

MARIA DO CARMO VITARELLI PEREIRA

**AVALIAÇÃO DE TÉCNICAS DE PRÉ-PROCESSAMENTO
DE SINAIS DO EEG PARA DETECÇÃO DE EVENTOS
EPILEPTOGÊNICOS UTILIZANDO REDES NEURAIAS
ARTIFICIAIS**

FLORIANÓPOLIS - 2003

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA

AVALIAÇÃO DE TÉCNICAS DE PRÉ-PROCESSAMENTO
DE SINAIS DO EEG PARA DETECÇÃO DE EVENTOS
EPILEPTOGÊNICOS UTILIZANDO REDES NEURAIAS
ARTIFICIAIS

Tese submetida à Universidade Federal de Santa Catarina como parte dos
requisitos para a obtenção do grau de Doutor em Engenharia Elétrica

MARIA DO CARMO VITARELLI PEREIRA

Florianópolis (2003)

**AVALIAÇÃO DE TÉCNICAS DE PRÉ-PROCESSAMENTO DE
SINAIS DO EEG PARA DETECÇÃO DE EVENTOS
EPILEPTOGÊNICOS UTILIZANDO REDES NEURAIAS
ARTIFICIAIS**

Maria do Carmo Vitarelli Pereira

Esta tese foi julgada adequada para obtenção do Título de Doutor em Engenharia Elétrica, Área de Concentração Engenharia Biomédica, 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. Jefferson Luiz Brum Marques, Ph.D.
Coordenador do Curso de Pós-Graduação em Engenharia Elétrica

Banca Examinadora:

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

Profa. Fernanda Isabel Marques Argoud, Dr. Eng.
Co-Orientadora

Prof. Cairo Lúcio Nascimento Jr, Ph.D.

Profa. Edna Lúcia Flores, D.Sc.

Prof. Jefferson Luiz Brum Marques, Ph.D.

Prof. Marco Aurélio Benedetti Rodrigues, Dr. Eng.

Agradecimentos:

Aos orientadores, Prof. Fernandes Mendes de Azevedo e Fernanda Isabel Marques Argoud, pela dedicação e apoio recebidos no decorrer deste trabalho. A todos os professores do IEB-UFSC. Ao Prof. Jefferson L. B. Marques, em especial, pela atenção. Aos amigos do IEB-UFSC pela cordialidade e amizade indispensável.

Resumo

A avaliação desenvolvida neste trabalho faz parte de uma seqüência de estudos realizados pelo Instituto de Engenharia Biomédica, na Universidade Federal de Santa Catarina, relacionados ao desenvolvimento de técnicas computacionais para processamento dos sinais eletroencefalográficos (EEG). Este processo computacional baseia-se em Redes Neurais Artificiais (RNA's) e especificamente, no caso deste estudo, tem como finalidade a detecção de eventos epileptogênicos. O foco desta análise encontra-se no pré-processamento na entrada das RNA's. Deseja-se avaliar os diversos tipos de pré-processamentos matemáticos utilizados para este tipo de sinal. É, também, questionada qual a melhor opção para a entrada destes sinais na rede, com ou sem pré-processamento. Os métodos de pré-processamento analisados consistiram: 1) no espectro de frequências obtido pela transformada rápida de Fourier com janela de Kaiser, 2) no plano tempo-frequência derivado da transformada de Fourier de curto termo na forma do espectrograma, 3) na transformada *wavelet* e 4) no método de extração de características, que destaca as características morfológicas dos sinais e os valores estatísticos a eles relacionados.

Os sinais do EEG dispostos em um banco de dados foram divididos em trechos de um segundo, constituindo os conjuntos de treinamento e teste, e posicionados nas entradas das RNA's. Os pré-processamentos foram desenvolvidos com o intuito de tratar estes sinais de forma que ressaltassem as características dos eventos epileptogênicos das características dos principais eventos que possam estar juntamente presentes. Várias RNA's foram implementadas para cada tipo de pré-processamento e também para o caso de sinais sem pré-processamento.

O pré-processamento utilizando-se o espectro de frequências necessitou de avaliar uma janela adequada para o sinal de EEG contendo evento epileptogênico. O pré-processamento utilizando-se o espectrograma necessitou analisar as diversas possibilidades para a entrada da rede, derivadas do plano tempo-frequência. A transformada *wavelet* exigiu um estudo diferenciado dos principais eventos presentes nos sinais de entrada das RNA's, para cada nível de decomposição *wavelet*. O método da extração de características com entradas parametrizadas gerou estudos adicionais das características morfológicas dos sinais de EEG contendo evento epileptogênico e dos principais eventos que possam estar juntamente presentes no sinal, como as ondas alfa e piscadas. Foram propostos vários parâmetros para as entradas das RNA's.

As redes foram desenvolvidas com a mesma arquitetura, possibilitando-se uma avaliação e comparação entre seus resultados. As redes com entradas sem pré-processamento apresentaram valores indefinidos elevados, sensibilidade de cerca de 85%, especificidade de 75% e taxa de acertos em torno de 67%. As redes com entradas geradas pelo espectro de frequências e pelo plano tempo-frequência obtiveram cerca de 80% de acertos, sua sensibilidade e especificidade foram em torno de 80% a 90%. As redes com entradas dos sinais tratados pela transformada *wavelet* obtiveram cerca de 80% de acertos, taxa de sensibilidade em torno de 95% e especificidade de 70%. E, as redes com entradas relacionadas ao método paramétrico obtiveram cerca de 90% de acertos, taxa de sensibilidade e especificidade girando em torno de 90%.

Palavras-chave: Sinais do EEG, eventos epileptogênicos, Pré-Processamento, Redes Neurais Artificiais.

Abstract

The evaluation developed in this work is part of the sequence of study accomplished by the Biomedical Engineering Institute, in federal university of Santa Catarina, related to the development of computational techniques for electroencephalographic (EEG) signals processing. This computational process consists of Artificial Neural Networks (ANN's), and specifically, in the case of this study, has as purpose the detection of epileptogenic events. The goal of this analysis is the pre-processing of the ANN input. It is desired to evaluate the several types of mathematical pre-processing used for this kind of signal. It is, also, questioned which is the best option for the input of these signals in the net, with or without pre-processing. The investigated pre-processing methods consisted of: 1) in the frequencies spectrum obtained for the fast Fourier's transform with Kaiser's window, 2) in the time-frequency plan derived of the short time Fourier's transforms in the form of the spectrogram, 3) in the wavelet transform and 4) in the method of extraction of characteristics, that emphasizes the morphologic characteristics of the signals and statistical values related to them.

The EEG signals disposed in a database were divided in periods of one second, constituting the training and test groups, and were presented directly in the ANN's inputs. The pre-processings were developed with the intention of treating these EEG signals in order to highlight the characteristics of the epileptogenic events among the characteristics of the principal events that can be present together. Several ANN's were implemented for each pre-processing type and also for the case of signals without pre-processing.

The pre-processing using the frequencies spectrum needed to evaluate an appropriate window for the EEG signal containing epileptogenic event. The pre-processing by using the spectrogram needed to analyze the several possibilities for the input of the net derived of the time-frequency plan. The wavelet transform demanded a differentiated study of the principal present events in the signals of input of the ANN's, for each wavelet decomposition level. The method of the extraction of characteristics with input parametric generated additional studies of the morphologic characteristics of the EEG signals containing epileptogenic event and of the morphologic characteristics of the principal events that can be present together in the signal, as the alpha waves and blinked. Several parameters were proposed for the input of ANN's.

These nets were developed with the same architecture, making possible an evaluation and comparison among their results. The nets with inputs without pre-processing have presented indefinite high values, with a rate around 67% and sensibility and specificity rates about 85% and 75%, respectively. The inputs of the net treated by the frequencies spectrum and time-frequency plan have obtained about 80% of success, its sensibility and specificity were around 80% to 90%. The inputs of the net treated by wavelet transform obtained about 80% of success, its sensibility around 95% and specificity around 70%. The method of the extraction of characteristics obtained about 90% of success, the sensibility and specificity rates were around 90%.

Word-key: EEG Signals, Epileptogenics Events, Pre-Processing, Artificial Neural Networks.

Sumário

Agradecimentos.....	III
Resumo	IV
Abstract.....	VI
Sumário	VIII
Lista de Figuras.....	XIV
Lista de Tabelas.....	XXII
Glossário.....	XXVIII

Estado da Arte.....	1
----------------------------	----------

Capítulo 1

1. Base de Dados.....	5
1.1. Principais Características dos Sinais do EEG Contendo Eventos Epileptogênicos	5
1.2. Banco de Dados	7
1.3. Considerações Finais do Capítulo.....	10

Capítulo 2

2. Rede Neural Artificial.....	11
2.1 Síntese dos Principais Fundamentos Teóricos Relacionados às RNA's	12
2.2 Redes Neurais Artificiais Propostas Neste Trabalho	16
2.3 Arquivos de Treinamento e Teste	20
2.4 Método de Avaliação dos Resultados das Redes.....	23
2.5 Síntese da Configuração das Redes	25
2.6 Considerações Finais do Capítulo	26

Capítulo 3

3. RNA's com Entradas sem Pré-Processamento	27
3.1 Entradas e Saídas das Redes	27
3.2 Treinamento e Testes	30
3.2.1 RNA sem caracterização prévia dos sinais de entrada	30
3.2.2 RNA com caracterização prévia dos sinais de entrada	32
3.3 Resultados e a Análise dos Resultados	32
3.3.1 Resultados das redes sem caracterização dos sinais de entrada	33
3.3.2 Resultados das redes com caracterização dos sinais de entrada	37
3.4 Conclusões e Discussões	40

Capítulo 4

4. RNA's com Entradas Pré-Processadas pela FFT Utilizando-se

Janelas	45
4.1 As Representações de Fourier	47
4.1.1 Representação da Transformada de Fourier na Forma Discreta.....	47
4.1.2 Representação utilizando a transformada rápida de Fourier.....	48
4.1.3 Representação no domínio da frequência utilizando a densidade espectral de potência	49
4.2 A Representação da Transformada de Fourier Utilizando Janela	50
4.2.1 As janelas clássicas	51
4.2.2 Análise dos lóbulos laterais e do lóbulo principal das janelas clássicas.....	52
4.3 Definição de uma Janela Adequada para Sinais do EEG Contendo Eventos Epileptogênicos.....	56
4.3.1 Análise da eficiência das janelas clássicas na detecção de frequências conhecidas.....	56
4.3.2 Análise da eficiência das janelas clássicas na detecção de frequências em sinais do EEG contendo um evento epileptogênico.....	59
4.4 Entradas e Saídas das Redes com Pré-Processamento pela Transformada de Fourier Utilizando-se Janelas	64
4.5 Treinamento e Teste	67
4.6 Resultados e Análise dos Resultados.....	67

4.6.1	RNA sem caracterização prévia dos sinais de entrada	68
4.6.2	Resultados das Redes com Caracterização Prévia dos Sinais de Entrada	70
4.7	Conclusões e Discussões	72

Capítulo 5

5. RNA's com Entradas Pré-Processadas Utilizando-se a Análise

Tempo-Frequência.....	75
5.1 Transformada de Fourier de Curto Termo	77
5.1.1 Dimensões da janela no tempo	77
5.1.2 Plano tempo-frequência	78
5.1.3 Representação complexa do espectrograma	79
5.2 Definições de uma Janela Adequada para o EEG	82
5.3 Entrada e Saída das Redes	87
5.4 Treinamento e Teste das RNA's com Entradas Pré-processadas Utilizando a Análise Tempo-Frequência	91
5.5 Resultados e Análise dos Resultados	93
5.5.1 RNA sem caracterização prévia dos sinais de entrada	93
5.5.2 RNA com caracterização prévia dos sinais de entrada	96
5.6 Conclusões e Discussões	97

Capítulo 6

6. RNA's com Entradas Pré-Processadas Utilizando-se a

Transformada <i>Wavelet</i>.....	89
6.1 A Transformada <i>Wavelet</i>	100
6.1.1 Formalizações para a transformada <i>wavelet</i>	102
6.1.2 Função <i>wavelet</i> base	104
6.1.3 A transformada <i>wavelet</i> rápida	105
6.1.4 Escolha da função <i>wavelet</i> básica	106
6.2 Entradas e Saídas das Redes com Entradas Pré-Processadas pela Transformada <i>Wavelet</i>	110
6.2.1 Rede geral com entradas pré-processadas pela FWT	115
6.2.2 Redes individuais com entradas pré-processadas pela FWT.....	116

6.3 Treinamento e Teste	117
6.3.1 Base de regras para os resultados das RNA's individuais	120
6.4 Resultados e Análise dos Resultados Utilizando-se RNA's com Entradas Pré-Processadas pela Transformada <i>Wavelet</i>	122
6.4.1 Resultados obtidos pela rede geral com entradas pré-processadas pela FWT	123
6.4.2 Resultados obtidos pelas redes individuais com entradas Pré-Processadas pela FWT.....	125
6.5 Conclusões e Discussões	128

Capítulo 7

7. RNA's com Entradas Parametrizadas.....	131
7.1 Trabalhos Relacionados a Parametrização dos Sinais do EEG com Eventos Epileptogênicos.....	131
7.2 Parâmetros Propostos Neste Trabalho	135
7.2.1 Parâmetros relacionados às amplitudes máxima e mínima	136
7.2.2 Parâmetro relacionado à duração do evento	140
7.2.3 Parâmetros relacionados ao ângulo de vértice	141
7.2.4 Parâmetros relacionados à distância entre pontos de máximo.....	143
7.2.5 Parâmetros relacionados a dados estatísticos	146
7.2.6 Parâmetros relacionados à entropia	146
7.3 Matriz Total dos Parâmetros.....	147
7.3.1 Análise preliminar dos parâmetros	148
7.4 Número adequado de parâmetros na entrada da RNA.....	151
7.5 Entradas e saídas das redes	154
7.6 Treinamento e Teste	154
7.7 Resultados e Análise dos Resultados.....	156
7.7.1 RNA sem caracterização prévia dos sinais de entrada	156
7.7.2 RNA com caracterização prévia dos sinais de entrada	158
7.8 Conclusões e Discussões	161

Capítulo 8

8. Conclusões e Contribuições deste Trabalho163

8.1 Conclusões 163

Capítulo 9

9. Sugestões para Trabalhos Futuros170

Anexo A

Tabelas Contendo os Arquivos de Treinamento e Teste.....172

Anexo B

Gráficos Obtidos no Treinamento das RNA's.....178

B.1. RNA's com Entradas Sem Pré-Processamento 178

B.2. RNA's com Entradas Pré-Processadas pela FFT com Janelas 179

B.3. RNA's com Entradas Pré-Processadas Utilizando a Análise Tempo-Frequência 180

B.4. RNA's com Entradas Pré-Processadas Utilizando a Transformada *Wavelet* 181

B.5. RNA's com Entradas Parametrizadas 183

Anexo C

Formulações Matemáticas.....184

C.1. As Representações de Fourier 184

C.2. As Representações das Janelas Clássicas 187

C.3. Densidade Espectral de Potência (*Power Spectral Density* (PSD)) 191

C.4. Princípio da Incerteza 192

C.5. Transformada de Fourier de Curto Termo 193

C.6. Transformada *Wavelet* 198

Anexo D

Formulações Estatísticas.....	205
D.1. Média, Correlação e Covariância	205
D.2. Teste Estatístico T^2 Aplicado à Definição de uma Janela Adequada	207
D.3. Teste Estatístico- T^2 Aplicado à Definição dos Parâmetros Adequados	209

Anexo E

Testes Utilizados na Definição de uma Janela Adequada.....	211
E.1. Testes para a Detecção de Frequências Conhecidas nos Sinais Senoidais	211
E.2. Espectros dos Sinais do EEG com o Evento Epileptogênico	215

Anexo F

Bases <i>Wavelets</i>	219
------------------------------------	------------

Anexo G

Parâmetros	228
G.1. Principais Parâmetros	228
G.2. Resultados da Correlação entre Parâmetros e Teste T^2	234

Anexo H

Algoritmo para Cálculo dos Parâmetros.....	238
---	------------

Referências Bibliográficas	247
---	------------

Lista de Figuras

Figura	Título	Página
Figura 1.1	Propostas para a análise de sinais do EEG contendo eventos epileptogênicos, segundo o tipo de entrada da RNA.	3
Figura 1.2	Seqüências de múltiplas espículas obtidas de um paciente adormecido [19].	6
Figura 1.3	Eventos Epileptogênicos: Em (a) espícula, em (b), onda aguda.	6
Figura 1.4	Tipo de montagem zigomática-temporal bipolar com 25 eletrodos arranjados em 32 canais. Os números ao lado das setas identificam as derivações bipolares. Os eletrodos Zg_1 e Zg_2 são posicionados nos maxilares.	8
Figura 1.5	Tela de um dos arquivos dos sinais do EEG, apresentando os 32 canais de 15 segundos.	9
Figura 1.6	Sinal do EEG do registro de St_Rock contendo o evento epileptogênico, arquivo Sr_945, referente ao canal 5 (Zy2-T4). Em (a), trecho completo de 15 segundos com espícula entre os pontos 1200 e 1300 e, em (b), época de 1 segundo (100 pontos) contendo espícula ao centro.	10
Figura 2.1	Grafo das redes propostas.	13
Figura 2.2	Elementos básicos de um neurônio artificial [34].	13
Figura 2.3	Evento epileptogênico juntamente com piscadas.	19
Figura 2.4	Em (a), a representação de um trecho de 1 segundo contendo uma espícula (entre os pontos 40 a 60). Em (b), a representação do trecho de 1 segundo contendo uma piscada (entre os pontos 50 a 70).	21
Figura 2.5	Morfologia dos eventos encontrados nos sinais do EEG, que podem aparecer juntamente com os eventos epileptogênicos. Em (a), uma atividade de fundo do sinal do EEG. Em (b), ondas alfa. Em (c), uma forma de piscada. Em (d), ruídos que podem ser de origem: muscular, em interferência eletromagnética no equipamento, etc.	22
Figura 2.6	Padrões apresentados por eventos epileptogênicos. Em (a), evento com parte positiva e negativa com o pico positivo aparecendo primeiro. Em (b), evento com parte negativa e positiva com pico negativo aparecendo primeiro. Em (c), evento com pico negativo e ondas positivas de baixa amplitude. Em (d), evento com pico positivo e ondas negativas de baixa amplitude.	22
Figura 2.7	Propostas deste trabalho para o sistema de redes.	26

Figura 3.1	Amostra de um trecho de 1 segundo, 100 pontos, de um registro contendo evento epileptogênico.	28
Figura 3.2	Amostra de um trecho de 1 segundo, 100 pontos, de um registro contendo piscada.	28
Figura 3.3	Amostra de um trecho de 1 segundo, 100 pontos, de um registro contendo EEG normal de fundo.	28
Figura 3.4	Amostra de um trecho de 1 segundo, 100 pontos, de um registro contendo ondas alfa.	29
Figura 3.5	Amostra de um trecho de 1 segundo, 100 pontos, de um registro contendo ruído.	29
Figura 3.6	Esquema simplificado de uma rede com sinais sem pré-processamento em suas entradas.	30
Figura 3.7	Desenvolvimento das RNA's para sinais sem pré-processamento.	31
Figura 3.8	Resultados fornecidos por algoritmo <i>Matlab</i> durante o treinamento de duas RNA's, usando os mesmos sinais em suas entradas. Em (a), resultados com entradas não-normalizadas. Em (b), resultados com entradas normalizadas.	35
Figura 3.9	Sinais encontrados nos registros do EEG que podem estar juntamente presentes com um evento epileptogênico. Em (a), sinal com um evento epileptogênico. Em (b), sinal com ruídos, cuja morfologia pode ser confundida com a forma espicular. Em (c), uma piscada cuja morfologia pode ser confundida com a morfologia de um evento epileptogênico.	42
Figura 3.10	Ondas alfa encontradas nos registros do EEG que podem estar presentes juntamente com um evento epileptogênico. Em (a), sinal com evento epileptogênico de amplitude reduzida. Em (b), sinal com ondas alfa cuja morfologia pode ser confundidas com a morfologia do evento epileptogênico.	43
Figura 3.11	Em (a), trecho de 15 segundos de um sinal do EEG contendo eventos epileptogênicos. Em (b) trechos de 15 segundos de sinais do EEG contendo o EEG normal de fundo. As dimensões reduzidas dos eventos epileptogênicos podem fazer com que estes eventos sejam confundidos com sinais normais do EEG de fundo.	44
Figura 3.12	Sugestão para o uso de redes neurais para identificar os eventos epileptogênicos tendo como entradas os trechos dos sinais do EEG sem pré-processamento.	44
Figura 4.1	Organização usada na classificação de sinais, destacando-se a posição do sinal estocástico não estacionário, por representar a linha de características dos sinais do EEG, [52].	45
Figura 4.2	Uma janela típica no domínio da frequência.	50

Figura 4.3	Em (a), representações no domínio da frequência para a janela de Chebyshev, de diferentes variáveis α ($\alpha = 20, 40, 60$). Em (b), representações para a Janela de Kaiser, de diferentes variáveis β ($\beta = 1, 4, 9$).	53
Figura 4.4	Representação em frequência das janelas retangular, triangular, Hamming, Hanning, Blackman, Chebyshev e Kaiser.	54
Figura 4.5	Respostas em frequência das janelas de Kaiser e de Chebyshev. Em (a), os níveis dos primeiros lóbulos laterais são iguais para ambas as janelas. Em (b), as larguras dos lóbulos principais são iguais para ambas as janelas.	55
Figura 4.6	Uso de uma janela de Hamming para detectar a frequência da ordem de grandeza das encontradas no sinal do EEG com evento epileptogênico, isto é, 2; 2,5; 3; 6; 10 e 20 Hz. Em (a), uma janela de 256 pontos, em (b), a janela de 512 pontos, em (c), a janela de 1024 pontos.	57
Figura 4.7	Em (a), sinal senoidal composto de frequências iguais a 20, 10 e 5 Hz. Em (b), resultado do uso das janelas clássicas para identificar as frequências deste sinal.	57
Figura 4.8	Espectro de frequências de um sinal formado pela soma de senóides, uma com amplitude 1 e frequência de 2 Hz e outra de amplitude 0,2 e frequência de 20 Hz.	58
Figura 4.9	Espectros de frequências de 10 e 20 Hz, obtidos com janelas de 256, 512 e 1024 pontos, respectivamente, de cima para baixo. Em (a), visualiza os espectros gerados por uma janela de Kaiser ($\beta=0.5$). Em (b), os espectros gerados por uma janela de Chebyshev ($\alpha=10$).	59
Figura 4.10	Resultados dos espectros de um sinal do EEG. Em (a), utiliza-se uma janela de Chebyshev ($\alpha = 10, 20, 40$ e 60). Em (b), utiliza-se uma janela de Kaiser ($\beta = 0,5, 1, 4$ e 9).	59
Figura 4.11	Sinal dos testes com um evento epileptogênico entre os pontos 800 a 900.	60
Figura 4.12	Espectros do sinal do EEG da Figura 4.16 obtidos a partir das janelas clássicas. As setas indicam diferentes picos para os espectros obtidos pelas diferentes janelas.	60
Figura 4.13	Magnitudes dos pontos representativos das frequências de um espectro para um sinal do EEG contendo evento epileptogênico.	61
Figura 4.14	Registro do EEG com evento epileptogênico e seu respectivo espectro.	64
Figura 4.15	Eventos com seus respectivos espectros. Em (a), registro com EEG de fundo. Em (b), registro com ondas alfa.	65
Figura 4.16	Eventos com seus respectivos espectros. Em (a), registro com piscada. Em (b), registro com ruídos.	65
Figura 4.17	Esquema simplificado de uma rede, tendo como entrada a magnitude dos espectros de trechos de sinais do EEG.	66
Figura 4.18	Desenvolvimento das RNA's com entradas baseadas no espectro dos sinais.	67

Figura 4.19	Sugestão para o uso de redes neurais tendo como entrada a magnitude dos espectros de trechos de sinais do EEG.	74
Figura 5.1	Reticulado do plano tempo e frequência com uma repartição uniforme para o tempo (t) e para a frequência (w).	78
Figura 5.2	Modelo de um neurônio usado no algoritmo <i>Backpropagation</i> de valores complexos. X_m , Y_n , V_n , W_{nm} , z e $f_c(z)$ são todos números complexos.	79
Figura 5.3	Decomposição do sinal resultante da soma de três senóides com frequências de 5, 10 e 15 Hz, destacadas pelas faixas vermelhas. Em (a), o sinal e seu correspondente espectro de frequências. Foram utilizadas as janelas de Kaiser de 1024, 128, 64 e 32 pontos, em (b), (c), (d) e (e), respectivamente.	82
Figura 5.4	Em (a), decomposição de um sinal senoidal com frequências de 5, 10 e 15 Hz variando ao longo do tempo. (b) utiliza-se uma janela de Kaiser de 32 pontos. (c) utiliza-se uma janela de Kaiser de 32 pontos e valor de Dt maior do que em (b). (d) utiliza-se uma janela de Kaiser de 64 pontos. (e) utiliza-se uma janela de Kaiser de 128 pontos.	83
Figura 5.5	Em (a), decomposição do sinal com frequências de 5, 10 e 15 Hz usando a janela de Kaiser. Em (b), uma janela de 512 pontos; em (c), uma janela de 64 pontos e Dt maiores do que em (d); em (e) uma janela de 32 pontos e Dt maiores do que em (f).	84
Figura 5.6	Espectrograma de dois sinais contendo eventos epileptogênicos, mostrados em (a). Em (b) e em (c) utiliza-se uma janela de Kaiser de 32 pontos e com os tamanhos de Dt aumentando de cima para baixo. Em (d) espectrogramas obtidos com uma janela de Kaiser de 64 pontos.	85
Figura 5.7	Espectrograma de dois sinais contendo eventos epileptogênicos, mostrados em (a). Em (b), resultados utilizando uma janela de Chebyshev de 32 pontos.	86
Figura 5.8	Proposta para a configuração da rede cujas entradas encontra-se o espectrograma dos trechos dos sinais do EEG.	87
Figura 5.9	Registro do EEG com evento epileptogênico e seu respectivo espectrograma típico obtido utilizando-se a janela de Kaiser.	88
Figura 5.10	Registro do EEG com ondas alfa e seu respectivo espectrograma típico obtido utilizando-se a janela de Kaiser.	89
Figura 5.11	Registro do EEG de fundo e seu respectivo espectrograma típico obtido utilizando-se a janela de Kaiser.	89
Figura 5.12	Registro do EEG com piscada e seu respectivo espectrograma típico obtido utilizando-se a janela de Kaiser.	90

Figura 5.13	Registro do EEG com ruído e seu respectivo espectrograma típico obtido utilizando-se a janela de Kaiser.	90
Figura 5.14	Desenvolvimento das RNA's com entradas baseadas nos valores dos espectrogramas dos sinais.	92
Figura 6.1	Em (a), representação do reticulado do plano tempo-freqüência da STFT. Em (b), representação tempo-escala (escalograma) da transformada de <i>wavelet</i> contínua.	101
Figura 6.2	Escala de funções. Em (a), $a < 1$, a função <i>wavelet</i> é contraída. Em (b), $a = 1$. Em (c), $a > 1$, a função <i>wavelet</i> é dilatada.	103
Figura 6.3	Funções Gaussianas de Gabor.	104
Figura 6.4	Processo de filtragem empregado na FWT, originando os níveis de <i>Aproximação</i> (<i>A</i>) e <i>Detalhe</i> (<i>D</i>), [91].	106
Figura 6.5	Árvore de decomposição para três níveis. Em cada nível são utilizados filtros passa-baixas obtendo as <i>Aproximações</i> (A_n) e filtros passa-altas obtendo os <i>Detalhes</i> (D_n), [91].	106
Figura 6.6	Proposta da análise dos sinais do EEG para identificar as espículas [1].	109
Figura 6.7	Eventos epileptogênicos com o primeiro pico positivo e com o primeiro pico negativo, respectivamente em (a.1 e a.2). As correspondentes <i>wavelets</i> calculadas com detalhe 2, em (b.1 e b.2) e, calculadas com detalhe 3, em (c.1 e c.2).	110
Figura 6.8	Eventos epileptogênicos de pico com polaridade negativa e positiva, respectivamente em (a.1 e a.2). As correspondentes <i>wavelets</i> calculadas com detalhe 2, em (b.1 e b.2) e, calculadas com detalhe 3 em (c.1 e c.2).	111
Figura 6.9	Em (a.1 e a.2) são mostrados sinais do EEG de fundo obtidos em dois trechos de 100 pontos dos registros. Em (b.1 e b.2), são mostradas suas respectivas <i>wavelets</i> , calculadas com detalhe 3.	112
Figura 6.10	Em (a) é mostrado um trecho do sinal do EEG contendo ondas alfa. Em (b), é mostrada sua respectiva <i>wavelet</i> calculada com detalhe 2. Em (c), mostra sua <i>wavelet</i> calculada com detalhe 3.	112
Figura 6.11	Em (a.1 e a.2), encontram-se dois trechos dos sinais do EEG contendo piscada. Em (b.1 e b.2), suas respectivas <i>wavelets</i> calculadas com detalhe 2. Em (c.1 e c.2), suas <i>wavelets</i> calculadas com detalhe 3.	113
Figura 6.12	Em (a.1 e a.2), dois trechos dos sinais do EEG contendo ruídos. Em (b.1 e b.2), suas respectivas <i>wavelets</i> calculadas com detalhe 1. Em (c.1 e c.2), suas <i>wavelets</i> calculadas com detalhe 2. Em (d.1 e d.2), suas <i>wavelets</i> calculadas com detalhe 3.	114

Figura 6.13	Em (a.1 e a.2), um trecho dos sinais do EEG contendo evento epileptogênico e sua respectiva FWT. Em (b.1 e b.2), um trecho do sinal contendo piscada e sua respectiva FWT. Em ambos os casos foi usada a função Coiflet 1 com detalhe 3.	115
Figura 6.14	Esquema simplificado das redes tendo como entradas os resultados do processamento dos sinais do EEG pela função Coiflet 1 detalhe 2 e 3.	115
Figura 6.15	Esquema proposto formado por várias redes, que fornecem informações para uma base de regras destinada a identificar os eventos epileptogênicos.	117
Figura 6.16	Esquema para o desenvolvimento da RNA para identificar os eventos Epileptogênicos em trechos dos sinais EEG pré-processados pela Transformada Wavelet usando a função Coiflet 1 e os níveis de decomposição 2 e 3.	118
Figura 6.17	Esquema para o desenvolvimento das redes individuais para identificar os eventos epileptogênicos, piscadas, ruídos e ondas alfa.	119
Figura 7.1	Características básicas apresentadas por um evento epileptogênico.	137
Figura 7.2	Sinais do EEG, contendo o evento epileptogênico e apresentando um ponto de máximo correspondente ao evento e um ponto de mínimo relativo a outros eventos, que não seja a espícula.	137
Figura 7.3	Amplitude máxima (A_{max_pts}) e mínima (B_{min_pts}) para o trecho correspondente a 15 pontos anteriores e 15 pontos posteriores ao pico da espícula.	139
Figura 7.4	Parâmetros obtidos no trecho correspondente aos 15 pontos posteriores e 15 pontos anteriores ao ponto de máximo do sinal do EEG, destacando-se a diferença entre os pontos de ocorrência de máximo e mínimo do evento (T_{dif_pts}) e a diferença de amplitude entre estes pontos ($DifAB_pts$).	140
Figura 7.5	Duração do evento epileptogênico (T) considerando suas 4 formas básicas.	140
Figura 7.6	Referências para os ângulos dos sinais: (a) um evento epileptogênico e (b) uma piscada.	141
Figura 7.7	Ângulo dos vértices positivo e negativo de um evento epileptogênico, calculados a partir das amplitudes máxima e mínima. Em (a) e (b), evento epileptogênico pertencente ao conjunto das ondas agudas e espículas, respectivamente.	142
Figura 7.8	Distâncias entre os pontos de máximo positivos e negativos subsequentes e as respectivas diferenças em amplitudes. Em (a), trecho contendo um evento epileptogênico. Em (b), trecho contendo os ruídos.	144
Figura 7.9	Trechos de 1 segundo contendo o EEG de fundo, em (a), e ondas alfa, em (b).	145
Figura 7.10	Esquema simplificado de uma rede tendo como entrada os parâmetros característicos dos trechos dos sinais do EEG.	154

Figura 7.11	Desenvolvimento das RNA's com entradas parametrizadas segundo as características dos eventos contidos nos sinais.	155
Figura 8.1	Esquema simplificado do estudo desenvolvido neste trabalho.	166
Figura 8.2	Esquema simplificado da implementação de uma avaliação de padrões antes do pré-processamento e da análise pela RNA.	167
Figura 8.3	Esquema simplificado da implementação de uma avaliação de limiar após o pré-processamento e antes da análise pela RNA.	168
Figura 9.1	Propostas para análise de sinais do EEG contendo eventos epileptogênicos, utilizando várias RNA's e pré-processamentos sugeridos.	171
Figura B.1.1	(a), resultados do treinamento da RNA com 11 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada. (b), resultados do treinamento da RNA com 13 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada e entrada normalizada. (c), resultados do treinamento da RNA com 12 neurônios na camada oculta e com caracterização prévia dos sinais de entrada. (d), resultados do treinamento da RNA com 12 neurônios na camada oculta, com caracterização prévia dos sinais de entrada e entrada normalizada por amplitude máxima de um evento epileptogênico.	182
Figura B.2.1	(a), resultados do treinamento da RNA com 13 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada. (b) RNA com 13 neurônios na camada oculta, sem caracterização prévia dos sinais de entrada e entrada normalizada. (c), RNA com 12 neurônios na camada oculta e com caracterização prévia dos sinais de entrada. (d), RNA com 12 neurônios na camada oculta, com caracterização prévia dos sinais de entrada e entrada normalizada.	183
Figura B.3.1	Resultados do treinamento da RNA com 31 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada.	184
Figura B.3.2	Resultados do treinamento da RNA com 28 neurônios na camada oculta e com caracterização prévia dos sinais de entrada.	184
Figura B.4.1	(a), Resultados do treinamento da RNA 1 com 12 neurônios na camada oculta e com caracterização prévia dos sinais de entrada. (b), RNA 2. (c), RNA 3. (d), RNA 4. (e), RNA 5.	185
Figura B.4.2	(a), Resultados do treinamento da RNA 1 com 12 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada. (b), RNA 2. (c), RNA 3. (d), RNA 4. (e) RNA 5.	186

Figura B.5.1	(a), Resultados do treinamento da RNA com 8 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada. (b), RNA com 8 neurônios na camada oculta, entrada normalizada e sem caracterização prévia dos sinais de entrada. (c), RNA com 9 neurônios na camada oculta e com caracterização prévia dos sinais de entrada. (d), RNA com 8 neurônios na camada oculta e com caracterização prévia dos sinais de entrada.	187
Figura C.1.1	Uma célula <i>butterfly</i> e sua relação matemática	186
Figura C.1.2	Arranjo de duas <i>butterflies</i> e suas relações matemáticas.	187
Figura C.1.3	Reticulado do plano tempo e frequência, mostrando uma repartição uniforme para o tempo (t) e a frequência (w).	196
Figura C.1.4	Resolução no plano tempo-frequência para a Transformada <i>Wavelet</i> .	200
Figura D.1	Representação das coordenadas da matriz randômica no espaço n-dimensional.	205
Figura F.1	Função Gaussiana base de Morlet.	219
Figura F.2	<i>Wavelet</i> chapéu-mexicano.	219
Figura F.3	<i>Wavelet</i> de Haar.	220
Figura F.4	Família de <i>wavelet</i> de Daubechies. Considera db1 igual a <i>wavelet</i> de Haar [90].	221
Figura F.5	Famílias de <i>wavelet</i> biortogonal [91].	222
Figura F.6	Famílias de <i>wavelet Coiflets</i> [91].	223
Figura F.7	Famílias de <i>wavelet Symlets</i> [91].	223
Figura H.1	Duração do evento epileptogênico (T) considerando as suas 4 morfologias básicas.	240

Lista de Tabelas

Tabela	Título	Página
Tabela 1.1	Síntese do banco de dados com seus respectivos arquivos	8
Tabela 2.1	Resultados obtidos pela rede com entrada sem pré-processamento dos sinais.	25
Tabela 3.1	Avaliação da eficiência das redes sem pré-processamento através dos números de acertos, valores indefinidos, verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN), segundo os 53 sinais de teste.	34
Tabela 3.2	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais da Tabela 3.1.	35
Tabela 3.3	Avaliação da eficiência das redes sem caracterização prévia dos sinais de entrada através dos números de acertos, verdadeiros positivos (VP) e negativos (VN) e falsos positivos (FP) e negativos (FN). Foram utilizados 58 sinais de teste, isto é, 30 sinais com eventos epileptogênicos e 28 sinais com os eventos não-epileptogênicos, incluindo os 5 sinais com piscadas.	36
Tabela 3.4	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as redes neurais sem caracterização prévia dos sinais de entrada. Foram utilizados os 58 sinais de teste.	37
Tabela 3.5	Avaliação da eficiência das redes através do número de acertos, valores indefinidos, verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN), com entradas sem pré-processamento e com caracterização prévia dos sinais de entrada, segundo os 45 sinais de teste.	38
Tabela 3.6	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as redes neurais treinadas com caracterização prévia dos sinais de entrada.	39
Tabela 3.7	Melhores resultados, quanto a porcentagem de acertos, número de verdadeiros positivos e negativos e número de falsos positivos e negativos, fornecidos pelas redes treinadas com sinais sem pré-processamento.	40
Tabela 3.8	Melhores resultados, quanto a sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, fornecidos pelas redes treinadas com sinais sem pré-processamento.	41
Tabela 4.1	Resultados da análise das distâncias e magnitudes dos pontos do espectro, aplicadas aos espectros obtidos pelas janelas clássicas, em 9 trechos de sinais do EEG.	62

Tabela 4.2	Valores estatísticos básicos relacionados às magnitudes do espectro (dB) obtidos com o uso das janelas clássicas no tratamento do sinal do EEG mostrado na Figura 4.11.	63
Tabela 4.3	Resultados do teste T^2 aplicado nas diferenças entre as magnitudes dos espectros fornecidos por duas janelas clássicas.	63
Tabela 4.4	Resultados quanto aos números de acertos, valores indefinidos, verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN), obtidos pelas redes sem caracterização prévia dos sinais de entrada.	68
Tabela 4.5	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais sem caracterização prévia dos sinais de entrada.	69
Tabela 4.6	Resultados obtidos pelas redes com os 58 espectros de sinais de teste, sendo 30 espectros de sinais com eventos epileptogênicos e 23 espectros de sinais com eventos não-epileptogênicos e 5 espectros de trechos com piscadas.	70
Tabela 4.7	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais definidas na Tabela 4.6.	70
Tabela 4.8	Resultados obtidos pelas redes com os 45 espectros de sinais de teste, isto é, 20 espectros de sinais com eventos epileptogênicos e 25 espectros de sinais com os eventos não-epileptogênicos, com características previamente definidas.	71
Tabela 4.9	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais definidas na Tabela 4.8.	71
Tabela 4.10	Melhores resultados das redes treinadas com sinais pré-processados pelo espectro obtido pela FFT utilizando-se a janela de Kaiser.	72
Tabela 4.11	Melhores resultados referentes aos valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais definidas na Tabela 4.10.	73
Tabela 5.1	Avaliação da eficiência das redes através dos números de acertos, valores indefinidos, verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN), com entradas pré-processadas e sem caracterização prévia dos sinais.	93
Tabela 5.2	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo obtidos pelas mesmas redes da Tabela 5.1.	94
Tabela 5.3	Resultados obtidos pelas redes sem caracterização prévia dos sinais de entrada.	94
Tabela 5.4	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo obtidos utilizando-se as mesmas redes da Tabela 5.3.	95

Tabela 5.5	Resultados obtidos pelas redes com caracterização prévia dos sinais de entrada.	96
Tabela 5.6	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, obtidos utilizando-se as mesmas redes da Tabela 5.5.	96
Tabela 5.7	Resumo dos melhores resultados obtidos pelas redes considerando-se os valores dos espectrogramas como entradas.	97
Tabela 5.8	Valores de sensibilidade, especificidade, valor preditivo positivo (VPP) e valor preditivo negativo (VPN), utilizando-se as redes da Tabela 5.7.	97
Tabela 6.1	Resultados obtidos pelas redes treinadas utilizando-se a FWT, função Coiflet 1 e detalhes 2 e 3, quanto aos números de acertos, valores indefinidos, verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN) .	123
Tabela 6.2	Resultados da sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo utilizando-se as redes para obter os resultados da Tabela 6.1.	124
Tabela 6.3	Resultados obtidos pelas redes treinadas com a FWT, com função Coiflet 1 de detalhes 2 e 3.	124
Tabela 6.4	Resultados da sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo utilizando-se as redes para obter a Tabela 6.3	125
Tabela 6.5	Resultados obtidos na aplicação da base de regras às saídas das redes individuais treinadas com a FWT, de função Coiflet 1 e detalhes definidos conforme o evento a ser detectado.	126
Tabela 6.6	Resultados da sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo utilizando-se as redes para obter os resultados da Tabela 6.5.	126
Tabela 6.7	Resultados obtidos na aplicação da base de regras às saídas obtidas pelas redes individuais treinadas conforme o conjunto da Figura 6.17.	127
Tabela 6.8	Resultados referentes a sensibilidade, a especificidade, ao valor preditivo positivo e ao valor preditivo negativo utilizando-se as redes para obter os resultados da Tabela 6.7.	128
Tabela 6.9	Melhores resultados considerando as entradas das redes pré-processadas utilizando-se a FWT.	129
Tabela 6.10	Melhores resultados referentes a sensibilidade, a especificidade, ao valor preditivo positivo e ao valor preditivo negativo utilizando-se as redes para obter os resultados da Tabela 6.9.	129
Tabela 7.1	Parâmetros obtidos no trecho correspondente a 1 segundo (100 pontos) de um sinal do EEG, destacando-se a diferença entre os pontos de ocorrência de máximo e mínimo do evento (Tdif).	138

Tabela 7.2	Amplitude máxima e mínima nos trechos correspondentes a 15 pontos anteriores e 15 pontos posteriores ao ponto máximo, destacando-se a diferença entre os pontos de ocorrência de máximo e mínimo do evento (Tdif_pts).	139
Tabela 7.3	Valores médios obtidos para a amplitude máxima (Amax) e mínima (Bmin), distância entre as amplitudes máxima e mínima (Tdif) e a diferença entre as amplitudes máxima e mínima (DifAB).	149
Tabela 7.4	Tempo de duração do evento epileptogênico (T), ângulo de pico do lado positivo (angp) e ângulo de pico do lado negativo (angn).	149
Tabela 7.5	Valores médios referentes ao tempo de duração dos eventos (T), ângulo de pico do lado positivo (angp) e ângulo de pico do lado negativo (angn).	150
Tabela 7.6	Valores médios obtidos do cálculo dos parâmetros estatísticos clássicos e do fator de crista.	150
Tabela 7.7	Resultados gerais da correlação e do teste estatístico T^2 . O valor 1 é favorável à utilização do parâmetro.	153
Tabela 7.8	Resultados obtidos pelas redes com 45 parâmetros em suas entradas, que são fornecidos por 53 e 58 (mais 5 piscadas) sinais de teste.	157
Tabela 7.9	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais utilizadas para obter os resultados da Tabela 7.8.	157
Tabela 7.10	Resultados obtidos pelas redes com 40 parâmetros em suas entradas.	158
Tabela 7.11	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais utilizadas na Tabela 7.10.	158
Tabela 7.12	Resultados obtidos pelas redes com 45 parâmetros em suas entradas, fornecidas pelos 45 sinais de teste.	159
Tabela 7.13	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, utilizando-se os resultados obtidos pelas redes neurais da Tabela 7.12.	159
Tabela 7.14	Resultados obtidos pelas redes utilizando-se 40 parâmetros em suas entradas, que são calculados para os 45 sinais de teste.	160
Tabela 7.15	Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais definidas na Tabela 7.14.	160
Tabela 7.16	Melhores resultados obtidos pelas redes utilizando nas entradas os parâmetros obtidos das características dos sinais.	161
Tabela 7.17	Resultados obtidos pelas redes com entradas obtidas dos parâmetros das características dos sinais.	162
Tabela 8.1	Melhores resultados obtidos pelas redes desenvolvidas neste estudo, destacadas pelas formas de pré-processamento dos sinais de entrada.	164

Tabela 8.2	Avaliação da eficiência dos métodos para detecção de espículas realizada e catalogada por Wilson e Emerson [107]. O termo GSD refere-se ao método de Gotman [3].	169
Tabela A.1	Conjunto de treinamento para as RNA's sem caracterização prévia dos sinais de entrada.	172
Tabela A.2	Conjunto de teste para as RNA's sem caracterização prévia dos sinais de entrada.	174
Tabela A.3	Ordem de apresentação dos sinais utilizados nos conjuntos de treinamento e teste das RNA's com caracterização prévia dos sinais de entrada.	175
Tabela A.4	Conjunto de treinamento para as RNA's com caracterização prévia dos sinais de entrada.	176
Tabela A.5	Conjunto de teste para as RNA's com caracterização prévia dos sinais de entrada.	177
Tabela C.1	Seqüência de cálculos para a FFT de 8 termos.	185
Tabela D.1	Distribuição da porcentagem de pontos ($F_{p,n-p}(\alpha) = F_{2,10}(0,05)$, para $\alpha=0,005$ [104].	210
Tabela E.1	Resultados referentes aos testes realizados para detectar as frequências cujos valores são da ordem de grandeza de um sinal do EEG apresentando os eventos epileptogênicos.	212
Tabela E.2	Resultados obtidos pelas janelas de Kaiser ($\beta= 0,5, 1, 4$ e 9) e pelas janelas de Chebyshev ($\alpha=10, 20, 40$ e 60).	213
Tabela E.3	Testes realizados para detectar as frequências da ordem de grandeza de um sinal do EEG apresentando os eventos epileptogênicos e variando ao longo do sinal.	214
Tabela E.4	Valores das magnitudes dos espectros fornecidos por uma janela de Hamming e a distância relativa entre seus pontos.	215
Tabela E.5	Valores das magnitudes dos pontos do espectro fornecidos por uma janela de Kaiser ($\beta=1$) e a distância relativa entre estes pontos.	216
Tabela E.6	Valores das magnitudes dos pontos do espectro fornecidos por uma janela de Chebyshev ($\alpha=20$) e a distância relativa entre estes pontos.	217
Tabela E.7	Resultados obtidos pelas janelas clássicas em 9 trechos dos sinais do EEG.	218
Tabela G.1	Amplitude máxima positiva (Amax) e negativa (Bmin).	224
Tabela G.2	Amplitude máxima positiva (Amax_pts) e negativa (Bmin_pts) destacadas no trecho de 30 pontos centrados no ponto de máximo positivo.	224
Tabela G.3	Diferença (DifAB) e distância (Tdif) entre as amplitudes máximas (positiva e negativa).	225
Tabela G.4	Diferença (DifAB_pts) e distância (Tdif_pts) entre as amplitudes máximas, destacadas no trecho de 30 pontos centrados no ponto de máximo positivo.	225
Tabela G.5	Duração do evento (T) em destaque no trecho em análise.	226

Tabela G.6	Lado oposto do ângulo do vértice positivo (dpos) e negativo (dneg) correspondente ao trecho entre a amplitude máxima e seu extremo.	226
Tabela G.7	Ângulo de vértice do evento em destaque.	227
Tabela G.8	Tangente do ângulo do vértice positivo (tgp) e negativo (tgn) do evento em destaque.	227
Tabela G.9	Distância em pontos (tA _i) e diferença em amplitude (DifA _i) entre o ponto de máximo positivo e um segundo ponto de máximo positivo encontrado na região inicial do trecho considerado.	228
Tabela G.10	Distância em pontos (tB _i) e diferença em amplitude (DifB _i) entre o ponto de máximo negativo e um segundo ponto de máximo negativo encontrado na região inicial do trecho considerado.	228
Tabela G.11	Distância em pontos (tA _f) e diferença em amplitude (DifA _f) entre o ponto de máximo positivo e um segundo ponto de máximo positivo encontrado na região final do trecho considerado.	229
Tabela G.12	Distância em pontos (tB _f) e diferença em amplitude (DifB _f) entre o ponto de máximo negativo e um segundo ponto de máximo negativo encontrado na região final do trecho considerado.	229
Tabela G.13	Desvio padrão calculado para o trecho de 30 pontos (desvio) e de 100 pontos (1 segundo).	230
Tabela G.14	Média calculada para o trecho de 30 pontos (media) e de 100 pontos (1 segundo).	230
Tabela G.15	Coeficiente de variação calculado para o trecho de 30 pontos (coef) e de 100 pontos (1 segundo).	231
Tabela G.16	Variância calculada para o trecho de 30 pontos (vari) e de 100 pontos (1 segundo).	231
Tabela G.17	Fator de crista (CF) calculado para o trecho de 30 pontos e de 100 pontos (1 segundo).	232
Tabela G.18	Entropia (entrop _{log} e entrop _{nor}) calculada para o trecho de 30 pontos.	232
Tabela G.19	Entropia (entrop _{log} e entrop _{nor}) calculada para o trecho de 100 pontos (1 segundo).	233
Tabela G.20	Correlação entre 10 trechos de 100 pontos (1 segundo) de sinais contendo evento epileptogênico e 10 trechos de sinais contendo os demais eventos (ondas alfa, piscadas e ruídos), calculada para os 45 parâmetros propostos.	236
Tabela G.21	Teste estatístico T^2 entre 10 trechos de 100 pontos (1 segundo) de sinais contendo evento epileptogênico e 10 trechos de sinais contendo ondas alfa, piscadas e ruídos. Teste calculado para os 45 parâmetros propostos. Observa-se que o valor obtido deve ser maior do que 9,2250.	237

Glossário

IEB	Instituto de Engenharia Biomédica
RNA	Rede Neural Artificial
EEG	Eletroencefalograma
CEO	Complexo Espícula-Onda.
DFT	Transformada Discreta de Fourier (<i>Discrete Fourier Transform</i> (DFT))
FFT	Transformada Rápida de Fourier (<i>Fast Fourier Transform</i> (FFT))
FWT	Transformada <i>Wavelet</i> Rápida (<i>Fast Wavelet Transform</i> (FWT))
NA	Neurônio Artificial
STFT	Transformada de Fourier de curto termo (<i>Short-Time Fourier Transform</i> (STFT))
VPP	Valor Preditivo Positivo
VPN	Valor Preditivo Negativo
VN	Verdadeiro Positivo
FN	Falso Negativo
VP	Verdadeiro Positivo
FP	Falso Positivo
ARMA	Método Auto-Regressivo Média Móvel (<i>Autoregressive Moving Average</i>)
ECG	Eletrocardiograma
PSD	Densidade Espectral de Potência (<i>Power Spectral Density Function</i>)
PM MW	Múltiplas Janelas de Pico Conjugado (<i>Peak Matched Multiple Window</i>)
WOSA	Média Ponderada de Segmentos Sobrepostos. (<i>Weighted Overlapped Segment Averaging</i>)
MLP	Largura da Base do Lóbulo Principal
NLL	Nível do Primeiro Lóbulo Lateral
CF	Fator de Crista
Ps	Produto Inclinação
LTSD	Desvio Padrão de Longo Termo
SI	Inclinação (dx/dt).
St	Estado de fundo do EEG (usando teorias de Gotman e Wang)

ESTADO DA ARTE

Nos últimos anos, vários estudos foram realizados no sentido de encontrar uma melhor forma de processar sinais bioelétricos, com a finalidade de obter informações acerca dos sistemas biológicos relacionados. Métodos computacionais vêm sendo aliados a uma constante evolução da tecnologia de sistemas eletrônicos e equipamentos.

A disponibilidade de novas tecnologias possibilitou a implementação de formalismos matemáticos, auxiliando diretamente no tratamento destes sinais. Utilizando-se estas técnicas matemáticas, a preocupação reside em como se processar determinado sinal a maneira pela qual o método pode ser aplicado e em como analisar os resultados.

Recentemente, as Redes Neurais Artificiais (RNA's) têm sido utilizadas com sucesso no processamento destes sinais. Uma RNA pode ser empregada para reconhecimento de padrões em sinais bioelétricos, por exemplo, para identificar patologias. A questão é saber qual forma de apresentação dos sinais à entrada da rede fornecerá a maior taxa de reconhecimento do tipo de sinal apresentado. Neste caso, os sinais podem ser apresentados na forma em que foram obtidos ou podem passar por um pré-processamento. O pré-processamento utiliza as ferramentas matemáticas com finalidade de “condicionar” o sinal para o processamento via redes neurais.

A motivação e objetivos deste trabalho podem ser definidos nos seguintes tópicos:

- 1- Questionar a necessidade de se realizar um pré-processamento dos sinais do EEG antes destes serem colocados como entradas em RNA's.
- 2- Analisar os vários métodos matemáticos de tratamento de sinais no sentido de adequá-los ao processamento de sinais de EEG com eventos epileptogênicos.
- 3- Propor um tratamento matemático confiável para o processamento automático de sinais de EEG contendo eventos epileptogênicos.
- 4- Analisar as características morfológicas dos sinais do EEG contendo eventos epileptogênicos com a finalidade de definir parâmetros que possam identificá-los.

A definição do tipo de pré-processamento depende essencialmente do tipo de sinal a ser analisado. Neste estudo, optou-se por utilizar sinais do eletroencefalograma (EEG) devido à grande necessidade de programas para auxílio ao seu diagnóstico, considerando-se o fato de que um especialista gasta longo tempo para analisar horas de registros.

Os tipos de eventos destacados nos sinais do eletroencefalograma a serem analisados neste estudo são aqueles relacionados ao diagnóstico da epilepsia. Considerando-se que estes eventos possuem uma grande variabilidade, faz-se necessário determinar exatamente quais formas de onda serão analisadas e classificadas. Determinou-se, então, os eventos epileptogênicos, espículas e ondas agudas, como foco de interesse e investigação deste trabalho.

Comentário: O que queres dizer com isto? Tás te referindo às variações morfológicas? Caso sim, sugiro trocar "vasta definição" por "grande variabilidade"

As descargas epileptogênicas são atividades paroxísticas efetivamente associadas e/ou originadas por distúrbios epilépticos. Diferenciam-se das descargas epileptiformes, que são atividades que apenas apresentam morfologias espicular ou rítmica e não são necessariamente epileptogênicas, mas consideradas como "variantes da normalidade", como por exemplo, a atividade variante psicomotora (rítmo teta em adultos). Observa-se que paroxismo é uma atividade eletrográfica que destaca-se visualmente da atividade básica do EEG. Este termo refere-se tanto as descargas epileptogênicas, quanto aos fusos do sono, complexos-K, etc [1, 19].

Comentário: Esta forma de citação está correta? Normalmente vejo "(Argoud, 2001)" ou simplesmente "[1]", nunca os dois ao mesmo tempo??

Os sinais do EEG, destacando-se aqueles contendo eventos epileptogênicos, possuem características peculiares, são imprevisíveis e de grande variabilidade, isto é, são sinais estocásticos por natureza. As ferramentas utilizadas em seu pré-processamento devem ser capazes de tratar convenientemente estas características.

Para o presente estudo, os métodos de pré-processamento analisados consistiram: 1) no espectro de frequências obtido pela transformada rápida de Fourier (*Fast Fourier Transform*: (FFT)) com janela de Kaiser, 2) no plano tempo-frequência na forma do espectrograma derivado da transformada de Fourier de curto termo (*Short-Time Fourier Transform* (STFT)), 3) na transformada *wavelet* e 4) no método paramétrico. O método paramétrico faz uma extração de parâmetros como entrada da rede, características ou descritivos da morfologia do sinal, bem como valores estatísticos a ele relacionados. A Figura 1.1 esquematiza em tópicos a forma empregada para avaliar-se os métodos matemáticos em questão, segundo seus resultados e sua repercussão no desempenho da rede neural utilizada.

As contribuições básicas deste trabalho estão em questionar a necessidade de se realizar um pré-processamento nos sinais do EEG antes destes serem colocados como entradas nas RNA's, quais os principais tipos de pré-processamentos que podem ser utilizados e como estes pré-processamentos são aplicados. Várias RNA's foram desenvolvidas tendo como entradas sinais do EEG com e sem pré-processamento.

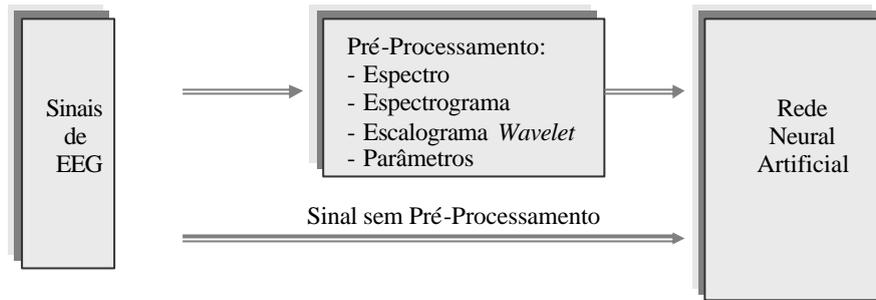


Figura 1.1- Propostas para a análise de sinais do EEG contendo eventos epileptogênicos, segundo o tipo de entrada da RNA.

Para implementar os pré-processamentos propostos explorou-se vários métodos matemáticos de tratamento de sinais no sentido de adequá-los ao processamento de sinais bioelétricos.

A transformada de Fourier foi utilizada com objetivo de obter os valores das frequências presentes em trechos escolhidos dos sinais do EEG. Deseja-se definir se estas frequências encontram-se na faixa de frequência dos eventos epileptogênicos. Contudo, esta transformada fundamentalmente não se aplica a sinais estocásticos e não-estacionários, como os sinais do EEG, assim, foi necessário utilizá-la juntamente com uma janela. Este trabalho analisou as janelas clássicas no sentido de definir uma, para ser aplicada. Várias simulações foram realizadas até definir uma janela adequada.

A transformada de Fourier de curto termo, visualizada no plano tempo-frequência, define o tempo de ocorrência de determinadas frequências, relação que pode gerar informações dos eventos presentes nos sinais. Para esta implementação foram simulados no plano tempo-frequência, na forma do espectrograma, vários sinais do EEG no sentido de adequar os parâmetros deste plano e retirar as informações que melhor definem a presença de um evento epileptogênico neste sinal.

A transformada *Wavelet* foi utilizada com a finalidade de destacar os eventos epileptogênicos dos demais eventos presentes nos sinais do EEG. Este estudo ressalta a necessidade de tratar separadamente os eventos epileptogênicos e os eventos que mais frequentemente são encontrados nestes sinais. As RNA's foram implementadas com os sinais tratados unicamente por uma *wavelet* de determinado nível de decomposição. Várias RNA's foram implementadas para detectar eventos epileptogênicos, ondas alfa, ruídos e piscadas. Os sinais foram tratados por *wavelets* com níveis de decomposições diferentes e adequados para destacar cada tipo de evento.

O método da extração de parâmetros exigiu a definição de vários parâmetros característicos de sinais do EEG contendo eventos epileptogênicos. Para uma resposta satisfatória das RNA's com entradas parametrizadas foram necessários estudos das formas de onda presentes nestes eventos com a finalidade de destacar as características que possam diferenciá-los dos demais eventos. Os parâmetros propostos foram calculados por um algoritmo desenvolvido especialmente para tratar estes sinais.

Este trabalho aliou as informações obtidas com estes pré-processamentos às RNA's com finalidade de verificar a presença de eventos epileptogênicos nos sinais do EEG.

Estudos relacionados aos sinais do EEG com eventos epileptogênicos vêm se desenvolvendo ao longo dos anos, sendo os de maior relevância citados no decorrer deste trabalho.

Os primeiros trabalhos realizados no sentido de se propor um método automático para detecção de eventos no EEG foram publicados por Gotman [2][3], baseado principalmente nas características morfológicas destes sinais.

Com o intuito de se obter um processo de detecção preciso e eficiente, vários métodos foram utilizados, muitas vezes apresentando certas restrições, como um elevado tempo computacional. Dentre os métodos que geram longos tempos computacionais destaca-se a análise espectral usando o modelo auto-regressivo, utilizado nos trabalhos de Bokehi [4], Muthuswamy [5] e Kong [6].

Os métodos relacionados à análise de frequência do sinal, como os que utilizam a transformada de Fourier, devido a certas restrições como a periodicidade, ao serem aplicados a sinais bioelétricos foram muitas vezes questionados. Contudo, surgiram a partir de 1995 alguns trabalhos usando representações tempo-frequência na forma de espectrogramas, como os publicados por Blanco [7], Wendling [8] e Baraniuk [9].

Um dos processos matemáticos mais explorados nos últimos tempos trata da transformada *Wavelet*, prometendo uma boa resolução no tempo e frequência. Dentre os trabalhos relacionados pode-se destacar as teses de Argoud [1] e Quiroga [10] e as publicações de Petrosian [11] e Geva [12].

Mais recentemente, nota-se uma tendência na utilização dos métodos estatísticos, os quais sugerem respostas mais rápidas, como a aplicação da correlação, variância, análise da coerência, ou mesmo uma combinação destes métodos. Seguindo esta linha de trabalho destaca-se a participação de Walczak [13], Matsumoto [14], Kaneko [15] e a tese de Esteller [16] usando um método de extração de características.

CAPÍTULO 1

1. BASE DE DADOS

O primeiro registro das variações de potencial do córtex em seres humanos, denominado de “eletroencefalograma” (EEG), foi feito por Hans Berger em 1929 e desde então são identificados nestes padrões característicos de alguma atividade cerebral, como o ritmo alfa. Baseando-se nas diferentes morfologias que caracterizam estas atividades, os sinais são classificados como indicadores de ritmos alfa, beta, teta, delta, e de eventos como os paroxismos, fusos do sono, complexos-K, crises eletrográficas, etc. A procura pela obtenção de sinais com boa qualidade para identificar estes padrões motivou muitas pesquisas. E, a partir destes registros foram implementados vários métodos para sua análise. Grande parte destes métodos constitui de algoritmos para a identificação automática do tipo de sinal apresentado. Contudo, a identificação automática correta é resultado da boa qualidade do sinal e das técnicas utilizadas para evidenciar as características, que marcam a existência de uma atividade específica.

A fisiologia dos sinais do EEG, descrita e comentada por Guyton [17], Lent [18] e Niedermeyer [19] fornece elementos teóricos úteis para as análises realizadas neste trabalho. Destacando-se o interesse nos eventos epileptogênicos, os relatos de Niedermeyer [19], Gotman [2, 3] e Guerreiro [20] são fundamentais para definir e classificar os tipos de epilepsias e as características mais marcantes em cada uma delas. São destacados, também, os estudos publicados por Lombroso [21], Wendling [22], Ohtahara [23], Walczak [13].

1.1 Principais Características dos Sinais do EEG Contendo Eventos Epileptogênicos

As características sintetizadas aqui são aquelas relacionadas às formas mais freqüentemente assumidas pelos eventos epileptogênicos em sinais do EEG e as mais relevantes para este estudo.

Um evento epileptogênico pode estar presente em sinais do EEG juntamente com outras formas de onda, como ondas alfa e mesmo ruídos e piscadas, e manifesta-se em mais de um canal ou em certos canais específicos, no caso dos eventos localizados. Este fato pode ser observado na Figura 1.2, onde as múltiplas espículas aparecem em vários canais.

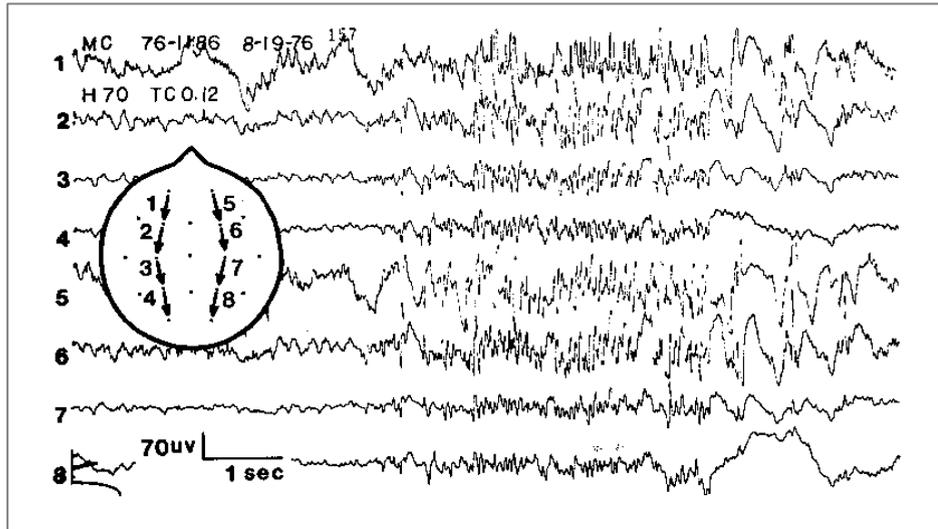


Figura 1.2- Sequências de múltiplas espículas obtidas de um paciente adormecido [19].

As espículas são representações no EEG das descargas de alta voltagem sincrônicas que ocorre no córtex durante uma crise epiléptica. O padrão de onda cerebral é caracterizado pela forma de ponta.

O evento epileptogênico clássico é representado no sinal sob a forma de uma espícula ou onda aguda. As atividades epilépticas incluem não só transientes de pequena duração, mas também ondas agudas de vários milissegundos (ondas *Sharp*). As diferenças entre estas duas formas de evento podem ser observadas na Figura 1.3.

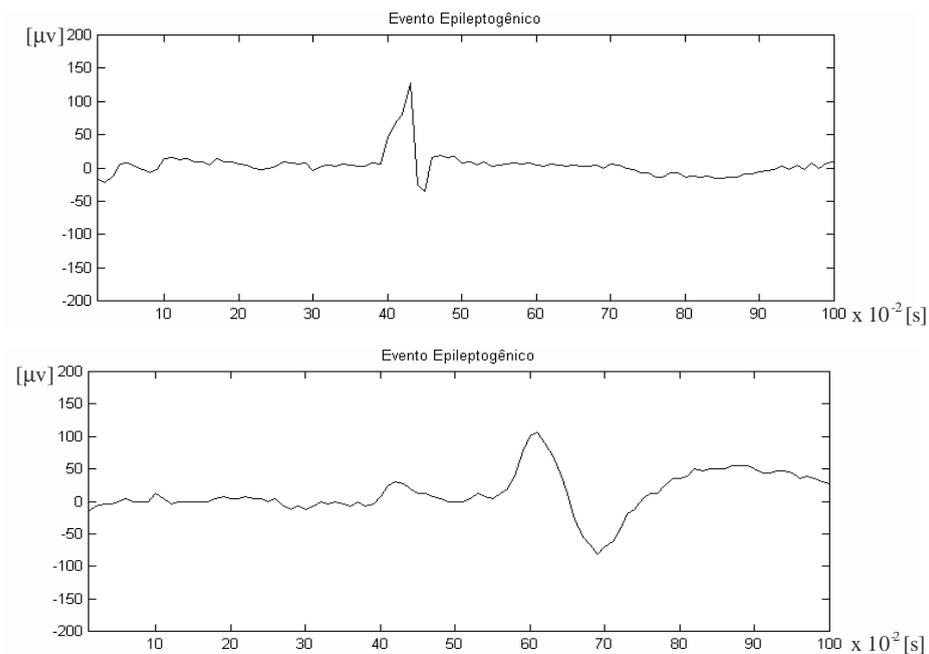


Figura 1.3- Eventos Epileptogênicos: Em (a), espícula; em (b), onda aguda.

Uma espícula dura de 20 milissegundos a 70 milissegundos e geralmente possui uma componente positiva com amplitude alta e variável. Uma onda aguda dura de 70 a 200 milissegundos, geralmente possui componentes positiva e negativa e seu crescimento de fase é como na espícula, mas a fase ascendente é prolongada [19].

As amplitudes típicas de eventos epileptogênicos são muito variadas, não existindo uma definição exata. Contudo, pode-se considerar que, em geral, suas amplitudes em média estão acima de 20 μV e abaixo de 200 μV . O EEG é um sinal cujas características como a amplitude e a frequência possuem uma alta variabilidade no tempo. Considerando-se os sinais do EEG contendo eventos epileptogênicos, as frequências que podem estar presentes na faixa crítica da epilepsia são de 2 a 20 Hz. O complexo espícula-onda (CEO) apresenta frequências de 3,5 a 6 Hz. Os CEO's podem vir acompanhados do complexo poli-espícula de 10 a 20 Hz. Um tipo particular de epilepsia, conhecido como ausência (ou *Petit-mal*), inicia com os CEO's de 3 Hz e termina com 2,5 a 2 Hz [1, 2, 3, 19].

1.2 Banco de Dados

O banco de dados utilizado foi apresentado por Argoud [1] em tese defendida no Instituto de Engenharia Biomédica, Programa de Pós-Graduação em Engenharia elétrica da Universidade Federal de Santa Catarina. Este banco de dados foi obtido com permissão do Montreal Neurological Institute (NMI) no Canadá. Contém nove registros do EEG, adquiridos a partir de sete pacientes adultos. Os nove registros, esquematizados na Tabela 1.1, são divididos em quatro registros com 60 minutos de duração, quatro registros de 90 minutos de duração e um registro de 120 minutos de duração, totalizando 12 horas de registros contínuos do EEG. Os sinais foram amostrados em 100 Hz e em 32 canais, exceto um dos registros, o qual foi adquirido em 24 canais. Foi utilizada uma montagem bipolar do tipo zigomática-temporal (*Zygo-Db-Temp*), apresentada na Figura 1.4, com eletrodos nas posições Zy1, Zy2, Fp1, Fp2, F3, F4, F7, F8, F9, F10, CZ, C3, C4, T3, T4, T5, T6, T9, T10, P3, P4, P9, P10, O1, O2 e dois eletrodos para os EOG: Eogl e Eogr. Os sinais foram pré-filtrados analogicamente no sistema de aquisição Harmonie, da Stellate Systems® CA, na faixa de 0,5 a 40 Hz, Não foram realizadas filtragens digitais adicionais.

Tabela 1.1: Síntese do banco de dados com seus respectivos arquivos.

