wavelets* mais alongadas. Isso implica que uma maior porção do sinal será correlacionada com a função *wavelet* e, desta forma, características mais lentas do sinal serão medidas pelos coeficientes *wavelets* (MISITI *et al.*, 2006). Existe, então, uma correspondência entre a escala e a frequência do sinal revelada pela análise *wavelet*:

- Pequenos valores de $a \rightarrow$ *wavelet* comprimida no tempo (espaço) \rightarrow detalhes com rápidas variações de amplitude \rightarrow alta frequência ω .
- Grandes valores de $a \rightarrow$ *wavelet* dilatada no tempo (espaço) \rightarrow detalhes com lentas variações de amplitude \rightarrow baixa frequência ω .

3.2.4. Funções Wavelets

Uma onda (*wave*, em inglês) é definida como uma função oscilante no tempo ou no espaço, como uma senóide, por exemplo. Uma *wavelet*, por sua vez, é uma onda pequena com energia finita, concentrada no tempo ou no espaço, possibilitando, desta forma, a análise de fenômenos transientes, não-estacionários ou variantes no tempo (REZA, 1999). Por conseguinte, as equações (3.17) e (3.18) são vistas como duas condições para que a função $\psi(t)$ possa ser considerada uma função *wavelet*.

$$\int_{-\infty}^{+\infty} |\psi(t)|^2 dt < +\infty \quad (3.17)$$

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (3.18)$$

Na transformada de Fourier, a base da transformação, $e^{j\omega t}$, define um conjunto de funções ortogonais que abrange todo o eixo temporal, ou seja, o intervalo $(-\infty, +\infty)$. No caso da transformada *wavelet*, para que um sinal seja efetivamente representado através de sua decomposição, as funções *wavelets* devem se comportar tal qual uma base matemática (RIOUL E VETERLLI, 1991). Desta forma, a síntese do sinal consiste na soma de todas as projeções do mesmo sobre as funções *wavelets*, como mostra a equação (3.19).

$$f(t) = \frac{1}{C} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} CWT(u, s) \cdot \psi_{u,s}(t) \frac{du}{u^2} ds \quad (3.19)$$

No entanto, para que a equação (3.19) seja verdadeira, a constante C deve obedecer a equação (3.20), também conhecida como **condição de admissibilidade**, onde $\widehat{\psi}(\omega)$ é a transformada de Fourier de $\psi(t)$ (MALLAT, 1999).

$$C = \int_{-\infty}^{+\infty} \frac{|\widehat{\psi}(\omega)|^2}{\omega} d\omega < +\infty \quad (3.20)$$

Para garantir que a integral da equação (3.20) seja finita, $\widehat{\psi}(0)$ deve ser nula, o que explica o fato de ter-se imposto que uma *wavelet* deve ter sua média nula, uma vez que:

$$\psi(0) = \int_{-\infty}^{+\infty} \psi(t) \cdot dt = 0 \quad (3.21)$$

Traduzindo a equação (3.21) em palavras, pode-se dizer que as funções *wavelets* devem ter média nula, pois, caso tenham algum valor DC, a soma nunca irá convergir para o sinal original. Uma vez que as *wavelets*-filhas são geradas a partir de uma única função, é necessário apenas fazer as restrições nas *wavelets*-mãe.

Resumindo, uma função $\psi(t)$ é uma *wavelet* caso tenha média nula, energia finita e possua um comportamento passa-banda no domínio da frequência, ou seja, tenha seu espectro limitado. Estas são as três restrições necessárias para se caracterizar uma *wavelet*.

3.2.5. Transformada Wavelet Contínua (TWC)

Ao contrário da transformada *wavelet* discreta, a TWC pode operar em qualquer escala. Adicionalmente, a TWC também é contínua em termos do deslocamento das *wavelets*, ou seja, durante o cálculo, a função *wavelet* é deslocada sobre todo o domínio do eixo temporal no qual se deseja fazer a análise do sinal.

Matematicamente, o processo de análise *wavelet* é representado pela transformada *wavelet* contínua, mostrado abaixo.

$$TWC_f(u, s) = \int_{-\infty}^{\infty} f(t) \cdot \psi_{u,s}(t) \cdot dt \quad (3.22)$$

A equação (3.22) define a transformada *wavelet* para um determinado deslocamento u e um fator de escala s e a função $\psi_{u,s}(t)$, como mostra a equação (3.23), é uma versão escalonada e deslocada de uma função *wavelet*-mãe $\psi(t)$.

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right) \quad (3.23)$$

A partir da equação (3.23), nota-se que uma vez que a *wavelet*-mãe representa um filtro passa-banda centrado em f_0 , com largura de banda Δf_0 , sua *wavelet*-filha $\psi_{u,s}(t)$ representará um filtro passa-banda centrado em af_0 e com largura de banda igual a $a\Delta f_0$ (AKANSU *et al.*, 1997). Desta forma, verifica-se que as funções *wavelets* possuem uma largura de banda proporcional a escala. A largura de banda relativa ($\Delta f / f$), no entanto, é constante e independe da escala, como mostra a Figura 3.13, permitindo, deste modo, uma variação na resolução temporal e espectral.




Figura 3.13 - Divisão do espectro para a (a) transformada de Fourier janelada e para a (b) transformada *wavelet*. No caso da STFT, observa-se uma cobertura uniforme do espectro, enquanto que na análise através da TW, tem-se uma cobertura uniforme do mesmo.

Combinando as equações (3.22) e (3.23), temos a equação (3.24), que nos revela que a resposta ao impulso da função *wavelet*, $\psi(t)$, torna-se mais espalhada no tempo à medida que a escala s aumenta, focando, com isso, os comportamentos de longa duração do sinal. Equivalentemente, à medida que diminuimos o valor de s , a função *wavelet* contrai-se no domínio do tempo e, desta forma, enxergam-se os pequenos detalhes do sinal. Conclui-se então que largas escalas implicam em visões mais globais do sinal, enquanto que escalas menores dão uma visão dos detalhes do sinal (RIOUL E VETERLLI, 1991).

$$TWC(u, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} f(t) \cdot \psi\left(\frac{t-u}{s}\right) \cdot dt \quad (3.24)$$

A equação (3.24) mostra também que a CWT é definida como a soma, em todo eixo temporal, do sinal multiplicado por versões escalonadas e deslocadas da função *wavelet* $\psi(t)$. Desta forma, assim como a análise de Fourier decompõe o sinal em senóides de diferentes frequências, a análise *wavelet* decompõe o sinal em funções derivadas de uma *wavelet*-mãe, por meios de deslocamentos e escalonamentos da mesma, como mostra a Figura 3.14.

Outra forma de interpretar a transformada *wavelet* é como uma medida de similaridade entre o sinal e a função base (*wavelet*), uma vez que a equação (3.24) é o produto interno entre $f(t)$ e $\psi_{u,s}(t)$.




Figura 3.14 – Em (a) temos a análise de Fourier, que decompõe o sinal em senóides com diferentes frequências. Em (b) temos a análise *wavelet*, que decompõe o sinal em versões deslocadas e escalonadas de uma função *wavelet*-mãe. Adaptado de (MISITI *et al.*, 2006).

3.2.6. Discretização dos Parâmetros Tempo-Escala

O cálculo dos coeficientes *wavelets* em todas as escalas possíveis é um trabalho bastante árduo e gera uma quantidade enorme de dados. A discretização das escalas e dos deslocamentos, no entanto, visa contornar esse problema. Em geral, considera-se $u = u_0^j$ e $s = k.u_0^j T$, sendo j , k e T inteiros. Assim, as *wavelets* correspondentes são dadas por:

$$\psi_{j,k}(t) = u_0^{-j/2} \psi(u_0^{-j} t - kT) \quad (3.25)$$

que resulta nos seguintes coeficientes *wavelets*:

$$CWT(j, k) = \int x(t) \cdot \psi_{j,k}^*(t) \cdot dt \quad (3.26)$$

Há casos, entretanto, em que a discretização é feita em oitavas, ou seja, os parâmetros de escala e posição são baseados em potência de dois⁴. Isso diminui bastante o esforço computacional, uma vez que o cálculo da CWT discretizada em oitavas é efetuado de forma bastante eficiente através de algoritmos piramidais e codificações por sub-bandas (GARCIA, 2005).

Mallat (1988) desenvolveu uma eficiente maneira de calcular a transformada *wavelet* utilizando filtros. Tal algoritmo é, na verdade, um esquema clássico conhecido na comunidade de processamento de sinal como codificador de sub-banda de dois canais. Este algoritmo de filtragem bastante prático produz a transformada *wavelet* rápida (FWT), que veremos no próximo tópico.

3.2.7. Transformada Wavelet Discreta (TWD)

Na análise *wavelet* geralmente fala-se de aproximações e detalhes. As aproximações são as largas escalas do sinal, ou seja, as componentes de baixa frequência. Os detalhes, por sua vez, são as pequenas escalas, ou seja, as componentes de alta frequência (MISITI *et al.*, 2006).

Para se obter os sinais de aproximação e detalhe de um sinal qualquer, devem-se separar suas componentes de alta e baixa frequência, conforme ilustra a Figura 3.15.

⁴ Quando os parâmetros da TW baseiam-se em potências de dois, ou seja, $u_0 = 2$, eles são denominados escala e/ou parâmetros diádicos.

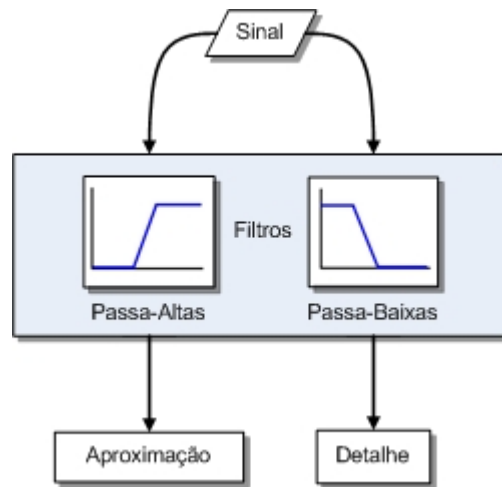


Figura 3.15 - Obtenção dos sinais de aproximação e detalhe a partir do sinal original. O sinal S passa por dois filtros complementares se decompondo em dois sinais.

Os coeficientes de decomposição em uma base ortogonal wavelet são computados por meio de um algoritmo rápido que cascadeia convoluções discretas com filtros conjugados espelhados passa-altas e passa-baixas, seguidas de subamostragens (MALLAT, 1999), conforme ilustra a Figura 3.15. Repare que os filtros PB removem as altas frequências do sinal original, enquanto que os filtros PA armazenam as componentes de alta frequência remanescentes do sinal.




Figura 3.16 - Processo de decomposição *wavelet* incluindo a sub-amostragem dos sinais filtrados. Os coeficientes de detalhe e aproximação possuem aproximadamente metade do número de amostras do sinal original.

A transformada rápida *wavelet* decompõe, conforme exibe a Figura 3.17, sucessivamente cada aproximação cA_n em uma aproximação de menor resolução, cA_{n+1} , mais os coeficientes wavelets, cD_{n+1} (MALLAT, 1999).

Uma vez que o processo é iterativo, em teoria ele poderia continuar indefinidamente. Na realidade, contudo, a decomposição pode ser calculada até que um coeficiente de

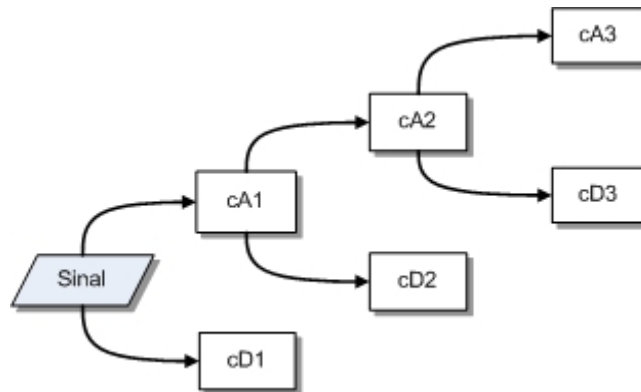


Figura 3.17 - Árvore de decomposição *wavelet*. O sinal original é decomposto em componentes de detalhe e aproximação com resolução cada vez menor.

detalhe seja composto por apenas uma amostra (ou um *pixel* no caso 2D). Esse processo pode ser usado para analisar, ou decompor, sinais e imagens e é chamado de decomposição ou análise (MISITI *et al.*, 2006). Na direção inversa, recupera-se progressivamente cada coeficiente de aproximação, cA_n , a partir dos coeficientes de aproximação, cA_{n+1} , e detalhe, cD_{n+1} , da escala posterior (MALLAT, 1999). Esse processo é chamado de reconstrução, ou síntese, e é ilustrado na Figura 3.18. A formulação matemática por trás desse processo de síntese é chamada transformada wavelet discreta inversa (MISITI *et al.*, 2006).

A reconstrução se dá através de uma sobre-amostragem dos coeficientes de detalhe e aproximação, seguida de uma filtragem e adição. No processo de sobre-amostragem, inserem-se zeros entre as amostras dos coeficientes de aproximação, cA_{n-1} , e detalhe, cD_{n-1} . No processo de filtragem, a escolha dos filtros é essencial para uma reconstrução perfeita do sinal.

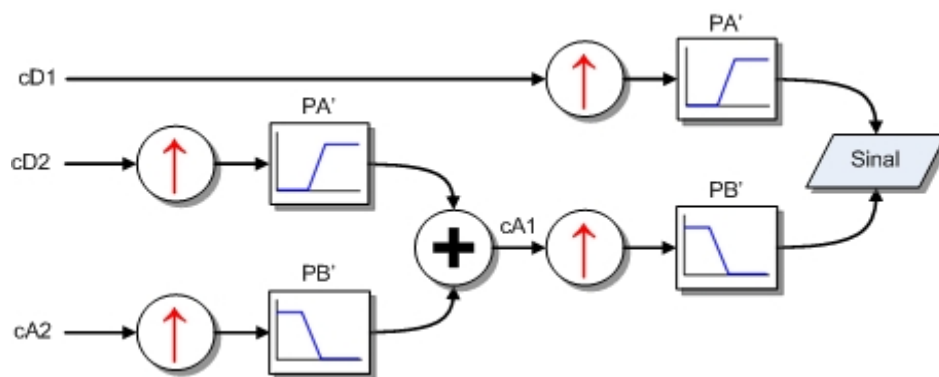


Figura 3.18 - Processo de reconstrução (síntese) *wavelet* a partir dos coeficientes da segunda escala. Primeiro, obtém-se o coeficiente de aproximação da primeira escala a partir dos coeficientes de aproximação e detalhe da 2ª escala. Em seguida, recupera-se o sinal a partir dos coeficientes da 1ª escala.




Figura 3.19 - Obtenção dos sinais de (a) aproximação e (b) detalhe da TW.

Para uma reconstrução satisfatória, os filtros de decomposição passa-baixas e passa-altas (L e H) juntamente com os filtros de reconstrução (L' e H') devem formar o que se conhece por filtros de quadratura espelhados. Para mais detalhes sobre como projetar esses filtros consultar a referência (STRANG E NGUYEN, 1996).

Aproximações e Detalhes

Além de reconstruir o sinal original a partir dos coeficientes *wavelets*, é possível também, a partir destes, gerar sinais de aproximação e detalhes do sinal original. Para isso, deve-se combinar um dos vetores de coeficientes *wavelet* com um vetor de zeros (MISITI *et al.*, 2006), como mostra a Figura 3.19.

Observe que para obtenção do sinal de aproximação sobre-amostram-se o vetor de zeros e o vetor de coeficientes de aproximação. Posteriormente, este passa por um filtro passa-baixas e aquele por um filtro passa-altas. Para obtenção do sinal de detalhes, no entanto, o vetor de zeros é filtrado por um filtro passa-baixas, enquanto que o vetor de coeficientes de detalhes por um filtro passa-altas.

Os sinais de aproximação e detalhes reconstruídos são efetivamente componentes do sinal original. De fato, caso os dois sinais reconstruídos sejam combinados, o sinal original é obtido (MISITI *et al.*, 2006), ou seja:

$$S = A_1 + D_1 \quad (3.27)$$

onde S é o sinal original, A_1 e D_1 são os sinais de aproximação e detalhe, respectivamente, reconstruídos a partir do nível 1 de decomposição.

Pode-se estender essa técnica de obtenção dos sinais de aproximação e detalhe para uma análise multi-nível, conforme ilustra a Figura 3.20.

3.3. Análise das Variáveis Canônicas

A análise das variáveis canônicas (AVC) fornece uma descrição das diferenças entre grupos especificados a priori em um conjunto de dados multivariados. Assim como no caso da análise de componentes principais (ACP), os princípios fundamentais de redução de dimensionalidade e explicação da variação em termos de variáveis latentes aplicam-se também para a AVC. A dedução das direções de maior variação nos dados originais que permitem a redução de dimensionalidade e explicação da variação em termos das variáveis latentes são obtidas por meio de autovalores e autovetores (MONTEIRO E REIS, 1999), como será discutido adiante.

O objetivo da análise das variáveis canônicas é separar as classes, procurando combinações lineares das variáveis de modo a maximizar a razão entre as variâncias intra-classe e extra-classe (GARDNER *et al.*, 2006).

Antes de iniciar a AVC, é essencial extrair os parâmetros fundamentais para quantificar os sinais (padrões). A escolha dos parâmetros deve ser feita com bastante cautela,

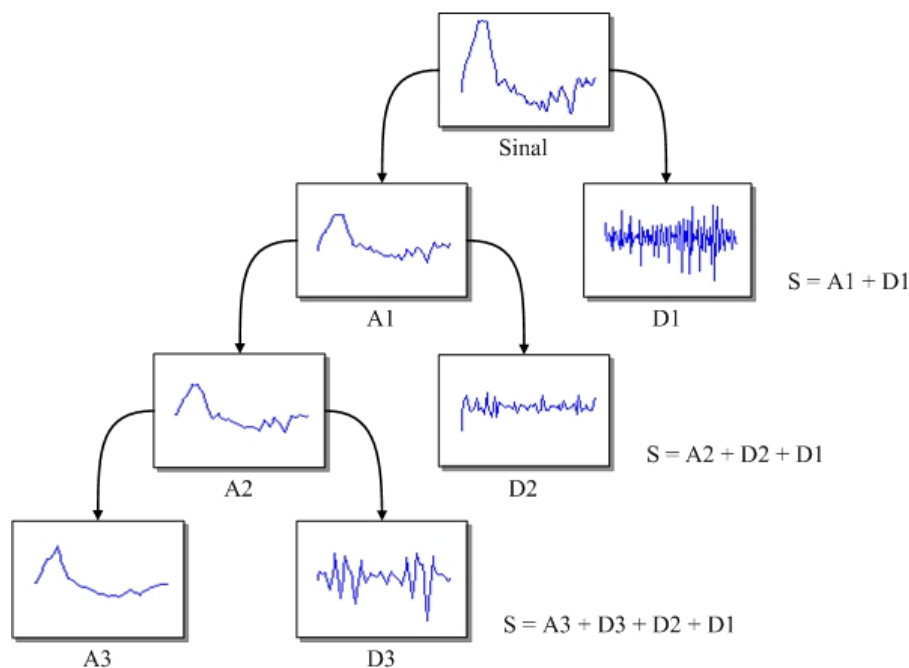


Figura 3.20 - Reconstrução do sinal através dos sinais de aproximação e detalhe multi-níveis.

uma vez que o resultado da AVC está intimamente ligado com a seleção das variáveis. É preferível, desta forma, que se faça um estudo detalhado das variáveis que irão quantificar os padrões em questão.

Após a escolha das variáveis que quantificarão os sinais (padrões), devem-se organizar os dados de tal forma que a implementação do processo seja favorecida. Sendo assim, torna-se necessário montar uma matriz onde os elementos (padrões) estejam separados pelas linhas e as variáveis estejam separadas por colunas. Adicionalmente, é preferível que os padrões pertencentes a uma mesma classe estejam agrupados numa sub-matriz, dentro da matriz principal, como mostra a Tabela 3.1.

Com os dados devidamente organizados, começa-se a AVC propriamente dita. Primeiro, é necessário construir uma matriz que quantifique a variação dentro dos grupos

Tabela 3.1 - Organização dos dados para a análise das variáveis canônicas. Os elementos devem estar agrupados em classes que devem estar separadas em linhas e as diferentes variáveis medidas devem estar organizadas em colunas. Φ_i é a i -ésima classe, P_{ij} representa o j -ésimo padrão da i -ésima classe e $D_{ij,k}$ representa a k -ésima variável do elemento j da classe i

CLASSES	PADRÕES	V_1	V_2	...	V_{N_V}
Φ_1	$P_{1,1}$	$D_{1,1,1}$	$D_{1,1,2}$...	$D_{1,1,N_V}$
	\vdots	\vdots	\vdots	...	\vdots
	P_{1,N_1}	$D_{1,N_1,1}$	$D_{1,N_1,2}$...	D_{1,N_1,N_V}
Φ_2	$P_{2,1}$	$D_{2,1,1}$	$D_{2,1,2}$...	$D_{2,1,N_V}$
	\vdots	\vdots	\vdots	...	\vdots
	P_{2,N_2}	$D_{2,N_2,1}$	$D_{2,N_2,2}$...	D_{2,N_2,N_V}
\vdots	\vdots	\vdots	\vdots	\ddots	\vdots
Φ_C	$P_{C,1}$	$D_{C,1,1}$	$D_{C,1,2}$...	$D_{C,1,N_V}$
	\vdots	\vdots	\vdots	...	\vdots
	P_{C,N_C}	$D_{C,N_C,1}$	$D_{C,N_C,2}$...	D_{C,N_C,N_V}

(matriz de espalhamento intra-grupo) e outra que quantifique a variação entre os grupos (matriz de espalhamento extra-grupo). Para isso, deve-se, antes de tudo, achar a média de cada variável para cada classe e para o conjunto inteiro de dados e, dessa forma, construir o vetor média de todo o conjunto e de cada classe.

A matriz mostrada na Tabela 3.1 possui dimensões $N_T \times N_V$, onde N_T é o número total de elementos e N_V é o número de parâmetros (variáveis) extraídos dos padrões. Observe que N_T é a soma do número de elementos de cada classe, ou seja:

$$N_T = \sum_{i=1}^C N_i \quad (3.28)$$

onde C é o número de classes e N_i é o número de elementos da classe i .

Assim, suponha que $\{\Phi_1, \Phi_2, \dots, \Phi_C\}$ represente o conjunto das classes que se deseja analisar. Define-se o vetor média de todo o conjunto, \mathbf{m} , através da equação (3.29).

$$\mathbf{m} = \frac{1}{N_T} \sum_{i=1}^C \sum_{j=1}^{N_i} D_{i,j,k}, \quad k = 1, 2, \dots, N_V \quad (3.29)$$

Similarmente, o vetor média da i -ésima classe, \mathbf{m}_i , é definido na equação (3.30).

$$\mathbf{m}_i = \frac{1}{N_i} \sum_j D_{i,j,k} \quad (3.30)$$

onde $D_{i,j,k} \in \Phi_i$ e $k = 1, 2, \dots, N_V$.

Definem-se, agora, as matrizes de espalhamento total (S_t), espalhamento intra-grupo (S_w) e espalhamento extra-grupo (S_b), pelas equações (3.31), (3.32) e (3.33), respectivamente, mostradas a seguir.

$$S_t = \frac{1}{N_T} \sum_{i=1}^C \sum_{j=1}^{N_i} (\mathbf{x}_{i,j} - \mathbf{m})(\mathbf{x}_{i,j} - \mathbf{m})^T \quad (3.31)$$

$$S_w = \frac{1}{N_T} \sum_{i=1}^C \sum_{j=1}^{N_i} (\mathbf{x}_{i,j} - \mathbf{m}_i)(\mathbf{x}_{i,j} - \mathbf{m}_i)^T \quad (3.32)$$

$$S_b = \frac{1}{N_T} \sum_{i=1}^C (\mathbf{m}_i - \mathbf{m})(\mathbf{m}_i - \mathbf{m})^T \quad (3.33)$$

onde $\mathbf{x}_{i,j}$ é o vetor de variáveis do j -ésimo padrão da i -ésima classe, $P_{i,j}$.

A matriz S_w representa a variância entre os elementos de uma mesma classe enquanto que a matriz S_b representa a variância entre elementos de classes diferentes (HUANG *et al.*, 1998), ou seja, S_w mede a densidade dos elementos de uma classe e S_b mede o espalhamento das classes entre si.

Para que os dados estejam bem descorrelacionados, então, é necessário que a densidade dos elementos de uma mesma classe seja alta (muitos elementos numa área pequena) e os elementos de diferentes classes estejam distantes um dos outros. Isso implica em um valor alto para S_w e um valor pequeno para S_b , simultaneamente.

O objetivo, desta maneira, é maximizar a variação entre os grupos relativa à variação dentro dos grupos. Sabendo que os autovetores de uma matriz de variâncias e covariâncias descrevem os eixos de variação máxima, escolhem-se os autovetores \mathbf{v} que maximizem a razão entre a matriz S_b e a matriz S_w (MONTEIRO E REIS, 1999). Em outras palavras, deve-se encontrar os autovetores \mathbf{v} que maximizem a função mostrada na equação (3.34), apresentada a seguir.

$$J(\mathbf{v}) = \frac{\mathbf{v}^T S_b \mathbf{v}}{\mathbf{v}^T S_w \mathbf{v}} \quad (3.34)$$

Para que a equação acima seja maximizada, deve-se encontrar um autovetor \mathbf{v} correspondente ao autovalor de maior magnitude que satisfaça a seguinte equação:

$$S_b \mathbf{v} = \lambda S_w \mathbf{v} \quad (3.35)$$

Os autovalores e autovetores, assim, devem ser calculados para a matriz M resultante do produto entre a inversa da matriz S_w e a matriz S_b (MONTEIRO E REIS, 1999).

$$M = S_w^{-1} \cdot S_b \quad (3.36)$$

Os autovalores extraídos da matriz M , definida na equação (3.36), são interpretados como a quantidade de variação associada a cada autovetor ou eixo de maior variação (MONTEIRO E REIS, 1999).

A solução da equação (3.35) gera $C-1$ autovalores não-nulos e seus correspondentes autovetores, que criam uma base ortogonal expandindo um espaço canônico de dimensão igual a $C-1$ (HUANG *et al.*, 1998).

A transformação, finalmente, é feita da seguinte forma:

$$\mathbf{y}_{i,j} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{c-1}]^T \mathbf{x}_{i,j} \quad (3.37)$$

onde $\mathbf{x}_{i,j}$ é o j -ésimo elemento da i -ésima classe de entrada (um vetor contendo os parâmetros do padrão $P_{i,j}$) e $\mathbf{y}_{i,j}$ é o j -ésimo elemento da i -ésima classe dentro do espaço canônico. A matriz composta pelos autovetores $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{c-1}$ é chamada de matriz de transformação do espaço canônico, ou simplesmente matriz de transformação canônica.

Seguindo os passos descritos anteriormente, diferentes classes estarão devidamente separadas, o que significa que a análise canônica é bastante adequada para discriminação de diferentes classes, mesmo quando o número de amostras para diferentes classes é aumentado (HUANG *et al.*, 1998).

É importante lembrar que a qualidade da análise de variáveis canônicas na discriminação de diferentes classes depende bastante das amostras (padrões) utilizadas, bem como das variáveis utilizadas para quantificar esses padrões. Desta forma, é necessário que se tenha bastante cuidado tanto na hora de escolher os padrões que irão representar uma classe como na hora de selecionar as variáveis que irão quantificar esses padrões.

3.4. Estudo Estatístico Para Validação de Testes

O desempenho de um sistema de detecção de padrões depende da precisão deste em discriminar corretamente os padrões alvo (p) dos demais (\bar{p}). Para isso, deve-se fazer uma comparação deste sistema com um sistema de padrão ouro, a fim de verificar a quantidade de erros e acertos do sistema em teste.

Quando o padrão alvo está presente e o sistema (teste), após uma inspeção, indica a presença do mesmo ocorre um verdadeiro positivo (VP), assim como quando o padrão alvo não está presente e o sistema aponta a ausência do mesmo ocorre um verdadeiro negativo (VN). Por outro lado, se um padrão alvo é apresentado ao sistema e este não o reconhece, ocorre um falso negativo (FN). Finalmente, se um padrão complementar é apresentado, porém é reconhecido como um padrão alvo ocorre um falso positivo (FP). Os verdadeiros

positivos e os verdadeiros negativos manifestam os acertos do sistema, assim como os falsos positivos e falsos negativos indicam os erros do mesmo.