Arquivos	Número de Canais	Arquivos de 15 Segundos (1500 pontos)
Jokhoo	32	jok_15, jok_30, jok_45, ..., jok_5400
Kurian	32	kur_15, kur_30, kur_45, ..., kur_5400
Laporte	32	lap_15, lap_30, lap_45, ..., lap_3600
St_rock	32	sr_15, sr_30, sr_45, ..., sr_7200
St_rock2	24	sr2_15, sr2_30, sr2_45, ..., sr2_3600
Vadnais1	32	vad1_15,vad1_30,vad1_45,...., vad1_3600
Vadnais2	32	vad2_15,vad2_30,vad2_45, ..., vad2_5400
Wamboldt	32	wam_15,wam_30,wam_45, ..., wam_3600
Zogrfo	32	zog_15,zog_30, zog_45, ..., zog_5400

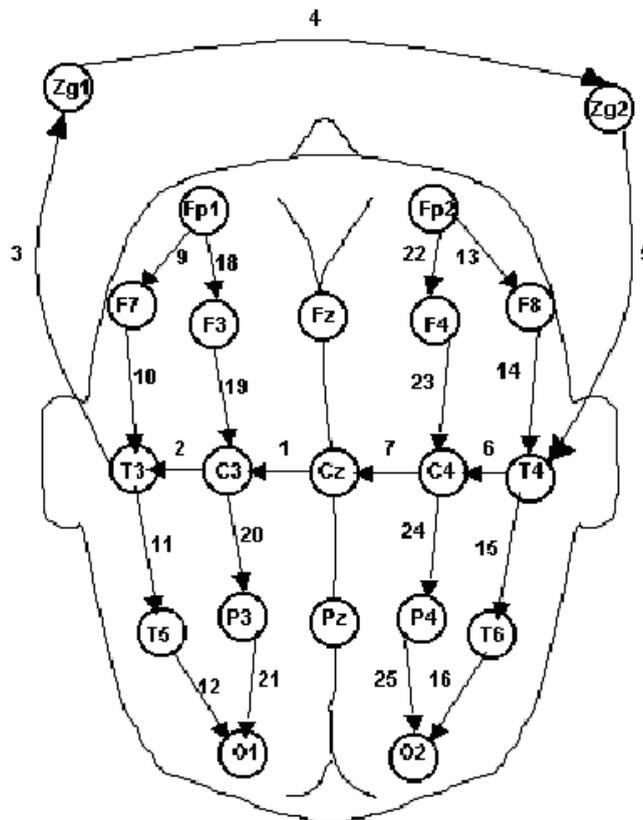


Figura 1.4- Tipo de montagem zigomática-temporal bipolar com 25 eletrodos arranjados em 32 canais. Os números ao lado das setas identificam as derivações bipolares. Os eletrodos Zg_1 e Zg_2 são posicionados nos maxilares.

Assim, $(12 \text{ h} \times 60' \times 60''/15'' =)$ um total de 2880 telas de 15 segundos, contendo 32 canais (exceto St_rock2 que possui 24 canais) cada, estão disponíveis para processamento por redes neurais, tratamento matemático ou processos que envolvam uma análise sistemática destes sinais. A Figura 1.5 mostra uma destas telas, contendo os 15 segundos da janela (13:59:58 a 14:00:13) bem como os 32 canais.



Figura 1.5- Tela de um dos arquivos dos sinais do EEG, apresentando os 32 canais de 15 segundos.

Para o desenvolvimento de uma rede neural para a análise de um único canal, com 1500 pontos, deve-se primeiro definir o tamanho viável em que será particionado o sinal de entrada. Para a análise, cada canal deve ser dividido em um número suficiente de pontos que possam evidenciar um evento epileptogênico, o qual dura no máximo 200 milissegundos ou cerca de 20 pontos. Assim, a divisão do canal para conter um único provável evento epileptogênico fragmentaria demasiadamente o sinal.

Foi, então, estipulada a divisão dos sinais a cada 1 segundo, correspondendo a 100 pontos, o que possibilita que ocorra neste trecho mais do que um evento epileptogênico. Para amostras menores do que 1 segundo o sinal ficaria fragmentado em excesso, aumentando as distorções de bordas. Usar amostras maiores do que 1 segundo dificultaria a centralização de um evento epileptogênico, já que sua duração é da ordem de milissegundos, aumentando a probabilidade de se encontrar mais de um evento em cada trecho. Pode-se observar, através da Figura 1.6, que o trecho de 100 pontos foi suficiente para a visualização do evento sem fragmentar demasiadamente o sinal.

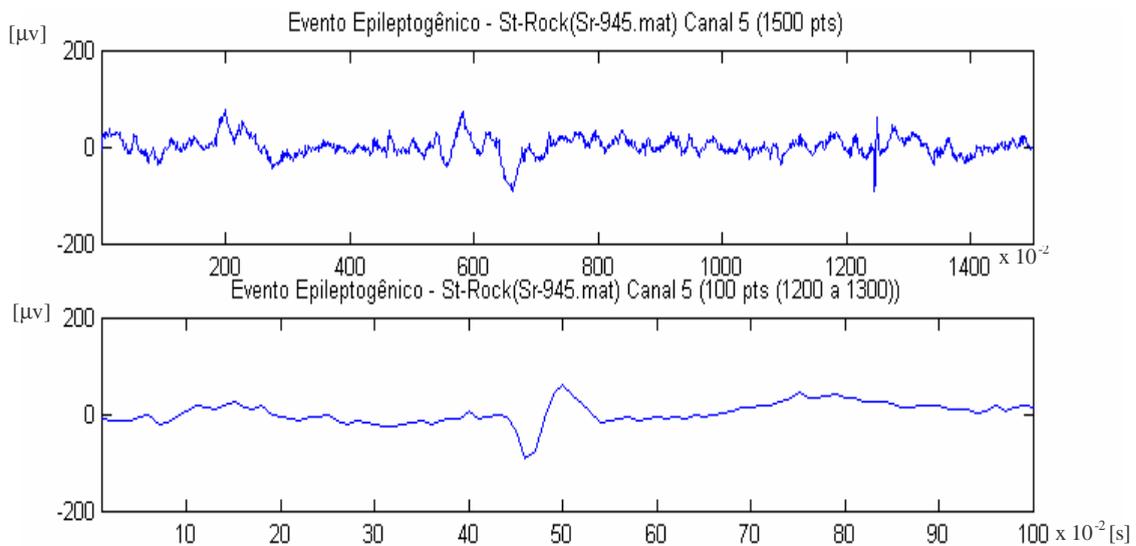


Figura 1.6- Sinal do EEG do registro de St_Rock contendo o evento epileptogênico, arquivo Sr_945, referente ao canal 5 (Zy2-T4). Em (a), trecho completo de 15 segundos com espícula entre os pontos 1200 e 1300 e, em (b), trecho de 1 segundo (100 pontos) contendo espícula ao centro.

A distorção de bordas é um fator a ser considerado, quando são propostos métodos de tratamento matemático utilizando médias móveis (*moving average*). Nestes casos, os pontos anteriores e posteriores devem ser utilizados, de forma ponderada, para obter-se o valor do coeficiente para o ponto atual. É necessário utilizar algum procedimento de tratamento dos vetores, pois estes não dispõem de pontos anteriores, no caso da borda à esquerda, ou posteriores, no caso da borda à direita [1].

1.3. Considerações Finais do Capítulo

Este capítulo descreveu de uma forma sintetizada a constituição do banco de dados disponível para este trabalho. Este banco consta de 43200 arquivos previamente analisados por um especialista. Nestes arquivos foram destacados vários trechos de sinais contendo eventos epileptogênicos bem como ondas alfa, ruídos, piscadas e EEG normal de fundo.

Inicialmente procurou enfatizar as principais características morfológicas dos eventos epileptogênicos encontrados nos sinais do EEG. Estas características foram a base de muitas análises envolvidas neste estudo.

CAPÍTULO 2

2. REDE NEURAL ARTIFICIAL

A busca de métodos para automatizar tarefas repetitivas e extensas, ou cujo contexto aborde muitos detalhes a serem considerados em investigações, é um interesse comum em quase todas as áreas de estudos e pesquisas. Uma Rede Neural Artificial (RNA) é a base para muitos destes métodos de automatização. Contudo, a opção de utilizar-se uma rede para desenvolver determinada tarefa leva à necessidade de se definir uma rede, dentre as várias redes descritas, que se adeque à aplicação desejada.

As redes surgiram como modelos matemáticos das funções dos neurônios biológicos. Este modelo é geral e deve ser adaptado para ser utilizado conforme determinada aplicação. Quando utilizadas em sinais bioelétricos, deve ater-se às características peculiares destes sinais, como a imprevisibilidade. Uma das formas de se adequar o uso de redes é através das entradas. No caso de sinais bioelétricos, os dados são manipulados em suas entradas visando aumentar o grau de informações a respeito da classe de sinais que se deseja que seja identificada.

A aplicação de RNA a sinais bioelétricos, principalmente os sinais do EEG, possui como uma das dificuldades a quantidade de eventos que podem ocorrer em um pequeno trecho destes sinais. A rede deve ser capaz de absorver as características de cada um destes eventos. Alguns dos trabalhos desenvolvidos, no sentido de definir-se uma metodologia para o uso de redes com sinais do EEG, podem ser conhecidos através das publicações de Devulapalli [24], Klöppel [25], [26], [27], Coimbra [28], Koprinska [29], Siregar [30], Lengellé [31], Kalcher [32], Steuer [33], Rodrigues [34], Pilla [35]. Em geral estes trabalhos são baseados no uso de determinado processo para tratar o sinal, antes deste ser colocado como entrada da rede. E, no caso específico da aplicação de RNA a sinais do EEG contendo eventos epileptogênicos, destacam-se os trabalhos de Argoud [36], Walczak [13], Kim [37] e Litt [38]. Evidencia-se em quase todos estes trabalhos o uso de redes Feedforward com o algoritmo de aprendizado Backpropagation.

2.1 Síntese dos Principais Fundamentos Teóricos Relacionados às RNA's

Em sua forma mais geral, uma rede neural é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse. A rede é normalmente implementada utilizando-se componentes eletrônicos ou é simulada por programação em um computador digital. Para alcançar bom desempenho, as redes neurais empregam uma interligação maciça de células computacionais simples denominadas “neurônios” ou “unidades de processamento”. Estas interligações são representadas pelos *pesos sinápticos*. O procedimento utilizado para realizar o processo de aprendizagem é chamado de “algoritmo de aprendizagem” e sua função é modificar os pesos das interligações entre os neurônios da rede de uma forma ordenada, para alcançar um objetivo de projeto desejado [39].

Uma descrição detalhada dos fundamentos das redes neurais artificiais é uma redação laboriosa sobre conceitos básicos da aplicação que vai utilizar as redes como ferramenta de análise. A literatura disponibiliza muitos destes trabalhos facilitando o desenvolvimento das aplicações (Haykin [39], Freeman [40] Azevedo [41, 42, 43], Demuth [44] e Barreto [45, 46]).

O objetivo proposto para as redes utilizadas neste estudo é destacar eventos epileptogênicos em sinais do EEG, considerando-se a possibilidade destes sinais serem ou não pré-processados. O interesse é definir uma forma adequada de pré-processamento na obtenção de um resultado positivo, ou não, da existência do evento. Optou-se, em termos da topologia, pela utilização de redes alimentadas diretamente com uma camada oculta. Como padrão para as implementações deste estudo, foram utilizadas as redes *feedforward* com algoritmo de aprendizado *backpropagation* (Figura 2.1). Elas foram constituídas por uma camada oculta e um neurônio de saída. O valor de n do vetor de entrada é igual ao número de entradas e o valor de s representa o número de neurônios na camada oculta.

Contudo, quando é desejada uma abordagem mais sistemática a respeito dos tipos de eventos presentes no sinal é aconselhável, também, o uso de mapas auto-organizáveis com classificação de padrões, descritos por Haykin [39] e Duda [47].

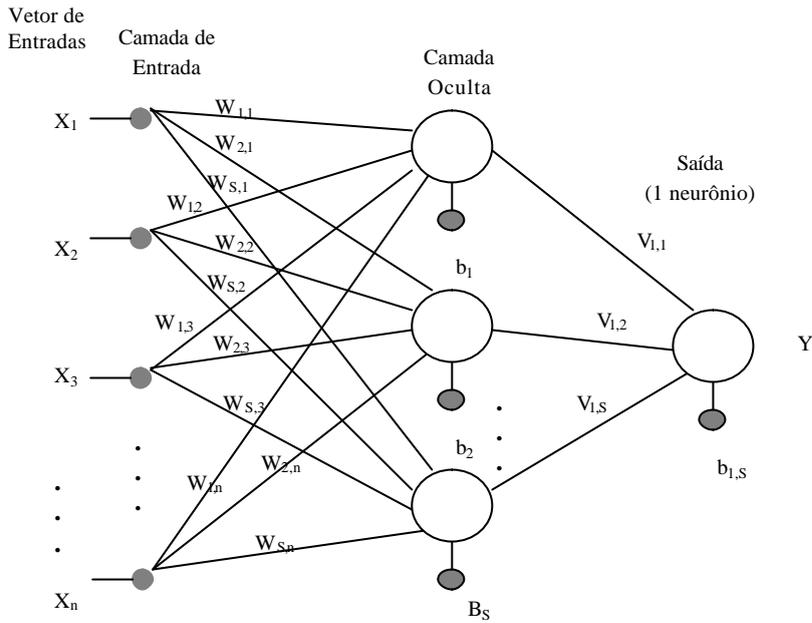


Figura 2.1 - Grafo das redes propostas.

A representação dos elementos básicos de um neurônio artificial (NA) mostrada na Figura 2.2 possibilita uma melhor definição dos elementos básicos na rede. No modelo geral de neurônios as entradas $w_n \cdot x_n$ são combinadas usando uma função ϕ para produzir um estado de ativação dos neurônios que, através da função λ , vai produzir a saída do neurônio, y [34].

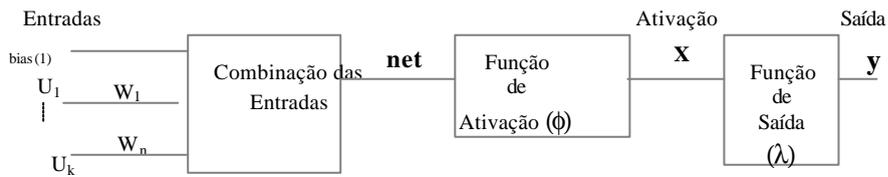


Figura 2.2 - Elementos básicos de um neurônio artificial [34].

Cada entrada do neurônio possui um conjunto de pesos associados, que pode ser entendido como a ‘força’ da conexão sináptica quando comparado ao neurônio biológico. As entradas de um neurônio podem ser as saídas de outros neurônios, $y(t)$, entradas externas u , um *bias* b ou qualquer combinação destes elementos. O somatório de todas estas entradas possibilita a origem do chamado *net* de um neurônio, que pode ser representado, pelo somatório das entradas proveniente de outros neurônios e pelo somatório das entradas externa, como mostra a Equação (2.1).

$$net_i(t) = \sum_{j=1}^p w_{ji} y_j(t) + \sum_{k=1}^m w_{ki} u_k(t) + b_i \quad (2.1)$$

onde:

y_j é a saída do j-ésimo neurônio;

u_k é a k-ésima entrada externa;

b_i é o bias do i-ésimo neurônio;

w refere-se ao peso correspondente.

Após a determinação do valor de $net_i(t)$, o estado do neurônio, ou ativação, é atualizado através da função de ativação $f(\cdot)$. Analiticamente, a ativação do neurônio é obtida pela Equação (2.2).

$$x_{t+h} = \phi [x_t, net_t, t, h] \quad (2.2)$$

Após a determinação do estado do neurônio $x(t)$, o sinal de saída do neurônio é calculado pela função de saída $I(\cdot)$, utilizando a Equação (2.3).

$$y(t) = I[x(t), t] \quad (2.3)$$

A função de ativação para as duas camadas adotada neste estudo foi a função tangente hiperbólica, a qual é definida pela Equação (2.4) [39,40].

$$y(x) = \tanh(kx) = \frac{e^{kx} - e^{-kx}}{e^{kx} + e^{-kx}} \quad (2.4)$$

onde k é um escalar positivo.

A função tangente hiperbólica representa a função bipolar sigmóide mais utilizada.

A aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede esta inserida. O tipo de aprendizado é determinado pela maneira pela qual a modificação dos parâmetros ocorre [39].

Uma rede neural aprende através de um processo interativo de ajustes aplicados a seus pesos simpáticos e níveis de *bias*.

O algoritmo de aprendizado é um conjunto pré-estabelecido de regras bem definidas. Na fase de aprendizado de uma RNA, uma regra é usada para alterar os elementos da matriz de pesos e outros parâmetros modificáveis da rede usando a informação do meio externo disponibilizada pelo supervisor do aprendizado. No caso das redes utilizadas neste trabalho o supervisor fornece para a rede um conjunto de treinamento, ou seja, um conjunto de entradas e suas respectivas saídas desejadas. Deseja-se que a rede ajuste os seus pesos de forma a produzir, para cada entrada do conjunto de treinamento, a saída desejada fornecida pelo supervisor. Para cada entrada do conjunto de treinamento a saída produzida pela rede neural é comparada com a saída desejada fornecida pelo supervisor e os pesos são alterados de forma a diminuir esta diferença [48].

Para o algoritmo supervisionado por uma meta T as alterações da matriz de pesos e do vetor *bias*, durante o processo de treinamento, são relacionadas através de uma taxa de aprendizado “ η ”, conforme as Equações (2.5) e (2.6). Observa-se que a taxa de aprendizado “ η ” é um valor maior que zero ($0 < \eta < 1$).

$$\Delta W_{ik} = \eta(T_i - y_i)U_k \quad (2.5)$$

$$\Delta bias_i = \eta(T_i - y_i) \quad (2.6)$$

O erro (e) para a unidade de saída resultante de cada ajuste de pesos é relacionado pela meta T e a saída y em cada interação do treinamento, conforme Equação (2.7).

$$e_k(i) = T_k(i) - y_k(i) \quad (2.7)$$

O erro quadrático calculado sobre as unidades de saída quando o padrão u é aplicado na entrada da rede é definido pela Equação (2.8).

$$E_k = \frac{1}{2} \sum_{i=1}^n (T_k(i) - y_k(i))^2 \quad (2.8)$$

Para as redes *feedforward* com uma camada oculta deve-se considerar as matrizes de pesos da unidade oculta j e unidade de entrada l ($W_k(j,l)$) e da unidade de saída i e unidade oculta j ($V_k(i,j)$). E, a alteração destes pesos é definida pelas equações (2.9) e (2.10), respectivamente.

$$\Delta w_k(i, j) = -\mathbf{h}e_k(i)\mathbf{f}'_k(i)u_k(j) \quad (2.9)$$

$$\Delta V_k(i, j) = \mathbf{h}e_k(i)\mathbf{I}_k(i)y_k(j) \quad (2.10)$$

O algoritmo *backpropagation* minimiza a soma dos quadrados dos erros de saída, considerando-se sua média sobre o conjunto de treinamento, usando uma busca baseada na direção do gradiente.

Os algoritmos utilizados para treinar uma rede *feedforward* podem convergir para a solução de mínimo global rapidamente ou lentamente. Os algoritmos que convergem rapidamente podem ficar presos em pontos de mínimo local. Por outro lado, a taxa de aprendizagem é relacionada aos pesos sinápticos da seguinte forma: quanto menor for a taxa de aprendizagem, “ η ”, menores são as variações dos pesos sinápticos da rede, e mais suave é a trajetória no espaço de pesos; neste caso, porém, o processo de aprendizagem é lento. Aumentando-se a taxa de aprendizagem, “ η ”, modificações significativas nos pesos sinápticos podem tornar a rede instável. A solução para este trabalho foi manter a taxa de aprendizagem alta, evitando-se a instabilidade através da inclusão de um termo de momento, isto é, constante de momento α .

Geralmente não é possível demonstrar que o algoritmo de retropropagação irá convergir, e não existem critérios bem definidos para encerrar sua operação. Contudo, existe alguns critérios razoáveis que podem ser usados para encerrar o ajuste dos pesos. Um dos métodos de parada usa a taxa de variação do erro médio quadrático, a qual deverá ser a menor possível. Isto, contudo, pode resultar em um encerramento prematuro do processo de aprendizagem.

2.2 Redes Neurais Artificiais Propostas Neste Trabalho

As redes propostas são redes estáticas organizadas conforme a topologia das redes *feedforward*, com o algoritmo de aprendizado *backpropagation*. O treinamento é supervisionado, conforme definições do supervisor do Item 2.1, tendo, de início, uma meta

a ser alcançada conforme os sinais apresentados em suas entradas. Durante a etapa de treinamento, os sinais com eventos epileptogênicos e as atividades normais são previamente conhecidos, definindo-se as saídas desejadas.

As entradas da rede irão variar conforme a forma em que o sinal é apresentado, isto é, irá depender dos resultados de cada tipo de pré-processamento.

Os pré-processamentos matemáticos em questão são:

- Densidade espectral de potência, envolvendo a transformada rápida de Fourier com janela;
- Espectrograma e plano tempo-frequência;
- Transformada *wavelet*;
- Parâmetros correspondentes às características morfológicas do sinal.

O número de neurônios das camadas de entrada e oculta tende a variar conforme o tipo de pré-processamento. Sugere-se uma análise individual para a arquitetura das redes, de acordo com o tipo de entrada. Contudo, as demais características devem ser iguais para todas as redes, já que o interesse é relacionar resultados no sentido de se comparar a eficiência de cada método de tratamento do sinal.

A camada de saída, em todos os casos, utiliza um único neurônio, o qual deve sinalizar a ocorrência de um evento (saída = 1), ou não (saída = 0).

Comentário: na minha opinião:
redundante

Como critério de parada, estabelece-se inicialmente um erro máximo permitido e o número máximo de interações. As características comuns para as redes são preliminarmente definidas:

- Número de neurônios da camada de saída = 1;
- Função de saída para os neurônios das camadas oculta e de saída = tangente hiperbólica;
- Momento = 0,9;
- Erro máximo básico = 0,001;
- Taxa de treinamento = 0,01;
- Número máximo de interações por treinamento = 100.000.

O número de neurônios na camada oculta (*hidden*), valor intermediário entre o número de unidades de entrada e a unidade de saída, modifica-se em cada caso. Mas o princípio utilizado na definição deste valor deve ser equivalente para todos os casos. Inicialmente, este é obtido através da relação que faz o tamanho da camada oculta ser igual à raiz quadrada do produto do número de neurônios de entrada pelo número de neurônios de saída [46]. A partir deste valor são simuladas várias redes, considerando-se os mesmos arquivos para treinamento e teste, até obter-se o menor erro.

Sendo o número de neurônios na camada oculta relacionado ao número de neurônios de entrada, logo seu valor é diferente para redes com entradas sem pré-processamento e para redes com os diferentes tipos de pré-processamento. E devido à tendência em se obter resultados diferentes para cada número de neurônios na camada oculta, várias redes são testadas.

Inicialmente, o melhor resultado para o número de neurônios na camada oculta foi julgado conforme o número de acertos obtidos pela rede, isto é, o número de vezes em que a saída da rede foi igual a uma meta previamente definida. Considera-se, também, valores de especificidade e sensibilidade alcançados.

A rede foi treinada e se o erro máximo básico não fosse atingido com 100.000 interações, neste caso, considerava-se o valor máximo de interações no treinamento igual a 300.000 e verificava se os resultados em sensibilidade e especificidade forneciam uma melhora significativa.

Utilizando a mesma arquitetura da rede proposta e os mesmos conjuntos de sinais para seu treinamento e teste, uma nova rede é treinada com a normalização dos sinais de entrada. Esta normalização é realizada baseada na amplitude máxima do conjunto de sinais de entrada, como a forma tradicional de normalização, conforme a Equação (2.11), e baseada na amplitude máxima de um evento epileptogênico. A necessidade de se normalizar o sinal conforme a amplitude máxima de um evento epileptogênico, que não passa de 200 μV , deve-se ao fato de serem encontrados, junto a estes eventos, sinais com amplitudes bem maiores, como os ruídos e piscadas com amplitudes em torno de 500 μV . Neste caso o sinal que apresenta a amplitude com maior valor absoluto, dentro do conjunto de sinais na entrada da rede, é de um evento não-epileptogênico. Assim, dentro do conjunto normalizado o evento epileptogênico apresentará pouco ressaltado comparado com o evento de maior amplitude. Visto que, é necessário ressaltar os eventos

epileptogênicos na entrada das redes, normalizar suas entradas com referência a amplitude máxima absoluta de todos tipos de sinais pode não evidenciar estes eventos.

$$\text{Entrada da Rede} = \text{Sinal} / \text{Maximo}(\text{absoluto}(\text{Conjunto_sinais})) \quad (2.11)$$

A Figura 2.3 mostra a questão de normalizar-se um sinal contendo eventos epileptogênicos junto com piscadas e mesmo certos tipos de ruídos. Com a normalização a forma do sinal não muda. A normalização atua nos valores das amplitudes do sinal, e estes valores fracionários influenciam na obtenção dos pesos resultantes do treinamento.

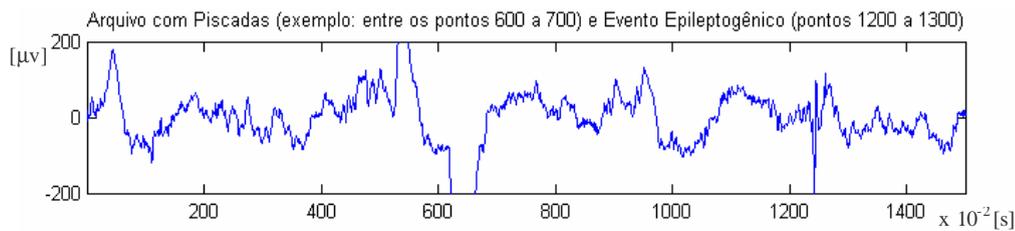


Figura 2.3 - Evento epileptogênico juntamente com piscadas.

Em casos como mostrado na Figura 2.3, quando a normalização é realizada sobre todos os eventos dos sinais de entrada da rede, a amplitude máxima relativa é calculada sobre as amplitudes máximas de cada sinal. E a amplitude máxima em um sinal tende a ser de uma piscada, por exemplo, e não de um evento epileptogênico. A normalização feita tendo a amplitude de uma piscada como referência faz com que os sinais com eventos epileptogênicos sejam pouco destacados.

A Figura 2.4 representa dois sinais que podem pertencer ao conjunto de entrada da rede e ilustra a diferença de magnitude entre os dois eventos: espícula e piscada. Em (a), é mostrada uma espícula cuja amplitude máxima não ultrapassa $\pm 200 \mu\text{V}$. Em (b), é mostrada uma piscada cuja amplitude máxima, em módulo, está em torno de $400 \mu\text{V}$. Quando a normalização é realizada, a questão das amplitudes máximas do sinal torna-se evidente.

Considerando-se que, em média, as amplitudes para os eventos epileptogênicos não ultrapassam $\pm 200 \mu\text{V}$, é possível estipular-se um patamar de análise. Assim, quando um ponto do sinal ultrapassar este patamar, ele terá sua amplitude convertida para o valor da média do sinal naquele período.

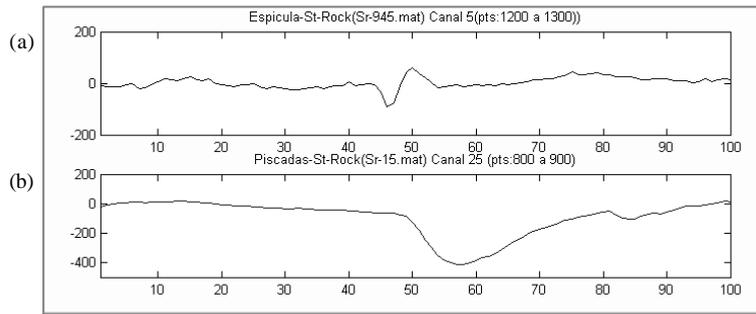


Figura 2.4- Em (a), a representação de um trecho de 1 segundo contendo uma espícula (entre os pontos 40 e 60). Em (b), a representação do trecho de 1 segundo contendo uma piscada (entre os pontos 50 e 70).

O processo de normalização, considerando-se a amplitude máxima do evento epileptogênico, faz a amplitude máxima da matriz resultante ser sempre em módulo menor ou igual a 200 μV . É importante ressaltar que a maioria dos sinais da base de dados não ultrapassam este patamar, com exceção dos sinais contendo ruídos e piscadas.

A questão da normalização dos sinais da entrada das redes foi tratada para cada tipo de pré-processamento em estudo neste trabalho e encontra-se referenciada nos próximos capítulos.

2.3 Arquivos de Treinamento e Teste

A proposta é utilizar-se dois conjuntos diferentes de arquivos com sinais de 1 segundo para treinar as redes mais dois conjuntos de testes, diferentes dos conjuntos de treinamento.

O primeiro conjunto de treinamento utilizado contém dois subconjuntos. O primeiro subconjunto é constituído por sinais definidos como não-epileptogênicos e contendo artefatos, como ruídos e piscadas, além do sinal do EEG normal de fundo. E o segundo subconjunto é constituído por sinais contendo eventos necessariamente epileptogênicos.

Este conjunto inclui sinais com eventos epileptogênicos e sem eventos epileptogênicos, sem detalhar a forma do evento epileptogênico ou o tipo de sinal não-epileptogênico. As redes que utilizam este conjunto foram designadas como RNA sem caracterização prévia dos sinais de entrada.

Comentário: acho que este termo não existe no português – usar algo como “setorização”, p.e.

O segundo conjunto de treinamento contém as principais formas de onda que caracterizam eventos epileptogênicos e não-epileptogênicos. Destacar-se as características mais freqüentemente encontradas, ao longo dos sinais do EEG. Por outro lado, junto aos eventos epileptogênicos, são encontrados vários tipos de sinais, como uma atividade de fundo do sinal do EEG, ondas alfa, ruídos em geral e piscadas. A Figura 2.5 apresenta uma amostra dos principais eventos não-epileptogênicos.

Uma atividade de fundo em um EEG normal tende a apresentar amplitudes positivas e negativas extremamente reduzidas comparadas com as amplitudes dos demais eventos. Os sinais contendo ondas alfas tendem a apresentar amplitudes reduzidas e uma freqüência fundamental dominante. Os sinais contendo piscadas, em geral, possuem uma maior amplitude e um ângulo mais aberto nos vértices. As formas apresentadas pelos ruídos mostram maiores componentes de freqüência e variações em suas amplitudes.

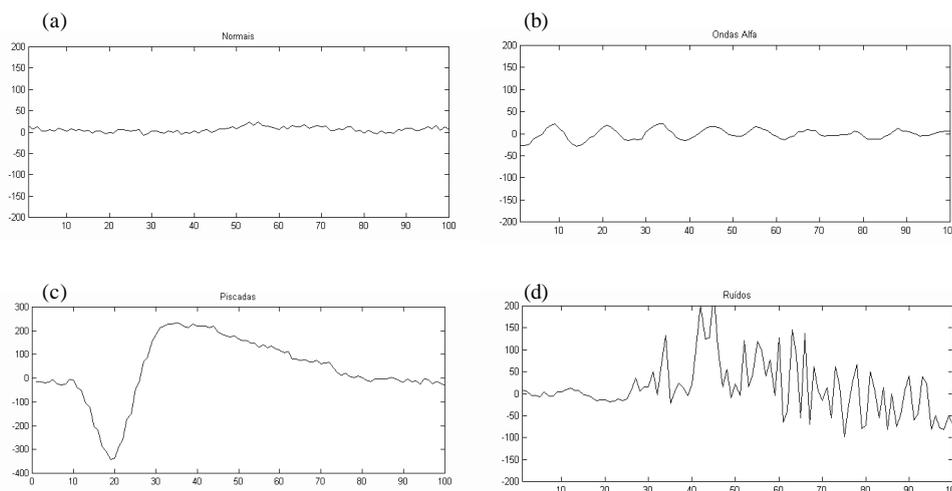


Figura 2.5 - Morfologias dos eventos encontrados nos sinais do EEG, que podem aparecer juntamente com os eventos epileptogênicos. Em (a), uma atividade de fundo do sinal do EEG. Em (b), ondas alfa. Em (c), uma forma de piscada. Em (d), ruídos que podem ser de origem muscular, por interferência eletromagnética no equipamento, etc.

É possível, mediante as análises e as definições de especialistas, obter-se um padrão de comportamento que possa ser usado para a detecção dos eventos presentes nos sinais do EEG. Neste sentido, são estabelecidos quatro eventos que mais freqüentemente são encontrados nos registros. Estes sinais, em síntese, podem apresentar um pico positivo e ondas negativas de baixa amplitude, um único pico negativo e ondas positivas de baixa amplitude, parte positiva e negativa com o pico positivo aparecendo primeiro e parte negativa e positiva com o pico negativo aparecendo primeiro. Estas quatro formas estão apresentadas na Figura 2.6, e podem ser observadas nos registros dos trechos dos sinais do EEG contendo eventos epileptogênicos.

Comentário: Evitar utilizar adjetivos abstratos/qualitativos, tá Carminha? Se absolutamente necessário, não usar figuras de linguagem. Ex: "análise longa" é uma análise comprida, metrologicamente falando.... termos como "extensivas", "abrangentes", etc, seriam mais adequados....

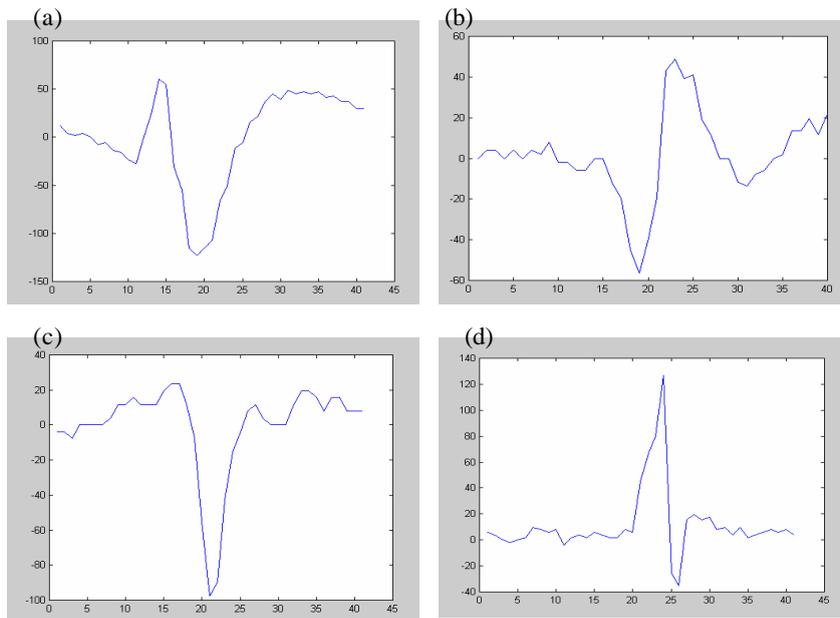


Figura 2.6- Padrões apresentados por eventos epileptogênicos. Em (a), evento com parte positiva e negativa com pico positivo aparecendo primeiro. Em (b), evento com parte negativa e positiva com pico negativo aparecendo primeiro. Em (c), evento com um pico negativo e ondas positivas de baixa amplitude. Em (d), evento com um pico positivo e ondas negativas de baixa amplitude.

Comentário: Carminha, melhora o contraste entre o fundo (que está muito escuro, cinza) e o gráfico, ok?

Comentário: Poxa, tu és osso-duro-de-roer, hem????????? Já não tinha pedido para retirar/mudar TODAS estas construções verbais sem sentido, estilo: "Em tal lugar, apresenta".... No mínimo, Carminha, tens que escrever "Em tal lugar é apresentado(a)".....

Portanto, o conjunto de sinais usados no treinamento das redes, para o primeiro tipo de arquivo de treinamento proposto, sem caracterização prévia dos sinais de entrada, é constituído de:

- 47 sinais contendo eventos epileptogênicos;
- 73 sinais contendo eventos não-epileptogênicos.

E o conjunto de sinais usados para teste destas redes é constituído de:

- 30 sinais contendo eventos epileptogênicos;
- 23 sinais contendo eventos não-epileptogênicos.

Para o segundo tipo de arquivo de treinamento proposto, com caracterização prévia dos sinais de entrada, é sugerido o uso de um conjunto de sinais que contenha as principais características apresentadas pelo evento em questão. O arquivo de treinamento é então constituído:

- 5 sinais com evento epileptogênico apresentando o primeiro pico positivo;
- 5 sinais com evento epileptogênico apresentando o primeiro pico negativo;
- 5 sinais com evento epileptogênico apresentando um pico negativo proeminente;
- 5 sinais com evento epileptogênico apresentando um pico positivo proeminente;
- 10 sinais com EEG de fundo;
- 5 sinais com ondas alfa;
- 5 sinais com ruídos;
- 5 sinais com piscadas.

Uma tabela contendo os arquivos dos quais foram obtidos tais sinais é encontrada no Anexo A, referente aos sinais dos conjuntos de treinamento e testes usados nas redes.

2.4 Método de Avaliação dos Resultados das Redes

Uma avaliação significativa para a resposta de uma rede pode ser feita em termos de sua sensibilidade, especificidade, valor preditivo positivo (VPP) e valor preditivo negativo (VPN) (Equações de (2.12) a (2.15)). A sensibilidade é calculada pela porcentagem dos eventos epileptogênicos presentes nos sinais que são detectados pela rede. A especificidade é a porcentagem dos eventos que não são epileptogênicos e não são detectados pela rede, de fato. Se a rede identificar um evento epileptogênico, a probabilidade dele o ser fornece o valor preditivo positivo. E, se a rede detectou um evento como não-epileptogênico, a possibilidade deste não ser fornece o valor preditivo negativo [49].

Seja, o número de verdadeiros positivos (VP); o número de falsos positivos (FP); o número de falsos negativos (FN) e o número de verdadeiros negativos (VN):

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (2.12)$$

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (2.13)$$

$$VPP = \frac{VP}{VP + FP} \quad (2.14)$$

$$VPN = \frac{VN}{VN + FN} \quad (2.15)$$

A rede treinada deve responder ao conjunto de teste com uma saída igual a 1 para uma detecção positiva do evento epileptogênico e com uma saída igual a zero, para uma detecção negativa deste evento. No entanto, a saída da rede gera valores absolutos entre 0 e 1 possibilitando uma margem para a detecção positiva ou negativa dos eventos epileptogênicos. Para estipular estas margens de detecção, foram traçadas várias tabelas como a Tabela 2.1, que apresenta os resultados, em módulo, obtidos na saída da rede junto à meta, ou a saída desejada. A saída da rede geralmente apresenta valores maiores do que 0,9 para uma meta igual a 1, contudo apresenta também resultados entre 0,7 e 0,9 representando a detecção positiva do evento epileptogênico cuja saída é 1. Geralmente, mais de 70% dos valores de saída correspondentes à meta igual a 1 estão entre 0,9 e 1, cerca de 15% estão entre 0,8 e 0,7 e 15% entre 0,7 e 0,8. Utilizando uma faixa de detecção positiva entre 0,7 e 1 todas estas detecções positivas corretas são consideradas, aumentando o número de verdadeiros positivos, embora aumente a possibilidade de falsos positivos.

Uma análise semelhante foi realizada para definir a faixa de detecção negativa do evento epileptogênico. Geralmente, a saída, em módulo, apresenta valores menores do que 0,1 para uma detecção negativa ou meta igual a zero. Contudo, apresenta cerca de 30% dos seus resultados entre 0,1 e 0,3, que correspondem à saída igual a zero. Foi proposto, neste trabalho, então, uma faixa de 0 a 0,3 para a detecção negativa do evento, a qual engloba um número significativo de sinais que realmente não apresentam eventos epileptogênicos, aumentando o número de verdadeiros negativos.

A Tabela 2.1 mostra em negrito e vermelho os casos onde houve um acerto da rede.

Tabela 2.1- Resultados, em módulo, obtidos pela rede com entrada sem pré-processamento dos sinais.

Saída Desejada	0	1	0	1	1	0	0
Saída Obtida	0,3450	0,4291	0,8767	0,2543	0,4836	0,8772	0,9296
Saída Desejada	1	0	1	0	0	0	1
Saída Obtida	0,7999	0,1338	0,7258	0,7305	0,9817	0,6122	0,9376
Saída Desejada	1	0	1	0	0	1	1
Saída Obtida	0,9142	0,1413	0,9130	0,0562	0,9616	0,8865	0,8482
Saída Desejada	0	0	1	0	1	0	0
Saída Obtida	0,1354	0,9835	0,1591	0,2315	0,9877	0,2149	0,3650
Saída Desejada	0	1	1	0	1	0	1
Saída Obtida	0,0015	0,9936	0,9812	0,7265	0,9528	0,9838	0,9074
Saída Desejada	0	1	1	0	1	0	1
Saída Obtida	0,3165	0,6290	0,9144	0,5951	0,9664	0,2711	0,3815
Saída Desejada	0	0	0				
Saída Obtida	0,9680	0,9649	0,2188				

Uma faixa mais ampla para a detecção positiva e negativa pode aumentar o número de falsos positivos e negativos, o que diminui as taxas de sensibilidade e especificidade. Uma faixa menor, além das considerações já mencionadas neste trabalho, também aumenta consideravelmente o número de valores indefinidos. Propõe-se, assim, as seguintes margens de valores representativas para a saída das redes:

- Saídas entre $0 \leq y \leq 0,3$ referem-se aos eventos não-epileptogênicos;
- Saídas entre $0,7 \leq y \leq 1$ referem-se aos eventos epileptogênicos.

Considerou-se os valores de saídas maiores do que 0,3 e menores do que 0,7 como indefinidos.

2.5 Síntese da Configuração das Redes

O esquema montado na Figura 2.7 ilustra o processo de definição das redes, considerando a possibilidade dos sinais de entrada serem pré-processados, ou não, conforme o número de neurônios na camada oculta.

Contudo, é importante ressaltar alguns trabalhos que abordam o uso de RNA em processamento de sinais, os quais contribuíram com informações úteis no decorrer deste estudo. Estes trabalhos foram publicados por Luo [50], Hu e Hwang [51] e Wisbeck [52].

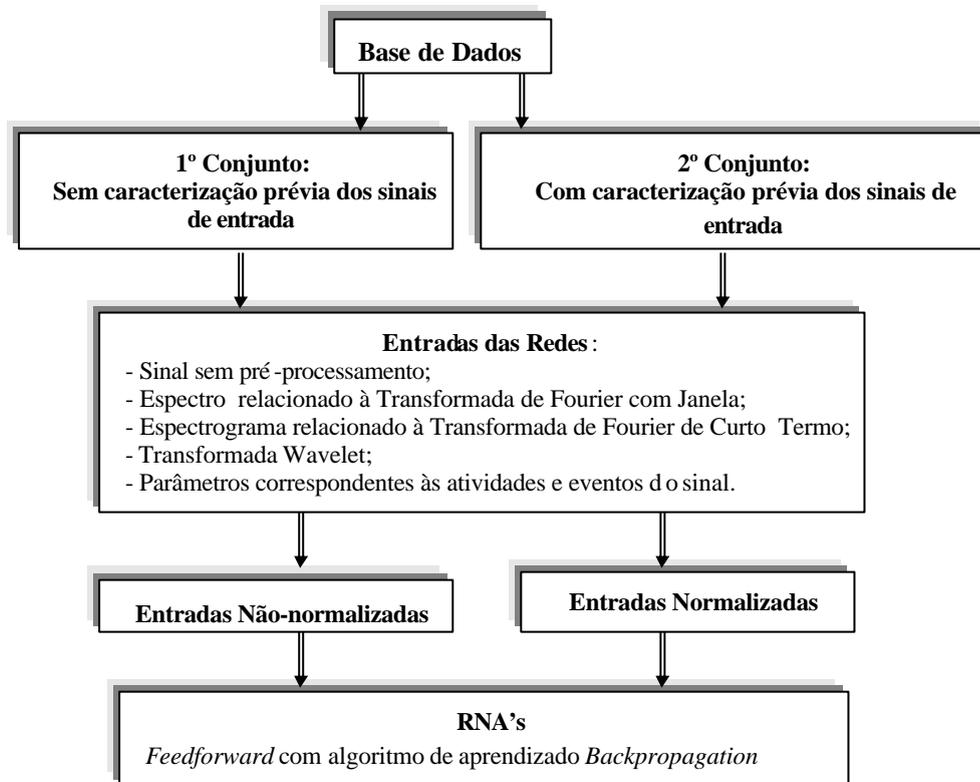


Figura 2.7- Propostas deste trabalho para o sistema de redes.

2.6. Considerações Finais do Capítulo

Este capítulo mostra uma síntese dos principais fundamentos teóricos relacionados às RNA's. Descreve as redes neurais artificiais propostas neste trabalho; os arquivos de treinamento e teste; o método de avaliação dos resultados das redes e finalmente a síntese da configuração de redes deste trabalho.

CAPÍTULO 3

3. RNA'S COM ENTRADAS SEM PRÉ-PROCESSAMENTO

O uso de sinais sem pré-processamento, tais como os obtidos pelo eletroencefalograma, não gerou um estudo adicional, já que os sinais foram simplesmente obtidos e processados pela RNA.

A atenção necessária no caso das RNA's com entradas de sinais sem pré-processamento é a organização dos arquivos de treinamento. Foram propostos dois tipos de arquivos formados por sinais com e sem eventos epileptogênicos. O primeiro arquivo contendo sinais sem definir previamente suas características morfológicas, classificado como o conjunto sem caracterização prévia dos sinais de entrada. E, o segundo contendo sinais com suas características morfológicas previamente definidas, classificado como o conjunto com caracterização prévia dos sinais de entrada. Estes arquivos foram formados por conjuntos diferentes, para treinamento e teste, os quais foram descritos no Capítulo 2 deste trabalho.

Este capítulo descreve as entradas e as saídas das redes com entradas sem pré-processamento, os treinamentos e os testes, os resultados e a análise dos resultados e finalmente as conclusões e as discussões sobre os resultados obtidos.

3.1 Entradas e Saídas das Redes

Os sinais sem pré-processamento destinados às entradas da rede foram obtidos diretamente do banco de dados. Cada sinal é identificado pelo registro de origem, um dos 9 registros apresentados na base de dados, seu canal correspondente e o trecho de 1 segundo destacado do canal. A Figura 3.1 mostra o canal 21 do registro "vad2_2655", apresentando um evento epileptogênico entre os pontos 400 a 500. Pode-se certificar a existência de 1 segundo de sinal entre estes pontos. Os sinais contendo outros eventos são identificados da mesma forma, como as piscadas na Figura 3.2, como o EEG normal de fundo mostrado na Figura 3.3, as ondas alfa na Figura 3.4 e os ruídos na Figura 3.5.

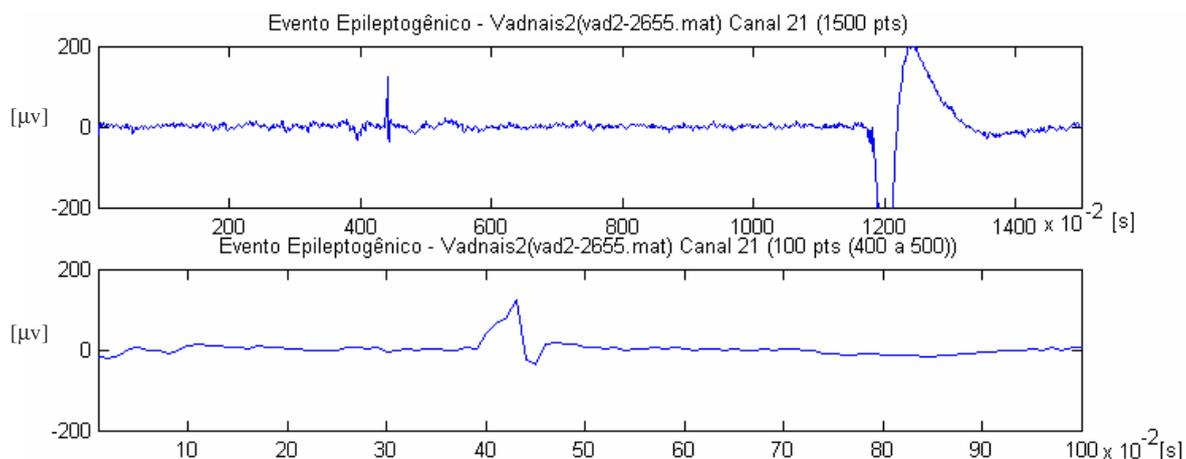


Figura 3.1- Amostra de um canal e seu respectivo trecho de 1 segundo, 100 pontos, de um registro contendo evento epileptogênico.

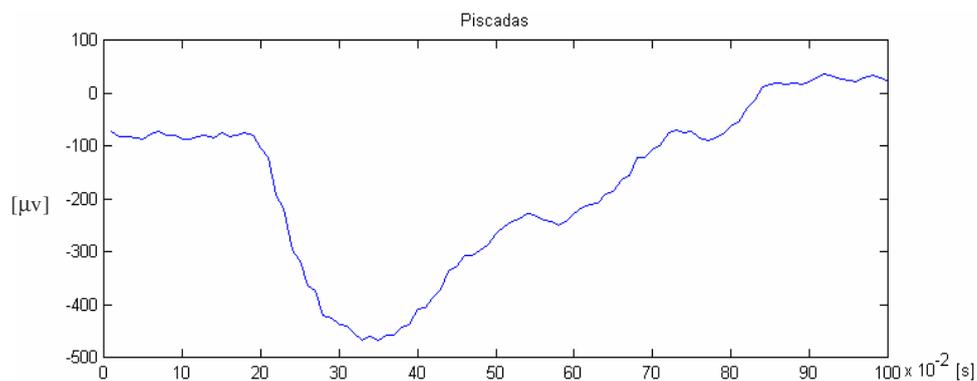


Figura 3.2- Amostra de um trecho de 1 segundo, 100 pontos, de um registro contendo piscada.

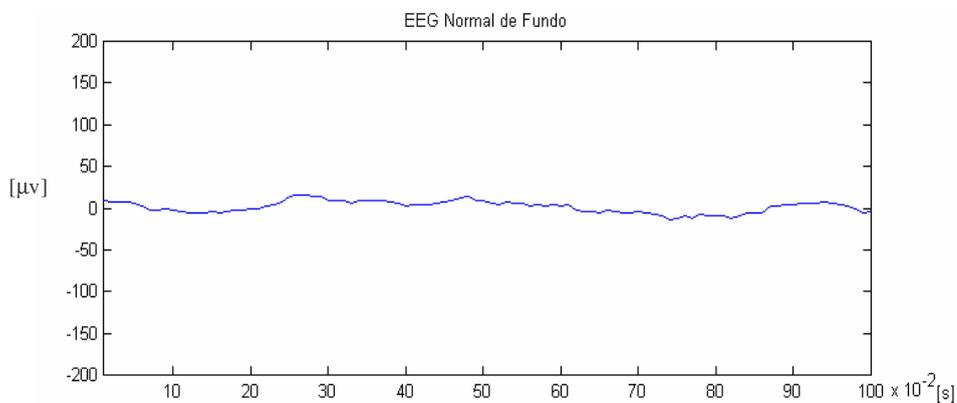


Figura 3.3- Amostra de um trecho de 1 segundo, 100 pontos, de um registro contendo EEG normal de fundo.

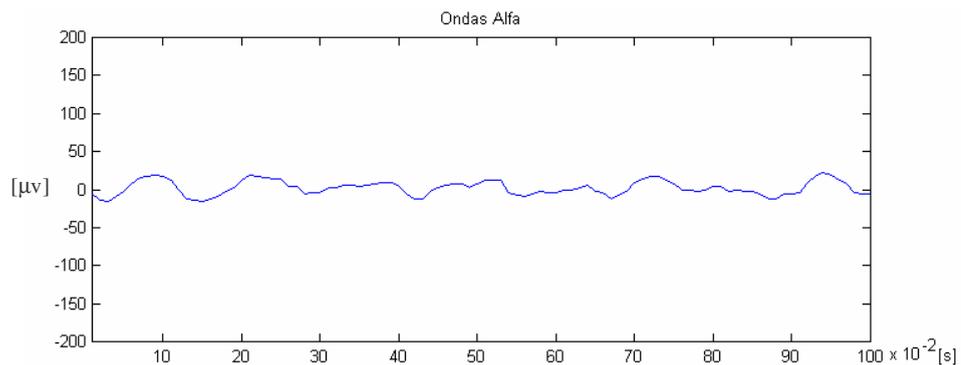


Figura 3.4- Amostra de um trecho de 1 segundo, 100 pontos, de um registro contendo ondas alfa.

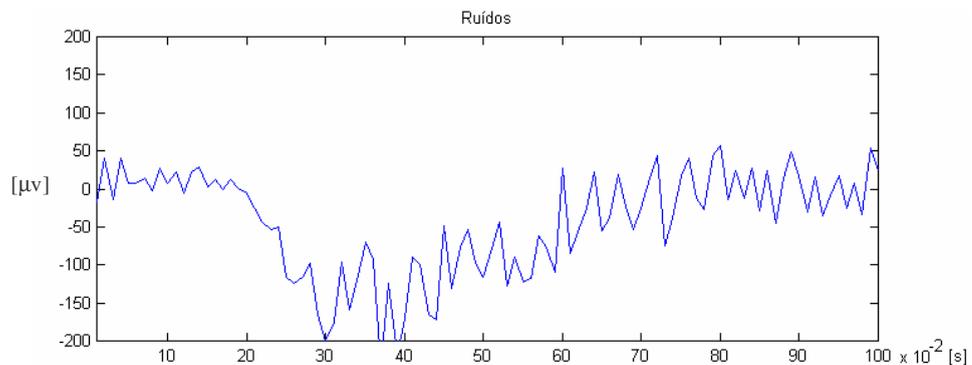


Figura 3.5- Amostra de um trecho de 1 segundo, 100 pontos, de um registro contendo ruído.

Os sinais sem pré-processamento foram colocados diretamente nas entradas da rede *feedforward* como esquematizado na Figura 3.6. Os trechos de 1 segundo do conjunto de treinamento foram divididos em 100 pontos na entrada das redes, formadas pelos 100 vetores de entrada, o número de neurônios na camada oculta variando de 10 a 13 e um neurônio de saída. A cada interação a rede foi treinada, até obter-se o erro mínimo (0,001) ou atingir-se o valor máximo de interação pré-definido. Este treinamento forneceu a matriz de pesos, que foi utilizada no algoritmo de teste. Da mesma forma, os trechos de 1 segundo do conjunto de sinais utilizados para teste foram divididos em 100 pontos na entrada da rede. Para cada sinal de teste a rede responde, conforme a matriz de pesos de treinamento, com uma detecção positiva ou negativa do evento epileptogênico.

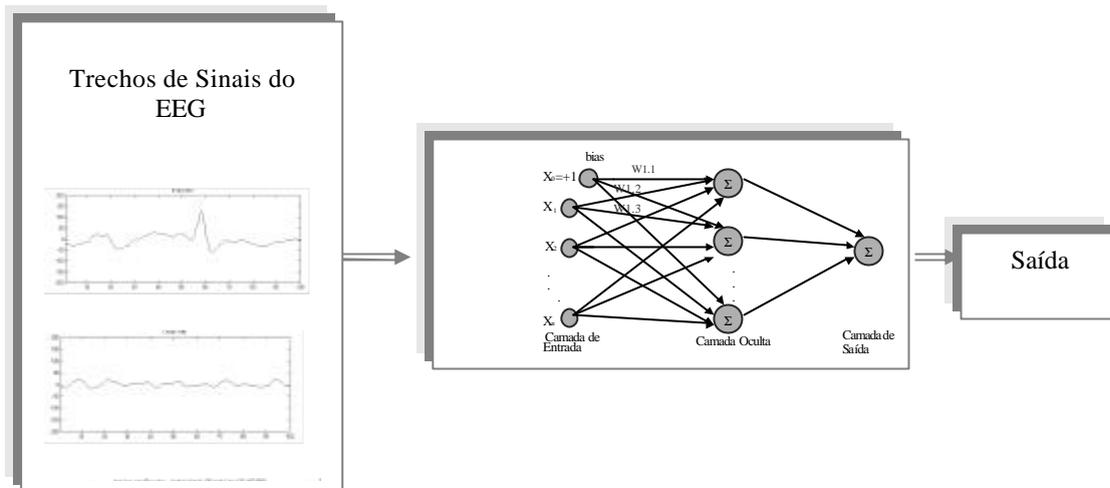


Figura 3.6- Esquema simplificado de uma rede com sinais sem pré-processamento em suas entradas.

3.2 Treinamento e Testes

A proposta para dois arquivos de treinamento gera duas linhas de abordagem para a entrada da rede. A primeira contendo sinais com e sem eventos epileptogênicos sem preocupar com a forma de onda destes sinais, e uma segunda, cujos sinais possuem os principais eventos e as atividades geralmente encontradas em trechos de sinais do EEG contendo eventos epileptogênicos. Uma organização para as redes propostas, mostrando suas variações segundo cada linha de abordagem e os tipos de análises desejadas, encontra-se no Capítulo 2 e na Figura 3.7 deste trabalho.

3.2.1 RNA sem caracterização prévia dos sinais de entrada

Para a abordagem com arquivos sem caracterização prévia dos sinais de entrada foram propostos dois tipos de testes. O primeiro teste usou 53 sinais com e sem eventos epileptogênicos e o segundo teste usou os 53 sinais acrescidos de mais 5 sinais contendo piscadas, para avaliar a capacidade de generalização da rede em identificar este tipo de evento.

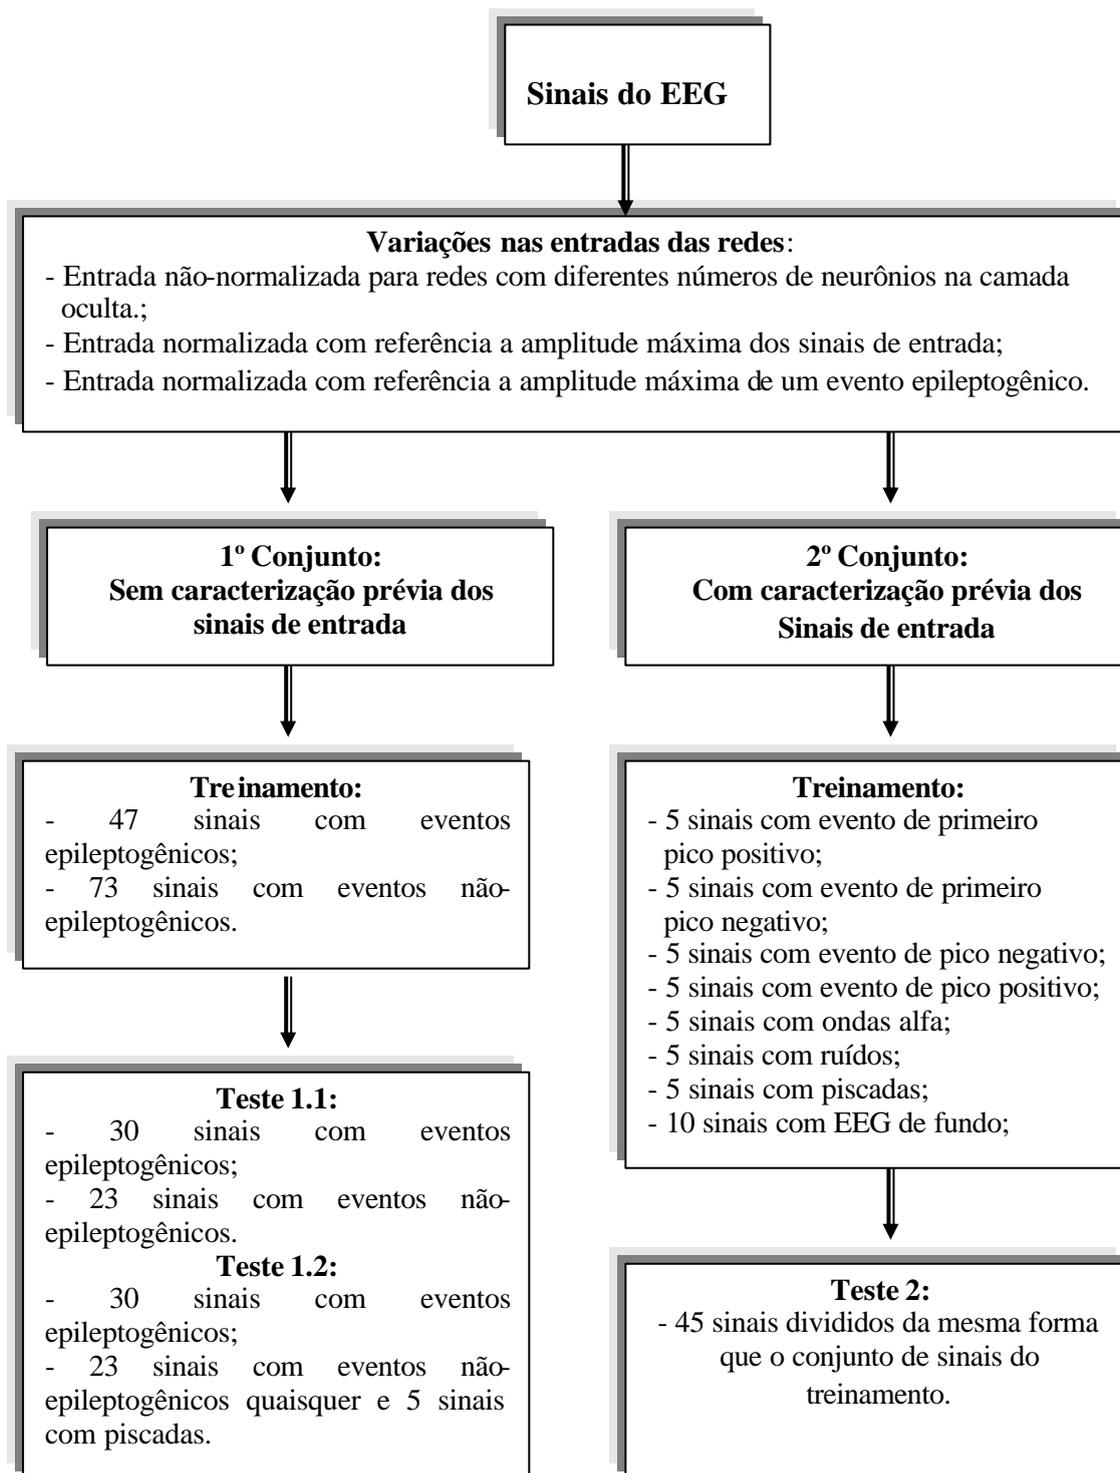


Figura 3.7- Desenvolvimento das RNA's para sinais sem pré-processamento.

Foram treinadas redes variando o número de neurônios na camada oculta, estipulando um número máximo de 100.000 interações. E, quando a rede não alcançou o erro máximo estipulado (0,001) a rede foi novamente treinada com 300.000 interações.

Para as entradas normalizadas, foram treinadas redes com as variações de neurônios ocultos que obtiveram melhores resultados, quando treinadas com sinais não normalizados.

Devido à possibilidade dos sinais com amplitudes maiores sobrepujarem a presença de sinais com amplitudes menores, quando usada a normalização, como no caso de algumas piscadas e ruídos anularem a presença de um evento epileptogênico, foram propostas redes onde a normalização foi feita segundo a amplitude máxima de uma evento epileptogênico, isto é, 200 μV , em módulo. Para os trechos dos sinais com amplitudes maiores do que a amplitude máxima do evento epileptogênico foi considerado neste trecho uma amplitude igual a amplitude média deste sinal.

3.2.1 RNA com caracterização prévia dos sinais de entrada

A segunda linha de abordagem do conjunto de treinamento seleciona os registros dos sinais contendo eventos epileptogênicos e dos sinais contendo eventos não-epileptogênicos, como relatado no Capítulo 2 deste trabalho. A intenção é colocar neste conjunto alguns dos principais tipos de eventos e as atividades encontradas nos sinais do EEG junto aos eventos epileptogênicos.

O conjunto de teste seguiu as mesmas definições do conjunto de treinamento, diferenciando grupos de sinais com e sem eventos epileptogênicos.

Os trechos de 1 segundo dos sinais incluídos nos arquivos de treinamento e teste foram catalogados no Anexo A desta tese.

Estas redes, também, foram treinadas variando o número de neurônios na camada oculta e considerando as entradas normalizadas e não-normalizadas. A normalização, também, foi feita segundo a amplitude máxima de um evento epileptogênico.

3.3 Resultados e a Análise dos Resultados

No Anexo B deste trabalho são encontrados os principais gráficos resultantes do treinamento de cada rede, sendo destacados os que tiverem informações necessárias à análise em desenvolvimento.

Os valores das saídas comparados com a meta forneceram avaliadores como os falsos positivos e negativos. Os falsos positivos são as saídas definidas como eventos

epileptogênicos, mas que na realidade não são eventos epileptogênicos. E, os falsos negativos são as saídas definidas como não sendo eventos epileptogênicos, que na realidade são eventos epileptogênicos. Estes avaliadores, juntamente com a sensibilidade e a especificidade serviram como referências para as análises em torno dos resultados obtidos para cada rede proposta.

3.3.1 Resultados das redes sem caracterização prévia dos sinais de entrada

A primeira finalidade da rede treinada sem definição das características do sinal de entrada é obter a informação do seu comportamento, quando qualquer tipo de sinal for colocado em suas entradas. E, a segunda finalidade é obter as informações a respeito da sua capacidade de identificar como não-epileptogênico mais 5 sinais incluídos no arquivo de teste da RNA contendo piscadas.

A Tabela 3.1 mostra o número de acertos em valor absoluto e percentual, os resultados indefinidos, o número de verdadeiros positivos e negativos, o número de falsos positivos e negativos. A Tabela 3.2 fornece uma avaliação em termos da sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo.

Os valores de acertos, absoluto e percentual, foram calculados baseando-se no número de acertos real. Não foram considerados os valores indefinidos.

Os resultados não variaram com o aumento do número de interações de 100.000 para 300.000, não houve grande melhora que pudesse valer o incremento no tempo de treinamento.

Embora a rede com entrada normalizada e 13 neurônios ocultos apresentasse uma sensibilidade elevada, 0,9, mas ela possuía uma especificidade igual a 0,39, que é considerada baixa.

Os valores altos para o número de falsos positivos revelam que existiam sinais de entrada com características semelhantes às dos eventos epileptogênicos. Este fato possibilitou valores baixos para a especificidade, embora mantinha a sensibilidade com valores elevados.

É observada uma melhora significativa nos resultados, quando a rede foi normalizada com referência à amplitude máxima do evento epileptogênico apresentado em suas entradas. A especificidade melhorou consideravelmente entre a rede com entradas

normalizadas segundo a amplitude máxima dos sinais e a normalizada segundo a amplitude máxima do evento epileptogênico.

Um fator que deve ser levado em consideração, quando se trata do treinamento de uma RNA é o seu tempo de treinamento que, muitas vezes, é relativamente longo. Em geral, o treinamento de uma rede com entradas normalizadas é menor que o tempo de treinamento de uma rede com entradas não-normalizadas, embora isso não reflita a melhor alternativa relacionada à confiabilidade dos resultados. Os gráficos da Figura 3.8 mostram o treinamento de uma rede com entradas normalizadas e uma com entradas não-normalizadas. Estes resultados foram obtidos através da aplicação direta dos algoritmos oferecidos pela ferramenta computacional *Matlab*, utilizando diretamente as suas funções aplicadas na arquitetura para as redes descritas no Capítulo 2 deste trabalho. A rede com entradas normalizadas utilizou 35.627 interações em seu treinamento, enquanto a rede com entradas não-normalizadas utilizou as 100.000 interações estipuladas.

Tabela 3.1- Avaliação da eficiência das redes sem pré-processamento através dos números de acertos, valores indefinidos, verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN), segundo os 53 sinais de teste.

Rede	Acertos Valor absoluto e percentual	Indefinidos	VP	VN	FP	FN
10 N. Ocultos 100.000 Interações	19 36%	20	15	15	8	15
11 N. Ocultos 100.000 Interações	28 53%	12	19	15	8	11
12 N. Ocultos 100.000 Interações	26 49%	14	20	13	10	10
11 N. Ocultos 300.000 Interações	28 53%	12	20	14	9	10
12 N. Ocultos Entrada Normalizada 16.928 Interações	29 55%	7	26	8	15	4
13 N. Ocultos Entrada Normalizada 20.941 Interações	32 60%	7	14	9	27	3
12 N. Ocultos Normalizada por Evento Epileptogênico 77.978 Interações	32 60%	14	25	17	6	5
13 N. Ocultos Normalizada por Evento Epileptogênico 85.453 Interações	34 64%	11	25	17	6	5

Tabela 3.2- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais da Tabela 3.1.

Rede	Sensibilidade	Especificidade	VPP	VPN
10 N. Ocultos 100.000 Interações	0,50	0,65	0,65	0,50
11 N. Ocultos 100.000 Interações	0,63	0,65	0,70	0,58
12 N. Ocultos 100.000 Interações	0,67	0,57	0,67	0,57
11 N. Ocultos 300.000 Interações	0,67	0,61	0,69	0,58
12 N. Ocultos Entrada Normalizada 16.928 Interações	0,87	0,35	0,63	0,60
13 N. Ocultos Entrada Normalizada 20.941 Interações	0,90	0,39	0,66	0,75
12 N. Ocultos Normalizada por Evento Epileptogênico. 77.978 Interações	0,83	0,74	0,81	0,78
13 N. Ocultos Normalizada por Evento Epileptogênico. 85.453 Interações	0,83	0,74	0,81	0,77

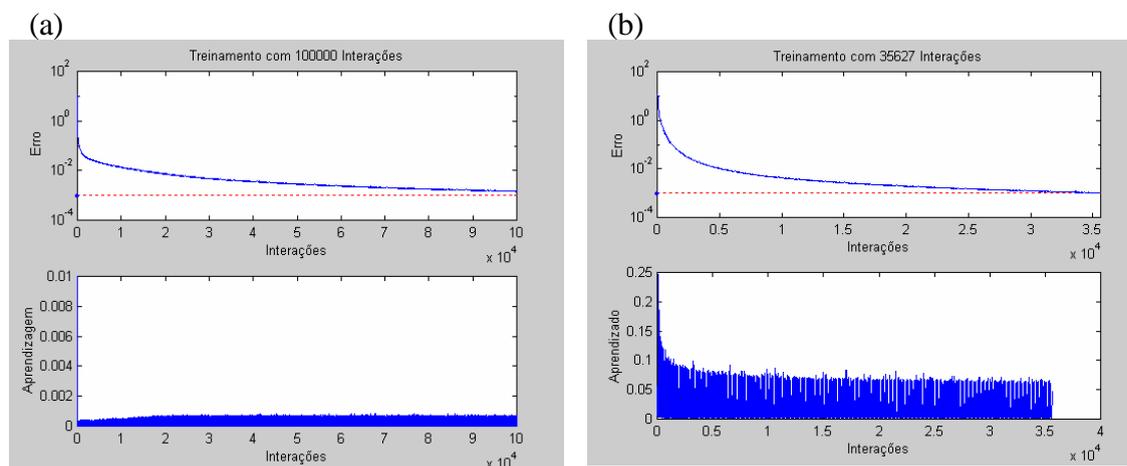


Figura 3.8- Resultados fornecidos por algoritmo *Matlab* durante o treinamento de duas RNA's, usando os mesmos sinais em suas entradas. Em (a), resultados com entradas não-normalizadas. Em (b), resultados com entradas normalizadas.