A sensibilidade de um teste é a capacidade do mesmo em reconhecer os verdadeiros positivos e a especificidade é habilidade de discernir os verdadeiros negativos. Quanto maior a sensibilidade, maior a chance de o teste detectar um padrão alvo corretamente. Por outro lado, uma especificidade alta implica em uma alta probabilidade do teste detectar corretamente um padrão não-alvo. As equações (3.38) e (3.39) formulam matematicamente estes dois conceitos.

$$Sen = 100 \cdot \frac{VP}{VP + FN} \quad (3.38)$$

$$Esp = 100 \cdot \frac{VN}{VN + FP} \quad (3.39)$$

Os valores da sensibilidade e especificidade do sistema são dados em percentagem e podem variar de 0, para o pior caso, até 100%, no caso ideal.

Além da sensibilidade e especificidade (que quantificam a precisão de um teste), outros dois parâmetros necessários para validação de um teste são o valor preditivo positivo (VPP) e o valor preditivo negativo (VPN), definidos pelas equações (3.40) e (3.41), respectivamente.

$$VPP = 100 \cdot \frac{VP}{VP + FP} \quad (3.40)$$

$$VPN = 100 \cdot \frac{VN}{VN + FN} \quad (3.41)$$

Pode-se afirmar que o VPP é a probabilidade de se encontrar um legítimo padrão alvo entre aqueles detectados pelo sistema. De maneira similar, o VPN é a probabilidade de um padrão detectado pelo sistema como sendo não-alvo (ou complementar) realmente ser um padrão não-alvo.

Quanto maior a sensibilidade de um teste, maior o seu VPP, ou seja, maior a confiança nos resultados positivos (padrões-alvo detectados). Também, quanto maior a especificidade de um teste, maior a confiança nos resultados negativos, ou seja, maior a certeza de que um padrão detectado como não-alvo realmente seja um padrão não-alvo.

Capítulo 4

Metodologia

Tendo em mãos toda a fundamentação teórica necessária ao entendimento dos processos que englobam este trabalho, este capítulo empenhar-se-á em explicar a metodologia proposta empregada na realização dos objetivos traçados.

4.1. Base de Dados

Os sinais dos registros polissonográficos usados neste trabalho foram adquiridos no “Laboratório do Sono”, em Florianópolis-SC, durante o trabalho de Rodrigues (2002), com auxílio da Dra. Vânia Andriani, especialista na área. Uma vez que o enfoque do trabalho de Rodrigues (2002) era a detecção e classificação de apnéias do sono em indivíduos com tais distúrbios, todos os registros foram obtidos em locais apropriados, com a segurança e o conforto necessários para que os pacientes tivessem uma noite de sono normal.

O banco de dados foi colhido ao longo de 3 anos, desde o começo do trabalho de Rodrigues (2002) e é composto por 12 registros de diferentes pacientes, com ou sem apnéia do sono. A Tabela 4.1 mostra algumas características desses indivíduos.


Os registros de polissonografia contêm vários sinais bioelétricos em sua composição. Desta maneira, o registro usado neste trabalho é composto de 4 canais de EEG (derivações C3-A1, C4-A2, O1-A1 e O2-A2), 2 de EOG (direito e superior), 1 de ECG, 3 de EMG (mento, mio direito e mio esquerdo), 1 de fluxo respiratório, 1 de movimento torácico, 1 de oximetria e 1 de nível sonoro (RODRIGUES, 2002). Os sinais possuem frequência de amostragem igual a 102,4 Hz, com exceção dos sinais de fluxo respiratório, movimento torácico, oximetria e nível sonoro, que possuem frequência de amostragem igual a 12,8 Hz.

Tabela 4.1 - Características dos pacientes utilizados na obtenção dos registros polissonográficos utilizados neste trabalho.

INDIVÍDUO	SEXO	IDADE (ANOS)	ALTURA (CM)	PESO (KG)
1	M	40	N.I.*	N.I.
2	M	43	190	120
3	M	N.I.	171	90
4	M	49	172	80
5	F	31	171	70
6	M	41	171	76
7	F	45	155	55
8	M	39	180	85
9	M	N.I.	N.I.	N.I.
10	F	50	155	56
11	F	49	160	60
12	M	37	176	104

*Valores não informados pelo médico ou paciente durante a aquisição do registro.

Uma vez que o objetivo das metodologias propostas neste trabalho é, sobretudo, a detecção e classificação apenas de padrões do sono nos sinais de EEG, analisar-se-á apenas os quatro primeiros canais do registro polissonográfico, os quais referem-se aos quatro canais de EEG. A escolha das quatro derivações de EEG utilizadas neste trabalho é recomendada por Rechtschaffen e Kales (1968), pois os fusos do sono, complexos K e ondas *vertex* são registrados com bastante nitidez nas derivações C3 e C4 e, por outro lado, o registro do ritmo alfa, usado para identificação do começo do sono, é melhor visualizado nas derivações O1 e O2. Além disso, o uso da orelha como referência maximiza a distância inter-eletrodo e evita a mistura de atividades elétricas advindas de diferentes áreas do scalp.

**Figura 4.1** - Janela de trinta segundos do registro polissonográfico contendo apenas os quatro canais de EEG.




Figura 4.2 - Hipnograma de um registro de polissonografia da base de dados.

Cada registro tem duração média de oito horas, ou seja, uma noite inteira de sono. O sinal, no entanto, é armazenado no arquivo em blocos de dez segundos. Não obstante, para visualização dos sinais, esse registro é dividido em épocas¹ de trinta segundos, como mostra a Figura 4.1, facilitando a análise dos sinais por parte do especialista. Juntamente com o arquivo de extensão “plg”, que abre o registro polissonográfico, existe um arquivo de extensão “hpn”, que armazena o hipnograma² do registro. A Figura 4.2 ilustra o hipnograma de um dos arquivos da base de dados. Observe que o tempo de duração do hipnograma é de aproximadamente 500 minutos, que equivale a pouco mais de oito horas.

Para classificação dos padrões, as épocas de 30 segundos são divididas em janelas de aproximadamente um segundo com sobreposição de 50% (0,5 segundos), onde cada uma destas representa um padrão de treinamento, que pode ser um complexo K, um fuso do sono, ou uma atividade de fundo de EEG. Desta maneira, cada padrão de treino possui 105 amostras ($\approx 1,0$ segundo de registro).

O nome do arquivo em que os padrões de treino são salvos contém informações sobre o nome do arquivo do registro polissonográfico em que esses padrões foram encontrados, o tipo de padrão, a página, o instante e o canal em que ele ocorre. Por consequência, o nome do arquivo funciona como uma espécie de cabeçalho para o arquivo do padrão, como mostra a Figura 4.3.

¹ Neste caso, uma época refere-se a um intervalo do registro de EEG. Geralmente, uma época tem duração de 20 ou 30 segundos, podendo subdividir-se em períodos de 5 ou 10 segundos, objetivando facilitar a visualização e classificação da mesma (RECHTSCHAFFEN & KALES, 1968).

² Uma vez que o estagiamento do sono já tenha sido realizado, uma forma bastante utilizada para se observar o progresso do sono durante a noite é o hipnograma. Este consiste num gráfico 2D, onde o eixo horizontal representa o tempo e o eixo vertical representa as fases do sono.

Tipo de Padrão	Nome do arquivo do registro polissonográfico	Página de ocorrência	Instante de ocorrência	Canal de ocorrência
----------------	--	----------------------	------------------------	---------------------

Figura 4.3 - Estrutura para montagem do nome do arquivo onde será salvo o padrao de treinamento.

Desta forma, se um complexo K, foi encontrado pelo especialista no arquivo 00588-1.plg, no instante 16,65 segundos da página 400 do registro, localizado no canal C3, este arquivo terá o seguinte nome: *CK.00588-1.0400.16,65.C3.std*, onde “std” é a extensão do arquivo salvo. A sigla CK corresponde a um padrão do tipo complexo K, assim como um fuso do sono é representado pela sigla FS e a atividade de fundo de EEG pela sigla AF. A seguir, a Figura 4.4 ilustra alguns exemplos desses padrões de treinamento.




Figura 4.4 - Exemplos de padrões de treinamento selecionados por um especialista. À esquerda alguns exemplos de atividade de fundo de EEG durante o estágio 2 do sono NREM são ilustrados. No centro, têm-se exemplares de complexos K e à direita alguns fusos do sono. Observe que a amplitude dos padrões está normalizada entre -1 e 1 e que a duração de cada um deles é de aproximadamente 1 segundo.

4.2. Esboço Geral das Metodologias

O propósito principal das metodologias empregadas neste trabalho é a detecção de complexos K e fusos do sono, funcionando, desta maneira, como uma ferramenta auxiliar no estagiamento automático do sono. Desta forma, este trabalho concentra-se apenas em analisar sinais de EEG. Especificamente, as metodologias utilizadas, com o intuito de evitar a presença de falsos positivos, analisam apenas as épocas do registro que contém características semelhantes às do segundo estágio do sono NREM. Assim sendo, a Figura 4.5 ilustra um diagrama geral da metodologia utilizada para detecção de complexos K e fusos do sono em sinais de eletroencefalograma.

O esboço da metodologia proposta neste trabalho é baseado no sistema desenvolvido por Rodrigues (2002), onde a estrutura geral da metodologia é semelhante à usada por ele. A diferença primordial, além de outras, está no método de detecção utilizado no bloco “Detecção de Padrões”.

Em primeiro lugar, os sinais de EEG são lidos a partir da base de dados montada no trabalho de Rodrigues (2002), onde são visualizados em épocas de 30 segundos, como mostra a Figura 4.1. Em seguida, calcula-se a FFT das derivações C3 e C4 dos sinais de EEG. O sistema de controle, então, fundamentado em informações de amplitude e frequência do sinal de EEG, verifica se a época em questão possui características típicas do estágio II do sono NREM. Apenas as épocas com características semelhantes ao do estágio II serão submetidas à etapa de detecção de padrões (RODRIGUES, 2002).

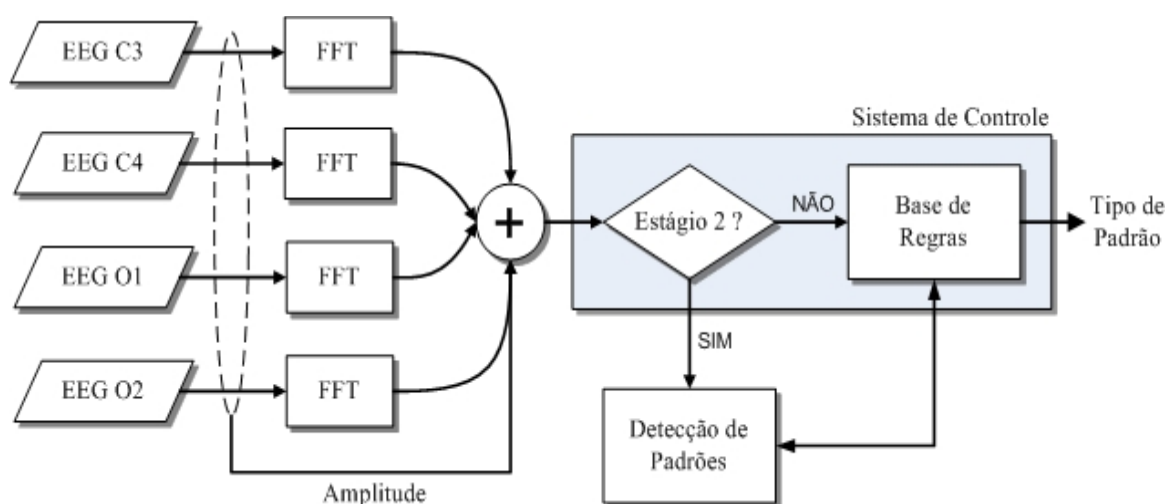


Figura 4.5 – Escopo geral da metodologia para detecção dos padrões.

Essa seleção das épocas que passarão pela etapa de detecção é essencial, pois a análise de todas as épocas do registro comprometeria o tempo de processamento do sistema, deixando a análise lenta e poderia, além disto, provocar a ocorrência de falsos positivos, decorrentes de artefatos em outros registros de EEG (SADASIVAN E DUTT, 1994).

Caso uma época seja escolhida para a fase de detecção, os canais centrais³ (C3 e C4) desta época são divididos em períodos de aproximadamente 1 segundo (105 amostras). Esses vetores de 105 amostras contém os padrões, que podem ser um complexo K, um fuso do sono ou uma atividade de fundo de EEG, que serão usados no treinamento e teste das RNAs e AVCs.

Na fase de treinamento das RNAs e AVCs, o usuário escolhe exemplares de cada uma das classes e constrói sua base de dados. Durante a análise de uma época (etapa de teste), os canais de EEG são analisados por meio de uma janela de um segundo, que se desloca em intervalos de 0,5 segundos, evitando, desta forma, que eventos que ocorrem entre um segundo e outro não sejam detectados.

4.3. Detecção de Padrões

O módulo de detecção de padrões é a diferença fundamental desta metodologia para aquela usada por Rodrigues (2002). Um diagrama geral do método de detecção de padrões proposto neste trabalho é mostrado na Figura 4.6.

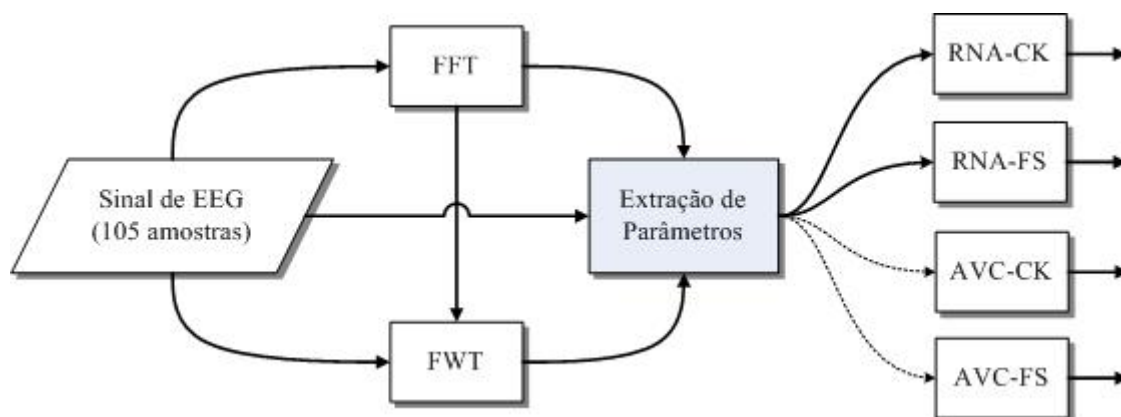


Figura 4.6 - Diagrama geral para metodologia de detecção dos padrões do EEG durante o sono. Primeiro, calcula-se a FFT e a FWT dos padrões do sono (AF, CK ou FS). Posteriormente, calculam-se alguns parâmetros desses padrões, os quais servirão de entrada para as RNAs e para as AVCs.

³ Analisam-se apenas os canais C3 e C4, pois são neles que os CK e os FS ocorrem mais nitidamente.

Observe na Figura 4.6, que disponibiliza-se a opção de utilizar as redes neurais artificiais ou as análises de variáveis canônicas para a detecção dos padrões. Inicialmente, pensou-se em utilizar a análise de variáveis canônicas para descorrelação e redução de dimensionalidade dos dados de entrada, servindo como um pré-processamento para as RNAs. No entanto, constatou-se que essa abordagem não seria possível, uma vez que a utilização da AVC com 2 classes de padrões⁴ gera, como explicado anteriormente, apenas um autovalor não-nulo com seu correspondente autovetor.

Não faz sentido, então, reduzir a dimensionalidade dos dados para uma dimensão (1-D), uma vez que esse é o papel da rede neural: receber um vetor de dimensionalidade $N > 1$ em sua entrada e reduzi-lo para uma 1-D em sua saída, utilizando, pois, um limiar para decisão. Por outro lado, uma vez que a AVC gera apenas um autovalor não-nulo, os outros autovetores, correspondentes aos autovalores nulos, não possuem nenhum poder de discriminação, descartando a possibilidade de descorrelação dos dados.

Resolveu-se então utilizar a análise de variáveis canônicas com a finalidade de discriminar padrões, assim como as RNAs os fazem. Desta forma, os padrões do sono foram submetidos aos dois métodos de detecção durante a fase de treino. Posteriormente, uma análise estatística mostrou-se necessária a fim de investigar os resultados e embasar a escolha do método mais apropriado.

Ainda com relação a Figura 4.6, pode-se perceber que existe uma RNA (e uma AVC) específica para detecção de complexos K e outra exclusiva para detecção de fusos do sono. Isso ocorre porque, com a especialização das redes neurais (e das AVCs) em apenas uma classe, a generalização das mesmas é beneficiada, uma vez que é mais fácil e óbvio discernir duas classes de padrões a três classes, ou mais.

Suponha, por exemplo, que um paciente com problemas cardiovasculares e neurológicos se consulte com um clínico geral. Posteriormente, o mesmo paciente se consulta com um neurologista e, logo após, com um cardiologista. É muito mais provável que o neurologista descubra o problema neurológico do paciente e, concomitantemente, o cardiologista reconheça a patologia cardiovascular do sujeito do que o clínico geral descubra as

⁴ Os padrões em questão são três: atividade de fundo de EEG, complexos K e fusos do sono. No entanto, cada AVC é especialista na detecção de um padrão. A AVC especialista em CK, por exemplo, enxerga apenas dois tipos de padrões: os complexos K (CK) e os não-complexos K (\overline{CK}).

duas enfermidades do paciente. Ou seja, médicos cardiologistas são mais eficazes em detectar doenças do coração, assim como neurologistas são mais competentes em diagnosticar doenças neurológicas. O mesmo ocorre com as redes neurais artificiais e a análise de variáveis canônicas, justificando a especialização de ambas.

No bloco FWT, na Figura 4.6, o sinal é decomposto até a sexta escala de decomposição da transformada *wavelet* e, em seguida, os sinais de detalhe das escalas 2, 3, 4, 5 e 6 são reconstruídos. O bloco FFT, por sua vez, calcula a transformada de Fourier⁵ do sinal de entrada. Conseqüentemente, como pode ser observado na Figura 4.6, a entrada do bloco Extração de Parâmetros é composta pelo sinal original, os sinais de detalhe da TW, a FFT do sinal original e a FFT dos sinais da TW. A saída deste módulo, por sua vez, como ilustra a Figura 4.7, é composta por várias medidas (parâmetros) que formam um vetor de características do sinal de entrada.

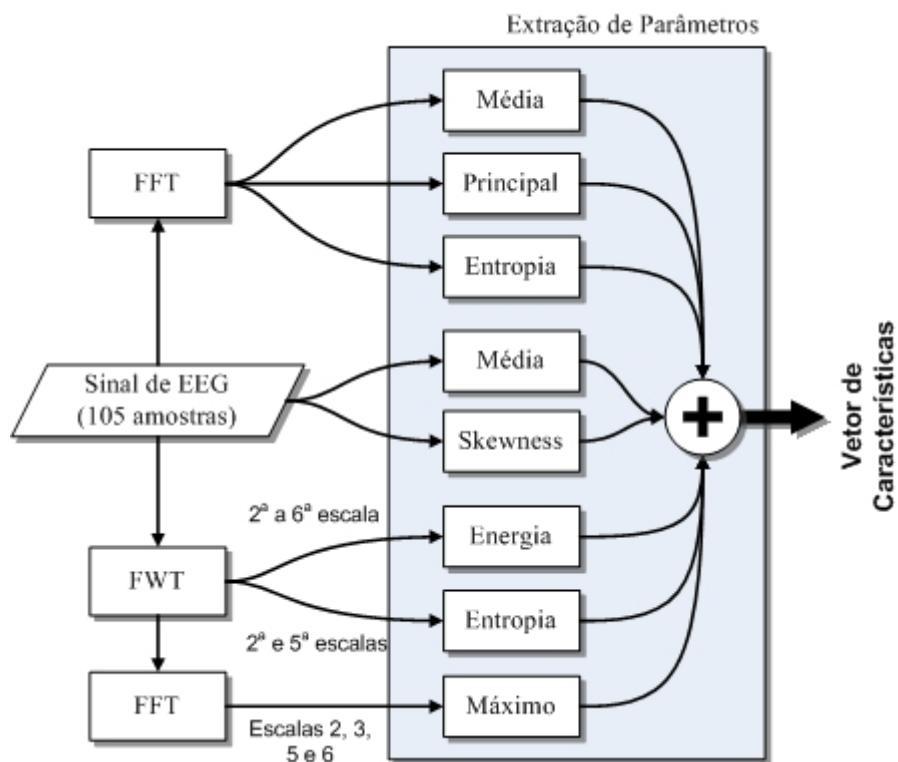


Figura 4.7 - Detalhe do módulo de extração de parâmetros. A saída deste módulo é um vetor de 16 posições (chamado de vetor de características do sinal) contendo todos os parâmetros extraídos, o qual servirá de entrada para as RNAs e as ACVs.

⁵ Com o intuito de evitar uma dispersão espectral, causada pelas descontinuidades nas bordas dos sinais, utilizou-se um janelamento do sinal, para o cálculo de sua FFT. A janela usada para tal fim foi a de *Hanning*, indicada para aplicações de propósitos gerais.

Na Figura 4.7, o bloco ‘+’ (acumulador ou agregador) não funciona como o somatório das entradas, mas sim como um acumulador de entradas, ou seja, ele agrega cada entrada em uma posição de um vetor, construindo, desta forma, o vetor de características do sinal.

O vetor de características é composto por vários parâmetros extraídos do sinal de entrada, que contém o padrão a ser examinado. Esses parâmetros são a média e o *skewness* do sinal temporal, a entropia da FFT do sinal, a frequência média, frequência dominante, energia dos sinais de detalhe das escalas 2, 3, 4, 5 e 6 da TW do sinal, entropia dos sinais de detalhe da 2ª e 6ª escala da TW e, finalmente, o máximo valor do espectro dos sinais de detalhe da 2ª, 3ª, 5ª e 6ª escalas da TW.

A média aritmética do sinal representa o valor médio do mesmo e é dada pela equação (4.1). No diagrama da Figura 4.7 é representada pelo bloco ‘Média’.

$$m(s) = \frac{1}{N} \sum_{n=1}^N s[n] \quad (4.1)$$

A energia de um sinal real é numericamente igual à área sob a curva descrita pela função do sinal elevada ao quadrado, como mostra a equação (4.2). A Figura 4.8 ilustra um sinal e a área sob a curva descrita pelo quadrado da função deste sinal.

$$E_2(s) = \sum_{n=1}^N |s[n]|^2 \quad (4.2)$$

A entropia é uma grandeza associada ao grau de desordem de um grupo de dados, ou sinal. Ela mede a parte da energia que não pode ser convertida em trabalho e é dada pela equação (4.3). Na Figura 4.7, seu cálculo se dá através do bloco “Entropia”.




Figura 4.8 - Sinal original (esquerda) e o quadrado de seu módulo (direita). A energia do sinal é numericamente igual à área sobre a curva direita.

$$E_1(s) = \sum_{n=1}^N s(n) \cdot \log_2(s[n]) \quad (4.3)$$

O *skewness*, definido pela equação (4.4), é uma medida do grau de assimetria de uma distribuição. Um valor negativo indica que a cauda negativa da distribuição é mais longa e um valor positivo, por outro lado, indica que a cauda positiva da distribuição é mais longa (WEISSTEIN, 2007).

$$Skew(s) = \frac{\mu_3}{\mu_2^{3/2}} \quad (4.4)$$

onde μ_k é o k -ésimo momento central.

A frequência média (f_m) do sinal é a média das frequências que compõem o sinal e é definida na equação (4.5). No diagrama da Figura 4.7, seu cálculo é representado pelo bloco ‘FFT’ seguido do bloco ‘Média’.

$$f_m(s) = \frac{f_s}{2N} \sum_{n=0}^{N-1} n \cdot S[n] \quad (4.5)$$

onde f_s é a frequência de amostragem do sinal, S é a transformada de Fourier do sinal s e N é o tamanho do vetor S .

A frequência média do sinal também pode ser entendida como a coordenada horizontal do centro de massa da área sob a curva do espectro do sinal. A Figura 4.9 ilustra um exemplo de um espectro com sua respectiva frequência média.

O máximo valor do espectro (MVE), dado pela equação (4.6), é o valor máximo da transformada de Fourier do sinal, ou seja, a coordenada y (vertical) do ponto onde ocorre o




Figura 4.9 - Espectro de um sinal e sua respectiva frequência média (linha vertical). O cálculo da frequência média se dá multiplicando cada amostra de frequência pela sua respectiva amplitude no espectro. A linha vertical representa a coordenada horizontal do centro de massa da área sob a curva.

máximo valor da curva da FFT. Na Figura 4.9, o MVE é aproximadamente 0.7, que é o máximo valor que a curva atinge. O mve é representado pelo bloco “FFT” seguido do bloco “Máximo”, na Figura 4.7.

$$\text{MVE}(s) = \max(S[n]) \quad (4.6)$$

A freqüência dominante (f_d), ou freqüência principal, do sinal é a freqüência que possui a maior amplitude no espectro. Em outras palavras é a coordenada x (horizontal) do ponto onde ocorre o máximo valor da curva da FFT. No espectro mostrado na Figura 4.9 a freqüência principal é 2.4 Hz. Na Figura 4.7, a f_d é simbolizada pelo bloco “FFT” seguido do bloco “Principal”.

4.3.1. Análise de Variáveis Canônicas

Como já mencionado anteriormente, o vetor de características dos padrões possui comprimento igual a 16. Na AVC isso significa que são 16 as variáveis que edificarão a matriz de dados. Desta forma, as matrizes de espalhamento intra-classe e extra-classe terão ordem igual a 16.

O sistema é composto por duas AVCs: uma especialista em complexos K e outra em fusos do sono. No primeiro caso, a AVC especialista em CK (AVC-CK) enxerga dois tipos de padrões: complexos K (CK) e não-complexos K ($\overline{\text{CK}}$). Da mesma forma, a AVC especialista em FS (AVC-FS) reconhece apenas dois tipos de padrões: fusos do sono (FS) e não-fusos do sono ($\overline{\text{FS}}$). Sendo assim, as AVCs, independente de sua especialidade, fazem a discriminação de duas classes diferentes. Por conseguinte, dos 16 autovalores extraídos da matriz $M = S_w^{-1} \cdot S_b$ apenas um possui valor não-nulo, criando uma base ortogonal num espaço canônico de dimensão única (1-D). No entanto, para uma melhor visualização dos resultados, usa-se um segundo autovetor (com respectivo autovalor nulo) extraído da matriz M , com a finalidade apenas de visualizar os resultados num plano 2-D. A Figura 4.10 ilustra a visualização dos padrões na saída das AVCs. Observe que a variável canônica 2 (VC2) não possui poder de discriminação.

A linha vertical na saída de cada AVC, na Figura 4.10, indica o limiar de decisão usado para discriminar as classes. Na saída da AVC-CK, por exemplo, todo padrão que encontrar-se ao lado esquerdo da linha de limiar será identificado como um complexo K. Os demais padrões, situados à direita do limiar, serão reconhecidos como não-complexo K.




Figura 4.10 - Resultado das AVC-CK (esquerda) e AVC-FS (direita). A linha vertical indica o limiar de decisão entre os padrões.

Existe uma situação, entretanto, em que o mesmo padrão pode ser identificado, através das duas AVCs distintas, como pertencente a duas classes diferentes. Neste caso, a decisão é tomada pelo sistema de controle, o qual será discutido posteriormente.

Para calcular o limiar de decisão da AVC⁶, primeiro calcula-se, durante a fase de treino⁷, a média da coordenada horizontal (variável canônica 1) dos padrões de cada classe, ou seja, calcula-se a coordenada horizontal do ponto onde localiza-se o centro de massa de uma classe.

$$\bar{x}_i = \frac{1}{N_i} \sum_{n=1}^{N_i} x_i(n) \quad (4.7)$$

onde N_i é o número de padrões da classe i , $x_i(n)$ é a coordenada horizontal, na saída da ACV, do n -ésimo padrão da classe i e \bar{x}_i é a média das coordenadas horizontais, na saída da ACV, da classe i .

Calculadas as médias \bar{x}_1 , para a classe padrão (CK ou FS), e \bar{x}_2 , para a classe não-padrão (\overline{CK} ou \overline{FS}), o próximo passo para obtenção do limiar é calcular a média ponderada entre \bar{x}_1 e \bar{x}_2 , como mostra a equação (4.8).

$$L = (s - 1) \cdot \bar{x}_1 + s \cdot \bar{x}_2 \quad (4.8)$$

⁶ O cálculo do limiar de decisão de uma AVC é feito pelo sistema de controle.

⁷ A etapa de treinamento de uma AVC é definida como a fase em que a matriz de transformação canônica, para um dado conjunto de treinamento, é construída.

onde s é a sensibilidade da RNA ou AVC, que determina o quão estas são capazes de identificar os padrões alvos corretamente.

Baseado na Figura 4.10, observe que quanto maior o valor de s , mais o limiar estará deslocado para a direita, no caso da AVC-CK, ou para a esquerda, no caso da AVC-FS. Em geral, o limiar se desloca em direção à coordenada horizontal (VC1) do centro de massa do grupo de padrões-complementares à medida que aumenta-se o valor de s . Desta forma, quanto maior o valor de s , maior a probabilidade da AVC identificar corretamente um padrão-alvo como sendo tal, ou seja, maior o número de VP. Além disso, percebe-se que um acréscimo em s ocasiona também um aumento na quantidade de FP em paralelo com uma redução do número de VN e FN.

Relembrando os conceitos de sensibilidade e especificidade definidos no capítulo anterior, deduz-se que um aumento na quantidade de VP e FP e uma correspondente redução no número de VN e FN implicam em um acréscimo e decréscimo, respectivamente, da sensibilidade e especificidade da AVC.

4.3.2. Rede Neural Artificial

A topologia das redes neurais empregadas neste trabalho é a direta (*feedforward*) com o algoritmo de retropropagação do erro (*backpropagation*). O número de neurônios na camada de entrada da RNA é determinado pela dimensionalidade do vetor de entrada. Assim sendo, as RNAs utilizadas neste trabalho possuem 16 neurônios em suas camadas de entrada. O número de neurônios na camada de saída, por sua vez, depende da quantidade de classes a serem separadas. Uma rede com n_s neurônios em sua camada de saída tem a capacidade de discriminar 2^{n_s} diferentes classes. Desta forma, como cada RNA faz a distinção entre duas classes apenas, utilizou-se um neurônio na camada de saída.

A quantidade de neurônios na camada oculta, por conveniência, deve ser um valor menor que o número de neurônios na camada de entrada e maior que a dimensionalidade da saída da rede. Por conseguinte, utilizou-se o mesmo critério utilizado no trabalho de Argoud (2001), onde o número de neurônios na camada oculta é definido como:

$$N_{hidden} = \sqrt{N_{in} \cdot N_{out}} \quad (4.9)$$

onde N_{in} é o tamanho da camada de entrada e N_{out} é o tamanho da última camada da rede. Assim, uma vez que $N_{in} = 16$ e $N_{out} = 1$, tem-se que $N_{hidden} = 4$.

A taxa de aprendizado das RNAs utilizadas neste trabalho é igual a 0.05, bem como o *momentum* das mesmas é igual a 0,9. Ademais, a função de ativação empregada foi a tangente hiperbólica, definida pela equação (4.10).

$$\varphi(v) = a \cdot \tanh(bv) \quad (4.10)$$

onde a é o parâmetro que regula os limites da saída dos neurônios e b o parâmetro que regula a inclinação da curva sigmóide. As RNAs utilizadas aqui possuem $a = 1,0$ e $b = 0,5$. Esses valores são tais que os campos locais induzidos dos neurônios fiquem dentro do intervalo linear da função de ativação sigmóide. Desta forma, a saída de cada neurônio das RNAs fica limitada entre -1 e 1. Além disso, o padrão de entrada, antes de ser apresentado à rede, é normalizado de tal forma que seus valores permaneçam entre -1 e 1.

A inicialização dos pesos das RNAs é feita de forma randômica, de maneira tal que os pesos da rede, para a primeira iteração na fase de treinamento, situem-se dentro do intervalo $[-0,5 : 0,5]$.

Com relação ao critério de parada das RNAs, optou-se por parar o treinamento das mesmas quando o erro máximo dentro de uma época de treinamento fosse menor que 0.1. Quanto à utilização do *bias*, resolveu-se utilizá-lo, uma vez que este tem por função polarizar o neurônio de modo que o campo local induzido deste situe-se dentro da parte linear da função de ativação.

O critério de decisão de uma RNA é semelhante ao usado por uma AVC. Durante a fase de treino, quando apresenta-se um padrão à RNA, sua respectiva saída desejada também é apresentada. Caso seja apresentado um padrão-alvo (CK ou FS), a saída desejada da rede é ajustada para +1. Por outro lado, quando se apresenta um padrão-complementar (\overline{CK} ou \overline{FS}), a saída da rede é regulada em -1.

Para decidir a qual classe pertence um padrão, o sistema de controle primeiro calcula um limiar de decisão, definido pela equação (4.11), baseado na sensibilidade, s , da RNA. Em seguida, o SC verifica se a saída, y , da RNA está à direita (entre L e $y_d = +1$) ou à esquerda (entre L e $y_d = -1$) do limiar de decisão. Caso $L \leq y \leq +1$, o padrão é reco-

nhecido como um padrão-alvo. Caso contrário, o padrão é identificado como um padrão-complementar.

$$L = (s - 1) \cdot (+1) + s \cdot (-1) \quad (4.11)$$

Observe que um aumento no valor de s desloca o limiar sempre para a esquerda, uma vez que a saída desejada da RNA é +1 para os padrões alvo. Desta forma, um alto valor de s implica em uma maior quantidade de VP e FP e, simultaneamente, um menor número de VN e FN, assim como na AVC.

A Figura 4.11 ilustra um exemplo de decisão de uma RNA especialista em complexos K (RNA-CK) com $s = 0,35$. A Figura 4.11 (a) ilustra os padrões usados no treinamento, marcados com um “O”, e um padrão de teste, marcado com um “X”. A saída da RNA para este padrão é igual a 0,053. Calculando o erro na saída da rede para a saída desejada das duas classes, tem-se que o erro para um CK é 0,947 e para um \overline{CK} é 1,054, como mostra a Figura 4.11 (b). No entanto, embora o erro para CK seja menor que o erro para \overline{CK} , como a saída da RNA-CK está à esquerda do limiar de decisão ($-1 \leq y < L$) o padrão é reconhecido como um \overline{CK} .

Assim como ocorre no módulo de análise de variáveis canônicas, no módulo de redes neurais, duas RNAs distintas podem indicar o mesmo padrão de teste como sendo de

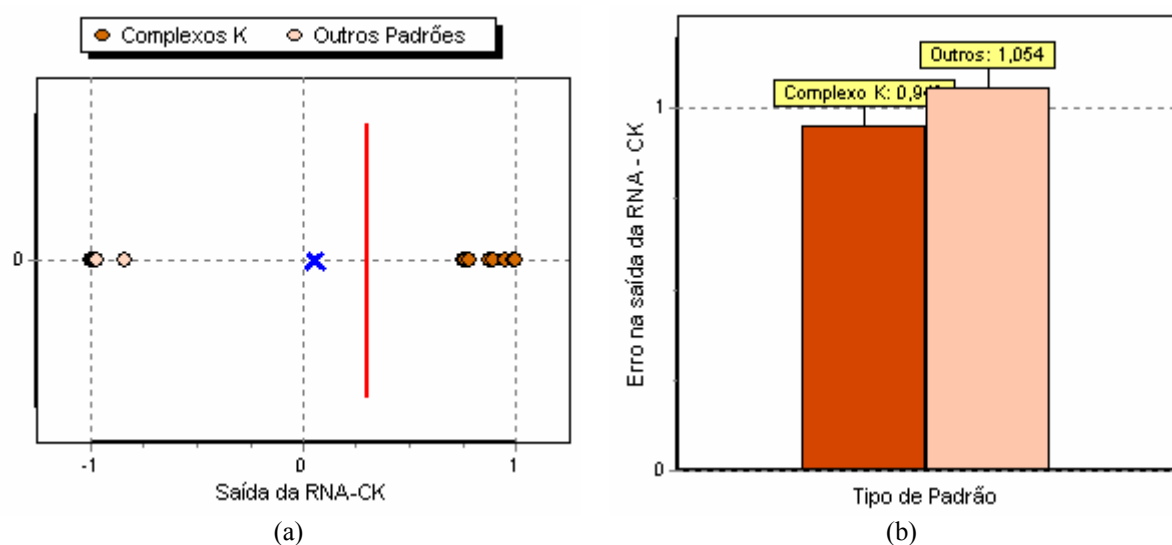


Figura 4.11 - Exemplo de decisão de uma RNA. Em (a), tem-se o limiar de decisão (linha vertical), a saída da RNA para os padrões usados durante o treinamento, marcados com “O”, e para um padrão de teste, marcado com um “X”. Em (b), o erro na saída da rede para as duas classes: CK e \overline{CK} .

diferentes classes. Quando isso ocorre, a decisão fica por conta do sistema de controle, que será detalhado posteriormente.

4.3.3. Transformada *Wavelet*

O módulo de transformada *wavelet*, como já dito anteriormente, analisa o sinal até o 6º nível de decomposição, adquirindo, desta forma, os sinais de detalhe das escalas 2, 3, 4, 5 e 6, que serão utilizados durante a etapa de extração de parâmetros, com a finalidade de construir o vetor de características do sinal.

Sabendo que o sucesso da metodologia proposta neste trabalho depende da escolha dos parâmetros extraídos dos sinais, procurou-se selecionar parâmetros que quantificassem, de alguma forma, a morfologia do sinal. Ao longo do desenvolvimento deste trabalho, então, percebeu-se que havia uma diferença entre os sinais de detalhe, em suas várias escalas, das diferentes classes de padrões tratadas aqui: complexos K, fusos do sono e atividades de fundo de EEG. Os fusos do sono, por exemplo, constituem-se, principalmente, dos sinais de detalhe das 2ª e 3ª escala da TW, como mostra a Figura 4.12. Os sinais de detalhe dos complexos K, conforme exhibe a Figura 4.13, são mais proeminentes nas escalas 4 e 5 (às vezes na 6ª escala), dependendo da duração da onda lenta do mesmo. As atividades de fundo de EEG, por sua vez, possuem componentes que podem se expressar em qualquer escala da TW. Às vezes, os sinais de detalhe da 4ª e 5ª escala das AF podem se confundir com os respectivos sinais de detalhes dos complexos K, segundo ilustra a Figura 4.14. Em geral, contudo, as escalas 4, 5 e 6 são mais ressaltadas nos complexos K.

Tendo em vista a diferença entre os diversos sinais de detalhes das diferentes classes de padrões, decidiu-se, então, selecionar parâmetros que quantificassem essa divergência nos sinais de detalhe das classes distintas. Após alguns testes, decidiu-se por escolher a energia das escalas 2, 3, 4, 5 e 6, a entropia das escalas 2 e 6 e o máximo valor do espectro das escalas 2, 3, 5 e 6. Estas medidas mostraram-se mais eficientes em se tratando de discriminar as classes pertinentes à este trabalho, no entanto não são, por si só, suficientes para realizar uma boa distinção das classes.

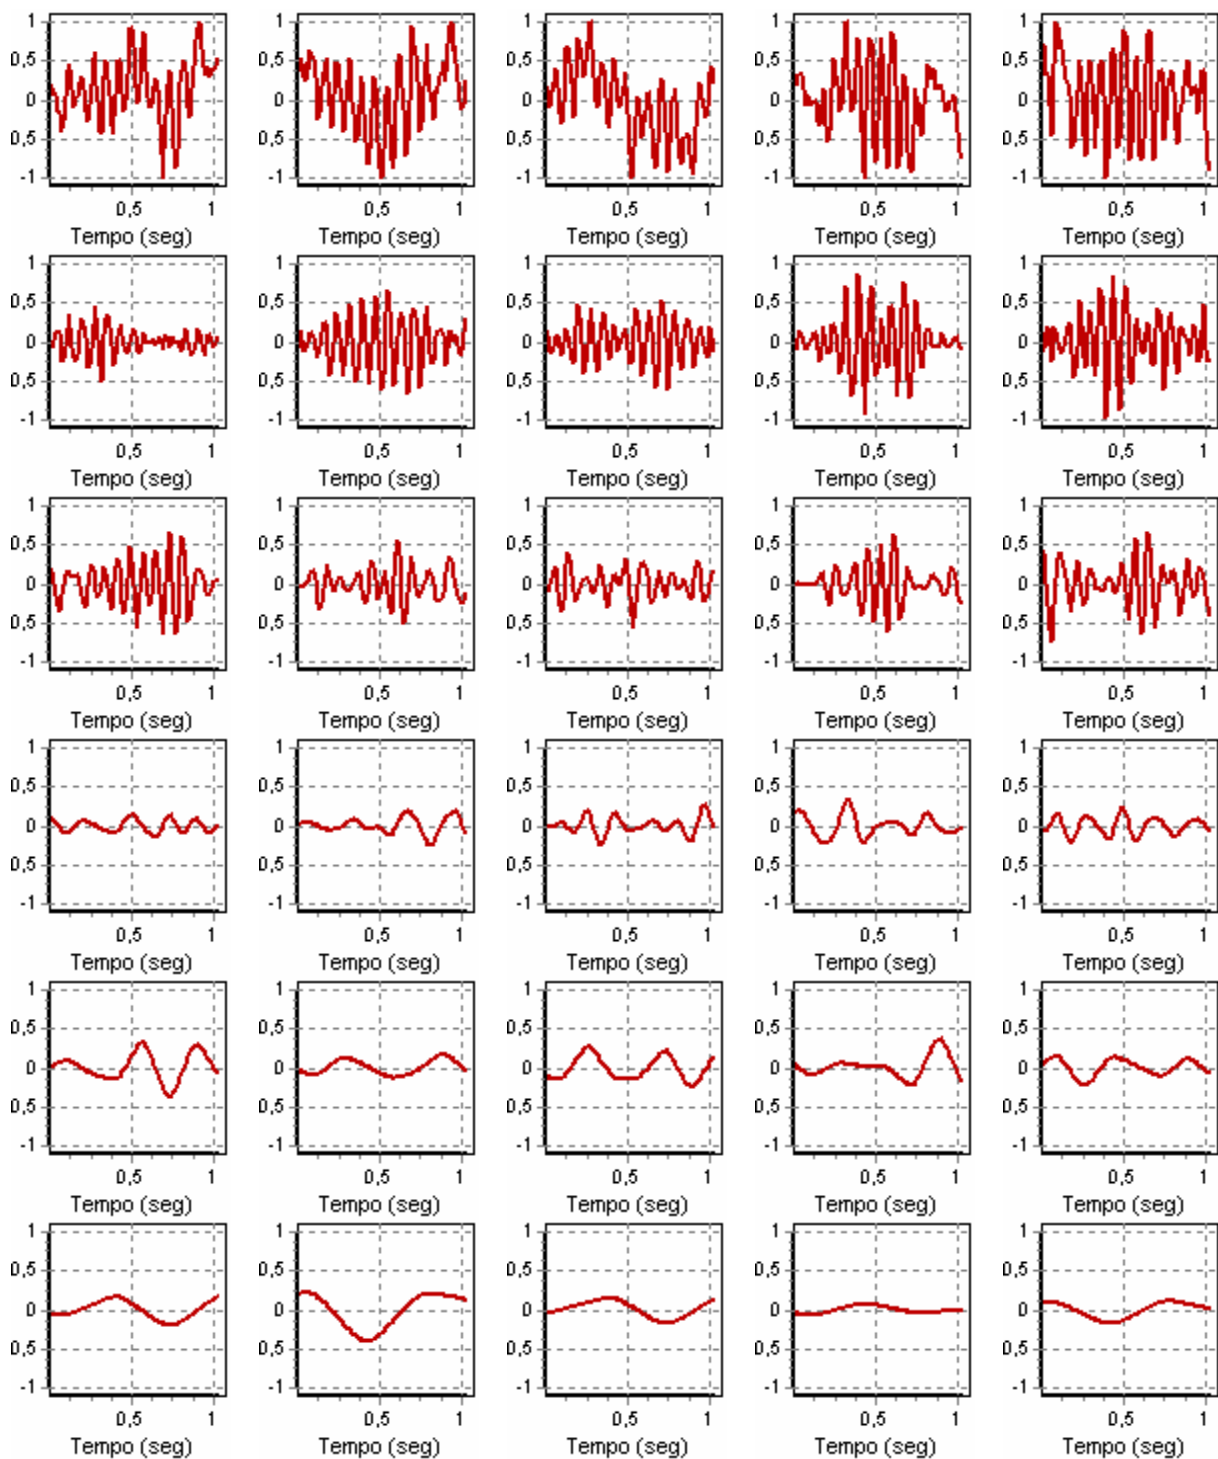


Figura 4.12 - Exemplos de fusos do sono e seus sinais de detalhe nas escalas 2, 3, 4, 5 e 6. A primeira linha mostra alguns fusos do sono com sua amplitude normalizada, a 2ª linha mostra o sinal de detalhe da 2ª escala, a 3ª linha ilustra o sinal de detalhe da 3ª escala, e assim por diante. Os sinais de detalhe dos FS são mais proeminentes nas escalas 2 e 3 da TW.

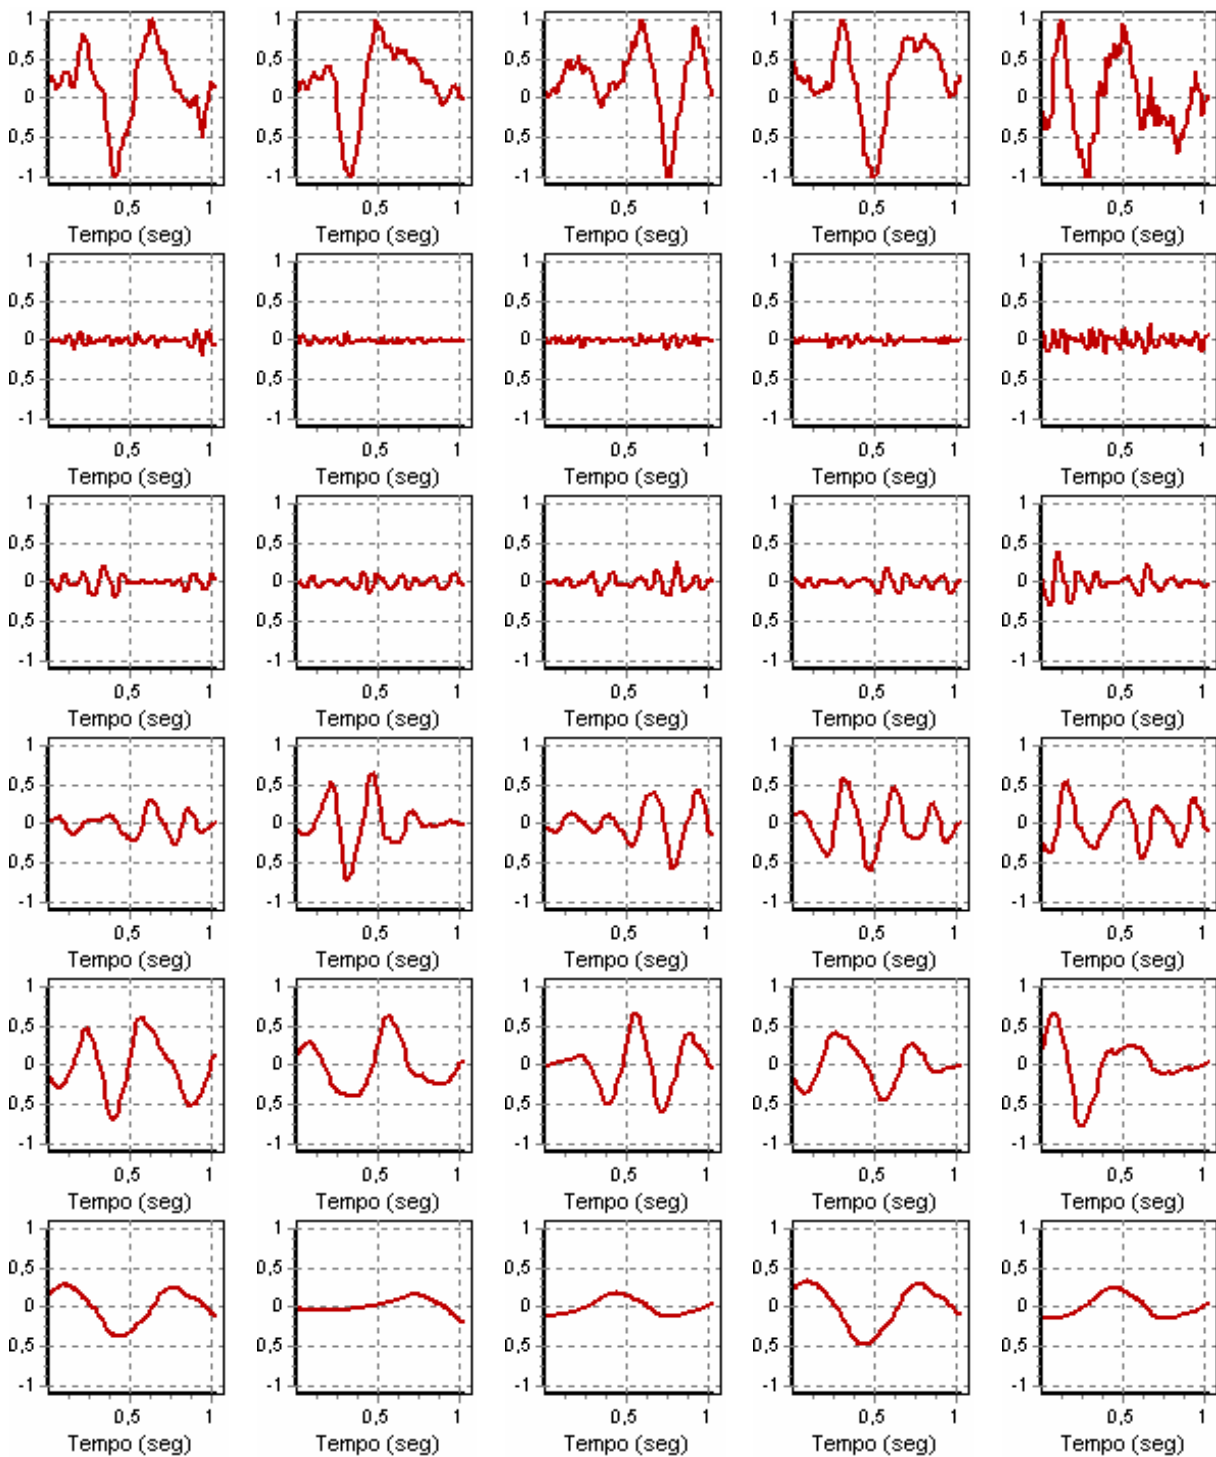


Figura 4.13 – Exemplos de complexos K e seus sinais de detalhe nas escalas 2, 3, 4, 5 e 6. A primeira linha mostra os complexos K com sua amplitude normalizada, a 2ª linha mostra os respectivos sinais de detalhe da 2ª escala, a 3ª linha ilustra os sinais de detalhe da 3ª escala, e assim por diante. Os sinais de detalhe dos CK são mais expressivos nas escalas 4 e 5 da TW.

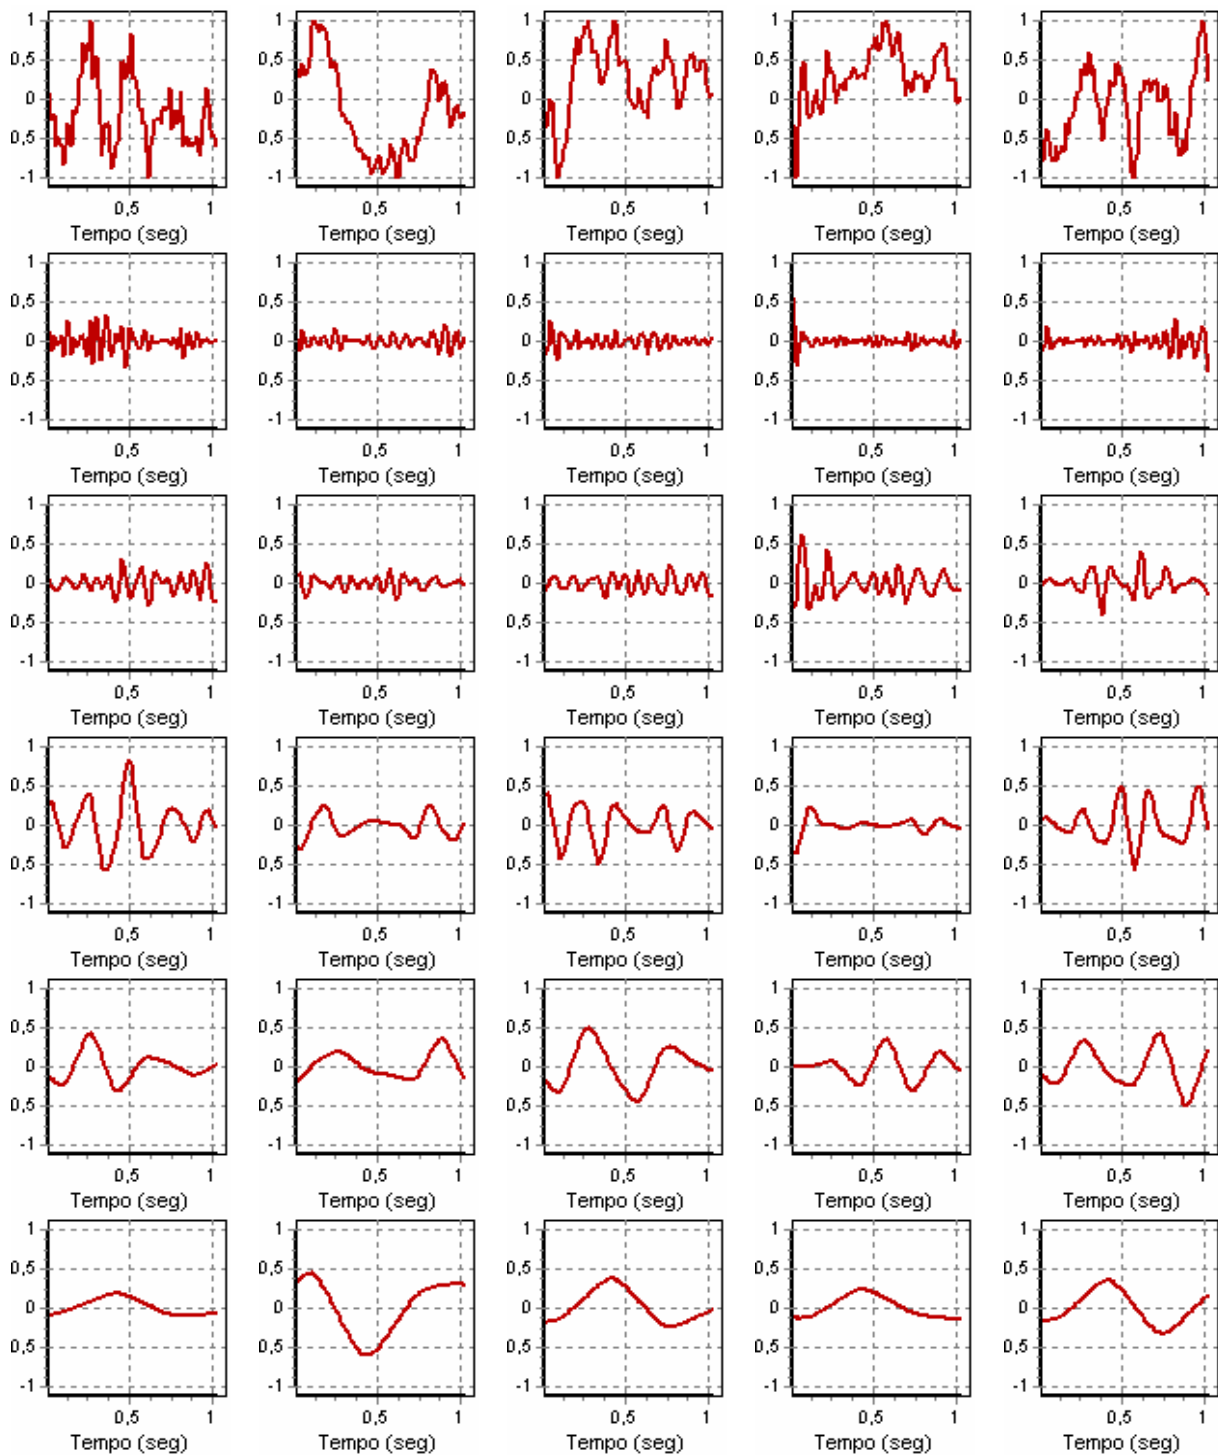


Figura 4.14 - Exemplos de atividade de fundo de EEG e seus respectivos sinais de detalhe nas escalas 2, 3, 4, 5 e 6. A primeira linha mostra algumas atividades de fundo de EEG com suas amplitudes normalizadas, a 2ª linha mostra os sinais de detalhe da 2ª escala, a 3ª linha ilustra os sinais de detalhe da 3ª escala, e assim por diante. Os sinais de detalhe das AF mostram-se bem distribuídos em todas as escalas da TW, dependendo do instante em que se calcula a transformada.