As Tabelas 3.3 e 3.4 fornecem os resultados desta mesma rede, já treinada, quando em seu conjunto de teste são acrescentados mais cinco sinais contendo piscadas. Estes resultados não possuem uma considerável alteração para os resultados da rede treinada sem as piscadas, contudo é marcante o aumento dos falsos positivos indicando que essas piscadas são confundidas com eventos epileptogênicos.

Um aumento do número de interações do treinamento não acrescenta melhorias significativas nos resultados da rede. A rede com entradas normalizadas segundo a amplitude máxima dos sinais de entrada possui resultados inaceitáveis para a especificidade. Os resultados melhoram quando os sinais são tratados para não ultrapassarem a amplitude máxima de um evento epileptogênico.

Tabela 3.3- Avaliação da eficiência das redes sem caracterização prévia dos sinais de entrada através dos números de acertos, verdadeiros positivos (VP) e negativos (VN) e falsos positivos (FP) e negativos (FN). Foram utilizados 58 sinais de teste, isto é, 30 sinais com eventos epileptogênicos e 28 sinais com os eventos não-epileptogênicos, incluindo os 5 sinais com piscadas.

Rede	Acertos Valor absoluto e percentual	Indefinidos	VP	VN	FP	FN
10 N. Ocultos 100.000 Interações	21 36%	20	15	17	11	15
11 N. Ocultos 100.000 Interações	29 50%	12	19	16	12	11
12 N. Ocultos 100.000 Interações	26 45%	17	20	16	12	10
11 N. Ocultos 300.000 Interações	29 50%	12	20	15	13	10
12 N. Ocultos Entrada Normalizada 16.928 Interações	28 48%	11	25	11	17	5
13 N. Ocultos Entrada Normalizada 20.941 Interações	30 52%	13	24	14	14	6
12 N. Ocultos Normalizada por Evento Epileptogênico 77.978 Interações	32 55%	14	25	17	11	5
13 N. Ocultos Normalizada por Evento Epileptogênico 85.453 Interações	34 59%	12	25	18	10	5

Tabela 3.4- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as redes neurais sem caracterização prévia dos sinais de entrada.

Foram utilizados os 58 sinais de teste.

Rede	Sensibilidade	Especificidade	VPP	VPN
10 N. Ocultos 100.000 Interações	0,50	0,61	0,58	0,53
11 N. Ocultos 100.000 Interações	0,63	0,57	0,61	0,67
12 N. Ocultos 100.000 Interações	0,67	0,57	0,63	0,67
11 N. Ocultos 300.000 Interações	0,67	0,53	0,61	0,69
12 N. Ocultos Entrada Normalizada 16.928 Interações	0,83	0,39	0,60	0,69
13 N. Ocultos Entrada Normalizada 20.941 Interações	0,80	0,50	0,63	0,70
12 N. Ocultos Normalizada por Evento Epileptogênico 77.978 Interações	0,83	0,61	0,70	0,78
13 N. Ocultos Normalizada por Evento Epileptogênico 85.453 Interações	0,83	0,65	0,71	0,78

Para os cinco sinais com piscada acrescentados no arquivo de teste somente um foi detectado corretamente. O número de falsos positivos aumentou, diminuindo a especificidade da rede.

3.3.2 Resultados das redes com caracterização prévia dos sinais de entrada

Os resultados relacionados ao número de acertos, falsos positivos e negativos, valores de sensibilidade e especificidade são encontrados na Tabela 3.5 e Tabela 3.6. Estes resultados confirmam as tendências previstas anteriormente, melhorando sensivelmente a sua confiabilidade, como pode ser certificado através dos valores de sensibilidade e especificidade.

Para o caso da rede com 12 neurônios ocultos e entradas não-normalizadas, observa-se que quase todos os eventos epileptogênicos foram detectados corretamente, gerando um valor 2 para os falsos negativos e um valor de sensibilidade igual a 0,9. A especificidade, em torno de 0,8, pode ser considerada razoável. Contudo, esta rede apresenta alguns falsos positivos e um valor considerável do número de sinais indefinidos.

Tabela 3.5- Avaliação da eficiência das redes através do número de acertos, valores indefinidos, verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN), com entradas sem pré-processamento e com caracterização prévia dos sinais de entrada, segundo os 45 sinais de teste.

Rede	Acertos Valor absoluto e percentual	n° Indefinidos	VP	VN	FP	FN
10 N. Ocultos 100.000 Interações	20 45%	10	13	14	11	7
12 N. Ocultos 100.000 Interações	30 67%	10	18	20	5	2
14 N. Ocultos 100.000 Interações	24 53%	12	17	16	9	3
12 N. Ocultos 300.000 Interações	29 64%	11	18	20	5	2
11 N. Ocultos Entrada normalizada 35.413 Interações	21 47%	14	14	18	7	6
12 N. Ocultos Entrada normalizada 39.484 Interações	24 53%	11	15	17	8	5
13 N. Ocultos Entrada normalizada 35.627 Interações	25 56%	7	16	16	9	4
11 N. Ocultos Entrada normalizada por Evento Epileptogênico 27.369 Interações	24 53%	12	17	17	8	3
12 N. Ocultos Entrada normalizada por Evento Epileptogênico 15.871 Interações	24 53%	10	17	15	10	3

Tabela 3.6- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as redes neurais treinadas com caracterização prévia dos sinais de entrada.

Rede	Sensibilidade	Especificidade	VPP	VPN
10 N. Ocultos 100.000 Interações	0,65	0,56	0,54	0,67
12 N. Ocultos 100.000 Interações	0,90	0,80	0,78	0,91
14 N. Ocultos 100.000 Interações	0,85	0,64	0,65	0,84
12 N. Ocultos 300.000 Interações	0,90	0,80	0,78	0,91
11 N. Ocultos Entrada normalizada 35.413 Interações	0,70	0,72	0,67	0,75
12 N. Ocultos Entrada normalizada 39.484 Interações	0,75	0,68	0,65	0,77
13 N. Ocultos Entrada normalizada 35.627 Interações	0,80	0,64	0,64	0,80
11 N. Ocultos Entrada normalizada por Evento epileptogênico 27.369 Interações	0,85	0,68	0,68	0,85
12 N. Ocultos Entrada normalizada por Evento epileptogênico 15.871 Interações	0,85	0,60	0,63	0,83

Para as redes com entradas normalizadas é notada uma redução da especificidade resultante do aumento do número de falsos positivos, comparadas com as especificidades obtidas pelas redes com entradas não-normalizadas. Os resultados quanto à sensibilidade destacam valores iguais a 0,90 para as entradas não-normalizadas e 0,85 para as entradas normalizadas com referência à amplitude máxima de um evento epileptogênico.

É, então, desaconselhável usar a normalização de sinais tendo como referência a amplitude máxima dos sinais de entrada. Como uma forma de melhorar esses resultados é sugerida neste trabalho uma normalização em relação à amplitude máxima do evento a ser detectado pela rede, no caso um evento epileptogênico.

A normalização mostra uma redução considerável no tempo de treinamento. A RNA com entradas normalizadas necessita de 15.871 interações para atingir o erro 0,001, enquanto a rede com entradas não-normalizadas é treinada até as 100.000 interações máximas.

De certa forma, estes resultados confirmam a hipótese da necessidade de se treinar as redes com alguns dos principais tipos de sinais encontrados no EEG, que possuem probabilidade de estarem juntamente presentes com o evento o qual se deseja identificar.

3.4 Conclusões e Discussões

O uso de sinais sem um pré-processamento na entrada de uma rede neural artificial é questionável, principalmente nos casos dos sinais do EEG. Estes sinais, apesar de possuírem morfologia característica são muito variáveis e imprevisíveis. Em adição, devido à presença de artefatos, alguns sinais podem ser confundidos entre si dificultando sua identificação pela rede. Mesmo com o melhor resultado obtido, a taxa de acertos é considerada pequena.

Nas Tabelas 3.7 e 3.8 estão destacadas as melhores representações para as redes usando o sinal sem pré-processamento como entrada. Observa-se em cada caso a utilização da melhor configuração para o número de neurônios na camada oculta.

Tabela 3.7- Melhores resultados, quanto a porcentagem de acertos, número de verdadeiros positivos e negativos e número de falsos positivos e negativos, fornecidos pelas redes treinadas com sinais sem pré-processamento.

Rede	Acertos Valor absoluto e percentual	Valores Indefinidos	VP	VN	FP	FN
Sem caracterização dos sinais 11 N. Ocultos 100.000 Interações	28 53%	12	19	15	8	11
Sem caracterização dos sinais 13 N. Ocultos Normalizada por Evento Epileptogênico 85.453 Interações	34 64%	11	25	17	6	5
Com caracterização dos sinais 12 N. Ocultos 100.000 Interações	30 67%	10	18	20	5	2
Com caracterização dos sinais 12 N. Ocultos Normalizada por Evento Epileptogênico 15.871 Interações	24 53%	10	17	15	10	3

Tabela 3.8- Melhores resultados, quanto à sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, fornecidos pelas redes treinadas com sinais sem pré-processamento.

Rede	Sensibilidade	Especificidade	VPP	VPN
Sem caracterização dos sinais 11 N. Ocultos 100.000 Interações	0,63	0,65	0,70	0,58
Sem caracterização dos sinais 13 N. Ocultos Normalizada por Evento Epileptogênico 85.453 Interações	0,83	0,74	0,81	0,78
Com caracterização dos sinais 12 N. Ocultos 100.000 Interações	0,90	0,80	0,78	0,91
Com caracterização dos sinais 12 N. Ocultos Normalizada por Evento Epileptogênico 15.871 Interações	0,85	0,60	0,63	0,85

Os resultados quanto a sensibilidade e a especificidade (Tabela 3.8) confirmam que a rede treinada usando a caracterização prévia dos sinais de entrada é a melhor opção para as aplicações de sinais sem pré-processamento.

Pode-se ressaltar o resultado em que as entradas normalizadas segundo a amplitude máxima de um evento epileptogênico apresentam melhores resultados do que as entradas normalizadas segundo a amplitude máxima apresentada por todos os sinais. Os valores de falsos positivos contribuíram para este resultado, diminuindo a especificidade. O número elevado de falsos positivos revela que as redes identificam sinais contendo eventos não-epileptogênicos como se fossem eventos epileptogênicos.

A maior dificuldade encontrada pela rede é distinguir os ruídos dos eventos epileptogênicos, uma vez que ela define arquivos com ruídos como contendo eventos epileptogênicos, refletindo no grande número de falsos positivos, repercutidos nos baixos valores para a especificidade. Na Figura 3.9 é observada a semelhança do sinal com ruídos (em (b)) e um evento epileptogênico (em (a)). Em alguns trechos, os sinais com ruídos apresentam morfologias semelhantes às dos eventos epileptogênicos. O mesmo pode-se dizer da semelhança desses eventos com as piscadas, embora saiba-se que estas aparecem somente em alguns canais e que possuem morfologia bem característica, como mostra o item (c) da Figura 3.9.

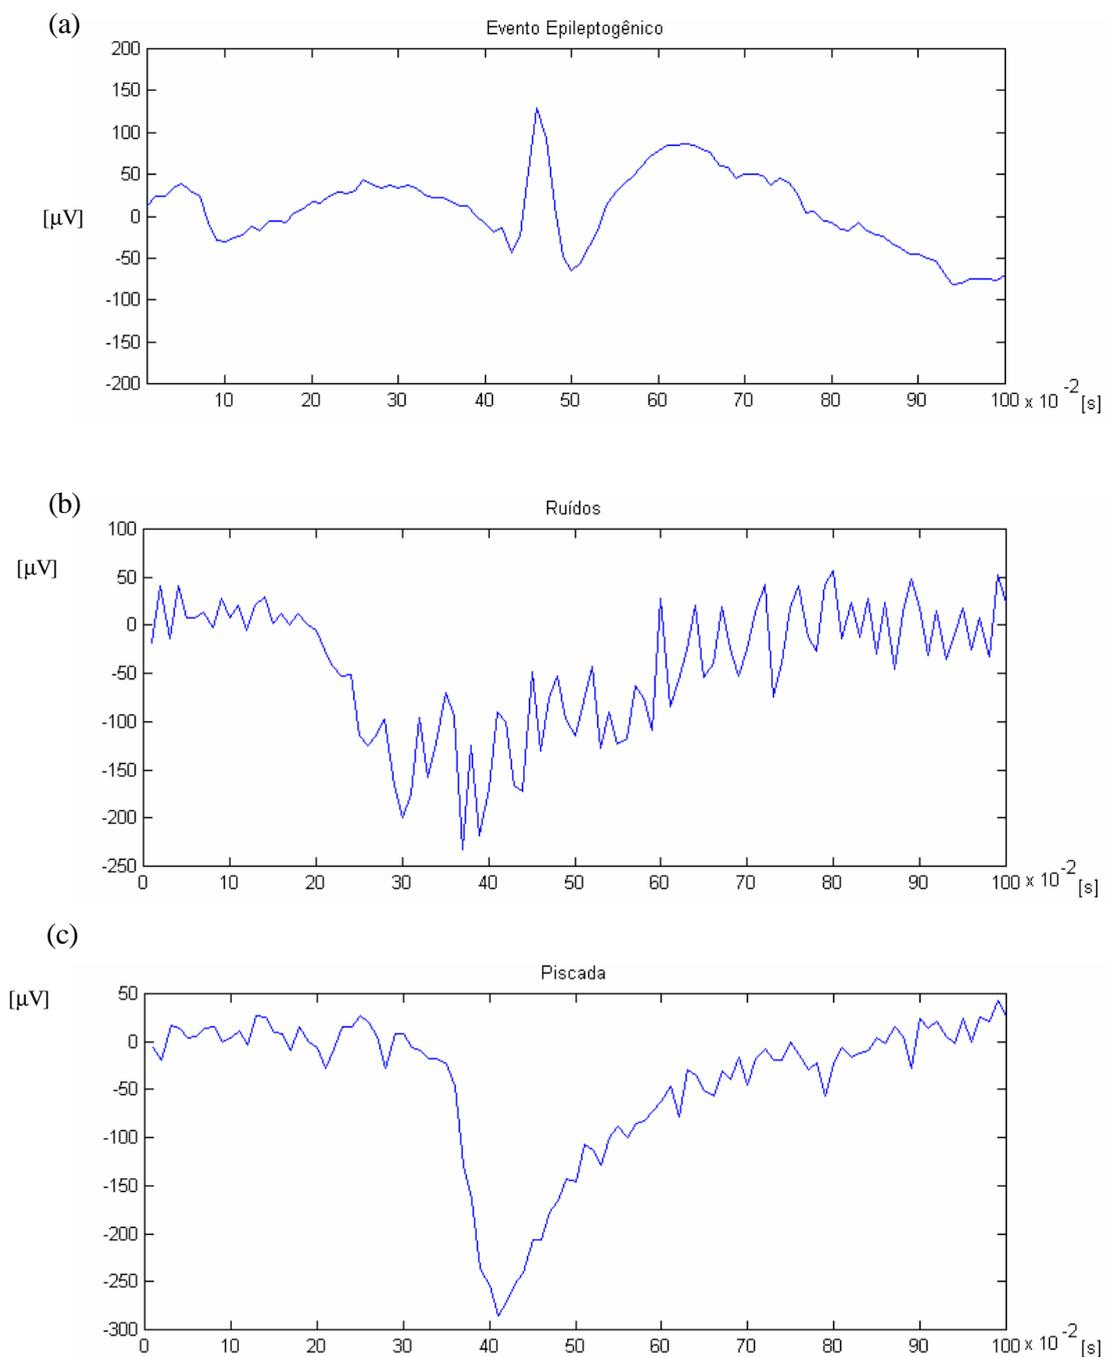


Figura 3.9- Sinais encontrados nos registros do EEG que podem estar juntamente presentes com um evento epileptogênico. Em (a), sinal com um evento epileptogênico. Em (b), sinal com ruídos, cuja morfologia pode ser confundida com a forma espicular. Em (c), uma piscada cuja morfologia pode ser confundida com a morfologia de um evento epileptogênico.

Existem também eventos epileptogênicos com morfologia semelhante a das ondas alfa acompanhadas de longos trechos do EEG de fundo, podendo gerar erros nas respostas da rede, como pode ser observado na Figura 3.10. As dimensões desses eventos, sem considerar a forma espicular, os tornam semelhantes.

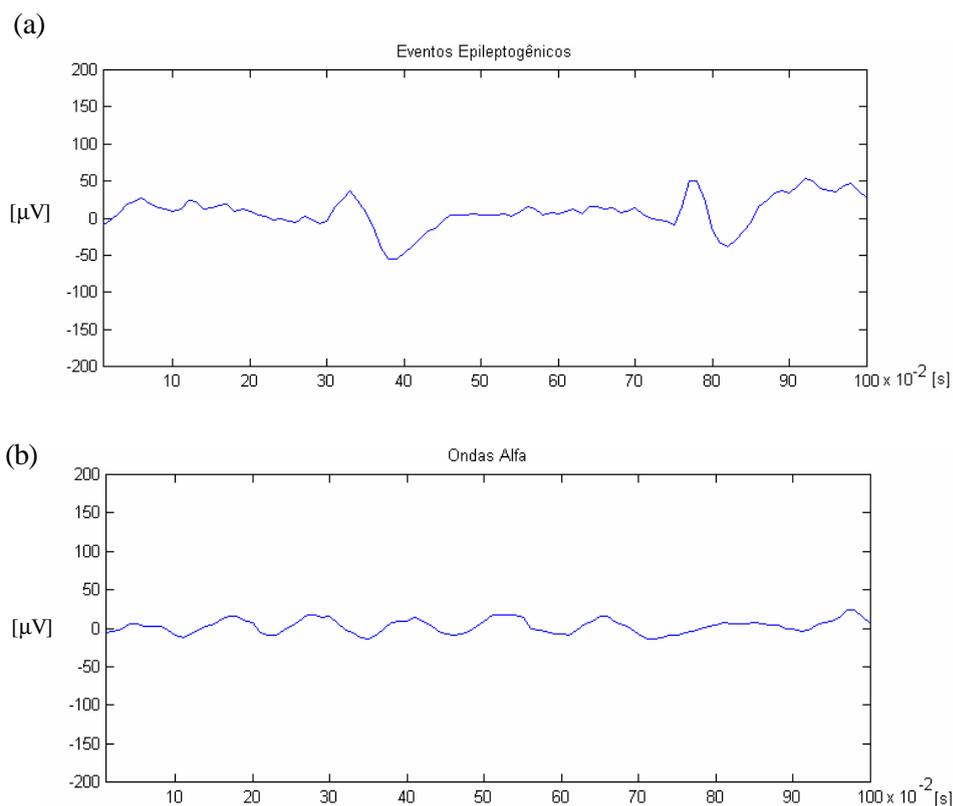


Figura 3.10- Ondas alfa encontradas nos registros do EEG que podem estar presentes juntamente com um evento epileptogênico. Em (a), sinal com evento epileptogênico de amplitude reduzida. Em (b), sinal com ondas alfa cuja morfologia pode ser confundidas com a morfologia do evento epileptogênico.

Alguns eventos epileptogênicos de dimensões reduzidas podem passar pelo EEG de fundo, como os eventos apresentados na Figura 3.11. Este fato pode gerar falsos negativos.

Contudo, os resultados, em geral, não foram muito satisfatórios, o que sugere o uso de um pré-processamento dos sinais na entrada da rede.

Para reduzir-se a taxa de falsos positivos, ao utilizar-se redes sem pré-processamento, é sugerida a retirada de sinais com amplitudes maiores que a faixa de amplitude dos eventos epileptogênicos, isto é, $200 \mu\text{V}$, em módulo. Um esquema desta proposta é mostrado na Figura 3.12.

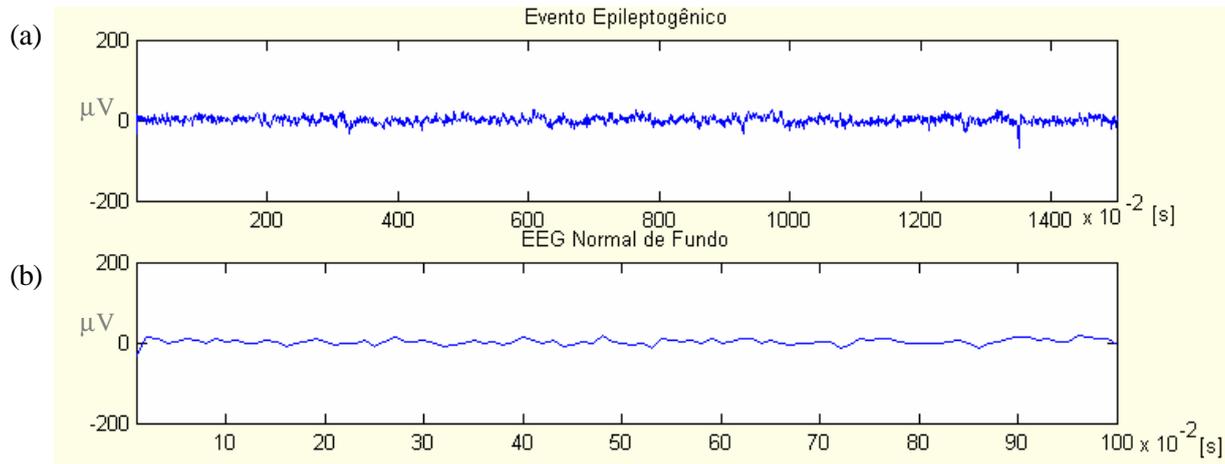


Figura 3.11- Em (a), trecho de 15 segundos de um sinal do EEG contendo eventos epileptogênicos. Em (b) trechos de 15 segundos de sinais do EEG contendo o EEG normal de fundo. As dimensões reduzidas dos eventos epileptogênicos podem fazer com que estes eventos sejam confundidos com sinais normais do EEG de fundo.

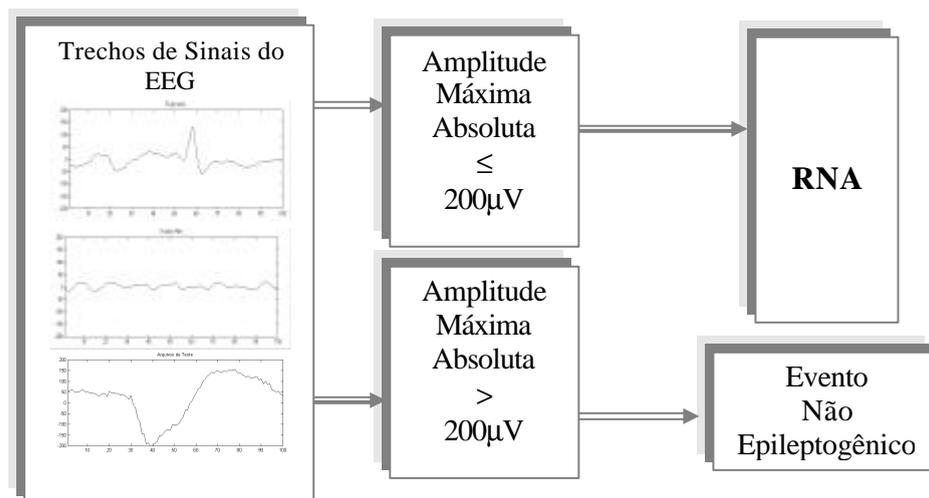


Figura 3.12- Sugestão para o uso de redes neurais para identificar os eventos epileptogênicos tendo como entradas os trechos dos sinais do EEG sem pré-processamento.

CAPÍTULO 4

4. RNA'S COM ENTRADAS PRÉ-PROCESSADAS PELA FFT UTILIZANDO-SE JANELAS

A análise de sinais bioelétricos constitui-se do uso de métodos e ferramentas para sua investigação e pesquisa. Então, é extremamente importante conhecer as limitações e as aplicações de cada um. A confiabilidade dos resultados é diretamente proporcional à satisfação das hipóteses sobre as quais o método foi baseado. Deve-se satisfazer as condições como estacionaridade, dimensionalidade apropriada, localização no tempo e frequência ou distribuição de energia, antes da aplicação de um determinado método.

Os sinais bioelétricos de interesse neste trabalho são essencialmente não-estacionários, estando classificados no ramo pertencente aos sinais estocásticos da Figura 4.1. Portanto, para se utilizar determinado tipo de método matemático no processamento de sinais não-estacionários é necessário adequar-se a forma com que este sinal deve ser processado.

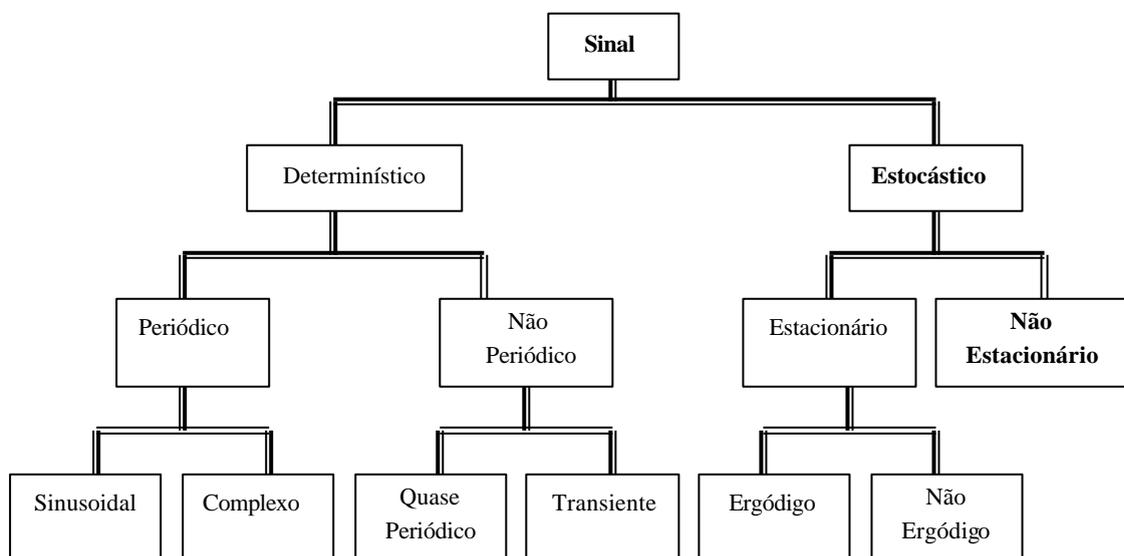


Figura 4.1- Organização usada na classificação de sinais, destacando-se a posição do sinal estocástico não-estacionário, por representar a linha de características dos sinais do EEG

O uso do tratamento matemático baseado em definições no domínio da frequência e na determinação dos espectros é um método de análise utilizada para sinais bioelétricos, devido ao fato de alguns eventos apresentarem frequências bem características. Estudos relativos ao espectro de frequências são bastante encontrados nos casos de análise de sinais do eletrocardiograma (ECG), devido, talvez, à sua relativa periodicidade. Dentre os estudos envolvendo a análise espectral de sinais de ECG, pode-se citar os desenvolvidos por: Silva [53], que fez uma comparação entre a Transformada Rápida de Fourier (*Fast Fourier Transform*: (FFT)) e o sinal sem pré-processamento; Pinna [54], fez uma comparação entre a FFT e o método Auto-Regressivo; Chen [55], usou a FFT para sinais de batimento cardíacos; Brennan [56], fez uma detalhada análise da transformada de Fourier discreta e Minami [57], usou diretamente a FFT sobre o sinal de interesse.

Estudos relacionados às frequências características de certos eventos encontrados em sinais do EEG são relatados em diversas publicações e, na maioria das vezes, é marcante o uso das formas de Fourier, sobretudo da FFT. Bokehi [4] usou a técnica da FFT com periodogramas (algoritmo de Blackman-Tukey) e a modelagem Auto-Regressiva, para determinar frequências dos sinais no EEG, mostrando que a modelagem auto-regressiva consegue detectar componentes de frequências bem próximas. Muthuswamy [5] fez um estudo dos métodos de análise espectral usando a FFT com a janela de Hamming e o método Auto Regressivo, ressaltando as vantagens do método auto-regressivo em relação à FFT. Glaria [58] usou a FFT junto a Densidade Espectral de Potência e a janela de Hamming para analisar sinais do EEG, em uma avaliação de técnicas anestésicas. Simpson [59] fez uma análise das janelas retangular e de Hamming para aplicação em sinais do EEG. Ferdjallah [60] fez um estudo sobre a análise do EEG utilizando a FFT truncada através de uma função *sinc*. Pilla [35] calculou através da FFT as frequências que seriam utilizadas como padrões nos mapas de Kohonen. Garoosi [61] apresentou um método baseado na Densidade Espectral de Potência junto com a FFT para o cálculo da frequência máxima e mínima dos sinais do EEG. Hansson [62] fez uma extensiva comparação entre o espectro obtido pelo método de múltiplas janelas e janelas de Hamming, bem como o espectro obtido usando os algoritmos auto-regressivo de média móvel (*autoregressive moving average* (ARMA)) e média ponderada de segmentos sobrepostos (*weighted overlapped segment averaging* (WOSA)). Vários estudos já publicados (Celka [63], Ramos [64,65], Ortolani [66], Rezek [67], Conradt [68]) utilizam algum método de análise espectral para investigações em sinais do EEG.

Este capítulo descreve as representações de Fourier, a representação de Fourier com janela, a definição de uma janela adequada para sinais do EEG contendo eventos epileptogênicos, as entradas e as saídas das redes com pré-processamento utilizando a Transformada de Fourier com janela, o treinamento e os testes das RNA's com entradas pré-processadas pela Transformada de Fourier com janelas e finalmente são mostrados os resultados obtidos e é realizada uma análise desses resultados.

4.1 As Representações de Fourier

A transformada de Fourier em sua forma discreta, comumente aplicada através do algoritmo da Transformada Rápida de Fourier (*Fast Fourier Transform* (FFT)) mostra algumas limitações ao trabalhar com sinais bioelétricos, que são, em essência, *estocásticos* não-estacionários. Contudo, ela é uma poderosa ferramenta para definir as componentes de frequência dos sinais. As explicações teóricas em torno das representações de Fourier são temas de relatos em diversas publicações, sendo largamente estudada por vários autores, tais como: Akay [69], Cohen [70], Haykin [71], Kraniuskas [72], Oppenheim [73], Poularikas [74], Tompkins [75], Ingle [76], Krauss [77], Siqueira [78], Gomes [79].

Estas publicações detalham minuciosamente todos seus processamentos matemáticos. Anexo C deste trabalho mostra resumidamente suas principais formulações.

4.1.1 Representação da Transformada de Fourier na forma discreta

Para operações com funções relativamente simples, a transformada de Fourier representou uma formidável operação por muitos anos. Antes do desenvolvimento dos computadores digitais, muitos métodos analíticos e experimentais foram investigados para se determinar o espectro aproximado das funções originadas em sistemas físicos. Com a computação digital, a Transformada Contínua de Fourier sofreu modificações, de modo a definir um par de transformadas adequadas aos sistemas discretos. A Série de Fourier de Tempo Discreto é a forma de Fourier utilizada em computadores digitais, e tanto a sua representação no domínio do tempo, $x[n]$, como a sua representação no domínio da frequência, $X[k]$, são caracterizadas por um conjunto finito de N números. A Transformada de Fourier Discreta no Tempo é obtida a partir da Série de Fourier de Tempo Discreto, descrevendo um sinal não-periódico como limite de um sinal periódico, cujo período, N ,

aproxima-se do infinito. Este processo foi bem detalhado por alguns autores como Haykin [71] e Oppenheim [73], estando, também, descrito no Anexo C deste trabalho.

A representação da Transformada de Fourier para sinais discretos no tempo satisfaz as propriedades desta transformada, tornando-a uma ferramenta poderosa para analisar os problemas que envolvem as combinações de tempo discreto e contínuo. As propriedades como a simetria, linearidade, deslocamento em frequência e do deslocamento no tempo. Esta representação é bem detalhada no *teorema da amostragem*, que possibilitam à Transformada de Fourier ser usada como uma ferramenta de análise, para as quatro classes de sinais mostradas na Figura 4.1. Este teorema é alvo de estudos em muitos textos de processamento digital de sinais e está bem detalhado por Haykin [71], que relata a amostragem dos sinais contínuos no tempo e a subamostragem, que é a amostragem dos sinais discretos no tempo.

4.1.2 Representação utilizando a transformada rápida de Fourier

Um grande número de multiplicações e adições é necessário para o cálculo da forma discreta de Fourier. Cada termo consiste da multiplicação de um termo exponencial, o qual é sempre complexo, por outro termo, que pode ser real ou complexo. Cada um destes termos é adicionado ao outro, sendo necessárias $(N)^2$ multiplicações complexas e mais ou menos o mesmo número de adições complexas, no cálculo do espectro para um valor particular de k . Portanto, é necessário uma forma de reduzir este volume de cálculos. Pode-se notar que existe uma quantidade considerável de redundância nas equações do cálculo da Transformada Discreta de Fourier.

O algoritmo de Cooley-Tukey, publicado em 1965 (*An Algorithm for Machine Calculation of Complex Fourier Series, Mathematics of Computation*) estabeleceu um caminho para executar esta transformação com um número de operações da ordem de $N \log_2 N$, o qual propiciou uma enorme economia no tempo de computação para grandes conjuntos de amostras de sinais. Este algoritmo é conhecido como Transformada Rápida de Fourier (*Fast Fourier Transform (FFT)*). No Anexo C deste trabalho são encontrados relatos e formulações presentes no desenvolvimento da FFT.

Contudo, o cálculo da Transformada de Fourier é feito em todo o intervalo para o qual o sinal é definido. Assim, os conjuntos diferenciados de componentes de frequência se

confundirem em um único espectro de frequência sem qualquer relação com o tempo em que ocorrem.

Em alguns estudos que abordam a Transformada de Fourier são relatadas críticas quanto à sua eficiência, quando é aplicada em determinados casos, e estas críticas geralmente baseiam-se em três fatores:

- 1- A Transformada de Fourier define as componentes de frequência do sinal, mas não define como estas componentes estão distribuídas no tempo. Um transiente no sinal não possui a localização no tempo em que ocorreu.
- 2- Para sinais com diferentes eventos, porém de frequências componentes iguais, a Transformada de Fourier representa em um único espectro as várias componentes desta frequência.
- 3- A Transformada de Fourier é mais apropriada como ferramenta de processamento de sinais estacionários enquanto na maioria dos casos reais os sinais são originalmente não-estacionários, como por exemplo os sinais bioelétricos.

4.1.3 Representação no domínio da frequência utilizando a densidade espectral de potência

A representação da Transformada de Fourier realmente possui limitações para o tratamento de sinais bioelétricos. Neste caso sua aplicação, para obter as componentes de frequência destes tipos de sinais, deve ser baseada no uso de uma janela de dados aliada à densidade espectral de potência (*Power Spectral Density Function (PSD)*), cujas definições e relatos encontram-se no Anexo C deste trabalho. Cohen [70, 81] é um dos autores que descreve longamente este tema citando exemplos da aplicação de PSD em EEG para a análise de detalhes espectrais aplicada à classificação automática de estágios do sono, dependência anestésica, bem como a classificação de uma variedade de desordens neurológicas.

A energia ou potência do sinal são preservadas na representação de Fourier. A potência é definida como a integral ou o somatório do módulo do sinal elevado ao quadrado, ao longo de um período normalizado pela duração do período. O espectro de potência ou energia de um sinal é definido como o quadrado do espectro de magnitude. Eles indicam como a potência ou a energia do sinal são distribuídas em função da

freqüência. A forma discreta do espectro de energia, $|X(jw)|^2$ é representada pela relação de Parseval definida na Equação (4.1) [70].

$$E = \frac{1}{N} \sum_{n=0}^{N-1} |x(n)|^2 = \sum_{k=0}^{N-1} |X(k)|^2 \quad (4.1)$$

onde:

N é o número de amostras;

x(n) é a amplitude do sinal no domínio do tempo;

X(k) é a amplitude do sinal no domínio da freqüência.

4.2 A Representação da Transformada de Fourier Utilizando Janela

O uso de janelas em conjunto com a transformada de Fourier é um artifício útil em muitos registros de longa duração, onde a multiplicação do sinal por uma janela de duração finita zera o sinal fora do período de observação.

Uma função janela, representada no domínio do tempo por $w(t)$, com transformada de Fourier $W(w)=F[w(t)]$, pode ser representada como mostrada na Figura 4.2. Nesta representação são mostrados os lóbulos laterais, como parte da curva destacada por (b), e a metade do lóbulo principal, como parte da curva destacada por (a). O lóbulo principal é definido como a faixa de freqüência entre o primeiro cruzamento por zero de sua resposta em freqüência $W(e^{jW})$ nos dois lados da origem. As regiões de transição individual que se situam nos dois lados do lóbulo principal são os lóbulos laterais.

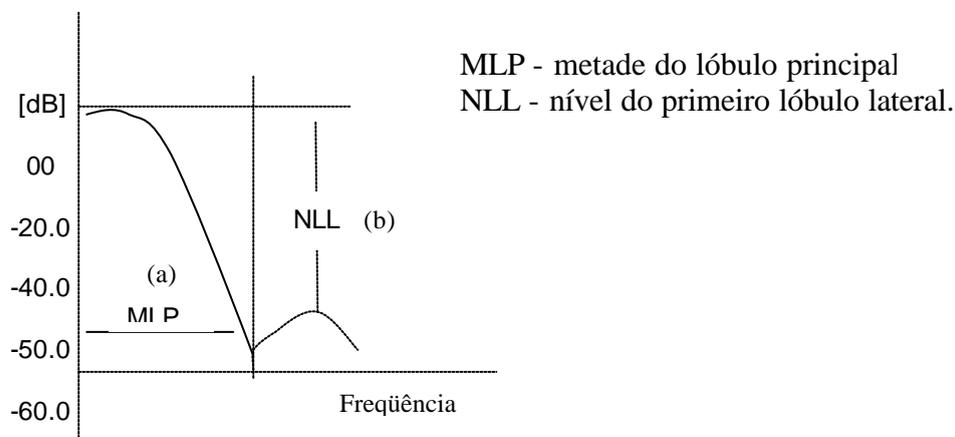


Figura 4.2- Uma janela típica no domínio da freqüência.

É comum relacionar-se a performance de uma janela ao comprimento dos seus lóbulos, quando esta é representada no domínio da frequência. Os lóbulos laterais são a consequência das aproximações oscilatórias da resposta em frequência. O ideal é uma janela que reduz ao máximo estas oscilações, isto é, que apresente lóbulos laterais reduzidos ou um maior nível para o primeiro lóbulo lateral.

Segundo Cohen [70], geralmente usa-se estimar a densidade espectral de potência junto às aplicações com a janela, para reduzir a dispersão espectral. No entanto, para cancelar-se completamente a dispersão espectral é necessário o uso de uma janela que se comporta como uma função delta no domínio da frequência, porém, tal janela não é possível sua execução. Para definir uma janela, que se assemelha a esta janela ideal, é requerido que esta tenha a metade do lóbulo principal e o nível dos lóbulos laterais os menores possíveis.

4.2.1 As janelas clássicas

Em síntese, as janelas clássicas definidas pela literatura são: a retangular, a triangular, a de Bartlett, a de Hamming, a de Hanning, a de Blackman, a de Kaiser e a de Chebyshev. A finalidade é escolher uma delas, para ser utilizada na obtenção do espectro de frequências dos sinais do EEG em estudo. As formulações referentes a cada janela no domínio do tempo e suas correspondentes Transformadas de Fourier são encontradas no Anexo C deste trabalho.

A janela retangular é uma janela simples e muito utilizada. Contudo, seu desempenho usualmente não é satisfatório, devido à suas alterações bruscas no domínio do tempo, as quais originam o fenômeno de *Gibbs*. O fenômeno de *Gibbs* são oscilações no domínio da frequência.

Uma janela triangular é definida de forma a não possuir variações bruscas, como a janela retangular. A janela de Bartlett é uma versão da janela triangular deslocada, isto é, a Bartlett $(n+2)$ é igual a triangular (n) .

As janelas de Hanning, de Hamming, e de Blackman são combinações de seqüência de senóides com frequências $0,2p / (N-1)$ e $4p / (N-1)$, onde N é o comprimento da janela. Estas janelas diferem entre si apenas por três variáveis, que possuem valores fixos e próprios para cada uma.

A janela de Chebyshev minimiza a amplitude do lóbulo principal, para uma altura do lóbulo lateral. É caracterizada por lóbulos laterais com a mesma altura como mostra a Figura 4.3 (a). E a janela de Kaiser é uma janela na qual a taxa de energia do lóbulo principal é maximizada. Possui os níveis dos lóbulos laterais decrescentes à medida que se distanciam do lóbulo principal como mostra a Figura 4.3 (b).

4.2.2 Análise dos lóbulos laterais e do lóbulo principal das janelas clássicas

A difícil ponderação entre os lóbulos laterais e o lóbulo principal para obter-se melhores resultados na utilização das janelas clássicas direciona um estudo de janelas onde as dimensões destes lóbulos podem ser determinadas segundo a necessidade. Dentre as janelas, que possuem em suas equações variáveis que atuam nestes lóbulos, destacam-se as janelas de Chebyshev e de Kaiser.

Nas equações referentes a cada janela, apresentadas no Anexo C deste trabalho, observa-se que na equação da janela de Chebyshev aparece uma variável α e na equação da janela de Kaiser aparece uma variável β . Estas variáveis são relacionadas aos lóbulos, apresentados por estas janelas no domínio da frequência. Assim, variando-se os valores destas variáveis, pode-se controlar as dimensões destes lóbulos.

A janela de Chebyshev foi feita para produzir uma mínima amplitude dos lóbulos laterais para um determinado lóbulo principal. A variável α registra a proporção do nível do lóbulo principal pelo nível do lóbulo lateral. Para uma janela de Kaiser de comprimento particular, o parâmetro β controla o lóbulo lateral.

No domínio da frequência, as janelas de Chebyshev e de Kaiser possuem representações semelhantes à Figura 4.3. Foram utilizados para a variável α os valores iguais a 20, 40 e 60. Observa-se que estes valores são iguais aos níveis negativos dos lóbulos laterais. Os valores de β foram escolhidos de forma que a janela de Kaiser apresentasse lóbulos laterais iguais os da janela de Chebyshev. Assim, as janelas de Kaiser foram traçadas com parâmetros β iguais a 1, 4, 9 e, com os níveis dos lóbulos laterais aproximadamente 20, 40 e 60, respectivamente.

À medida que os valores dos parâmetros aumentam a diferença entre o nível do lóbulo principal e o nível do primeiro lóbulo lateral aumenta, mas o valor da largura da base do lóbulo principal também aumenta.

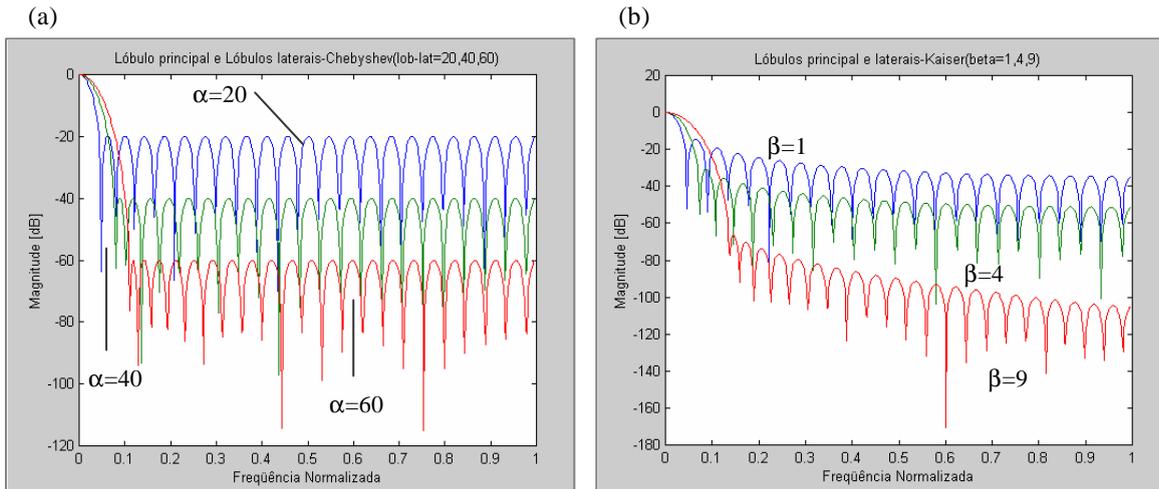


Figura 4.3- Em (a), representações no domínio da frequência para a janela de Chebyshev, de diferentes valores para variável α ($\alpha=20, 40, 60$). Em (b), representações para a Janela de Kaiser, de diferentes valores para a variável β ($\beta=1, 4, 9$).

Para ilustrar, a Figura 4.4 realiza um paralelo entre as janelas retangular, triangular, Hamming, Hanning, Blackman, Chebyshev e Kaiser, segundo o comprimento dos lóbulos.

A janela retangular possui um valor cerca de -16 dB para o nível do primeiro lóbulo lateral, enquanto a janela triangular apresenta o primeiro lóbulo lateral em cerca de -26 dB. A janela de Hamming apresenta uma melhor configuração quanto ao nível do primeiro lóbulo lateral, chegando ao valor de -50 dB, comparada com a janela de Hanning. A janela de Blackman destaca-se a configuração para o primeiro nível dos lóbulos laterais, sendo este maior do que -60 dB, porém possui ampla base do lóbulo principal.

Nas representações para as janelas de Hamming, de Blackman e de Chebyshev a variável α da janela de Chebyshev é definida de forma que sua representação em frequência apresenta o nível do lóbulo principal igual ao da janela de Hamming. E, semelhantemente, a variável β da janela de Kaiser é definida de forma que sua representação em frequência apresente o nível do lóbulo principal igual ao da janela de Hamming e de Blackman.

Em todos os casos, um aumento na diferença entre os níveis do lóbulo principal e o primeiro lóbulo lateral leva também a um aumento na largura da base do lóbulo principal, que é um efeito indesejável. Contudo, dentre as janelas clássicas, pode-se destacar as janelas de Chebyshev e de Kaiser devido à flexibilidade destas em manipular as dimensões dos lóbulos.

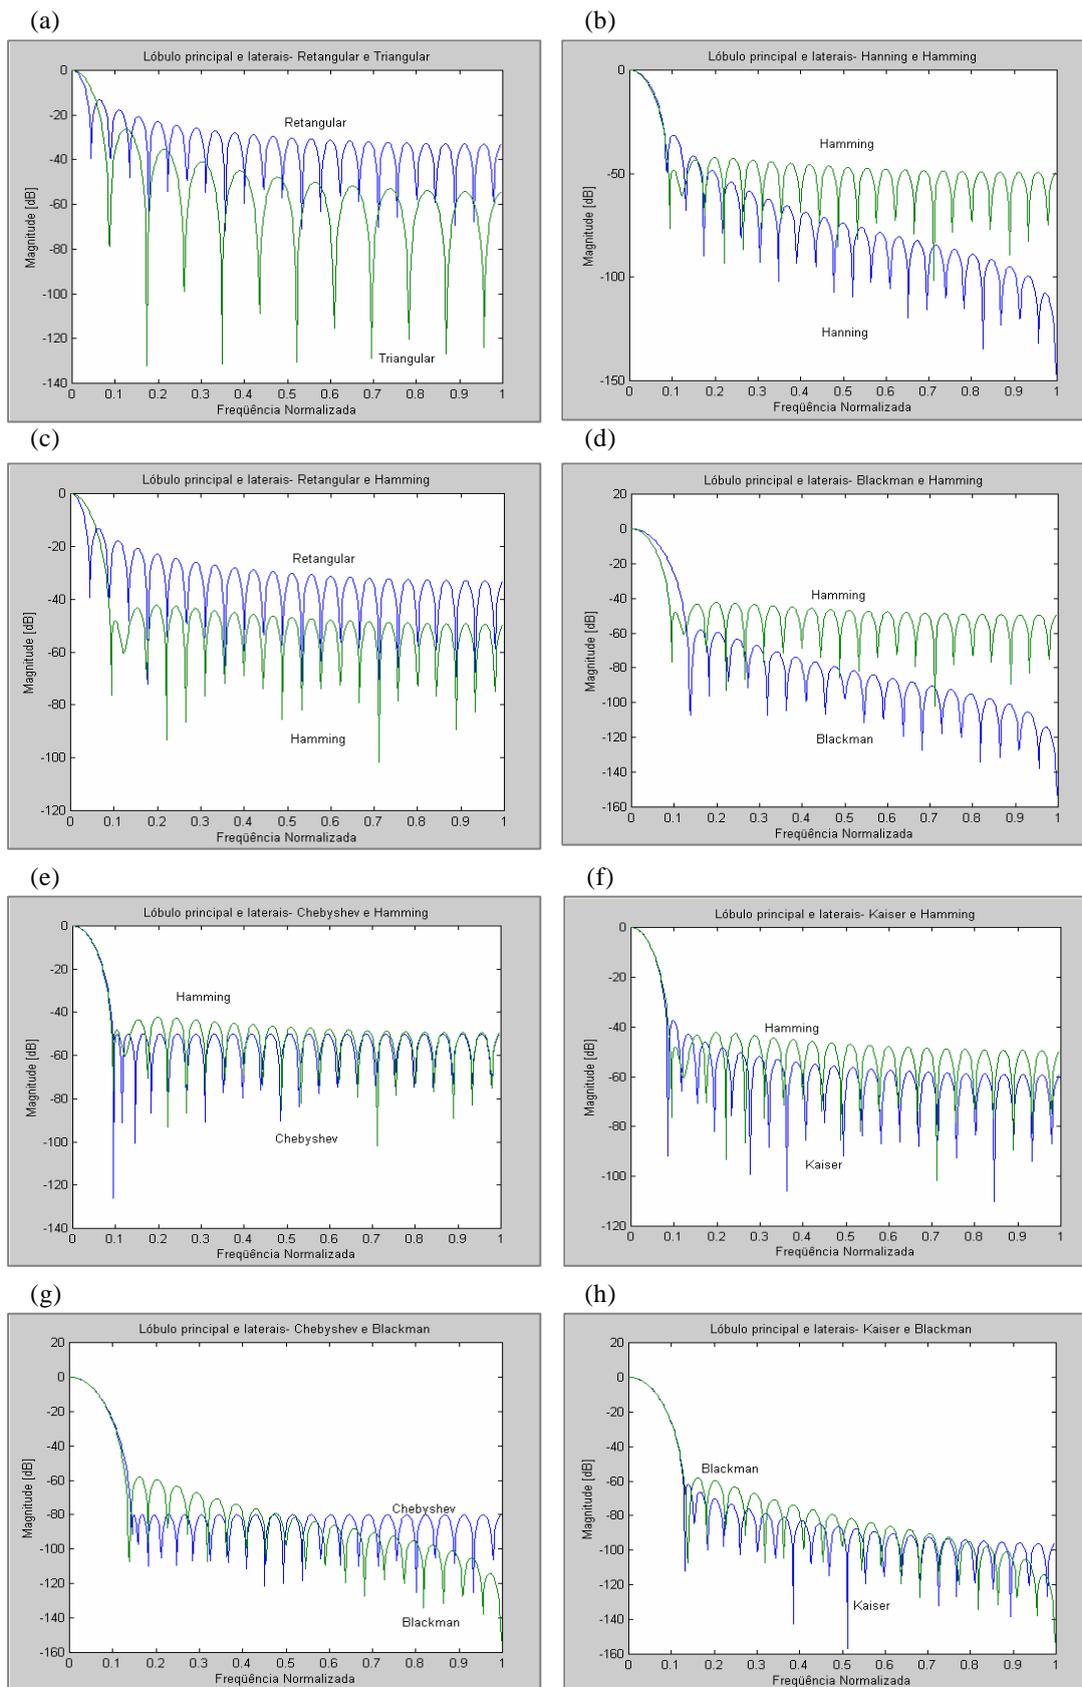


Figura 4.4- Representação em frequência das janelas retangular, triangular, Hamming, Hanning, Blackman, Chebyshev e Kaiser.

Enquanto os níveis dos primeiros lóbulos laterais são iguais para ambas as janelas, de Kaiser e de Chebyshev, o lóbulo principal mostra uma mínima diferença na largura de base, como mostra a Figura 4.5. Quando as janelas possuem lóbulos principais iguais, a janela Chebyshev apresenta o nível do primeiro lóbulo lateral ligeiramente maior que a Kaiser.

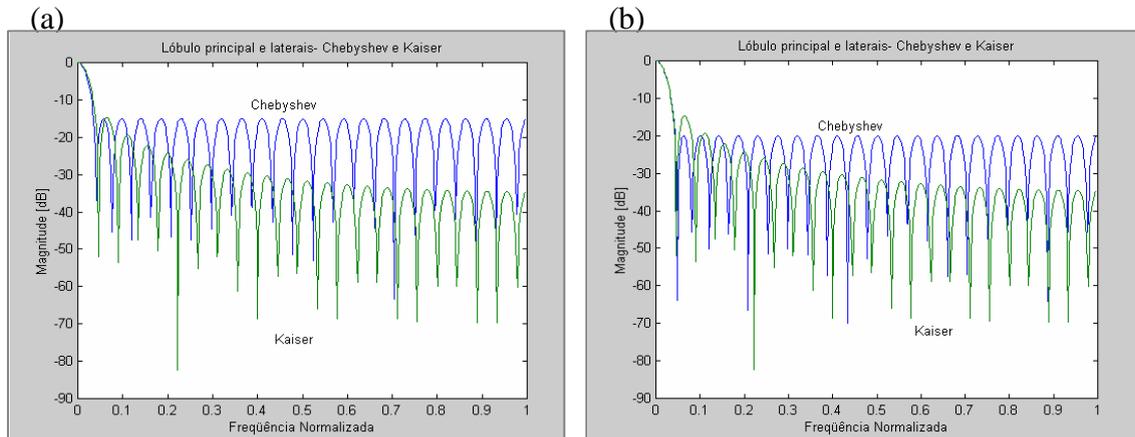


Figura 4.5- Respostas em frequência das janelas de Kaiser e de Chebyshev. Em (a), os níveis dos primeiros lóbulos laterais são iguais para ambas as janelas. Em (b), as larguras dos lóbulos principais são iguais para ambas as janelas.

Os lóbulos laterais da janela de Chebyshev possuem um nível constante, enquanto na janela de Kaiser os níveis dos lóbulos laterais vão decrementando, ficando cada vez mais destacados do lóbulo principal. Este efeito pode tornar a janela de Kaiser uma das melhores opções para o processamento de determinado sinal.

A opção em utilizar janelas para analisar um sinal requer duas decisões, que devem ser tomadas inicialmente. Qual é a melhor janela, dentre as tradicionalmente utilizadas, que melhor se enquadra dentro das características do sinal a ser analisado. E, qual é o melhor tamanho da janela.

Entretanto, poucos são os estudos publicados sobre janelas e o porquê da sua utilização. Um dos trabalhos que mais explora os critérios para uma escolha foi realizado por Cohen [70]. Ele propõe um sinal resultante da soma de duas senóides, uma com frequência de 10,5 Hz e amplitude unitária e outra com frequência de 16 Hz e amplitude igual a 0,01. Este sinal foi tratado pelas janelas: retangular, triangular, de Hamming, de Hanning e de Chebyshev, com destaque para a janela de Chebyshev como a que detectou melhor as duas frequências. Um estudo semelhante foi feito por Ingle e Proakis [76] e Hankin e Veen [71].

4.3 Definição de uma Janela Adequada para Sinais do EEG Contendo Eventos Epileptogênicos

No intuito de definir-se uma janela adequada para ser usada junto à FFT, na detecção das frequências em sinais biomédicos, alguns testes foram propostos. Estes testes consistem do cálculo das frequências presentes em vários tipos de sinais utilizando-se as janelas clássicas.

O método da densidade espectral de potência (*Power Spectral Density, (PSD)*) apresentou-se como o de uso mais indicado, sendo referência em todos os casos dos testes. A PSD foi detalhada por Haykin [71, 80] e Cohen [70, 81] e encontra-se referenciada no Anexo C deste trabalho.

4.3.1 Análise da eficiência das janelas clássicas na detecção de frequências conhecidas

Inicialmente utilizou-se como sinal de análise a soma de senóides envolvendo todas as frequências que podem estar presentes na faixa crítica da epilepsia, que é de 2 a 20 Hz, podendo-se encontrar eventos definidos entre 2.5 a 3 Hz. Os comprimentos de cada janela foram as potências de dois como: 32, 64, 128, 256, 512, 1024.

Os sinais do EEG com evento epileptogênico possuem baixas frequências e um intervalo de difícil detecção; poucas janelas conseguiram detectar todas as frequências em questão, ficando as janelas clássicas de 512 e 1024 pontos como as mais recomendáveis. Este fato pode ser constatado na Figura 4.6, onde uma janela de Hamming de 256 pontos não foi capaz de definir o grupo de baixas frequências (2, 2,5 e 3 Hz), mostrando em um único espectro as três frequências, enquanto a mesma janela com 1024 pontos destacou visivelmente estas frequências em espectros diferentes.

Foi proposto, também, neste trabalho, um sinal onde as frequências decrescem ao longo do trecho considerado como mostrado na Figura 4.7 (a). Os resultados seguiram a mesma tendência, com destaque para as janelas com 1024 pontos de Kaiser, de Chebyshev, como ilustrado na Figura 4.7 (b).

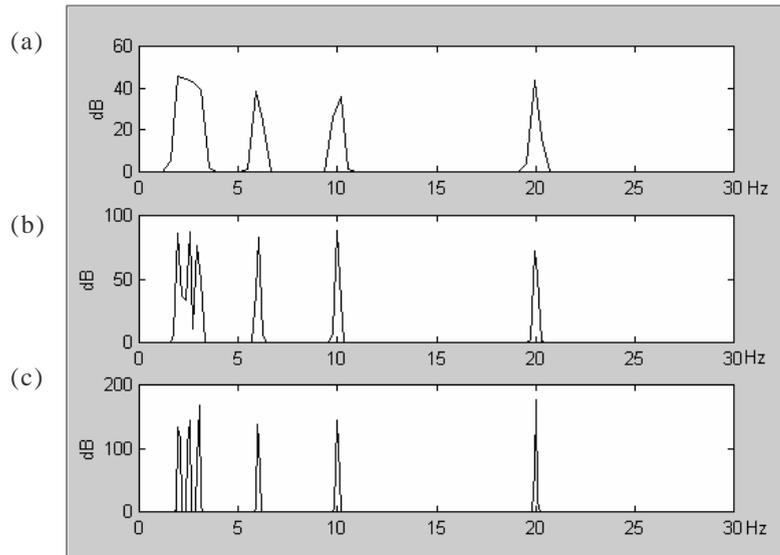


Figura 4.6- Uso de uma janela de Hamming para detectar as frequências componentes no sinal do EEG com evento epileptogênico, isto é, 2; 2,5; 3; 6; 10 e 20 Hz. Em (a), uma janela de 256 pontos, em (b), a janela de 512 pontos, em (c), a janela de 1024 pontos.

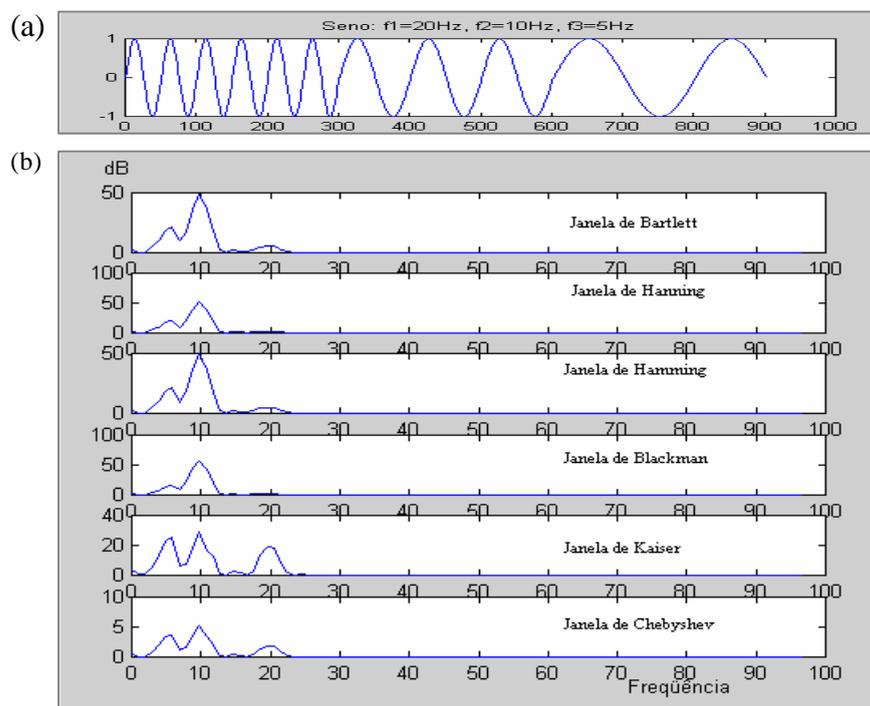


Figura 4.7- Em (a), sinal senoidal composto de frequências iguais a 5, 10 e 20 Hz. Em (b), resultado do uso das janelas clássicas para identificar as frequências deste sinal.

A dificuldade encontrada consistiu na detecção de baixas frequências, com valores muito próximos como 3 e 5 Hz. Para frequências próximas, como 2 e 3 Hz, a utilização de janelas menores, como de 32 e de 64 pontos, resultou em um espectro onde não distinguem-se com exatidão uma frequência da outra, pois as mesmas apareceram em um único espectro.

Tabelas referentes aos tipos de testes e resultados são encontradas no Anexo E deste trabalho.

Uma observação a ser destacada nas análises dos resultados destes testes refere-se à sensibilidade deste método quanto a amplitude do sinal. A amplitude do espectro foi proporcional à amplitude do sinal, fato observado na Figura 4.8. Quanto menor a amplitude imposta ao sinal, mais difícil foi a detecção da frequência envolvida.

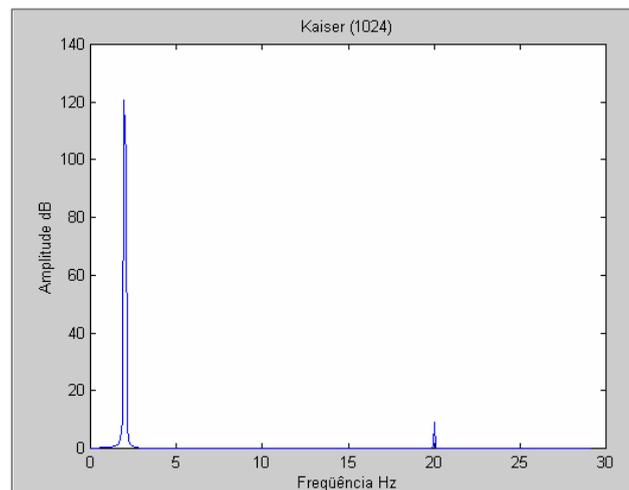


Figura 4.8- Espectro de frequências de um sinal formado pela soma de senóides, uma com amplitude 1 e frequência de 2 Hz e outra de amplitude 0,2 e frequência de 20 Hz.

Ao se destacar as janelas de Kaiser e de Chebyshev como as melhores opções, deve-se ressaltar que as variáveis, α e β , que controlam a magnitude dos lóbulos laterais e do lóbulo principal, são de fundamental importância. Uma escolha do parâmetro α da janela de Chebyshev menor que 10 pode gerar um espectro com oscilações na resposta, como mostrado na Figura 4.9. No entanto, estas oscilações desaparecem quando é usada uma janela de Chebyshev com α maior que 10. Pode-se notar também o deslocamento da linha de frequências, apresentando uma ligeira inclinação, na janela de Chebyshev com 1024 pontos. No entanto, estas oscilações desaparecem quando é usada uma janela de Chebyshev com α igual a 20 ou 40, correspondente aos valores de β iguais a 1 e 4.

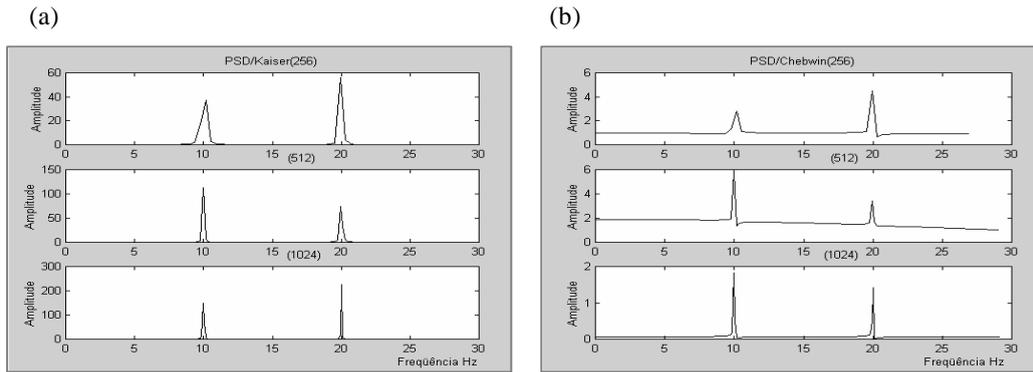


Figura 4.9- Espectros de freqüências de 10 e 20 Hz, obtidos com janelas de 256, 512 e 1024 pontos, respectivamente, de cima para baixo. Em (a), visualiza-se os espectros gerados por uma janela de Kaiser ($\beta=0.5$). Em (b), os espectros gerados por uma janela de Chebyshev ($\alpha=10$).

4.3.2 Análise da eficiência das janelas clássicas na detecção de freqüências em sinais do EEG contendo um evento epileptogênico

A janela de Kaiser mostra uma forte tendência em adequar-se às necessidades dos sinais em questão. Os melhores resultados destacaram as janelas de Kaiser, com variável β igual a 1, e de Chebyshev, com variável α igual a 20, como mostrado na Figura 4.10.

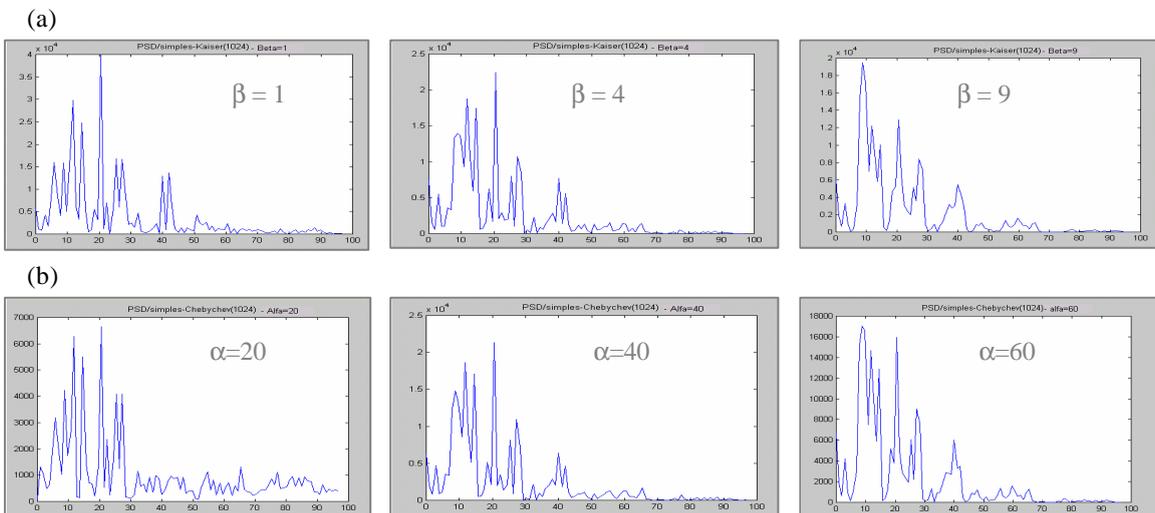


Figura 4.10- Resultados dos espectros de um sinal do EEG. Em (a), utiliza-se uma janela de Kaiser ($\beta = 1, 4$ e 9). Em (b), utiliza-se uma janela de Chebyshev ($\alpha = 20, 40$ e 60).

Os espectros resultantes da aplicação da transformada de Fourier e janelas clássicas no sinal do EEG contendo a espícula da Figura 4.11, são mostrados na Figura 4.12.

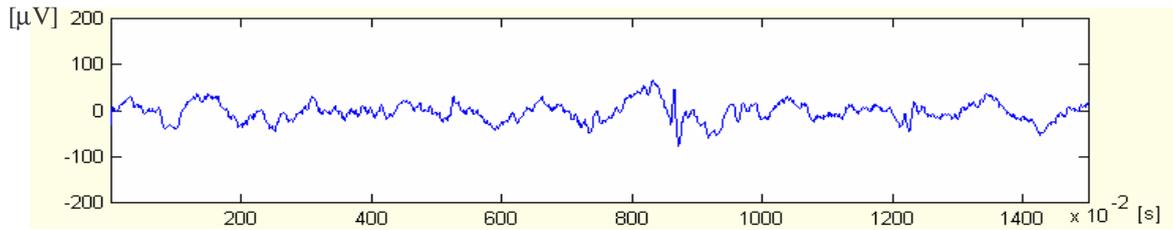


Figura 4.11- Sinal dos testes com um evento epileptogênico entre os pontos 800 a 900.