Para aprimorar a metodologia, então, optou-se por utilizar outras medidas, já mencionadas anteriormente, tais como frequência principal, frequência média, entropia do sinal, entre outras.

De acordo com a Figura 4.12, a Figura 4.13 e a Figura 4.14 é possível observar que a distinção dos fusos do sono das demais classes deve-se, em grande proporção, às medidas relacionadas à transformada wavelet, uma vez que uma alta energia dos sinais de detalhe na 2ª e 3ª escala é característica desta classe. A distinção dos complexos K, porém, é um pouco mais complicada, pois algumas atividades de fundo de EEG, na faixa de frequência delta, confundem-se com a morfologia dos complexos K.

4.4. Escolha da Função Wavelet

Uma vez que o resultado das RNAs e das ACVs dependem da escolha da função wavelet utilizada para a decomposição e reconstrução dos sinais, foi elaborada uma análise comparativa, com a finalidade de embasar a escolha da melhor função wavelet⁸ para cada RNA e ACV do sistema.

Esse estudo comparativo consiste em treinar as AVCs (AVC-CK e AVC-FS) e RNAs (RNA-CK e RNA-FS) utilizando diferentes funções *wavelets*, mostradas na Tabela 4.2. Em seguida, calculam-se a sensibilidade (Sen), a especificidade (Esp), o valor prediti-

Tabela 4.2 - Funções *wavelets* utilizadas na análise comparativa empregada para verificação das *wavelets* mais adequadas à detecção dos complexos K e fusos do sono.

FUNÇÕES WAVELETS					
bior1.1	bior3.9	db3	db14	dmey	rbio3.7
bior1.3	bior4.4	db4	db15	rbio1.1	rbio3.9
bior1.5	bior5.5	db5	db16	rbio1.3	rbio4.4
bior2.2	bior6.8	db6	db17	rbio1.5	rbio5.5
bior2.4	coif1	db7	db18	rbio2.2	rbio6.8
bior2.6	coif2	db8	db19	rbio2.4	sym2
bior2.8	coif3	db9	db20	rbio2.6	sym3
bior3.1	coif4	db10	db25	rbio2.8	sym4
bior3.3	coif5	db11	db30	rbio3.1	sym5
bior3.5	db1 (Haar)	db12	db35	rbio3.3	sym6
bior3.7	db2	db13	db40	rbio3.5	sym7

⁸ ⁸As funções wavelet utilizadas pertencem às seguintes famílias: biortogonal (bior), coiflets (coif), daubechies (db), dmeyer (dmey), biortogonal reversa (rbio) e symlets (sym).

vo positivo (VPP) e o valor preditivo negativo (VPN) de cada AVC e RNA, utilizando um conjunto de testes diferente daquele usado durante o treinamento.

O desempenho das AVCs e RNAs, neste trabalho, é medido por meio da média entre a sensibilidade e a especificidade das mesmas, como mostra a equação (4.12).

$$D = \frac{Sen + Esp}{2} \quad (4.12)$$

O resultado da análise comparativa, usada para escolha da função *wavelet*, é detalhado no capítulo 5, referente aos resultados deste trabalho. As funções *wavelets* que proporcionaram os melhores resultados para as RNAs e AVCs foram submetidas à etapa final de testes, onde foram escolhidas épocas aleatórias dos registros que não fizeram parte da etapa de treinamento.

4.5. Sistema de Controle

O sistema de controle (SC) é o módulo responsável em tomar decisões dentro do sistema. Por exemplo, caso a época em teste não tenha amplitudes e frequências relativas ao estágio II do sono NREM ele decide por não enviá-la à fase de detecção de padrão. Desta maneira, uma de suas funções é fazer o controle das épocas que passarão para a fase de detecção dos padrões. O cálculo do limiar de decisão das AVCs e das RNAs também é responsabilidade do SC. Além disso, o sistema de controle também é, na verdade, quem decide a qual classe pertence determinado padrão, baseado nas informações enviadas pelas RNAs ou pelas AVCs.

No caso das RNAs, por exemplo, o SC primeiro calcula o limiar de decisão da RNA-CK e da RNA-FS. Em seguida, ele verifica se a saída da RNA-CK, $y(CK)$, é maior ou menor do que o limiar da RNA-CK. Caso seja menor, o SC identifica o padrão com sendo um \overline{CK} , que pode ser um fuso do sono, caso a saída da RNA-FS seja maior que o limiar da mesma, ou uma atividade de fundo de EEG, caso contrário. Por outro lado, caso a saída da RNA-CK seja maior que o limiar desta, o padrão é reconhecido como um complexo K, se a saída da RNA-FS for menor que o limiar da mesma; se não o SC verifica qual RNA obteve sua saída mais distante do seu respectivo limiar de decisão. Caso tenha sido a RNA-CK, o padrão é reconhecido como um complexo K; caso tenha sido a RNA-FS, o

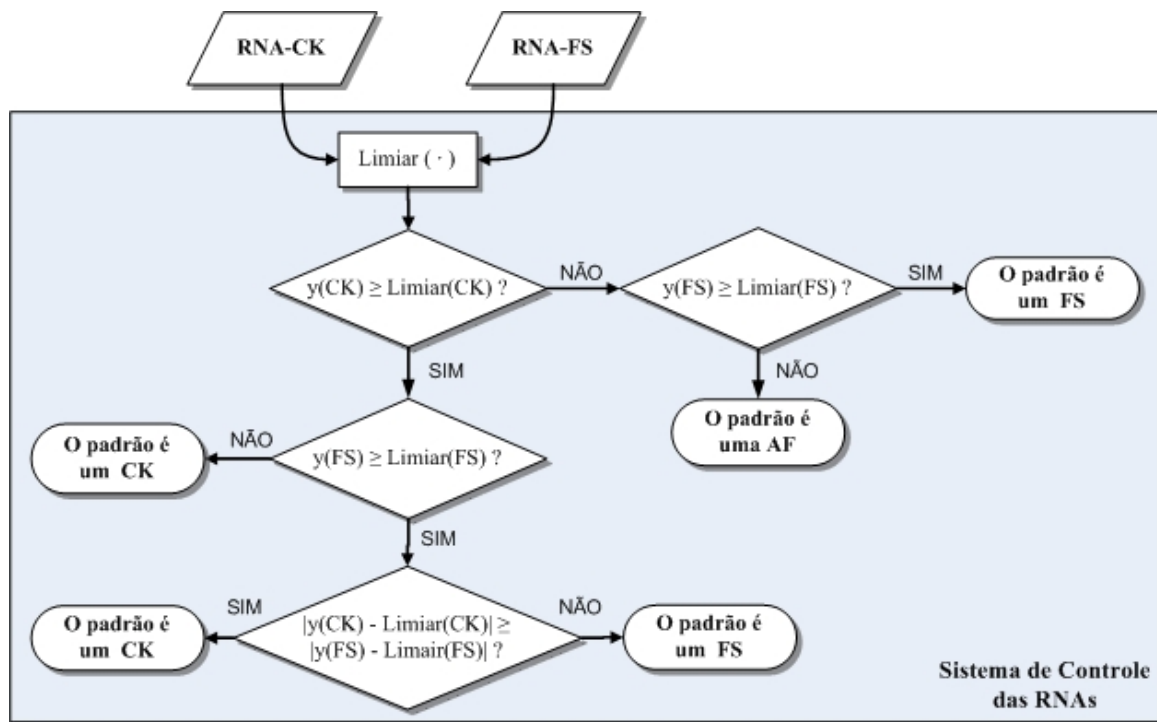


Figura 4.15 – Sistema de controle das RNAs. Esta parte do SC é responsável pela definição (identificação) do padrão apresentado pelo par de RNAs do sistema. O bloco “Limiar (·)”, calcula o limiar de decisão das RNAs baseado na sensibilidade de cada uma.

padrão é definido como um fuso do sono. A Figura 4.15 ilustra um fluxograma baseado nessas regras.

A base de regras do sistema de controle responsável pela identificação dos padrões através da análise de variáveis canônicas é similar ao das RNAs. O SC, no caso das AVCs, primeiro verifica se os padrões-alvo estão à direita ou à esquerda do limiar de decisão⁹. Para isso, o SC verifica se a média dos padrões-alvo é maior ou menor que o limiar de decisão da AVC.

Após verificar a região dos padrões alvos e dos padrões complementares, o sistema de controle compara a variável canônica 1 na saída da AVC-CK, $VC1(CK)$, com o limiar de decisão da mesma. Caso a $VC1(CK)$ não esteja na região correspondente ao CK, o padrão é reconhecido como um fuso do sono, se $VC1(FS) \in Side(FS)$ ¹⁰, ou como uma ativi-

⁹ Na análise de variáveis canônicas, ao contrário das RNAs, a classe de padrões-alvo pode estar à direita ou à esquerda do limiar de decisão, dependendo do conjunto de treinamento e da função wavelet utilizada.

¹⁰ $Side(P)$, onde $P = CK$ ou $P = FS$, representa a região correspondente à classe P , ou seja, a região $(x \geq L$ ou $x < L$: L é o limiar da AVC e x é a coordenada horizontal, $VC1$, do espaço canônico) onde encontram-se os padrões P .

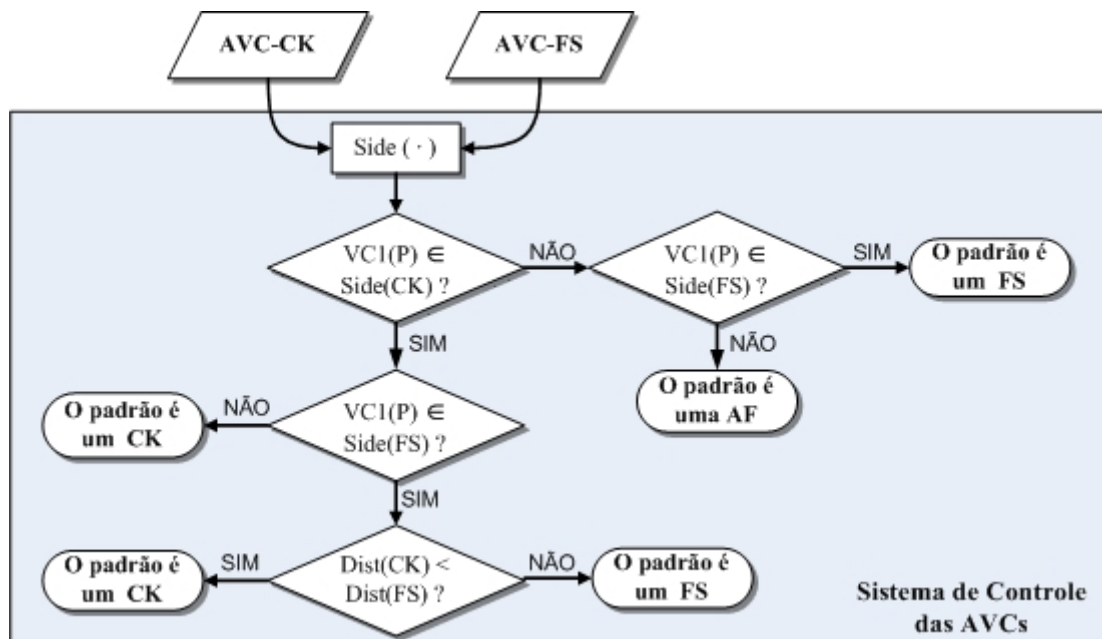


Figura 4.16 – Sistema de controle das ACVs. Esta parte do SC é responsável pela definição (identificação) do padrão apresentado pelo par de ACVs do sistema. O bloco “Side (·)” verifica se a saída da AVC, para o padrão teste, está dentro ou fora da região correspondente ao padrão P.

dade de fundo de EEG, caso $VC1(FS) \notin Side(FS)$. Caso $VC1(CK) \in Side(CK)$, o SC verifica então se a AVC-FS também identificou o padrão como um fuso do sono. Caso a ACV-FS não o tenha feito, o padrão é definido como sendo um complexo K; caso contrário, o SC verifica qual AVC obteve a saída mais distante do limiar. Se a distância entre a saída da AVC-CK e seu respectivo limiar for maior ou igual a distância entre a saída da AVC-FS e seu respectivo limiar, o padrão é, então, reconhecido como um CK; se não, o padrão é reconhecido como um FS. A Figura 4.16 ilustra um fluxograma baseado nestas regras.

Observe que um padrão é reconhecido como um complexo K somente se $VC1(CK)$ estiver no mesmo lado que a média dos CKs, ou seja, se ambos estiverem à direita, ou ambos à esquerda do limiar de decisão da AVC-CK. Equivalentemente, um padrão somente é reconhecido como um FS somente se $VC1(FS)$ e a média da classe FS estiverem ambos à esquerda ou ambos à direita do limiar de decisão da AVC-FS.

O bloco Side (·) verifica se a média das VC1 da classe P, $P = CK$ ou $P = FS$, está situada à direita ou à esquerda do limiar de decisão, ou seja, verifica a região onde locali-

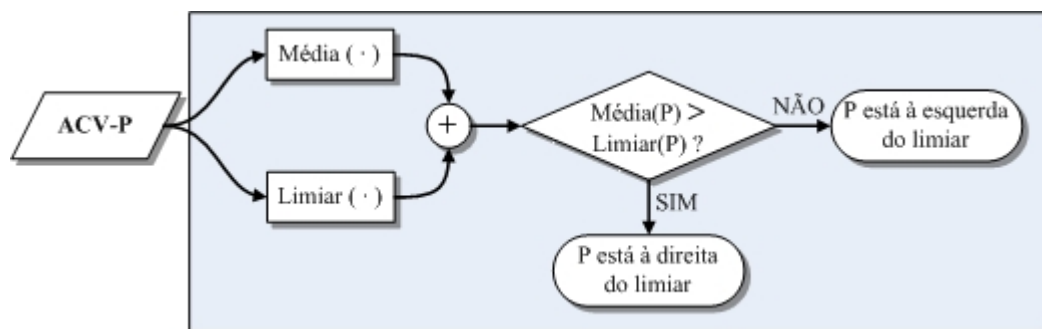


Figura 4.17 - Fluxograma para detecção da região dos padrões-alvo. AVC-P é uma análise canônica de variáveis especialista em identificar o padrão-alvo P (P = CK ou P = FS). Resumidamente, esta função investiga se os padrões da classe P estão à esquerda ou à direita do limiar de decisão da AVC-P.

zam-se os padrões da classe P. A Figura 4.17 apresenta um detalhamento do funcionamento do bloco Side (·).

Capítulo 5

Software Desenvolvido

Para realização deste trabalho, foi desenvolvido um software que consiste em dois módulos principais. O primeiro módulo diz respeito à visualização e inspeção dos sinais de EEG do registro polissonográfico. O segundo módulo, por sua vez, consiste no treinamento das RNAs e AVCs, responsáveis pela detecção dos padrões de EEG durante o sono. Este capítulo, então, se destina a descrever os módulos do software, detalhando seu funcionamento e, de certa forma, servindo como um manual do usuário para o mesmo.

5.1. Módulo de Visualização e Inspeção dos Sinais (MVIS)

Uma vez que este trabalho tem o intuito de detectar e classificar somente padrões do sono nos sinais de EEG, o software desenvolvido possibilita a visualização apenas dos quatro primeiros canais do registro polissonográfico, referentes aos quatro canais de EEG (C3, C4, O1 e O2). A Figura 5.1 ilustra a interface do MVIS, onde se pode observar a visualização dos quatro canais de EEG. Abaixo da tela de exibição dos sinais, têm-se as opções de visualização dos mesmos (**Página / Escala e Transformada Wavelet**), bem como as opções de salvamento dos padrões (**Salvar Padrão**).

O menu **Página / Escala**, na Figura 5.1, permite ao usuário avançar ou recuar as páginas do registro e aumentar ou diminuir a escala de amplitude dos sinais de EEG. O menu **Transformada Wavelet**, por sua vez, possibilita ao usuário alternar entre a visualização do sinal original e dos sinais de detalhes e aproximação da TW. Além disso, pode-se também escolher a escala e a função *wavelet* usada na análise e síntese do sinal. Finalmente, o menu **Salvar Padrão** concede ao usuário a capacidade de escolher o canal e o instante onde ocorre um determinado padrão, antes de salvá-lo.

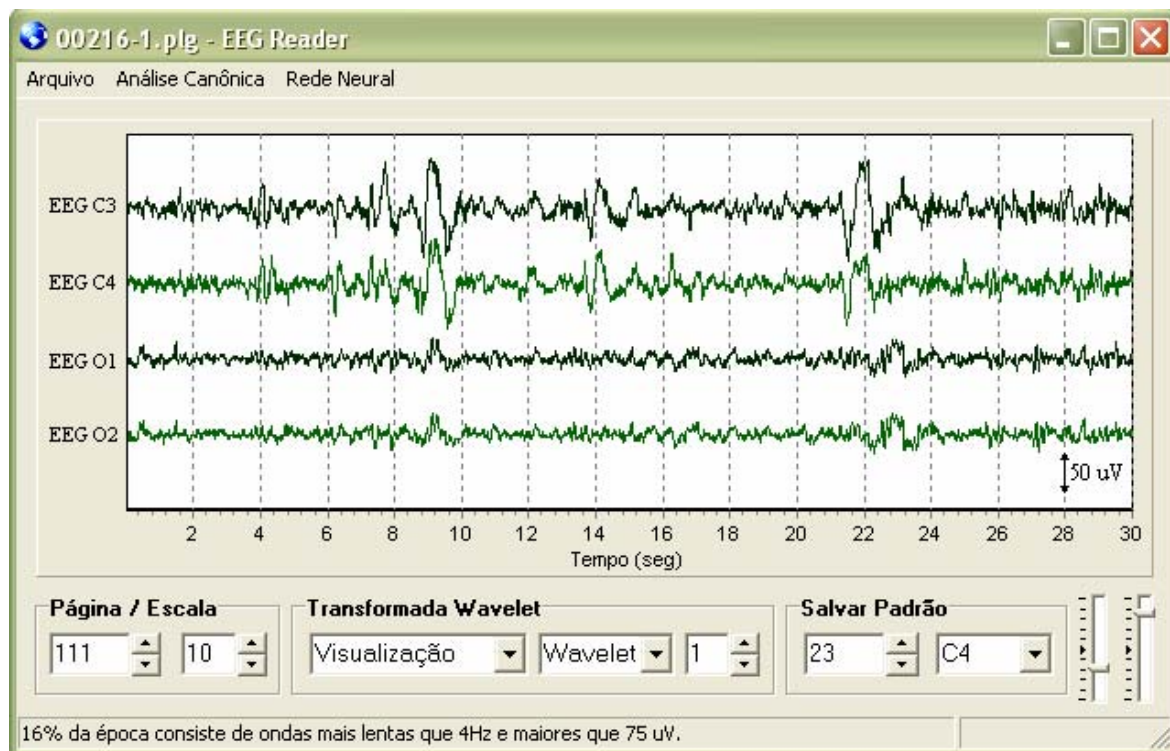


Figura 5.1 - Interface do módulo de visualização e inspeção de sinais do software desenvolvido.

Ao lado do menu **Salvar Padrão** existem duas barras de rastreamento que regulam a sensibilidade das RNAs e AVCs. A barra à esquerda é responsável pela sensibilidade das RNAs e AVCs especialistas em complexos K, já a barra à direita regula a sensibilidade relativa à detecção dos fusos do sono.

Além das opções descritas nos parágrafos anteriores, o MVIS também permite ao usuário carregar um registro polissonográfico, visualizar o hipnograma do mesmo, calcular a FFT de uma época do registro, salvar um padrão de treino, carregar uma AVC ou uma RNA salva anteriormente e analisar uma época, ou um registro inteiro, através das RNAs ou das AVCs. Tudo isso pode ser feito por meio das opções no menu do software. A Figura 5.2 apresenta uma árvore desse menu, ilustrando as opções que o MVIS disponibiliza ao usuário.

Observe que o usuário pode optar em salvar um padrão como pertencente a um dos três tipos de classe: atividade de fundo de EEG, complexo K e fuso do sono. Isso ocorre porque o treinamento das RNAs e das AVCs é supervisionado, então é indispensável que os padrões de treinamento sejam conhecidos a priori.

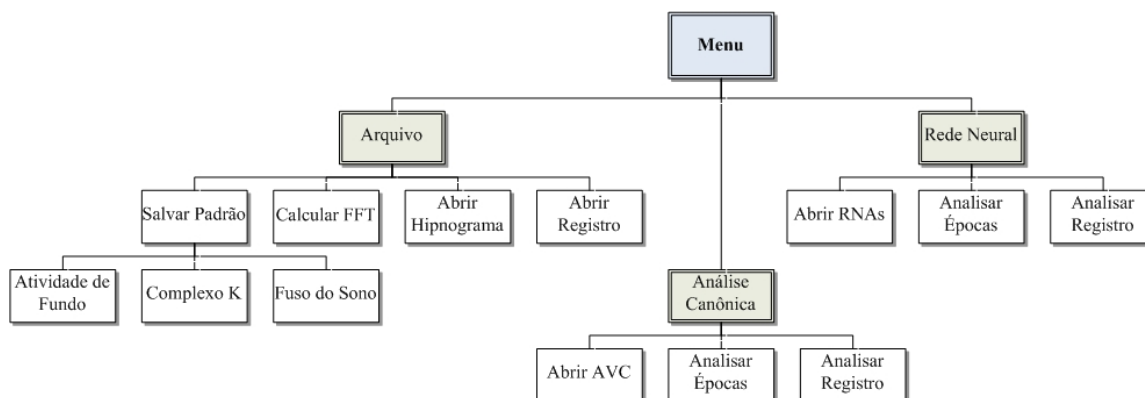


Figura 5.2 - Organização do menu principal do módulo de visualização do software desenvolvido.

Tanto no menu Análise Canônica, como no menu Rede Neural o usuário tem a opção de analisar uma época, caso queira detectar os padrões somente na época atual, ou o registro inteiro, caso queira detectar os padrões em todo o registro. Só é possível realizar a detecção, no entanto, após carregar uma RNA, ou uma AVC, salva anteriormente. A Figura 5.3 ilustra a visualização de uma época após a inspeção dos canais de EEG, por meio da análise de variáveis canônicas. Os complexos K são destacados em laranja e os fusos do sono são destacados em azul.

Observe que o sistema de controle faz a inspeção dos padrões em intervalos de 0,5 segundos, ou seja, primeiro ele verifica se existe um CK, ou um FS, entre os instantes $t = 0,0$ s e $t = 1,0$ s. Em seguida, inspeciona-se o intervalo $0,5 \leq t \leq 1,5$ e assim por diante. Isso evita que eventos que começam no final de um segundo e terminam no começo do segundo posterior passem despercebidos pelo sistema.




Figura 5.3 - Detecção de complexos K e fusos do sono por meio da análise das variáveis canônicas, com $s = 0,8$ para a AVC-CK e $s = 0,5$ para a AVC-FS e wavelet = coif3.

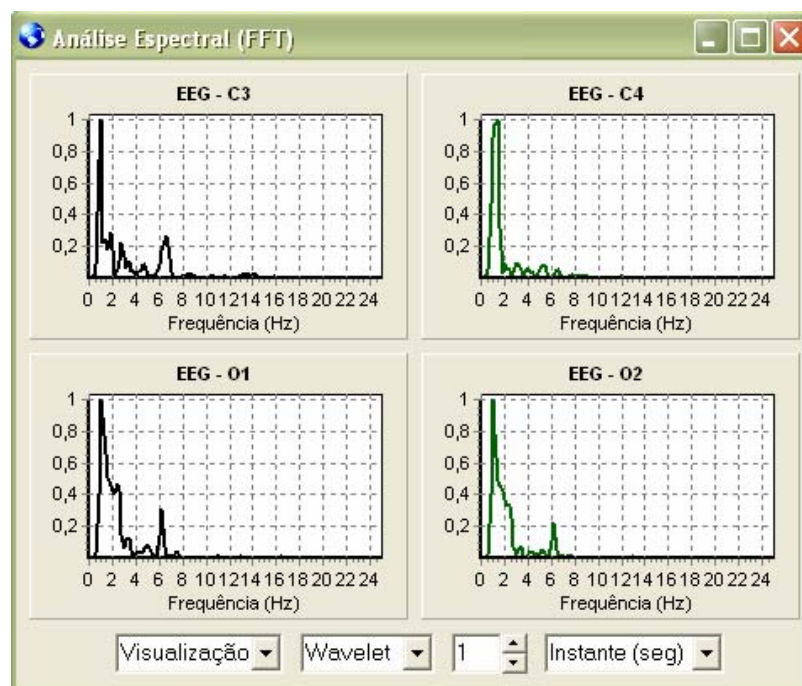


Figura 5.4 - Análise espectral do módulo de visualização e inspeção de sinais. Esta janela exibe a transformada de Fourier dos canais de EEG do registro polissonográfico.

Além da janela principal, o módulo de visualização e inspeção de sinais possui uma interface, Análise Espectral (FFT)¹, onde é possível visualizar as FFTs, calculadas para trechos de quatro segundos² do sinal, das quatro derivações de EEG, conforme ilustra a Figura 5.4. Além de exibir a FFT do sinal de EEG, pode-se visualizar a TW do espectro do sinal, em suas várias escalas e para várias funções *wavelets*.

Perceba ainda que, na parte inferior da interface principal do MVIS, existe uma barra de status que indica a funcionalidade de cada componente da tela do software, servindo, desta forma, como um *help* para o mesmo. Além disso, a barra de status indica se o software está ocupado processando algum tipo de informação, tal como fazendo a análise do registro através das RNAs.

5.2. Módulo de Treinamento

O módulo de treinamento tem como principal finalidade treinar e testar as RNAs (RNA-CK e RNA-FS) e as AVCs (AVC-CK e AVC-FS) do sistema, utilizando os padrões

¹ Para exibir a janela Análise Espectral (FFT) deve-se escolher a opção Calcular FFT no menu Arquivo.

² A escolha de um trecho de quatro segundos para o cálculo da FFT do sinal fundamenta-se na escolha de uma janela com uma boa resolução temporal, sem, no entanto, prejudicar a resolução espectral.

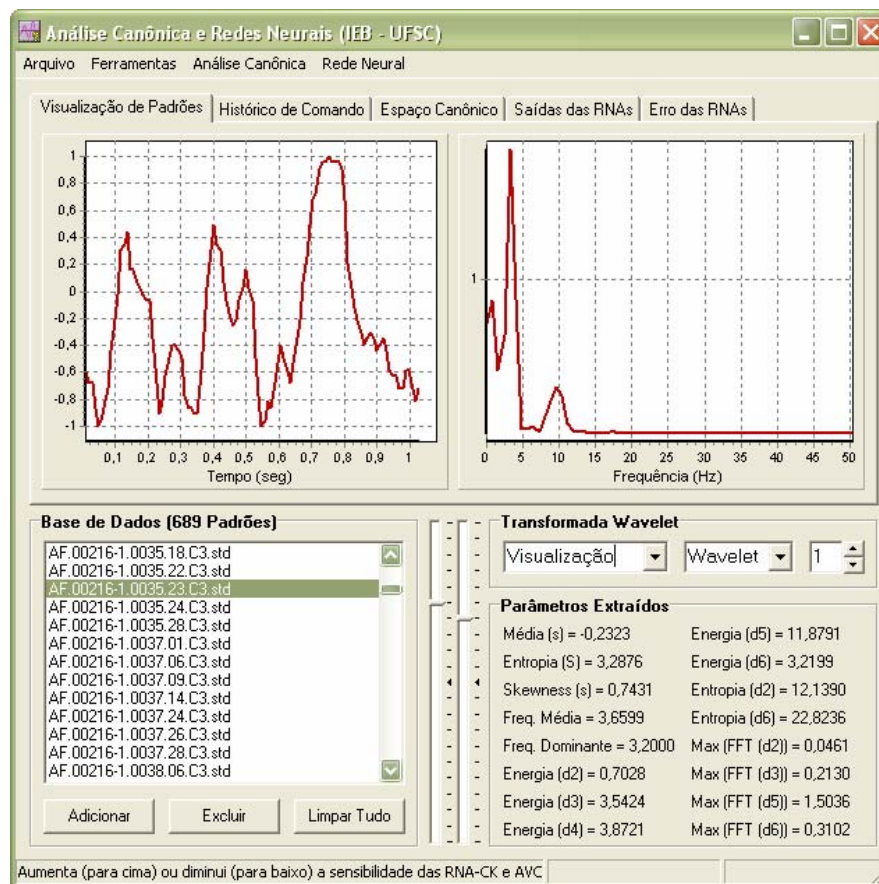


Figura 5.5 - Módulo de treinamento do sistema. Neste módulo o usuário pode visualizar os padrões salvos, extrair parâmetros destes, treinar e testar as RNAs e as AVCs do sistema de detecção de padrões.

salvos, por meio do MVIS, durante a análise dos registros. A Figura 5.5 apresenta a interface do módulo de treinamento do sistema.

Observe que a interface do módulo de treinamento é composta por um menu principal, localizado na parte superior da mesma, um menu de visualização (logo abaixo do menu principal), duas barras de rastreamento, uma barra de status, na parte inferior, e três blocos (caixa de grupamento³): **Base de Dados**, **Transformada Wavelet** e **Parâmetros Extraídos**.

As duas barras de rastreamento, assim como no MVIS, regulam a sensibilidade das RNAs e AVCs. A barra à esquerda regula a sensibilidade da RNA-CK e da AVC-CK. A barra à direita, por sua vez, é responsável pela sensibilidade relativa à detecção dos fusos do sono.

³ Caixa de grupamento (*GroupBox*) é um componente do software C++ Builder, que agrupa componentes com finalidades semelhantes. Quando um componente é colocado dentro de um *groupbox*, este torna-se pai (*parent*) desse componente.

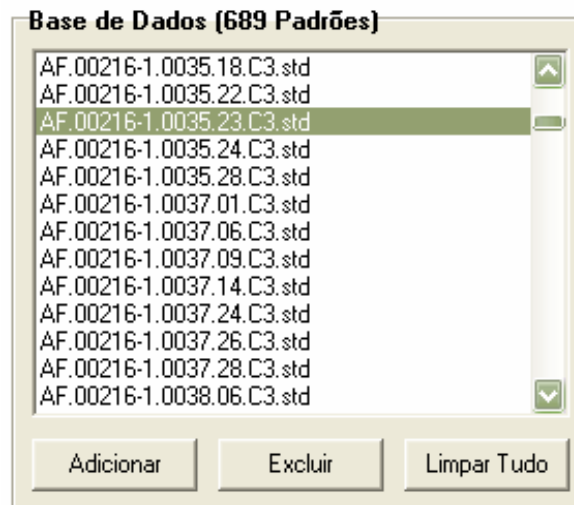


Figura 5.6 - Bloco **Base de Dados**: grupo de componentes onde o usuário pode montar uma base de dados.

No bloco **Base de Dados**, mostrado na Figura 5.6, o usuário pode adicionar ou excluir um padrão à base de dados. Além disso, podem-se apagar todos os padrões enumerados na lista. Desta forma, o usuário pode montar sua própria base para treinar e testar as RNAs e AVCs.

Ao selecionar um dos padrões na lista da base de dados, o software automaticamente mostra tal padrão, assim como seu respectivo espectro, no item **Visualização de Padrões** do menu de visualização. Adicionalmente, o software calcula e exhibe, no bloco **Parâmetros Extraídos**, os parâmetros extraídos do padrão em destaque, conforme ilustra a Figura 5.7.

No menu **Transformada Wavelet**, assim como no **MVIS**, pode-se alternar entre a visualização do sinal original e dos sinais de detalhe e aproximação da TW do padrão destacado. Pode-se ainda visualizar a TW para diferentes escalas e funções *wavelets*. À medida

Parâmetros Extraídos	
Média (s) = 0,3270	Energia (d5) = 2,3904
Entropia (S) = -6,2854	Energia (d6) = 0,8132
Skewness (s) = -1,4773	Entropia (d2) = 13,2192
Freq. Média = 1,4101	Entropia (d6) = 20,2861
Freq. Dominante = 0,0000	Max (FFT (d2)) = 0,0319
Energia (d2) = 0,8829	Max (FFT (d3)) = 0,1427
Energia (d3) = 2,2513	Max (FFT (d5)) = 0,0249
Energia (d4) = 1,9965	Max (FFT (d6)) = 0,0873

Figura 5.7 - Caixa de agrupamento **Parâmetros Extraídos**. Este bloco exhibe as medidas extraídas do padrão selecionado na lista da base de dados.

que o usuário muda a função *wavelet*, a escala da TW, ou o modo de visualização, os parâmetros exibidos no bloco **Parâmetros Extraídos** são atualizados automaticamente.

5.2.1. Opções de Menu

A barra de menus do módulo de treinamento do sistema é composta pelos menus e submenus mostrados na Figura 5.8.

No menu Arquivo, tem-se as opções Abrir Base, que carrega uma base de dados já salva anteriormente, e Salvar Base, que salva uma base de dados com os padrões exibidos na lista do bloco **Base de Dados**. O menu Ferramentas também possui dois submenus: Extrair Parâmetros e Limpar Histórico. O primeiro permite a extração dos parâmetros de todos os padrões na lista da base de dados exibindo-os, em seguida, no Histórico de Comandos, conforme ilustra a Figura 5.9. O segundo, por sua vez, apaga tudo o que foi escrito no Histórico de Comandos anteriormente.

O submenu Calcular AVCs do menu Análise Canônica realiza a análise das variáveis canônicas utilizando os padrões disponíveis na lista da base de dados. Após realizar a AVC, caso o usuário queira salvar a matriz de transformação canônica (MTC), deve-se selecionar opção Salvar Matriz de Transformação Canônica. Para carregar uma MTC salva outrora deve-se escolher a opção Abrir Matriz de Transformação Canônica. O submenu Testar Padrões mostra o resultado da AVC para os padrões da base de dados. Já o submenu Análi-

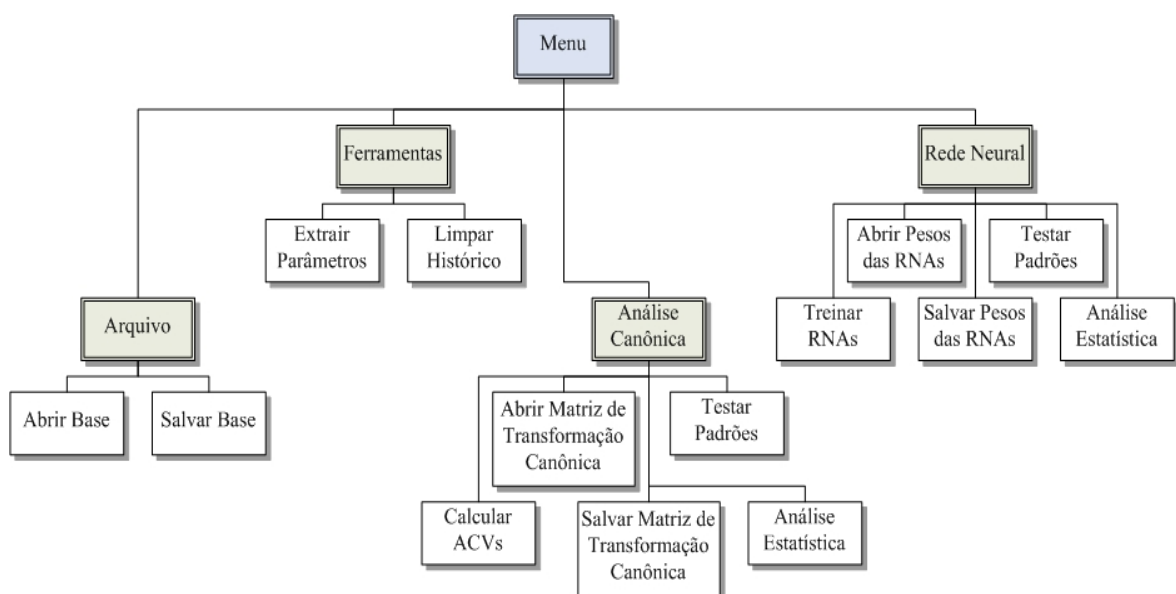


Figura 5.8 - Organização do menu do módulo de treinamento do software desenvolvido.

Visualização de Padrões							Histórico de Comando	Espaço Canônico	Saídas das RNAs	Erro das RNAs
0,1256	7,1630	-0,0401	4,9098	1,6000	1,0854	3,5304				
0,0019	6,8855	-0,0893	4,2603	3,2000	0,7927	4,3804				
0,0234	6,2251	0,0456	12,6682	2,4000	1,0978	3,0272				
0,0103	7,3365	-0,1282	5,4499	1,6000	0,6848	2,7411				
0,0649	-0,2027	-0,1481	2,4445	1,6000	0,5379	2,8643				
Complexos K:										
Média	Entropia	Skewness	Freq. Média	Freq. Dom.	Energia (d2)	Energia (d3)	E			
-0,0335	-14,4045	-0,0716	1,3914	1,6000	0,0625	0,3490				
0,0025	-1,5623	-0,1770	3,0102	2,4000	0,3880	0,2798				
-0,1845	-1,8704	0,5581	1,9452	1,6000	0,3133	0,4519				
-0,3229	-8,0037	1,3763	1,6845	1,6000	0,1132	1,0435				
-0,2930	-12,3985	0,8274	1,4263	0,8000	0,1642	1,0345				
-0,2058	-12,3485	0,8560	1,3007	0,8000	0,1115	0,6264				
-0,0659	-0,4799	0,2763	1,6512	1,6000	0,2388	0,8953				

Figura 5.9 - Histórico de Comando durante a extração de parâmetros dos padrões da base de dados.

se Estatística verifica os erros e acertos das AVCs, executando um estudo estatístico⁴ a fim de avaliar o desempenho do teste feito através da AVC.

A opção Treinar RNAs do menu Rede Neural inicia o treinamento da RNA-CK e da RNA-FS utilizando os padrões exibidos na lista da base de dados. Caso se deseje salvar as RNAs já treinadas deve-se escolher a opção Salvar Pesos das RNAs. Por outro lado, para carregar RNAs já salvas anteriormente basta selecionar o submenu Abrir Pesos das RNAs. A opção Testar Padrões propaga os vetores de característica dos padrões nas RNA-CK e RNA-FS, ilustrando o resultado do mapeamento entrada/saída feito pelas RNAs no item Saída das RNAs do menu de visualização. O submenu Análise Estatística, por sua vez, verifica os erros e acertos das RNAs e realiza uma análise estatística para avaliar o desempenho das RNAs no papel de distinção dos padrões de EEG durante o sono.

5.2.2. Opções de Visualização

Na interface do módulo de treinamento há um Menu de Visualização, ilustrado na Figura 5.10, que se dedica à visualização dos resultados. Esse menu é composto por cinco opções de visualização: Visualização dos Padrões, Histórico de Comando, Espaço Canônico, Saída das RNAs e Erro das RNAs.

⁴ A análise estatística (ou estudo estatístico) tanto das AVCs como das RNAs, é feita para os padrões exibidos na lista da base de dados, da mesma forma que o teste dos padrões.




Figura 5.10 - Visualização de Padrões do menu de visualização, ilustrando um fuso do som (esquerda) e sua FFT (direita).

Cada opção de visualização destina-se a um propósito específico. Desta forma, torna-se necessário uma explanação de cada uma delas.

Visualização de Padrões

A opção Visualização de Padrões exibe, como ilustra a Figura 5.10, o padrão, juntamente com seu espectro, quando aquele é selecionado na lista da base de dados.

Histórico de Comando

O Histórico de Comando (HC) é usado para exibir os resultados numéricos. Desta forma, o HC é usado em três situações distintas:

- Ao selecionar a opção Extração de Parâmetros no menu Ferramentas, o software extrai os parâmetros dos padrões da base de dados e exibe-os no HC, como mostra a Figura 5.9.
- Quando a opção Calcular AVCs do menu Análise Canônica é escolhida, o HC mostra a média de cada classe, a média geral do conjunto de dados, a matriz de espalhamento intra-grupo (S_w) e extra-grupo (S_b), assim como a matriz $M = S_w^{-1} \cdot S_b$ e seus autovalores e autovetores. A Figura 5.11 ilustra o HC durante a realização de uma análise de variáveis canônicas.

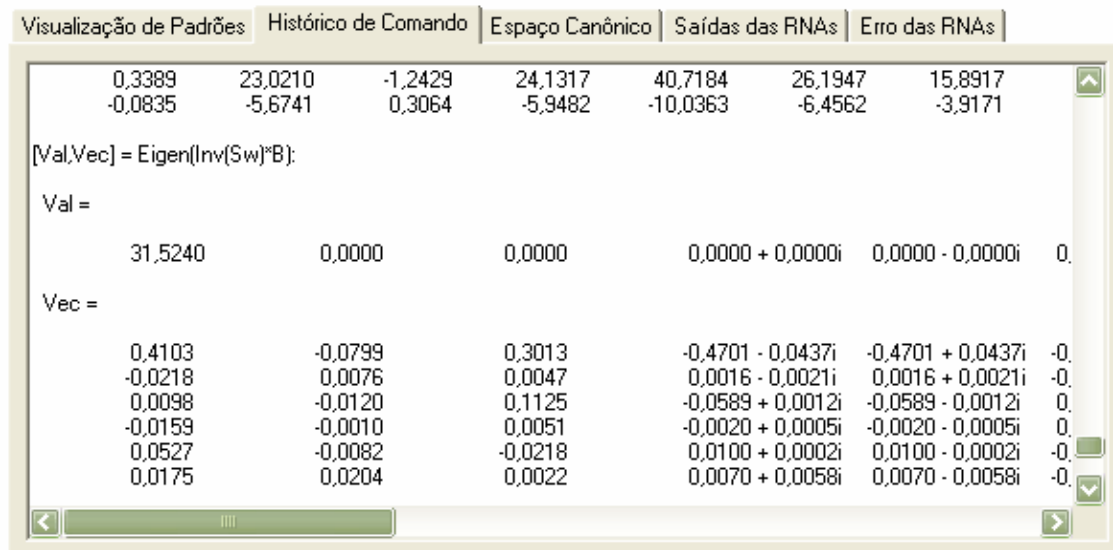


Figura 5.11 - Histórico de Comando durante a análise das variáveis canônicas.

- Ao se efetuar uma análise estatística, tanto de uma RNA como de uma AVC, os resultados são ilustrados no HC, conforme exhibe a Figura 5.12.

Espaço Canônico

Quando o usuário realiza uma AVC (selecionando Calcular AVCs no menu Análise Canônica) ou quando seleciona o item Testar Padrões do menu Análise Canônica, os resultados são expostos no item Espaço Canônico do menu de visualização, conforme exemplifica a Figura 5.13.

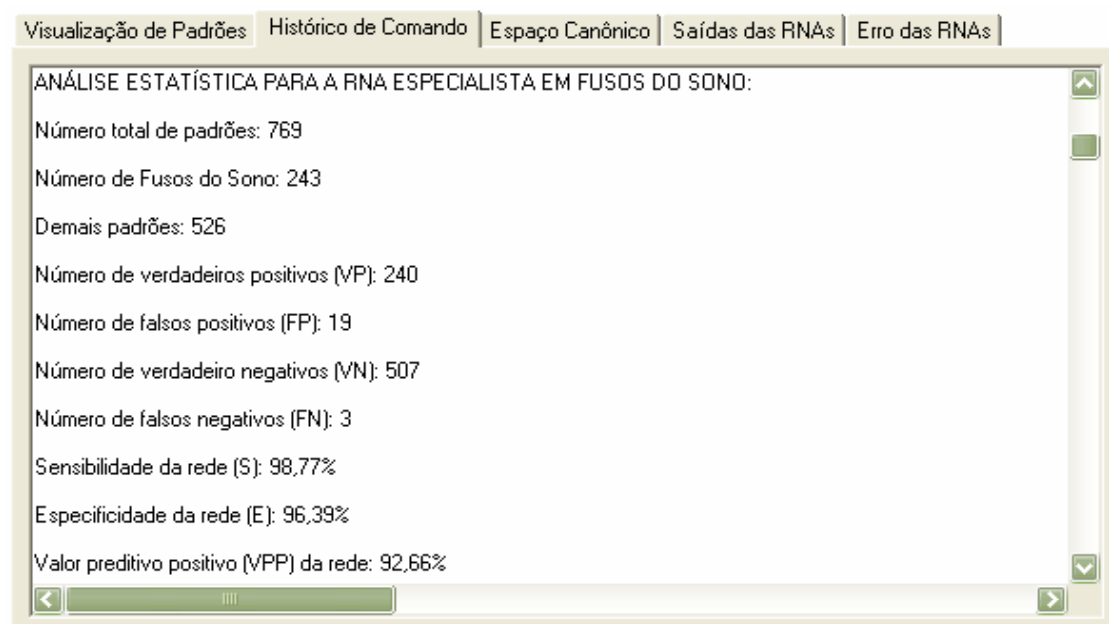


Figura 5.12 - Histórico de Comando exibindo o resultado de uma análise estatística de uma RNA-FS.




Figura 5.13 - Espaço Canônico do menu de visualização, onde são exibidos os resultados das duas AVCs: AVC-CK e ACV-FS.

Saída das RNAs

Após treinar uma RNA, ou após selecionar a opção Testar Padrões no menu Rede Neural, as saídas da RNA-CK e da RNA-FS são exibidas no item Saídas das RNAs do menu de visualização, conforme representa a Figura 5.14.

Para obter os gráficos ilustrados na Figura 5.14, os parâmetros necessários para construção do vetor de características dos padrões na lista de dados são extraídos. Em seguida, propaga-se tal vetor através das RNAs (RNA-CK e RNA-FS). A saída do único neurônio das RNAs é então representada no eixo horizontal dos gráficos.

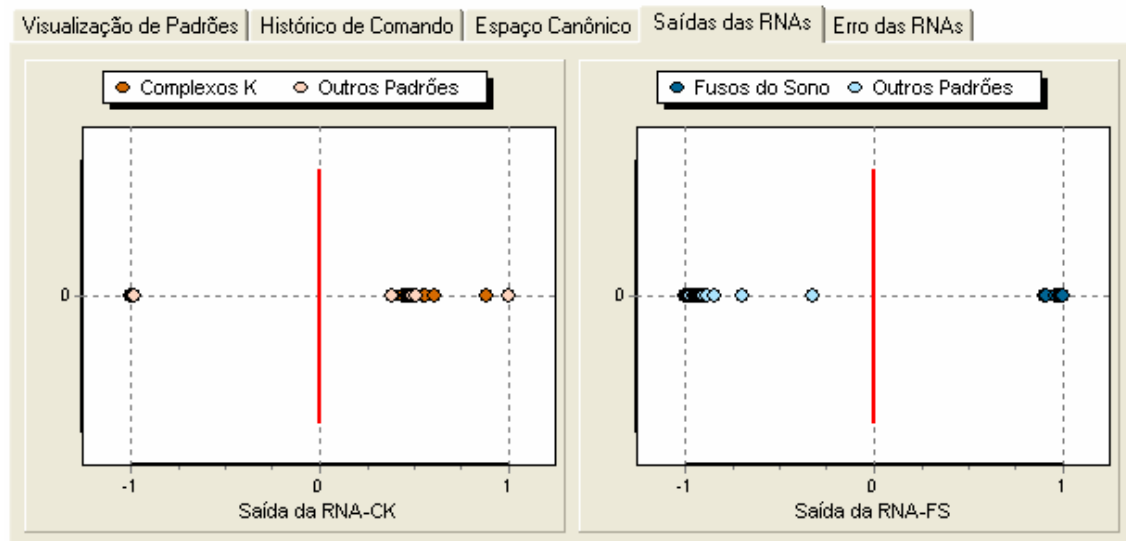


Figura 5.14 - Saída das RNAs do menu de visualização. Do lado direito, a saída da RNA-CK e à esquerda a saída da RNA-FS.

Erro das RNAs

Quando o usuário seleciona um padrão na lista de dados após ter treinado ou aberto uma RNA, automaticamente o sistema propaga o vetor de características deste padrão por meio das duas RNAs especialistas. A saída de cada RNA, para este padrão, é então exibida no item Saídas das RNAs, conforme demonstrado na Figura 5.14, e o erro de cada rede é mostrado no item Erro das RNAs do menu de visualização, como mostra a Figura 5.15.




Figura 5.15 - Erro das RNAs do menu de visualização.

Capítulo 6

Resultados e Discussões

Neste capítulo serão ilustrados e comentados os resultados obtidos através das simulações das ferramentas computacionais descritas nos capítulos anteriores. Estes resultados consistem em testes para validação dos módulos específicos do sistema (módulo de transformação, módulo neural e o módulo de análise das variáveis canônicas), bem como a validação da metodologia como um todo. Este capítulo apresenta-se, então, da seguinte forma: a seção 6.1 ilustra os testes realizados na avaliação de desempenho das RNAs e AVCs para diferentes wavelets¹; a seção 6.2, por sua vez, analisa o desempenho das RNAs e AVCs durante a inspeção de épocas do registro; finalmente, a seção 6.3 apresenta os testes finais para avaliação das metodologias.

6.1. Escolha das Funções *Wavelets*

Conforme descrito no capítulo anterior, referente à metodologia deste trabalho, efetuou-se um procedimento para verificar qual a função *wavelet* mais adequada para a detecção dos complexos K e fusos do sono nos registros de EEG. Tal procedimento consiste em treinar as RNAs e as AVCS do sistema utilizando diversas funções *wavelets*, mantendo, entretanto, a mesma estrutura (topologia e parâmetros) das RNAs e das AVCs.

6.1.1. Redes Neurais Artificiais

As RNAs foram treinadas com um conjunto de 200 padrões, sendo 100 atividades de fundo de EEG, 50 complexos K e 50 fusos do sono. Posteriormente, cada RNA foi testada utilizando-se um conjunto de teste contendo 565 padrões de teste, diferentes daqueles usados na fase de treino.

¹ Nesta etapa de testes as RNAs e AVCs foram treinadas e testadas com padrões extraídos (selecionados) das épocas do registro por um especialista treinado para analisar registros polissonográficos.

As redes neurais foram treinadas, por meio do algoritmo de retropropagação do erro, apresentando randomicamente os vetores de características de cada padrão do conjunto de treinamento às mesmas. Este processo repetiu-se até que o erro na saída da RNA atingisse um valor aceitável. Na etapa de testes, entretanto, os vetores de características dos padrões do conjunto de teste são apresentados sequencialmente à rede e os valores nas saídas das RNAs são computados. O critério de decisão usado é aquele descrito no capítulo anterior.

É importante lembrar que quando apresenta-se um padrão à RNA, este pode ser um padrão alvo, p , ou um padrão complementar, \bar{p} . A saída desejada da RNA para um padrão alvo sempre será +1, enquanto que a saída desejada para um padrão complementar sempre será -1, independente se o padrão alvo é um complexo K ou um fuso do sono.

Em primeiro lugar, realizaram-se os testes para a rede neural especialista em complexos K (RNA-CK). Foram treinadas, então, 66 RNAs, cada qual com uma função *wavelet* específica. A Figura 6.1 ilustra a variação do desempenho das RNA-CK de acordo com a função *wavelet* usada para análise e síntese do sinal, durante a extração dos parâmetros que constituem o vetor de característica. Os resultados estatísticos foram obtidos para uma sensibilidade de 0,5 (50%), ou seja, toda saída da RNA-CK que for maior ou igual a zero é identificado como um CK e tudo que for menor que zero é reconhecido como um \overline{CK} .

A Tabela 6.1, de acordo com os valores de desempenho mostrados na Figura 6.1, detalha os parâmetros estatísticos das funções *wavelet* que proporcionaram os melhores




Figura 6.1 - Desempenho das RNA-CK para as várias funções *wavelets*.

Tabela 6.1 - Resultado da análise estatística para as 10 melhores *wavelets* utilizadas na detecção de complexos K. Em destaque, a função *wavelet* que obteve o melhor desempenho.

WAVELET	VP	FN	VN	FP	SEN (%)	ESP (%)	VPP (%)	VPN (%)
db5	109	15	369	72	87,90	83,67	60,22	96,09
db15	110	14	372	69	88,71	84,35	61,45	96,37
db16	107	17	384	57	86,29	87,07	65,24	95,76
db18	106	18	383	58	85,48	86,85	64,63	95,51
db30	116	8	388	53	93,55	87,98	68,64	97,98
db35	105	19	389	52	84,68	88,21	66,88	95,34
db40	108	16	393	48	87,10	89,12	69,23	96,09
dmey	108	16	395	46	87,10	89,57	70,13	96,11
rbio5.5	103	21	389	52	83,06	88,21	66,45	94,88
sym6	105	19	383	58	84,68	86,85	64,42	95,27

resultados, por meio de RNAs, para a detecção dos complexos K. Observe que a *wavelet* com melhor desempenho foi a db30.

Posteriormente, realizaram-se os testes para as redes neurais especialistas em fusos do sono (RNA-FS). Da mesma forma, 66 RNAs foram treinadas, cada uma utilizando uma *wavelet* distinta na análise e síntese dos sinais. A Figura 6.2 exibe a curva de desempenho das RNAs especialistas em fusos do sono (RNA-FS) para as diferentes funções *wavelets* utilizadas. Assim como na RNA-CK, a sensibilidade utilizada para a RNA-FS foi de 50%, para todas as *wavelets*.

Baseado nos resultados apresentados na Figura 6.2, a Tabela 6.2 detalha os parâmetros estatísticos das funções *wavelets* que proporcionaram às RNA-FS os melhores desempenhos. Note que a *wavelet* com melhor desempenho foi a *coif1*.




Figura 6.2 - Desempenho das RNA-FS para diversas funções *wavelets*.

Tabela 6.2 - Resultado do teste estatístico para as 10 melhores *wavelets* utilizadas na detecção de fusos do sono, por meio de RNA. Em destaque, a função *wavelet* que obteve o melhor desempenho.

WAVELET	VP	FN	VN	FP	SEN (%)	ESP (%)	VPP (%)	VPN (%)
bior2.2	89	5	458	13	94,68	97,24	87,25	98,92
coif1	91	3	455	16	96,81	96,60	85,05	99,34
coif4	88	6	464	7	93,62	98,51	92,63	98,72
coif5	88	6	458	13	93,62	97,24	87,13	98,71
db6	87	7	462	9	92,55	98,09	90,63	98,51
db7	91	3	453	18	96,81	96,18	83,49	99,34
db9	87	7	461	10	92,55	97,88	89,69	98,50
db30	89	5	461	10	94,68	97,88	89,90	98,93
db35	89	5	454	17	94,68	96,39	83,96	98,91
rbio3.5	88	6	463	8	93,62	98,30	91,67	98,72

Pode-se perceber, comparando a Tabela 6.1 com a Tabela 6.2, que, a priori, a detecção dos fusos do sono é mais eficiente que a dos complexos K. Isso ocorre porque, em alguns casos, a atividade de fundo de EEG possui componentes de detalhe nas escalas 4 e 5 tão expressivas quanto as dos complexos K, confundindo, desta maneira, a RNA-CK.

A Figura 6.3 ilustra a saída das RNA-CK e RNA-FS que obtiveram o melhor desempenho, segundo os testes realizados. Observe que a saída das RNAs é visualizada no eixo horizontal. O eixo vertical, contudo, foi aleatorizado com a finalidade de melhorar a visualização, pois como são muitos os padrões testados há uma grande superposição entre eles, o que dificulta a avaliação gráfica.




Figura 6.3 – Saída da RNA-CK para o teste realizado com a *wavelet* db30 (à esquerda) e da RNA-FS para o teste realizado com a *wavelet* coif3 (à direita).

6.1.2. Análise das Variáveis Canônicas

Para ter-se uma melhor comparação entre os resultados das RNAs e AVCs, os conjuntos de padrões utilizados durante o treinamento e o teste das AVCs foram os mesmos utilizados na análise estatística das RNAs. Além disto, a sensibilidade usada durante os testes das AVC-CK e das AVC-FS foram iguais às usadas pelas RNAs, ou seja, a sensibilidade foi igual a 50%.

Primeiramente, treinaram-se as AVCs especialistas em complexos K (AVC-CK), cada qual com uma função *wavelet* distinta. Em seguida, cada uma destas AVCs foi testada utilizando-se a base de testes e os critérios de decisão descritos no capítulo anterior para a análise de variáveis canônicas. A Figura 6.4 apresenta o desempenho das AVC-CK em função da *wavelet* utilizada durante a extração dos parâmetros.

Observe que a *wavelet* que proporcionou o melhor desempenho da AVC-CK foi a rbio3.1 (biortogonal reversa 3.1). A Tabela 6.3, então, baseada no gráfico da Figura 6.4, apresenta as *wavelets* que possibilitaram os melhores desempenhos das análise de variáveis canônicas especialistas em complexos K.