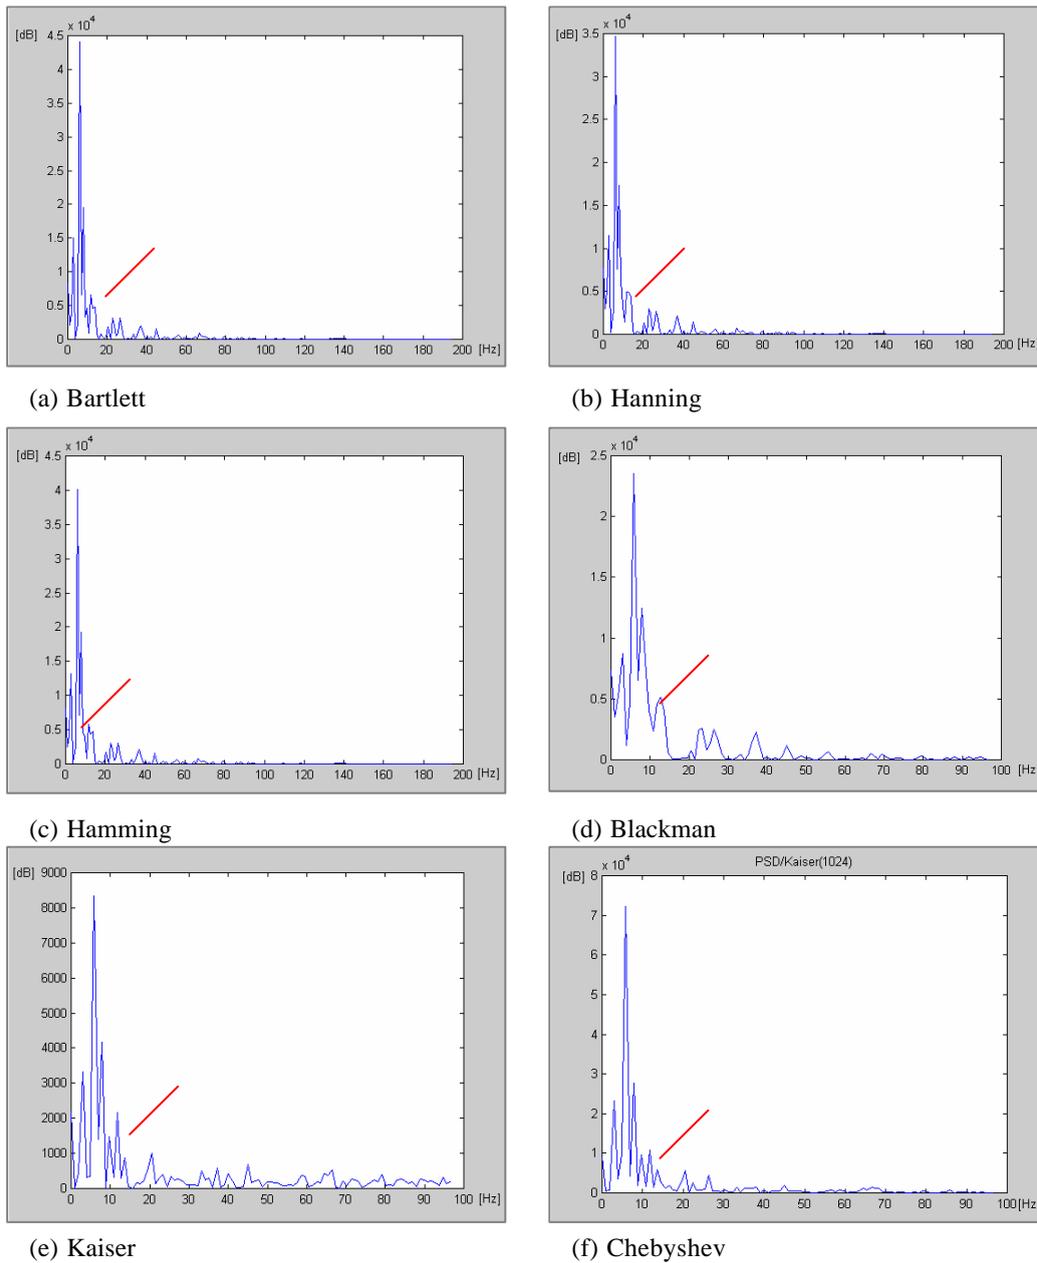


Figura 4.12- Espectros do sinal do EEG da Figura 4.16 obtidos a partir das janelas clássicas. As setas indicam diferentes picos para os espectros obtidos pelas diferentes janelas.

As setas indicadas na Figura 4.12 marcam os pontos onde os espectros dos sinais analisados apresentam-se diferentes, quando obtidos pelas diferentes janelas clássicas. Observa-se, por exemplo, que a seta identificando as frequências em torno de 10 Hz mostra um único pico para as janelas de Bartlett, de Hanning, de Hamming, e de Blackman, enquanto mostra três picos identificando três frequências diferentes, para os casos das janelas Chebyshev e Kaiser.

A questão relevante é determinar-se qual destas configurações melhor representa as frequências de interesse, presentes no sinal do EEG.

Quando a diferença de amplitude entre um ponto e o seu consecutivo for considerável, diz-se que no ponto de maior amplitude foi definida uma frequência. Assim, quanto maior a variabilidade das amplitudes dos pontos do espectro, maior será a definição da localização em frequências do espectro.

Uma forma de analisar a relação entre o espectro e os pontos representativos na sua formação é considerar os pontos vizinhos como mostrados na Figura 4.13.

Seja x_n o ponto candidato a ser um ponto representativo para a formação do espectro, x_{n-1} o ponto imediatamente antecessor e x_{n+1} o ponto adjacente à direita. Para um espectro bem definido, $x_{n-1} < x_n < x_{n+1}$, de forma que o ponto central x_n esteja destacado, e a distância entre estes pontos seja mensurável. Foi necessário eliminar-se pontos com distâncias muito pequenas entre si e que não eram perceptíveis no espectro.

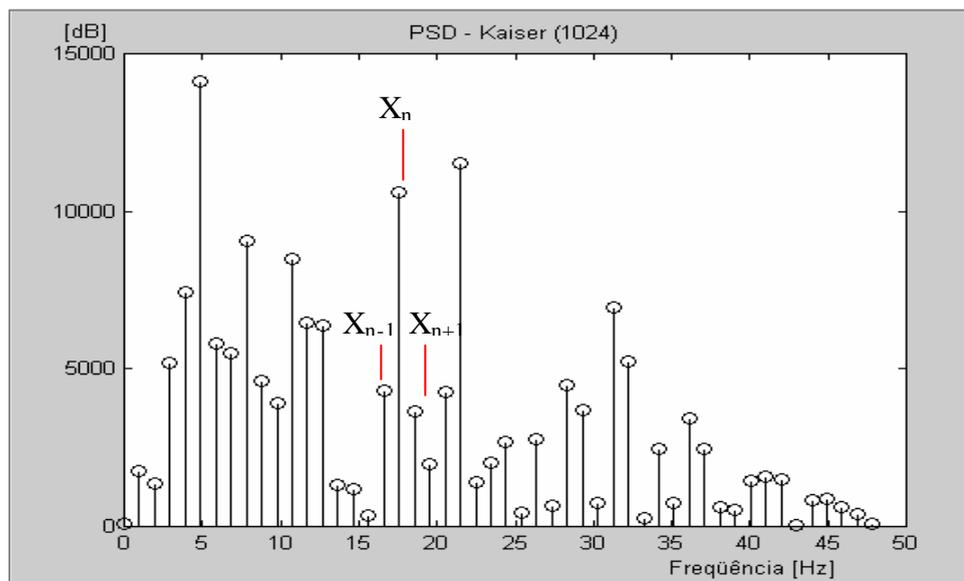


Figura 4.13- Magnitudes dos pontos representativos das frequências de um espectro para um sinal do EEG contendo evento epileptogênico.

Para 9 sinais do EEG contendo eventos epileptogênicos, foram obtidos valores das amplitudes dos espectros, fornecidos pelas janelas clássicas, para sucessivos pontos considerados como: x_{n-1} , x_n e x_{n+1} . Foram contados os casos onde $x_{n-1} < x_n < x_{n+1}$, considerados como os pontos de detecção das frequências e, para cada x_n calculado, a distância relativa entre os pontos adjacentes e antecessor. A totalização dos pontos que possam representar um espectro encontra-se na Tabela 4.1. Para esta análise não foi considerada a janela Retangular, devido ao efeito de *Gibbs*, que “mascara” a variabilidade dos resultados.

Tabela 4.1- Resultados da análise das distâncias e magnitudes dos pontos do espectro, aplicadas aos espectros obtidos pelas janelas clássicas, em 9 trechos de sinais do EEG.

Trechos	Bartlett	Hanning	Hamming	Blackman	Kaiser	Chebyshev
EEG1	9	8	8	8	11	9
EEG2	7	6	7	6	9	8
EEG3	10	10	9	10	10	11
EEG4	8	8	8	6	10	8
EEG5	3	4	3	4	6	4
EEG6	5	5	1	5	9	6
EEG7	8	9	9	9	8	7
EEG8	5	4	5	3	8	5
EEG9	7	7	7	5	8	7
Média	7	7	7	6	9	7

Os valores obtidos na Tabela 4.1 relacionam o número de pontos onde a magnitude espectral corresponde ao caso onde $x_{n-1} < x_n < x_{n+1}$ e cuja distância entre os pontos esteja dentro de um limite no qual seja possível diferenciar-se um ponto do outro.

Os parâmetros estatísticos básicos relacionados aos resultados de cada janela clássica, aplicada no sinal da Figura 4.11, são relatados na Tabela 4.2. O coeficiente de variação determina a variação relativa obtida nos resultados das janelas, mostrando seu maior ou menor grau de dispersão, ou seja, variabilidade dos dados para definição do espectro.

Tabela 4.2- Valores estatísticos básicos relacionados às magnitudes do espectro (dB) obtidos com o uso das janelas clássicas no tratamento do sinal do EEG mostrado na Figura 4.11.

Janelas	Magnitude máxima	Média	Desvio Padrão (1,0e+004)	Covariância (1,0e+008)	Coefficiente de Variação
Bartlett	44.113	4.771,2	0,8631	0,7449	1,8089
Hanning	34.667	4.313,0	0,6910	0,4775	1,6022
Hamming	40.129	4.558,7	0,7930	0,6289	1,7396
Blackman	23.544	3.842,9	0,4848	0,2350	1,2615
Kaiser	49.835	5.077,3	0,9747	0,9501	1,9198
Chebyshev	44.644	4.731,1	0,8798	0,7741	1,8597

O teste estatístico T^2 (qui-quadrado), que encontra-se descrito no Anexo D deste trabalho, também foi utilizado com a finalidade de avaliar se os espectros obtidos por cada janela clássica mostram as diferenças significativas ou se os espectros não diferem significativamente. O valor crítico obtido para T^2 foi igual a 6,9185 e os valores de T^2 obtido na comparação dos espectros fornecidos pelas janelas, duas a duas, encontram-se na Tabela 4.3. Se o valor de T^2 for menor que o crítico os espectros são considerados semelhantes e se for maior os espectros diferem significativamente. Os resultados mostram que somente na comparação realizada entre as janelas de Kaiser e de Chebyshev e nas janelas de Kaiser e Hamming, o valor encontrado para T^2 superou o valor mínimo estipulado de 6,9185.

Tabela 4.3- Resultados do teste T^2 aplicado nas diferenças entre as magnitudes dos espectros fornecidos por duas janelas clássicas.

Janelas Comparadas	T^2
Retangular Hamming	2,4849
Hanning Hamming	1,8401
Hamming Blackman	2,0493
Hamming Kaiser	6,9990
Chebyshev Kaiser	8,8063

Um estudo dos lóbulos laterais do lóbulo principal das janelas de Kaiser e Chebyshev, juntamente com os resultados relacionados à detecção das frequências, indica que a janela de Chebyshev de parâmetro igual a 20 e a janela de Kaiser de parâmetro igual a 1 são adequadas por apresentarem um lóbulo principal mais estreito e acentuado.

O estudo estatístico relacionado à variabilidade do espectro de magnitude, para nove sinais do EEG contendo evento epileptogênico, indica a grande variabilidade da janela de Kaiser. Esta variabilidade evidencia os pontos que realmente contam para formar o espectro das frequências presentes no sinal original.

4.4 Entradas e Saídas das Redes com Pré-Processamento pela Transformada de Fourier Utilizando-se Janelas

Os mesmos sinais sem pré-processamento utilizados como entradas da rede no Capítulo 3 deste trabalho são agora tratados pela FFT com janela de Kaiser de 1024 pontos e β igual a 1. Os espectros resultantes deste processo são expostos na entrada da rede, com o intuito de se destacar os possíveis eventos epileptogênicos.

Os diversos tipos de eventos com seus respectivos espectros encontram-se representados nas Figuras 4.14 a 4.16, com escalas diferentes.

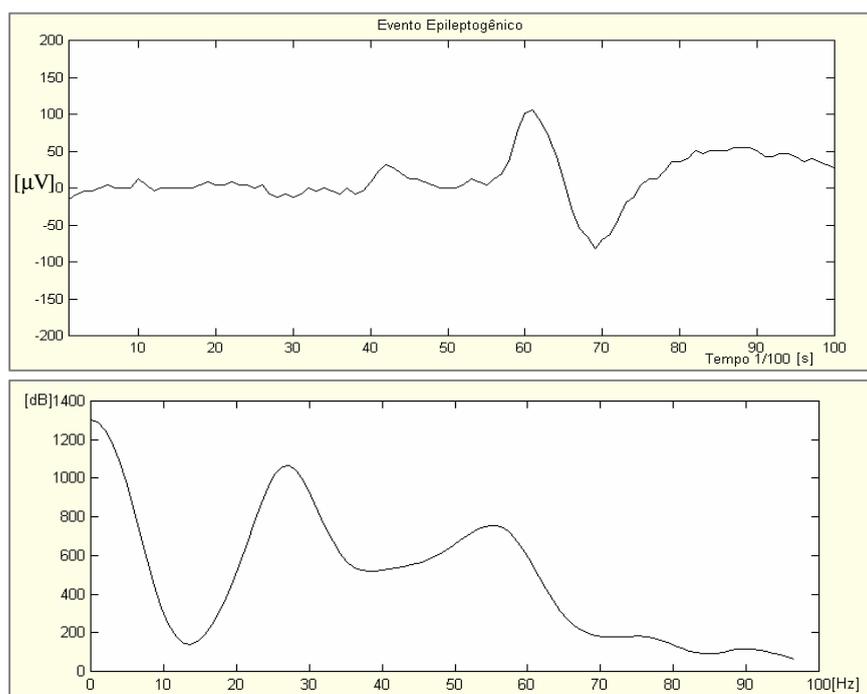


Figura 4.14- Registro do EEG com evento epileptogênico e seu respectivo espectro.

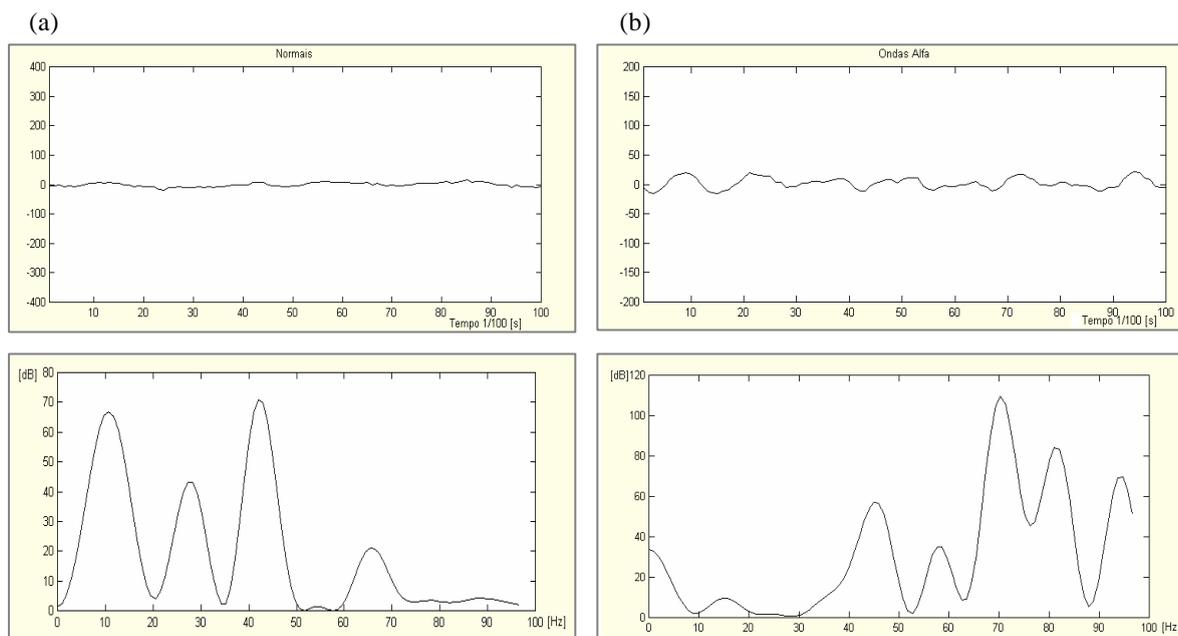


Figura 4.15- Eventos com seus respectivos espectros. Em (a), registro com EEG de fundo. Em (b), registro com ondas alfa.

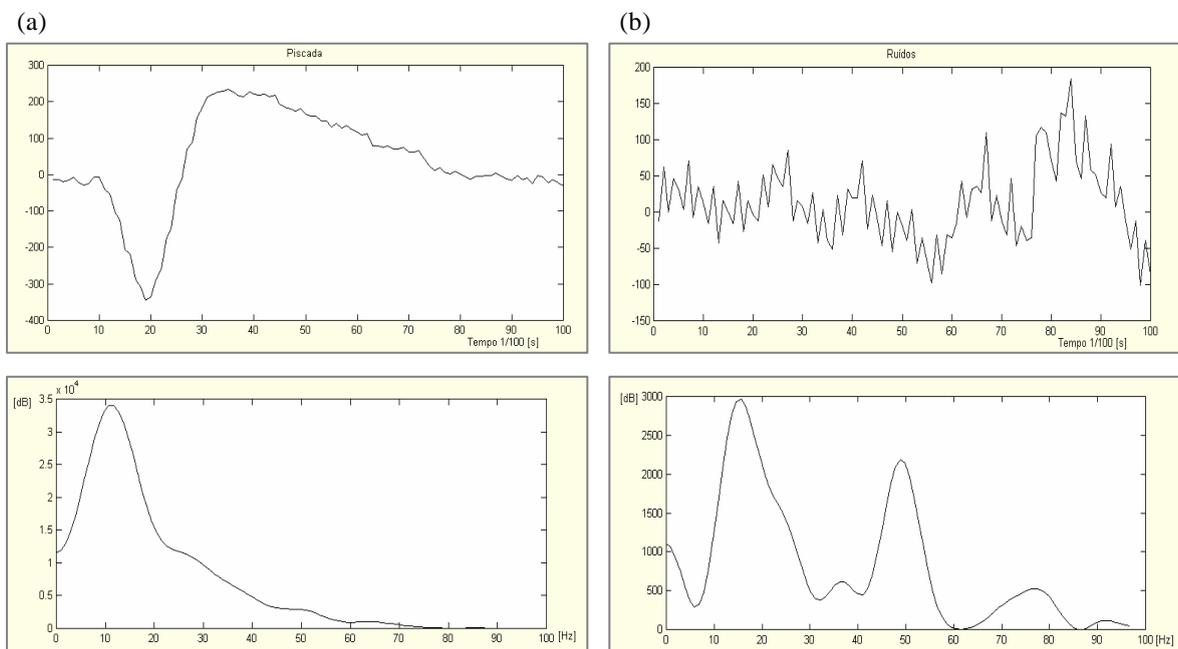


Figura 4.16- Eventos com seus respectivos espectros. Em (a), registro com piscada. Em (b), registro com ruídos.

Nas Figuras 4.14 a 4.16 os eventos e seus correspondentes espectros encontram-se em escalas diferentes com a finalidade de melhorar a visualização das características da sua forma espectral. A escolha de uma escala para comportar todos os tipos de eventos, os eventos de maiores amplitudes ficariam bem representados, mas os demais eventos resultariam em espectros mal definidos.

Pode-se observar uma diferença significativa nas magnitudes dos espectros resultantes dos sinais com ruídos e piscadas, relacionadas às magnitudes apresentadas pelas ondas alfa e EEG de fundo. Os registros com eventos epileptogênicos ficam em uma posição intermediária.

Os procedimentos relativos às implementações das redes desenvolvidas para terem nas entradas os espectros dos sinais, foram os mesmos realizados com os sinais sem pré-processamento. Os registros escolhidos foram os mesmos, para todos os conjuntos de treinamento e teste. A única variação foi a rotina do cálculo do espectro, acrescentada antes da entrada da rede, como generaliza o diagrama mostrado na Figura 4.17.

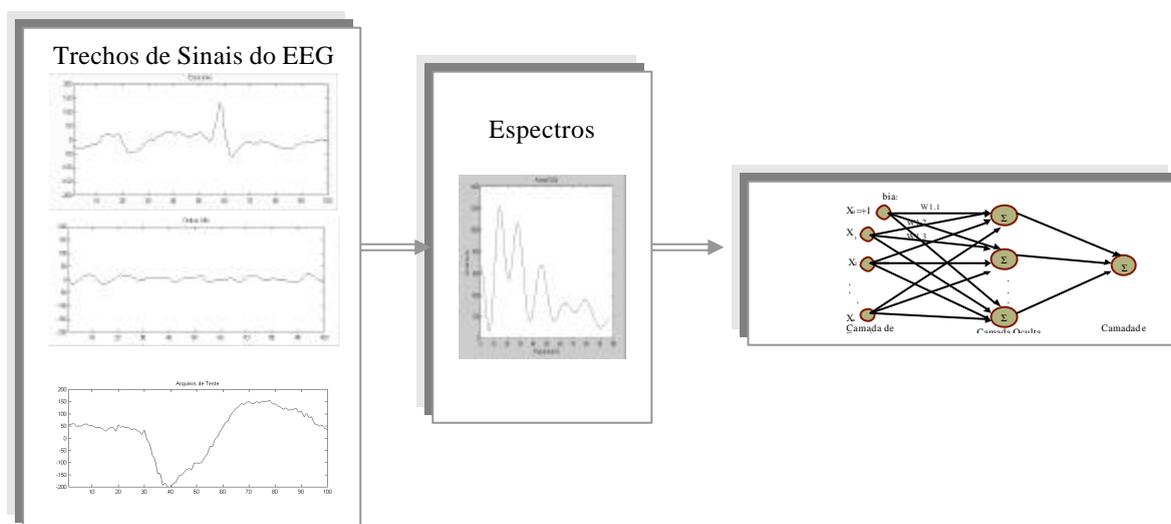


Figura 4.17- Esquema simplificado de uma rede, tendo como entrada a magnitude dos espectros de trechos de sinais do EEG.

Observa-se que o resultado da FFT é dado em uma janela de 100 pontos no eixo das frequências os quais formam os 100 vetores de entrada. E, os valores da magnitude em dB correspondem aos valores na entrada da rede. Foram treinadas redes com 10 a 14 neurônios na camada oculta e um neurônio na saída como descritas no Capítulo 2 deste trabalho.

4.5 Treinamento e Teste

Seguiu-se a mesma proposta para os conjuntos de treinamento e teste utilizados nas redes sem pré-processamento mostrados no capítulo 3 deste trabalho. Propõe-se um arquivo de treinamento sem caracterização prévia dos sinais de entrada, e um arquivo com caracterização prévia dos sinais de entrada. A Figura 2.7, encontrada no Capítulo 2, propõe a organização básica para as redes. O pré-processamento foi acrescentado na Figura 4.21, para completar a organização destas redes.

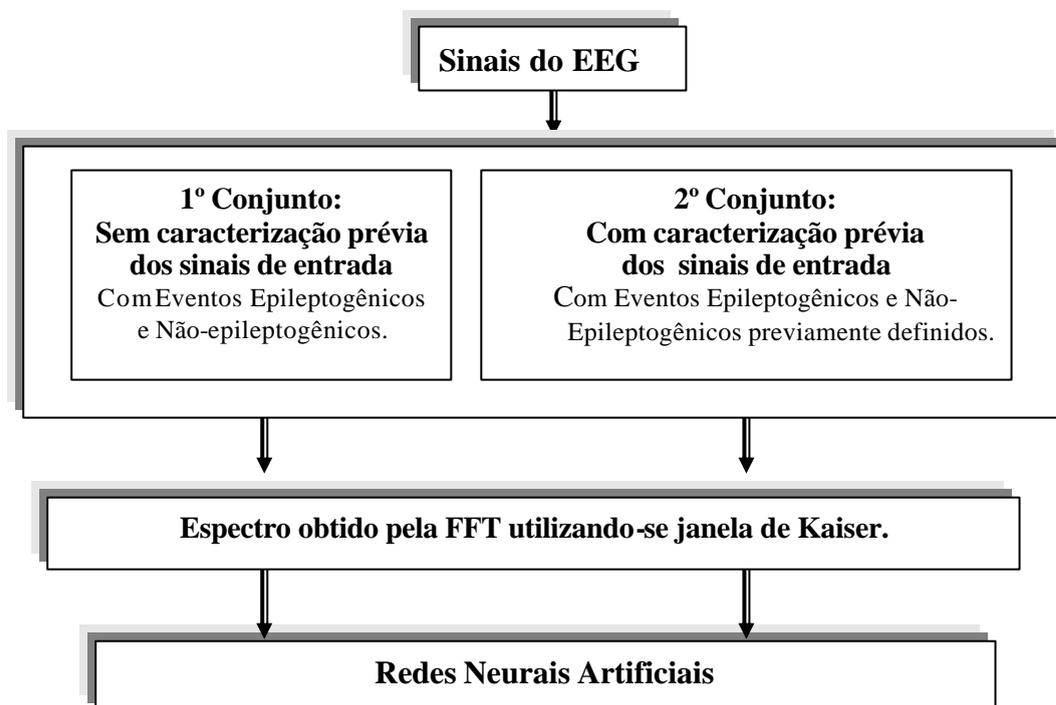


Figura 4.18- Desenvolvimento das RNA's com entradas baseadas no espectro dos sinais.

Foram consideradas redes com entradas normalizadas e não-normalizadas. A normalização foi realizada segundo a amplitude máxima da entrada da rede e segundo a amplitude máxima do espectro do evento epileptogênico de maior amplitude.

4.6 Resultados e Análise dos Resultados

No Anexo B deste trabalho são encontrados os gráficos resultantes do treinamento de cada rede. Não houve uma redução substancial no tempo de treinamento com entradas normalizadas.

4.6.1 RNA sem caracterização prévia dos sinais de entrada

As redes sem caracterização prévia dos sinais de entrada foram treinadas para classificar espectros de sinais, sem se preocupar com o tipo de atividade ou evento existente nestes sinais. Sua meta era distinguir o espectro de um sinal contendo eventos epileptogênicos, do espectro de um sinal contendo atividades e eventos não epileptogênicos.

Os resultados das redes treinadas sem caracterização prévia dos sinais de entrada e com as variações dos neurônios da camada oculta, para determinação de uma melhor topologia de rede, são visualizados nas Tabelas 4.4 e 4.5. Nestes testes utilizou-se 53 espectros dos sinais de teste, sendo 30 espectros de sinais com eventos epileptogênicos e 23 espectros de sinais com os eventos não-epileptogênicos.

Tabela 4.4- Resultados quanto aos números de acertos, valores indefinidos, verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN), obtidos pelas redes sem caracterização prévia dos sinais de entrada.

Rede	Acertos Valor absoluto e percentual	Indefinidos	VP	VN	FP	FN
12 N. Ocultos 100.000 Interações	35 (66%)	14	18	21	2	12
13 N. Ocultos 100.000 Interações	40 (75%)	10	22	22	1	8
14 N. Ocultos 100.000 Interações	34 (64%)	12	17	22	1	13
13 N. Ocultos 300.000 Interações	38 (72%)	12	22	22	1	8
13 N. Ocultos Normalizada 100.000 Interações	30 (57%)	2	28	2	21	2
13 N. Ocultos Normalizada segundo a amplitude máxima do espectro de um evento epileptogênico 100.000 Interações	42 (79%)	3	27	17	6	3

Tabela 4.5- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais sem caracterização prévia dos sinais de entrada.

Rede	Sensibilidade	Especificidade	VPP	VPN
12 N. Ocultos 100.000 Interações	0,60	0,91	0,90	0,63
13 N. Ocultos 100.000 Interações	0,73	0,96	0,96	0,73
14 N. Ocultos 100.000 Interações	0,57	0,96	0,94	0,63
13 N. Ocultos 300.000 Interações	0,73	0,96	0,96	0,73
13 N. Ocultos Normalizada 100.000 Interações	0,93	0,09	0,57	0,50
13 N. Ocultos Normalizada segundo a amplitude máxima do espectro de um evento epileptogênico 100.000 Interações	0,90	0,74	0,82	0,85

Não houve alterações significativas nos resultados quando foi aumentado o número de interações de 100.000 para 300.000, a não ser um incremento no tempo de treinamento.

A rede com entrada normalizada mostrou-se deficiente, apresentando elevado valor de falsos positivos. A normalização segundo a amplitude máxima do espectro de um sinal contendo evento epileptogênico reduziu o número de saídas indefinidas e aumentou o número de acertos. No entanto, continuou-se com um alto número de falsos positivos.

O acréscimo de cinco trechos de sinais contendo piscada no conjunto de teste fornece os resultados mostrados nas Tabelas 4.6 e 4.7.

Os resultados mostraram alterações comparando-se à rede testada sem as piscadas. Resultou em uma menor taxa de especificidade devido ao aumento do número de falsos positivos e indicou que algumas destas piscadas são confundidas com eventos epileptogênicos pelas redes neurais. No entanto, o valor da sensibilidade não foi afetado.

Tabela 4.6- Resultados obtidos pelas redes com os 58 espectros de sinais de teste, sendo 30 espectros de sinais com eventos epileptogênicos, 23 espectros de sinais com eventos não-epileptogênicos e destes, 5 espectros de trechos com piscadas.

Rede	Acertos Valor absoluto e percentual	Indefinidos	VP	VN	FP	FN
13 N. Ocultos 100.000 Interações	40 (69%)	10	22	22	6	8
14 N. Ocultos 100.000 Interações	36 (62%)	13	17	25	3	13
13 N. Ocultos Normalizada 100.000 Interações	27 (47%)	7	25	5	23	5
13N. Ocultos Normalizada segundo a amplitude máxima do espectro de um evento epileptogênico 100.000 Interações	44 (76%)	3	27	19	9	3

Tabela 4.7- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais definidas na Tabela 4.6.

Rede	Sensibilidade	Especificidade	VPP	VPN
13 N. Ocultos 100.000 Interações	0,73	0,78	0,78	0,73
14 N. Ocultos 100.000 Interações	0,57	0,90	0,85	0,66
13 N. Ocultos Normalizada 100.000 Interações	0,83	0,18	0,52	0,50
13N. Ocultos Normalizada segundo a amplitude máxima do espectro de um evento epileptogênico 100.000 Interações	0,90	0,68	0,75	0,86

4.6.2 Redes com caracterização prévia dos sinais de entrada

A segunda abordagem do conjunto de treinamento selecionou os registros conforme grupos pré-estabelecidos nos sinais contendo evento epileptogênicos, bem como nos sinais contendo eventos não-epileptogênicos, como ruídos e piscadas. Estes sinais também foram tratados pela transformada de Fourier utilizando-se a janela de Kaiser de 1024 pontos e variável β igual a 1. O conjunto de teste seguiu as mesmas definições do conjunto de treinamento, diferenciando cada grupo de sinal conforme as características de sua forma.

Os resultados relacionados ao número de acertos, falsos positivos e negativos são encontrados na Tabela 4.8. Na seqüência, a Tabela 4.9 apresenta os valores de sensibilidade e especificidade obtidos nos testes propostos.

Tabela 4.8- Resultados obtidos pelas redes com os 45 espectros de sinais de teste, isto é, 20 espectros de sinais com eventos epileptogênicos e 25 espectros de sinais com os eventos não epileptogênicos, com características previamente definidas.

Rede	Acertos Valor absoluto e percentual	Indefinidos	VP	VN	FP	FN
10 N. Ocultos 100.000 Interações	27 (60%)	10	15	18	7	5
12 N. Ocultos 100.000 Interações	27 (60%)	13	14	23	2	6
13 N. Ocultos 100.000 Interações	23 (52%)	16	12	23	2	8
12 N. Ocultos 300.000 Interações	25 (56%)	15	14	23	2	6
12 N. Ocultos Normalizada 100.000 Interações	25 (56%)	7	18	12	13	2
12 N. Ocultos Normalizada segundo a amplitude máxima do espectro de um evento epileptogênico 87.667 Interações	26 (56%)	6	17	13	12	3

Tabela 4.9- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais definidas na Tabela 4.8.

Rede	Sensibilidade	Especificidade	VPP	VPN
10 N. Ocultos 100.000 Interações	0,75	0,72	0,68	0,78
12 N. Ocultos 100.000 Interações	0,70	0,92	0,87	0,79
13 N. Ocultos 100.000 Interações	0,60	0,92	0,86	0,74
12 N. Ocultos 300.000 Interações	0,70	0,92	0,86	0,79
12 N. Ocultos Normalizada 100.000 Interações	0,90	0,52	0,60	0,87
12 N. Ocultos Normalizada segundo a amplitude máxima do espectro de um evento epileptogênico 87.667 Interações	0,85	0,52	0,59	0,81

A tendência de se obter um número elevado de falsos positivos, quando o sinal de entrada da rede é normalizado, novamente foi confirmada. Tanto normalizando-se as entradas em relação à amplitude máxima de um evento epileptogênico, bem como em relação a amplitude máxima de seu espectro.

4.7 Conclusões e Discussões

Nas Tabelas 4.10 e 4.11 estão destacados os melhores resultados das redes usando o espectro dos sinais contidos nos arquivos de entrada. Em cada caso observa-se a utilização da melhor configuração para o número de neurônios na camada oculta.

O uso deste pré-processamento na entrada das redes mostra uma sensível melhora dos resultados comparados aos resultados das redes sem pré-processamento.

Contudo, em todas as redes analisadas os números de falsos positivos e negativos encontram-se presentes. Em algumas redes estes valores são considerados elevados.

Tabela 4.10- Melhores resultados das redes treinadas com sinais pré-processados pelo espectro obtido pela FFT utilizando-se a janela de Kaiser.

Rede	Acertos Valor absoluto e percentual	Indefinidos	VP	VN	FP	FN
Sem caracterização dos sinais 13 N. Ocultos	40 (75%)	10	22	22	1	8
Sem caracterização dos sinais. 13 N. Ocultos. Normalizada segundo a amplitude máxima do espectro de um evento epileptogênico	42 (79%)	3	27	17	6	3
Com caracterização dos sinais 12 N. Ocultos	27 (60%)	13	14	23	2	6
Com caracterização dos sinais. 12 N. Ocultos. Normalizada segundo a amplitude máxima do espectro de um evento epileptogênico	26 (56%)	6	17	13	12	3

Na Tabela 4.10 os acertos são dados em valor absoluto e percentual. É registrado o número de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos.

Tabela 4.11- Melhores resultados referentes aos valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais definidas na Tabela 4.10.

Rede	Sensibilidade	Especificidade	VPP	VPN
Sem caracterização dos sinais 13 N. Ocultos	0,73	0,96	0,96	0,73
Sem caracterização dos sinais. 13 N. Ocultos. Normalizada segundo a amplitude máxima do espectro de um evento epileptogênico	0,90	0,74	0,82	0,85
Com caracterização dos sinais 12 N. Ocultos	0,70	0,92	0,87	0,79
Com caracterização dos sinais. 12 N. Ocultos. Normalizada segundo a amplitude máxima do espectro de um evento epileptogênico	0,85	0,52	0,59	0,81

O ideal é fazer um refinamento dos sinais ao montar-se os conjuntos de treinamento e teste das redes. Como as amplitudes de trechos com ruídos e piscadas, na maioria das vezes, possuem valores elevados em relação aos eventos epileptogênicos, pode-se atribuir um limiar para a amplitude máxima dos sinais analisados pelas redes. Se a amplitude máxima ultrapassar este limiar, assume-se que neste trecho existem piscadas ou ruídos, não sendo considerados na entrada da rede.

A Figura 4.22 mostra uma sugestão para se adequar as redes neurais à identificação de eventos epileptogênicos, utilizando-se como sinais de entrada os espectros dos sinais obtidos pelo processo de ajanelamento. A proposta é eliminar-se os trechos de sinais “contaminados” por ruídos e piscadas que, embora possam conter alguma atividade epileptogênica, geralmente geram dúvidas quanto à detecção. Se a magnitude do espectro do sinal de entrada for maior do que a dos eventos epileptogênicos o sinal é considerado como contendo evento não-epileptogênico.

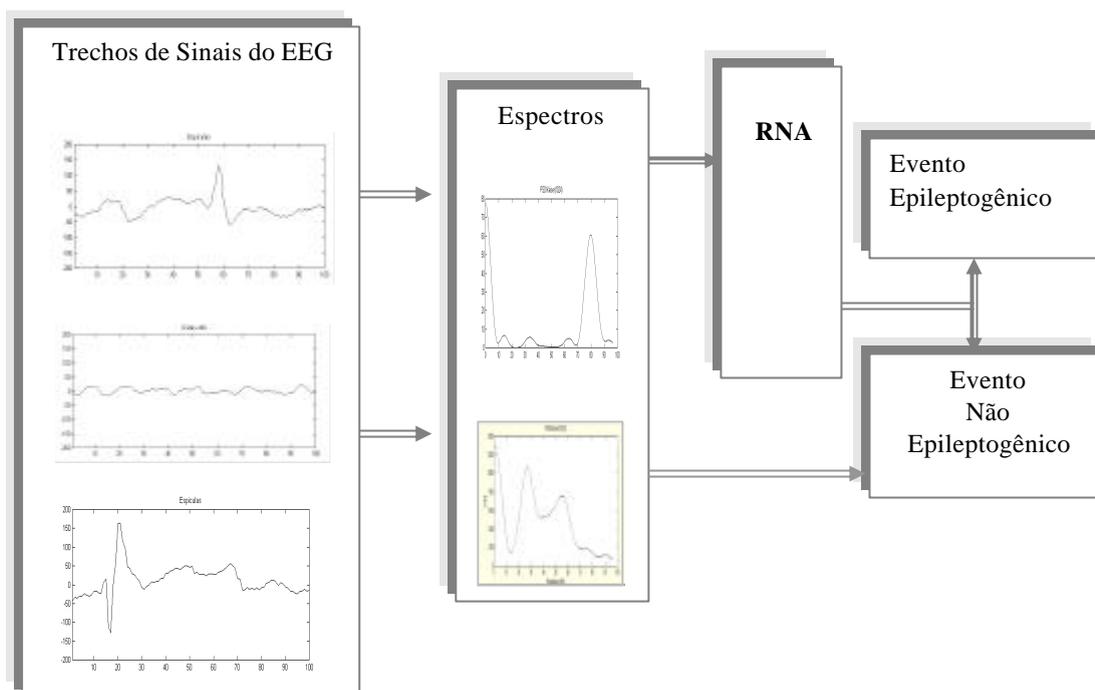


Figura 4.19- Sugestão para o uso de redes neurais tendo como entrada a magnitude dos espectros de trechos de sinais do EEG.

CAPÍTULO 5

5. RNA'S COM ENTRADAS PRÉ-PROCESSADAS UTILIZANDO-SE A ANÁLISE TEMPO-FREQÜÊNCIA

A Transformada de Fourier fornece as características espectrais de frequência de um sinal, entretanto, existem questionamentos em torno deste método no que se refere à estacionaridade do sinal original. Os métodos de Fourier não são geralmente apropriados para a análise de sinais com componentes transientes, no entanto são largamente utilizados na análise de sinais biomédicos, os quais são frequentemente não-estacionários. Para satisfazer-se a condição de estacionaridade, é comum dividir-se os longos trechos do sinal em blocos de curta duração. Esta forma de tratar a transformada de Fourier foi proposta inicialmente por Gabor, através da Transformada de Fourier de Curto Termo [69].

Para a análise de frequências em sinais não-estacionários, como os sinais do EEG, o método indicado é o uso da análise em tempo e frequência. Esta análise representa o sinal e suas componentes espectrais como função do tempo. Em outras palavras, é uma representação espectral variável no tempo, com o tempo e a frequência representando os dois eixos principais do gráfico. Em síntese, o método fornece os instantes de tempo em que certos componentes espectrais do sinal são observados.

Nos últimos anos, o tratamento matemático baseado nas representações tempo-frequência vem se destacando em muitos estudos relacionados a sinais bioelétricos, principalmente naqueles dedicados à interpretação dos sinais do EEG. Contudo, suas formulações teóricas ainda são muito pouco exploradas pela literatura, em comparação com as formas tradicionais de Fourier. Dentre as referências que mais detalham estes conceitos pode-se destacar os trabalhos de Akai [69], Haykin [71] e Gomes [79]. Em todos os relatos, o tema do tempo-frequência é tratado como uma interligação entre as formas tradicionais de Fourier e a representação tempo-escala relacionada à Transformada *Wavelet*.

Alguns trabalhos vêm sendo publicados, utilizando-se como método básico de análise a representação no plano tempo-frequência, principalmente em estudos relacionados a sinais bioelétricos. Dentre estes trabalhos são ressaltadas as aplicações envolvendo sinais do EEG em análises de eventos relativos a crises epiléticas. Bergery [82], utiliza um algoritmo rápido baseado nas Representações de Gabor para detectar, em

sinais do EEG, trechos onde ocorreram crises epilépticas, através de observações das variações da energia presentes nas representações.

Quiroga [10, 83] desenvolveu uma análise quantitativa de sinais do EEG com registros de crises epilépticas (*tônico-clônicas*) baseando-se nos métodos de tempo-frequência. Embora as maiores considerações do seu trabalho estejam nos métodos relativos à transformada Wavelet, ele desenvolveu gráficos tridimensionais ressaltando tempo-frequência-amplitude dos sinais do EEG, marcando de forma certa a ocorrência do evento. Ele mencionou que o espectrograma é útil para discriminar os diferentes estágios do sono, que mostram uma lenta variação nos padrões de frequência, contudo não é um método adequado para as análises de sinais epileptiformes, onde os padrões de frequência variam rapidamente.

Osório [84] usou um algoritmo que combina a densidade espectral de potência e o método de Gabor para localizar crises epilépticas em sinais do EEG. Ele também destacou a utilização da transformada *wavelet* rápida.

Wendling [85] desenvolveu um mapeamento tempo-frequência dos sinais do EEG contendo crises epilépticas, mostrando que importantes características podem ser extraídas dos registros. Descreveu detalhadamente as formulações do método e seu algoritmo de aplicação. Mostrou resultados utilizando o plano tempo-frequência, destacando os trechos de importância para a análise neurológica necessária.

Xu [86] fez uma análise da técnica tempo-frequência aplicada aos sinais do EEG. Ele mencionou o fato de que os métodos tradicionais como os de Fourier, Transformada Wavelet e Distribuição Wigner-Ville são designados para sinais determinísticos, e o sinal do EEG deve ser tratado como um processo randômico ou estocástico. Ele descreveu detalhadamente as formulações matemáticas da técnica, destacando a Análise de Coerência junto à Distribuição Tempo-Frequência.

Em todos os estudos que empregam a análise tempo-frequência geralmente o objetivo é a detecção da ocorrência de um evento como, por exemplo, a crise epiléptica, destacando-se no plano o trecho de interesse. Em geral esta análise não é tratada como uma fonte de dados para ser utilizada como entrada em uma RNA.

Este capítulo descreve a transformada de curto termo, define uma janela adequada para o EEG, mostra as entradas das redes, como foi realizado o treinamento e os testes das RNA's, os resultados obtidos e as análises dos resultados. Finalmente mostra as conclusões e discussões sobre esses resultados.

5.1 Transformada de Fourier de Curto Termo

A Transformada de Fourier de Curto Termo (*Short-Time Fourier Transform (STFT)*) é basicamente o processo de ajanelamento do sinal de entrada, através da associação da transformada a uma janela de largura fixa. Desta forma, o sinal é dividido em um determinado número de segmentos e a Transformada de Fourier é aplicada em cada segmento localizado do sinal. A STFT foi introduzida por Gabor em 1946, e pode-se destacar também os trabalhos de Daubechies em 1992, e Kaiser em 1994 [69].

Considerando que $x(t)$ denota um sinal, que presume-se ser estacionário quando visualizado através de uma janela $w(t)$ temporal de extensão limitada; em geral, $w(t)$ tem valor complexo (as equações matemáticas relativas a STFT são encontradas no Anexo C deste trabalho). A STFT de $x(t)$, denotada por $X(\mathbf{t}, w)$, é a transformada de Fourier do sinal "ajanelado", onde, \mathbf{t} é a posição central da janela $w(t)$. Para um dado $x(t)$ o resultado obtido calculando-se a $X(\mathbf{t}, w)$ depende da escolha da janela $w(t)$ [71].

5.1.1 Dimensões da janela no tempo

A questão mais difícil da análise STFT é determinar-se o tamanho da janela de tempo. Se a janela for suficientemente pequena para assegurar que os componentes muito rápidos ou transientes de um sinal sejam discriminados dos demais, apresentará uma boa resolução no tempo, mas irá gerar uma banda passante de frequências mais larga, devido às descontinuidades bruscas desta janela, que adicionam componentes extras de alta frequência, prejudicando a resolução em frequência. Se a janela no tempo for suficientemente larga para não adicionar as componentes de frequência, a resolução em frequência estará assegurada, mas a resolução no tempo diminuirá [87].

O *Princípio da Incerteza* governa as transformadas no espaço tempo-frequência. Ele é representado na Equação (5.1) e detalhado no Anexo C deste trabalho. Por esse princípio, não é possível obter-se a localização precisa simultaneamente no domínio do tempo e no domínio da frequência, quando trabalha-se com janelas de tamanho fixo.

$$\Delta w \Delta t \geq \frac{1}{4p} \quad (5.1)$$

A largura D_t da janela no domínio do tempo e o comprimento da faixa de frequência D_w da janela no domínio da frequência são definidos considerando-se a resolução desejada para a janela. Os menores valores de D_w e D_t para os quais os sinais podem ser distinguidos são definidos como “resolução de frequência” e “resolução de tempo”, respectivamente. Uma vez que o tipo de janela tenha sido escolhido para a STFT, o comprimento da faixa de frequência D_w e da largura da janela no tempo D_t , são dados de acordo com o teorema da incerteza.

5.1.2 Plano tempo-frequência

A análise da STFT depende criticamente da escolha da janela. Em aplicações que requerem prioridade na informação temporal de evolução das propriedades do sinal, esta escolha é ainda mais importante. Uma vez escolhida a janela, o comprimento da janela ao longo dos eixos de frequência e de tempo é fixado no plano tempo-frequência como mostrado na Figura 5.1.

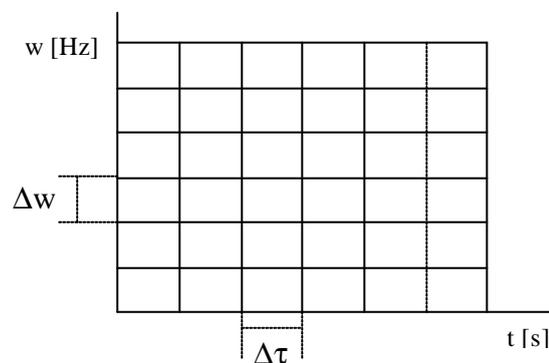


Figura 5.1- Reticulado do plano tempo-frequência com uma repartição uniforme para o tempo (t) e para a frequência (w).

É comum associar uma escala de cinza ou de cores a cada retângulo para indicar a energia do átomo na decomposição. Os espectrogramas, desenvolvidos neste estudo, apresentam as células no plano tempo-frequência formadas por um padrão de cores, que indica a energia do sinal. As cores em ordem decrescente de energia são: o vermelho, o amarelo e o azul.

5.1.3 Representação complexa do espectrograma

A fórmula analítica do espectrograma fornece valores complexos, como todas as representações baseadas na Transformada de Fourier. Esta formulação complexa dificulta o uso das redes *feedforward* com algoritmo de aprendizado *backpropagation*, as quais não trabalham com valores complexos. Para estes casos a opção é utilizar-se os valores absolutos, ou em módulo, ou utilizar algoritmos desenvolvidos especialmente para implementar estas redes com valores complexos em sua arquitetura. No entanto, estes algoritmos produzem uma saída complexa, determinando uma meta também complexa. Este fato dificulta sua utilização, quando deseja-se uma saída que simplesmente identifica a presença ou não de determinado evento nos sinais apresentados em suas entradas.

Algoritmos para redes com valores complexos foram detalhados nas publicações de Kin [88], Nitta [89] e Jargon [90]. Estes trabalhos apresentam o algoritmo de aprendizado *backpropagation* na versão de valores complexos, que pode ser aplicado em redes neurais de multi-camadas, onde os pesos, valores de limiar, entradas e saídas são todos números complexos. A Figura 5.2 mostra o modelo de um neurônio usado na rede complexa, segundo Nitta [89]. A ativação Y_n do neurônio n é definida pela Equação (5.2).

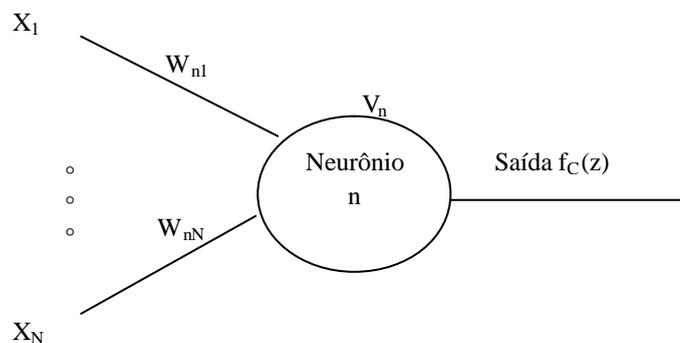


Figura 5.2- Modelo de um neurônio usado no algoritmo *backpropagation* de valores complexos. X_m , Y_n , V_n , W_{nm} , z e $f_C(z)$ são todos números complexos.

$$Y_n = \sum_m W_{nm} X_m + V_n \quad (5.2)$$

onde, W_{nm} é o valor complexo do peso da conexão do neurônio n e m . X_m é o valor complexo do sinal de entrada do neurônio m e V_n é o valor complexo do limiar do neurônio n . Para obter o valor do sinal de saída complexo, converte-se o valor de ativação Y_m em partes real e imaginária, como na Equação (5.3):

$$Y_n = x + iy = z \quad (5.3)$$

A função de saída de cada neurônio é considerada na Equação (5.4):

$$f_C(z) = f_R(x) + if_R(y) \quad (5.4)$$

O valor de $f_R(u)$ é uma função sigmoideal apresentada na Equação (5.5):

$$f_R(u) = \frac{1}{1 + \exp(-u)} \quad (5.5)$$

Por simplicidade, utilizou-se para análise uma rede de três camadas. Usou W_{ml} para o peso entre o neurônio de entrada l e o neurônio da camada oculta m , V_{nm} , para o peso entre o neurônio da camada oculta m e o neurônio de saída n , q_m , como o limiar do neurônio da camada oculta m , e g_n como o limiar do neurônio de saída n , respectivamente. Sendo que I_l , H_m e O_n denotam o valor do neurônio de entrada l , do neurônio da camada oculta m e do neurônio de saída n , respectivamente. Sendo que, também, U_m e S_n denotam o potencial interno do neurônio da camada oculta m e do neurônio de saída n , respectivamente. Estes termos estão relacionados nas Equações (5.6) a (5.9).

$$U_m = \sum_l w_{ml} I_l + q_m \quad (5.6)$$

$$S_n = \sum_m v_{nm} H_m + g_n \quad (5.7)$$

$$H_m = f_C(U_m) \quad (5.8)$$

$$O_n = f_C(S_n) \quad (5.9)$$

O erro entre o padrão atual O_n e a meta T_n do neurônio de saída n é obtido pela Equação (5.10).

$$d^n = T_n - O_n \quad (5.10)$$

Pode-se definir o erro quadrático para um padrão p conforme Equação (5.11):

$$E_p = \frac{1}{2} \sum_{n=1}^N |T_n - O_n|^2 \quad (5.11)$$

onde, N é o número de neurônios de saída.

A regra de aprendizagem para o algoritmo *backpropagation* com valores complexos é descrita assumindo-se uma constante de aprendizagem suficientemente pequena (taxa de aprendizagem) $\hat{I} > 0$ e uma matriz unitária A . Demonstrou-se que os pesos e os limiares podem ser modificados conforme as Equações 5.12 a 5.15.

$$\Delta v_{nm} = \bar{H}_m \Delta \mathbf{g}_n \quad (5.12)$$

$$\Delta \mathbf{g}_n = \mathbf{e}(\operatorname{Re}[\mathbf{d}^n](1 - \operatorname{Re}[O_n])\operatorname{Re}[O_n] + i \operatorname{Im}[\mathbf{d}^n](1 - \operatorname{Im}[O_n])\operatorname{Im}[O_n]) \quad (5.13)$$

$$\Delta w_{ml} = \bar{I}_l \Delta \mathbf{q}_m \quad (5.14)$$

$$\begin{aligned} \Delta \mathbf{q}_m &= \mathbf{e}[(1 - \operatorname{Re}[H_m])\operatorname{Re}[H_m] \times \\ &\times \sum_n (\operatorname{Re}[\mathbf{d}^n](1 - \operatorname{Re}[O_n])\operatorname{Re}[O_n]\operatorname{Re}[v_{nm}] + \\ &+ \operatorname{Im}[\mathbf{d}^n](1 - \operatorname{Im}[O_n])\operatorname{Im}[O_n]\operatorname{Im}[v_{nm}]) - \\ &- i(1 - \operatorname{Im}[H_m])\operatorname{Im}[H_m] \times \\ &\times \sum_n (\operatorname{Re}[\mathbf{d}^n](1 - \operatorname{Re}[O_n])\operatorname{Re}[O_n]\operatorname{Im}[v_{nm}] - \\ &- \operatorname{Im}[\mathbf{d}^n](1 - \operatorname{Im}[O_n])\operatorname{Im}[O_n]\operatorname{Re}[v_{nm}])] \end{aligned} \quad (5.15)$$

O valor \bar{z} denota o complexo conjugado do número complexo z .

As regras para a atualização do algoritmo *backpropagation* são descritas pelas Equações (5.16) a (5.19).

$$\Delta v_{nm} = H_m \Delta \mathbf{g}_n \quad (5.16)$$

$$\Delta \mathbf{g}_n = \mathbf{e}(1 - O_n)O_n \mathbf{d}^n \quad (5.17)$$

$$\Delta w_{ml} = I_l \Delta \mathbf{q}_m \quad (5.18)$$

$$\Delta \mathbf{q}_m = (1 - H_m)H_m \sum_n v_{nm} \Delta \mathbf{g}_n \quad (5.19)$$

onde \mathbf{d}^n , I_l , H_m , O_n , v_{nm} , \mathbf{g}_n , w_{ml} , \mathbf{q}_m são todos números reais.

Neste trabalho este algoritmo foi implementado, no entanto, sem uma definição representativa para a detecção positiva ou negativa dos eventos epileptogênicos. Como as saídas obtidas são valores complexos é necessário uma definição representativa para a parte imaginária dos resultados.

Para esta implementação foram utilizados os mesmos arquivos de treinamento e teste propostos nos pré-processamentos no Capítulo 4 deste trabalho. Em uma análise preliminar dos resultados verificou-se que os valores das saídas representativos dos ruídos e das piscadas apresentam-se diferenciados dos valores representativos dos eventos epileptogênicos, ondas alfa e EEG de fundo. Dentro de um plano complexo as saídas relativas às piscadas e aos ruídos apresentam-se destacadas das demais.

5.2 Definições de uma Janela Adequada para o EEG

A Figura 5.3 fornece uma visualização das células de informação da decomposição tempo-frequência do sinal constituído da soma de senóides, formadas por três frequências diferentes. Foram utilizadas as janelas de Kaiser de diferentes tamanhos.

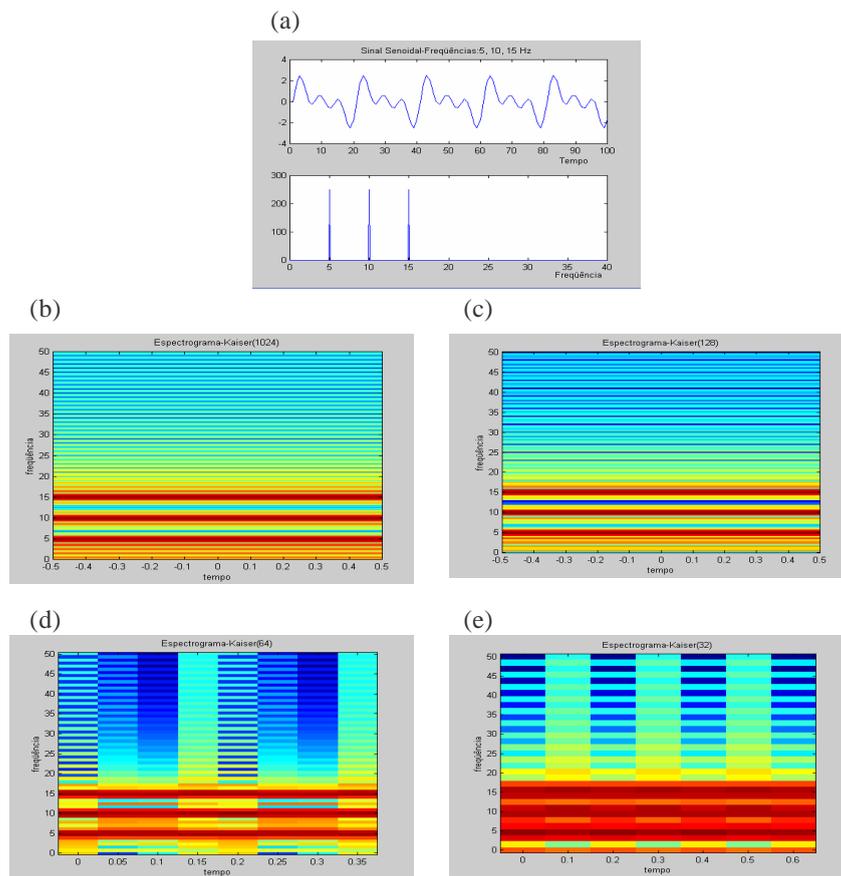


Figura 5.3- Decomposição do sinal resultante da soma de três senóides com frequências de 5, 10 e 15 Hz, destacadas pelas faixas vermelhas. Em (a), o sinal e seu correspondente espectro de frequências. Foram utilizadas as janelas de Kaiser de 1024, 128, 64 e 32 pontos, em (b), (c), (d) e (e), respectivamente.

Pode-se verificar na Figura 5.3 como os resultados relativos ao conteúdo das frequências vão ficando pouco definidos quando a dimensão da janela diminui no tempo. Até a análise com janela de 64 pontos tem-se uma boa identificação das três componentes de frequência. Já a localização das frequências para a janela de 32 pontos não é clara, apresentando áreas escuras entre 0 e 20 HZ. Diversas células de informação aparecem na decomposição sem estarem relacionadas com as frequências existentes no sinal.

Se diferentes frequências variam ao longo do sinal como na Figura 5.4 (a), a localização no tempo destas variações pode ser comprometida, dependendo do comprimento da janela utilizado. Neste caso, as janelas menores fornecem melhores resoluções no tempo.

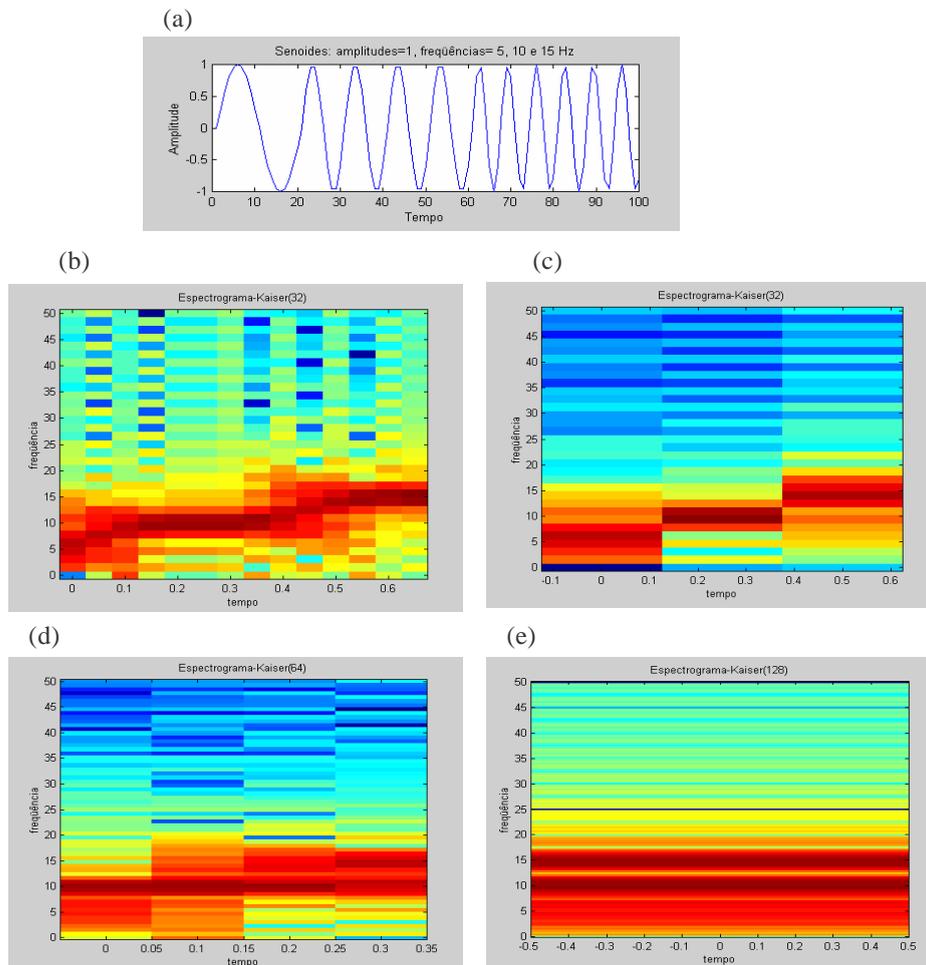


Figura 5.4- Em (a), decomposição de um sinal senoidal com frequências de 5, 10 e 15 Hz variando ao longo do tempo. (b) utiliza-se uma janela de Kaiser de 32 pontos. (c) utiliza-se uma janela de Kaiser de 32 pontos e valor de Dt maior do que em (b). (d) utiliza-se uma janela de Kaiser de 64 pontos. (e) utiliza-se uma janela de Kaiser de 128 pontos.

A janela de 128 pontos não distingue as variações das frequências no tempo, e a janela de 64 pontos mostra uma diferenciação pouco satisfatória. Contudo, a janela de 32 pontos distingue as variações das 3 frequências presentes no sinal.

Um fator importante além da definição do tipo e do tamanho da janela refere-se às dimensões de Dt no plano tempo-frequência. Como pode-se observar na Figura 5.5, os valores das frequências encontram-se bem definidos para as janelas de 512 e 64 pontos, mas o valor de Dt é grande e uma variação no tempo é dificilmente percebida. A janela de 32 pontos apresenta variações no espectro com o tempo, embora seja prejudicada a definição das frequências.

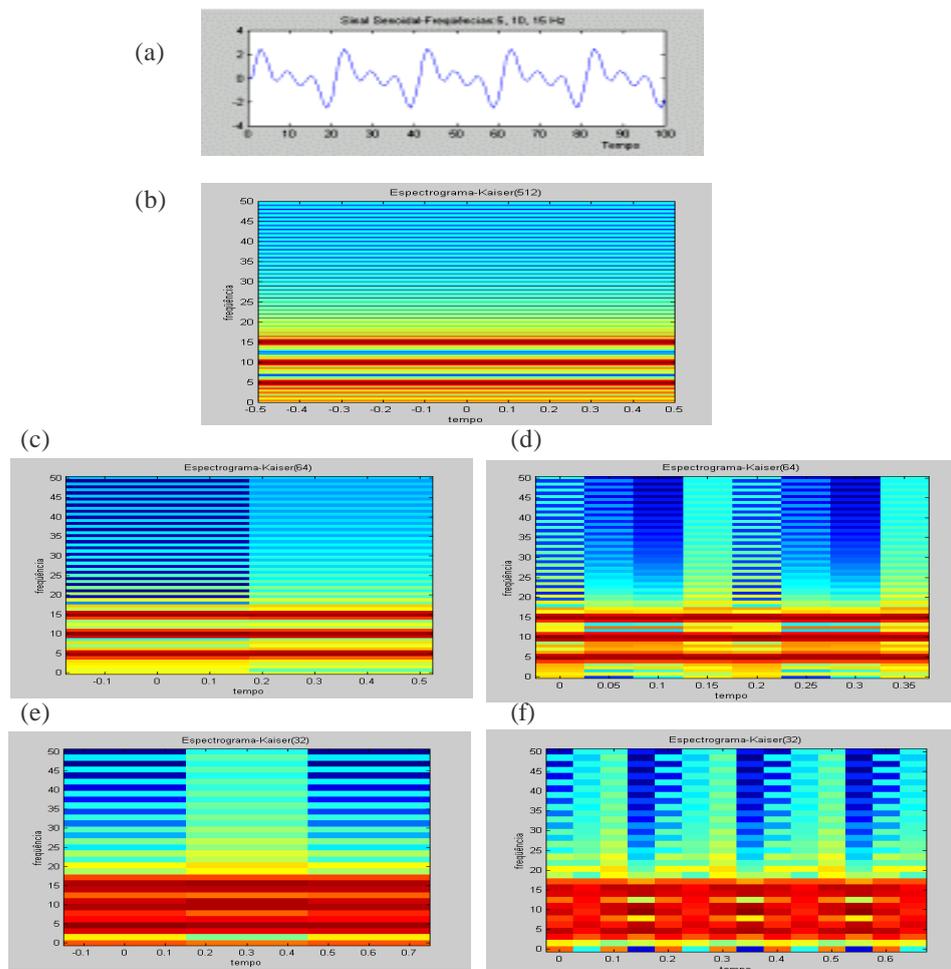


Figura 5.5- Em (a), decomposição do sinal com frequências de 5, 10 e 15 Hz usando a janela de Kaiser. Em (b), uma janela de 512 pontos; em (c), uma janela de 64 pontos e Dt maiores do que em (d); em (e) uma janela de 32 pontos e Dt maiores do que em (f).

A aplicação das janelas de Kaiser e de Chebyshev no desenvolvimento dos espectrogramas foi analisada utilizando-se sinais do EEG contendo eventos epileptogênicos.

Os espectrogramas com as janelas de Kaiser com 32 e 64 pontos foram traçados, variando os valores de Dt como mostrado na Figura 5.6.

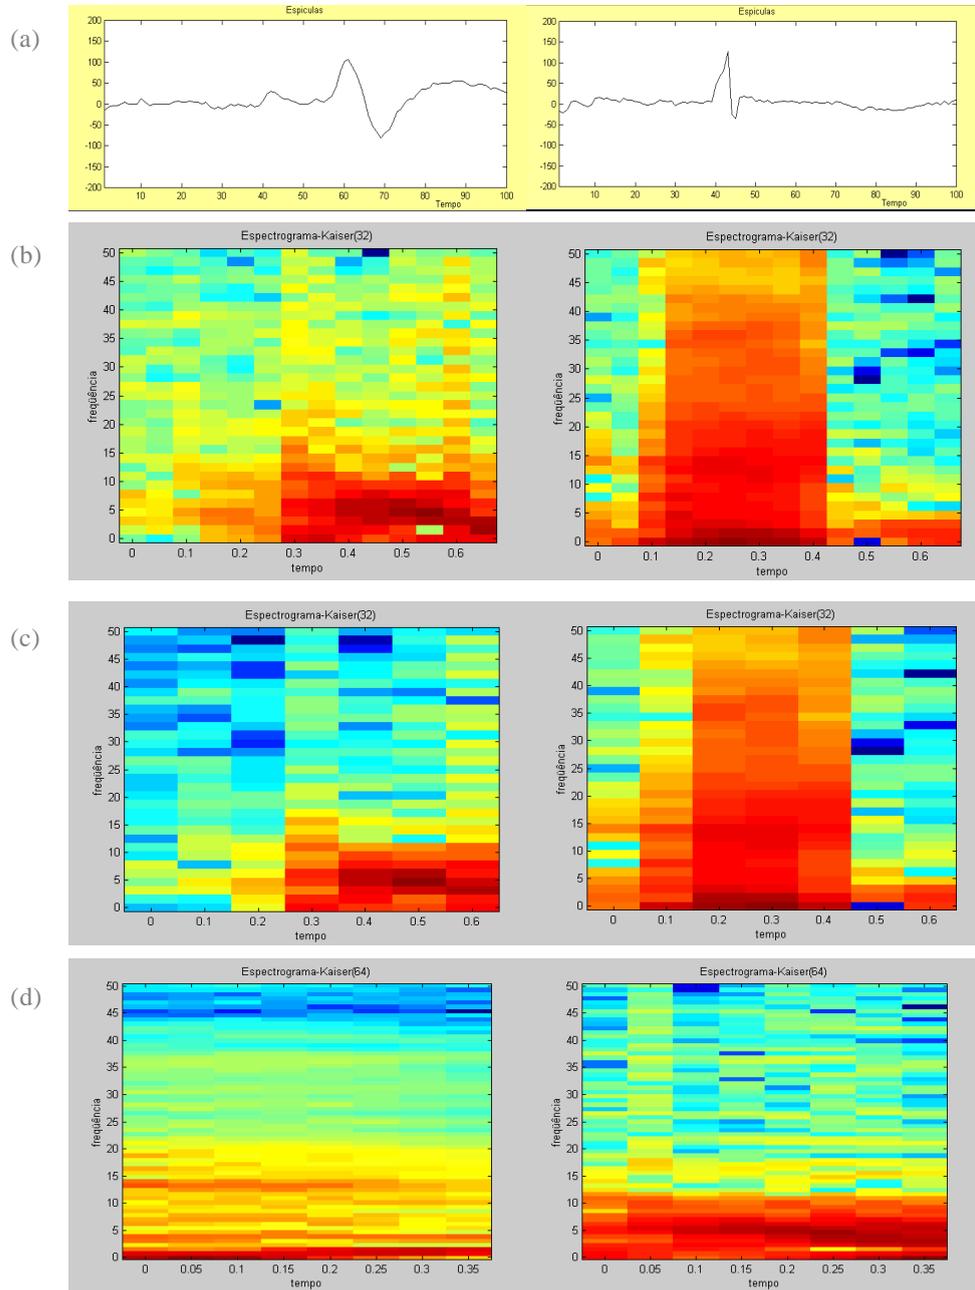


Figura 5.6- Espectrograma de dois sinais contendo eventos epileptogênicos, mostrados em (a). Em (b) e em (c) utiliza-se uma janela de Kaiser de 32 pontos e com os tamanhos de Dt aumentando de cima para baixo. Em (d) espectrogramas obtidos com uma janela de Kaiser de 64 pontos.

De modo análogo, os espectrogramas com a janela de Chebyshev de 32 pontos foram traçados para dois sinais do EEG contendo evento epileptogênico como mostrado na Figura 5.7. Nesta figura foram utilizados pequenos valores de Dt .

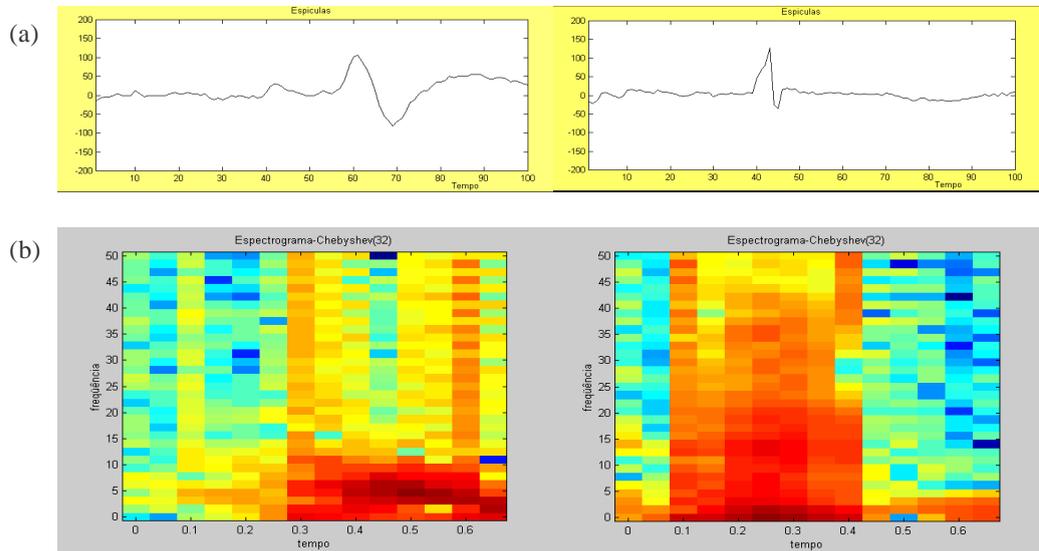


Figura 5.7: Espectrograma de dois sinais contendo eventos epileptogênicos, mostrados em (a). Em (b), resultados utilizando uma janela de Chebyshev de 32 pontos.

Os espectrogramas resultantes da aplicação da janela de Kaiser de 32 e 64 pontos evidenciam que as janelas de 64 pontos não oferecem definição das alterações em freqüência ocorridas ao longo do sinal, apresentando um espectro concentrado em torno de 0 a 15 Hz e estendendo-se ao longo do eixo do tempo. Mesmo em uma janela pequena, de tamanho 32, este efeito aparece, havendo necessidade de diminuir o tamanho do reticulado do plano tempo-freqüência, para aumentar, de certa forma, a resolução obtida nos resultados. O efeito do tamanho das células do reticulado pode ser observado na Figuras 5.6 (b), onde as menores células aumentam tanto a resolução no tempo como na freqüência dos resultados.

Assim, quanto maior o número de retângulos cobrindo o plano, mais as variações no tempo e na freqüência do sinal apresentam-se definidas. No entanto, um maior número de células implica em uma maior quantidade de dados a serem manipulados, já que cada coluna do reticulado representa uma coluna de dados na matriz que define cada plano. Se estas colunas forem utilizadas como entradas de uma RNA, quanto maior o número de reticulados, maior é a quantidade de neurônios de entrada.

Escolheu-se a janela de Kaiser com 32 pontos para a análise tempo-freqüência deste trabalho. Pois, a janela de Kaiser, como vem sendo evidenciado nos resultados parciais, oferece uma melhor definição das freqüências, principalmente nas baixas freqüências, próximas às freqüências componentes dos sinais do EEG.

A opção em utilizar-se células menores (menor Dt) para o reticulado do plano tempo-freqüência gera uma grande quantidade de colunas para este plano. Contudo, gera uma razoável definição tanto da freqüência como do tempo de ocorrência do evento. Em conseqüência, aumenta consideravelmente o número de neurônios de entrada da rede, o que acarreta um substancial aumento no seu tempo de treinamento. Para as aplicações com RNA foram estipuladas 14 colunas e 33 linhas para o reticulado do plano tempo-freqüência, gerando 462 entradas para cada trecho de 1 segundo do sinal apresentado.

5.3 Entrada e Saída das Redes

Como as entradas das RNA's são dados relativos ao espectrograma, que gera como resultado valores complexos, foram treinadas redes com os valores absolutos, que representam as magnitudes do espectrograma obtido para cada trecho de 1 segundo do sinal.

Os trechos de 1 segundo do EEG são pré-processados gerando o espectrograma, que fornece os valores em magnitudes que representam as entradas da rede, conforme o esquema da Figura 5.8.

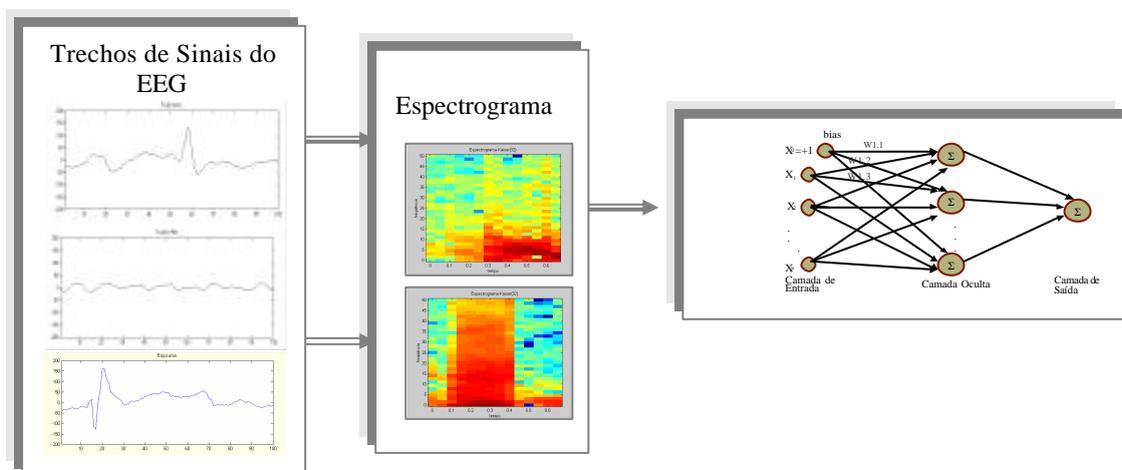


Figura 5.8- Proposta para a configuração da rede cujas entradas encontra-se o espectrograma dos trechos dos sinais do EEG.

A arquitetura para as RNA's em estudo é a mesma já relatada no Capítulo 2 deste trabalho. Como foram utilizados 462 neurônios de entrada, iniciou-se a implementação das redes com 22 neurônios na camada oculta. Este valor inicial foi obtido através da relação que faz o tamanho da camada oculta ser igual à raiz quadrada do produto do número de neurônios de entrada pelo número de neurônios de saída [46].

Nas Figuras 5.9 a 5.13 pode-se visualizar os espectrogramas típicos dos trechos de 1 segundo dos sinais do EEG contendo evento epileptogênico, bem como eventos que podem ser encontrados juntamente com o evento epileptogênico, como ruídos e piscadas. As diferenças entre os espectros destes eventos devem possibilitar a identificação dos eventos epileptogênicos. Espera-se que quanto mais caracterizados e mais diferenciados estiverem, maior a possibilidade de uma identificação correta da rede.

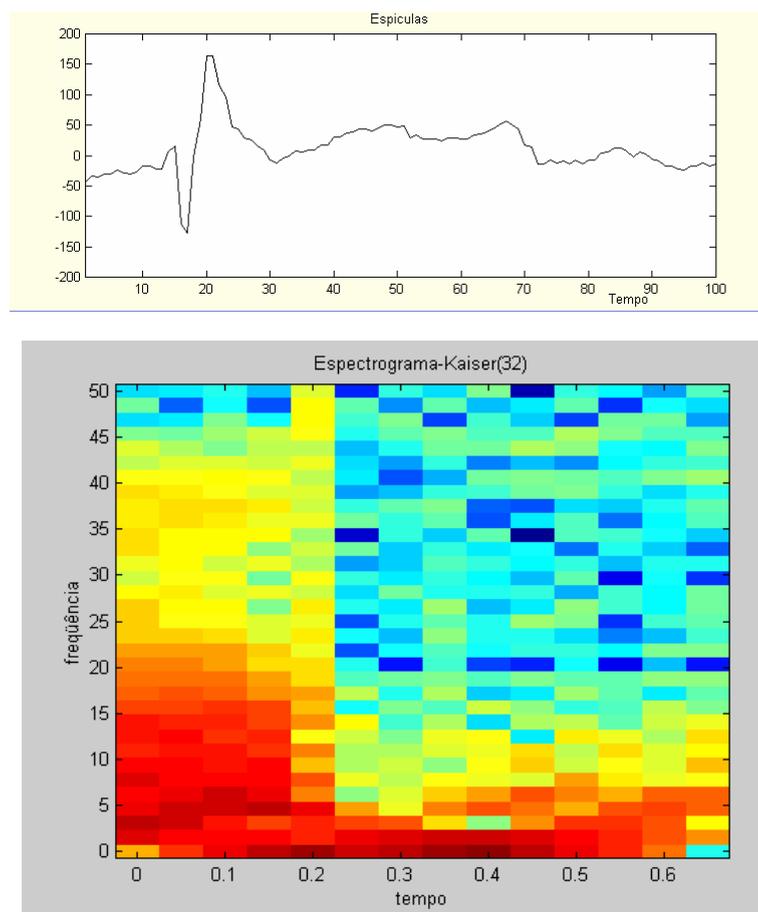


Figura 5.9- Registro do EEG com evento epileptogênico e seu respectivo espectrograma típico obtido utilizando-se a janela de Kaiser.

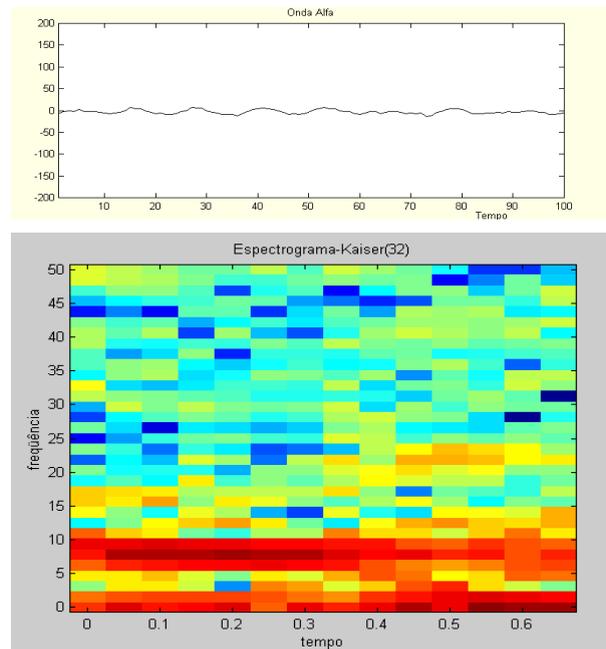


Figura 5.10- Registro do EEG com ondas alfa e seu respectivo espectrograma típico obtido utilizando-se a janela de Kaiser.

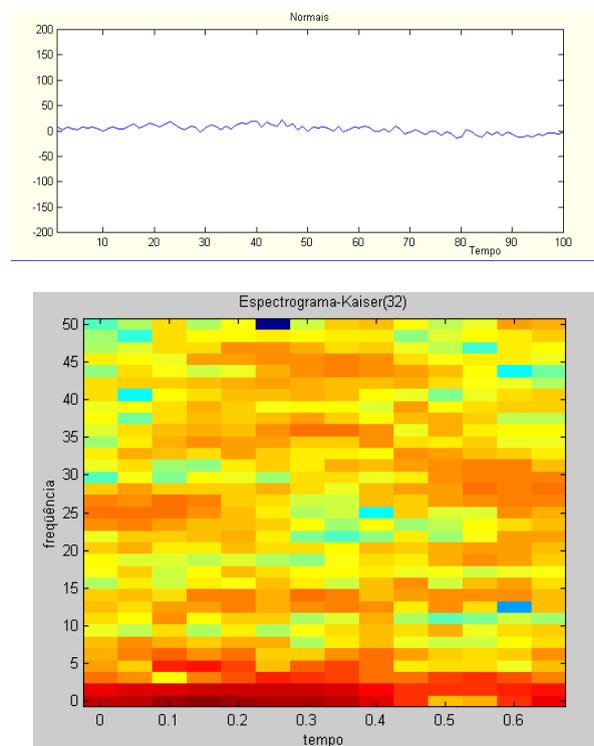


Figura 5.11- Registro do EEG de fundo e seu respectivo espectrograma típico obtido utilizando-se a janela de Kaiser.

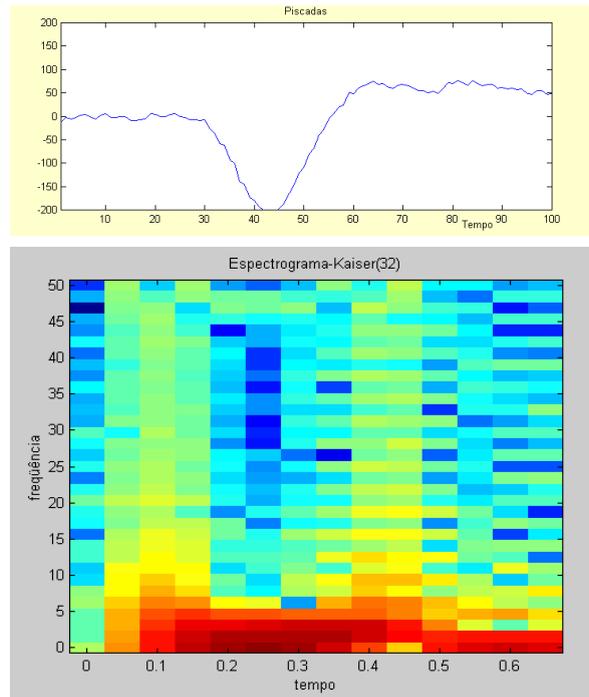


Figura 5.12- Registro do EEG com piscada e seu respectivo espectrograma típico obtido utilizando-se a janela de Kaiser.

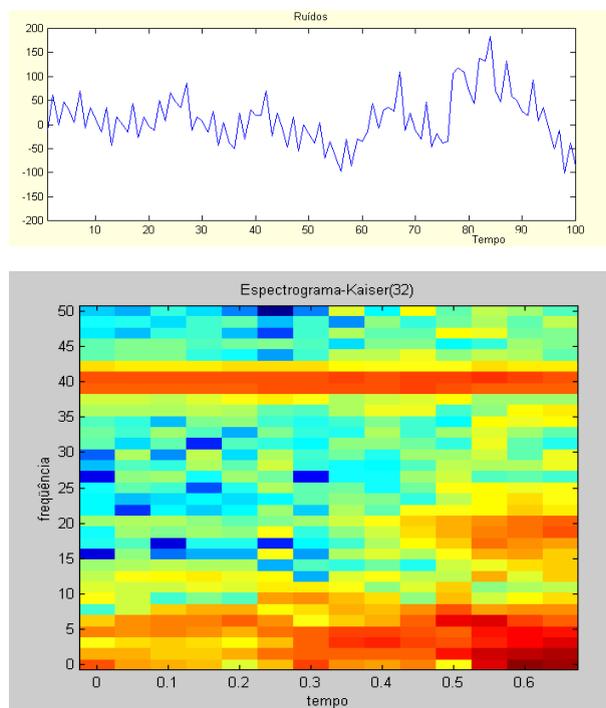


Figura 5.13- Registro do EEG com ruído e seu respectivo espectrograma típico obtido utilizando-se a janela de Kaiser.

O trecho de maior energia no espectrograma do sinal contendo um evento epileptogênico concentra-se exatamente na região correspondente ao evento e na faixa de frequência crítica da epilepsia. Pode-se observar na Figura 5.9 uma maior concentração de energia entre as frequências 2 e 20 Hz e nos pontos relativos a posição exata do evento epileptogênico, considerada a faixa crítica da epilepsia, esta característica não ocorre nos demais espectrogramas.

Nos sinais contendo ondas alfa as maiores energias espalham-se ao longo do tempo. Ele apresenta concentração nas baixas frequências, nas faixas de 5 a 10 Hz. Pode-se observar uma certa constância nas frequências apresentadas pelas ondas alfa, e isto proporciona que os espectrogramas dos eventos epileptogênicos possam ser diferenciados daqueles das ondas alfas.

Os espectrogramas dos sinais contendo EEG normal de fundo mostram uma distribuição uniforme de frequências bastante baixa, em média de 2 Hz, ao longo de todo o período. Diferentemente dos sinais contendo eventos epileptogênicos, que possuem células de maior energia (cores mais fortes) concentradas nos instantes correspondentes à ocorrência do evento.

A característica de concentração das células de maior energia destaca-se das demais em espaço de tempo, ela pode ser encontrada também em sinais contendo piscadas. Este fato pode fazer com que os sinais com piscadas sejam confundidos com os eventos epileptogênicos, aumentando o número de falsos positivos. No entanto, as piscadas possuem um maior período de duração, com variações mais lentas, comparadas aos eventos epileptogênicos. Assim, os sinais com piscadas possuem as células de maior energia concentradas em regiões de menores frequências do plano.

Os espectros dos sinais com ruídos são os que mais se diferenciam daqueles contendo eventos epileptiformes. Apresentam frequências bem maiores e células de maior energia espalhadas em toda a extensão do plano.

5.4 Treinamento e Teste das RNA's com Entradas Pré-Processadas Utilizando a Análise Tempo-Frequência

Os conjuntos de treinamento e teste foram os mesmos utilizados nas redes desenvolvidas anteriormente neste trabalho. Utilizou-se arquivos com e sem caracterização prévia dos sinais de entrada, como mostrado na Figura 5.14.

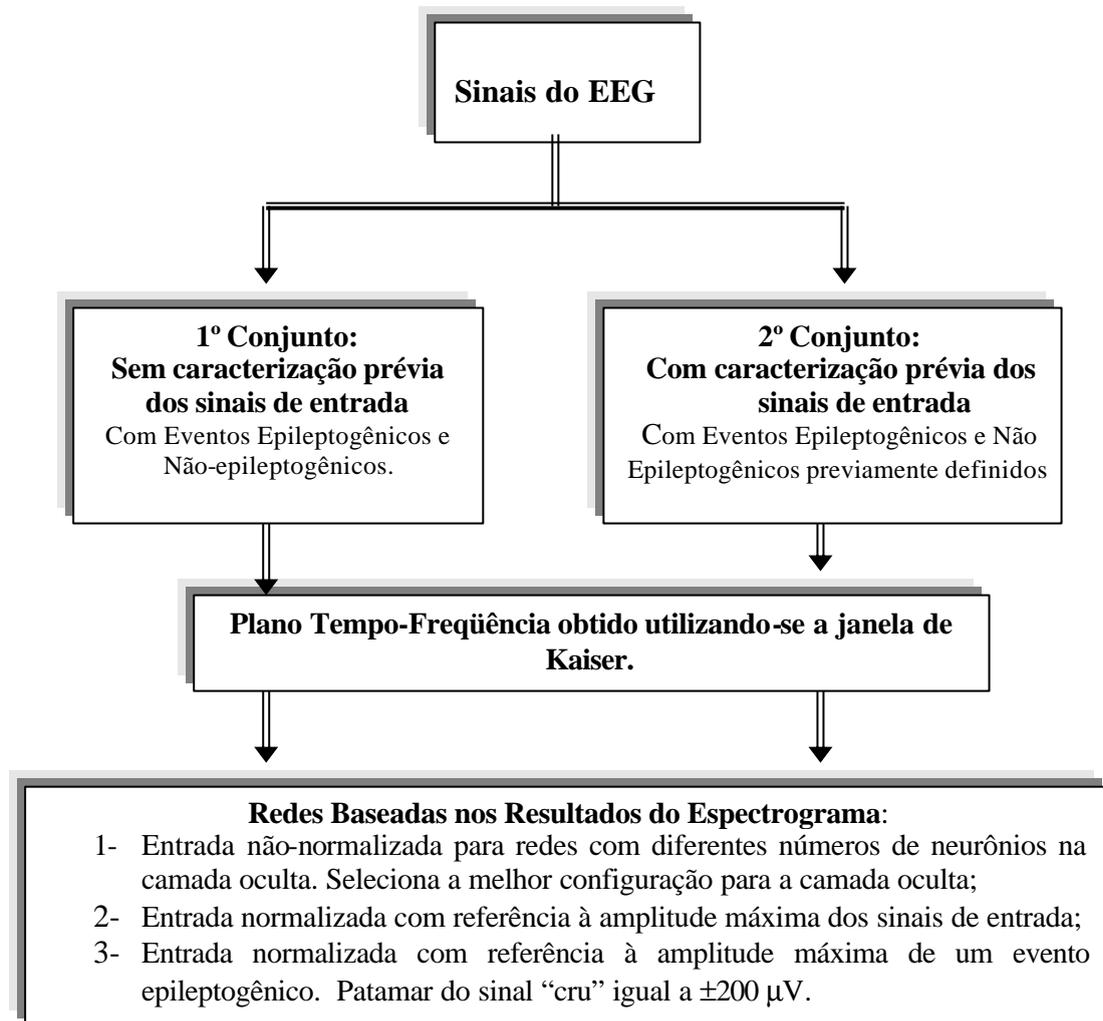


Figura 5.14- Desenvolvimento das RNA's com entradas baseadas nos valores dos espectrogramas dos sinais.

Foram treinadas redes variando-se o número de neurônios na camada oculta, estipulando-se um número máximo de 100.000 interações e verificando-se qual forneceu o melhor resultado. Utilizou-se entradas normalizadas e não-normalizadas. A normalização foi realizada nas entradas das redes conforme o valor máximo real obtido a partir dos resultados do espectrograma e conforme o valor máximo real dos espectrogramas, os quais foram obtidos do conjunto de sinais, cujas amplitudes não ultrapassavam o patamar já estabelecido de $\pm 200 \mu V$.

5.5- Resultados e Análise dos Resultados

Os gráficos resultantes dos treinamentos das redes são encontrados no Anexo B deste trabalho. O tempo de treinamento das redes foi longo, chegando a 4 a 5 horas (Microprocessador HP 950 MHz). Na maioria dos casos não houve uma redução substancial no tempo de treinamento com o uso de entradas normalizadas.

5.5.1 RNA sem caracterização prévia dos sinais de entrada

Como nos outros tipos de pré-processamento, estas redes foram treinadas com os espectros de 47 sinais com eventos epileptogênicos e 73 sinais com eventos não-epileptogênicos. O conjunto de teste formado pelos espectros de 30 sinais com eventos epileptogênicos e 23 sinais com os eventos não-epileptogênicos, gerou os resultados mostrados nas Tabelas 5.1 e 5.2. Nestas tabelas o conjunto de teste utilizado foi 53 espectrogramas.

Tabela 5.1- Avaliação da eficiência das redes através dos números de acertos, valores indefinidos, verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN), com entradas pré-processadas e sem caracterização prévia dos sinais.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
23 N. Ocultos 100.000 Interações	30 57%	16	24	18	5	6
27 N. Ocultos 100.000 Interações	41 77%	8	25	20	3	5
28 N. Ocultos, 100.000 Interações	40 75%	8	25	20	3	5
31 N. Ocultos 100.000 Interações	42 79%	7	26	20	3	4
27 N. Ocultos Normalizada 100.000 Interações	28 53%	2	27	1	22	3
27 N. Ocultos Normalizada p/ Espícula 100.000 Interações	31 58%	6	28	7	16	2

Tabela 5.2- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo obtidos pelas mesmas redes da Tabela 5.1.

Rede	Sensibilidade	Especificidade	VPP	VPN
23 N. Ocultos 100.000 Interações	0,80	0,78	0,83	0,75
27 N. Ocultos 100.000 Interações	0,83	0,87	0,89	0,80
28 N. Ocultos 100.000 Epocas	0,83	0,87	0,89	0,90
31 N. Ocultos 100.000 Interações	0,87	0,87	0,89	0,83
27 N. Ocultos Normalizada 100.000 Interações	0,90	0,05	0,55	0,25
27 N. Ocultos Normalizada p/ Espícula 100.000 Interações	0,93	0,30	0,63	0,78

Este mesmo conjunto de teste, formado por 53 espectrogramas, acrescido de mais 5 espectrogramas de sinais contendo piscadas, gerou os resultados das Tabelas 5.3 e 5.4.

Tabela 5.3- Resultados obtidos pelas redes sem caracterização prévia dos sinais de entrada.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
23 N. Ocultos 100.000 Interações	31 53%	18	24	21	7	6
27 N. Ocultos 100.000 Interações	42 72%	9	25	22	6	5
28 N. Ocultos 100.000 Interações	40 69%	9	25	21	7	5
31 N. Ocultos 100.000 Interações	42 72%	7	26	20	8	4
27 N. Ocultos Normalizada 100.000 Interações	29 50%	6	29	5	23	1
27 N. Ocultos Normalizada p/ Espícula 100.000 Interações	32 55%	13	26	16	12	4

Tabela 5.4- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo obtidos utilizando-se as mesmas redes da Tabela 5.3.

Rede	Sensibilidade	Especificidade	VPP	VPN
23 N. Ocultos 100.000 Interações	0,80	0,75	0,77	0,78
27 N. Ocultos 100.000 Interações	0,83	0,79	0,81	0,81
28 N. Ocultos 100.000 Interações	0,83	0,75	0,78	0,81
31 N. Ocultos 100.000 Interações	0,87	0,71	0,76	0,83
27 N. Ocultos Normalizada 100.000 Interações	0,97	0,18	0,56	0,83
27 N. Ocultos Normalizada p/ Espícula 100.000 Interações	0,87	0,57	0,68	0,80

Com o acréscimo dos 5 sinais contendo piscadas a taxa de acertos de 79% caiu para 72%. No entanto, os valores de sensibilidade permanecem em torno de 83%, mas a especificidade diminui de 87% para 75%.

A rede com 31 neurônios ocultos alcançou uma sensibilidade de 0,87, uma especificidade de 0,71 e pode ser destacada como a organização de neurônios ocultos mais adequada.

A rede com entrada normalizada obteve elevado valor de falsos positivos, chegou a detectar erroneamente até 23 sinais como contendo evento epileptogênico. Este fato diminuiu o número de acertos e fez cair a taxa de especificidade. Por outro lado, esta rede gerou poucos falsos negativos, mostrando que conseguiu identificar os sinais contendo evento epileptogênico, e levando também a uma boa taxa para a sensibilidade. A normalização proposta na entrada da rede, através do truncamento puro do sinal com amplitude superior ao patamar de $\pm 200 \mu V$, não melhorou substancialmente os resultados.

O aumento de 3 para 6 falsos positivos, no caso da rede com 27 neurônios ocultos, utilizando o conjunto de teste contendo piscadas, revela que a rede interpretou 3 sinais contendo piscadas como sinais contendo eventos epileptogênicos.

5.5.2- RNA com caracterização prévia dos sinais de entrada

Na segunda linha de abordagem do conjunto de treinamento, foram selecionados os registros conforme grupos pré-estabelecidos, com os sinais contendo evento epileptogênico, bem como, sinais contendo eventos não-epileptogênicos, como ruídos e piscadas, conforme mostrado no Capítulo 2 deste trabalho.

Os resultados do número de acertos, falsos positivos e negativos são encontrados na Tabela 5.5, e os valores de sensibilidade e especificidade são encontrados na Tabela 5.6.

Nestas tabelas o conjunto de teste utilizado foi de 45 espectrogramas.

Tabela 5.5- Resultados obtidos pelas redes com caracterização prévia dos sinais de entrada.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
22 N. Ocultos 100.000 Interações	21 47%	13	17	5	10	3
26 N. Ocultos 100.000 Interações	30 67%	8	19	19	6	2
28 N. Ocultos 100.000 Interações	30 67%	10	19	21	4	1
26 N. Ocultos Normalizada 35.206 Interações	31 69%	5	19	17	8	1
26 N. Ocultos Normalizado p/espícula 31.975 Interações	27 60%	8	19	16	9	1

Tabela 5.6- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, obtidos utilizando-se as mesmas redes da Tabela 5.5.

Rede	Sensibilidade	Especificidade	VPP	VPN
22 N. Ocultos 100.000 Interações	0,85	0,60	0,63	0,83
26 N. Ocultos 100.000 Interações	0,90	0,76	0,75	0,90
28 N. Ocultos 100.000 Interações	0,95	0,84	0,83	0,95
26 N. Ocultos Normalizada 35.206 Interações	0,95	0,68	0,70	0,94
26 N. Ocultos Normalizado p/espícula 31.975 Interações	0,95	0,64	0,68	0,94

Deve-se ressaltar que em todas as redes os eventos epileptogênicos foram praticamente identificados corretamente (valor 1 de falsos negativos), aumentando o valor da sensibilidade. A dificuldade está na identificação errônea dos eventos não-epileptogênicos como epileptogênicos, fato que eleva o número de falsos positivos e reduz a especificidade.

A rede com 28 neurônios ocultos obteve 90% de sensibilidade e 84% de especificidade, sendo ressaltada das demais.

Para este caso, a normalização não alterou substancialmente os resultados,.

5.6- Conclusões e Discussões

Nas Tabelas 5.7 e 5.8 estão mostradas as melhores representações para as redes usando valores complexos obtidos com os espectrogramas dos sinais de entrada.

Tabela 5.7- Resumo dos melhores resultados obtidos pelas redes considerando-se os valores dos espectrogramas como entradas.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
Sem caracterização dos sinais e 53 sinais de teste 31 N. Ocultos e 100.000 Interações	42 79%	7	26	20	3	4
Sem caracterização dos sinais e 58 sinais de teste 31 N. Ocultos e 100.000 Interações	42 72%	7	26	20	8	4
Com caracterização dos sinais e 45 sinais de teste 28 N. Ocultos e 100.000 Interações	30 67%	10	19	21	4	1

Tabela 5.8- Valores de sensibilidade, especificidade, valor preditivo positivo (VPP) e valor preditivo negativo (VPN), utilizando-se as redes da Tabela 5.7.

Rede	Sensibilidade	Especificidade	VPP	VPN
Sem caracterização dos sinais e 53 sinais de teste 31 N. Ocultos e 100.000 Interações	0,87	0,87	0,89	0,83
Sem caracterização dos sinais e 58 sinais de teste 31 N. Ocultos e 100.000 Interações	0,87	0,71	0,76	0,83
Com caracterização dos sinais e 45 sinais de teste 28 N. Ocultos e 100.000 Interações	0,95	0,84	0,83	0,95

Observa-se uma ligeira melhora nos resultados, quando comparados com os da rede utilizando-se nas entradas o sinal sem pré-processamento. Estas redes chegam a apresentar valores de sensibilidade em torno de 90% e especificidade em torno de 85%, enquanto as redes sem pré-processamento apresentaram valores de sensibilidade em torno de 80% e especificidade em torno de 70%.

Para sinais relativamente simples, fazendo-se o ajuste adequado do tamanho da janela, pode-se obter resultados satisfatórios na análise do sinal, usando-se a transformada de Fourier com janela. Como as células de informação desta transformada são uniformes, se o sinal possui frequências de valores muito variáveis não é possível obter-se uma janela de largura adequada que tenha boas propriedades de localização tempo-frequência, de todos os valores de frequência envolvidos.

O problema com a STFT é que a janela de análise pequena sobrepõe-se de certa forma à potência do sinal e falha para representá-lo adequadamente, devido à sua baixa resolução espectral. Contudo, a resolução espectral da STFT pode ser melhorada com o uso de uma janela de dados maior, porém isso compromete a suposição de estacionaridade obtida com a janela. A STFT pode ser utilizada para analisar um sinal se este estiver muito concentrado em um dado intervalo de tempo e em um intervalo de frequência [71].

Recentemente, métodos tempo-escala, como a transformada *wavelet*, têm sido propostos para superar as limitações dos métodos tradicionais tempo-frequência.

Vários outros métodos, que possuem análises semelhantes são encontrados na literatura, principalmente relacionados a análise de frequências. Contudo, os métodos abordados neste trabalho são considerados os mais tradicionais e os mais utilizados nos últimos anos. Eles foram escolhidos como uma seqüência de estudos desde a transformada de Fourier a transformada *wavelet*.

CAPÍTULO 6

6. RNA'S COM ENTRADAS PRÉ-PROCESSADAS UTILIZANDO-SE A TRANSFORMADA WAVELET

A transformada *wavelet* é um método matemático desenvolvido em 1984 por Grossmann e Morlet, inicialmente denominada de *Ondelettes*. Esta transformada consiste na representação em tempo e frequência de um sinal, como a Transformada de Fourier de Curto Termo (*Short-Time Fourier Transforms* (STFT)). Contudo, possui características que permitem superar as deficiências encontradas na Transformada de Fourier de Curto Termo [71].

A STFT, representada pelos espectrogramas, consegue definir a localização das frequências no tempo. No entanto, conforme o tamanho da janela, a resolução no tempo ou na frequência fica comprometida. Sendo uma janela pequena, tem-se boa localização da informação no tempo. Sendo uma janela grande, a definição das componentes de frequência melhora, mas perde-se a resolução no tempo. Sendo assim, deseja-se uma transformada que permita variar o tamanho desta janela e fornecer uma boa resolução tanto no tempo como na frequência [87].

A transformada *wavelet* foi formalizada utilizando-se janelas de tempo com tamanhos variados, de diferentes larguras através dos processos de “dilatação”. Em adição, a transformada é calculada deslocando-se estas janelas ao longo do sinal, através do processo de “translação”.

Na literatura existem muitos relatos, que abrangem os conceitos em torno da transformada *wavelet*. Como referência, pode-se citar os trabalhos de Akay [69], Cohen [70] e Haykin [71]. Algumas aplicações simples são fornecidas por Gomes [79]. Como referência, também, são destacadas a tese de Argoud [1] e a tese de Esteller [16], por utilizar a transformada *wavelet* para detectar crises relacionadas à epilepsia. E, um relato sintetizado, porém, de forma abrangente, pode-se citar o guia de *wavelet* publicado por Misiti [91].

Nos últimos anos, muitos estudos vêm sendo relatados empregando a transformada *wavelet* como ferramenta de análise. Na maioria dos casos, ela é tratada na sua forma clássica ou através de pacotes *wavelets*.

Existem alguns trabalhos que focalizam um estudo da transformada *wavelet* e Entropia, como a tese defendida por Quiroga [10], que relata esta técnica e sua aplicação em sinais do EEG relacionados a crises epilépticas e eventos relativos a potenciais evocados. O Método da entropia também foi mencionado no trabalho de Diabra [92], que apresenta um algoritmo para a análise de atividades epilépticas.

Os pacotes *wavelets* vêm sendo largamente utilizados, e na maioria das vezes, como um método para compressão de sinais do EEG, como descrito por Accardo [93].

A forma tradicional de uso desta transformada é explorada em inúmeros trabalhos, mas todos relativos a sinais do EEG e com poucos tratando de sinais do EEG com eventos epileptogênicos. A maioria emprega uma das *wavelets* bases sem definir o porquê da sua escolha. Dentre estes trabalhos pode-se destacar o publicado por Osorio [84], que usa a *wavelet* de Daubechies, para previsão de crises epilépticas. A *wavelet* de Morlet é aliada a gráficos tridimensionais, para a análise de espículas, em um trabalho publicado por Barreto [94]. Outras *wavelets* bases também podem ser encontradas em alguns trabalhos relativos a sinais do EEG, como a *wavelet* Hermite, descrita por Geva [95] e a *wavelet* Bi-Escala descrita por Mason [96]. Algumas aplicações com a *wavelet* bifásica e agrupamentos *Fuzzy* dinâmicos não supervisionados, foram relatados por Geva [12].

Petrosian [11] utilizou a *wavelet* e a rede recorrente tendo como objetivo as previsões das crises epilépticas. E Kim [97], utilizou vários processos gráficos para visualizar os resultados das *wavelets* em sinais do EEG.

6.1 A Transformada *Wavelet*

A transformada *wavelet* elimina o problema da FFT para obter a decomposição atômica das células no domínio tempo-frequência. A transformada de Fourier de janela introduz uma escala fixa e analisa o sinal do ponto de vista desta escala. Se o sinal possui detalhes importantes fora desta escala, tem-se um problema de análise. E, detalhes do sinal menores que a largura da janela não são localizados, apesar de serem detectados. O problema inverte-se se as características forem muito maiores que a largura da janela. Para resolver este problema deve-se definir uma transformada independente da escala.

O processo de variação da escala de uma função pela transformada *wavelet* pode ser facilmente compreendido observando-se as diferenças entre a representação tempo-

freqüência da Transformada Rápida de Fourier e a representação tempo-escala da transformada *wavelet*, como mostrado na Figura 6.1.

A STFT possui uma resolução fixa, enquanto a transformada *wavelet* possui uma capacidade de múltipla resolução. A transformada *wavelet* divide o plano tempo-freqüência em retângulos que possuem a mesma área, mas com altura e largura variáveis, que dependem da freqüência da portadora W da função *wavelet* base. Assim, diferente da STFT, a transformada *wavelet* fornece um compromisso entre as resoluções de tempo e freqüência, que são representadas pelas larguras e alturas dos retângulos, respectivamente.

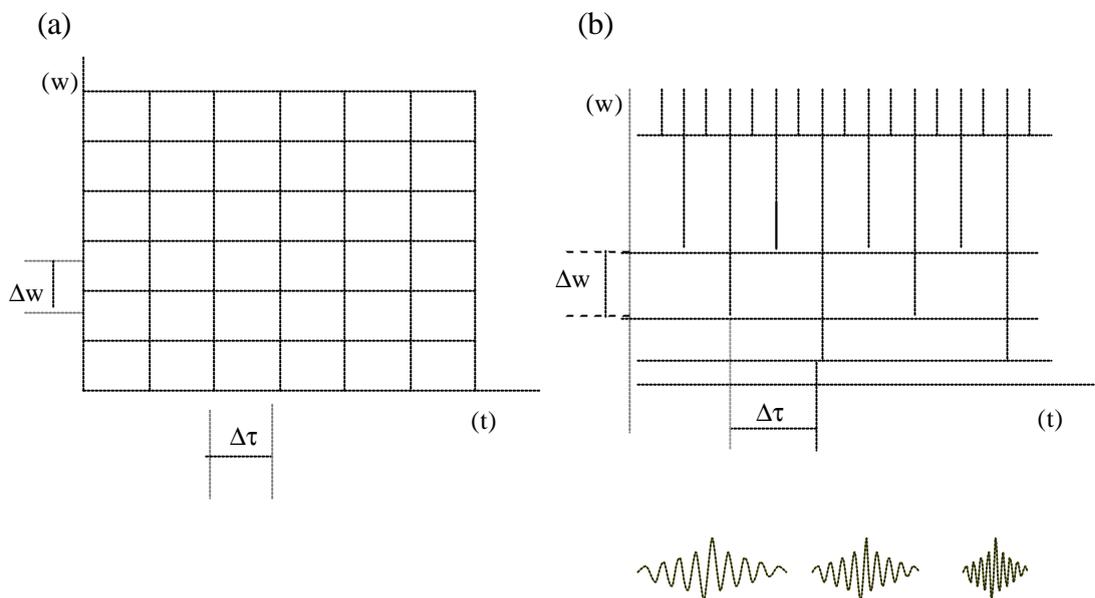


Figura 6.1- Em (a), representação do reticulado do plano tempo-freqüência da STFT. Em (b), representação tempo-escala (escalograma) da transformada de *wavelet* contínua.

O escalograma da Figura 6.1 (b) representa, no eixo vertical, uma escala a , aumentando no sentido inverso de W e, no eixo horizontal, o tempo t e os valores de translação t , aumentando com t .

6.1.1 Formalizações para a transformada *wavelet*

A transformada *wavelet* combina as variações de escala e deslocamento. Sua definição em termos matemáticos é expressa como o produto interno de uma função $x(t)$ com uma família de funções bases denotadas como na Equação (6.1). Nesta equação, a é um fator de escala, ou parâmetro de dilatação, e τ é o retardo de tempo, ou parâmetro de translação. A função $\psi(t)$ é a janela de tempo a partir da qual outras funções podem ser obtidas.

$$y_{t,a}(t) = \frac{1}{\sqrt{|a|}} y\left(\frac{t-\tau}{a}\right) \quad (6.1)$$

O termo $\frac{1}{\sqrt{|a|}}$ tem a função de conservação da energia com a dilatação das funções *wavelets* filhas.

A transformada *wavelet* de um sinal não estacionário $x(t)$ é definida pela Equação (6.2), onde, ψ^* é o complexo conjugado da *wavelet* base.

$$W_x(\tau, a) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) y^*\left(\frac{t-\tau}{a}\right) dt \quad (6.2)$$

O parâmetro de translação τ fornece a posição da *wavelet* $y_{t,a}(t)$, enquanto o parâmetro de dilatação, ou escala, a controla seu conteúdo de frequência.

Com a transformada *wavelet* mede-se a similaridade entre o sinal $x(t)$ e a *wavelet* $y_{t,a}(t)$, para τ e a variáveis. As dilatações por $1/a$ resultam em diversas aplicações do sinal com resoluções diferentes.

A escala é definida pela largura da função de modulação, ou função *wavelet* base. A Figura 6.2 mostra a função de modulação de uma família de funções, para as possíveis variações de a .

Para $a \ll 1$, a *wavelet* $y_{t,a}(t)$ é uma versão altamente concentrada e contraída da *wavelet* base $\psi(t)$, com conteúdo de frequência concentrado a maior parte na faixa de alta frequência. Por outro lado, para $a \gg 1$, a *wavelet* $y_{t,a}(t)$ é muito espalhada e possui conteúdo de frequência concentrado a maior parte na faixa de baixas frequências. Quando uma função base é comprimida, sua frequência de portadora é aumentada pelo mesmo fator.

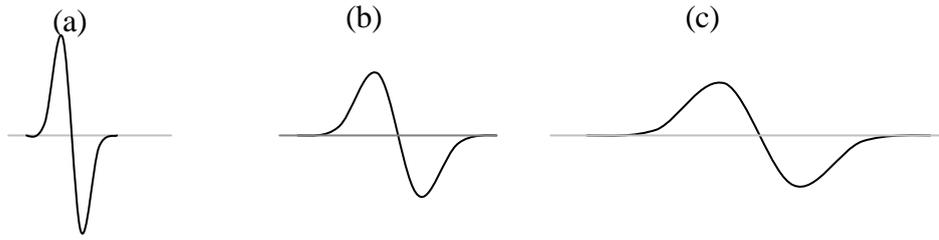


Figura 6.2- Escala de funções. Em (a), $a < 1$, a função *wavelet* é contraída. Em (b), $a = 1$. Em (c), $a > 1$, a função *wavelet* é dilatada.

Na transformada *wavelet*, a função base $y_{t,a}(t)$ é uma função oscilante. Mas, a função $e^{j\omega t}$ na análise de Fourier oscila ilimitadamente; por outro lado, a função base $y_{t,a}(t)$ na análise *wavelet*, está localizada no tempo e dura somente por alguns ciclos [71].

Os valores do escalograma são obtidos do módulo da transformada *wavelet* elevado ao quadrado, como definido pela Equação (6.3).

$$|W_x(\mathbf{t}, a)|^2 = \frac{1}{a} \left| \int_{-\infty}^{\infty} x(t) \mathbf{y}^* \left(\frac{t - \mathbf{t}}{a} \right) dt \right|^2 \quad (6.3)$$

Este escalograma representa a distribuição de energia do sinal no plano escala-tempo. Tanto no espectrograma quanto no escalograma a informação de fase do sinal $x(t)$ é perdida.

A variação da escala a nas *wavelets* é inversamente proporcional à variação da frequência. Assim, o espectro das componentes de uma *wavelet* não é dito como dependente da frequência, mas sim da escala a . Quando se varia a função *wavelet* segundo um valor alto de a , é como se o sinal $f(t)$ estivesse sendo submetido a um filtro passa-baixas, já que o sinal é correlacionado com a função *wavelet*. Ao contrário, um valor baixo de a filtra o sinal com um filtro passa-altas. Na prática, isso funciona como se estivesse ocorrendo uma decomposição de $f(t)$ em componentes, desde as mais "grosseiras" (com valor alto de a), até as mais "finas" (com valor pequeno de a). Esta aproximação de $f(t)$ "grosseira a fina", também é conhecida como *banco de filtros multirresolução*, ela é extremamente interessante para se utilizar em algoritmos de reconhecimento de estruturas, pois permite que se rastreie todas as possíveis variações de amplitude, frequência e fase de uma estrutura específica [79].

Segundo Haykin [71], a *wavelet* base $\psi(t)$ pode ser qualquer função passa-faixa que estabelece uma conexão com a janela moduladora na STFT, onde:

$$y(t) = w(t)e^{-jw_0t}$$

A janela $w(t)$ é uma função passa-baixas. Admitindo que w é a portadora de uma *wavelet* $y_{t,a}(t)$, o fator de escala a fica inversamente relacionado à frequência da portadora: $a=w_0/w$. Sendo Dw a resolução de frequência da *wavelet* e Q , uma constante, tem-se que: $(Dw/w)=Q$. A resolução no tempo da *wavelet* fica: $Dt = 1/2Dw = 1/2Qw$. Assim, a resolução no tempo $\Delta\tau$ varia inversamente com a frequência da portadora w da *wavelet* $y_{t,a}(t)$; logo, esta pode ser tomada como arbitrariamente pequena em altas frequências. E a resolução de frequência Dw varia linearmente com a frequência da portadora w da *wavelet* $y_{t,a}(t)$; logo, ela pode-se tornar arbitrariamente pequena em baixas frequências. Portanto, a transformada *wavelet* é apropriada para a análise de sinais não-estacionários que contenham transitórios de alta frequência sobrepostos a componentes de baixas frequências, de longa duração.

Um complemento das formulações relacionadas à transformada *wavelet*, bem como suas propriedades e condições para que uma função seja usada como *wavelet* base, encontra-se no Anexo C deste trabalho.

6.1.2 Função *wavelet* base

Uma das janelas mais utilizadas na transformada *wavelet* é a Gaussiana. Esta possui largura fixa e é denominada de “função de Gabor”. Esta função é mostrada na Figura 6.3. A Gaussiana é a função utilizada, pois sua transformada também tem comportamento Gaussiano, gerando pequeno espalhamento do espectro de frequências.



Figura 6.3- Funções Gaussianas de Gabor.

A função Gaussiana foi utilizada como *wavelet* pela primeira vez por Morlet, Morlet e Grossman e atualmente é conhecida como “base de Morlet”. Sua representação gráfica encontra-se no Anexo F deste trabalho.

As bases da transformada *wavelet* possuem várias representações como a *wavelet* de Haar, as *wavelets* de Daubechies, a *wavelet* Biortogonal, a *wavelet Coiflets* e a *wavelet Symlets*. Todas estas bases encontram-se descritas no Anexo F deste trabalho.

6.1.3 A transformada *wavelet* rápida

A transformada *wavelet* rápida permite uma implementação computacionalmente veloz da transformada *wavelet* discreta. O algoritmo foi desenvolvido por Sweldens em 1994, e inspirado no trabalho de Lounsbery e Donoho. Por apresentar baixo custo computacional, este algoritmo foi escolhido como opção no desenvolvimento deste estudo [71, 91].

A estrutura hierárquica do algoritmo da transformada *wavelet* rápida permite que se calcule esta transformada ou sua inversa utilizando-se apenas $2N$ operações, sendo mais rápida que a transformada rápida de Fourier [1].

O algoritmo da transformada *wavelet* rápida (FWT) implementa a decomposição de um sinal discreto utilizando *bancos de filtros espelho multirresolução em quadratura*. Isto é, um conjunto de filtros que vai extrair as características médias, definidas como *Aproximações*, do sinal. Estes são somados a um conjunto de filtros baseados nas funções *wavelets*, que extraem as características de alta frequência, definidas como *Detalhes*, do sinal. As *Aproximações* são as componentes de alta escala e baixas frequências do sinal e os *Detalhes* são as componentes de baixa escala e alta frequência [1, 91]. A Figura 6.4 generaliza a forma de obtenção destas *Aproximações (A)* e os *Detalhes (D)* utilizando um processo básico de filtragem.

No processo da Figura 6.4, para cada 100 pontos de amostra do sinal são obtidas 100 amostras para a *Aproximação* e 100 amostras para o *Detalhe*, resultando 200 amostras. Para uma redução nestas saídas, o algoritmo introduz um processo de subamostragem, resultando em um total de 50 coeficientes para a *Aproximação* e 50 coeficientes para o *Detalhe*, resultando em um total de 100 coeficientes.

O processo de decomposição por filtros passa-alta e passa-baixa pode interagir com múltiplas decomposições, originando a chamada “árvore de decomposição”, mostrada na Figura 6.5.

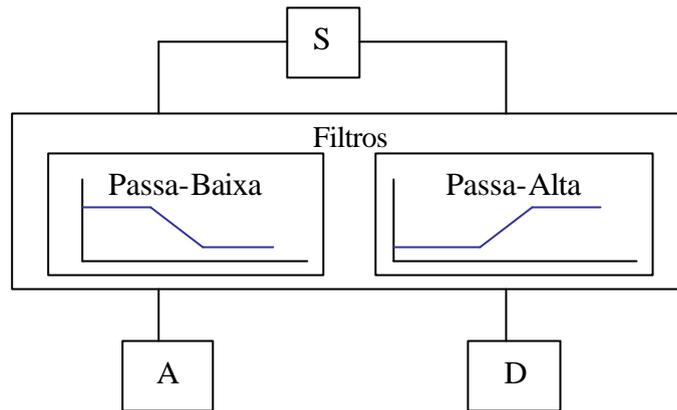


Figura 6.4- Processo de filtragem empregado na FWT, originando os níveis de *Aproximação (A)* e *Detalhe (D)*, [91].

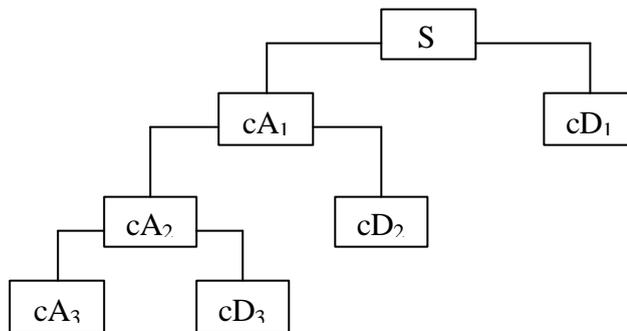


Figura 6.5- Árvore de decomposição para três níveis. Em cada nível são utilizados filtros passa-baixas obtendo as *Aproximações (A_n)* e filtros passa-altas obtendo os *Detalhes (D_n)*, [91].

6.1.4 Escolha da função *wavelet* básica

Para implementar qualquer processamento de sinal utilizando a transformada *wavelet*, uma das primeiras decisões a ser tomada é quanto à escolha da função *wavelet* base adequada, dentre as funções disponíveis. De modo geral, não se tem um critério ou uma metodologia, previamente definida, que indique qual a melhor função base para determinado caso específico.

Em muitos trabalhos já publicados não se verifica a preocupação de definir a função *wavelet* base adequada a sua aplicação. Em geral escolhe-se uma das funções disponível sem relacionar as causas da escolha. Contudo, uma escolha inadequada desta função compromete diretamente os resultados.

A questão da escolha da função *wavelet* base para este estudo parte do princípio de que esta função deve estar o mais próxima possível do evento epileptogênico que se deseja destacar. Para verificar esta similaridade, parte-se dos princípios adotados por Argoud [1]. Supõe-se que variando as funções *wavelet* bases, para a transformada *wavelet* de cada sinal do EEG, pode-se verificar, através da medida de Desvio-Padrão, qual *wavelet* base estará mais próxima matematicamente da atividade epileptogênica. Pois uma função *wavelet* altamente correlacionada ao padrão de espícula deve gerar valores mais elevados de dispersão nos pontos de ocorrência da atividade discrepante (epileptogênica) que nos demais pontos associados à atividade de fundo do EEG.

A definição da base *wavelet* adequada neste estudo foi tomada considerando-se os resultados obtidos na tese defendida por Argoud [1], seguindo uma das linhas de pesquisas adotadas pelo Instituto de Engenharia Biomédica. A autora adotou um método denominado: Método Comparativo de Dispersão. Este método tem por princípio a probabilidade de ocorrência de um evento baseado no Desvio-Padrão.

Com a aplicação deste método, concluiu-se que os níveis de decomposição D2 e D3 (Figura 6.5) foram os mais freqüentes portadores de maiores valores de desvio, sendo os valores de escala onde o sinal da espícula fica mais ressaltado em relação aos demais. Foi definido que o nível de decomposição D2 apresenta certa vantagem sobre o nível D3, por este último apresentar-se mais sensível a eventos do tipo artefatos de EOG (eletroculograma) são movimentos lentos do paciente, presentes no EEG. Contudo, o nível de decomposição D3 foi capaz de captar as ondas agudas *sharp*, mais freqüentemente que o nível D2. Este nível apresentou-se mais localizado no tempo, gerando menos atrasos de fase dos sinais reconstruídos, permitindo maior confiabilidade em relação a coincidência do pico gerado após a transformação, devido à espícula.

Adotou-se a função *wavelet* Coiflet 1, nos níveis decomposição D1, D2 e D3 para processar os sinais e gerar os sinais reconstruídos como entradas para as redes neurais. Em adição, foram colocadas neste trabalho as seguintes conclusões:

- Observou-se que os eventos no EEG relacionados aos movimentos oculares (piscadas), que possuíam faixa de freqüência abaixo da faixa da espícula, eram maximizados no vetor de detalhe 3.
- Os eventos do EEG devido a quaisquer artefatos, como do equipamento e do movimento do paciente, apresentavam maiores concentrações de energia no vetor

de detalhes 1, principalmente por que normalmente eram compostos de frequências localizadas acima da faixa das espículas.

- Para trechos dos sinais do EEG contendo espícula, os sinais reconstruídos a partir dos vetores dos coeficientes-detalle 2 praticamente mantinham apenas a espícula, em relação ao resto do evento. Já os sinais obtidos a partir do detalhe 3 apresentavam-se mais “serrilhados”.
- Para o trecho do sinal do EEG contendo espícula-onda, o sinal reconstruído a partir do detalhe 3 apresentavam máxima amplitude absoluta exatamente no ponto de ocorrência do pico da espícula, porém, apresentava também excessivo *ripple*, o que dificultava o trabalho da rede de reconhecimento e de diferenciação.
- Para sinais do EEG com onda aguda, apenas o sinal derivado da componente de detalhe 3 era capaz de ressaltar a onda *sharp*.

A FWT gera sinais com altas amplitudes apenas durante a ocorrência das espículas e elimina a maior parte das influências devido a outros tipos de eventos. Porém, alguns aspectos de ordem quantitativa dificultam a análise direta dos sinais reconstruídos por parte das RNA's, como a grande variabilidade das amplitudes nos sinais do EEG. Dependendo do estado físico e comportamental do paciente, as amplitudes podem variar de $-25 \mu\text{V}$ a $+25 \mu\text{V}$, com predomínio das bandas beta e alfa, ou chegar às oscilações da ordem de $-500 \mu\text{V}$ a $500 \mu\text{V}$, como nos casos do movimento muscular de grande intensidade. Este fato torna difícil treinar uma RNA de forma que esta reconheça as espículas com amplitudes máximas absolutas variando de $20 \mu\text{V}$ a $200 \mu\text{V}$. Sendo assim, e baseando-se na necessidade de utilizar-se diferentes detalhes, para ressaltar determinado evento em particular (como o detalhe 3 para ressaltar piscadas e o detalhe 1 para ressaltar ruídos) foi necessário desenvolver várias RNA's para separar as espículas dos demais eventos. As redes foram propostas usando, como entradas, os detalhes da função base *wavelet* Coiflet 1 que melhor identifica o evento do EEG que se deseja destacar e assim definidos:

- RNA 1: usa Coiflet 1, nível D2, para identificar as espículas;
- RNA 2: usa Coiflet 1, nível D3, para identificar as espículas;
- RNA 3: usa Coiflet 1, nível D1, para identificar os ruídos;
- RNA 4: usa Coiflet 1, nível D3, para identificar as piscadas;

Não foi implementada uma RNA para identificar as ondas alfa, pois verificou-se que a banda alfa é bastante filtrada na FWT Coiflet 1 e manifesta-se pouco na maioria dos sinais reconstruídos.

Como mostrado na Figura 6.6, estas redes convergiram para uma base de regras, que define os trechos dos sinais contendo espículas.

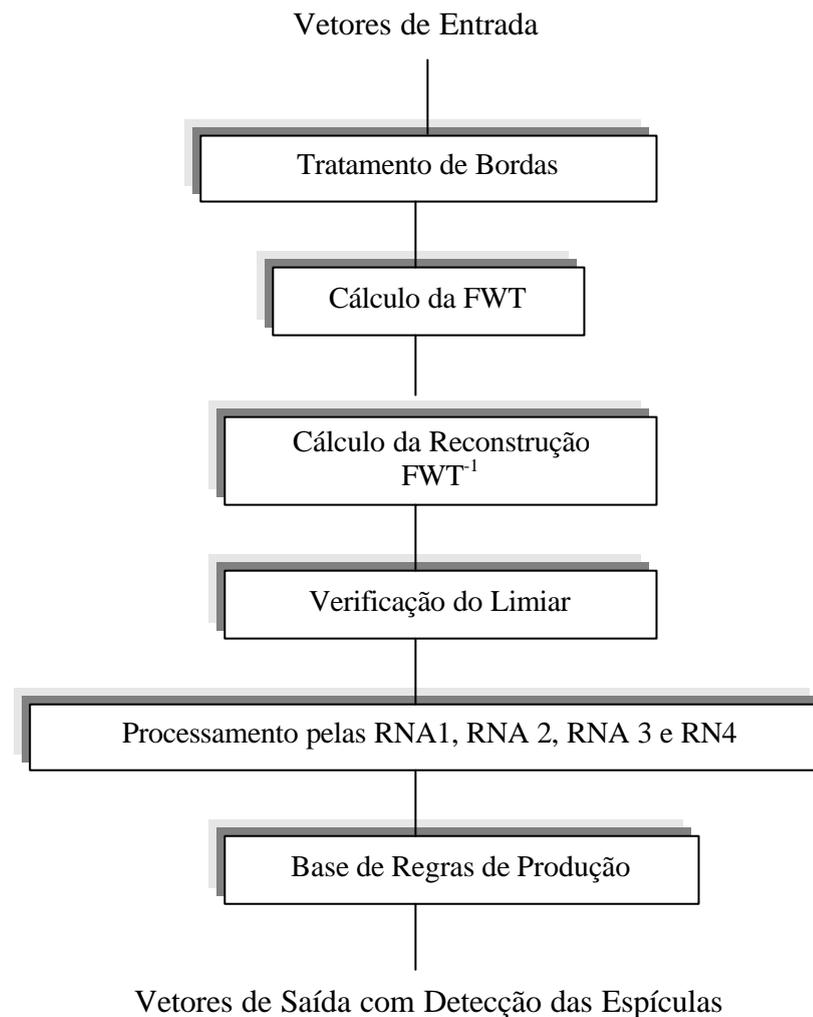


Figura 6.6- Proposta da análise dos sinais do EEG para identificar as espículas [1].

O tratamento das bordas foi utilizado porque a filtragem das “médias móveis” realizada pela transformada, que pondera os pontos anteriores e posteriores, para obter o valor da saída atual, gerava distorções nas bordas à esquerda (que não possuíam pontos anteriores) e nas bordas à direita (que não possuíam pontos posteriores). A verificação do limiar é realizada para eliminar-se os possíveis sinais que não se encontravam dentro da faixa de amplitude de uma espícula, que normalmente ultrapassava a 8 desvios-padrões

acima da média após a transformação. Assim, eliminam-se os sinais cujas amplitudes máximas não ultrapassam a 7,5 desvios-padrões além da média. A base de regras trabalha as saídas das redes de forma a eliminar os pontos onde ocorriam piscadas e ruídos e destacando os pontos onde ocorriam espículas e ondas agudas [1].

6.2 Entradas e Saídas das Redes com Entradas Pré-Processadas pela Transformada *Wavelet*

É proposta como *wavelet* base a Coiflet 1 e os níveis de detalhes 2 ou 3, dependendo do evento em questão. A Figura 6.7 detalha trechos de registros contendo eventos epileptogênicos, um dos eventos com o primeiro pico positivo e um segundo pico negativo e o outro com o primeiro pico negativo e um segundo pico positivo, juntamente com suas respectivas *wavelets* calculadas com detalhe 2 e 3. E a Figura 6.8 detalha os trechos de registros contendo eventos epileptogênicos, um com pico positivo proeminente e outro com pico negativo proeminente, juntamente com suas respectivas *wavelets* calculadas com detalhes 2 e 3.

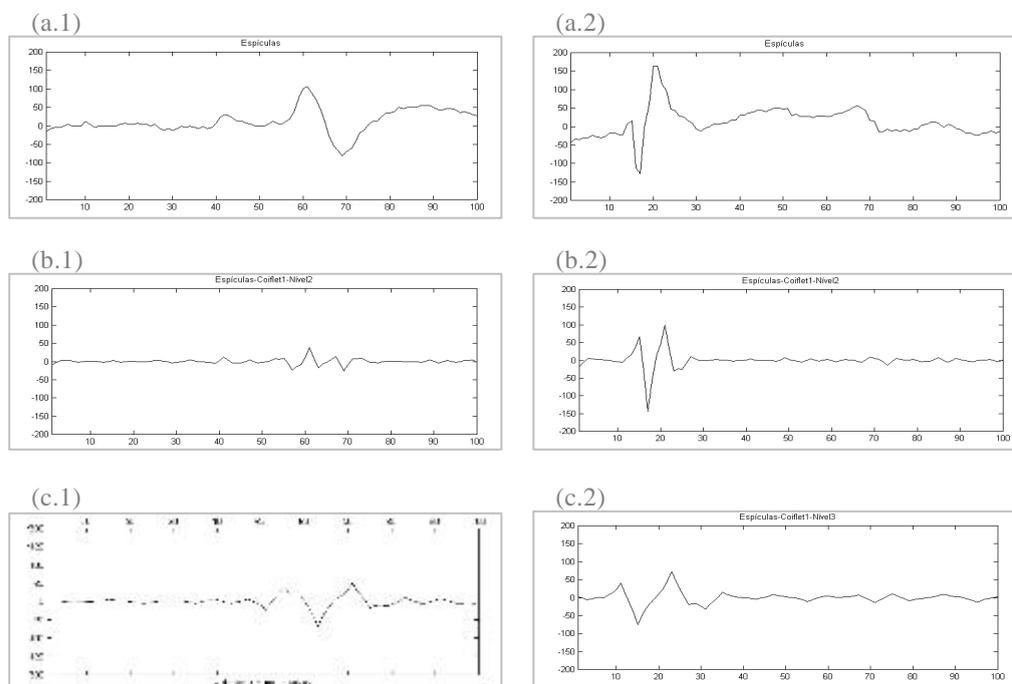


Figura 6.7- Eventos epileptogênicos com o primeiro pico positivo e com o primeiro pico negativo, respectivamente em (a.1 e a.2). As correspondentes *wavelets* calculadas com detalhe 2, em (b.1 e b.2) e, calculadas com detalhe 3, em (c.1 e c.2).

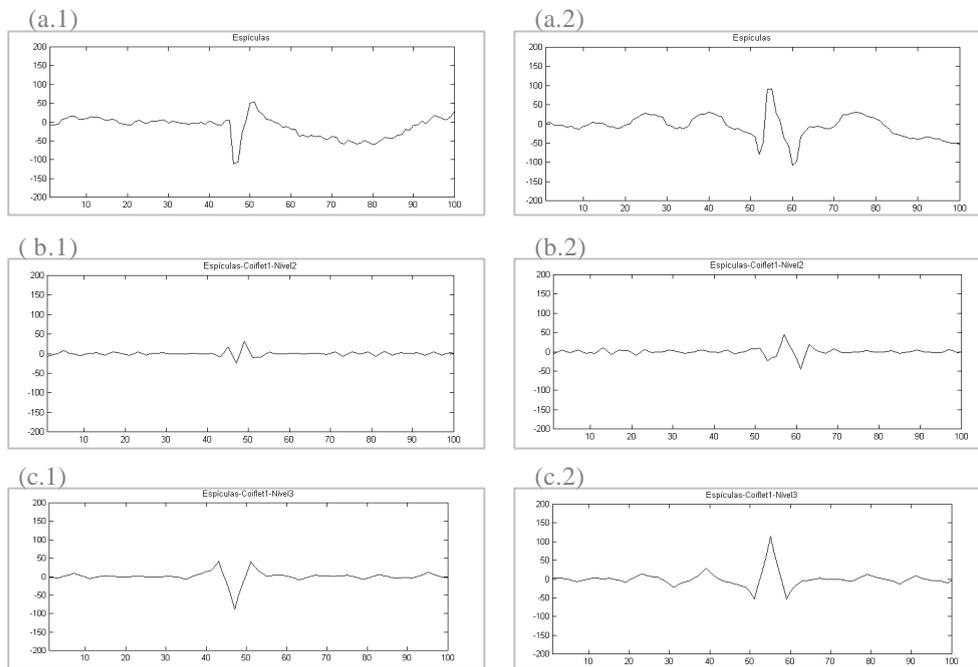


Figura 6.8- Eventos epileptogênicos de pico com polaridade negativa e positiva, respectivamente em (a.1 e a.2). As correspondentes *wavelets* calculadas com detalhe 2, em (b.1 e b.2) e, calculadas com detalhe 3 em (c.1 e c.2).

Nas Figuras 6.7 e 6.8 pode-se observar que os eventos epileptogênicos do pico positivo seguido de pico negativo, ou vice-versa, são melhores destacados com a *wavelet* Coiflet 1 no detalhe 2. Já quando o evento epileptogênico apresenta um pico positivo ou negativo proeminente, o melhor destaque é fornecido pela *wavelet* Coiflet 1 no detalhe 3.

Os registros do EEG normal de fundo são tratados com a *wavelet* de função Coiflet 1 e nível de detalhe 3. Os resultados encontram-se destacados na Figura 6.9. Este evento apresenta a sua FWT com oscilações de pequena amplitude ao longo do eixo zero. Este evento possui uma morfologia que facilita sua diferenciação do evento epileptogênico.

As ondas alfa apresentam características diferenciadas do EEG de fundo e dos eventos epileptogênicos, devido as suas oscilações de pequenas amplitudes. Os resultados destacados na Figura 6.10 são gerados pela *wavelet* de função Coiflet 1 e detalhe 3. Embora, alguns eventos epileptogênicos de pequenas amplitudes possam apresentar picos semelhantes, estes não são repetitivos como no caso das ondas alfa.

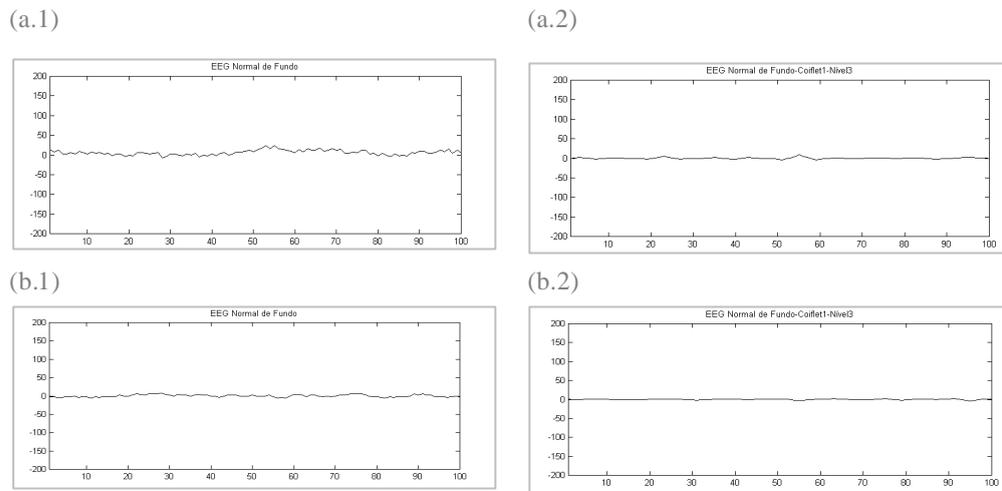


Figura 6.9- Em (a.1 e a.2), sinais do EEG de fundo obtidos em dois trechos de 100 pontos dos registros. Em (b.1 e b.2) suas respectivas *wavelets*, calculadas com detalhe 3.

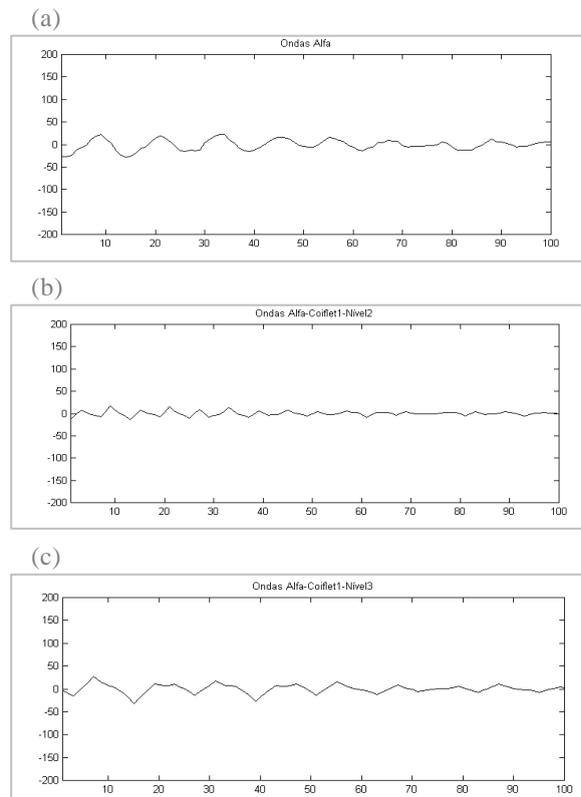


Figura 6.10- Em (a) um trecho do sinal do EEG contendo ondas alfa. Em (b), sua respectiva *wavelet* calculada com detalhe 2. Em (c), sua *wavelet* calculada com detalhe 3.

Dois trechos dos sinais do EEG contendo piscadas são destacados na Figura 6.11. Observa-se que, em ambos os casos, a função *wavelet* Coiflet 1 de detalhe 3 destaca a existência do evento exatamente no ponto de sua ocorrência. Uma indagação a ser feita relativa aos resultados obtidos na aplicação da FWT em trechos do EEG contendo piscadas refere-se à similaridade que suas representações possuem com as representações de trechos contendo o evento epileptogênico. Em muitos casos pode tornar-se difícil diferenciar uma representação da outra.