A *wavelet* com maior sensibilidade foi a rbio3.1 e a *wavelet* com maior especificidade foi a db40. Observe que o valor preditivo positivo da AVC-CK utilizando a rbio3.1 é de apenas 58.42%, o que significa que a probabilidade de um padrão ser, de fato, um complexo K quando a AVC o reconhece como tal é de 58.42%.




Figura 6.4 - Desempenho das AVC-CK para as várias funções *wavelets*.

Tabela 6.3 - Resultado do teste estatístico para as 10 melhores *wavelets* utilizadas na detecção de complexos K, por meio de AVC. Em destaque, a função *wavelet* que obteve o melhor desempenho.

WAVELET	VP	FN	VN	FP	SEN (%)	ESP (%)	VPP (%)	VPN (%)
db12	111	13	359	82	89,52	81,41	57,51	96,51
db13	113	11	366	75	91,13	82,99	60,11	97,08
db14	111	13	362	79	89,52	82,09	58,42	96,53
db15	109	15	368	73	87,90	83,45	59,89	96,08
db17	116	8	354	87	93,55	80,27	57,14	97,79
db18	112	12	359	82	90,32	81,41	57,73	96,77
db30	108	16	371	70	87,10	84,13	60,67	95,87
db40	107	17	376	65	86,29	85,26	62,21	95,67
dmey	110	14	363	78	88,71	82,31	58,51	96,29
rbio3.1	118	6	357	84	95,16	80,95	58,42	98,35

Após avaliar o desempenho das AVC-CK, realizou-se o teste estatístico para descobrir qual a função *wavelet* mais adequada para detecção de fusos do sono utilizando análise de variáveis canônicas. O resultado de tal teste é apresentado na Figura 6.5, onde pode-se observar o desempenho das AVC-FS para cada uma das *wavelets* testadas.

A Tabela 6.4 detalha os parâmetros estatísticos para as funções *wavelets* que obtiveram os melhores desempenhos através das AVC-FS. Observe que a função biortogonal 3.1 obteve o melhor desempenho dentre as *wavelets*. Além de obter uma alta sensibilidade e especificidade, a AVC-FS treinada com a *wavelet* biortogonal 3.1 alcançou um alto valor de confiabilidade (> 90%) nos resultados positivos e negativos de detecção.

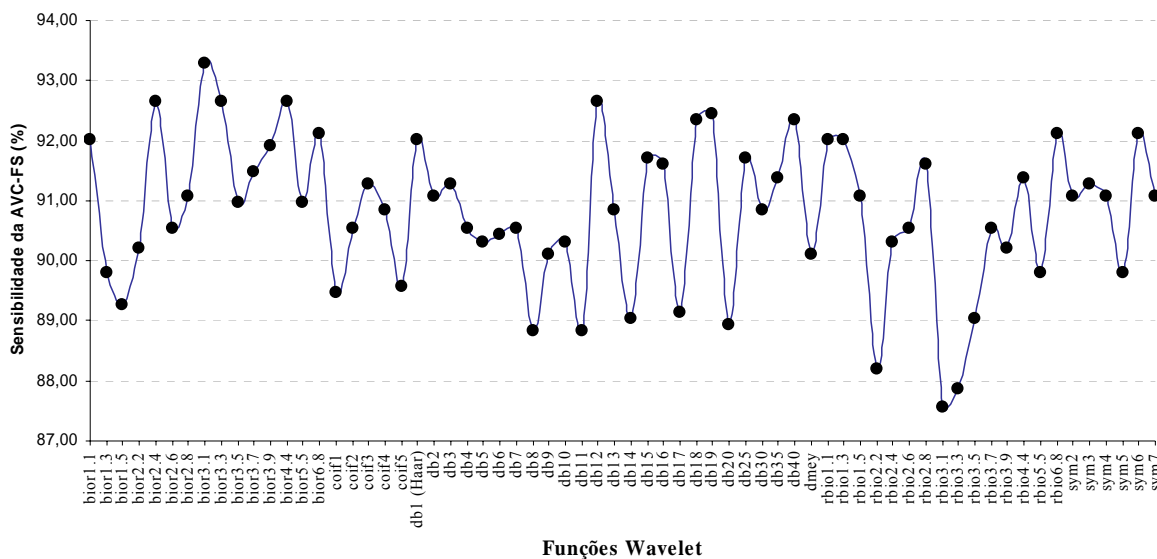


Figura 6.5 - Desempenho das AVC-FS para as várias funções *wavelets*.

Tabela 6.4 – Resultado do teste estatístico para as 11 melhores *wavelets* utilizadas na detecção de fusos do sono, por meio de AVC. Em destaque, a função *wavelet* que obteve o melhor desempenho.

WAVELET	VP	FN	VN	FP	SEN (%)	ESP (%)	VPP (%)	VPN (%)
bior2.4	81	13	467	4	86,17	99,15	95,29	97,29
bior3.1	83	11	463	8	88,30	98,30	91,21	97,68
bior3.3	81	13	467	4	86,17	99,15	95,29	97,29
bior4.4	81	13	467	4	86,17	99,15	95,29	97,29
bior6.8	80	14	467	4	85,11	99,15	95,24	97,09
db12	81	13	467	4	86,17	99,15	95,29	97,29
db18	81	13	464	7	86,17	98,51	92,05	97,27
db19	81	13	465	6	86,17	98,73	93,10	97,28
db40	81	13	464	7	86,17	98,51	92,05	97,27
rbio6.8	80	14	467	4	85,11	99,15	95,24	97,09
sym6	80	14	467	4	85,11	99,15	95,24	97,09

De acordo com os resultados dos testes realizados para as AVCs, a Figura 6.6 ilustra a saída das AVCs que obtiveram os melhores desempenhos. Observe que a variável canônica 1 (eixo horizontal) é responsável pela discriminação dos padrões, enquanto que a variável canônica 2 não possui nenhum poder de discriminação e serve apenas para propiciar uma melhor visualização da saída das AVCs.




Figura 6.6 - Saída da AVC-CK para o teste realizado com a *wavelet* rbio3.1 (à esquerda) e da AVC-FS para o teste realizado com a *wavelet* bior3.1 (à direita).

Vale ressaltar que os valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo obtidos durante os estudos estatísticos, tanto das RNAs como das AVCS, não retratam seguramente a realidade do problema, pois nessa etapa de testes foram selecionados apenas alguns padrões de cada classe. Na análise de um registro

de polissonografia, entretanto, a diversidade dos padrões de cada classe é bem maior, o que acarreta em uma diminuição desses parâmetros estatísticos, como veremos a seguir.

6.2. Teste nos Registros Polissonográficos

Para obter uma melhor representação do problema de detecção de padrões no EEG durante o sono, as RNAs e AVCs que obtiveram os melhores desempenhos foram submetidas a testes realizados em épocas dos registros, cujas características de amplitude e frequência assemelhavam-se àquelas relativas ao estágio II do sono NREM.

Foram selecionadas, ao todo, 20 épocas: 10 para testes relativos à detecção de CK e 10 para testes relativos à detecção de FS. Como cada época possui uma duração de 30 segundos e o sistema verifica os padrões em intervalos de 0.5 segundos² apenas nos dois canais centrais (C3 e C4), então, no total, são analisados 118 padrões em cada época. Visto que são 10 as épocas analisadas para cada classe, o total de padrões testados nessa etapa é de 1180 para cada RNA ou AVC especialista.

Durante a seleção das épocas que foram submetidas ao teste, tomou-se o cuidado de escolher aquelas que contivessem pelo menos um exemplar da classe alvo. Ou seja, as épocas escolhidas para os testes das RNA-CK e AVC-CK, por exemplo, deviam conter ao menos um complexo K. Outra condição para utilização de uma época no teste diz respeito à utilização da mesma durante o treinamento da rede. Assim, épocas que continham padrões utilizados no treinamento das RNAs e AVCs não fizeram parte do conjunto de épocas disponíveis para essa etapa de testes.

6.2.1. Redes Neurais Artificiais

Os primeiros testes foram realizados com as RNAs especialistas na detecção de complexos K. Sendo assim, baseado nos resultados da Figura 6.1 e da Tabela 6.1, efetuou-se a análise das épocas mostradas na Tabela 6.5 utilizando-se as três *wavelets* que propiciaram os melhores desempenhos.

² Primeiro, verifica-se o intervalo $0 \leq t \leq 1$, em seguida o intervalo $0,5 \leq t \leq 1,5$, depois o intervalo $1 \leq t \leq 2$ e assim por diante, até que o ultimo intervalo ($29 \leq t \leq 30$) seja analisado.

Para realização dessa etapa de testes, as RNAs foram treinadas novamente com um conjunto de padrões mais robusto (maior), composto por 1330 padrões, sendo 793 atividades de fundo de EEG, 298 complexos K e 239 fusos do sono. A Tabela 6.5 ilustra o resultado dos testes realizados para analisar a detecção de complexos K através de RNA. A coluna CK exibe a quantidade de complexos K na época, assim como \overline{CK} indica a quantidade de padrões que não são complexos K. VP, FN, VN e FP denotam o número de verdadeiros positivos, falso negativos, verdadeiros negativos e falsos positivos, respectivamente. Por último, Sen, Esp, VPP, VPN e TA são os parâmetros estatísticos utilizados para avaliação e comparação dos resultados e simbolizam a sensibilidade, especificidade, valor preditivo positivo, valor preditivo negativo e taxa de acerto³ do teste, respectivamente. Todos estes parâmetros estatísticos são mostrados em percentagem.

Além da *wavelet* db30, os testes realizados nos registros foram executados para as *wavelets* dmey e db40, todos com uma sensibilidade de 20%. Igualmente, foram analisadas as 10 épocas mostradas na Tabela 6.5, com o intuito de fazer o reconhecimento dos complexos K contidos nas mesmas. Os resultados obtidos para as *wavelets* dmey e db40 estão expostos na Tabela 6.6 e na Tabela 6.7, respectivamente. Observe o decréscimo nos valores de sensibilidade de ambas *wavelets*, se comparados com os da Tabela 6.1. A especificidade e a taxa de acertos, no entanto, conservaram-se altas.

Tabela 6.5 - Resultado do teste nos registros de EEG através da RNA-CK para detecção de complexos K, utilizando a *wavelet* db30.

ÉPOCA	CK	\overline{CK}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/356	6	112	4	2	110	2	66,67	98,21	66,67	98,21	96,61
00228-1/722	2	116	2	0	113	3	100,00	97,41	40,00	100,00	97,46
00275-1/324	2	116	2	0	113	3	100,00	97,41	40,00	100,00	97,46
00588-1/009	6	112	5	1	110	2	83,33	98,21	71,43	99,10	97,46
00588-1/266	4	114	3	1	112	2	75,00	98,25	60,00	99,12	97,46
00601-1/219	6	112	6	0	108	4	100,00	96,43	60,00	100,00	96,61
00603-1/701	2	116	1	1	116	0	50,00	100,00	100,00	99,15	99,15
00614-1/138	8	110	8	0	102	8	100,00	92,73	50,00	100,00	93,22
00615-1/010	3	115	3	0	111	4	100,00	96,52	42,86	100,00	96,61
00617-1/237	2	116	2	0	116	0	100,00	100,00	100,00	100,00	100,00
TOTAL	41	1139	36	5	1111	28	87,80	97,54	56,25	99,55	97,20

³ A taxa de acerto é definida como a razão entre os acertos do sistema (VP + VN) e o número total de padrões testados

Tabela 6.6 - Resultado do teste nos registros de EEG através da RNA-CK para detecção de complexos K, utilizando a *wavelet* dmey.

ÉPOCA	CK	\overline{CK}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/356	6	112	4	2	109	3	66,67	97,32	57,14	98,20	95,76
00228-1/722	2	116	1	1	115	1	50,00	99,14	50,00	99,14	98,31
00275-1/324	2	116	1	1	116	0	50,00	100,00	100,00	99,15	99,15
00588-1/009	6	112	3	3	112	0	50,00	100,00	100,00	97,39	97,46
00588-1/266	4	114	2	2	113	1	50,00	99,12	66,67	98,26	97,46
00601-1/219	6	112	2	4	111	1	33,33	99,11	66,67	96,52	95,76
00603-1/701	2	116	1	1	115	1	50,00	99,14	50,00	99,14	98,31
00614-1/138	8	110	5	3	106	4	62,50	96,36	55,56	97,25	94,07
00615-1/010	3	115	3	0	112	3	100,00	97,39	50,00	100,00	97,46
00617-1/237	2	116	2	0	115	1	100,00	99,14	66,67	100,00	99,15
TOTAL	41	1139	24	17	1124	15	58,54	98,68	61,54	98,51	97,29

Observe que na época 701 do registro 00603-1 houve uma diminuição significativa na especificidade e na taxa de acerto da RNA-CK que utilizou a *wavelet* db40. Isso ocorreu porque esta época do registro, assim como algumas outras, continha uma componente do sinal na faixa de 42,4 Hz. A *wavelet* db40, então, mostrou-se sensível a esse artefato, gerando uma quantidade significativa de falsos positivos.

Tabela 6.7 - Resultado do teste nos registros de EEG através da RNA-CK para detecção de complexos K, utilizando a *wavelet* db40.

ÉPOCA	CK	\overline{CK}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/356	6	112	4	2	108	4	66,67	96,43	50,00	98,18	94,92
00228-1/722	2	116	1	1	115	1	50,00	99,14	50,00	99,14	98,31
00275-1/324	2	116	2	0	115	1	100,00	99,14	66,67	100,00	99,15
00588-1/009	6	112	5	1	110	2	83,33	98,21	71,43	99,10	97,46
00588-1/266	4	114	4	0	111	3	100,00	97,37	57,14	100,00	97,46
00601-1/219	6	112	5	1	107	5	83,33	95,54	50,00	99,07	94,92
00603-1/701	2	116	2	0	62	54	100,00	53,45	3,57	100,00	54,24
00614-1/138	8	110	6	2	102	8	75,00	92,73	42,86	98,08	91,53
00615-1/010	3	115	1	2	111	4	33,33	96,52	20,00	98,23	94,92
00617-1/237	2	116	2	0	116	0	100,00	100,00	100,00	100,00	100,00
TOTAL	41	1139	32	9	1057	82	78,05	92,80	28,07	99,16	92,29

A Figura 6.7, apresentada a seguir, ilustra a época 701 do registro 00603-1, com seus dois complexos K destacados. Perceba que a componente de 42,4 Hz está presente em toda a época.




Figura 6.7 – Página 701 do registro 00603-1. Em destaque, os dois complexos K presentes na época.

A Figura 6.8, por sua vez, apresenta a página 219 do registro 00601-1, destacando os padrões identificados como complexos K por meio da RNA-CK, que utilizou a *wavelet* db30. Os padrões destacados com um retângulo preenchido são os verdadeiros positivos; os demais são os falsos positivos. No instante $t=9$ ocorrem, nas duas derivações, padrões muito semelhantes ao complexo K. No entanto, estes padrões não possuem a duração necessária para serem reconhecidos como tal.

Note que na derivação C3, foi identificado um complexo K no intervalo $3 \leq t \leq 4,5$. Ou seja, um complexo K com duração de 1,5 segundos. Isso acontece porque o sistema de controle identificou um complexo K no intervalo $3 \leq t \leq 4$ e outro no período $3,5 \leq t \leq 4,5$. Quando isso ocorre, identificam-se os dois intervalos como sendo um único complexo K.




Figura 6.8 - Página 219 do registro 00601-1. Os padrões destacados são aqueles que a RNA-CK identificou como um complexo K, utilizando a *wavelet* db30.

Pode acontecer, no entanto, do sistema de controle reconhecer três, ou mais, complexos K seguidos. Neste caso, esses complexos K também são marcados com um único retângulo. Porém, para cada segundo de duração de um retângulo, conta-se um complexo K⁴. Por exemplo, se cinco padrões são identificados seguidamente como sendo complexos K, o sistema marca-os com um único retângulo de duração igual a três segundos. Desta forma, contam-se três complexos K dentro desse intervalo.

Após os experimentos referentes à detecção de complexos K por meio de RNAs, efetuaram-se testes para verificação de fusos do sono em épocas do registro polissonográfico. Para realizar tais testes as RNA-FS foram, também, re-treinadas utilizando-se o mesmo conjunto de padrões utilizado no treino das RNA-CK para o teste nos registros de EEG. Ao todo, foram re-treinadas e testadas as três RNA-FS com o melhor desempenho, de acordo com os resultados apresentados na Figura 6.2 e na Tabela 6.2. A Tabela 6.8, por conseguinte, ilustra as épocas utilizadas para tal inspeção, assim como a quantidade de fusos do sono contida em cada época e os parâmetros estatísticos necessários para avaliação e comparação dos resultados. A *wavelet* utilizada no treinamento e no teste da RNA-FS responsável pela edificação da Tabela 6.8 foi a *coif1*.

Além da RNA-FS treinada com a *wavelet* *coif1* (RNA-FS_ *coif1*), as RNA-FS_ *db7* e a RNA-FS_ *db30*, ambas com sensibilidade de 20%, também foram re-treinadas e testadas,

Tabela 6.8 – Resultado do teste nos registros de EEG através da RNA-FS, utilizando a *wavelet* *coif1*.

ÉPOCA	FS	\overline{FS}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/048	7	111	6	1	108	3	85,71	97,30	66,67	99,08	96,61
00275-1/059	4	114	4	0	111	3	100,00	97,37	57,14	100,00	97,46
00275-1/519	5	113	4	1	112	1	80,00	99,12	80,00	99,12	98,31
00275-1/532	12	106	9	3	104	2	75,00	98,11	81,82	97,20	95,76
00588-1/031	2	116	2	0	112	4	100,00	96,55	33,33	100,00	96,61
00614-1/019	4	114	3	1	111	3	75,00	97,37	50,00	99,11	96,61
00614-1/024	11	107	9	2	105	2	81,82	98,13	81,82	98,13	96,61
00614-1/195	12	106	10	2	98	8	83,33	92,45	55,56	98,00	91,53
00617-1/178	2	116	2	0	114	2	100,00	98,28	50,00	100,00	98,31
00617-1/185	6	112	4	2	111	1	66,67	99,11	80,00	98,23	97,46
TOTAL	65	1115	53	12	1086	29	81,54	97,40	64,63	98,91	96,53

⁴ Se a duração do retângulo, em segundos, não for um número inteiro, contam-se apenas os segundos inteiros. Desta forma, por exemplo, um retângulo de duração igual a 2.5 segundos acomoda apenas dois complexos K: um com duração de 1.0 segundo e outro com duração de 1.5 segundos.

Tabela 6.9 – Resultado do teste nos registros de EEG através da RNA-FS, utilizando a *wavelet* db7.

ÉPOCA	FS	\overline{FS}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/048	7	111	7	0	109	2	100,00	98,20	77,78	100,00	98,31
00275-1/059	4	114	4	0	110	4	100,00	96,49	50,00	100,00	96,61
00275-1/519	5	113	5	0	113	0	100,00	100,00	100,00	100,00	100,00
00275-1/532	12	106	10	2	105	1	83,33	99,06	90,91	98,13	97,46
00588-1/031	2	116	2	0	112	4	100,00	96,55	33,33	100,00	96,61
00614-1/019	4	114	4	0	110	4	100,00	96,49	50,00	100,00	96,61
00614-1/024	11	107	9	2	101	6	81,82	94,39	60,00	98,06	93,22
00614-1/195	12	106	12	0	91	15	100,00	85,85	44,44	100,00	87,29
00617-1/178	2	116	2	0	113	3	100,00	97,41	40,00	100,00	97,46
00617-1/185	6	112	3	3	110	2	50,00	98,21	60,00	97,35	95,76
TOTAL	65	1115	58	7	1074	41	89,23	96,32	58,59	99,35	95,93

utilizando o método de apresentação de épocas à RNA. As épocas apresentadas a tais RNAs são as mesmas mostradas na Tabela 6.8. Adicionalmente, a Tabela 6.9 e a Tabela 6.10 ilustram o resultado do teste para as RNA-FS_db7 e RNA-FS_db30, respectivamente.

Observe que a sensibilidade da RNA-FS_db7 mostrou-se ligeiramente superior à sensibilidade das RNA-FS_coif1 e RNA-FS_db30. No entanto, a RNA-FS_coif1 obteve os maiores valores de especificidade, taxa de acerto e valor preditivo positivo, justificando sua escolha para a fase final de testes.

Tabela 6.10 – Resultado do teste nos registros de EEG através da RNA-FS, utilizando a *wavelet* db30.

ÉPOCA	FS	\overline{FS}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/048	7	111	5	2	107	4	71,43	96,40	55,56	98,17	94,92
00275-1/059	4	114	4	0	113	1	100,00	99,12	80,00	100,00	99,15
00275-1/519	5	113	4	1	113	0	80,00	100,00	100,00	99,12	99,15
00275-1/532	12	106	8	4	103	3	66,67	97,17	72,73	96,26	94,07
00588-1/031	2	116	2	0	112	4	100,00	96,55	33,33	100,00	96,61
00614-1/019	4	114	4	0	111	3	100,00	97,37	57,14	100,00	97,46
00614-1/024	11	107	8	3	104	3	72,73	97,20	72,73	97,20	94,92
00614-1/195	12	106	12	0	95	11	100,00	89,62	52,17	100,00	90,68
00617-1/178	2	116	2	0	114	2	100,00	98,28	50,00	100,00	98,31
00617-1/185	6	112	4	2	108	4	66,67	96,43	50,00	98,18	94,92
TOTAL	65	1115	53	12	1080	35	81,54	96,86	60,23	98,90	96,02

A seguir, a Figura 6.9 ilustra um exemplo de uma época utilizada durante os testes da RNA-FS. Os padrões reconhecidos pela RNA estão destacados com um retângulo.




Figura 6.9 - Exemplo de uma época (página 24 do registro 0614-1.plg) utilizada no teste da RNA-FS. Os padrões destacados são aqueles que a RNA-FS identificou como um fuso do sono, utilizando a *wavelet* *coif1*. Os retângulos preenchidos representam os verdadeiros positivos. Os demais indicam os falsos positivos.

Repare que os dois falsos positivos estão localizados no intervalo $7 \leq t \leq 8,5$ da derivação C3 e no intervalo $11 \leq t \leq 12$ da derivação C4. Os dois falsos negativos ocorrem nos períodos $2 \leq t \leq 3$ e $12,5 \leq t \leq 13,5$ da derivação C3.

6.2.2. Análise de Variáveis Canônicas

Todos os testes realizados para as redes neurais artificiais foram reproduzidos aplicando-se a análise de variáveis canônicas. O mesmo conjunto de padrões aplicado no treinamento das RNAs foi empregado para treinar as AVCs. Além disso, para tornar a comparação dos resultados mais coesa, as épocas utilizadas nos testes das AVCs são as mesmas usadas nos testes das RNAs.

Os primeiros testes referentes à análise de variáveis canônicas foram realizados para as AVCs especialistas em complexos K. Para tal, utilizou-se uma sensibilidade de 20%, assim como no caso das RNAs. Ademais, baseado nos resultados apresentados na Figura 6.4 e na Tabela 6.3 foram testadas as três AVCs que obtiveram os melhores desempenhos. Ou seja, as AVCs utilizadas nesta etapa de teste foram as que utilizaram as *wavelets* *rbio3.1*, *db13* e *db17*.

A seguir, a Tabela 6.11 descreve os resultados obtidos na identificação de complexos K em dez épocas de diferentes registros, por meio da AVC-CK que utilizou a *wavelet* *rbio3.1*.

Tabela 6.11 - Resultado do teste nos registros de EEG através da AVC-CK para detecção de complexos K, utilizando a *wavelet* rbio3.1.

ÉPOCA	CK	$\overline{\text{CK}}$	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/356	6	112	4	2	110	2	66,67	98,21	66,67	98,21	96,61
00228-1/722	2	116	1	1	111	5	50,00	95,69	16,67	99,11	94,92
00275-1/324	2	116	2	0	111	5	100,00	95,69	28,57	100,00	95,76
00588-1/009	6	112	4	2	110	2	66,67	98,21	66,67	98,21	96,61
00588-1/266	4	114	2	2	111	3	50,00	97,37	40,00	98,23	95,76
00601-1/219	6	112	4	2	109	3	66,67	97,32	57,14	98,20	95,76
00603-1/701	2	116	0	2	116	0	0,00	100,00	100,00	98,31	98,31
00614-1/138	8	110	6	2	108	2	75,00	98,18	75,00	98,18	96,61
00615-1/010	3	115	3	0	111	4	100,00	96,52	42,86	100,00	96,61
00617-1/237	2	116	2	0	116	0	100,00	100,00	100,00	100,00	100,00
TOTAL	41	1139	28	13	1113	26	68,29	97,72	51,85	98,85	96,69

Perceba que, assim como no caso das RNAs, a sensibilidade das AVC-CK diminuiu com relação àquelas obtidas nos testes das funções *wavelets*. Note também que a grande quantidade de falsos positivos leva a uma redução do valor preditivo positivo das AVCs. No caso da AVC-CK_rbio3.1 a confiabilidade é de aproximadamente 50%. Ou seja, se a AVC detecta um CK, a probabilidade de que este padrão realmente seja um CK é de 50%.

A seguir, a Tabela 6.12 e a Tabela 6.13 exibem os resultados dos testes das AVC-CK_db13 e AVC-CK_db17, respectivamente. Veja que tanto a AVC-CK_db13 como a AVC-CK_db17 revelaram-se sensíveis ao artefato existente na época 701 do registro 00603-1, o que acarretou em uma redução ainda maior do VPP de ambas AVCs.

Tabela 6.12 - Resultado do teste nos registros de EEG através da AVC-CK para detecção de complexos K, utilizando a *wavelet* db13.


ÉPOCA	CK	$\overline{\text{CK}}$	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/356	6	112	4	2	109	3	66,67	97,32	57,14	98,20	95,76
00228-1/722	2	116	2	0	109	7	100,00	93,97	22,22	100,00	94,07
00275-1/324	2	116	2	0	111	5	100,00	95,69	28,57	100,00	95,76
00588-1/009	6	112	4	2	111	1	66,67	99,11	80,00	98,23	97,46
00588-1/266	4	114	3	1	112	2	75,00	98,25	60,00	99,12	97,46
00601-1/219	6	112	3	3	107	5	50,00	95,54	37,50	97,27	93,22
00603-1/701	2	116	2	0	98	18	100,00	84,48	10,00	100,00	84,75
00614-1/138	8	110	7	1	107	3	87,50	97,27	70,00	99,07	96,61
00615-1/010	3	115	2	1	107	8	66,67	93,04	20,00	99,07	92,37
00617-1/237	2	116	2	0	114	2	100,00	98,28	50,00	100,00	98,31
TOTAL	41	1139	31	10	1085	54	75,61	95,26	36,47	99,09	94,58

Tabela 6.13 - Resultado do teste nos registros de EEG através da AVC-CK para detecção de complexos K, utilizando a *wavelet* db17.

ÉPOCA	CK	\overline{CK}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/356	6	112	4	2	109	3	66,67	97,32	57,14	98,20	95,76
00228-1/722	2	116	1	1	112	4	50,00	96,55	20,00	99,12	95,76
00275-1/324	2	116	2	0	111	5	100,00	95,69	28,57	100,00	95,76
00588-1/009	6	112	3	3	112	0	50,00	100,00	100,00	97,39	97,46
00588-1/266	4	114	4	0	112	2	100,00	98,25	66,67	100,00	98,31
00601-1/219	6	112	1	5	107	5	16,67	95,54	16,67	95,54	91,53
00603-1/701	2	116	2	0	95	21	100,00	81,90	8,70	100,00	82,20
00614-1/138	8	110	7	1	107	3	87,50	97,27	70,00	99,07	96,61
00615-1/010	3	115	1	2	110	5	33,33	95,65	16,67	98,21	94,07
00617-1/237	2	116	0	2	115	1	0,00	99,14	0,00	98,29	97,46
TOTAL	41	1139	25	16	1090	49	60,98	95,70	33,78	98,55	94,49

As três AVCs testadas aqui obtiveram uma sensibilidade relativamente baixa, assim como um valor preditivo positivo bem reduzido. A especificidade, o VPN e a taxa de acerto, entretanto, mantiveram-se elevados, devido principalmente à grande quantidade de verdadeiros negativos obtidos nos testes.

A Figura 6.10, mostrada a seguir, apresenta a página 138 do registro 00614-1, destacando os padrões identificados como complexos K através da AVC-CK_rbio3.1. Observe que dos oito padrões identificados pela AVC, seis são realmente complexos K e dois são falsos positivos.