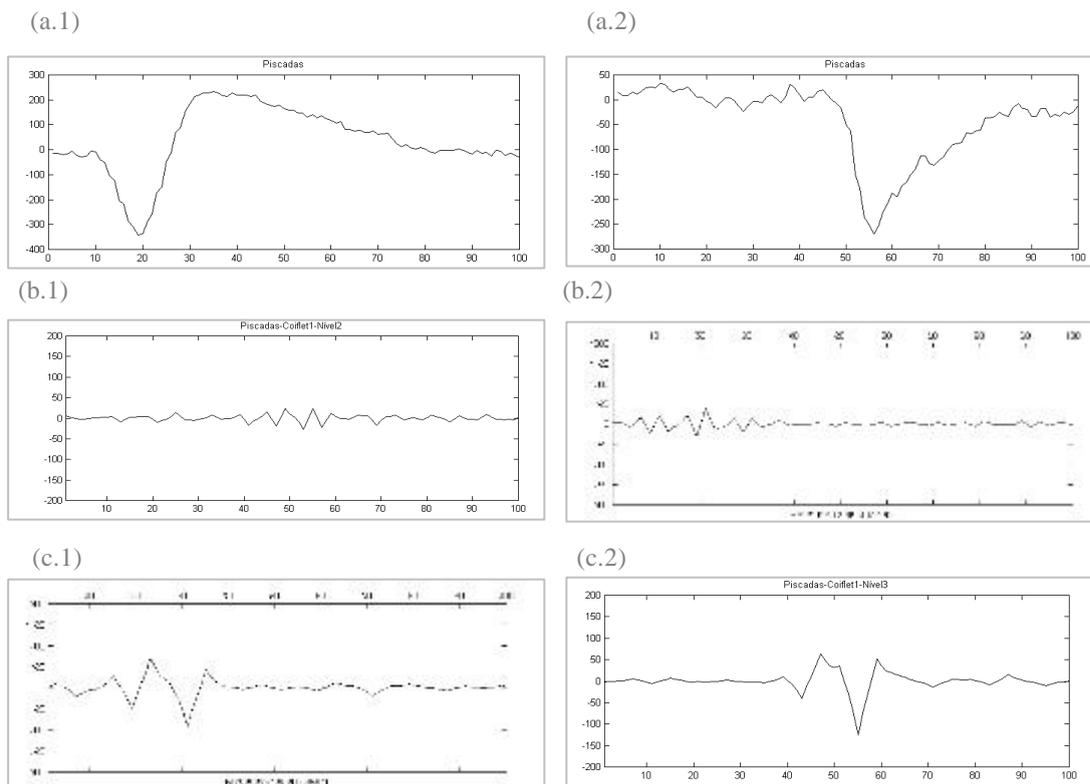


Figura 6.11- Em (a.1 e a.2), encontram-se dois trechos de sinais do EEG contendo piscada. Em (b.1 e b.2), suas respectivas *wavelets* calculadas com detalhe 2. Em (c.1 e c.2), suas *wavelets* calculadas com detalhe 3.

É importante observar que as representações encontradas nas Figuras 6.7 a 6.11 mostram os resultados da aplicação da função *wavelet* básica e detalhes escolhidos segundo o “método comparativo de dispersão” relatado no item 6.1.4 deste trabalho. As figuras apresentadas fornecem uma avaliação da aplicação da *wavelet coiflet 1* e detalhes escolhidos nos sinais do EEG, destacados para as entradas das redes tratadas neste trabalho.

Os trechos dos sinais do EEG contendo ruídos são melhores diferenciados com a função Coiflet 1 de detalhe 1, como representados na Figura 6.12. Nesta figura são, também, apresentados os resultados das representações *wavelets* nos detalhes 1, 2 e 3.

Apesar da aplicação da FWT a trechos com ruído gerar resultados morfológicamente semelhantes aos resultados dos eventos epileptogênicos, existe uma diferenciação nas faixas de frequência representativas de cada evento.

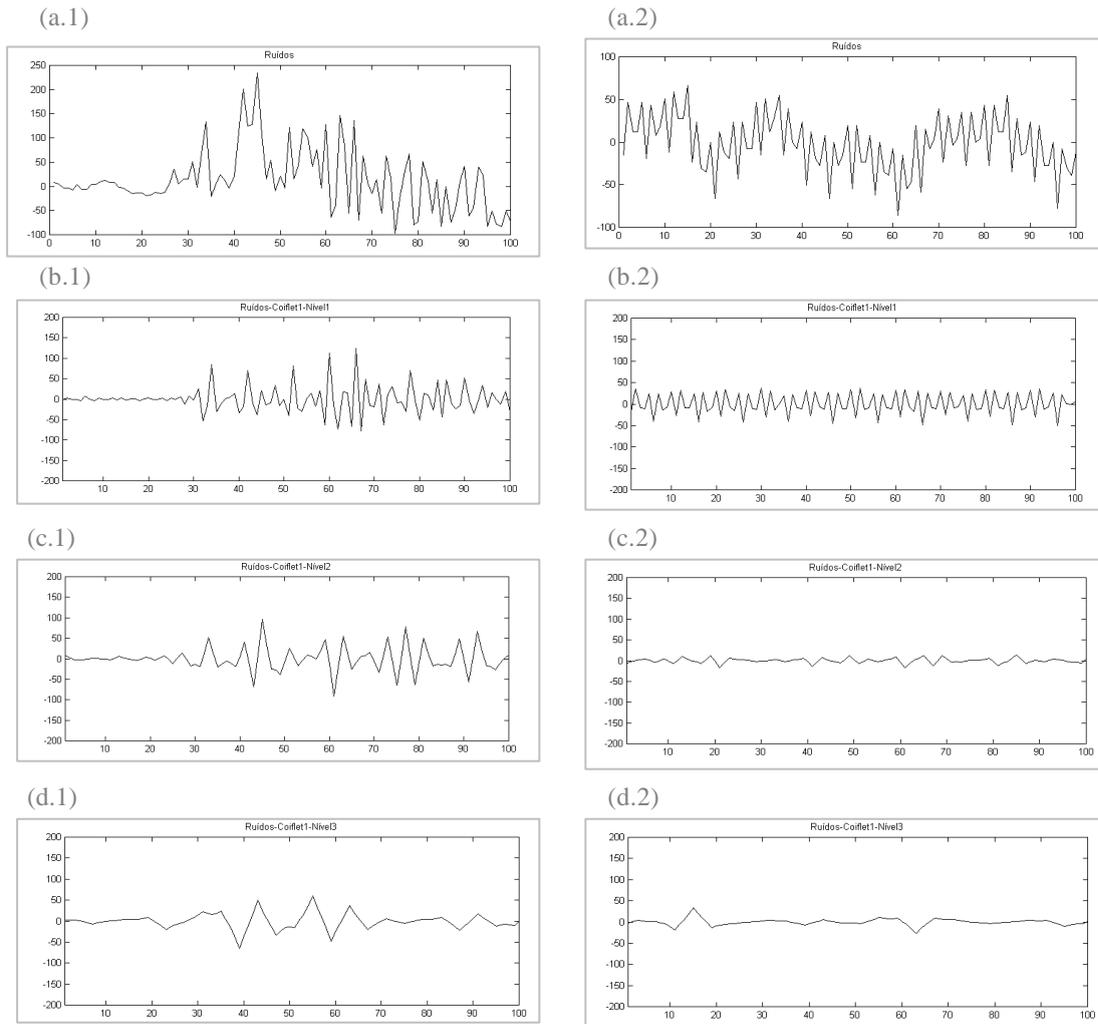


Figura 6.12- Em (a.1 e a.2), dois trechos dos sinais do EEG contendo ruídos. Em (b.1 e b.2), suas respectivas *wavelets* calculadas com detalhe 1. Em (c.1 e c.2), suas *wavelets* calculadas com detalhe 2. Em (d.1 e d.2), suas *wavelets* calculadas com detalhe 3.

Pode-se destacar casos, como os da Figura 6.13, onde os resultados da FWT são semelhantes, dificultando a diferenciação dos eventos epileptogênicos.

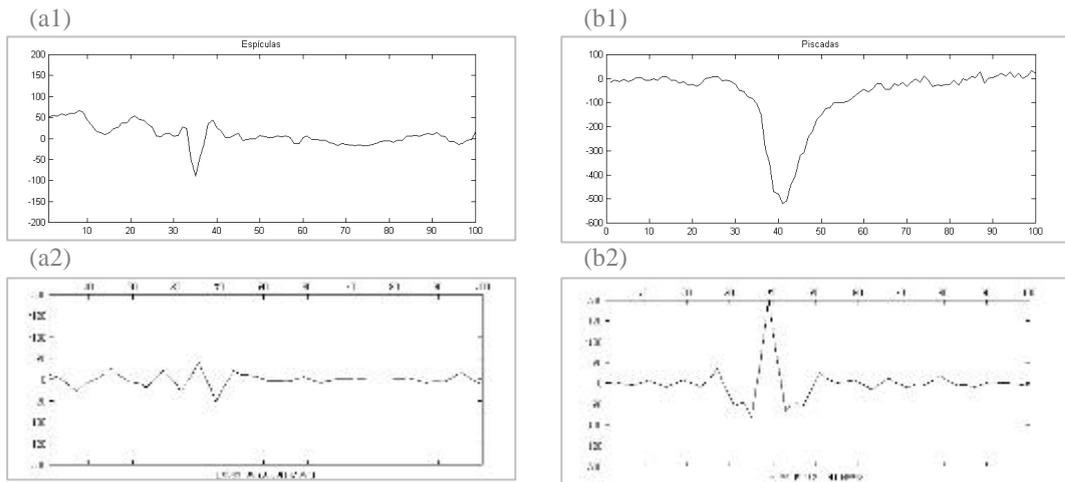


Figura 6.13- Em (a.1 e a.2), um trecho dos sinais do EEG contendo evento epileptogênico e sua respectiva FWT. Em (b.1 e b.2), um trecho do sinal contendo piscada e sua respectiva FWT. Em ambos utilizou-se a função Coiflet 1 com detalhe 3.

6.2.1 Rede geral com entradas pré-processadas pela FWT

A primeira análise realizada com os resultados da FWT, no sentido de sua interação com as RNA's, foi sua utilização como entradas das redes que, ao longo deste estudo, vêm se desenvolvendo. A Figura 6.14 esquematiza esta proposta.

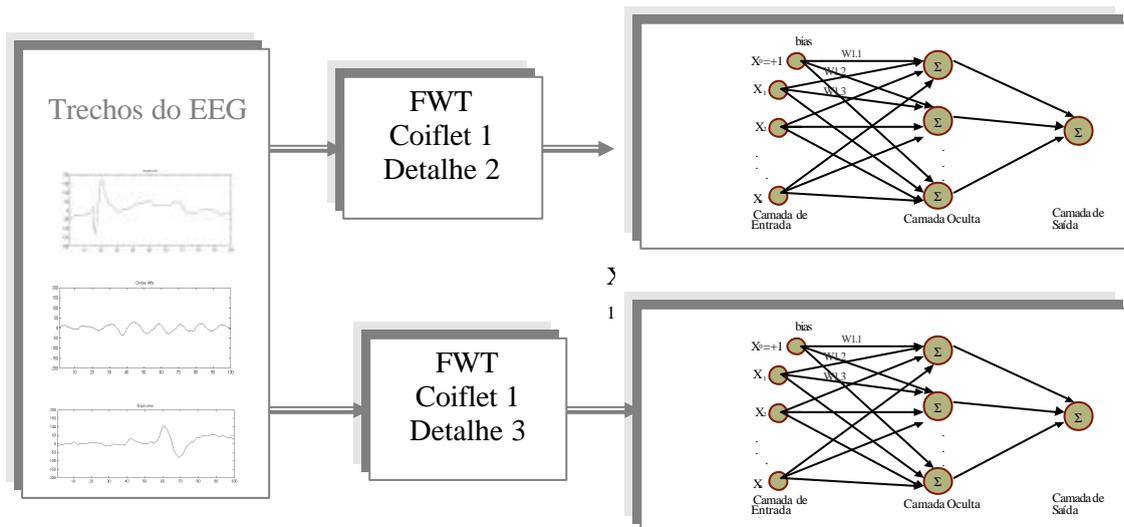


Figura 6.14- Esquema simplificado das redes tendo como entradas os resultados do processamento dos sinais do EEG pela função Coiflet 1 detalhe 2 e 3.

As entradas de duas RNA's foram apresentadas aos conjuntos de sinais pré-processados pela FWT, com função *wavelet Coiflet 1* de detalhe 2 e 3. Esta função e os detalhes *wavelets* foram escolhidos pois foram considerados os que melhor destacaram os eventos epileptogênicos dos demais. As duas redes forneceram resultados independentes.

Observa-se que a entrada da rede é igual ao resultado do pré-processamento. No caso da transformada *wavelet*, ela fornece um resultado com as mesmas dimensões do sinal processado. Assim, o número de vetores na entrada da rede são os 100 pontos referentes a 1 segundo do sinal analisado.

6.2.2 Redes individuais com entradas pré-processadas pela FWT

O treinamento de uma única rede neural para diferenciar espículas, piscadas, ruídos e ondas alfa, isto é, 4 padrões diferentes, mostrou-se inadequado. Propõe-se o treinamento de uma rede neural para o reconhecimento específico de cada um destes padrões, o que deveria teoricamente facilitar os processos de treinamento.

Ao observar as Figuras 6.7 a 6.8, pode-se concluir que existe um detalhe (D_n) próprio para cada tipo de evento. Portanto, é necessário mais de uma rede para identificar os diversos eventos presentes em componentes de detalhes distintos. Várias redes especializadas, cada uma em destacar determinado evento, devem ter seus resultados interagindo em uma base de regras que define se determinado trecho em suas entradas possui ou não eventos epileptogênicos. Esta proposta é mostrada na Figura 6.15.

Assim, as redes foram treinadas e testadas de forma que cada uma delas apresente entradas resultantes do processamento da FWT utilizando a função *Coiflet 1*; contudo, o detalhe utilizado depende do evento a ser identificado da seguinte maneira:

- Evento epileptogênico com dois picos, um positivo e outro negativo: usa detalhe 2;
- Evento epileptogênico com um pico proeminente, positivo ou negativo: usa detalhe 3;
- Movimentos oculares como piscadas: usa detalhe 3;
- Ruídos como movimento do paciente: usa detalhe 1;
- Ondas alfa: usa detalhe 3.

O EEG normal de fundo é bem definido com o uso da função Coiflet 1 não sendo necessário uma rede particular para identificá-lo.

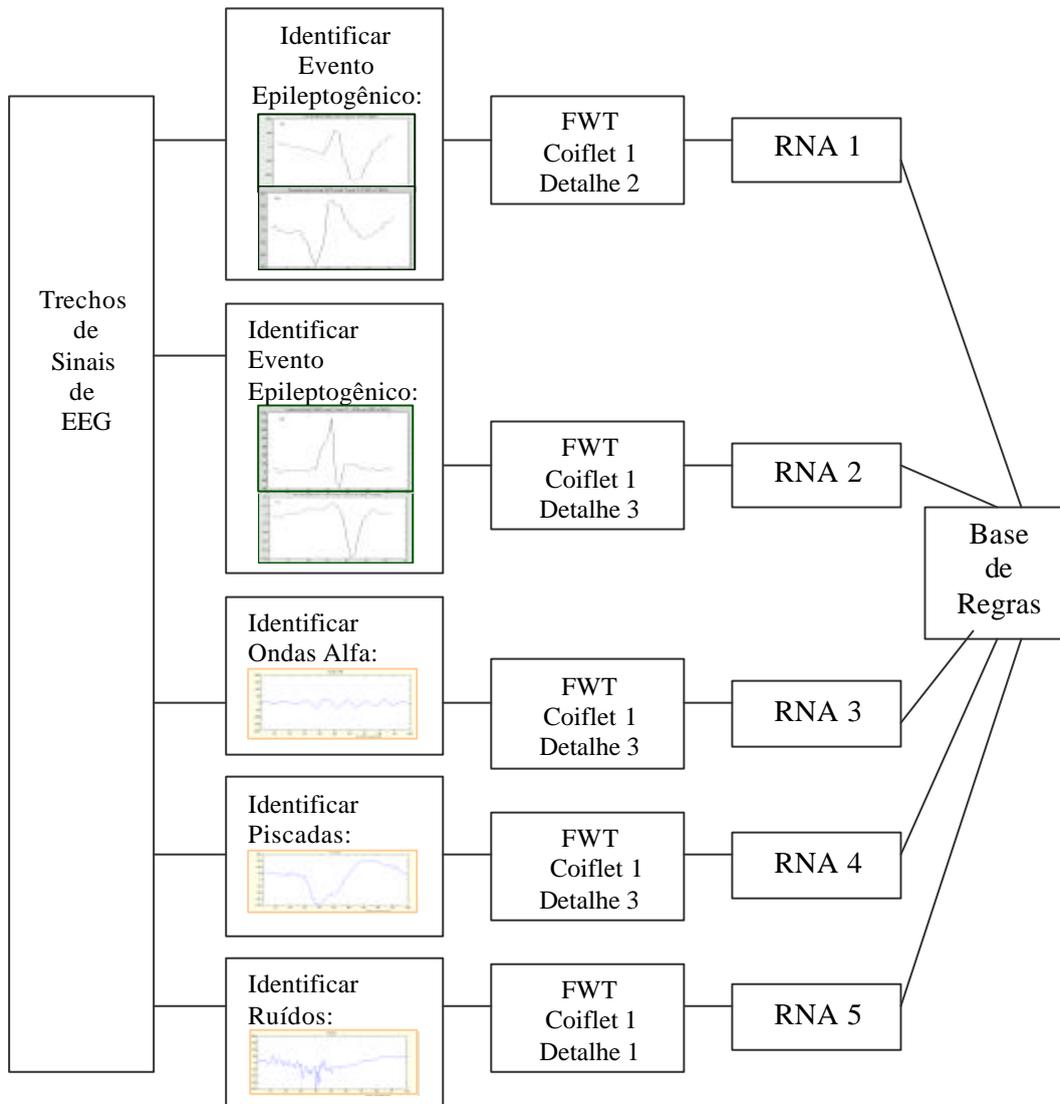


Figura 6.15- Esquema proposto formado por várias redes, que fornecem informações para uma base de regras destinada a identificar os eventos epileptogênicos.

6.3 Treinamento e Teste

As etapas de treinamento e teste foram divididas em duas linhas diferentes de implementação, a primeira utilizando uma rede geral para identificar o evento epileptogênico e a segunda utilizando redes individuais para identificar o evento epileptogênico e os demais eventos como ruídos e piscadas. Os esquemas de desenvolvimento destas etapas são mostrados nas Figuras 6.16 e 6.17.

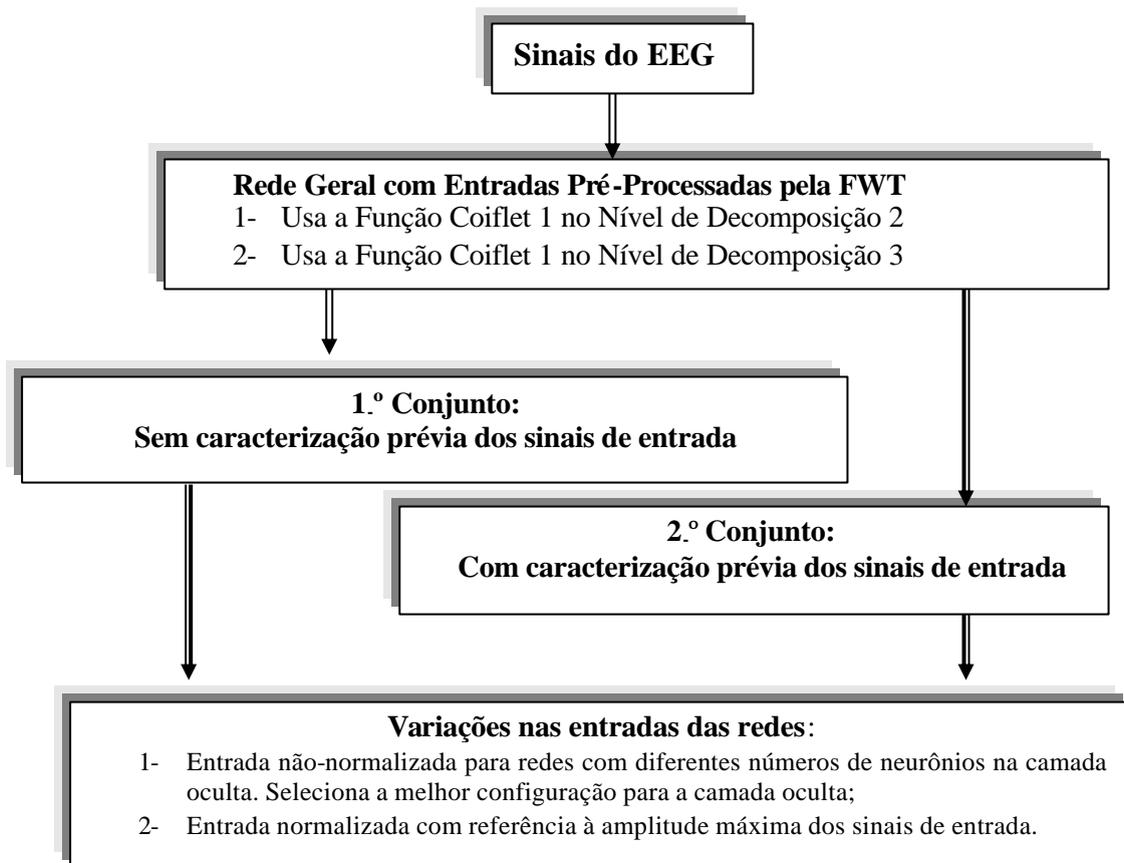


Figura 6.16- Esquema para o desenvolvimento da RNA para identificar os eventos Epileptogênicos em trechos dos sinais EEG pré-processados pela Transformada *Wavelet* usando a função Coiflet 1 e os níveis de decomposição 2 e 3.

A proposta das redes individuais mostrada na Figura 6.17 é considerada a mais recomendada para ser utilizada nos casos de pré-processamento com a Transformada *Wavelet*, devido às características de focos e filtragens destinadas a morfologias diferentes de sinais.

Para as redes individuais os conjuntos de treinamento e teste seguem as mesmas propostas que vêm sendo utilizadas nos capítulos anteriores deste trabalho. Contudo, as redes são treinadas conforme o tipo de evento a ser identificado. Foram consideradas metas iguais a 1 diferentes para cada rede. A RNA 1 possui meta igual a 1 para os eventos epileptogênicos com dois picos, um positivo e outro negativo. A RNA 2 possui meta igual a 1 para eventos epileptogênicos com um pico proeminente, positivo ou negativo. A RNA 3 possui meta igual a 1 ao ser apresentado sinais contendo piscadas. A RNA 4 define meta igual a 1 para os ruídos e a RNA 5 para as ondas alfa.

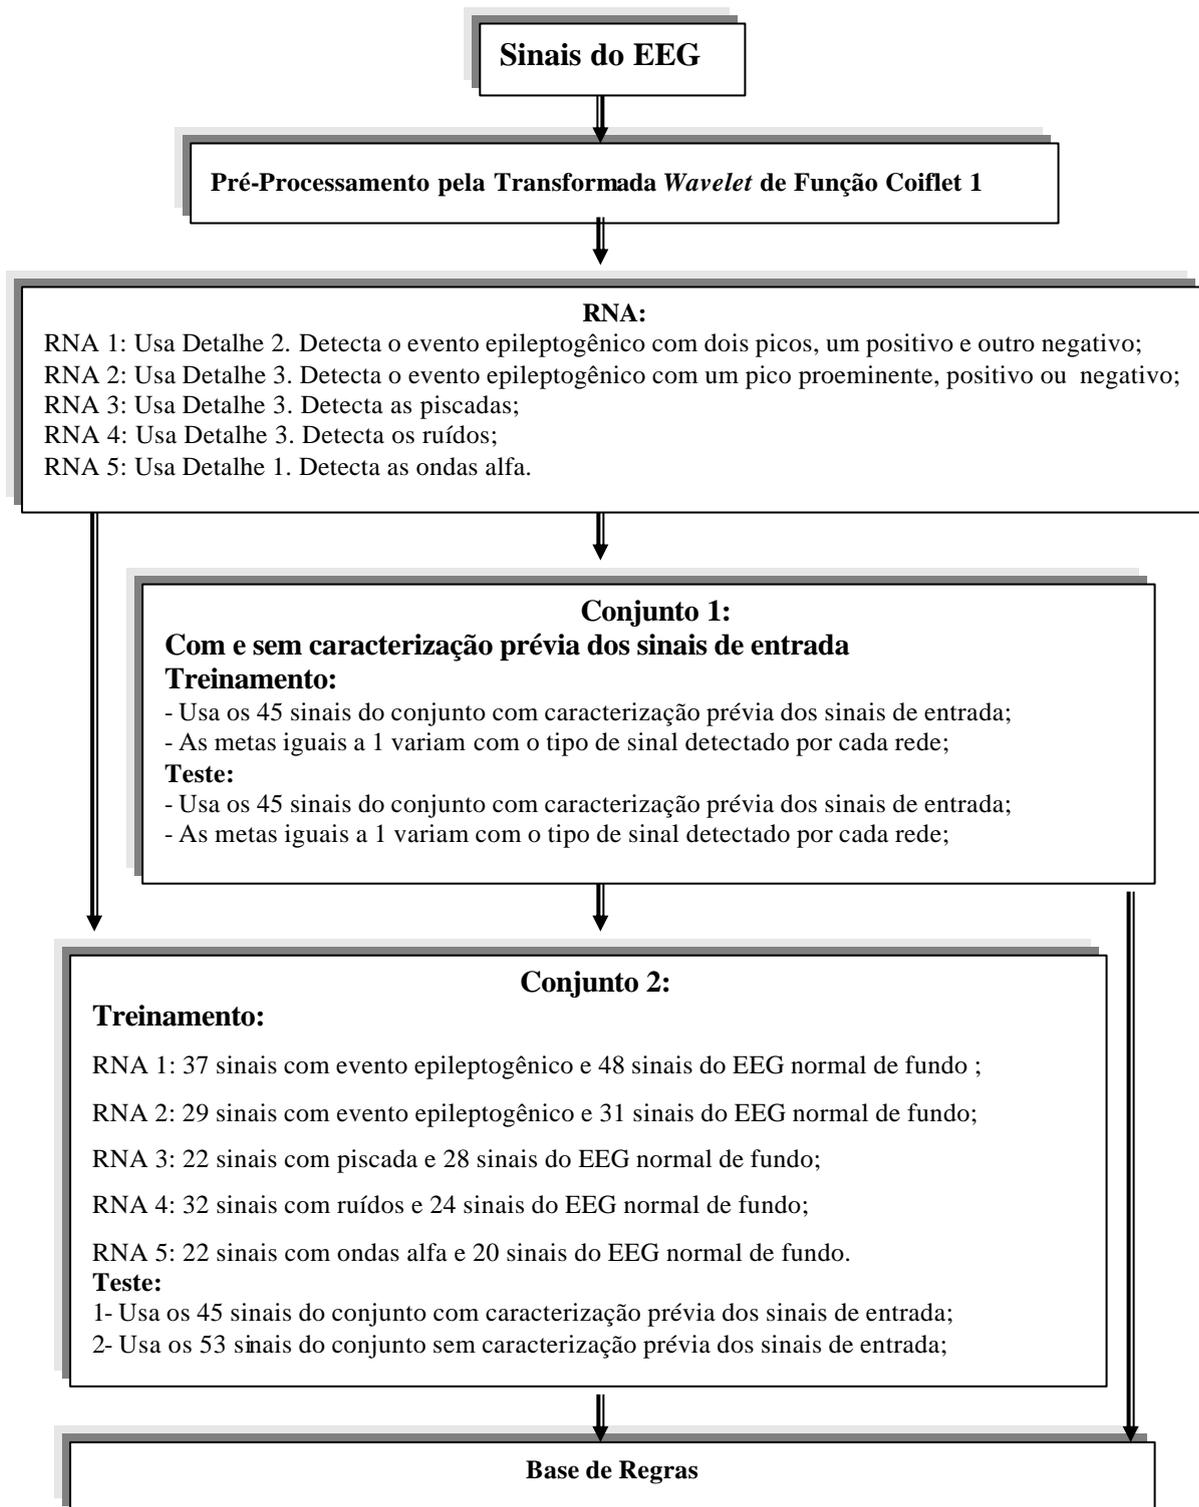


Figura 6.17- Esquema para o desenvolvimento das redes individuais para identificar os eventos epileptogênicos, piscadas, ruídos e ondas alfa.

6.3.1 Base de regras para os resultados das RNA's individuais

A base das regras utilizadas separa as redes em dois grupos, cujas saídas definem a existência de um evento epileptogênico ou não-epileptogênico no trecho de sinal apresentado. As RNA 1 e RNA 2 destinam-se a detectar os eventos epileptogênicos e as RNA 3, RNA 4 e RNA 5 detectam os eventos não-epileptogênicos.

Como critério para detecção do evento epileptogênico, basta que uma das redes (RNA 1 e RNA 2) produza uma detecção positiva para o trecho do sinal.

No caso das ondas alfa, piscadas e ruídos, considera-se a detecção do evento quando a rede destinada a detectar um destes eventos indica a sua presença na saída.

A análise entre os resultados das redes para detectar os eventos epileptogênicos (RNA 1 e RNA 2) e os resultados das redes para detectar os eventos não-epileptogênico (RNA 3, RNA 4 e RNA 5) concede a preferência para a detecção do evento epileptogênico. Assim, havendo uma resposta positiva por parte da RNA 1 ou RNA 2 para o trecho do sinal apresentado, define-se uma detecção positiva do evento epileptogênico neste trecho. A detecção negativa do evento é quando houver uma detecção do evento não-epileptogênico e não houver a detecção de um evento epileptogênico, simultaneamente.

A detecção negativa também é considerada se a rede não detectar nem um evento não-epileptogênico e nem um evento epileptogênico, simultaneamente.

O resultado intermediário ocorre entre a margem de uma detecção positiva e a margem de uma detecção negativa, ele é definido quando todas as redes apresentam resultados entre 0,3 a 0,7. Existindo resultados intermediários próximos a uma detecção positiva, considera-se a detecção positiva, e próximos a detecção negativa, considera-se a detecção negativa. Estes valores foram fixados após várias análises dos resultados das redes comparados com a meta, como mostra a Tabela 2.1 e descrições do item 2.2 do Capítulo 2 deste trabalho.

De forma sintetizada, a base das regras utilizadas segue as proposições esquematizadas pelo algoritmo mostrado abaixo.

As regras para as redes que detectam os eventos epileptogênicos são:

$$\text{Evento_Epileptogênico} = \text{Máximo}(\text{RNA 1}, \text{RNA 2})$$

$$\text{SE Evento_Epileptogênico} \geq 0,7$$

$$\text{Detecta_Evento_Epileptogênico} = 1$$

FIM SE

SE Evento_Epileptogênico £ 0,3

Detecta_Evento_Epileptogênico = 0

FIM SE

SE (0,3 < *Evento_Epileptogênico* < 0,7)

Detecta_Evento_Epileptogênico = *Indefinido*

FIM SE

As regras para as redes que detectam os eventos não-epileptogênicos são:

Evento_Não-epileptogênico = *Máximo* (*RNA 3*, *RNA 4*, *RNA 5*)

SE Evento_Não-epileptogênico ≥ 0,7

Detecta_Evento_Não-epileptogênico = 1

FIM SE

SE Evento_Não-epileptogênico £ 0,3

Detecta_Evento_Não-epileptogênico = 0

FIM SE

SE (0,3 < *Evento_Não-epileptogênico* < 0,7)

Detecta_Evento_Não-epileptogênico = *Indefinido*

FIM SE

O conjunto de regras destinadas a realizar uma análise cruzada entre o conjunto que detecta os eventos epileptogênicos com o conjunto que detecta os eventos não-epileptogênicos fornece a definição da existência ou não de um evento epileptogênico no trecho do sinal analisado. As regras propostas para esta análise cruzada são:

Detecta_Evento_Epileptogênico = *DEE*

Detecta_Evento_Não-Epileptogênico = *DENE*

SE DEE = 0 e *DENE* = 0

Saída = 0

FIM SE

SE DEE = *indefinido* e *DENE* = 0

Saída = 0

FIM SE

SE DEE = 0 e DENE = 1

Saída = 0

FIM SE

SE DEE = 1 e DENE = 0

Saída = 1

FIM SE

SE DEE = indefinido e DENE = indefinido

Saída = Indefinida

FIM SE

SE DEE = 1 e DENE = 1

Saída = 1

FIM SE

SE DEE = 1 e DENE = indefinido

Saída = 1

FIM SE

Neste trabalho foram testadas outras bases de regras, incluindo principalmente, a avaliação da situação onde existe uma simultaneidade na detecção de um evento epileptogênico e de um evento não-epileptogênico. Nestes casos, foram desconsideradas as detecções negativas de um evento epileptogênico se houvesse uma detecção positiva de piscadas e ruídos no mesmo trecho de sinal considerado. Nestes mesmos casos, também foi considerada a possibilidade de definir como a detecção correta aquela que possuísse um maior valor absoluto para a saída da rede. Contudo, as bases das regras apresentadas foram as que apresentaram melhores resultados.

6.4 Resultados e Análise dos Resultados Utilizando-se RNA's com Entradas Pré-Processadas pela Transformada *Wavelet*

Como a análise utilizando a FWT em estudo propõe duas linhas de abordagens, uma considerando uma rede geral e outra considerando redes individuais, a implementação das redes e a análise dos resultados foram realizadas de forma independente.

No Anexo B deste trabalho são encontrados os gráficos resultantes do treinamento das principais redes.

6.4.1 Resultados obtidos pela rede geral com entradas pré-processadas pela FWT

As redes foram treinadas com os mesmos tipos de conjunto para treinamento e teste já definidos no Capítulo 2 deste trabalho. Todas as entradas foram tratadas igualmente pela FWT com função *wavelet* Coiflet 1 de detalhe 2 ou 3.

Foram utilizados os conjuntos de treinamento com e sem caracterização prévia dos sinais de entrada, como mostrado na Figura 6.16. Os resultados das redes treinadas sem caracterização prévia dos sinais de entrada são mostrados nas Tabelas 6.1 e 6.2. Nos testes para obter essas tabelas foram consideradas 53 e 58 (mais 5 piscadas) FWT do conjunto de sinais sem caracterização prévia dos sinais de entrada. Neste caso, em uma das análises foram acrescentados 5 sinais contendo piscadas. Os resultados das redes treinadas com caracterização prévia dos sinais de entrada são mostrados nas Tabelas 6.3 e 6.4. Nos testes para obter estas tabelas foram consideradas 45 FWT de sinais de teste, escolhidos conforme estabelecido pelo segundo conjunto da Figura 6.16.

Tabela 6.1- Resultados obtidos pelas redes treinadas utilizando-se a FWT, função Coiflet 1 e detalhes 2 e 3, quanto aos números de acertos, valores indefinidos, verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN) .

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
11 N. Ocultos 70.023 Interações Detalhe 2	24 45%	11	20	9	14	10
11 N. Ocultos 100.000 Interações Detalhe 3	21 40%	18	19	13	10	11
12 N. Ocultos 55.110 Interações Detalhe 2	26 50%	18	20	16	7	10
12 N. Ocultos 100.000 Interações Detalhe 3	25 48%	13	18	16	7	12
12 N. Ocultos Normalizada 100.000 Interações Detalhe 2	28 53%	1	28	0	23	2
12 N. Ocultos Mais 5 sinais com piscadas 55.110 Interações Detalhe 2	26 45%	19	20	17	11	10

Tabela 6.2- Resultados da sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo utilizando-se as redes para obter os resultados da Tabela 6.1.

Rede	Sensibilidade	Especificidade	VPP	VPN
11 N. Ocultos 70.023 Interações Detalhe 2	0,67	0,39	0,59	0,47
11 N. Ocultos 100.000 Interações Detalhe 3	0,63	0,57	0,66	0,54
12 N. Ocultos 55.110 Interações Detalhe 2	0,67	0,70	0,74	0,75
12 N. Ocultos 100.000 Interações Detalhe 3	0,60	0,70	0,72	0,57
12 N. Ocultos Normalizada e 100.000 Interações Detalhe 2.	0,93	0	0,55	0
12 N. Ocultos Mais 5 sinais com piscadas 55.110 Interações Detalhe 2	0,67	0,61	0,65	0,63

Tabela 6.3- Resultados obtidos pelas redes treinadas com a FWT, com função Coiflet 1 de detalhes 2 e 3.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
11 N. Ocultos 1000.000 Interações Detalhe 2	20 45%	6	9	14	11	11
11 N. Ocultos 100.000 Interações Detalhe 3	13 29%	15	12	10	15	8
12 N. Ocultos 1.038 Interações Detalhe 2	19 42%	10	16	11	14	4
12 N. Ocultos 100.000 Interações Detalhe 3	14 31%	10	11	9	16	9
11 N. Ocultos Normalizada 100.000 Interações Detalhe 2	20 45%	5	19	5	20	1

Tabela 6.4- Resultados da sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo utilizando-se as redes para obter a Tabela 6.3.

Rede	Sensibilidade	Especificidade	VPP	VPN
11 N. Ocultos 1000.000 Interações Detalhe 2	0,45	0,56	0,45	0,56
11 N. Ocultos 100.000 Interações Detalhe 3	0,60	0,40	0,44	0,42
12 N. Ocultos 1.038 Interações Detalhe 2	0,80	0,44	0,53	0,73
12 N. Ocultos 100.000 Interações Detalhe 3	0,55	0,36	0,41	0,50
11 N. Ocultos, Normalizada 100.000 Interações Detalhe 2	0,95	0,20	0,49	0,83

Pode-se observar na Tabela 6.3 que a aplicação da FWT gerou muitos falsos positivos e um baixo número de acertos e a sensibilidade e a especificidade apresentaram valores consideravelmente baixos.

Pode-se concluir dos resultados das Tabelas 6.3 e 6.4 que para uma única rede eles são ruins, ocorre um grande número de falsos positivos, refletindo em valores indesejados de especificidade.

6.4.2 Resultados obtidos pelas redes individuais com entradas pré-processadas pela FWT

O conjunto de treinamento é formado por sinais contendo o evento a ser identificado e os sinais contendo somente o EEG normal de fundo, como classificação das redes individuais mostradas nas Figuras 6.15. e 6.17. Assim, a RNA 1 para identificar os eventos epileptogênicos com picos positivos e negativos é treinada com um conjunto de sinais contendo um número razoável destes eventos, mais sinais contendo o EEG normal de fundo. A RNA 4 que identifica piscada deve conter sinais com piscadas, mais sinais com o EEG normal de fundo.

Para treinar as redes individuais foram utilizados os conjuntos de teste e de treinamento com caracterização prévia dos sinais de entrada, formado por 45 sinais. A

opção para o uso destes conjuntos, e não um conjunto destinado ao tipo de evento que a rede deve detectar, deve-se à necessidade de um padrão para comparar o pré-processamento pela FWT com os demais pré-processamentos analisados neste estudo.

Os primeiros resultados mostram que estas bases de regras utilizando a FWT fazem uma grande diferença, melhorando consideravelmente os acertos nas saídas das redes.

As Tabelas 6.5 e 6.6 fornecem os resultados obtidos com as redes treinadas com os mesmos 45 sinais utilizados nos outros pré-processamentos. Neste caso, as redes individuais foram treinadas considerando-se a meta igual a 1 para os sinais correspondentes a sua proposta de detecção, isto é, para a rede destinada a detectar piscadas foram consideradas como uma detecção positiva os casos onde este conjunto apresentava um trecho com piscada. Assim, foram consideradas as 45 FWT's dos sinais de teste e treinamento, escolhidos conforme mostrado no primeiro conjunto da Figura 6.17.

Tabela 6.5- Resultados obtidos na aplicação da base de regras às saídas das redes individuais treinadas com a FWT, de função Coiflet 1 e detalhes definidos conforme o evento a ser detectado.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
11 N. Ocultos	28 62%	0	15	13	12	5
12 N. Ocultos	32 71%	0	19	13	12	1
12 N. Ocultos Entrada Normalizada	32 71%	0	15	17	8	5

Tabela 6.6- Resultados da sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo utilizando-se as redes para obter os resultados da Tabela 6.5.

Rede	Sensibilidade	Especificidade	VPP	VPN
11 N. Ocultos	0,75	0,52	0,56	0,72
12 N. Ocultos	0,95	0,52	0,69	0,93
12 N. Ocultos Entrada Normalizada	0,75	0,68	0,65	0,77

Em todos os casos, as redes treinadas com 12 neurônios na camada oculta apresentam uma tendência em proporcionar melhores valores quanto à sensibilidade e especificidade. Portanto, nas redes desenvolvidas e analisadas em seqüência foram definidas redes com 12 neurônios na última camada.

Os acertos obtidos, para estas redes treinadas com todos os tipos de eventos em questão, não foram grandes, no entanto, deve-se levar em consideração que para este tipo de pré-processamento, junto ao conjunto de regras, não houve nenhum sinal com evento indefinido. Os falsos positivos continuaram altos, mas, dentro de um limite aceitável devido ao reduzido valor dos falsos negativos. A especificidade pode ser considerada razoável, acompanhada de uma sensibilidade em torno de 0,95.

Os resultados com este conjunto de treinamento reforçam a idéia de que as redes treinadas com a FWT de eventos epileptogênicos apresentam entradas com características ambíguas destes eventos, gerando uma certa dificuldade por parte da rede em “aprender” a diferenciar um do outro. Devido a este fato, foram propostas redes cujos conjuntos de treinamento contenham basicamente o evento que esta seja destinada a destacar, junto a vários trechos com EEG normal de fundo. As redes assim treinadas obtiveram os resultados mostrados nas Tabelas 6.7 e 6.8.

Tabela 6.7- Resultados obtidos na aplicação da base de regras às saídas obtidas pelas redes individuais treinadas conforme o conjunto da Figura 6.17.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
12 N. Ocultos 45 sinais de teste	32 71%	0	20	12	13	0
12 N. Ocultos; 45 sinais de teste Entrada Normalizada	32 71%	0	19	13	12	1
12 N. Ocultos 53 sinais de teste	30 56%	0	24	6	18	5
12 N. Ocultos 53 sinais de teste Entrada Normalizada	43 81%	0	28	15	9	1

Tabela 6.8- Resultados referentes a sensibilidade, a especificidade, ao valor preditivo positivo e ao valor preditivo negativo utilizando-se as redes para obter os resultados da

Tabela 6.7.

Rede	Sensibilidade	Especificidade	VPP	VPN
12 N. Ocultos 45 sinais de teste	1	0,48	0,61	1
12 N. Ocultos 45 sinais de teste Entrada Normalizada	0,95	0,52	0,62	0,93
12 N. Ocultos 53 sinais de teste	0,83	0,25	0,57	0,55
12 N. Ocultos 53 sinais de teste Entrada Normalizada	0,97	0,62	0,76	0,94

As redes individuais foram treinadas com os sinais relacionados no segundo conjunto da Figura 6.17. Os conjuntos de teste permaneceram os mesmos utilizados nos outros pré-processamentos, considerando os 45 e 53 trechos dos sinais tratados utilizando-se a FWT Coiflet 1 de nível relacionado ao tipo de evento a ser classificado. Observa-se que os testes geraram estudos individuais para cada tipo de evento a ser detectado.

Não se pode dizer que houve uma diferença considerável nos resultados, para a rede treinada com todos os tipos de eventos epileptiformes e para a rede treinada com um tipo de evento específico e o EEG normal de fundo. Contudo, os resultados mostram a tendência de considerar o uso da FWT a uma base de regras.

As tabelas mostram claramente dois fatos importantes ocorridos com o uso deste tipo de pré-processamento. Primeiro, mostram a possibilidade de se obter, na maioria dos casos, uma detecção total de todos os eventos epileptogênicos e segundo uma melhora nos resultados obtidos com as entradas normalizadas.

6.5 Conclusões e Discussões

Ao acrescentar a base de regras observa-se uma considerável melhora. Vários eventos, como os já destacados, devem ser detectados com a finalidade de excluí-los ou não no momento da definição da existência de um evento epileptogênico no trecho do sinal apresentado.

Nas Tabelas 6.9 e 6.10 estão mostradas as melhores representações para as redes treinadas utilizando-se a FWT.

Tabela 6.9- Melhores resultados considerando as entradas das redes pré-processadas utilizando-se a FWT.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
12 N. Ocultos 45 sinais de teste Entrada Normalizada	32 71%	0	19	13	12	1
12 N. Ocultos 53 sinais de teste Entrada Normalizada	43 81%	0	28	15	9	1

Tabela 6.10- Melhores resultados referentes a sensibilidade, a especificidade, ao valor preditivo positivo e ao valor preditivo negativo utilizando-se as redes para obter os resultados da Tabela 6.9.

Rede	Sensibilidade	Especificidade	VPP	VPN
12 N. Ocultos 45 sinais de teste Entrada Normalizada	0,95	0,52	0,62	0,93
12 N. Ocultos 53 sinais de teste Entrada Normalizada	0,97	0,63	0,76	0,94

As entradas normalizadas apresentam melhores resultados, ao contrário do que ocorreu nos demais tipos de pré-processamento.

Um fato constatado é que esta forma de pré-processamento consegue detectar praticamente todos os eventos epileptogênicos apresentados para análise. Resultando em baixos valores de falsos negativos e altos valores de sensibilidade.

Contudo, este pré-processamento apresenta valores altos de falsos positivos, indicando que um evento qualquer, como uma piscada, foi identificado como sendo um evento epileptogênico. Este fato é constatado pelos valores baixos de especificidade. Em geral, os ruídos são os que mais se confundem com os eventos epileptogênicos, devido principalmente à sua forma aguda de vértice.

Os resultados tendem a uma melhora substancial quando, além da base de regras, os sinais são tratados por um algoritmo de verificação de limiar. Este procedimento elimina os possíveis sinais que não se encontra dentro da faixa de amplitude de uma espícula. Contudo, como o objetivo deste trabalho é analisar a capacidade da RNA de identificar os eventos epileptogênicos em sinais do EEG e avaliar seu comportamento quando são aplicados pré-processamentos, a verificação do limiar não foi realizada. Os resultados

obtidos são devidos estritamente à capacidade de identificação da rede e à capacidade de determinado pré-processamento em oferecer sinais bem caracterizados em sua entrada. O pré-processamento deve resultar em sinais onde os eventos epileptogênicos são ressaltados dos demais.

Trabalhos que aliam a verificação do limiar e o pré-processamento, para sinais de entrada para RNA, vêm obtendo bons resultados. Argoud [1] realizou a verificação do limiar para eliminar possíveis sinais que não se encontram dentro da faixa de amplitude de uma espícula, os quais normalmente ultrapassam 8 desvios-padrões acima da média após a transformação. Assim, pode-se eliminar os sinais cuja amplitude máxima não ultrapassa a 7,5 desvios-padrões além da média.

CAPÍTULO 7

7. RNA'S COM ENTRADAS PARAMETRIZADAS

A parametrização é uma forma de extrair as características predominantes em um trecho específico do sinal, produzindo-se dados que possam representar determinado evento.

Em se tratando dos sinais do EEG, a questão fundamental foi determinar quais características poderiam ser extraídas destes sinais e como seriam formalizadas. Estudos similares, que utilizam o recurso da parametrização, geralmente empregam técnicas estatísticas aliadas as características predominantes em trechos específicos do sinal.

Na seqüência, vários parâmetros relativos aos sinais do EEG contendo eventos epileptogênicos são catalogados, calculados e utilizados como dados para as entradas das redes neurais artificiais. Estas redes devem classificar os trechos dos sinais a ela apresentados como contendo ou não um evento epileptogênico.

A parametrização, no âmbito de análise de sinais, vem sendo utilizada há muito tempo para obter uma forma de classificar eventos em sinais do EEG. Alguns destes trabalhos (Gotman [2, 3], Dianbra[92], Webber [98], Luo [99], Walczak [13], Litt [38], Kim [37], Marchesi [100], Coimbra[28, 101], Galhanone [102], Kong [6], Muthuswamy [103]) foram analisados na intenção de se direcionar a escolha dos parâmetros adequados para este estudo em particular.

7.1 Trabalhos Relacionados a Parametrização dos Sinais do EEG com Eventos Epileptogênicos

Os primeiros estudos relatados com o objetivo de detectar os eventos epileptogênicos em sinais do EEG foram publicados por Gotman [2, 3]. As suas publicações podem ser consideradas pioneiras e definem uma linha de parâmetros cruciais na detecção destes eventos. Outros estudos foram encontrados, seguindo uma linha de pesquisa semelhante e os que se destacam são descritos a seguir.

- Gotman [2, 3]: em seus trabalhos, Gotman trata o sinal dividido-o em segmentos, denominados “segmentos de meia-onda”. Os segmentos de meia-onda são categorizados pela duração pela amplitude absoluta e pelo coeficiente de variação.

Isto é, utilizou-se interações de 2 segundos categorizadas pela: amplitude média de meia-onda relativa às atividades de fundo do EEG, sua duração média e o coeficiente de variação desta duração. O coeficiente de variação é pequeno, quando todas as meias-ondas possuem duração similar e, alto, quando a variabilidade em duração, em cada interação, é grande. O coeficiente de variação mede a ritmicidade do EEG. Ocorre uma detecção, quando os parâmetros de cada interação estiverem dentro de limites pré-definidos.

- Webber, W. R. S., Litt, B., Wilson, K., Lesser, R. P [98]: o trabalho deles abrange com detalhes a análise dos parâmetros relativos aos sinais do EEG com eventos epileptogênicos. Eles propõem a análise da eficiência das RNA's treinadas com sinais de entradas com e sem o pré-processamento por um detector de descargas epileptogênicas.

O EEG é dividido em interações de 2 segundos. As espículas são detectadas submetendo-se isoladamente medidas de vértices de um simples canal que ultrapasse um limiar pré-determinado. Foram computados, para cada vértice, os parâmetros como amplitude, duração, agudeza (d^2x/dt^2), fator de crista (CF), o produto inclinação (Ps), o desvio-padrão de longo termo (LTSD), o comprimento do trajeto de meia onda, o desvio-padrão de uma derivação do EEG, a linha base do EEG cruzada por segundo, a contagem do vértice por segundo.

O produto inclinação é calculado pela diferença em amplitude do sinal, para intervalos de tempo fixo (8 e 40 ms). Esta diferença é calculada em ambos os lados da forma de onda pela Equação (7.1).

$$Ps = \sqrt{(As_0 - Ade) \times (As_i - Ade)} \quad (7.1)$$

O desvio-padrão de longo termo (LTSD_n) é uma média ponderada do desvio padrão da interação de 2 segundos atual e da média dos desvios passados. Para cada nova interação, o LTSD é calculado por 0,75 vezes o LTSD da interação passada (LTSD_{n-1}) mais 0,25 vezes o desvio-padrão da interação corrente (σ).

$$LTSD_n = (0,75 \times LTSD_{n-1}) + (0,25 \times \sigma_n) \quad (7.2)$$

O fator de crista (CF) é a amplitude máxima do sinal menos a amplitude mínima, dividida pelo desvio-padrão do sinal, calculados em um intervalo de 2 segundos.

$$CF = \frac{(Amplitude_máxima) - (Amplitude_mínima)}{Desvio - Padrão} \quad (7.3)$$

As interações para as quais os parâmetros encontram-se com valores dentro de limites pré-estabelecidos foram indicadas como candidatas a possuírem o evento epileptogênico.

A rede utilizada é uma *Feedforward*, com algoritmo de aprendizado *backpropagation* com três camadas.

O cruzamento das curvas de sensibilidade e de seletividade ocorreu a 73,0% para os dados parametrizados e 46,0 % para os dados não parametrizados. Os dados parametrizados apresentados à rede geraram uma sensibilidade de 78,4% e uma seletividade de 64,8%, e os dados sem pré-processamento definiram uma sensibilidade de 83,1% e uma seletividade de 26,9%. Ao aumentar-se os limites dos parâmetros para os candidatos ao evento epileptogênico, os dados parametrizados apresentados à rede geraram uma sensibilidade de 38,4% e uma seletividade de 90,9%, e os dados sem pré-processamento definiram uma sensibilidade de 23,9% e uma seletividade de 61,4%.

- Luo, Q [99]: considerando os segmentos de 10 segundos e as características foram calculadas para cada segmento. Ele utilizou os seguintes parâmetros:
 - 1- Valor máximo das frequências do espectro (Fmax), obtido através da FFT de cada segmento.
 - 2- Energia Média (AE) é calculado o valor médio da energia do sinal em cada segmento.

$$AE = \frac{\sum_i x(i)^2}{N.T_s} \quad (7.4)$$

onde N é o número total de amostras em um segmento e T, é o período de amostragem.

- 3- Entropia do espectro de potência (PSE), aplicando-se a entropia ao espectro de potência do EEG obtém-se uma medida que representa o grau de irregularidade deste sinal.

$$\sum_{f=0}^{f_m} S(f) = 1 \quad (7.5)$$

onde $S(f)$ é o espectro de potência normalizado e f_m é o limite superior de frequência. A potência normalizada é a taxa de cada valor de potência para a potência total. A entropia da potência normalizada definida em *bits* fica:

$$PSE = -\sum_{f=0}^{f_m} S(f) \log_2 S(f) \quad (7.6)$$

O trabalho de Luo utilizou os métodos do classificador linear de Bayes, análise de componentes principais e redes neurais artificiais *feedforward*, com algoritmo de aprendizado *backpropagation*. Como resultado, ele descreveu que o classificador de Bayes com distribuição normal mostrou a melhor performance, com taxa de erro de 2,47%. O classificador linear de Fisher também mostrou um bom desempenho, com taxa de erro de 3,70%.

- Walczak, S., Nowack, W. J. [13]: usou uma base de dados de 1500 registros, com a finalidade do diagnóstico da epilepsia. Foram usadas 8 diferentes características: frequência, lateralidade, localização temporal (se o canal está localizado em um lóbulo temporal), ritmicidade, prevalência, duração, estado fisiológico (acordado/sono), agudeza (d^2x/dt^2).

Foi implementada a rede *feedforward* com algoritmo de aprendizado *backpropagation*. A rede obteve uma eficiência de 62,0%, uma especificidade de 68,1% e uma sensibilidade de 55,6%. Gerou como resultados 70,0% de eficiência em classificar pacientes que de fato tinham crises epiléticas, mas também classificou cerca de 44,4% de pacientes como tendo crises não epiléticas.

- Litt, B., Estelle, R., Echauz J., *Et. Al.*, [38]: supuseram que as crises epiléticas podem iniciar com uma cascata de eventos “eletrofisiológicos”. Medidas quantitativas das atividades elétricas pré-crise possibilitam prever a ocorrência de uma crise. O trabalho mostra a evolução no tempo da energia contida em um sinal até a presença da crise. Nos trechos destacados pela janela foram calculados:

- 1- A energia instantânea, obtida pelo quadrado de cada valor da seqüência do EEG.
- 2- A energia média, calculada usando-se a média móvel com sobreposições consecutivas.

$$E_k = \frac{1}{N} \sum x^2[n] \quad (7.7)$$

- 3- A energia acumulada, dez valores consecutivos da energia média são adicionados, e o resultado é dividido por 10 e somado à energia acumulada na interação anterior, AE_{m-1} (AE_m é o m -ésimo valor da energia acumulada).

$$AE_m = \frac{1}{10} \sum E_k + AE_{m-1} \quad (7.8)$$

- Dianbra, L. [92]: usou-se a entropia para reconhecer as atividades epilépticas. Esta consiste em um quantificador estatístico que estima a regularidade, no tempo, da série de dados e sua complexidade. O artigo defende que os métodos usados para detectar as crises baseados somente nos aspectos morfológicos requerem uma grande base de dados desses aspectos, para uma identificação mais precisa, para que todos os padrões necessários estejam dentro da base de dados. Em contraste, um método que utiliza a entropia é capaz de caracterizar os diferentes tipos de descargas epileptogênicas usando pequenas amostras dos sinais.

Embora a literatura disponibilize vários trabalhos utilizando os parâmetros característicos dos sinais do EEG, foi necessário criar um conjunto de parâmetros para atender as necessidades da aplicação deste estudo. Assim, muitos dos parâmetros propostos foram desenvolvidos para identificar um evento epileptogênico, baseando-se nas suas diferenças morfológicas com os demais eventos.

7.2 Parâmetros Propostos Neste Trabalho

Um sinal do EEG contendo eventos epileptogênicos pode apresentar simultaneamente outros tipos de eventos, como a atividade de fundo normal, ondas alfa e artefatos como ruídos e piscadas. Para destacar-se os eventos epileptogênicos, as características destes devem ser diferenciadas das características dos demais tipos de eventos. Assim, por exemplo, ao definir as características dos trechos de um sinal contendo

uma espícula é necessário destacar-se também as características dos sinais que podem estar presentes juntamente. Por esta razão, os sinais utilizados neste trabalho são obtidos de trechos dos sinais do EEG contendo eventos epileptogênicos, atividade de fundo do EEG normal, ondas alfa, ruídos e piscadas.

As características básicas de um evento epileptogênico são relacionadas à duração e à amplitude. Uma espícula tem duração de 20 ms a 70 ms, a componente principal é geralmente negativa e a amplitude é grande e variável. Uma onda aguda dura de 70 ms a 200 ms. As amplitudes são variadas, mas em geral estão acima de 20 μV e abaixo de 200 μV . Assim, um evento com duração de 20 a 200 ms e amplitude de 20 a 200 μV , em módulo, possivelmente é classificado como epileptogênico.

A forma de obtenção, os cálculos e os resultados de todos os parâmetros descritos aqui são mostrados nos algoritmos e nas tabelas apresentadas no Anexo H deste trabalho.

7.2.1 Parâmetros relacionados às amplitudes máxima e mínima

Um evento epileptogênico pode apresentar-se, na maioria dos casos, principalmente de quatro formas como mostrado na Figura 2.6 do Capítulo 2 deste trabalho.

A Figura 7.1 mostra um evento epileptogênico típico, do qual pode-se destacar alguns parâmetros que descrevem sua morfologia. A amplitude máxima (A_{max}), que define o pico positivo, juntamente com seu ponto de ocorrência (t_a). A sua amplitude mínima (B_{min}), que define o pico negativo, juntamente com seu ponto de ocorrência (t_b). A partir dos pontos de ocorrência máximo e mínimo, pode-se obter a distância entre estes pontos (T_{dif}).

Outro parâmetro relacionado às amplitudes do sinal mostrado na Figura 7.1 é a diferença entre as amplitudes máxima e mínima (D_{ifAB}). Esta diferença é mais acentuada no caso das piscadas e dos ruídos que nas ondas alfa e nas atividades de fundo consideradas normais. Esta mesma diferença, no caso dos eventos epileptogênicos, não é tão elevada quanto nas piscadas (maior que $\pm 200 \mu\text{V}$) nem tão pequena quanto nas ondas alfa (menor que $\pm 40 \mu\text{V}$). Devido a este contraste, a diferença entre as amplitudes máxima e mínima é definida como um parâmetro relevante.

Um fato observado foi que, em interações de 100 pontos (1 segundo), as amplitudes encontradas podem não representar as amplitudes reais dos pontos de máximo e mínimo de um evento epileptogênico, como mostrado na Figura 7.2.

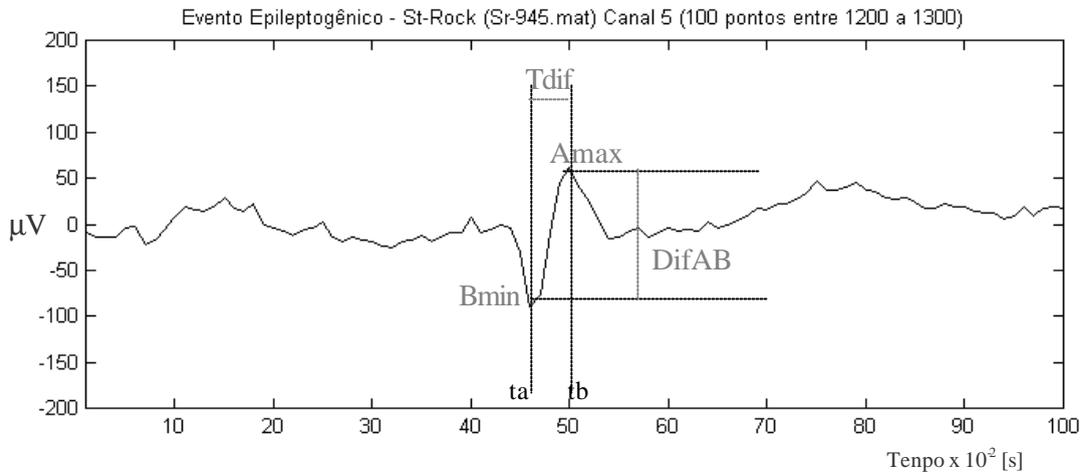


Figura 7.1- Características básicas apresentadas por um evento epileptogênico.

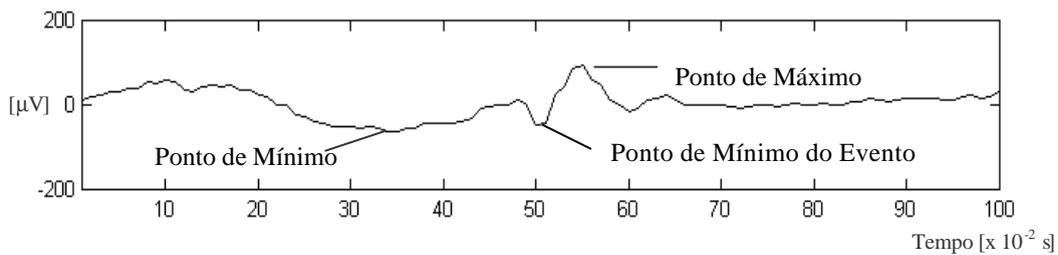


Figura 7.2- Sinal do EEG contendo o evento epileptogênico e apresentando um ponto de máximo correspondente ao evento e um ponto de mínimo relativo a outros eventos, que não seja a espícula.

Para corresponder às amplitudes de um evento epileptogênico, é necessário que a distância entre o máximo e o mínimo seja de, no máximo, a metade da duração de uma espícula ou de uma onda aguda. Mais especificamente, esta distância deve estar em torno de 35 a 100 ms, ou seja, no pior caso deve ser menor ou igual a 0,10 segundos, isto é, 10 pontos.

A Tabela 7.1 mostra os valores das amplitudes máxima e mínima, juntamente com a distância entre estes pontos, para 8 trechos de 1 segundo (100 pontos) dos sinais do EEG contendo eventos epileptogênicos. Nesta tabela foram mostrados os valores em que as distâncias entre os pontos de máximo e mínimo não correspondem à distância suposta de um evento epileptogênico, isto é, menor ou igual a 0,10 segundos ou 10 pontos.

Na Tabela 7.1 os valores destacados são os casos onde os pontos de mínimo calculados diferem dos pontos de mínimo do evento epileptogênico contido no sinal.

Tabela 7.1- Parâmetros obtidos no trecho correspondente a 1 segundo (100 pontos) de um sinal do EEG, destacando-se a diferença entre os pontos de ocorrência de máximo e mínimo do evento (Tdif).

Arquivos com Eventos Epileptogênicos (100 pontos)	Amplitude Máxima Amax_1s	Ponto de Ocorrência TAmaz_1s	Amplitude Mínima Bmin_1s	Ponto de Ocorrência TBmin_1s	Distância entre Amax e Amin Tdif_1s
jok-585, Canal 3 Pontos: 700 a 800	60,5468	53	-123,0468	58	0,05
kur-780, Canal 27 Pontos: 1200 a 1300	64,4531	40	-27,3437	13	0,27
lap-3120, Canal 29 Pontos: 700 a 800	48,8281	50	-52,7343	42	0,08
Sr-945, Canal 5 Pontos: 1200 a 1300	62,4999	50	-89,8437	46	0,04
Sr-540, Canal 21 Pontos: 250 a 350	93,7499	55	-64,4531	34	0,21
vad2-2655, Canal 21 Pontos: 400 a 500	126,9530	43	-35,1562	45	0,02
wam-1140, Canal 30 Pontos: 350 a 450	23,4375	35	-97,6562	40	0,05
zog-1815, Canal 3 Pontos: 1200 a 1300	48,8281	23	-56,6406	19	0,04

Na Tabela 7.2 os mesmos trechos dos sinais do EEG da Tabela 7.1 foram subdivididos em trechos de 15 pontos anteriores e 15 pontos posteriores ao ponto máximo absoluto. Foram calculadas as amplitudes máximas e mínimas, juntamente com a distância entre estes pontos. Pode-se observar que os valores destacados na Tabela 7.1 alteraram na Tabela 7.2 e a distância encontrada entre os pontos de máximo e mínimo correspondem à distância entre os pontos de máximo e mínimo de um evento epileptogênico.

Foram definidas a amplitude máxima (Amax_pts) e a amplitude mínima (Bmin_pts) no trecho correspondente a 15 pontos anteriores e 15 pontos posteriores ao ponto máximo, como mostrado na Figura 7.3. O trecho de 30 pontos centraliza, de uma certa forma, o evento. A diferença entre o ponto máximo e o ponto mínimo (Tdif_pts) e a distância entre os pontos Amax e Bmin devem ser como mostrado na Figura 7.4.

Tabela 7.2- Amplitude máxima e mínima nos trechos correspondentes a 15 pontos anteriores e 15 pontos posteriores ao ponto máximo, destacando-se a diferença entre os pontos de ocorrência de máximo e mínimo do evento (Tdif_pts).

Arquivos com Espículas	Amplitude Máxima Amax_pts	Amplitude Mínima Bmin_pts	Distância: Amax a Amin Tdifm_pts (seg)
jok-585, Canal 3 Pontos: 700 a 800	60,5468	-123,0468	0,05
kur-780, Canal 27 Pontos: 1200 a 1300	64,4531	-9,7656	0,09
lap-3120, Canal 29 Pontos: 700 a 800	48,8281	-52,7343	0,08
Sr-945, Canal 5 Pontos: 1200 a 1300	62,4999	-89,8437	0,04
Sr-540, Canal 21 Pontos: 250 a 350	93,7499	-46,8750	0,05
vad2-2655, Canal 21 Pontos: 400 a 500	126,9530	-35,1562	0,02
wam-1140, Canal 30 Pontos: 350 a 450	23,4375	-97,6562	0,05
zog-1815, Canal 3 Pontos: 1200 a 1300	48,8281	-56,6406	0,04

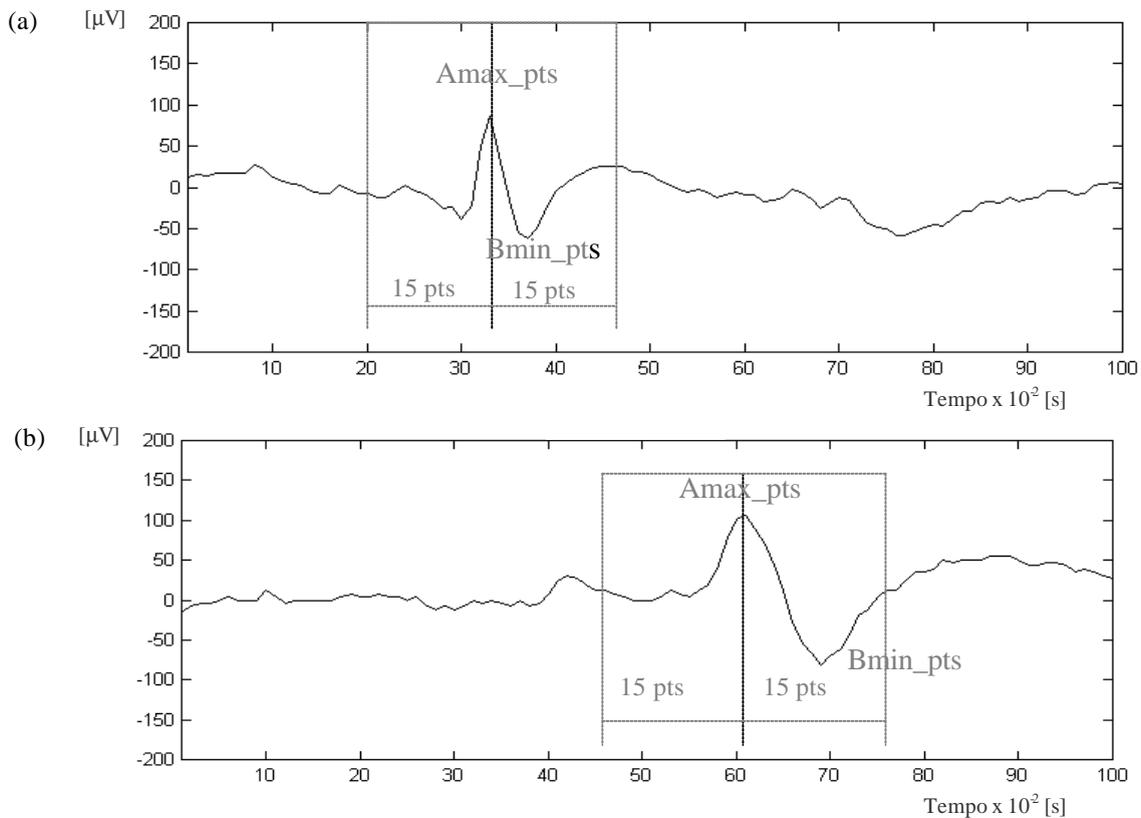


Figura 7.3- Amplitudes máxima (Amax_pts) e mínima (Bmin_pts) no trecho correspondente a 15 pontos anteriores e 15 pontos posteriores ao pico da espícula.