**Figura 6.10** - Página 138 do registro 00614-1, com os complexos K reconhecidos pela AVC-CK_rbio3.1. Os retângulos preenchidos representam os verdadeiros positivos. Os demais indicam os falsos positivos.

Os testes realizados nas épocas dos registros referentes à identificação dos fusos do sono através da AVC foram realizados para as três AVCs que obtiveram os melhores desempenhos de acordo com a Figura 6.5 e a Tabela 6.4. Os resultados destes testes são mostrados na Tabela 6.15, Tabela 6.14 e Tabela 6.16.

Repare que, assim como verificado nas RNAs, nas AVCs a identificação de fusos do sono mostrou-se mais eficiente que a identificação dos complexos K, uma vez que a sensibilidade, especificidade, VPP, VPN e taxa de acerto das AVC-FS foram, em média, superiores se comparados com as das AVC-CK.

Tabela 6.14 – Resultado do teste nos registros de EEG através da AVC-FS para detecção de fusos do sono, utilizando a *wavelet* bior3.1.

ÉPOCA	FS	\overline{FS}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/048	7	111	7	0	108	3	100,00	97,30	70,00	100,00	97,46
00275-1/059	4	114	3	1	112	2	75,00	98,25	60,00	99,12	97,46
00275-1/519	5	113	4	1	113	0	80,00	100,00	100,00	99,12	99,15
00275-1/532	12	106	8	4	106	0	66,67	100,00	100,00	96,36	96,61
00588-1/031	2	116	2	0	115	1	100,00	99,14	66,67	100,00	99,15
00614-1/019	4	114	4	0	112	2	100,00	98,25	66,67	100,00	98,31
00614-1/024	11	107	7	4	106	1	63,64	99,07	87,50	96,36	95,76
00614-1/195	12	106	10	2	102	4	83,33	96,23	71,43	98,08	94,92
00617-1/178	2	116	2	0	113	3	100,00	97,41	40,00	100,00	97,46
00617-1/185	6	112	4	2	110	2	66,67	98,21	66,67	98,21	96,61
TOTAL	65	1115	51	14	1097	18	78,46	98,39	73,91	98,74	97,29

Tabela 6.15 – Resultado do teste nos registros de EEG através da AVC-FS para detecção de fusos do sono, utilizando a *wavelet* bior2.4.

ÉPOCA	FS	\overline{FS}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/048	7	111	5	2	110	1	71,43	99,10	83,33	98,21	97,46
00275-1/059	4	114	2	2	114	0	50,00	100,00	100,00	98,28	98,31
00275-1/519	5	113	4	1	113	0	80,00	100,00	100,00	99,12	99,15
00275-1/532	12	106	8	4	106	0	66,67	100,00	100,00	96,36	96,61
00588-1/031	2	116	2	0	116	0	100,00	100,00	100,00	100,00	100,00
00614-1/019	4	114	4	0	113	1	100,00	99,12	80,00	100,00	99,15
00614-1/024	11	107	7	4	106	1	63,64	99,07	87,50	96,36	95,76
00614-1/195	12	106	11	1	100	6	91,67	94,34	64,71	99,01	94,07
00617-1/178	2	116	2	0	110	6	100,00	94,83	25,00	100,00	94,92
00617-1/185	6	112	5	1	110	2	83,33	98,21	71,43	99,10	97,46
TOTAL	65	1115	50	15	1098	17	76,92	98,48	74,63	98,65	97,29

Tabela 6.16 – Resultado do teste nos registros de EEG através da AVC-FS para detecção de fusos do sono, utilizando a *wavelet* bior4.4.

ÉPOCA	FS	\overline{FS}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1/048	7	111	5	2	110	1	71,43	99,10	83,33	98,21	97,46
00275-1/059	4	114	3	1	111	3	75,00	97,37	50,00	99,11	96,61
00275-1/519	5	113	4	1	113	0	80,00	100,00	100,00	99,12	99,15
00275-1/532	10	108	8	2	108	0	80,00	100,00	100,00	98,18	98,31
00588-1/031	2	116	2	0	115	1	100,00	99,14	66,67	100,00	99,15
00614-1/019	4	114	4	0	113	1	100,00	99,12	80,00	100,00	99,15
00614-1/024	11	107	7	4	106	1	63,64	99,07	87,50	96,36	95,76
00614-1/195	12	106	11	1	98	8	91,67	92,45	57,89	98,99	92,37
00617-1/178	2	116	2	0	110	6	100,00	94,83	25,00	100,00	94,92
00617-1/185	6	112	5	1	110	2	83,33	98,21	71,43	99,10	97,46
TOTAL	63	1117	51	12	1094	23	80,95	97,94	68,92	98,92	97,03

Repare que a *wavelet* bior4.4 propiciou a melhor sensibilidade dentre as três ACV-FS testadas. No entanto, sua confiabilidade (VPP) foi a mais baixa. Em geral, com o aumento da sensibilidade temos um decréscimo do valor preditivo positivo da AVC (ou RNA) testada. A mesma relação ocorre com a especificidade e o VPN. Assim, deseja-se encontrar um equilíbrio entre valores que seja o maior possível.

A Figura 6.11, abaixo, mostra a página 19 do registro 00614-1, utilizada durante o teste da AVC-CK_bior3.1. Perceba que foram detectados, ao todo, seis fusos do sono, sendo quatro verdadeiros positivos e dois falsos positivos.




Figura 6.11 - Exemplo de uma época (página 19 do registro 0614-1.plg) utilizada no teste da AVC-FS. Os padrões destacados são aqueles que a AVC-FS identificou como fusos do sono, utilizando a *wavelet* bior3.1. Os retângulos preenchidos representam os verdadeiros positivos. Os demais indicam os falsos positivos.

6.3. Testes Finais

Esta etapa é semelhante à anterior. No entanto, baseado nos resultados obtidos na seção 5.2, apenas as melhores RNAs e AVCs especialistas foram selecionadas para esta fase. Também, ao contrário do teste anterior, nesta fase as duas RNAs (ou as duas AVCs) interagem entre si através do sistema de controle, para definir qual o padrão (AF, CK ou FS) na saída do sistema.

A Tabela 6.17 e a Tabela 6.18 ilustram uma sinopse dos resultados obtidos nos testes realizados na seção anterior, onde foram testadas três RNAs e três AVCs para detecção de cada padrão alvo. Ao todo, então, foram testadas seis RNAs e seis AVCs. As RNAs e AVCs em destaque nas duas tabelas foram aquelas que alcançaram os melhores resultados e, assim, foram selecionadas para efetuar a fase final de testes, onde o sistema é testado como um todo.

Observe que nem sempre a RNA (ou AVC) com melhor sensibilidade ou especificidade foi aquela escolhida para a etapa posterior de testes. A AVC-FS_bior4.4, por exemplo, obteve a maior sensibilidade dentre as três AVC-FS testadas. Seu VPP, no entanto, foi

Tabela 6.17 – Resumo dos testes em registros polissonográficos realizados nas RNAs para detecção de complexos K e fusos do sono. As RNAs destacadas serão submetidas à etapa final de testes.

RNA	VP	FN	VN	FP	SEN (%)	ESP (%)	VPP (%)	VPN (%)	TA (%)
CK_db30	36	5	1111	28	87,80	97,54	56,25	99,55	97,20
CK_dmey	24	17	1124	15	58,54	98,68	61,54	98,51	97,29
CK_db40	32	9	1057	82	78,05	92,80	28,07	99,16	92,29
FS_coif1	53	12	1086	29	81,54	97,40	64,63	98,91	96,53
FS_db7	58	7	1074	41	89,23	96,32	58,59	99,35	95,93
FS_db30	53	12	1080	35	81,54	96,86	60,23	98,90	96,02

Tabela 6.18 - Resumo dos testes em registros polissonográficos realizados nas AVCs para detecção de complexos K e fusos do sono. As AVCs destacadas serão submetidas à etapa final de testes.

AVC	VP	FN	VN	FP	SEN (%)	ESP (%)	VPP (%)	VPN (%)	TA (%)
CK_rbio3.1	28	13	1113	26	68,29	97,72	51,85	98,85	96,69
CK_db13	31	10	1085	54	75,61	95,26	36,47	99,09	94,58
CK_db17	25	16	1090	49	60,98	95,70	33,78	98,55	94,49
FS_bior2.4	50	15	1098	17	76,92	98,48	74,63	98,65	97,29
FS_bior3.1	51	14	1097	18	78,46	98,39	73,91	98,74	97,29
FS_bior4.4	51	12	1094	23	80,95	97,94	68,92	98,92	97,03

Tabela 6.19 – Resultado do teste final da RNA-CK_db30, com $s = 0,3$, na detecção de complexos K.

REGISTRO	ÉPOCAS	CK	\overline{CK}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1	40	101	4619	82	19	4558	61	81,19	98,68	57,34	99,58	98,31
00275-1	81	130	9428	98	31	9256	172	75,97	98,18	36,30	99,67	97,88
00588-1	81	197	9361	155	42	9260	101	78,68	98,92	60,55	99,55	98,50
00601-1	81	252	9306	200	52	9175	131	79,37	98,59	60,42	99,44	98,09
00603-1	81	161	9397	114	47	9349	48	70,81	99,49	70,37	99,50	99,01
00614-1	81	349	9209	256	91	9029	180	73,78	98,05	58,72	99,00	97,16
TOTAL	445	1190	51320	905	282	50627	693	76,24	98,65	56,63	99,45	98,14

inferior ao VPP da AVC-FS_bior3.1. Na verdade, a escolha da melhor RNA e da melhor AVC é baseada na média dos parâmetros estatísticos. Portanto, no caso das RNAs, a *wavelet* escolhida para detecção de complexos K foi a db30 e para a detecção de fusos do sono foi a coif1. No caso das AVCs, as *wavelets* escolhidas foram a rbio3.1, para detecção de CK, e a bior3.1, para detecção de fusos do sono.

As RNAs e AVCs utilizadas nos testes finais do sistema são as mesmas usadas nos testes da seção anterior. Nesta etapa, em contrapartida, o teste é feito em um número bem maior de épocas, a fim de se obter parâmetros estatísticos mais próximos da realidade. No total, foram investigadas 500 épocas, de diferentes registros polissonográficos, com características de amplitude e frequências semelhantes às do estágio II do sono NREM.

A Tabela 6.19 ilustra o resultado do teste final na detecção de complexos K utilizando RNAs. A Tabela 6.20, por sua vez, exhibe o resultado da AVC-CK_rbio3.1 na detecção de complexos K. Ademais, a Tabela 6.22 e a Tabela 6.22 ilustram os parâmetros estatísticos obtidos na detecção de fusos do sono, através das RNA-FS_coif1 e AVC-FS_bior3.1, respectivamente.

Tabela 6.20 – Resultado do teste final da AVC-CK_rbio3.1, com $s = 0,3$, na detecção de complexos K.

REGISTRO	ÉPOCAS	CK	\overline{CK}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1	40	101	4619	71	30	4533	86	70,30	98,14	45,22	99,34	97,54
00275-1	81	130	9428	84	45	9200	228	65,12	97,58	26,92	99,51	97,14
00588-1	81	130	9428	84	45	9200	228	65,12	97,58	26,92	99,51	97,14
00601-1	81	252	9306	170	81	9156	150	67,73	98,39	53,13	99,12	97,58
00603-1	81	161	9397	104	57	9304	93	64,60	99,01	52,79	99,39	98,43
00614-1	81	161	9397	104	57	9304	93	64,60	99,01	52,79	99,39	98,43
TOTAL	445	1190	51320	768	418	50337	983	64,76	98,08	43,86	99,18	97,33

Tabela 6.22 – Resultado do teste final da RNA-FS_coif1, com $s = 0,3$, na detecção de fusos do sono.

REGISTRO	ÉPOCAS	FS	\overline{FS}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1	81	167	9391	137	30	9156	235	82,04	97,50	36,83	99,67	97,23
00275-1	81	265	9293	208	57	9161	132	78,49	98,58	61,18	99,38	98,02
00588-1	81	265	9293	208	57	9161	132	78,49	98,58	61,18	99,38	98,02
00601-1	60	97	6983	80	18	6795	188	81,63	97,31	29,85	99,74	97,09
00603-1	17	61	1945	60	1	1829	116	98,36	94,04	34,09	99,95	94,17
00617-1	80	259	9181	232	27	8991	190	89,58	97,93	54,98	99,70	97,70
TOTAL	400	1048	46152	860	189	45169	983	81,98	97,87	46,66	99,58	97,52

Tabela 6.21 - Resultado do teste final da AVC-FS_bior3.1, com $s = 0,3$, na detecção de fusos do sono.

REGISTRO	ÉPOCAS	FS	\overline{FS}	VP	FN	VN	FP	SEN	ESP	VPP	VPN	TA
00228-1	81	164	9394	113	51	9288	106	68,90	98,87	51,60	99,45	98,36
00275-1	81	265	9293	181	84	9211	82	68,30	99,12	68,82	99,10	98,26
00588-1	81	199	9359	107	92	9301	58	53,77	99,38	64,85	99,02	98,43
00603-1	60	97	6983	64	32	6772	211	66,67	96,98	23,27	99,53	96,57
00614-1	17	61	1945	58	3	1863	82	95,08	95,78	41,43	99,84	95,76
00617-1	80	260	9180	199	61	9071	109	76,54	98,81	64,61	99,33	98,20
TOTAL	400	1046	46154	722	323	45506	648	69,09	98,60	52,70	99,30	97,94

Considerando cada módulo de detecção separadamente, nota-se que o módulo de redes neurais artificiais obteve 78,94% de sensibilidade, 98,28% de especificidade, 51,29% de VPP, 99,51% de VPN e uma taxa de acerto de 97,85%⁵. Já o módulo de detecção baseado em análise de variáveis canônicas alcançou 66,79% de sensibilidade, 98,33% de especificidade, 47,74% de VPP, 99,23% de VPN e uma taxa de acerto de 97,62%. Desta forma, infere-se que o sistema baseado em RNAs obteve um melhor resultado se comparado com o sistema fundamentado em AVC.

Em geral, o número de falsos positivos na detecção dos padrões alvos, tanto do módulo neural como do módulo canônico, foi relativamente elevado se comparado com o número de verdadeiros positivos. Isso implica em uma baixa confiabilidade do sistema na detecção de tais padrões. Para contornar esse problema e diminuir o número de falsos posi-

⁵ Nesse caso, esses valores são obtidos considerando os dois padrões em questão, ou seja, os 78,94% de sensibilidade das RNAs, por exemplo, é devido à detecção de complexos k e fusos do sono.

tivos do sistema, pode-se diminuir a sensibilidade dos módulos de detecção. No entanto, ao adotar esse procedimento, a sensibilidade na detecção dos padrões⁶ também diminui.

Perceba que a taxa de acerto das RNAs e AVCs é bastante elevada (> 90% em todos os casos). Isso ocorre, principalmente, devido ao grande número de verdadeiros negativos. Ou seja, a taxa de acerto é mais uma reação à especificidade do que à sensibilidade.

⁶ Não confundir sensibilidade da RNA (ou da AVC ou dos módulos) com a sensibilidade do teste (ou sensibilidade na detecção dos padrões): a primeira refere-se àquela sensibilidade definida no capítulo 4, usada para definir o limiar de decisão da RNA ou AVC; a segunda é a sensibilidade calculada durante os testes do sistema.

Capítulo 7

Conclusões e Trabalhos Futuros

Para a implementação do sistema proposto tornou-se necessário o estudo de diversas técnicas de processamento de sinais, tais como a transformada *wavelet*, transformada de Fourier, análise de variáveis canônicas (AVC) e redes neurais artificiais (RNA). Nos primórdios deste trabalho, a idéia era integrar todas essas técnicas para desenvolver uma nova metodologia para detecção de complexos K e fusos do sono. Ao longo do desenvolvimento deste trabalho, contudo, percebeu-se que a unificação da AVC com a RNA tornou-se impraticável, pois a utilização da AVC com duas classes gera um espaço canônico de dimensão única, descartando a possibilidade de redução de dimensionalidade e descorrelação de dados. Após essa descoberta, o trabalho focou-se em realizar uma análise comparativa entre o desempenho das RNAs e das AVCs na detecção de complexos K e fusos do sono, utilizando a metodologia descrita no capítulo 4.

Foram desenvolvidas, então, duas novas metodologias para detecção de padrões específicos do estágio II do sono NREM em sinais de EEG (uma utilizando RNA e outra empregando AVC), com intuito de auxiliar no estagiamento do sono e no diagnóstico de doenças relacionadas a ele. Para tal, foi necessário a construção de um software que possibilitou o treinamento das RNAs e AVCs do sistema. Além disso, o software também permitiu realizar alguns testes de sensibilidade e especificidade das RNAs e AVCs, bem como a visualização dos sinais de EEG, para inspeção das épocas dos registros polissonográficos¹.

Ao todo foram selecionados 16 parâmetros para extração de características dos sinais de EEG, os quais mostraram-se competentes na identificação dos complexos K e fusos do sono nos sinais de EEG durante o sono. No entanto, estudos mais aprofundados em relação aos parâmetros que quantificam a morfologia dos sinais podem melhorar os resulta-

¹ Para mais detalhes do software desenvolvido, consultar o Apêndice A deste documento.

dos obtidos através dos métodos utilizados neste trabalho. A transformada *wavelet* foi a principal responsável pelo sucesso destes parâmetros em realizar a separação dos complexos K e fusos do sono, uma vez que em sua ausência esta tarefa tornou-se impraticável. Além da TW, parâmetros baseados no conteúdo espectral do sinal também foram de suma importância.

O software implementado foi de fundamental importância para o desenvolvimento desta pesquisa, uma vez que possibilita a visualização dos sinais de EEG, durante o sono, o treinamento das RNAs e AVCs, bem como a realização de testes para avaliação do sistema. No entanto, tal software ainda encontra-se em uma versão de testes e precisa de uns ajustes para tornar-se uma ferramenta apta para utilização do usuário final: o médico especialista.

Em termos gerais a RNA mostrou ser mais apropriada em se tratando de identificar os complexos K e fusos do sono, para auxiliar no estagiamento do sono. Apesar dos baixos valores de confiabilidade, o sistema obteve valores aceitáveis de sensibilidade e especificidade, tanto na identificação de complexos K, como no reconhecimento de fusos do sono, uma vez que a detecção de tais padrões é uma tarefa bastante complexa e que até mesmo especialistas discordam entre si.

Apesar de ter obtido resultados inferiores ao da RNA, a AVC mostrou ser uma alternativa interessante na identificação de padrões. Uma vez que a AVC depende bastante das variáveis que quantificam o conjunto de treinamento, bem como da representatividade do próprio conjunto de treinamento, estima-se que os resultados obtidos (não só para as AVCs, como para as RNAs também) podem ser melhorados caso seja feito um estudo mais detalhado a cerca das variáveis que melhor quantificam os padrões de diferentes classes, bem como dos padrões que melhor representam uma dada classe.

Para alavancar os valores de confiabilidade do sistema (VPP e VPN), pode-se inserir ao sistema um estudo de contexto na análise dos sinais. Por exemplo, como o complexo K é um evento síncrono ao longo de todo o córtex, ele geralmente é visto nas duas derivações centrais. Desta forma, uma forma de diminuir o número de falsos positivos seria reconhecer apenas os complexos K, quando estes aparecerem nas duas derivações centrais usadas neste trabalho (C3 e C4).

7.1. Trabalhos Futuros

Em função dos resultados obtidos, sugerem-se algumas implementações futuras para a melhoria deste trabalho:

1. Como se sabe que a escolha das medidas utilizadas durante a extração de parâmetros dos sinais influencia bastante nos resultados, é interessante que se faça um estudo mais intenso no sentido de garantir a escolha daqueles parâmetros que aperfeiçoem o processo de detecção de padrões do sono;
2. Calcular os coeficientes de detalhe da TW nas escalas 2, 3, 4, 5 e 6 para construir um vetor contendo todos esses componentes. Analisar o desempenho do sistema inserindo tal vetor na entrada das RNAs e AVCs do sistema. O objetivo é investigar a capacidade da RNA (ou AVC) de extrair as singularidades de cada classe de padrão;
3. Como o sistema não alcançou uma versão final para comercialização de um produto, sugere-se o desenvolvimento de um software robusto, com todos os recursos de visualização necessários para uma boa usabilidade do usuário final;
4. Testar a metodologia proposta na detecção de outros tipos de padrões, tais como reconhecimento de formas em imagens digitais, reconhecimento de ondas no ECG, entre outras.
5. Inserir duas RNAs (ou AVCs) especialistas no sistema. Uma capaz de reconhecer atividades de fundo de EEG semelhantes a complexos K e outra especialista em detectar ruídos de fundo de EEG similares aos fusos do sono, como feito no trabalho de Argoud (2001);
6. Implementação de um sistema de aquisição de sinais de EEG, para facilitar a construção da base de dados e possibilitar ao usuário do sistema a construção de bases de dados específicas para determinadas pesquisas;
7. Sugere-se também uma fusão do sistema proposto com redes neurais dinâmicas.

Apêndice A

Eletroencefalografia

Desde sua descoberta, em 1929, os registros de EEG vêm sendo alvo de vários estudos relacionados à atividade cerebral e, por conseguinte, atualmente, é considerada uma das principais fontes de informação em se tratando do diagnóstico de doenças relacionadas ao sistema nervoso central. O estudo do sono, por sua vez, é uma das áreas que se beneficiou como início dos estudos acerca da atividade cerebral.

Registros elétricos a partir da superfície do cérebro, ou mesmo a partir da superfície da cabeça (escalpo), demonstram que existe uma contínua atividade elétrica no cérebro. Tanto a intensidade como os padrões dessa atividade elétrica são determinados pelo grau de excitação das diferentes partes do cérebro, resultantes do sono, vigília ou de doenças como a epilepsia ou ainda a psicose (GUYTON E HALL, 2006).

Eletroencefalografia é definida com a medição neurofisiológica da atividade elétrica do cérebro por meio de eletrodos colocados no escalpo de um indivíduo¹. Os sinais resultantes, então, são conhecidos como eletroencefalograma (EEG) e representam um sinal elétrico obtido a partir de um largo número de neurônios. Estes sinais, algumas vezes, são chamados de ondas cerebrais, apesar de este termo ser desaconselhado (NIEDERMEYER E DA SILVA, 1993).

Um registro de EEG é caracterizado pelas flutuações da atividade elétrica de grandes conjuntos de neurônios no cérebro. Especificamente, o EEG é a medida do fluxo de corrente extracelular associado com a soma das atividades individuais de muitos neurônios (KELLY, 1991). Estas atividades elétricas são resultado da atividade coletiva de muitas células em uma pequena área do córtex cerebral (RODRIGUES, 2002).

¹ Em alguns casos, o eletrodo é colocado sob o escalpo ou até mesmo em contato direto com o córtex.

O EEG tem se mostrado bastante útil como ferramenta de monitoração e diagnóstico em certas situações clínicas, tais como epilepsia, distúrbios do sono, coma e morte cerebral. Neurocientistas, bio-psiquiatras e vários outros profissionais de áreas afins utilizam o EEG para estudar o funcionamento do cérebro, registrando a atividade cerebral durante comportamentos controlados de humanos voluntários e de animais em experimentos laboratoriais.

Em 1875, Richard Caton (*apud* NIEDERMEYER E SILVA, 1993, p. 1), usando um galvanômetro, foi o primeiro a observar a atividade elétrica no cérebro. O primeiro registro de atividade elétrica feita em humanos, no entanto, foi feito, em 1929, pelo neuropsiquiatra alemão Hans Berger (*apud* NIEDERMEYER E SILVA, 1993, p. 4), marcando o início da eletroencefalografia, que foi incorporada à prática clínica a partir de 1930. O alemão, que deu nome ao dispositivo (eletroencefalograma), às vezes é creditado pela invenção do EEG, embora outros cientistas tenham trabalhado com experimentos similares na mesma época. Edgar Douglas Adrian, por exemplo, também está intimamente ligado à invenção da eletroencefalografia, uma vez que ele solidificou as descobertas de Berger (NIEDERMEYER E SILVA, 1993). Em 1934, Fisher e Löwenback (*apud* NIEDERMEYER E SILVA, 1993, p. 7) demonstraram, pela primeira vez, espículas epleptiformes. Em 1935, Gibbs, Davis e Lennox (*apud* NIEDERMEYER E SILVA, 1993, p. 8) descreveram alguns tipos de ondas no EEG, dando início ao campo de eletroencefalografia clínica. Em 1936, o primeiro laboratório de EEG foi aberto no Hospital Geral de Massachusetts e, em 1947, a Sociedade Americana de EEG foi fundada e, conseqüentemente, realizou-se o primeiro congresso internacional em EEG. Em 1953, Aserinsky e Kleitman (*apud* FERNANDES, 2006, p. 159) descreveram o sono REM e, desde então, vários cientistas, de várias áreas (medicina, engenharia, biologia, etc), focaram suas atenções nessa área de pesquisa. Até hoje, vários estudos têm sido feitos, a fim de entender-se o funcionamento do sistema nervoso central, visando solucionar casos clínicos e aprofundar o conhecimento.

Atualmente o eletroencefalograma tornou-se uma das principais ferramentas para diagnosticar doenças do sistema nervoso central (SNC) e monitoração da atividade elétrica do cérebro. Além disso, o EEG possibilitou (e ainda possibilita) grandes avanços nas áreas ligadas a neurologia, tais como a neurofisiologia e neuropsiquiatria, dentre outras. Sua alta resolução temporal, seu baixo custo e sua fácil implementação fazem do EEG uma atrativa

ferramenta de monitoração, embora hoje em dia existam avançadas técnicas de imagem, com maior resolução espacial, para captação de atividade cerebral.

A.1. Aspectos Fisiológicos do EEG

O EEG é gerado principalmente por interações sinápticas entre neurônios das redes corticocorticais e corticotálamicais. Potenciais sinápticos e propriedades neuronais intrínsecas geram correntes no espaço extracelular que se somam algebricamente e linearmente, contribuindo para a geração do EEG. Respostas ativas dos dendritos podem também implicar em potenciais de EEG (AMZICA E STERIADE, 1997).

O sinal de eletroencefalograma ocupa uma banda de frequência entre 0 e 100 Hz, embora se considere, para efeito de utilização clínica, que a energia destes sinais está concentrada na faixa de 0,5 a 60 Hz. Existem frequências tanto superiores como inferiores a essa faixa, que, no entanto, não possuem significado no EEG clínico. A amplitude do sinal de EEG de escalpo é medida em volts e ocupa uma faixa entre 10 e 200 μV , aproximadamente (NIEDERMEYER E SILVA, 1993).

A banda dos sinais de EEG é compartilhada com vários outros sinais biológicos (ECG, EOG, EMG, etc), cujas amplitudes possuem uma magnitude bem superior. Com isso, podemos perceber a dificuldade que existe para captar-se um sinal de EEG, necessitando, desta forma, de um sistema de aquisição bem robusto, com bons filtros e bons amplificadores.

A morfologia dos sinais de EEG pode variar de acordo com a localização dos eletrodos, bem como com as condições nas quais foram efetuados os registros, tais como: idade, estado físico (vigília, sono, anestesiado, etc) e emocional (raiva, depressão, estresse, etc) do paciente. Pelo fato de certas frequências no sinal de EEG estarem ligadas a certas regiões e atividades do indivíduo, as ondas cerebrais captadas no eletroencefalograma são divididas em quatro grupos básicos, como mostra a Figura A.7.1.

As ondas *alfa* possuem frequência entre 8 e 13 Hz que ocorrem geralmente durante a vigília, com maior amplitude na região posterior do escalpo, podendo, no entanto, aparecer nas regiões frontal e parietal. São mais comuns em indivíduos com olhos fechados e em




Figura A.7.1 - Diferentes ondas cerebrais em um registro de EEG de uma pessoa normal. A amplitude e a morfologia variam de acordo com a excitação das partes do córtex (GUYTON E HALL, 2006).

estado de relaxação mental (TYNER *et al.*, 1989; NIEDERMEYER E SILVA, 1993; GUYTON E HALL, 2006).

O ritmo *beta*, que possui frequência acima de 13 Hz, ocorre geralmente nas regiões frontal e parietal, quando um indivíduo normal está acordado com os olhos abertos, ou em caso de intensa ativação do SNC. Geralmente a amplitude do EEG neste ritmo não ultrapassa 30 µV e sua frequência é inferior a 35 Hz (NIEDERMEYER E SILVA, 1993). A Figura A.7.2 mostra a aparição das ondas beta ao abrirem-se os olhos.