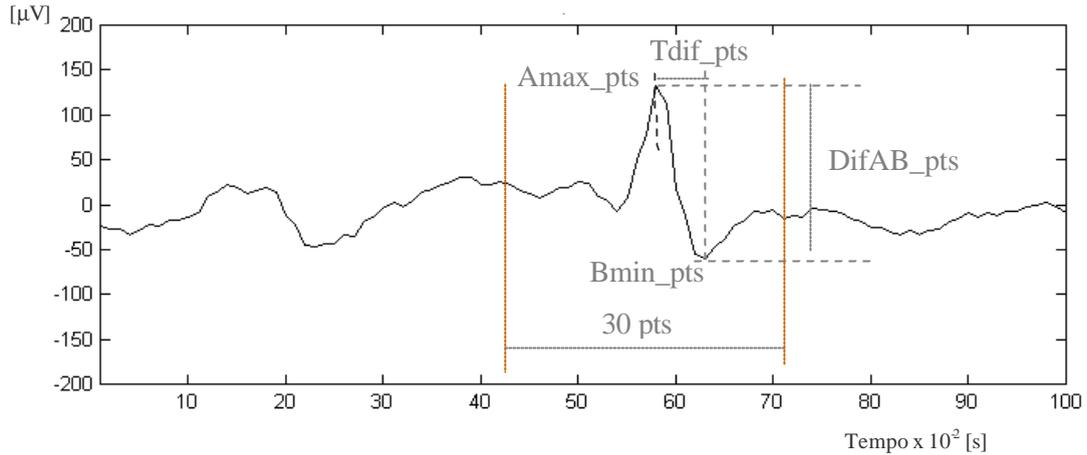


Figura 7.4- Parâmetros obtidos no trecho correspondente aos 15 pontos posteriores e 15 pontos anteriores ao ponto de máximo do sinal do EEG, destacando-se a diferença entre os pontos de ocorrência de máximo e mínimo do evento (T_{dif_pts}) e a diferença de amplitude entre estes pontos ($DifAB_pts$).

7.2.2 Parâmetro relacionado à duração do evento

Um parâmetro muito utilizado na modelagem dos eventos epileptogênicos é a duração do evento, T . Para este estudo, foi considerada a distância entre o início e o final do evento como mostrado na Figura 7.5, ressaltando-se os pontos onde a fase do sinal passa de positiva para negativa, e vice-versa.

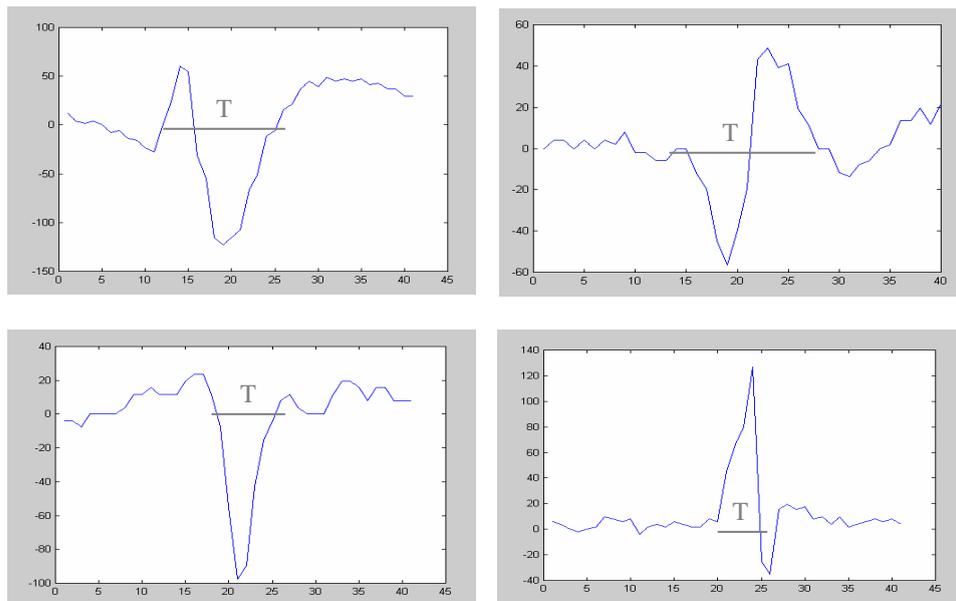


Figura 7.5- Duração do evento epileptogênico (T) considerando suas 4 formas básicas.

É considerado o primeiro ponto de cruzamento do eixo zero das abscissas, após os pontos de máximo e mínimo, em ambos os sentidos, ou uma variação no sentido do sinal (se o sinal diminui ou passa a aumentar), considerando-se as possibilidades do que ocorrer primeiro. Este mesmo algoritmo foi implementado para todos os trechos considerados, mesmo sem a presença do evento epileptogênico.

7.2.3 Parâmetros relacionados ao ângulo de vértice

Um evento epileptogênico, principalmente a espícula, apresenta picos mais acentuados, mais agudos, se comparados aos picos mais obtusos das ondas alfa ou das piscadas, como pode ser observado na Figura 7.6, permitindo uma distinção entre os eventos. É possível calcular-se esta diferença algebricamente pelo ângulo do vértice formado pelos picos, utilizando os cálculos trigonométricos simples.

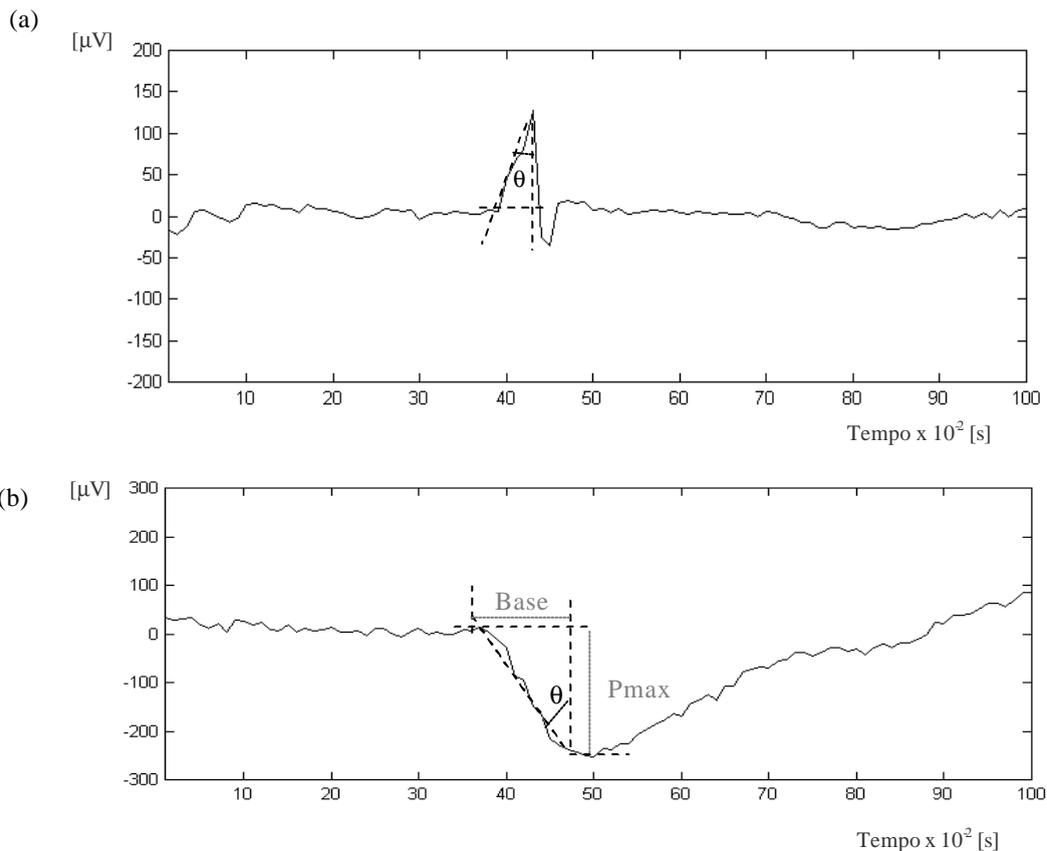


Figura 7.6- Referências para os ângulos dos sinais: (a) um evento epileptogênico e (b) uma piscada.

A avaliação do ângulo do vértice utiliza a amplitude máxima encontrada no trecho de 1 segundo e o primeiro cruzamento pelo eixo zero adjacente, como mostrado na Figura 7.7. É traçada uma reta entre o ponto de máximo e o ponto do início ou do fim da espícula, bem como uma perpendicular ao ponto máximo.

Para o cálculo do ângulo (θ) apresentado pelo pico mais proeminente do sinal, foram utilizadas as Equações (7.9) e (7.10). O termo $Arc\mathbf{q}$ representa a relação entre o lado oposto deste ângulo ($Base$) com o valor da distância entre o ponto máximo (positivo ou negativo) e o ponto de interseção do evento epileptogênico com o eixo x ($Pmax$).

$$\mathbf{q} = [\text{arco_tg}(Arc\mathbf{q}) * 180 / \mathbf{p}] \quad (7.9)$$

$$Arc\mathbf{q} = \frac{Base}{P\ max} \quad (7.10)$$

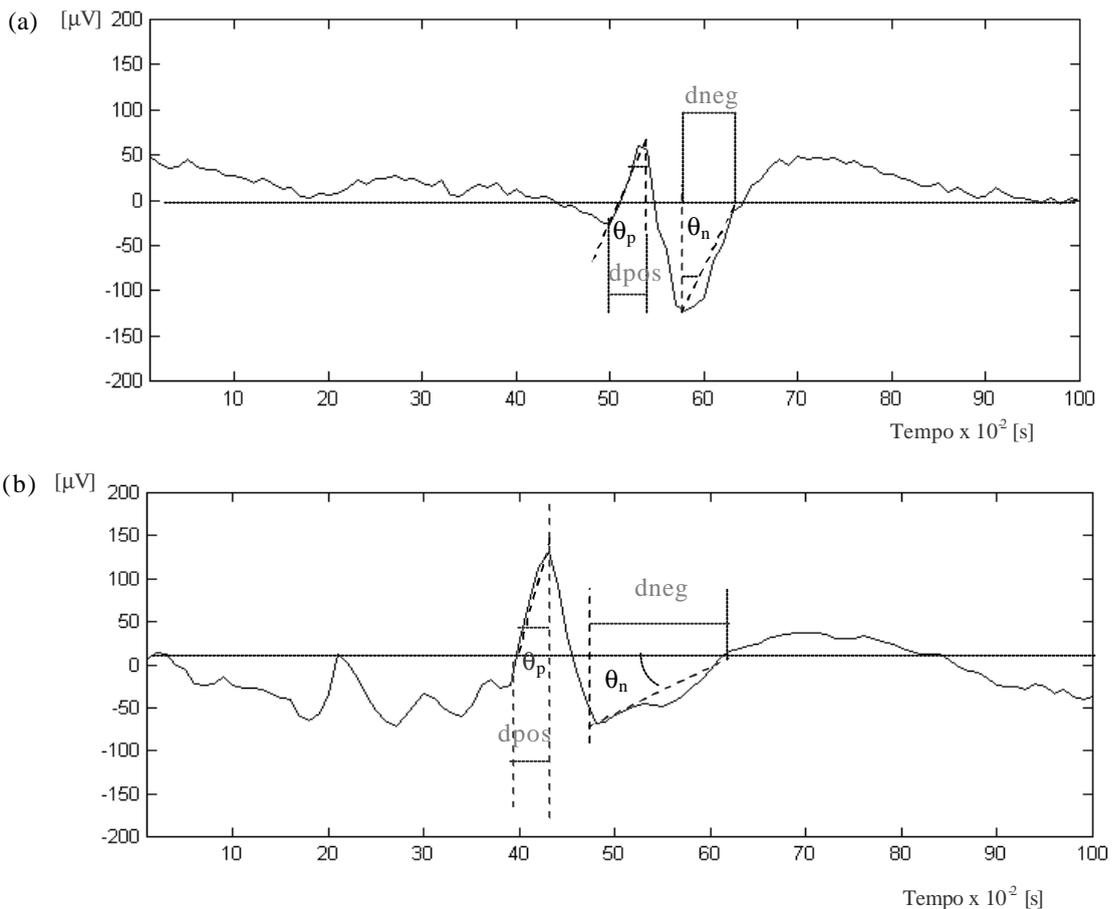


Figura 7.7- Ângulo dos vértices positivo e negativo de um evento epileptogênico, calculados a partir das amplitudes máxima e mínima. Em (a) e (b), evento epileptogênico pertencente ao conjunto das ondas agudas e espículas, respectivamente.

O ângulo (θ) deriva outras variáveis como: ângulo de pico positivo (θ_p), tangente do ângulo de pico positivo (tg_p), valor da relação entre a base do evento e sua amplitude máxima positiva (trp), ângulo de pico negativo (θ_n), tangente do ângulo de pico negativo (tg_n), valor da relação entre a base do evento e sua amplitude máxima negativa (trn).

As bases positiva e negativa do evento são os lados opostos aos respectivos ângulos. O lado oposto ao ângulo do pico positivo ($dpos$) é o valor da distância entre o ponto máximo positivo e o ponto de interseção do evento epileptogênico com o eixo x. O lado oposto ao ângulo do pico negativo ($dneg$) é o valor da distância entre o ponto máximo negativo e o ponto de interseção do evento epileptogênico com o eixo x. Para o cálculo dos ângulos de pico positivo e negativo foram utilizadas as Equações (7.11) a (7.14).

$$q_p = [\arctg(trp) * 180 / p] \quad (7.11)$$

$$trp = \frac{dpos}{A_{max}} \quad (7.12)$$

$$q_n = [\arctg(trn) * 180 / p] \quad (7.13)$$

$$trn = \frac{dneg}{B_{max}} \quad (7.14)$$

7.2.4 Parâmetros relacionados às distâncias entre os pontos de máximo

Uma das dificuldades encontradas na diferenciação de um sinal epileptogênico dos demais sinais encontrados no EEG é que sua morfologia pode assemelhar-se às morfologias dos outros eventos. A morfologia de uma espícula pode, muitas vezes, ser confundida com a morfologia dos ruídos. Contudo, foi observado que as formas de onda do ruído possuem vários pontos de máximo e mínimo com altas amplitudes e aparentemente próximos, enquanto os eventos epileptogênicos apresentam pontos de máximo e pontos de mínimo, para cada evento, relativamente distantes (com exceção das múltiplas espículas) como mostrado na Figura 7.8.

As formas de onda típicas dos ruídos geralmente repetem-se em curto espaço de tempo, fazendo com que picos de alta amplitude apresentem distâncias mínimas entre si. Já os picos de alta amplitude, típicos do evento epileptogênico, aparecem mais espaçados no trecho considerado. Assim, foram propostos parâmetros característicos das amplitudes, os

quais procuram distinguir as formas de onda dos ruídos e dos eventos epileptogênicos. Estes parâmetros relacionam as distâncias e as diferenças entre os pontos de máximo e mínimo. A Figura 7.8 mostra esses parâmetros e essas diferenças.

- Diferença em amplitude entre A_{max} e A_{max_i} ($DifA_i$): diferença entre a amplitude máxima do evento com a amplitude máxima da região inicial.
- Diferença em distância entre A_{max} e A_{max_i} (tA_i): diferença entre o ponto de ocorrência da amplitude máxima do evento com o ponto de ocorrência da amplitude máxima da região inicial.

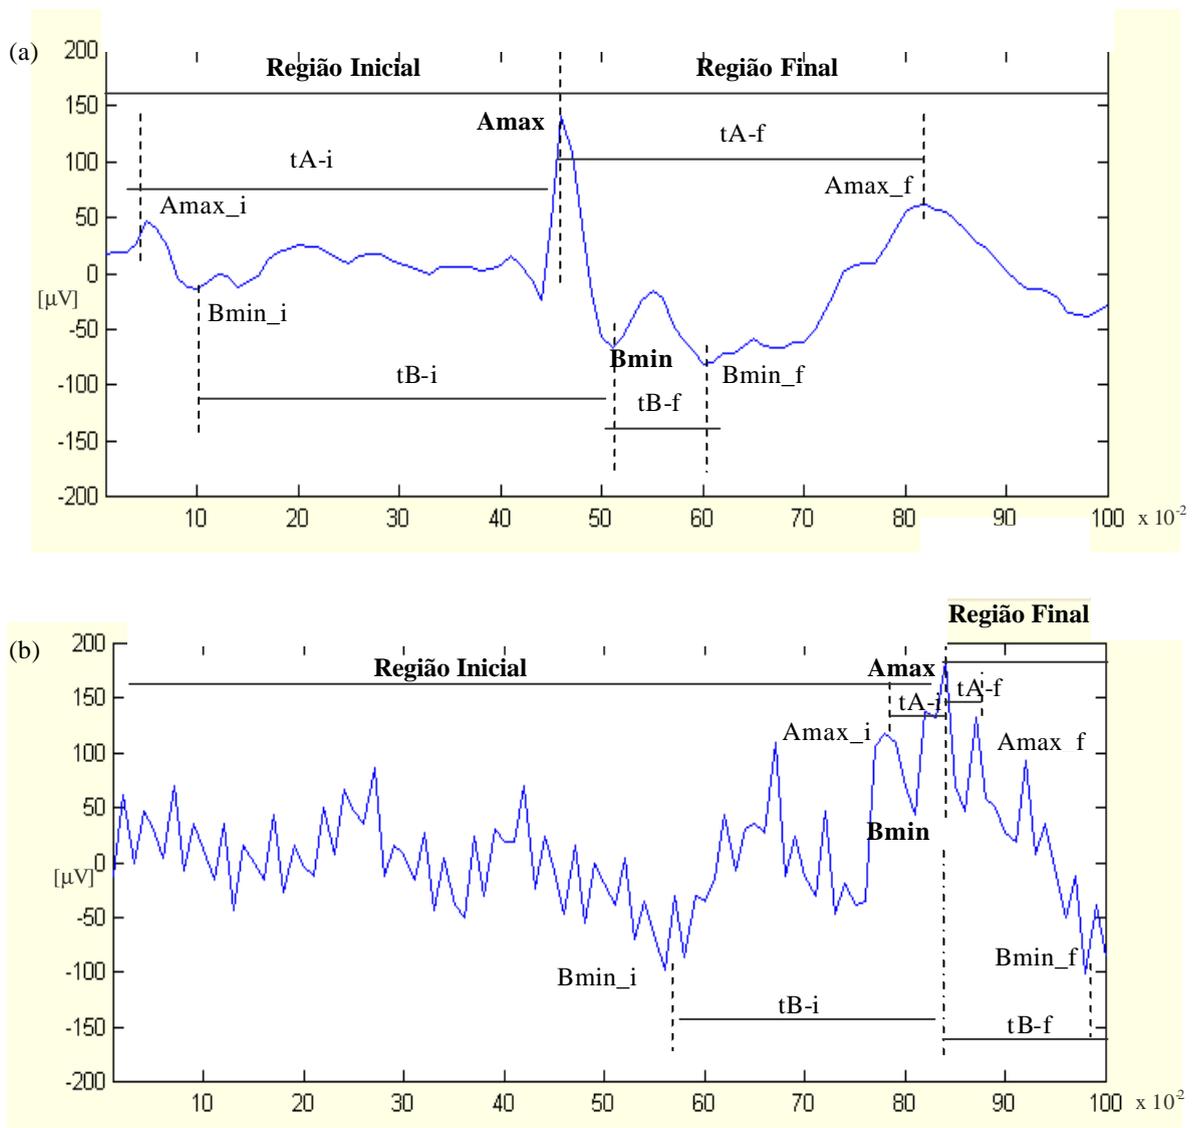


Figura 7.8- Distâncias entre os pontos de máximo positivos e negativos subsequentes e as respectivas diferenças em amplitudes. Em (a), trecho contendo um evento epileptogênico.

Em (b), trecho contendo os ruídos.

- Diferença em amplitude entre B_{min} e B_{min_i} ($DifB_i$): diferença entre a amplitude mínima do evento e a amplitude mínima da região inicial.
- Diferença em distância entre A_{min} e A_{min_i} (tB_i): diferença entre o ponto de ocorrência da amplitude mínima do evento com o ponto de ocorrência da amplitude mínima da região inicial.
- Diferença em amplitude entre A_{max} e A_{max_f} ($DifA_f$): diferença entre a amplitude máxima do evento com a amplitude máxima da região final.
- Diferença em distância entre A_{max} e A_{max_f} (tA_f): diferença entre o ponto de ocorrência da amplitude máxima do evento com o ponto de ocorrência da amplitude máxima da região final.
- Diferença em amplitude entre B_{min} e B_{min_f} ($DifB_f$): diferença entre a amplitude mínima do evento e a amplitude mínima da região final.
- Diferença em distância entre A_{min} e A_{min_f} (tAB_f): diferença entre o ponto de ocorrência da amplitude mínima do evento e o ponto de ocorrência da amplitude mínima da região final.

Estes parâmetros também permitem diferenciar entre os eventos epileptogênicos e as ondas alfa e o EEG de fundo, como se pode observar na Figura 7.9, onde ao longo de todo o sinal estes eventos apresentam poucas diferenças de amplitude.

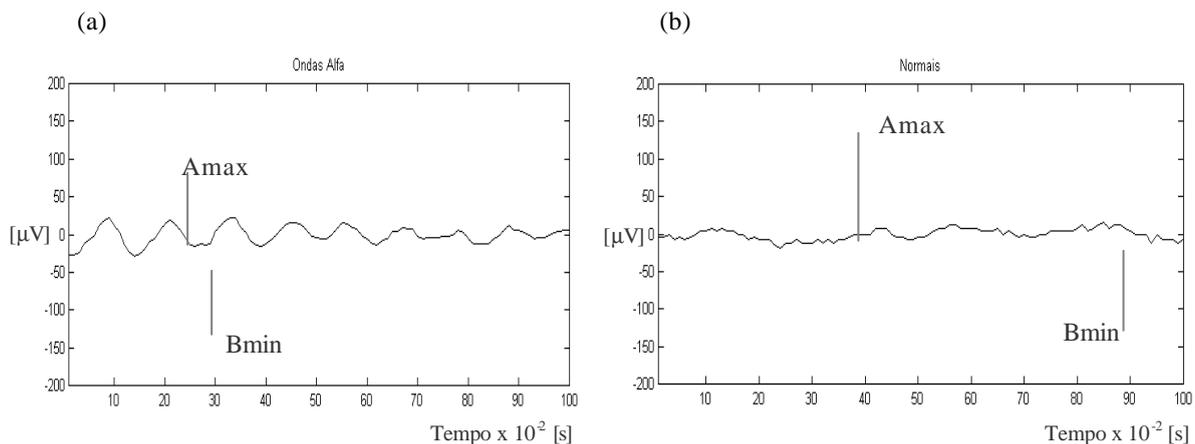


Figura 7.9- Trechos de 1 segundo contendo o EEG de fundo, em (a), e ondas alfa, em (b).

Na Figura 7.9 pode-se destacar os pontos de máximos e de mínimos e suas respectivas diferenças em amplitudes, as quais, como se pode observar, são relativamente pequenas quando encontradas em escalas adaptadas aos eventos epileptogênicos.

7.2.5 Parâmetros relacionados a dados estatísticos

Os parâmetros estatísticos fornecem uma informação sucinta de todos os arquivos e dos trechos do EEG considerados. Para este estudo foram destacados os valores clássicos da média, desvio padrão e variância. As formulações destes parâmetros encontram-se no Anexo D deste trabalho e são desenvolvidos detalhadamente nas referências [104, 105, 106]. Também são estabelecidos o “coeficiente de variação” e o “fator de crista”.

O coeficiente de variação (CV), é usado para medir a ritmicidade do EEG. Este é independente da frequência da onda, somente mede sua regularidade, e pode ser obtido segundo a Equação (7.15).

O fator de crista (FC), utilizado por Webber, [98], gerencia os valores da morfologia do sinal com o desvio-padrão na Equação (7.16).

$$CV = \frac{\text{Desvio_Padrão}}{\text{Média}} \quad (7.15)$$

$$FC = \frac{(\text{Amplitude_máxima}) - (\text{Amplitude_mínima})}{\text{Desvio - Padrão}} \quad (7.16)$$

7.2.6 Parâmetros relacionados à entropia

A análise da entropia exige um estudo detalhado e é relatada em vários trabalhos como os publicados por Quiroga [10] e Estelle [16]. Nestes as formulações não se estendem a um estudo aprofundado, somente destaca-se o uso da entropia na obtenção de um parâmetro que mede a complexidade do trecho do sinal apresentado.

É um tema que vem se destacando principalmente nos algoritmos de reconhecimento das atividades epileptogênicas. É considerado um quantificador de regularidade e complexidade.

Neste trabalho, a entropia foi obtida usando-se uma função do *Matlab*: $E = \text{wentropy}(\text{sinal})$.

7.3 Matriz Total dos Parâmetros

A matriz total de parâmetros é formada por todos os parâmetros definidos como possíveis características obtidas nos sinais contendo o evento epileptogênico, e que possam destacá-los dos demais eventos que aparecem mais frequentemente nos registros do EEG. Estas características já relatadas e descritas podem ser enumeradas como mostrado a seguir:

- 1- amplitude máxima do trecho de 1 segundo, 100 pontos (Amax);
- 2- amplitude mínima do trecho de 1 segundo, 100 pontos (Bmin);
- 3- distância entre Amax e Bmin do trecho de 1 segundo, 100 pontos (Tdif);
- 4- diferença entre Amax e Bmin do trecho de 1 segundo, 100 pontos (DifAB);
- 5- amplitude máxima do trecho centrado no evento, 30 pontos (Amax_pts);
- 6- amplitude mínima do trecho centrado no evento, 30 pontos (Bmin_pts);
- 7- distância entre Amax_pts e Bmin_pts do trecho centrado no evento (Tdif_pts);
- 8- diferença entre Amax_pts e Bmax_pts do trecho centrado no evento (DifAB_pts);
- 9- duração do evento (T);
- 10- lado oposto ao ângulo de pico positivo (dpos);
- 11- lado oposto ao ângulo de pico negativo (dneg);
- 12- distância da amplitude máxima ao extremo do evento/amplitude máxima positiva (trp);
- 13- distância da amplitude máxima ao extremo do evento/amplitude máxima negativa (trn);
- 14- tangente do ângulo positivo (tgp);
- 15- tangente do ângulo negativo (tgn);
- 16- ângulo positivo (θ_p);
- 17- ângulo negativo (θ_n);
- 18- ângulo de pico, relativo ao vértice de maior amplitude do evento (θ);
- 19- base do evento, relativa à sua amplitude máxima relativa (d_{base});
- 20- amplitude máxima da região inicial do sinal (Amax_i);
- 21- amplitude mínima da região inicial do sinal (Bmin_i);
- 22- amplitude máxima da região final do sinal (Amax_f);
- 23- amplitude mínima da região final do sinal (Bmin_f);

- 24- diferença entre as amplitude Amax e Amax_i (DifA_i);
- 25- diferença entre as distância Amax e Amax_i (tA-i);
- 26- diferença entre as amplitude Bmin e Bmin_i (DifB_i);
- 27- diferença entre as distância Amin e Amin_i (tB-i);
- 28- diferença entre as amplitude Amax e Amax_f (DifA_f);
- 29- diferença entre as distância Amax e Amax_f (tA-f);
- 30- diferença entre as amplitude Bmin e Bmin_f (DifB_f);
- 31- diferença entre as distância Amin e Amin_f (tB-f);
- 32- desvio padrão do trecho de 1 segundo, 100 pontos (desvioC);
- 33- desvio padrão do trecho centrado no evento, 30 pontos (desvio);
- 34- média do trecho de 1 segundo, 100 pontos (médiaC);
- 35- média do trecho centrado no evento, 30 pontos (média);
- 36- coeficiente de variação do trecho de 1 segundo, 100 pontos (coefC);
- 37- coeficiente de variação do trecho centrado no evento, 30 pontos (coef);
- 38- variância do trecho de 1 segundo, 100 pontos (variC);
- 39- variância do trecho centrado no evento, 30 pontos (vari);
- 40- fator de crista do trecho de 1 segundo, 100 pontos (CFC);
- 41- fator de crista do trecho centrado no evento, 30 pontos (CF);
- 42- entropia do trecho de 1 segundo, 100 pontos (entrop_lgC);
- 43- entropia do trecho de 1 segundo, 100 pontos (entrop_norC);
- 44- entropia do trecho centrado no evento, 30 pontos (entrop_log);
- 45- entropia do trecho centrado no evento, 30 pontos (entrop_nor).

7.3.1 Análise preliminar dos parâmetros

A avaliação dos parâmetros deve ressaltar a contribuição de determinado parâmetro em diferenciar os eventos epileptogênicos dos eventos que possam estar presentes no sinal do EEG.

A Tabela 7.3 mostra as médias das amplitudes máximas e mínimas, a distância entre os pontos de máximo e mínimo e a variação em amplitude entre os pontos de máximo e mínimo dos eventos. Para comparação estes valores foram calculados utilizando 5 conjuntos formados por 9 trechos de 1 segundo do sinal do EEG. Um conjunto para cada

tipo de evento: eventos epileptogênicos, EEG normal, ondas alfa, ruídos, piscadas. Nota-se que a faixa dos valores para os trechos contendo os eventos epileptogênicos está entre a faixa dos valores da onda alfa e do EEG normal e a faixa dos valores da piscada e dos ruídos. Além disso, um evento epileptogênico possui a distância no tempo, entre os pontos de máximo e mínimo, marcadamente menor.

Tabela 7.3- Valores médios obtidos para a amplitude máxima (Amax) e mínima (Bmin), distância entre as amplitudes máxima e mínima (Tdif) e a diferença entre as amplitude máxima e mínima (DifAB).

	Amax (m V)	Bmin (m V)	Tdif (seg.)	DifAB (mV)
Espícula	65,75	64,23	0,05	126,08
Normal	25,82	26,58	0,33	52,40
Alfa	20,18	20,61	0,32	39,71
Ruído	97,22	108,94	0,22	193,14
Piscada	130,20	169,27	0,27	280,59

A duração do evento foi calculada em 9 sinais contendo o evento epileptogênico e os resultados são mostrados na Tabela 7.4. Os valores obtidos confirmam a duração de um evento epileptogênico entre 70 a 230 ms. A Tabela 7.4, também, mostra os ângulos obtidos para estes sinais.

Tabela 7.4- Tempo de duração do evento epileptogênico (T), ângulo de pico do lado positivo (angp) e ângulo de pico do lado negativo (angn).

EEG	T (Duração) segundos	angp (q)	angn (q)	Ocorrência
Sinal 1	0,16	5,67	7,43	Espícula
Sinal 2	0,17	8,87	34,15	Só parte positiva
Sinal 3	0,23	25,39	8,67	Espícula onda lenta
Sinal 4	0,13	9,14	5,09	Espícula
Sinal 5	0,12	6,10	4,83	Espícula
Sinal 6	0,21	9,14	28,71	Espícula onda lenta
Sinal 7	0,09	4,51	6,51	Espícula
Sinal 8	0,13	14,58	5,86	Só parte negativa
Sinal 9	0,15	14,01	10,08	Espícula onda lenta

Os resultados em torno dos ângulos de pico revelam que o evento epileptogênico possui um ângulo agudo, bem pequeno, geralmente em torno de 4 a 14 graus. Observa-se também que junto a um ângulo pequeno podem ocorrer ângulos maiores, pois, em geral, existe uma tendência em se ter uma onda lenta antes ou após o pico positivo ou negativo.

Pode-se fazer uma analogia entre os ângulos e a duração de um evento epileptogênico. Geralmente, a duração é menor quando o pico, positivo ou negativo, não está acompanhado de uma onda lenta. Estas características ressaltam consideravelmente as diferenças entre as espículas e ondas agudas.

A Tabela 7.5 completa a análise feita na Tabela 7.4. Na Tabela 7.5 são apresentados os parâmetros médios de duração, em 9 sinais com EEG normal, ondas alfa, ruído e piscada. Também são mostradas as médias dos ângulos obtidos por cada um dos grupos de 9 sinais, considerando a sua amplitude máxima e mínima. Analisando-se estas tabelas, nota-se a duração reduzida do evento epileptogênico, comparado com os demais sinais.

Tabela 7.5- Valores médios referentes ao tempo de duração dos eventos (T), ângulo de pico do lado positivo (angp) e ângulo de pico do lado negativo (angn).

	T (Duração) segundos	angp (q_p)	angn (q_n)
Normal	0,47	33,37	28,25
Alfa	0,42	34,96	28,18
Ruído	0,39	12,91	7,86
Piscada	0,60	23,90	8,90

Os parâmetros estatísticos clássicos como média, desvio padrão e variância, são calculados em relação à amplitude em μ V. As médias dos resultados destes parâmetros, calculadas para os 9 sinais de cada conjunto de evento, são mostradas na Tabela 7.6.

Tabela 7.6- Valores médios obtidos do cálculo dos parâmetros estatísticos clássicos e do fator de crista.

	Desvio Padrão	Média	Variância	Fator de crista
Espícula	29,41	20,35	928	4,30
Normal	10,99	9,65	128	4,80
Alfa	9,15	8,76	104	4,39
Ruído	41,14	38,26	1803	4,58
Piscada	72,28	64,71	7515	4,03

7.4 Número Adequado de Parâmetros na Entrada da RNA

Um dos maiores questionamentos relacionados ao método paramétrico diz respeito ao número de parâmetros necessários para se definir as características que realmente destacam o sinal desejado. É possível que determinadas características não venham a contribuir com a definição do tipo de evento presente nos sinais apresentados. É, também, possível que determinada característica contribua negativamente para a classificação do evento.

Muitos dos parâmetros catalogados representam os valores obtidos de uma mesma fonte de características, representando variáveis que se relacionam, como ângulo, tangente e arco-tangente. Contudo, é questionável se somente o valor do ângulo é suficiente para definir a característica relativa à forma aguda apresentada pelo pico do sinal.

Foram estipulados conjuntos com 10 registros contendo o evento epileptogênico, 10 registros contendo piscadas, 10 registros contendo ruídos, 10 registros contendo ondas alfa e 10 registros contendo o EEG normal de fundo. Para estes conjuntos, foram calculados todos os parâmetros estipulados, os quais são mostrados nas tabelas no Anexo G deste trabalho.

Um fato observado quanto aos resultados em quase todos os parâmetros calculados é a posição intermediária dos eventos epileptogênicos com relação ao grupo dos sinais contendo ruídos e piscadas (com valores elevados) e o grupo dos sinais contendo o EEG de fundo e as ondas alfa (com valores baixos).

Foram calculadas as correlações entre os parâmetros obtidos do conjunto com o EEG normal de fundo e os conjuntos com os demais eventos. Os resultados das correlações encontram-se no Anexo G deste trabalho. Considera-se que quanto menor a correlação, mais distintas são as características de um conjunto do outro, pressupondo-se que mais facilmente uma RNA irá diferenciá-los.

Um segundo procedimento utilizado para destacar os parâmetros que definem as melhores características, que ressaltam um evento epileptogênico de um evento não-epileptogênico, foi a utilização do teste estatístico T^2 . Este teste encontra-se detalhado nas publicações como Johnson [104] e Beiguelman [106] e é descrito no Anexo D deste trabalho.

O teste estatístico T^2 baseia-se nas diferenças entre os parâmetros. É obtida a diferença entre os resultados relativos a um determinado parâmetro calculado para 10

trechos de sinais contendo eventos epileptogênicos com os resultados de 10 trechos de sinais contendo um outro evento. Esta diferença, definida como a distância entre os resultados, é manipulada pela fórmula de T^2 pelas medidas de sua média e sua covariância inversa, conforme as equações do Anexo D deste trabalho. O valor crítico para T^2 deve ser maior do que 10,0350. Portanto, se seu resultado for maior que este parâmetro é considerado como uma provável entrada para a RNA, caso contrário, o parâmetro pode ser desconsiderado. Um resultado maior do que o valor de T^2 crítico revela a existência das diferenças entre o parâmetro calculado para o evento epileptogênico e o outro evento considerado.

A Tabela 7.7 mostra os resultados obtidos com a correlação e com o teste T^2 . Esta tabela relaciona cada parâmetro com seus respectivos eventos considerados nos cálculos. Quando a correlação entre os eventos, relativa a um determinado parâmetro, é baixa, indica que este é um diferenciador e ele ganha o valor 1. Quando a correlação é alta, acima de 0,4, recebe o valor zero. E, quando o valor obtido de T^2 ultrapassa o limiar estabelecido (10,0350), o parâmetro ganha o valor 1; caso contrário, recebe o valor zero.

Os resultados iguais a zero na Tabela 7.7 indicam uma similaridade entre os parâmetros calculados para os sinais contendo o evento epileptogênico com os sinais contendo os demais eventos.

Os parâmetros que receberam a maioria de zeros, principalmente com o teste T^2 , foram destacados para serem desconsiderados. Este conjunto de parâmetros desconsiderados foi formado pelos parâmetros: trp, trn, tgp, tgn, dpos, dneg, coefC, coef e CF.

Inicialmente uma rede foi treinada e testada com os parâmetros de entrada desconsiderados. Contudo, os resultados não foram satisfatórios, sendo pior do que os resultados com todos os 45 parâmetros. Assim, várias redes foram treinadas e testadas retirando os parâmetros em destaque, um de cada vez. Após vários treinamentos e testes variando os parâmetros de entrada das redes considerou-se que os parâmetros: tgp, tgn, dpos, dneg e Cf, não alteram os resultados da rede. Os resultados obtidos com a retirada destes parâmetros foram praticamente iguais aos resultados com todos os 45 parâmetros.

7.5 Entradas e Saídas das Redes

Os sinais foram utilizados em um programa desenvolvido para o cálculo dos 45 parâmetros característicos de cada trecho. Um algoritmo que possibilita o entendimento da forma em que estes parâmetros foram obtidos encontra-se no Anexo H deste trabalho.

Nas entradas das redes foram colocados todos os parâmetros calculados para os sinais de treinamento e testes já definidos no Capítulo 2 deste trabalho. A Figura 7.10 visualiza o esquema de organização dos parâmetros na entrada da rede.

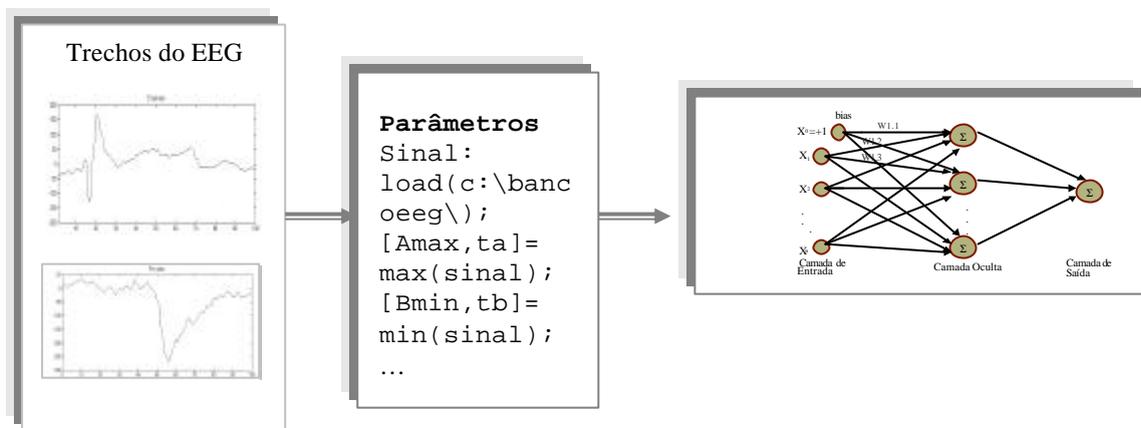


Figura 7.10- Esquema simplificado de uma rede tendo como entrada os parâmetros característicos dos trechos dos sinais do EEG.

O vetor na entrada da rede corresponde ao conjunto de parâmetros da lista apresentada no item 7.3 deste trabalho. Cada parâmetro foi calculado através do algoritmo proposto antes da entrada da rede. Este algoritmo fornece uma matriz que é o vetor de entrada para as RNA's analisadas.

7.6 Treinamento e Teste

A arquitetura das RNA's desenvolvidas, tendo como entradas as características parametrizadas dos sinais, segue as mesmas propostas do Capítulo 2 deste trabalho, utilizadas em todos os pré-processamentos desenvolvidos em capítulos anteriores. A diferença com relação as demais redes encontra-se no número de neurônios de entrada, o que irá implicar em diferentes números de neurônios na camada oculta.

Os conjuntos de treinamento e teste utilizados foram os mesmos até então definidos nos pré-processamentos já relatados neste trabalho. Que são um conjunto sem caracterização prévia dos sinais de entrada e um segundo conjunto com caracterização prévia dos sinais de entrada. Foram desenvolvidas várias redes seguindo as duas linhas de abordagens, como mostrado na Figura 7.11.

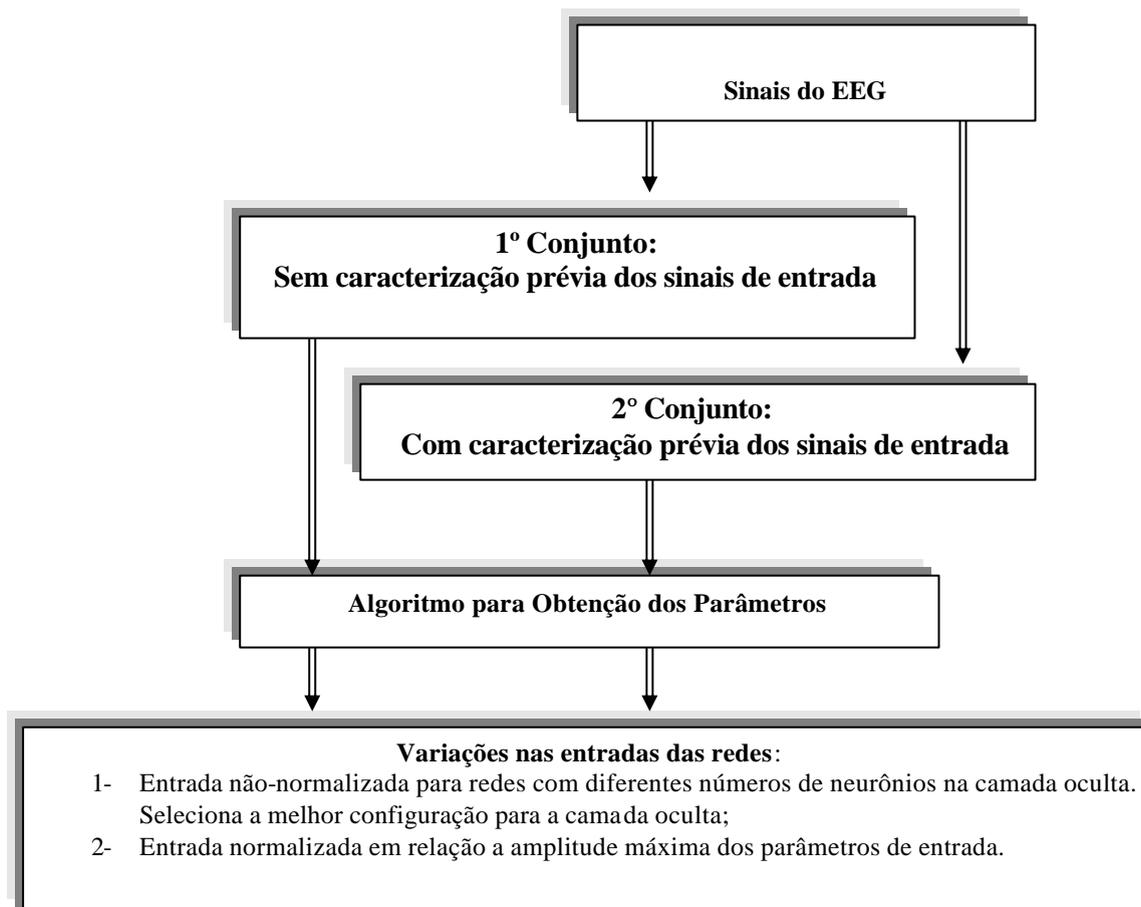


Figura 7.11- Desenvolvimento das RNA's com entradas parametrizadas segundo as características dos eventos contidos nos sinais.

As redes foram treinadas inicialmente com os 45 parâmetros propostos e, após o estudo daqueles que devem ser desconsiderados, como explica no item 7.4 deste capítulo, foram treinadas novamente com um valor reduzido de parâmetros em suas entradas.

Foram treinadas redes variando-se o número de neurônios na camada oculta, estipulando-se um número máximo de 100.000 interações e considerando-se a que mostrou o melhor resultado. Foram consideradas redes com entradas normalizadas e não-normalizadas.

A normalização foi realizada para cada coluna de parâmetros, conforme a matriz da entrada dos sinais na rede. Isto é, foi calculado o valor máximo para cada parâmetro, dentro da matriz de parâmetros fornecida pelo conjunto dos sinais apresentados.

7.7 Resultados e Análise dos Resultados

No Anexo B deste trabalho são encontrados os principais gráficos resultantes do treinamento das redes. Os resultados obtidos junto aos conjuntos de testes são exibidos nas tabelas seguintes.

7.7.1 RNA sem caracterização prévia dos sinais de entrada

As primeiras redes foram treinadas com 45 parâmetros de 47 sinais com eventos epileptogênicos e 73 sinais com eventos não-epileptogênicos. O conjunto de teste, formado por 45 parâmetros de 30 sinais com os eventos epileptogênicos e 23 sinais com os eventos não-epileptogênicos. Um segundo conjunto de teste foi criado com mais 5 sinais contendo piscadas totalizando 58 sinais no arquivo de teste para serem parametrizados.

Estes registros foram catalogados em tabelas no Anexo A deste trabalho. Os resultados para esta rede com as variações consideradas encontram-se nas Tabelas 7.8 e 7.9.

O acréscimo de cinco trechos dos sinais contendo piscadas no conjunto de teste altera os resultados. A especificidade foi reduzida, devido ao aumento do número de falsos positivos. Em geral, as redes confundem as piscadas com o evento epileptogênico, classificando-as erradamente. Dos cinco sinais com piscadas, estas redes classificaram corretamente cerca de um ou dois.

Tabela 7.8- Resultados obtidos pelas redes com 45 parâmetros em suas entradas, que são fornecidos por 53 e 58 (mais 5 piscadas) sinais de teste.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
8 N. Ocultos 100.000 Interações	43 81%	5	27	19	4	3
9 N. Ocultos 100.000 Interações	42 79%	6	27	20	3	3
11 N. Ocultos 100.000 Interações	41 77%	7	27	20	3	3
8 N. Ocultos 100.000 Interações Normalizada/ Evento	42 72%	2	27	16	7	3
8 N. Ocultos 100.000 Interações Mais 5 piscadas	43 74%	6	27	20	8	3
8 N. Ocultos 100.000 Interações Normalizada Mais 5 piscadas	38 65%	6	20	19	9	10

Tabela 7.9- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais utilizadas para obter os resultados da Tabela 7.8.

Rede	Sensibilidade	Especificidade	VPP	VPN
8 N. Ocultos 100.000 Interações	0,90	0,83	0,87	0,86
9 N. Ocultos 100.000 Interações	0,90	0,87	0,90	0,87
11 N. Ocultos 100.000 Interações	0,90	0,87	0,90	0,87
8 N. Ocultos, 100.000 Interações Normalizada por Evento	0,90	0,70	0,79	0,84
8 N. Ocultos, 100.000 Interações Teste com mais 5 piscadas	0,90	0,71	0,77	0,87
8 N. Ocultos, 100.000 Interações Normalizada Teste com mais 5 piscadas	0,67	0,67	0,69	0,66

Um dos questionamentos realizados ao utilizar os parâmetros na RNA é se existem entre eles alguns que possam ser retirados sem prejudicar o desempenho da rede. Assim, são retirados alguns parâmetros, como proposto no item 7.4 deste trabalho, presumindo-se como sendo dispensáveis nas entradas das redes. Os resultados obtidos ao retirar estes parâmetros da entrada da rede com 8 neurônios ocultos foram alterados, como pode-se observar nas Tabelas 7.10 e 7.11.

Tabela 7.10- Resultados obtidos pelas redes com 40 parâmetros em suas entradas.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
8 N. Ocultos 100.000 Interações	46 87%	1	27	19	4	3
8 N. Ocultos 100.000 Interações Normalizada	32 60%	8	20	13	10	10
8 N. Ocultos 100.000 Interações Mais 5 piscadas	46 87%	1	27	19	9	3

Tabela 7.11- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as mesmas redes neurais utilizadas na Tabela 7.10.

Rede	Sensibilidade	Especificidade	VPP	VPN
8 N. Ocultos 100.000 Interações	0,90	0,83	0,87	0,86
8 N. Ocultos, 100.000 Interações Normalizada	0,67	0,56	0,67	0,57
8 N. Ocultos, 100.000 Interações Teste com piscadas	0,90	0,68	0,75	0,86

Estas redes treinadas com os 5 parâmetros desconsiderados apresentaram uma melhora no número de acertos, mas em um quadro geral as variações não foram representativas.

7.7.2 RNA com caracterização prévia dos sinais de entrada

Foram selecionados grupos pré-estabelecidos, para os sinais contendo os eventos epileptogênicos, bem como para os sinais contendo os eventos não-epileptogênicos, conforme estabelecido no Capítulo 2 deste trabalho.

As redes foram treinadas inicialmente com 45 parâmetros retirados dos 45 sinais previamente escolhidos. Assinalando-se o fato de serem encontrados nestes arquivos trechos dos sinais com as várias formas dos eventos epileptogênicos e trechos dos sinais contendo eventos como ruídos, piscadas, ondas alfa e o EEG normal de fundo. O conjunto de teste é semelhantemente constituído por 45 trechos dos sinais contidos no banco de dados. As Tabelas 7.12 e 7.13 mostram os resultados das redes treinadas e testadas com estes conjuntos.

Dos resultados das redes treinadas com a caracterização prévia dos sinais de entrada destacam-se os números de acertos. Estas redes apresentam 40 sinais identificados corretamente dos 45 sinais apresentados em suas entradas. Dos 5 sinais não identificados, 2 são indefinidos, 2 são falsos negativos e um falso positivo.

Tabela 7.12- Resultados obtidos pelas redes com 45 parâmetros em suas entradas, fornecidas pelos 45 sinais de teste.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
8 N. Ocultos 100.000 Interações	36 80%	6	18	24	1	2
9 N. Ocultos 11.863 Interações	40 89%	2	17	24	1	3
10 N. Ocultos 100.000 Interações	35 78%	7	18	23	2	2
9 N. Ocultos 100.000 Interações Normalizada	30 67%	7	20	17	8	0
9 N. Ocultos 12.026 Interações Normalizada por Evento	31 69%	8	19	19	6	1

Tabela 7.13- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, utilizando-se os resultados obtidos pelas redes neurais da Tabela 7.12.

Rede	Sensibilidade	Especificidade	VPP	VPN
8 N. Ocultos 100.000 Interações	0,90	0,96	0,95	0,92
9 N. Ocultos 11.863 Interações	0,85	0,96	0,94	0,89
10 N. Ocultos 100.000 Interações	0,90	0,92	0,90	0,92
9 N. Ocultos 100.000 Interações Normalizada	1,00	0,68	0,71	1,00
9 N. Ocultos 12.026 Interações Normalizada por Evento	0,95	0,76	0,76	0,95

Um outro ponto interessante nestes resultados encontra-se nos valores de sensibilidade e especificidade, que estão em torno de 0,90, e que podem ser considerados razoavelmente bons.

Os valores normalizados nas entradas da rede continuam produzindo uma especificidade relativamente baixa, embora com bons valores de sensibilidade. A baixa especificidade é um resultado que geralmente aparece quando é utilizado este procedimento, devido ao número de falsos positivos gerados.

Dando seqüência ao desenvolvimento proposto, realiza-se uma abordagem dos parâmetros utilizados com intuito de poder desconsiderar alguns deles sem prejudicar o desempenho da rede. Conforme as análises apresentadas na unidade 7.4 deste capítulo e os parâmetros definidos para serem retirados, são treinadas algumas redes até encontrar-se uma configuração, em termos de neurônios ocultos, satisfatória. Nas Tabelas 7.14 e 7.15 são mostrados os resultados obtidos ao retirar-se estes parâmetros. A rede de 8 neurônios ocultos é considerada a que produz os melhores resultados.

Tabela 7.14- Resultados obtidos pelas redes utilizando-se 40 parâmetros em suas entradas, que são calculados para os 45 sinais de teste.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
8 N. Ocultos 10.886 Interações	40 89%	1	18	23	2	2
8 N. Ocultos 3.261 Interações Normalizada por Evento	30 67%	8	18	20	5	2

Tabela 7.15- Valores de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, para as redes neurais definidas na Tabela 7.14.

Rede	Sensibilidade	Especificidade	VPP	VPN
8 N. Ocultos 10886 interações 10.886 Interações	0,90	0,92	0,90	0,92
8 N. Ocultos, 3.261 Interações Normalizada por Evento	0,90	0,80	0,78	0,91

Uma análise dos resultados das redes treinadas com 40 parâmetros, comparadas com as redes treinadas com 45 parâmetros, mostra poucas variações. De toda a forma, os resultados continuaram estáveis, indicando que os parâmetros desconsiderados não contribuem para a distinção do evento epileptogênico dos demais.

7.8 Conclusão e Discussão

A parametrização mostra-se aparentemente simples por se tratar de um levantamento de dados direto e de cálculos básicos, como dimensões em amplitude e duração. No entanto, exige uma boa bagagem de informações a respeito do sistema, do qual se deseja catalogar as características. No caso da detecção dos eventos epileptogênicos no EEG, são necessários estudos adicionais da fisiologia do sinal, adicionados as informações de um especialista.

Nos cálculos relacionados às amplitudes observa-se que um evento epileptogênico encontra-se em uma posição intermediária. Eventos como ondas alfa e EEG normal de fundo são considerados de baixa amplitude e eventos como ruídos e piscadas são considerados de alta amplitude.

Nas Tabelas 7.16 e 7.17 estão destacadas as melhores representações para as redes usando parâmetros característicos dos sinais como entrada.

Tabela 7.16- Melhores resultados obtidos pelas redes que utilizando nas entradas os parâmetros obtidos das características dos sinais.

Rede	Acertos Valor Absoluto e Percentual	Indefinidos	VP	VN	FP	FN
Sem caracterização dos sinais e 53 sinais de teste 8 N. Ocultos e 100.000 Interações 45 parâmetros	43 81%	5	27	19	4	3
Sem caracterização dos sinais e 53 sinais de teste 8 N. Ocultos e 100.000 Interações 40 parâmetros	46 87%	1	27	19	4	3
Com caracterização dos sinais e 45 sinais de teste 8 N. Ocultos e 100.000 Interações 45 parâmetros	36 80%	6	18	24	1	2
Com caracterização dos sinais e 45 sinais de teste 9 N. Ocultos e 11.863 Interações 45 parâmetros	40 89%	2	17	24	1	3
Com caracterização dos sinais e 45 sinais de teste 8 N. Ocultos e 10.886 Interações 40 parâmetros	40 89%	1	18	23	2	2

Rede	Sensibilidade	Especificidade	VPP	VPN
Sem caracterização dos sinais e 53 sinais de teste. 8 N. Ocultos e 100.000 Interações 45 parâmetros	0,90	0,83	0,87	0,86
Sem caracterização dos sinais e 53 sinais de teste. 8 N. Ocultos e 100.000 Interações 40 parâmetros	0,90	0,83	0,87	0,86
Com caracterização dos sinais e 45 sinais de teste. 8 N. Ocultos e 100.000 Interações 45 parâmetros	0,90	0,96	0,95	0,92
Com caracterização dos sinais e 45 sinais de teste 9 N. Ocultos e 11.863 Interações 45 parâmetros	0,85	0,96	0,94	0,89
Com caracterização dos sinais e 45 sinais de teste 8 N. Ocultos e 10.886 Interações 40 parâmetros	0,90	0,92	0,90	0,92

Tabela 7.17- Resultados obtidos pelas redes com entradas obtidas dos parâmetros das características dos sinais.

Algumas vezes os ruídos possuem amplitudes comparáveis às de um evento epileptogênico, o que dificulta a sua identificação. Contudo, ao se relacionar a duração e as distâncias entre as amplitudes máximas e mínimas, é possível verificar-se que estes valores são menores para o evento epileptogênico. Em geral, um parâmetro de determinado sinal pode cair na faixa de variação do evento epileptogênico, no entanto, quando todos os parâmetros são considerados em conjunto, um deles pode excluir o sinal em questão do grupo dos eventos epileptogênicos.

Um grupo de parâmetros faz a distinção entre os eventos epileptogênicos e as ondas alfa e o EEG normal de fundo. Neste grupo, pode-se citar as diferenças entre as amplitudes máximas e mínimas e a duração de um evento calculada a partir da amplitude máxima. Um segundo grupo de parâmetros faz a distinção entre os eventos epileptogênicos e os trechos dos sinais contendo ruídos e piscadas. Desconsiderar um parâmetro nas entradas destas redes é delicado, pois em conjunto os parâmetros se completam.

CAPÍTULO 8

8. CONCLUSÕES E CONTRIBUIÇÕES DESTE TRABALHO

8.1. Conclusões

Para uma análise geral das redes implementadas neste trabalho, é necessário uma visualização de todos os resultados segundo o tipo de pré-processamento. Os melhores resultados obtidos pelas redes variando-se a forma de entrada encontram-se nas Tabelas 8.1. Eles seguem os mesmos padrões de exposições desenvolvidas ao longo deste estudo, mostrando a porcentagem de acertos, o número de verdadeiros positivos (VP), o número de verdadeiros negativos (VN), o número de falsos positivos (FP), o número de falsos negativos (FN), a sensibilidade (S), a especificidade (E), o valor preditivo positivo (VPP) e o valor preditivo negativo (VPN).

Os resultados da Tabela 8.1 foram destacados conforme o conjunto de teste, que apresentou as melhores taxas de sensibilidade e especificidade, podendo ser o conjunto sem caracterização prévia do sinal de entrada ou o conjunto com caracterização prévia do sinal de entrada, como descritos no Capítulo 2 e aplicados nos demais capítulos deste trabalho. O conjunto de teste sem caracterização prévia dos sinais de entrada considerou 53 sinais com e sem eventos epileptogênicos e o conjunto com caracterização prévia dos sinais de entrada considerou 45 sinais com e sem eventos epileptogênicos de morfologias previamente definidas.

Os resultados para a rede com entradas pré-processadas utilizando-se a FWT são obtidos pela base de regras responsável para analisar os resultados das redes individuais definidas nas Figuras 6.15 e 6.17 do Capítulo 6 deste trabalho. Os arquivos de teste, para este caso, foram os mesmos considerados nos demais pré-processamentos; no entanto, os arquivos de treinamento foram adequados segundo o tipo de RNA (RNA 1, RNA 2, RNA 3 e RNA 4) usada para identificar os eventos em questão.

Foram destacados os casos em que as entradas normalizadas apresentaram os melhores resultados. O objetivo é definir em quais pré-processamentos a entrada normalizada é indicada, já que a normalização em algumas aplicações aumenta o número de falsos positivos.

Tabela 8.1- Melhores resultados obtidos pelas redes desenvolvidas neste estudo, destacadas pelas formas de pré-processamento dos sinais de entrada.

Rede	Acertos	VP	VN	FP	FN	S	E	VPP	VPN
Sem pré-processamento Com caracterização 12 N. Ocultos	30 67%	18	20	5	2	0,90	0,80	0,78	0,91
Espectro Sem caracterização 13 N. Ocultos Normalizada.	42 79%	27	17	6	3	0,90	0,74	0,82	0,85
Espectrograma Com caracterização 28 N. Ocultos	30 67%	19	21	4	1	0,95	0,84	0,83	0,95
FWT Com caracterização 12 N. Ocultos Normalizada	32 71%	19	13	12	1	0,97	0,63	0,76	0,94
Parâmetros Com caracterização 8 N. Ocultos	36 80%	18	24	1	2	0,90	0,96	0,95	0,92

As redes sem pré-processamento resultaram em muitas saídas indefinidas, o seu número de acertos foi baixo, não passando de 67%; logo, muitas saídas consideradas definidas não foram identificadas corretamente. A sensibilidade e a especificidade foram em média 80% e 70%, respectivamente.

Devido à grande variação na morfologia dos sinais do EEG, a identificação de determinado evento, dentre os demais eventos existentes, é difícil para somente uma RNA. A implementação de redes individuais para identificar os principais eventos não-epileptogênicos com intuito de separá-los da rede destinada a detectar os eventos epileptogênicos gerou individualmente as mesmas dificuldades já relatadas para este caso. Portanto, é aconselhável o uso de um pré-processamento, com a finalidade de ressaltar as características do evento, o qual se deseja identificar.

O uso da densidade espectral de potência na entrada das redes aumentou o número de acertos em relação às entradas sem pré-processamento. A sensibilidade e especificidade foram em torno de 80% a 90%. Nos resultados, foi constatado o fato de que entradas normalizadas reduzem os valores indefinidos e aumentam o número de falsos positivos.

As redes com entradas obtidas dos espectrogramas tiveram em torno de 80% de acertos. A sensibilidade e a especificidade foram de 90% e 85%, respectivamente. Os resultados obtidos ao utilizar essas redes evidenciam baixos valores de falsos positivos e negativos.

O resultado da rede quando foi utilizada a transformada *wavelet* foi cerca de 80% de acertos sem nenhum valor indefinido. A taxa de sensibilidade dessa rede foi em torno de 95% e a sua especificidade foi de 65%. Assim, esta transformada realmente detecta os eventos epileptogênicos como sendo epileptogênicos, contudo, detecta os eventos não epileptogênicos como sendo epileptogênicos. Para uma melhora nos resultados, sugere-se a verificação de um limiar após seu pré-processamento.

O método que utiliza a extração de características com entradas parametrizadas apresentou uma boa porcentagem de acertos em torno de 90%, com quase nenhum valor indefinido; suas taxas de sensibilidade e especificidade foram boas, em torno de 90% a 95%. Este método chegou a apresentar 40 sinais identificados corretamente dos 45 sinais de entradas. Dos 5 sinais não identificados, 2 são indefinidos, 2 são falsos negativos e 1 falso positivo.

A viabilidade do uso de um pré-processamento para sinais do EEG, antes de serem submetidos a uma análise utilizando-se a RNA, torna-se evidente ao considerar-se os vários resultados e os trabalhos já desenvolvidos neste sentido. A questão é definir qual pré-processamento deve ser utilizado para determinado tipo de sinal. Após esta definição é necessário determinar como este pré-processamento deve ser melhor implementado.

A avaliação dos resultados das RNA's utilizadas neste trabalho procurou destacar somente a atuação dos pré-processamentos, sem nenhuma forma adicional de tratamento matemático. Os resultados obtidos com os diversos pré-processamentos foram colocados diretamente nas entradas das RNA's, como mostrado na Figura 8.1. Não foi realizada nenhuma verificação do limiar ou outras formas de eliminar os sinais cujas características diferiam dos padrões dos sinais do EEG contendo os eventos epileptogênicos.

Contudo, em uma análise seqüencial, para todos os canais do eletroencefalograma, é conveniente realizar um estudo adicional que possa eliminar os trechos dos sinais com características morfológicas diferentes dos eventos a serem destacados pelas RNA's.

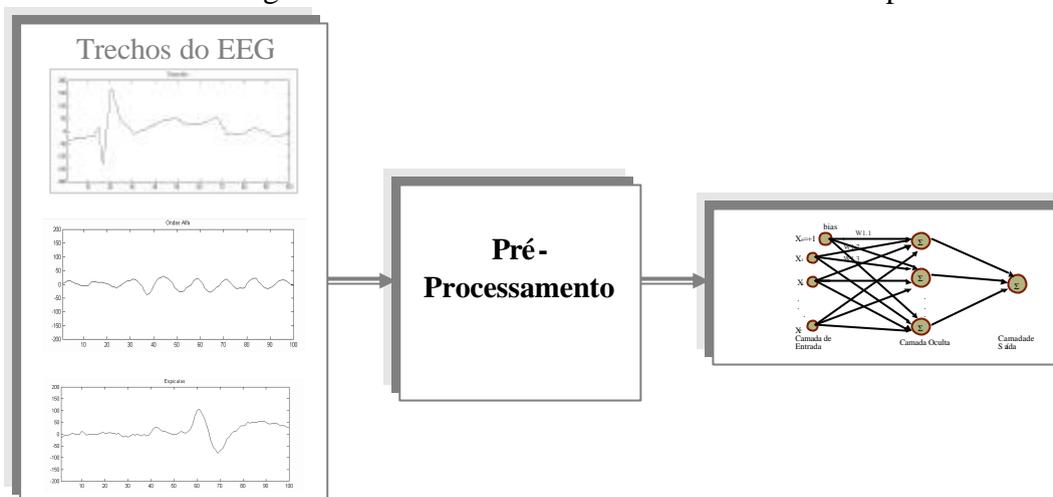


Figura 8.1- Esquema simplificado do estudo desenvolvido neste trabalho.

Portanto, os resultados tendem a melhorar se também for realizada uma avaliação da morfologia do sinal, antes que ele seja pré-processado. Os sinais que possuem morfologias semelhantes às dos eventos epileptogênicos são candidatos a serem pré-processados e analisados pela RNA.

Assim, é aconselhável uma avaliação das características básicas dos sinais, como amplitude máxima e mínima, antes de serem pré-processados, para verificar se estas encontram-se dentro dos padrões relativos ao sinal a ser detectado pela RNA. Esta sugestão está ilustrada na Figura 8.2.

Contudo, a utilização de um conjunto de padrões que contenha as características necessárias para distinguir um evento epileptogênico dos demais é difícil, pois estes eventos são imprevisíveis com muitas variações na sua forma de onda. Os casos mais complicados para serem distinguidos, como os apresentados nas Figuras 3.10 a 3.12 do Capítulo 3 deste trabalho, aparecem com frequência ao longo dos sinais do EEG. São muitos os eventos que apresentam características morfológicas semelhantes as características dos eventos epileptogênicos. As RNA's são essenciais na tomada de decisão em todos os casos.

Por outro lado, na maioria dos casos, os parâmetros calculados individualmente não definem se no sinal em questão contem um evento epileptogênico. É necessário associar as informações fornecidas pelos vários parâmetros, para poder decidir quanto a existência do

evento, pois em conjunto os parâmetros se completam. As RNA's associam estas informações e decidem a possível existência do evento no sinal apresentado em sua entrada.

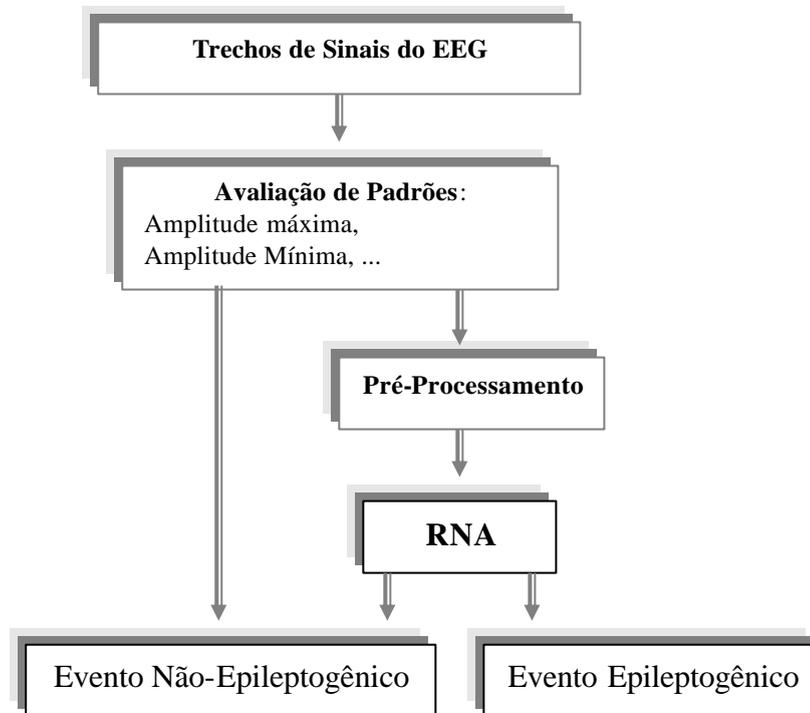


Figura 8.2- Esquema simplificado da implementação de uma avaliação de padrões antes do pré-processamento e da análise pela RNA.

Uma outra alternativa, para facilitar o trabalho das redes em definir e classificar os sinais, é utilizar as características obtidas pelo pré-processamento de sinais contendo os eventos epileptogênicos. A avaliação destas características seria após o pré-processamento. Por exemplo, o espectro revela valores de amplitudes (em dB) característicos para os eventos epileptogênicos; assim os sinais com espectros semelhantes devem ser avaliados pela rede, e os demais são considerados como trechos que não contêm o evento epileptogênico. Do mesmo modo é possível definir padrões para os demais tipos de pré-processamento, como mostrado na Figura 8.3.

Um dos pré-processamentos que sugere uma avaliação das características morfológicas dos sinais, como a avaliação do limiar, é a transformada *wavelet*. Os

resultados melhoram, quando é realizada a avaliação do limiar. Esta avaliação foi utilizada nos trabalhos de Argound [1] e Esteller [16].

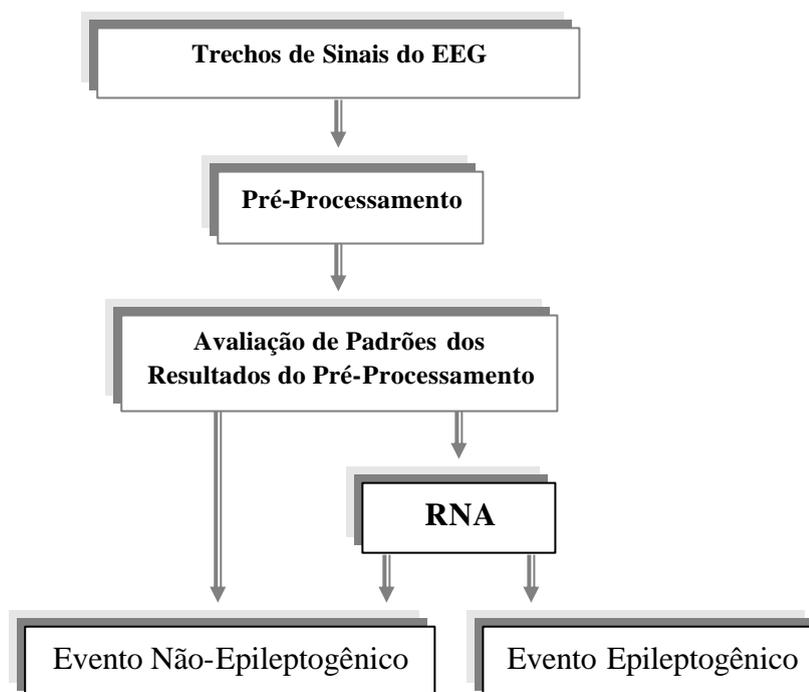


Figura 8.3- Esquema simplificado da implementação de uma avaliação de limiar após o pré-processamento e antes da análise pela RNA.