Ondas do tipo *delta* possuem frequência inferior a 4 Hz e são geralmente associadas à crianças pequenas (bebês) e em pacientes com lesões cerebrais, contudo podem ser vistas, também, em pessoas normais durante os estágios mais profundos do sono (estágios III e IV do sono NREM) (NIEDERMEYER E SILVA, 1993).

Já as ondas *theta* situam-se no intervalo de 4 a 8 Hz do espectro do EEG e estão associadas à sonolência e ao início do sono. Podem ser encontradas em crianças, adolescen-



Figura A.7.2 - Reposição das ondas alfa, no início do registro, pelo ritmo beta, assíncrono, quando o indivíduo abre os olhos (GUYTON E HALL, 2006).

Tabela A.1 - Principais ritmos cerebrais e suas respectivas frequências.

TIPO DE ONDA	FREQUÊNCIA (HZ)
Delta	0.5 – 4
Teta	4 – 8
Alfa	8 – 13
Beta	13 – 35

tes e adultos jovens, durante estágios de inconsciência como a hipnose, sonhos diurnos, sonhos lúcidos, sono leve, entre outros. A Tabela A.1 mostra os principais ritmos do EEG e suas respectivas faixas de frequência.

Como visto anteriormente, o nível de consciência do indivíduo influencia a atividade elétrica do córtex e, conseqüentemente, a morfologia do EEG. À medida que a atividade aumenta, o EEG muda para ondas de frequências maiores e amplitudes menores. Quando os olhos são fechados, por exemplo, as ondas alfa começam a dominar o EEG. Nos instantes iniciais do sono, a frequência do EEG vai se tornando cada vez mais lenta e, à medida que o indivíduo mergulha num sono mais profundo, a frequência vai diminuindo e a amplitude aumentando, como pode ser visto na Figura A.7.3.

No começo do sono, o ritmo alfa tende a se espalhar na região anterior do escalpo, transformando-se em aparições intermitentes durante o estágio I do sono e, então, a medida




Figura A.7.3 - Dependência entre o nível de consciência do indivíduo e a atividade elétrica no EEG. A morfologia do EEG muda de acordo com os diferentes estágios de vigília e sono (GUYTON E HALL, 2006).

que o sono vai se aprofundando ele desaparece (TERZANO *et al.*, 2001), dando lugar a uma atividade mista nas faixas de frequência teta (4 a 7 ciclos/seg.) e beta (acima de 13 ciclos/seg.), com poucas componentes delta de média amplitude. Surgem também as ondas *vertex*, características da sonolência (estágio I do sono NREM). Com o aprofundamento do sono para o estágio II, surgem os fusos do sono e os complexos K, juntamente com um aumento no traçado de ondas delta. Nas fases III e IV há um domínio das ondas delta no traçado do EEG.

A.2. Posicionamento de Eletrodos

O sistema internacional 10-20 é geralmente o mais aplicado para se registrar o EEG de escalpo. Nesse sistema, 21 eletrodos são fixados na superfície do escalpo, como ilustra a Figura A.7.4.

As posições são determinadas da seguinte maneira: os pontos de referência são o nasal (depressão acima do nariz entre os olhos) e o ínio (uma protuberância de osso localizada na parte posterior do crânio na linha central). A partir destes pontos, os perímetros da cabeça são medidos nos planos transversal e mediano. As localizações dos eletrodos são determinadas dividindo-se esses perímetros em intervalos de 10% e 20%, como mostra a

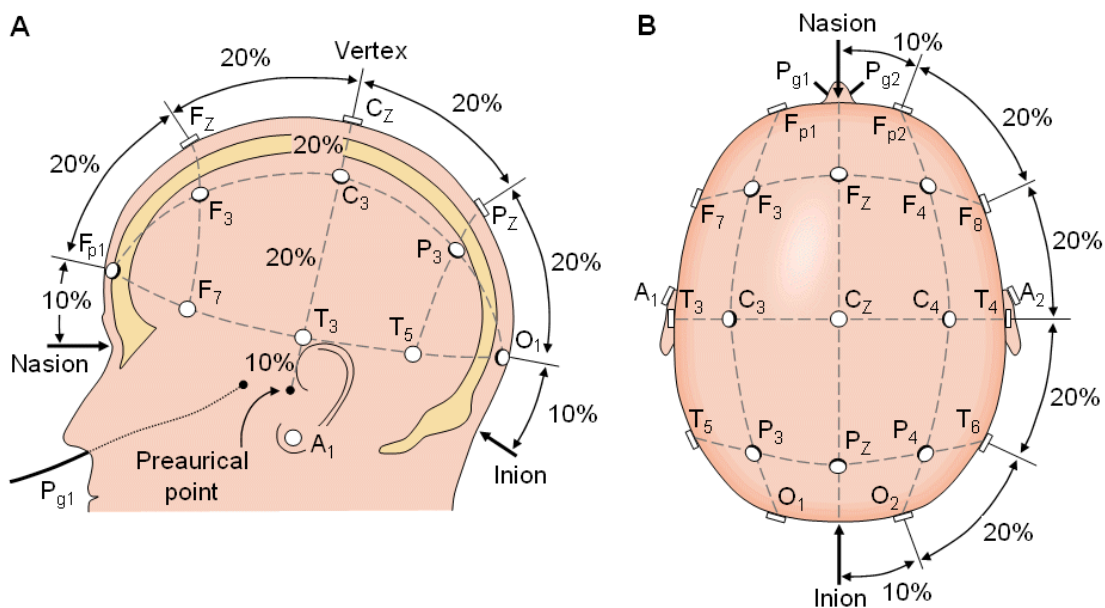


Figura A.7.4 - Sistema internacional de 10-20 de colocação de eletrodos. Eletrodos com índices ímpares localizam-se no lado esquerdo, índices pares ficam no lado direito e índice Z ou 0 na linha central (MALMIVUO E PLONSEY, 1995).

Figura A.7.4. Três eletrodos adicionais são postos em cada lado da cabeça, equidistantes dos pontos vizinhos.

A nomenclatura dos eletrodos varia de acordo com a região em que este se localiza. A primeira letra representa a região do escalpo onde o eletrodo está fixado. Um eletrodo situado na região temporal, por exemplo, recebe a nomenclatura T_x , onde o índice ‘x’ indica a posição nesta região. Se x é um número ímpar, o eletrodo deverá estar localizado no lado esquerdo do crânio, caso x seja par, deverá estar no lado direito, ou, ainda, se o eletrodo estiver no centro, este receberá a letra Z ou o número zero como índice. As regiões existentes são a frontal (F), central (C), temporal (T), parietal (P) e occipital (O).

Os sistemas de aquisição de EEG podem ser usados em dois modos (ver Figura A.7.5): unipolar ou bipolar. No primeiro método, o potencial de cada eletrodo é medido em relação a um eletrodo neutro, ou em relação à média de todos os eletrodos. No segundo caso, a diferença de potencial entre um par de eletrodos é medida.

As atividades neuronais geradoras dos complexos K são síncronas sobre amplos territórios corticais (AMZICA E STERIADE, 1995). Desde que a montagem bipolar registra a diferença entre dois eletrodos de diferentes áreas do escalpo, esta alternativa torna-se inviável para visualização do complexo K, pois a diferença do sinal entre dois eletrodos é relativamente pequena. Por conseguinte, montagens monopolares são a melhor escolha para o estudo dos complexos K (AMZICA E STERIADE, 2002).

Geralmente, para um estagiamento adequado do sono, monitoram-se as derivações C3-A1, C4-A1, O1-A2, O2-A1 (RECHTSCHAFFEN E KALES, 1968). Como os eletrodos no

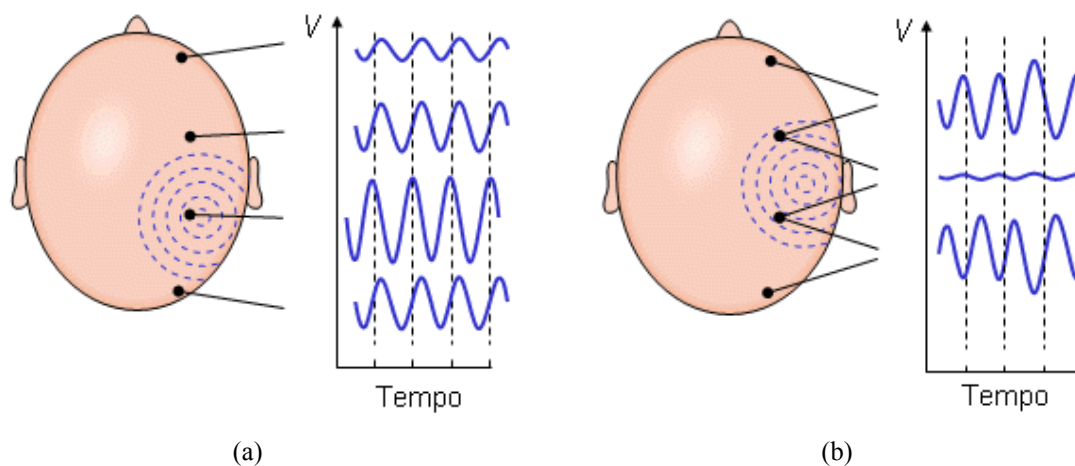


Figura A.7.5 - Montagem (a) unipolar e (b) bipolar de eletrodos (MALMIVUO E PLONSEY, 1995).

lobo da orelha podem ser considerados sem atividade elétrica relevante, a montagem é dita unipolar e as derivações são intituladas C3, C4, O1 e O2, respectivamente.

Referências Bibliográficas

- AKANSU, A.N.; TAZEBAY, M.V.; MEDLEY, M.J.; DAS, P.K.; 1997. Wavelet and subband transforms: fundamentals and communication applications. *Communications Magazine, IEEE*. v. 35. n. 12, p. 104-115.
- AKGÜL, T., SUN, M., SCLABASSI, R.J., *et al.*; 2000. Characterization of Sleep Spindles Using Higher Order Statistics and Spectra. *IEEE Transactions on Neural Networks*. v. 47, n. 8, p. 997-1009.
- AKIN, A., AKGUL, T.; 1998. Detection of Sleep Spindles by Discrete Wavelet Transform. In: IEEE 246TH ANNUAL NORTHEAST BIOENGINEERING CONFERENCE. (Apr. 1998: Hershey, Pennsylvania). *Proceedings*. Pennsylvania, 1998. p. 15-17.
- ALEKSANDER, I., MORTON, H.; 1990. *An Introduction to Neural Computing*, London: Chapman and Hall.
- AMZICA, F., STERIADE, M.; 1995. Short- and long-range neuronal synchronization of the slow (< 1 Hz) cortical oscillation. *Journal of Neurophysiology*. v. 75, p. 20-38.
- AMZICA, F., STERIADE, M.; 1997. The K-complex: Its slow (<1-Hz) rhythmicity and relation to delta waves. *Neurology*. v. 49, n. 4, p. 952-959.
- AMZICA, F., STERIADE, M.; 2002. The functional significance of K-complexes. *Sleep Medicine Reviews*. v. 6, n. 2, p. 139-149.
- ARGOUD, F.I.M., 2001. *Contribuição ao Estudo da Automatização da Detecção e Análise de Eventos Epileptiformes em Eletroencefalograma*. Florianópolis. Tese (Doutorado em Engenharia Elétrica) - Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina.
- ESTRADA, E., NAZERAN, H., NAVA, P., *et al.*; 2005. Itakura Distance: A Useful Similarity Measure between EEG and EOG Signals in Computer-aided Classification of Sleep Stages. In: 27TH ANNUAL CONFERENCE ON ENGINEERING IN MEDICINE

- AND BIOLOGY. (Sep. 2005: Shangai, China). *Proceedings*. China, 2005. p. 1189-1192.
- FERNANDES, R.M.F.; 2006. O Sono Normal. In: SIMPÓSIO BRASILEIRO DE DISTÚRBIOS RESPIRATÓRIOS DO SONO. (Jun. 2006 : Ribeirão Preto). *Proceedings*. Ribeirão Preto. p. 157-168.
- FRANK, M.G.; 2006. The Function of Sleep. In: LEE-CHIONG, T.L.; 2006. *Sleep - A Comprehensive Handbook*. New Jersey: Wiley-Liss.
- GARCIA, E.V., 2005. *Processamento de Sinais Usando Wavelets Para Caracterização da Repolarização Ventricular Durante Hipoglicemia*. Florianópolis. Tese (Doutorado em Engenharia Elétrica) - Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina.
- GARDNER, S., GOWER, J.C., ROUX, N.J.; 2006. A synthesis of canonical variate analysis, generalised canonical correlation and Procrustes analysis. *Computational Statistics and data Analysis*, v. 50, n. 1, p. 106-134.
- GENNARO L. DE, FERRARA, M.; 2003. Sleep spindles: an overview. *Sleep Medicine Reviews*. v. 7, n. 5, p. 423-440.
- GILLIN, J.C.; 1998. Are sleep disturbances risk factors for anxiety, depressive and addictive disorders?. *Acta Psychiatrica Scandinavica Supplementum*. v. 98, n. 393. p. 39-43.
- GLAVINOVITCH, A., SWAMY, M.N.S., PLOTKIN, E.I.; 2005. Wavelet-Based Segmentation Techniques in the Detection of Microarousals in the Sleep EEG.
- GORUR, D., HALICI, U., AYDIM, H., *et al.*; 2002. Sleep Spindles Detection Using Short Time Fourier Transform And Neural Networks. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS. (May 2002 : Honolulu) *Proceedings*. Honolulu. p. 1631-1636.
- GOURINENI R., ZEE, P.C.; 2006. Neurological and Medical Disorders Associated With Circadian Rhythm Disturbances. In: Lee-Chiong, T.L.; 2006. *Sleep – A Comprehensive Handbook*. New Jersey: Wiley-Liss.
- GUAZZELLI, M., FEINBERG, I., AMINOFF, M., *et al.*; 1986. Sleep spindles in normal elderly: comparison with young adult patterns and relation to nocturnal awakening, cognitive

- function and brain atrophy. *Electroencephalography and Clinical Neurophysiology*. v. 63, n. 6, p. 526-539.
- GUYTON, A.C., HALL, J.E.; 2006. *Textbook of Medical Physiology*. 11. ed. Philadelphia : Elsevier Saunders.
- HAYKIN, S.; 2001. *Redes Neurais: Princípios e Prática*. 2. ed. Porto Alegre: Bookman.
- HE, W., YAN, X., CHEN, X., *et al.*; 2005. Nonlinear Feature Extraction of Sleeping EEG Signals. In: 27TH ANNUAL CONFERENCE ON ENGINEERING IN MEDICINE AND BIOLOGY. (Sep. 2005: Shangai, China). *Proceedings*. China, 2005. p. 4614-4617.
- HELD, C.M., CAUSA, L., ESTÉVEZ, P., *et al.*; 2004. Dual Approach for Automated Sleep Spindles Detection within EEG Background Activity in Infant Polysomnograms. In: 26TH ANNUAL INTERNATIONAL CONFERENCE OF THE EMBS. (Sep. 2004: San Francisco, California). *Proceedings*. California, 2004. p. 566-569.
- HENRY, D., SAUTER, D., CASPARY, O; 1994. Comparison of Detection Methods: Application to K-Complex Detection in Sleep EEG. In: IEEE 16TH ANNUAL INTERNATIONAL CONFERENCE OF ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY. (Jul. 1999: Baltimore, Maryland). *Proceedings*. Maryland, 1994. p. 1218-1219.
- HESE, P.V., PHILIPS, W., KONINCK, J. DE, *et al.*; 2001. Automatic Detection of Sleep Stages Using The EEG. In: 23RD. ANNUAL EMBS INTERNATIONAL CONFERENCE. (Oct. 2001 : Istambul). *Proceedings*. Istambul. p. 172-174.
- HIMANEN, S.L., HASAN, J.; 2000. Limitations of Rechtschaffen and Kales. *Sleep Medicine Reviews*. v. 4, n. 2, p. 149-167.
- HU, J., KNAPP, B.; 1991. Electroencephalogram Pattern Recognition Using Fuzzy Logic. In: 25th Asilomar Conference on Signals, Systems and Computers. (Nov. 1991: Pacific Groove, California). *Proceedings*. California. p. 805-807.
- HUANG, L., SUN, Q., CHENG, J.; 2003. Novel Method of Fast Automated Discrimination of Sleep Stages. In: 25TH ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE

- EMBS. (Sep. 2003, Cancún, Quintana Roo, Mexico). *Proceedings*. Quintana Roo, 2003. p. 2273-2276.
- HUANG, P.S., HARRIS, C.J., NIXON, M.S.; 1998. Canonical space representation for recognizing humans by gait and face. In: IEEE SOUTHWEST SYMPOSIUM ON IMAGE ANALYSIS AND INTERPRETATION. (Apr. 1998 : Arizona). *Proceedings*. Arizona. p.180-185.
- IAIONE, F.; 2003. *Proposta e Implementação de Metodologia para Detecção de Hipoglicemia Baseada na Análise e Classificação do Eletroencefalograma*. Florianópolis. Tese (Doutorado em Engenharia Elétrica) - Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina.
- KAM, A., COHEN, A., GEVA, A.B., TARASIUK, A.; 2004. Detection of K-Complexes in Sleep EEG Using CD-HMM. In: 26TH ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE EMBS. (Sep. 2004 : San Francisco). *Proceedings*. San Francisco. p. 33-36.
- KIM, B.Y., PARK, K.S.; 2000. Automatic sleep stage scoring system using genetic algorithms and neural network. In: 22TH ANNUAL EMBS INTERNATIONAL CONFERENCE. (Jul. 2000: Chicago, Illinois). *Proceedings*. Illinois, 2000. p. 849-850.
- KELLY, D.D.; 1991. Sleep and Dreaming - Disorders of Sleep and Consciousness. In: KANDEL, E.R., SCHARTZ, J.H., JESSEL, T.M.; 1991. *Principles of Neural Science*. 2 ed. London. Prentice-Hall. p. 792-819.
- KRUEGER J.M., OBÁL F.J., FANG, J.; 1999. Why we sleep: a theoretical view of sleep function. *Sleep Medicine Reviews*. v. 3, n. 2, p. 119-129.
- KUBICK, S., HERMMAN, W.M., HÖLLER, L.; 1985. Critical comments on the rules by Rechtschaffen and Kales concerning the visual evaluation of EEG sleep records. In: KUBICKI, S., HERMMAN, W.M.; 1985. *Methods of Sleep Research*. Stuttgart, New York: Gustav Fisher. p. 19-35.
- LI, J., DU, Y., ZHAO, L.; 2005. Sleep Stage Study with Wavelet Time-Frequency Analysis. In: INTERNATIONAL CONFERENCE ON NEURAL NETWORKS AND BRAIN. (Oct. 2005: Shenyang, China). *Proceedings*. China, 2005. p. 872-875.

- MALLAT, S.; 1989. A Theory for multiresolution signal decomposition: the wavelet representation. *IEEE Pattern Analysis and Machine Intelligence*. v. 1, p. 674-693.
- MALLAT, S.; 1999. *A Wavelet Tour of Signal Processing*. 2. ed. Elsevier (USA): Academic Express.
- MALMIVUO, J., PLONSEY, R.; 1995. *Bioelectromagnetism – Principles and Applications of Bioelectric and Biomagnetic Fields*. Oxford University Press, New York. <http://butler.cc.tut.fi/~malmivuo/bem/bembook/> (último acesso em 23/04/2007).
- MARKS, G.A.; 2006. The Neurobiology of Sleep. In: LEE-CHIONG, T.L.; 2006. *Sleep - A Comprehensive Handbook*. New Jersey: Wiley-Liss.
- MILLÁN, J.R., MOURIÑO, J., FRANZÉ, M. *et al.*; 2002. A Local Neural Classifier for the Recognition of EEG Pattern Associated to Mental Tasks. *IEEE Transactions on Neural Networks*. v. 13, n. 3, p. 678-686.
- MISITI, M., MISITI, Y., OPPENHEIM, G., POGGI, J.M.; 2006. *Wavelet Toolbox User's Guide - For use with MATLAB*. 3 ed. Massachusetts (USA): The MathWorks, Inc.
- MONTEIRO, L.R., REIS, S.F. DOS; 1999. *Princípios de Morfometria Geométrica*. 1 ed. Ribeirão Preto (BRA): Holos Editora.
- NATAJARAN, K., ACHARYA, U.R., ALIAS, F., *et al.*; 2004. Nonlinear analysis of EEG signals at different mental states. *Biomedical Engineering OnLine*. v. 3, n. 7, p. 1-11.
- NICOLAS, A., PETIT, D., ROMPRÉ, S., MONTPLAISIR, J.; 2001. Sleep spindle characteristics in healthy subjects of different age groups. *Clinical Neurophysiology*. v. 112, n. 3, p. 521-527.
- NIEDERMEYER, E., SILVA, F.L. DA; 1993. *Electoencephalography – Basic Principles, Clinical Applications, and Related Fields*. 3. ed. Baltimore (USA): Williams & Wilkins.
- OHAYON, M.M., GUILLEMINAULT, C.; 2006. Epidemiology of Sleep Disorders. In: Lee-Chiong, T.L.; 2006. *Sleep – A Comprehensive Handbook*. New Jersey: Wiley-Liss.
- PAIVA, T., ROSA, A.; 1991. The K complex variability in normal subjects. In: TERZANO, M.G., HALÁSZ, P., DECLERCK, A.C.; 1991. *Phasic Events and Organization of Sleep*. New York: Raven Press. p. 167-184.

- POHL, V., FAHR, E.; 1995. Neuro-Fuzzy recognition of K-Complexes in Sleep EEG Signals. In: IEEE 17TH ANNUAL CONFERENCE IN ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY. (Sep. 1995 : Montreal). *Proceedings*. Montreal. p. 789-790, 20-25 Sep.
- POWER, A.E.; 2004. Slow-wave sleep, acetylcholine, and memory consolidation. *Proceedings of National Academy of Sciences of United States of America*. v. 101. n. 7, p. 1795-1796. 17 Feb.
- RAMA, A.N., CHO, S.C., KUSHIDA, C.A.; 2006. Normal Human Sleep. In: Lee-Chiong, T.L.; 2006. *Sleep – A Comprehensive Handbook*. New Jersey: Wiley-Liss.
- RECHTSCHAFFEN, A., KALES, A.; 1968. *A Manual of standardized terminology, technique and scoring system for sleep stages of human subjects*, Washington DC: National Institutes of Health, no. 204.
- REETH, O.V., WEIBEL, L., SPIEGEL, K., ET AL.; 2000. Interactions between stress and sleep: from basic research to clinical situations. *Sleep Medicine Reviews*. v. 4, n. 2, p. 201-219.
- REINOSO-SUÁREZ, F., ANDRÉS, I.DE, RODRIGO-ANGULO, M.L., GARZÓN, M.; 2001. Brain structures and mechanisms involved in the generation of REM sleep. *Sleep Medicine Reviews*. v. 5, n. 1, p. 93-77.
- REZA, A.M.; 1999. Wavelet Characteristics, What Wavelets Should I Use?, *White Paper*. 1999, Referenced 1.4.2002
- RICHARD, C., LENGELLE, R.; 1998. Joint Time and Time-Frequency Optimal Detection of K-Complexes in Sleep EEG. *Computers and Biomedical Research*. v. 31, p. 209-229.
- RIOUL, O., VETTERLI, M.; 1991. Wavelets and Signal Processing. *IEEE Signal Processing Magazine*, p. 14-28, Oct.
- ROBERTS, S., TARASSENKO, L.; 1992. Analysis of the sleep EEG using a multilayer network with spatial organization. *IEEE Proceedings F Radar and Signal Processing*. v. 139, n. 6, p. 420-425.
- RODRIGUES, M.A.B., AZEVEDO, F.M. DE, MARINO NETO, J.; 1999. Sistema Para Identificação de Padrões do Sono com o Auxílio de Redes Neurais Dinâmicas. In: IV BRAZIL-

- IAN CONFERENCE ON NEURAL NETWORKS. (Jul. 1999: São José dos Campos). *Proceedings*. São José dos Campos. p. 326-331.
- RODRIGUES, M.A.B., 2002. *Sistema para detecção e classificação automática de apnéias do sono a partir de registros polissonográficos*. Florianópolis. Tese (Doutorado em Engenharia Elétrica) - Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina.
- ROSENTHAL, L.; 2006. Physiologic Processes During Sleep. In: Lee-Chiong, T.L.; 2006. *Sleep - A Comprehensive Handbook*. New Jersey: Wiley-Liss.
- SADASIVAN, P.K. E DUTT, D.N.A.; 1994; A non-linear estimation model for adaptive minimization of EOG artifacts from EEG signals. *International Journal of Bio-Medical Computing*. v.36, p. 199-207.
- SAKAI, K., CROCHET S.; 2003. A Neural mechanism of sleep and wakefulness. *Sleep and Biological Rhythms*. v. 1, p. 29-42.
- SALA, F.A.; 2005. *Mapas de Kohonen na Detecção de Eventos Epileptogênicos*. Florianópolis. Dissertação (Mestrado em Engenharia Elétrica) - Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina.
- SAMPAIO, E.; 2007. Tecidos Muscular e Nervoso. *Bio Tempori* (página pessoal). <http://www.decisivo.com.br/elvira/bnresposta6c.htm> (último acesso em 31/05/2007).
- SHIMADA, T., SHIINA, T., SAITO, Y.; 2000. Detection of Characteristic Waves of Sleep EEG by Neural Networks Analysis. *IEEE Transactions on Biomedical Engineering*, New York, v. 47, n. 3 (Mar.), p. 369-379.
- SILVA, R.S. DA; 1995. Introdução à Técnica de Polissonografia. *Brazilian Journal of Epilepsy and Clinical Neurophysiology*. Porto Alegre, v. 1, n. 1, p. 23-32.
- SMITH, J.R, NEGIN, M., NEVIS, A.H.; 1969. Automatic Analysis of Sleep Electroencephalograms by Hybrid Computation. *IEEE Transactions on Systems Science and Cybernetics*. New York, v. 5, n. 4, p. 278-284.
- STERIADE, M., MCCORMICK, D.A., SEJNOWSKI, T.J.; 1993. Thalamocortical oscillations in the sleeping and aroused brain. *Science*. v. 262, p. 679-685.

- STRANG, G., NGUYEN, T.; 1996. *Wavelets and Filter Banks*. Wellesley: Wellesley-Cambridge Press.
- SUSMAKOVA, K.; 2004. Human Sleep and Sleep EEG. *Measurement Science Review*, v. 4, n. 2, p. 59-74.
- TAKAHASHI, Y., KIPNIS, D.M., DAUGHADAY, W.H.; 1968. Growth Hormone Secretion during Sleep. *The Journal of Clinical Investigation*. v. 47, p. 2079-2090.
- TERZANO, M.G., PARRINO, L., SHERIERI, A. *et al.*; 2001. Atlas, rules and recording techniques for the scoring of cyclic alternating pattern (CAP) in human sleep. *Sleep Medicine*. v. 2, p. 537-553.
- TIAN, J.Y., LIU, J.Q.; 2005. Automated Sleep Staging by a Hybrid System Comprising Neural Network and Fuzzy Rule-based Reasoning. In: 27TH ANNUAL CONFERENCE ON ENGINEERING IN MEDICINE AND BIOLOGY. (Sep. 2005: Shanghai, China). *Proceedings*. China, 2005. p. 4115-4118.
- TRAVESSA, S.S.; 2006. *Investigação sobre Redes Neurais Complexas para separação entre padrões epileptiformes*. Florianópolis. Dissertação (Mestrado em Engenharia Elétrica) - Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina.
- TYNER, F.S., KNOTT, J.R., MAYER, W.B.; 1989. *Fundamentals of EEG Technology*. New York: Raven Press.
- VIVALDI, E.A., BASSI, A.; 2006. Frequency Domain Analysis of Sleep EEG for Visualization and Automated State Detection. In: ANNUAL INTERNATIONAL CONFERENCE ON EMBS. (Aug. 2006: New York City, New York). *Proceedings*. New York, 2006. p. 3740-3743.
- WEISSTEIN, E.W.; Skewness. From *MathWorld - A Wolfram Web Resource*. <http://mathworld.wolfram.com/Skewness.html> (último acesso em 14/04/2007).
- WORLD HEALTH ORGANIZATION; 2004. *WHO technical meeting on sleep and health*. Bonn, Germany. Jan. 22-24. www.euro.who.int/document/E84683_1.pdf (último acesso em 30/05/2007).

ZYGIEREWICZ, J.; 2000. *Analysis of sleep spindles and model of their generation*. Warszawa. Dissertation (Degree of Doctor of Physics) - Institute of Experimental Physics, Warsaw University.