Uma avaliação dos resultados já publicados, relativos aos vários métodos empregados nos estudos dos eventos característicos dos sinais do EEG, indica que os valores obtidos com as redes destacadas acima encontram-se dentro de uma faixa considerada de bom desempenho. O trabalho de Wilson e Emerson [107] fez uma avaliação da eficiência de alguns métodos de detecções de espículas publicados desde 1976 a 2000, totalizando 24 estudos. A maioria dos métodos analisados baseia-se no método de Gotman, o qual foi relatado no item 7.1 do Capítulo 7 deste trabalho. Os principais resultados deste estudo encontram-se na Tabela 8.2. Nesta tabela, os valores não definidos não foram apresentados pelo autor.

Tabela 8.2- Avaliação da eficiência dos métodos para detecção de espículas realizada e catalogada por Wilson e Emerson [107]. O termo GSD refere-se ao método de Gotman [3].

Autor	Ano	Duração [min]	Algoritmo	Sensibilidade	Falsos Positivos [min]
Gotman <i>et al</i>	1976	189	GSD	-	0,33
Gotman <i>et al</i>	1979	12240	GSD	-	0,11
Davey	1989	5.3	Limiar	0,74	0,38
Witte <i>et al</i>	1991	1	Potência-Frequência	0,90	4,0
Gabor, Seyal	1992	63,8	RNA	0,97	1,5
Gotman, Wang	1992	2000	GSD	-	0,79
Hostetler <i>et al</i>	1992	100	GSD	0,76	5,2
Webber <i>et al</i>	1994	40	RNA	0,73	6,1
Senhadji	1995	10	Wavelet (DWT)	0,86	6,8
Feucht <i>et al</i>	1997	90	Potência instantânea RNA	0,88	1,8
Dumpelmann, Elger	1999	136	Dois estágios de detecção	0,32	9,4
			GSD	0,23	14,4
			Wavelet	0,28	12,6
Wilson <i>et al</i>	1999	143	Múltiplas RNA's	0,47	2,5
			GSD	0,15	3,2
Goelz <i>et al</i>	2000	278	Wavelet	0,84	-

CAPÍTULO 9

9. SUGESTÕES PARA TRABALHOS FUTUROS

As análises dos vários pré-processamentos dos sinais destinados às entradas das RNA's descritas neste trabalho forneceram um direcionamento para serem implementados nos sinais do EEG, para detectar os eventos epileptogênicos. Com base nos resultados, sugere-se os seguintes estudos adicionais:

- Implementação de forma contínua dos registros do banco de dados utilizando-se como pré-processamento os parâmetros relativos às características morfológicas dos sinais, bem como os dados estatísticos relacionados.
- Estudo dos padrões que possam eliminar os eventos não-epileptogênicos antes de serem processados pelas redes, como a definição de limiares.
- Implementação de um sistema Híbrido abrangendo os pré-processamentos analisados neste estudo, como mostrado na Figura 9.1. A Densidade Espectral de Potência é representada pelos valores máximos das amplitudes do espectro e suas frequências correspondentes. Elas são catalogados como características do sinal utilizadas no pré-processamento com parâmetros. O método dos parâmetros foi destacado devido aos bons resultados apresentados e a Transformada *Wavelet* foi destacada por ser o método mais indicado para se trabalhar com estes tipos de sinais.
- Organizar visualmente telas de programas que possam oferecer uma análise dos eventos epileptogênicos detectados de forma contínua, segundo seu tipo de pré-processamento.

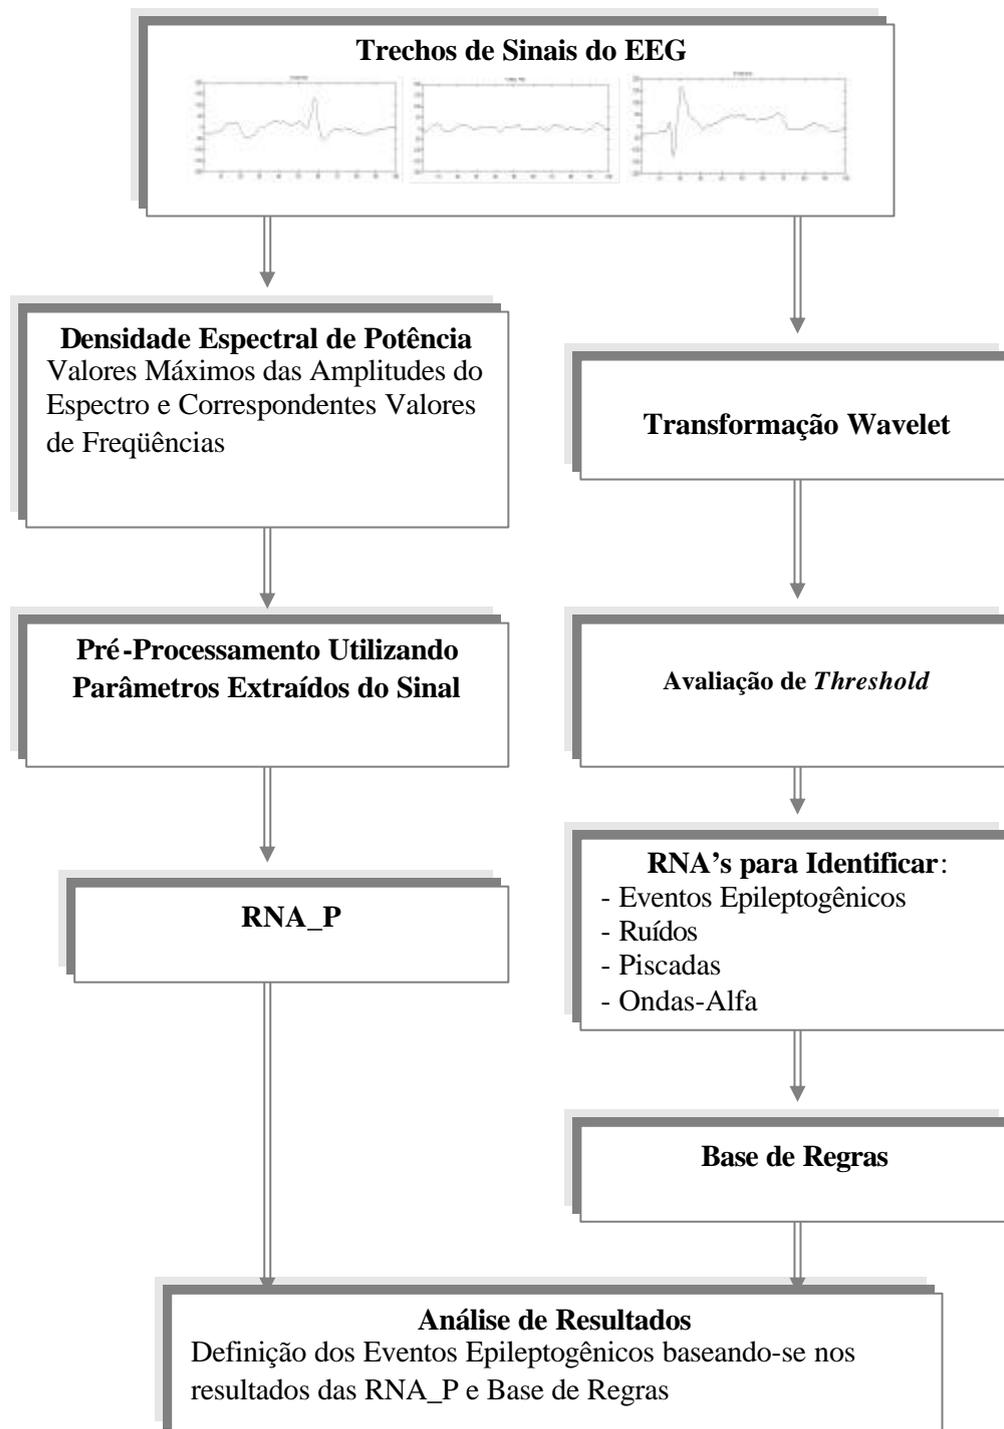


Figura 9.1: Propostas para análise de sinais do EEG contendo eventos epileptogênicos, utilizando várias RNA's e pré-processamentos sugeridos.

ANEXO A TABELAS CONTENDO OS ARQUIVOS DE TREINAMENTO E TESTE

A Tabela A.1 mostra o conjunto de treinamento para as RNA's sem caracterização prévia dos sinais de entrada. Este conjunto possui 47 sinais com eventos epileptogênicos e 73 sinais com eventos não-epileptogênicos.

Tabela A.1- Conjunto de treinamento para as RNA's sem caracterização prévia dos sinais de entrada.

Sinais Número	Sinais	Canais	Ponto Inicial
1	laporte\lap_3510	29	800
2	laporte\lap_3510	8	800
3	laporte\lap_3510	5	800
4	laporte\lap_3510	6	800
5	Wamboldt\wam_720	8	1000
6	Wamboldt\wam_720	13	1000
7	Wamboldt\wam_720	32	1000
8	Wamboldt\wam_720	29	1000
9	St_rock\sr_945	7	800
10	St_rock\sr_945	24	1200
11	St_rock\sr_15	17	200
12	St_rock\sr_15'	5	400
13	'St_rock\sr_15	1	500
14	St_rock\sr_15	4	500
15	St_rock\sr_15	5	500
16	St_rock\sr_15	6	500
17	St_rock\sr_15	11	500
18	St_rock\sr_15	15	500
19	St_rock\sr_15	15	500
20	St_rock\sr_15	19	500
21	St_rock\sr_945	1	1200
22	St_rock\sr_945	2	1200
23	St_rock\sr_945	5	1200
24	Vadnais2\vad2_2955	4	300
25	Vadnais2\vad2_2955	8	300
26	Vadnais2\vad2_2955	29	300
27	Vadnais2\vad2_2955	13	300
28	Vadnais2\vad2_2955	15	300
29	Vadnais2\vad2_2955	8	900
30	Vadnais2\vad2_2955	31	900
31	St_rock\sr_15'	2	200
32	St_rock\sr_15	4	200
33	St_rock\sr_15	7	200
34	St_rock\sr_15	8	200
35	St_rock\sr_15	10	200
36	St_rock\sr_15	11	200
37	St_rock\sr_15	12	200
38	St_rock\sr_15	13	200
39	St_rock\sr_15	15	200
40	St_rock\sr_15	16	200
41	Vadnais2\vad2_2955	29	900
42	Zografo\zog_1815	2	1200
43	Zografo\zog_1815	3	1200
44	Zografo\zog_1815	8	1200
45	Zografo\zog_1815	9	1200
46	Zografo\zog_1815	10	1200
47	Jokhoo\jok_585	11	400
48	Jokhoo\jok_585	27	400

49	Jokhoo\jok_585	2	600
50	Jokhoo\jok_585	8	600
51	St_rock\sr_15	1	1
52	St_rock\sr_15	5	1
53	St_rock\sr_15	15	200
54	St_rock\sr_15	16	50
55	St_rock\sr_15	15	1
56	St_rock\sr_15	18	1
57	St_rock\sr_15	2	100
58	St_rock\sr_15	9	100
59	St_rock\sr_15	10	100
60	St_rock\sr_15	2	1300
61	Jokhoo\jok_585	1	900
62	Jokhoo\jok_585	3	800
63	Wamboldt\wam_450	5	1000
64	St_rock2\sr2_3480	6	1000
65	St_rock2\sr2_1080	1	1100
66	St_rock2\sr2_1080	24	1100
67	St_rock2\sr2_1080	21	1100
68	Vadnais1\vad1_1260	31	200
69	Vadnais1\vad1_1260	4	200
70	Wamboldt\wam_660	6	200
71	Jokhoo\jok_60	5	200
72	Jokhoo\jok_60	31	100
73	St_rock\sr_30	2	2
74	St_rock\sr_30	24	200
75	St_rock\sr_30	3	700
76	laporte\lap_45	4	900
77	laporte\lap_45	8	1200
78	laporte\lap_45	27	700
79	laporte\lap_45	31	300
80	Jokhoo\jok_375	1	400
81	Vadnais1\vad1_1260	8	200
82	Vadnais1\vad1_1260	13	200
83	Vadnais1\vad1_1260	15	200
84	St_rock\sr_15	21	100
85	St_rock\sr_15	4	300
86	St_rock\sr_15	12	300
87	St_rock\sr_15	21	700
88	Kurian\kur_15	2	400
89	Kurian\kur_15	4	300
90	Kurian\kur_15	32	600
91	Kurian\kur_15	28	1100
92	Kurian\kur_15	20	1200
93	Zografo\zog_15	1	400
94	Zografo\zog_15	32	700
95	Zografo\zog_15	7	1100
96	Zografo\zog_15	8	1100
97	Zografo\zog_15	22	700
98	St_rock2\sr2_15	24	100
99	St_rock2\sr2_15	5	400
100	Vadnais2\vad2_15	3	400
101	Vadnais2\vad2_15	29	300
102	Vadnais2\vad2_15	2	700
103	Vadnais2\vad2_15	21	1300
104	Vadnais2\vad2_15'	10	1400
105	Wamboldt\wam_15	32	300
106	Wamboldt\wam_15	32	500
107	Wamboldt\wam_15	25	1400
108	Wamboldt\wam_15	16	1200
109	St_rock\sr_15	2	1100
110	St_rock\sr_15	22	200
111	St_rock\sr_15	1	500
112	laporte\lap_15	27	1000
113	laporte\lap_15	2	400
114	laporte\lap_15	20	100
115	Vadnais1\vad1_60	4	200
116	Vadnais1\vad1_60	32	1
117	Vadnais1\vad1_60	2	1300
118	Vadnais1\vad1_60	14	500
119	Vadnais1\vad1_60	27	800
120	Jokhoo\jok_60	24	900

A Tabela A.2 mostra o conjunto de teste para as RNA's sem caracterização prévia dos sinais de entrada. Este conjunto possui 30 sinais com eventos epileptogênicos e 23 sinais com eventos não-epileptogênicos quaisquer e 5 sinais com piscadas.

Tabela A.2- Conjunto de teste para as RNA's sem caracterização prévia dos sinais de entrada.

Sinais Número	Sinais	Canais	Ponto Inicial
1	laporte\lap_3510	9	800
2	Wamboldt \wam_720	8	600
3	St_rock \sr_945	8	700
4	Vadnais2 \vad2_2955	31	800
5	Zografo \zog_1815	8	1000
6	Kurian \kur_15	6	1200
7	Kurian \kur_15	4	900
8	laporte \lap_15	4	1200
9	laporte \lap_75	28	600
10	Jokhoo \jok_585	27	800
11	St_rock2 \sr2_930	23	1000
12	St_rock2 \sr2_1080	30	1300
13	Vadnais1 \vad1_1260	27	800
14	Laporte \lap_3120	18	100
15	St_rock \sr_60	21	1100
16	St_rock \sr_135	29	200
17	Wamboldt \wam_30	29	700
18	St_rock \sr_15	31	100
19	Vadnais2 \vad2_2250	21	1100
20	St_rock2 \sr2_15'	21	1000
21	Vadnais1 \vad1_60	4	300
22	Vadnais1 \vad1_3510	13	500
23	Zografo \zog_225	16	100
24	Jokhoo \jok_60	20	1200
25	Kurian \kur_3060	22	1100
26	laporte \lap_2520	4	1400
27	laporte \lap_3405	11	600
28	Wamboldt \wam_510	1	1200
29	Wamboldt \wam_1140	29	800
30	Vadnais2 \vad2_15	29	800
31	Wamboldt \wam_15	1	600
32	Wamboldt \wam_15	30	300
33	Zografo \zog_15	29	700
34	St_rock \sr_540	2	300
35	St_rock \sr_2430	3	100
36	Vadnais1 \vad1_1920	32	100
37	Vadnais2 \vad2_1620	21	300
38	Zografo \zog_15	2	700
39	Vadnais2 \vad2_2415	15	200
40	St_rock2 \sr2_2250	14	1200
41	St_rock2 \sr2_3390	10	400
42	laporte \lap_1875	4	400
43	St_rock \sr_120	6	1
44	Kurian \kur_120	23	1
45	Zografo \zog_120	17	1200
46	Zografo \zog_3180	2	800
47	Jokhoo \jok_165	8	200
48	Kurian \kur_540	14	600
49	Vadnais1 \vad1_120	25	400
50	Vadnais2 \vad2_150	11	1040
51	Wamboldt \wam_180	5	740
52	St_rock2 \sr2_120	19	400
53	Jokhoo \jok_375'	12	1200
54	Wamboldt \wam_180	20	600
55	St_rock2 \sr2_120	4	100
56	Jokhoo \jok_375	9	100
57	St_rock \sr_15	8	550
58	Vadnais1 \vad1_120	9	700

A Tabela A.3 mostra a ordem de apresentação dos sinais utilizados nos conjuntos de treinamento e teste das RNA's com caracterização prévia dos sinais de entrada. Os sinais são divididos em grupos segundo o tipo de evento presente.

Tabela A.3- Ordem de apresentação dos sinais utilizados nos conjuntos de treinamento e teste das RNA's com caracterização prévia dos sinais de entrada.

Tipo do Sinal de Entrada da Rede	Número do Sinal no Arquivo de Teste	Número do Sinal no Arquivo de Treinamento
Espículas com 1º pico positivo	2, 4, 33, 35, 40	3, 12, 20, 21, 33
Espículas com 1º pico Negativo	14, 17, 20, 26, 31	4, 9, 25, 27, 39
Espículas com pico positivo	8, 30, 39, 42, 24	1,14,18,30,35
Espículas com pico positivo	10, 15, 21, 36, 5	11, 17, 26, 34, 41.
Arquivos normais	1, 11, 12, 16, 19, 23, 28, 32, 38, 41	2, 6, 15, 16, 24, 29, 32, 36, 37, 42
Arquivos com Piscadas	7, 9, 13, 25, 43	5, 10, 19, 28, 40
Ondas Alfa	3, 18, 29, 37, 45	7, 22, 31, 43, 45
Ruídos	6, 22, 27, 34, 44	8, 13, 23, 38, 44

A Tabela A.4 mostra um conjunto de treinamento para as RNA's com caracterização prévia dos sinais de entrada. Este conjunto possui 5 sinais com evento de primeiro pico positivo, 5 sinais com evento de primeiro pico negativo, 5 sinais com evento de pico negativo, 5 sinais com evento de pico positivo, 5 sinais com ondas alfa, 5 sinais com ruídos, 5 sinais com piscadas e 10 com EEG de fundo.

Tabela A.4- Conjunto de treinamento para as RNA's com caracterização prévia dos sinais de entrada.

Sinais Número	Sinais	Canais	Ponto Inicial
1	Wamboldt \wam_720	16	1000
2	Jokhoo\jok_375	9	100
3	Wamboldt \wam_450	15	200
4	Zografo\zog_1815	3	1150
5	Kurian\kur_30	9	800
6	laporte\lap_75	30	700
7	Jokhoo\jok_15	12	100
8	Jokhoo\jok_150	10	450
9	St_rock2\sr2_945	5	300
10	Kurian\kur_780	8	600
11	St_rock\sr_75	24	1320
12	St_rock2\sr2_3480	16	50
13	Jokhoo\jok_420	13	600
14	Wamboldt \wam_660	2	1300
15	laporte\lap_45	27	1000
16	Zografo\zog_315	12	100
17	St_rock\sr_4725	23	1180
18	St_rock\sr_1890	16	750
19	Kurian\kur_150	8	700
20	Wamboldt \wam_810	2	940
21	St_rock\sr_1950	12	1100
22	laporte\lap_15	12	100
23	Vadnais1 \vad1_15	10	50
24	laporte\lap_3030	19	600
25	Vadnais2\vad2_2955	4	900
26	St_rock2\sr2_3375	13	460
27	Wamboldt \wam_435	14	1250
28	St_rock\sr_15	8	550
29	Vadnais1 \vad1_1800	1	800
30	Wamboldt \wam_675	2	1320
31	laporte\lap_15	15	400
32	Zografo\zog_3150	14	800
33	Jokhoo\jok_180	11	650
34	St_rock2\sr2_75	15	500
35	St_rock2\sr2_2880	23	220
36	laporte\lap_1815	17	800
37	Vadnais1 \vad1_60	20	1200
38	Jokhoo\jok_390	6	800
39	St_rock2\sr2_900	23	80
40	Vadnais1 \vad1_120	9	700
41	Wamboldt \wam_765	29	860
42	Wamboldt \wam_180	20	600
43	laporte\lap_30	20	100
44	Wamboldt \wam_75	4	50
45	laporte\lap_30	15	100

A Tabela A.5 mostra um conjunto de teste para as RNA's com caracterização prévia dos sinais de entrada. Este conjunto possui 5 sinais com evento de primeiro pico positivo, 5 sinais com evento de primeiro pico negativo, 5 sinais com evento de pico negativo, 5 sinais com evento de pico positivo, 5 sinais com ondas alfa, 5 sinais com ruídos, 5 sinais com piscadas e 10 com EEG de fundo.

Tabela A.5- Conjunto de teste para as RNA's com caracterização prévia dos sinais de entrada.

Sinais Número	Sinais	Canais	Ponto Inicial
1	laporte\lap_3135	8	1000
2	Wamboldt\wam_975	2	1100
3	Vadnais2\vad2_15	2	1050
4	St_rock2\sr2_3330	24	1300
5	St_rock2\sr2_930	18	100
6	Wamboldt\wam_240	4	1100
7	Jokhoo\jok_2805	13	730
8	Vadnais1\vad1_1080	18	1300
9	St_rock2\sr2_3585	8	1380
10	St_rock\sr_60	11	1140
11	Vadnais1\vad1_3510	22	1100
12	St_rock2\sr2_15'	24	1100
13	Vadnais1\vad1_15	17	220
14	laporte\lap_3120	29	700
15	Vadnais2\vad2_2655	21	400
16	laporte\lap_1485	16	750
17	St_rock\sr_6105	22	640
18	Kurian\kur_15	12	200
19	Zografo\zog_120	14	460
20	Kurian\kur_540	5	740
21	St_rock\sr_1950	31	750
22	laporte\lap_510	2	300
23	Vadnais2\vad2_3495	22	600
24	St_rock\sr_2910	14	60
25	Jokhoo\jok_360	8	820
26	Wamboldt\wam_630	2	240
27	Kurian\kur_795	9	1050
28	St_rock\sr_2835	11	50
29	laporte\lap_15	24	700
30	St_rock\sr_945	7	1200
31	Wamboldt\wam_510	2	550
32	Kurian\kur_3390	24	600
33	Jokhoo\jok_585	3	700
34	Jokhoo\jok_210	10	300
35	Wamboldt\wam_780	29	110
36	St_rock2\sr2_3345	23	1040
37	Jokhoo\jok_15	20	100
38	Vadnais1\vad1_2580	20	1000
39	St_rock2\sr2_165	4	1020
40	St_rock2\sr2_1635	16	650
41	Zografo\zog_2385	9	60
42	Jokhoo\jok_165	11	1040
43	Vadnais1\vad1_15	8	600
44	Wamboldt\wam_150	5	50
45	Zografo\zog_15	24	1300

ANEXO B

GRÁFICOS OBTIDOS NO TREINAMENTO DAS RNA'S

B.1 RNA's com Entradas Sem Pré-Processamento

A Figura B.1.1 mostra os resultados das RNA's com entradas sem pré-processamento.

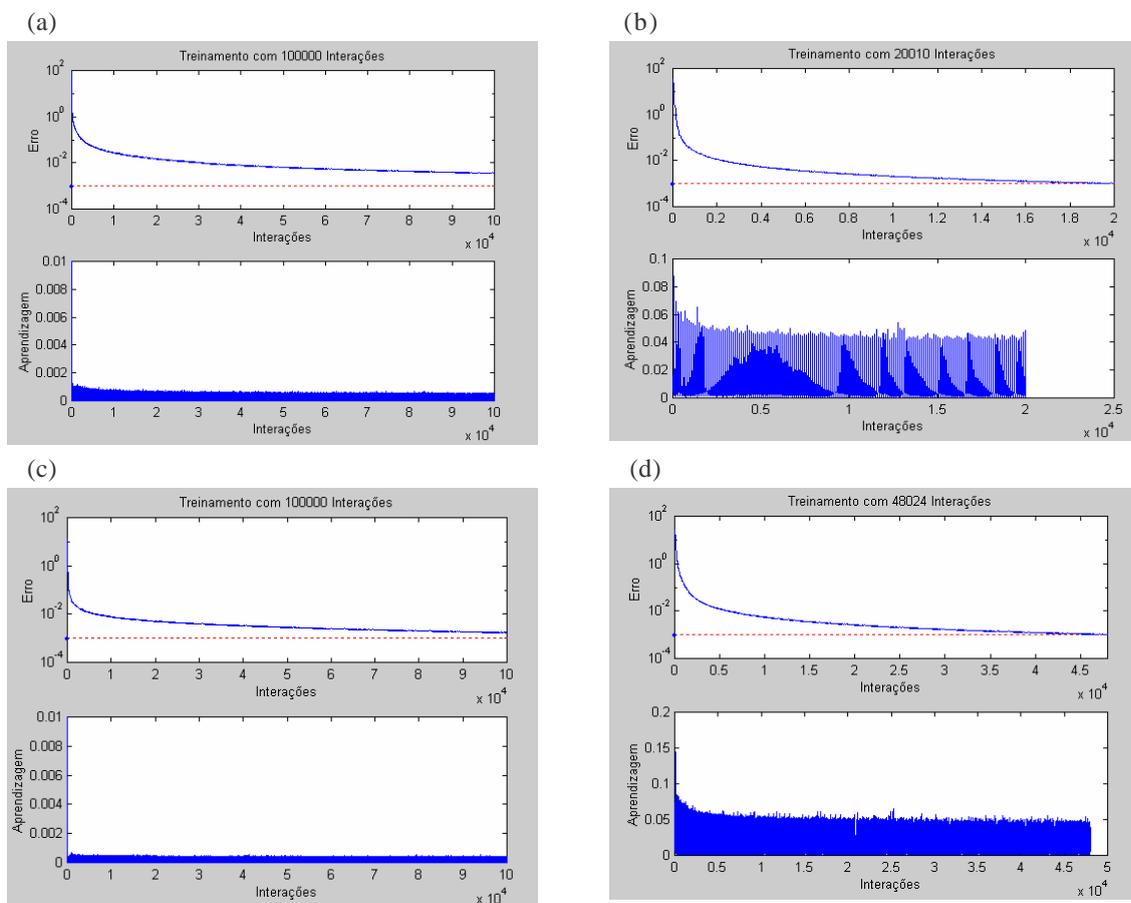


Figura B.1.1- (a), resultados do treinamento da RNA com 11 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada. (b), resultados do treinamento da RNA com 13 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada e entrada normalizada. (c), resultados do treinamento da RNA com 12 neurônios na camada oculta e com caracterização prévia dos sinais de entrada. (d), resultados do treinamento da RNA com 12 neurônios na camada oculta, com caracterização prévia dos sinais de entrada e entrada normalizada por amplitude máxima de um evento epileptogênico.

B.2 RNA's com Entradas Pré-Processadas pela FFT com Janelas

A Figura B.2.1 mostra os resultados das RNA's com entradas pré-processadas pela FFT com janelas.

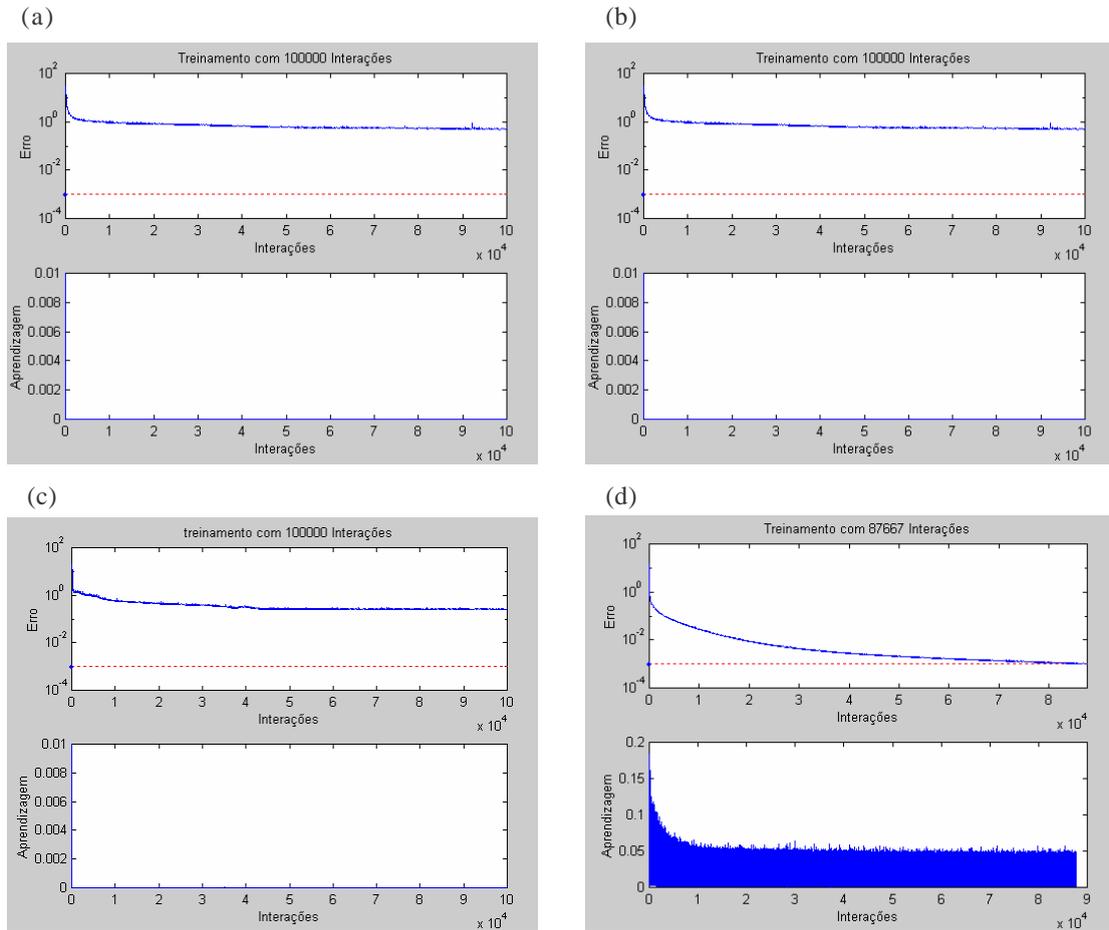


Figura B.2.1- (a), resultados do treinamento da RNA com 13 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada. (b) RNA com 13 neurônios na camada oculta, sem caracterização prévia dos sinais de entrada e entrada normalizada. (c), RNA com 12 neurônios na camada oculta e com caracterização prévia dos sinais de entrada. (d), RNA com 12 neurônios na camada oculta, com caracterização prévia dos sinais de entrada e entrada normalizada.

B.3 RNA's com Entradas Pré-Processadas Utilizando a Análise Tempo-Frequência

A Figura B.3.1 mostra os resultados do treinamento da RNA com 31 neurônios na camada oculta e sem caracterização prévia dos sinais de entradas.

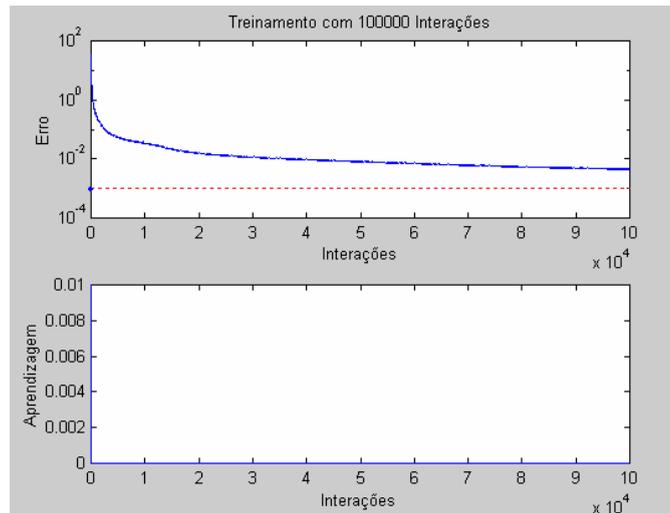


Figura B.3.1- Resultados do treinamento da RNA com 31 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada.

A Figura B.3.2 mostra os resultados do treinamento da RNA com 28 neurônios na camada oculta e com caracterização prévia dos sinais de entradas.

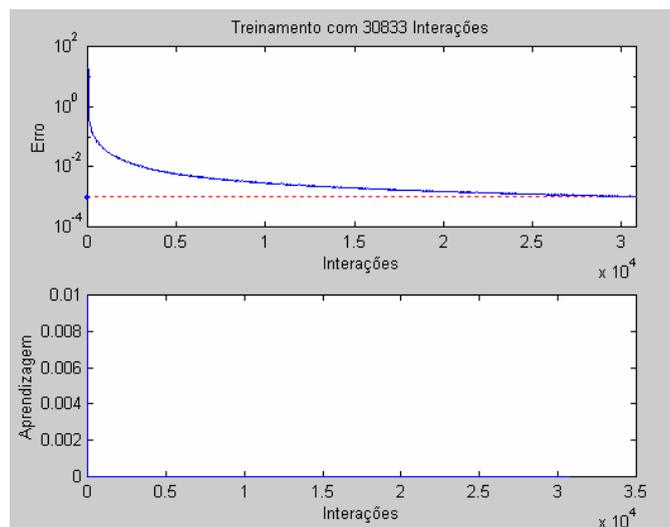


Figura B.3.2- Resultados do treinamento da RNA com 28 neurônios na camada oculta e com caracterização prévia dos sinais de entrada.

B.4 RNA's com Entradas Pré-Processadas Utilizando a Transformada *Wavelet*

As Figuras B.4.1 e B.4.2 mostram os resultados do treinamento das RNA's com entradas pré-processadas utilizando a Transformada *Wavelet*.

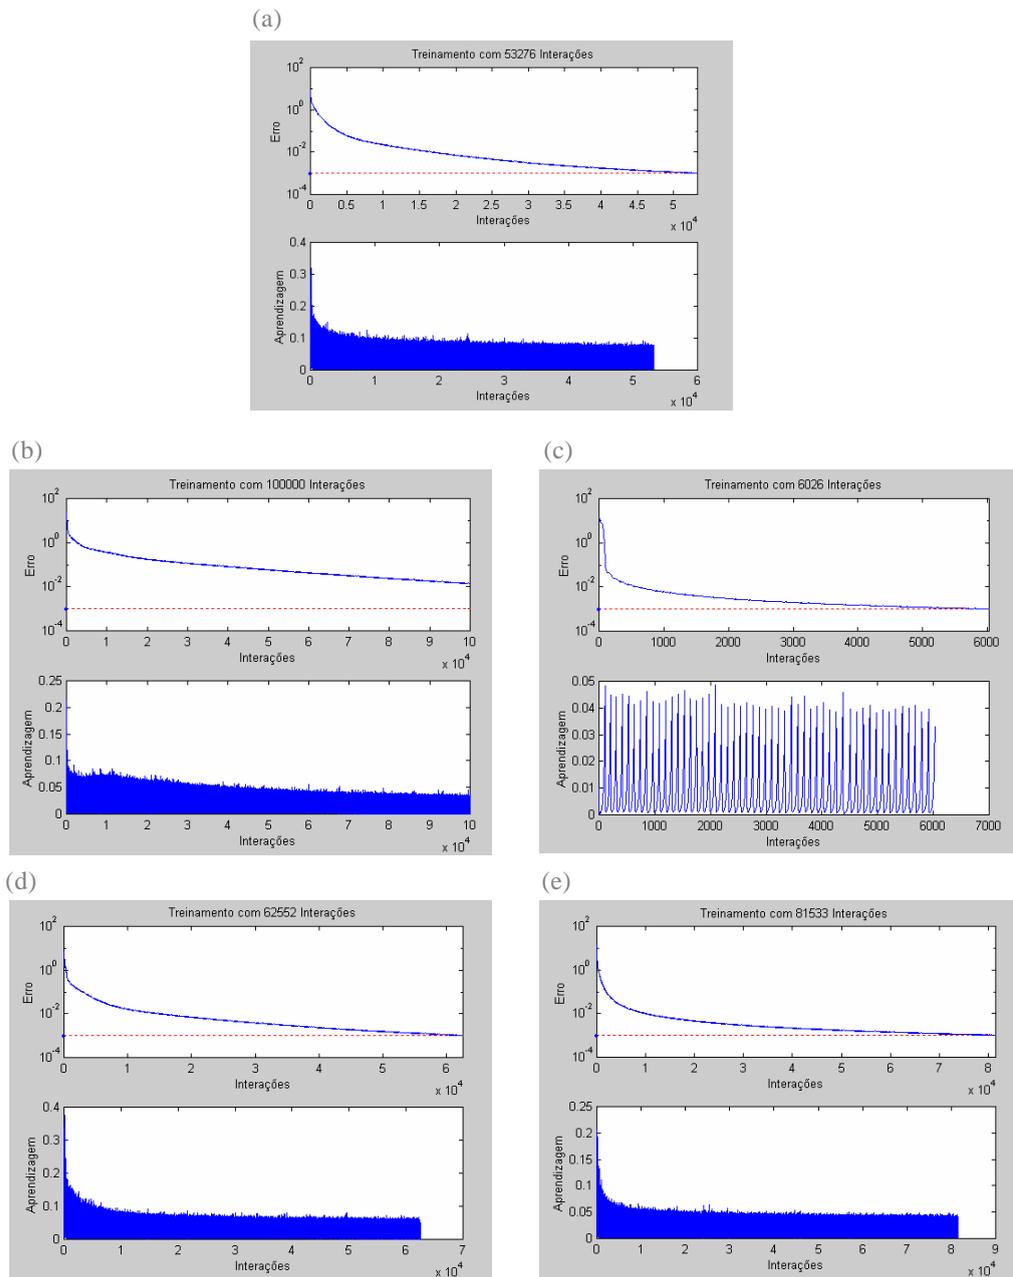


Figura B.4.1- (a), Resultados do treinamento da RNA 1 com 12 neurônios na camada oculta e com caracterização prévia dos sinais de entrada. (b), RNA 2. (c), RNA 3. (d), RNA 4. (e), RNA 5.

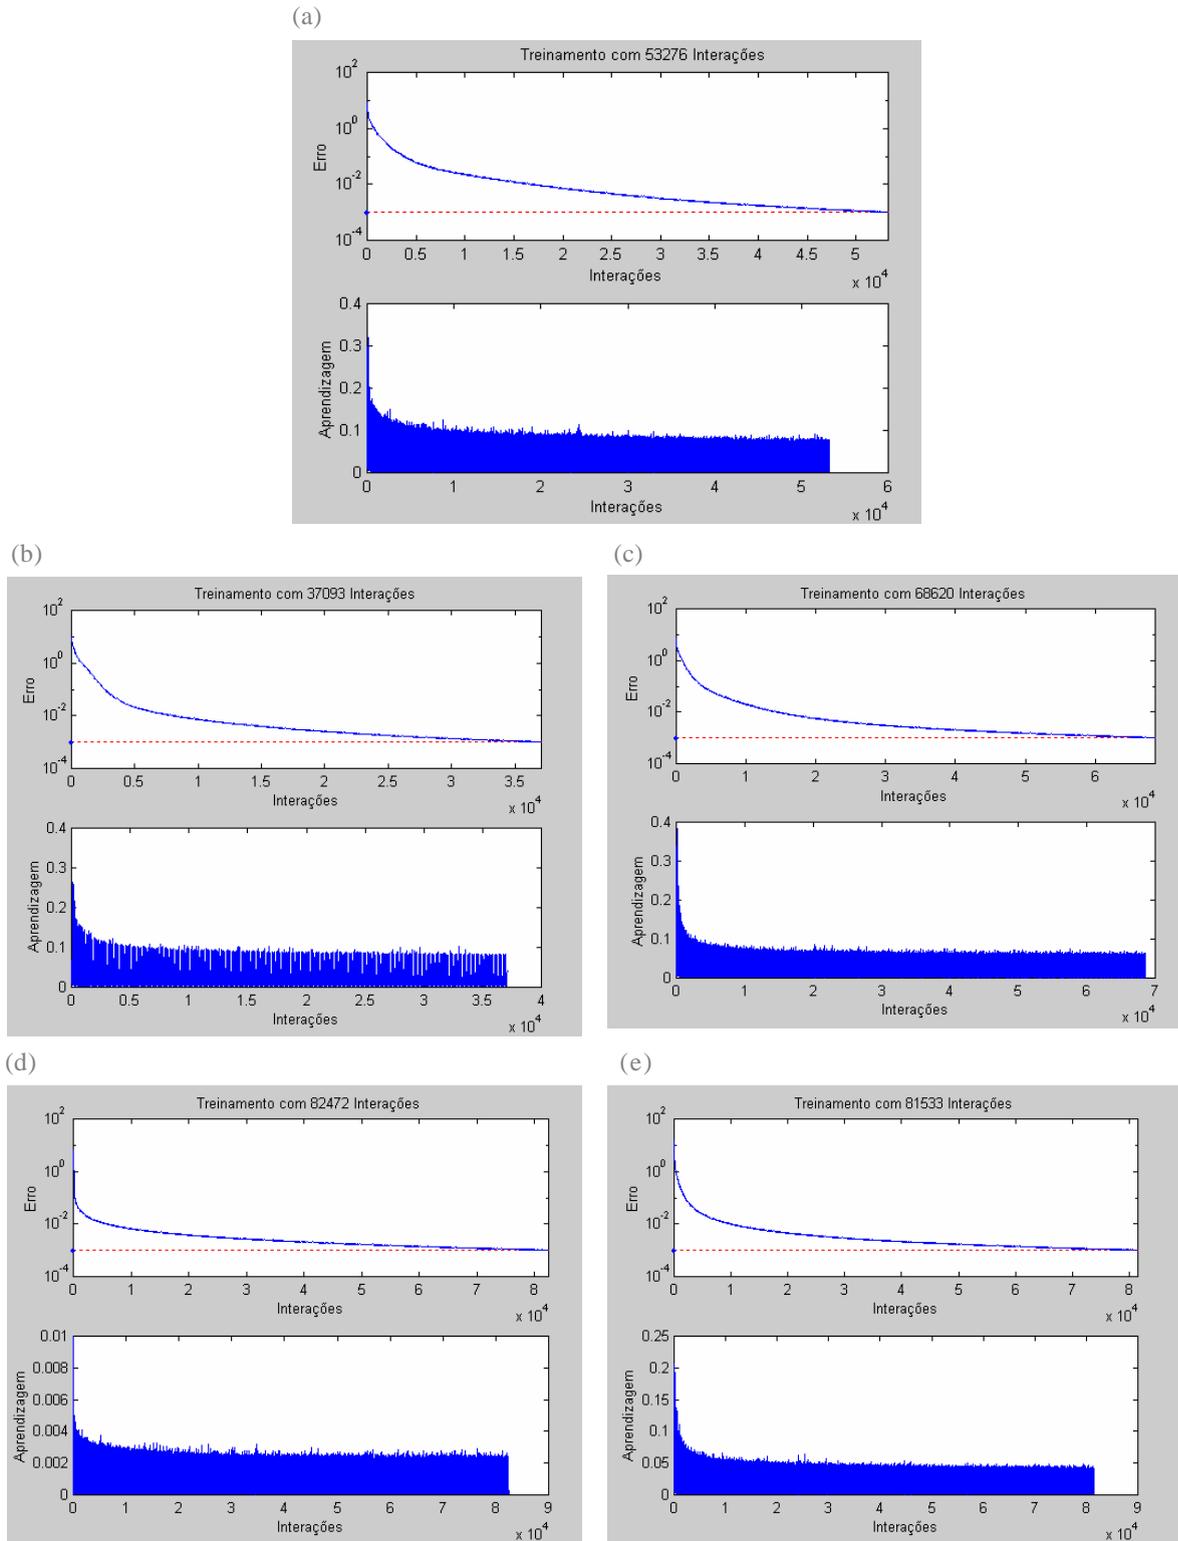


Figura B.4.2- (a), Resultados do treinamento da RNA 1 com 12 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada. (b), RNA 2. (c), RNA 3. (d), RNA 4. (e) RNA 5.

B.5 RNA's com Entradas Parametrizadas

A Figura B.5.1 mostra os resultados do treinamento das RNA's com entradas parametrizadas.

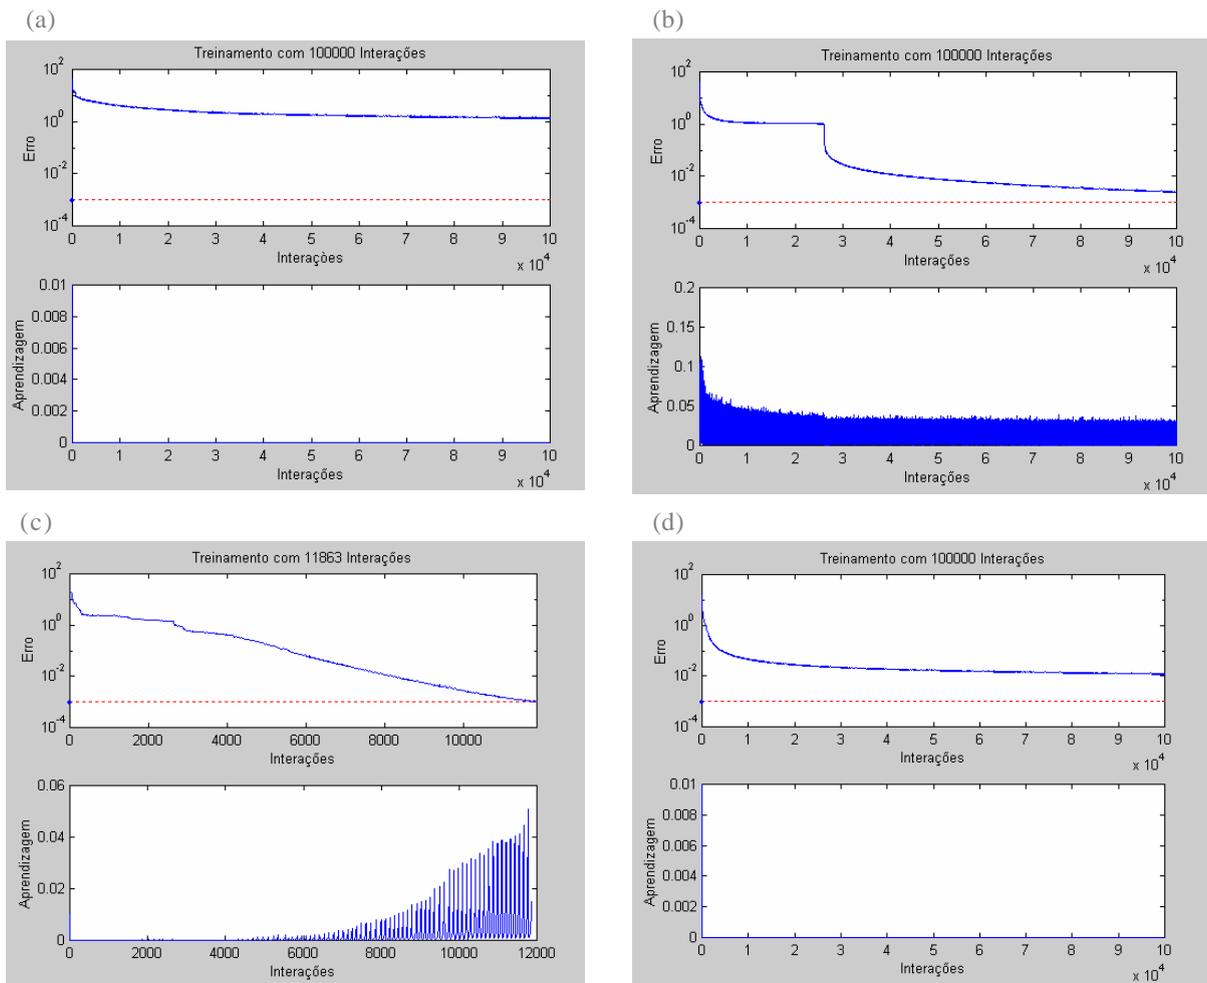


Figura B.5.1- (a), Resultados do treinamento da RNA com 8 neurônios na camada oculta e sem caracterização prévia dos sinais de entrada. (b), RNA com 8 neurônios na camada oculta, entrada normalizada e sem caracterização prévia dos sinais de entrada. (c), RNA com 9 neurônios na camada oculta e com caracterização prévia dos sinais de entrada. (d), RNA com 8 neurônios na camada oculta e com caracterização prévia dos sinais de entrada.

ANEXO C

FORMULAÇÕES MATEMÁTICAS

C.1 As Representações de Fourier

A série de Fourier discreta no tempo é a forma de Fourier utilizada em computadores digitais. Para sua representação, admite-se que as N amostras da função original $x(n)$ possuem N amostras calculadas pela Equação (C.1). E sua forma inversa é calculada pela Equação (C.2).

$$x(n) = \sum_{k=0}^{N-1} X(k)W_N^{kn} \quad n = 0, 1, 2, \dots, N-1 \quad (C.1)$$

$$X(k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n)W_N^{-kn} \quad k = 0, 1, 2, \dots, N-1 \quad (C.2)$$

onde: $W_N = e^{j \cdot \frac{2 \cdot \pi}{N}}$ (C.3)

A série de Fourier discreta no tempo possui sua aplicação computacional largamente utilizada devido à disponibilidade de algoritmos eficientes como o algoritmo da transformada rápida de Fourier (*Fast Fourier Transform (FFT)*). A análise do desenvolvimento do algoritmo da transformada rápida de Fourier deve partir das relações matemáticas fornecidas pelas Equações (C.1) e (C.2). O índice n da equação vai de $n=0$ até $n=N-1$ correspondendo aos valores de $x_0, x_1, x_2, x_3, \dots, x_{N-1}$. As seqüências pares são numeradas $x_0, x_2, x_4, \dots, x_{N-2}$, e as seqüências ímpares são numeradas x_1, x_3, \dots, x_{N-1} . Sendo que ambas as seqüências contêm $N/2$ pontos. Assim a seqüência par pode ser designada por x_{2n} com $n=0$ até $n=(N/2)-1$, e a seqüência ímpar é designada por x_{2n+1} .

Em $0 \leq n \leq N-1$, ambas as seqüências contêm $N/2$ pontos. Assim, a seqüência par pode ser designada por x_{2n} com $n=0$ até $n=(N/2)-1$, e a seqüência ímpar designada por x_{2n+1} .

$$X(k) = \sum_{n=0}^{(N/2)-1} x_{2n} W_N^{2nk} + W_N^k \sum_{n=0}^{(N/2)-1} x_{2n+1} W_N^{2nk} \quad (C.4)$$

A equação pode ser dividida em seqüências pares e ímpares, considerando que:

$$W_N^{2nk} = W_{N/2}^{nk}$$

$$X_1(k) = X_{11}(k) + w_N^k \cdot X_{12}(k) \tag{C.5}$$

Comparando-se as equações, observa-se que $X_{11}(k)$ é realmente a transformada de Fourier de uma seqüência par e $X_{12}(k)$ a transformada de Fourier de uma seqüência ímpar. Esse fator ocorre em ambas as equações sendo necessário calcular somente em um.

A Tabela C.1 mostra uma síntese de uma seqüência de 8 pontos da DFT que vão servir de base para o desenvolvimento do algoritmo FFT. A seqüência $A_0\{x_0, x_1, x_2, x_3, \dots, x_7\}$ calcula X_1 , que depende de X_{11} e X_{12} , os quais são obtidos a partir das seqüências pares e ímpares.

Tabela C.1- Seqüência de cálculos para a FFT de 8 termos.

$A_0\{x_0, x_1, x_2, x_3, x_4, x_5, x_6, x_7\}$			
$X_1(k) = X_{11}(k) + w_N^k X_{12}(k)$			
$A_1\{x_0, x_2, x_4, x_6\}$		$A_2\{x_1, x_3, x_5, x_7\}$	
$X_{11}(k) = X_{21}(k) + w_{N/2}^k X_{22}(k)$		$X_{12}(k) = X_{23}(k) + w_{N/2}^k X_{24}(k)$	
$A_3\{x_0, x_4\}$	$A_4\{x_2, x_6\}$	$A_5\{x_1, x_5\}$	$A_6\{x_3, x_7\}$
$X_{21}(k) = x_0 + w_{N/4}^k x_4$	$X_{22}(k) = x_2 + w_{N/4}^k x_6$	$X_{23}(k) = x_1 + w_{N/4}^k x_5$	$X_{24}(k) = x_3 + w_{N/4}^k x_7$

Formando as seqüências pares e ímpares: $A_1\{x_0, x_2, x_4, x_6\}$ e $A_2\{x_1, x_3, x_5, x_7\}$. Essas seqüências calculam X_{11} e X_{12} , que dependem de X_{21} , X_{22} , X_{23} e X_{24} . Para calcular esses novos termos as duas seqüências são divididas em 4 seqüências cada uma com 2 pontos: $A_3\{x_0, x_4\}$, $A_4\{x_2, x_6\}$, $A_5\{x_1, x_5\}$, $A_6\{x_3, x_7\}$.

Encontrando os valores de X_{21} , X_{22} , X_{23} e X_{24} pode-se obter o restante das amostras.

$$X_{21}(k) = x_0 + w_{N/4}^k x_4$$

$$X_{21}(0) = x_0 + x_4$$

$$\begin{aligned}
 X_{21}(1) &= x_0 + w_{N/4} x_4 \\
 \dots\dots\dots &= x_0 + w_2 x_4 = x_0 + e^{-jp/2} x_4 \\
 \dots\dots\dots &= x_0 - x_4 \\
 X_{22}(0) &= x_2 + x_6 \\
 X_{23}(0) &= x_1 + x_5 \\
 X_{24}(0) &= x_3 + x_7 \\
 X_{22}(1) &= x_2 - x_6 \\
 X_{23}(1) &= x_1 - x_5 \\
 X_{24}(1) &= x_3 + x_7
 \end{aligned}$$

A seqüência do algoritmo é obtida pelo desenvolvimento do diagrama denominado “butterfly”. No diagrama, as componentes espectrais são separadas e interligadas por um fator de peso (w), correspondendo à parte complexa da equação. Para a formação da butterfly consideram-se as equações resultantes do processamento matemático, $(X_{11}(0), X_{11}(2), X_{11}(1), X_{11}(3))$, representadas explorando a simetria sobre a diferença dos sinais e tornando as equações em pares. Considerando-se $X_{11}(0)$ e $X_{11}(2)$ como saídas fornecidas pelas entradas $X_{21}(0), X_{22}(0)$, na Figura C.1.1.

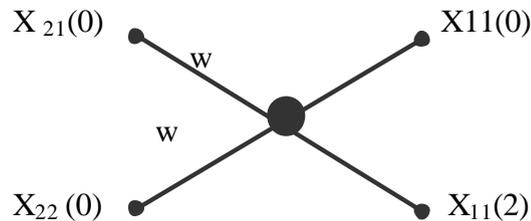


Figura C.1.1- Uma célula butterfly e sua relação matemática.

Juntado as equações de $X_{11}(1), X_{11}(3)$ resulta no arranjo de butterflies das Figuras C.1.1 e C.1.2. Os termos: $X_{11}(0), X_{11}(2), X_{11}(1), X_{11}(3)$, da seqüência: $\{1, 0, 0, 1\}$, definem: $x_0=1, x_1=0, x_2=0, x_3=1$.

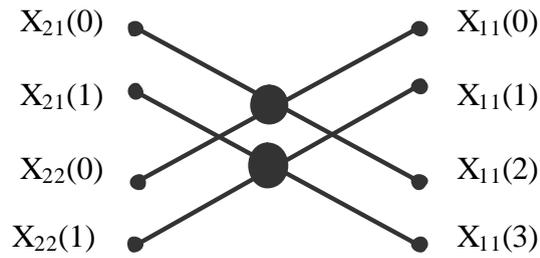


Figura C.1.2- Arranjo de duas *butterflies* e suas relações matemáticas.

C.2 As Representações das Janelas Clássicas

Considera-se que uma janela possui a função de transferência definida pela Equação (C.6).

$$h_d[n] = \frac{1}{2p} \int_{-p}^p H_d(e^{jw}) dw \quad -\infty < n < \infty \quad (C.6)$$

Uma janela, $h[n]$ possui uma resposta ideal com um intervalo finito quando:

$$h[n] = h_i[n]$$

onde:

$$-N \leq n \leq N$$

Utilizando-se um filtro causal $h[n-N]$, tem-se a mesma magnitude, mas a fase linear desloca de wN .

Os coeficientes de Fourier entre $-N$ a N , ficam:

$$H(e^{jw}) = \begin{cases} 1 & |w| \leq w_c \\ 0 & w_c < w \leq p \end{cases}$$

$$h[n] = \frac{\sin w_c n}{pn} \quad -\infty < n < \infty$$

$$H[n] = \begin{cases} \frac{\text{sen}(w_c(n-N))}{p(n-N)} & 0 \leq n \leq 2N \\ 0 & \end{cases} \quad (C.7)$$

Em geral as janelas clássicas podem ser definidas no domínio do tempo, $w(n)$, e no domínio da frequência, $W(k)$, conforme as equações abaixo.

1- Janela Retangular:

A janela Retangular possui alterações bruscas no domínio do tempo que originam o fenômeno de *Gibbs*. Os fenômenos de *Gibbs* são oscilações no domínio da frequência. A janela retangular é definida pelas equações abaixo.

$$w(n) = \begin{cases} 1, \dots \text{para } : 0 \leq n \leq N \\ 0, \dots \text{contrário} \end{cases} \quad (\text{C.8})$$

onde:

N é o comprimento da janela.

$$n = -\frac{N}{2}, \dots, -1, 0, 1, \dots, \frac{N}{2}$$

$$W(k) = \exp\left(-j\frac{N-1}{2}k\right) \frac{\text{sen}\left(\frac{N}{2}k\right)}{\text{sen}\left(\frac{1}{2}k\right)} \quad (\text{C.9})$$

2- Janela Triangular:

A janela triangular é a convolução de duas janelas retangulares. A janela de Bartlett sempre retorna a janela com dois zeros no final da seqüência, assim a janela de Bartlett $(n+2)$ é igual a janela triangular (n) .

$$w(n) = \begin{cases} \frac{2n}{N} & 0 \leq n \leq \frac{N}{2} \\ 2\left(1 - \frac{n}{N}\right) & \frac{N}{2} \leq n \leq N-1 \end{cases} \quad (\text{C.10})$$

$$W(k) = \frac{2}{N} \exp\left(-j\left(\frac{N}{2}-1\right)k\right) \frac{\text{sen}^2\left(\frac{N}{4}k\right)}{\text{sen}^2\left(\frac{1}{2}k\right)} \quad (\text{C.11})$$

3- Janela de Hanning:

$$w(n) = 0,5 + 0,5 \cos\left(\frac{2\mathbf{p}}{N}n\right) \quad -\frac{N}{2} \leq n \leq \frac{N}{2} \quad (\text{C.12})$$

$$W(k) = 0,5D(k) + 0,25\left(D\left(k - \frac{2\mathbf{p}}{N}\right) + D\left(k + \frac{2\mathbf{p}}{N}\right)\right) \quad (\text{C.13})$$

$$D(k) = \exp\left(j\frac{k}{2}\right) \frac{\text{sen}\left(\frac{N-k}{2}\right)}{\text{sen}\left(\frac{1}{2}k\right)} \quad (\text{C.14})$$

4- Janela de Hamming:

$$w(n) = 0,54 + 0,46 \cos\left(\frac{2\mathbf{p}}{N}n\right) \quad -\frac{N}{2} \leq n \leq \frac{N}{2} \quad (\text{C.15})$$

Para a transformada discreta usa:

$$w(n) = 0,54 - 0,46 \cos\left(\frac{2\mathbf{p}}{N}n\right) \quad 0 \leq n \leq N-1 \quad (\text{C.16})$$

$$W(k) = 0,54D(k) + 0,23\left(D\left(k - \frac{2\mathbf{p}}{N}\right) + D\left(k + \frac{2\mathbf{p}}{N}\right)\right) \quad (\text{C.17})$$

5- Janela de Blackman:

$$w(n) = 0,35875 - 0,48829 \cos\left(\frac{2\mathbf{p}}{N}n\right) - 0,14128 \cos\left(\frac{2\mathbf{p}}{N}2n\right) - 0,01168 \cos\left(\frac{2\mathbf{p}}{N}3n\right) \quad (\text{C.18})$$

As janelas de Hanning, Hamming e Blackman são todas um caso especial da janela cosseno. Esta janela é a combinação da seqüência de senóides com frequências de $0,2\pi/(N-1)$ e $4\pi/(N-1)$, onde N é o comprimento da janela. O termo geral dessas janelas é:

$$\varphi = (0:n-1)'*2*\pi/(n-1);$$

$$w = A-B*\cos(\varphi) + C*\cos(2*\varphi);$$

onde A , B , C são constantes a definir.

O conceito atrás desta janela é que pelo somatório dos termos individuais para formar a janela, os picos de baixa frequência no domínio da frequência combinam de maneira que decresce a amplitude do lóbulo lateral. Este tem o efeito lateral de incrementar a amplitude do lóbulo principal. As constantes A , B e C para as janelas de Hanning, Hamming e Blackman.

A janela Hanning: A=0.5 e B=0.5 e C=0.

A janela Hamming: A=0.54 e B=0.46 e C=0.

A janela Blackman: A=0.42, B=0.5 e C=0,08.

6- Janela de Chebyshev:

Considera-se que uma janela possui uma resposta ideal com um intervalo finito.

$$w(n) = \frac{1}{2N+1} \left[\frac{1}{\mathbf{a}} + 2 \sum_{k=1}^N T_k \left(\mathbf{g} \cos \frac{k\mathbf{p}}{2N+1} \right) \cos \frac{2nk\mathbf{p}}{2N+1} \right] \tag{C.19}$$

onde:

$$\mathbf{a} = \frac{\textit{amplitude _ l\u00f3bulos _ laterais}}{\textit{amplitude _ l\u00f3bulo _ principal}}$$

$$\mathbf{g} = \cosh \left(\frac{1}{2N} \cosh^{-1} \frac{1}{\mathbf{a}} \right)$$

$$T_1(x) = \begin{cases} \cos(1 \cos^{-1} x) & |x| \leq 1 \\ \cosh(1 \cosh^{-1} x) & |x| > 1 \end{cases}$$

7- Janela de Kaiser:

O equacionamento da janela de Kaiser é centralizado na função de Bessel modificada de ordem zero, I_0 , conforme a Equação (C.20).

$$W(n) = \frac{I_0 \left[\mathbf{b} \sqrt{1 - (1 - (n - N)^2)} \right]}{I_0(\mathbf{b})} \tag{C.20}$$

O parâmetro β da janela de Kaiser depende do comprimento da janela e pode ser escolhido para produzir vários comprimentos de transições e aproxima-la da faixa de interrupção ótima. Essa janela pode possuir diferentes comprimentos de transição, para um mesmo comprimento da janela. Para encontrar a altura dos lóbulos laterais, em $-\alpha$ dB, através do parâmetro β , pode-se calcular utilizando-se as expressões da Equação (C.21).

$$b = \begin{cases} 0,1102 (a - 8,7) & a \geq 50 \\ 0,5842 (a - 21)^{0,4} + 0,07886 (a - 21) & 50 \geq a \geq 21 \\ 0 & a < 21 \end{cases} \quad (C.21)$$

A faixa de transição, $\Delta\omega$, é determinada pelo comprimento da janela, conforme a Equação (C.22).

$$N = \frac{a - 8}{2,285\Delta\omega} + 1 \quad (C.22)$$

Em termos da frequência o comprimento da janela fica conforme a Equação C.23.

$$N = \begin{cases} \frac{a - 7,95}{14,36} \left(\frac{f}{\Delta f} \right) + 1 \dots\dots\dots a > 21 \\ \frac{0,9222}{\Delta f} f \dots\dots\dots a \geq 21 \end{cases}$$

Em aplicações com o intuito de comparar os resultados obtidos por uma janela de Kaiser e uma janela de Chebyshev é necessário que os parâmetros escolhidos correspondam, isto é, o valor de β escolhido para a janela de Kaiser deve corresponder ao valor de α para a janela de Chebyshev. Observando que o valor α representa o nível do primeiro lóbulo lateral e β pode ser obtido utilizando-se a Equação (C.22).

C.3 Densidade Espectral de Potência (*Power Spectral Density (PSD)*)

A densidade espectral de potência de um processo $x(n)$ é matematicamente relacionada como a correlação da seqüência utilizando-se a transformada discreta de Fourier.

Dada uma seqüência $x(t)$, sua transformada discreta de Fourier é definida pela Equação (C.23).

$$X(\omega) = \Delta t \sum_{m=-M}^M R_x(m) e^{-j\omega m \Delta t} \quad (C.23)$$

onde:

Δt - intervalo de amostragem;

$R_x(m)$ - estimativa discreta da função correlação.

Os coeficientes de correlação são estimados da seqüência de dados amostrados x_k , onde $k = 0, 1, 2, \dots, N-1$.

$$R_x(m) = \frac{1}{N} \sum_{n=0}^{N-m-1} x_{n+m} x_n \quad (\text{C.24})$$

onde:

$$m = 0, 1, 2, \dots, N-1;$$

$$R_x(-m) = R_x(m)$$

Em síntese a densidade espectral de potência pode ser definida pela Equação (C.25).

$$P_{xx}(w) = \sum_{m=-\infty}^{\infty} R_{xx}(m) e^{-jwm} \quad (\text{C.25})$$

C.4 Princípio da Incerteza

O termo $WT \geq 1/4p$, denominado de desigualdade de Heisenberg definirá a resoluções no tempo e na freqüência utilizando-se os valores de W e T . Portanto, deve-se optar por um valor de largura no tempo, T , segundo a solução que se deseja priorizar, já que não é possível obter ambas as resoluções em níveis satisfatórios, simultaneamente. Uma vez fixado o valor de T obtém-se o valor de W através do princípio da incerteza.

Em poucas palavras, o princípio de Heisenberg pode ser definido conforme a Equação (C.26). Nesta, a variância do valor absoluto do sinal no tempo e a variância do valor absoluto do sinal no domínio da freqüência indicam a desigualdade.

$$\Delta f \Delta t \geq \frac{1}{4p} \quad (\text{C.26})$$

A função que é geralmente empregada como janela $g(t)$ foi proposta por Gabor e é chamada de Gaussiana, definida pela Equação (C.27).

$$g(t) = \frac{1}{a} e^{-\frac{t^2}{a^2}} \quad (\text{C.27})$$

$$G(w) = \frac{1}{\sqrt{p}} e^{-\frac{a^2 w^2}{4p}} \quad (\text{C.28})$$

C.5 Transformada de Fourier de Curto Termo

O termo janela agregado à transformada foi introduzido por Gabor em 1946, e em seqüência de destaque estão os trabalhos de Doubechies em 1992 e Kaiser em 1994. Para satisfazer a condição de estacionaridade, foi proposta uma forma de dividir os longos termos de um sinal em blocos de curta duração introduzindo a Transformada de Fourier de Curto Termo (*Short-Time Fourier Transforms (STFT)*). A STFT é basicamente o processo de ajanelamento do sinal de entrada, associando a transformada com uma janela de largura fixa. Desta forma, o sinal é dividido em um número de segmentos e a Transformada de Fourier é aplicada em cada segmento localizado do sinal [71].

A STFT é uma extensão da transformada de Fourier. Considere que $x(t)$ denota um sinal que é suposto ser estacionário quando é visualizado através de uma janela $w(t)$ temporal de extensão limitada; em geral, $w(t)$ tem valor complexo. A STFT de $x(t)$, denotada por $X(\mathbf{t}, w)$, é definida como a transformada de Fourier do sinal ajanelado $x(t)w^*(t-\mathbf{t})$, em que \mathbf{t} é a posição central da janela e o asterisco denota conjugado complexo. Para um determinado $x(t)$ o resultado obtido calculando $X(\mathbf{t}, w)$ depende da escolha da janela [79].

Considera-se inicialmente que uma função x é a transformada em um sinal no domínio do tempo e no domínio da frequência $X(t, w)$. Somente os valores da função para $t \leq t_0$ podem ser calculados. O tempo futuro não entra nos cálculos. E esse processo possui memória finita para $T > 0$. Assim, o cálculo de $X(t, w)$ depende apenas de t no intervalo $[t-T, t]$. A função moduladora utilizada para calcular a transformada da densidade de frequência $X(t, w)$ em um determinado tempo t deve ter seus valores concentrados em uma vizinhança de t . Para obter essa função moduladora satisfazendo essas condições, usa-se a função auxiliar $w(t)$ para localizar a função moduladora $e^{-j2\pi w t}$ usada na transformada de Fourier em determinada vizinhança de tempo t [79].

$$w(t) = w(t - \mathbf{t}) e^{-j2\pi w \mathbf{t}} \quad (\text{C.29})$$

A STFT representada por $X(\mathbf{t}, w)$ é linear em relação ao sinal $x(t)$ e é definida pela Equação (C.30).

$$X(\mathbf{t}, w) = \int_{-\infty}^{\infty} x(t)w^*(t-\mathbf{t})e^{-j2\pi w t} dt \quad (\text{C.30})$$

A Equação (C.31) define $x(t)$ como o sinal discreto no tempo a ser transformado e $w(t, \mathbf{t})$ como a janela de tempo atrasada de \mathbf{t} no tempo. Considerando, também, $w^*(t)$ o complexo conjugado da janela $w(t)$ e \mathbf{w} a frequência angular igual a $2\mathbf{p}f$. A integral representa o produto interno (escalar) do sinal $x(t)$ com uma família de funções básicas de dois parâmetros, $w(t-\mathbf{t})e^{j\mathbf{w}t}$ para \mathbf{t} e \mathbf{w} variáveis. E, em geral estas funções básicas não constituem um conjunto ortogonal.

Cada valor de τ correspondente à transformada de Fourier de um segmento do sinal $x(t)$, centrado em $t = \mathbf{t}$ é uma operação linear.

Sua forma inversa original pode ser obtida usando-se a expressão:

$$x(t) = \frac{1}{\|w\|^2} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} X(t, w) w^*(t - \mathbf{t}) e^{j\mathbf{w}t} dt dw \quad (\text{C.31})$$

ou

$$x(t) = \frac{1}{2\mathbf{p}} \int \int X(t, w) w(t - \mathbf{t}) e^{j\mathbf{w}t} dt dw \quad (\text{C.32})$$

A transformada com janela foi desenvolvida buscando-se obter boas propriedades de localização no domínio do tempo-frequência. Assim, se a janela é bem localizada no tempo, e se ela é pequena fora de um pequeno intervalo de tempo, então sua transformada é também bem localizada. Se a janela possui boas propriedades de localização no domínio da frequência, e se ela é pequena fora do intervalo de frequência w , então sua transformada é também bem localizada na frequência. Esta transformada fornece uma análise da função f no domínio tempo-frequência, no sentido em que se tem informações localizadas tanto no domínio do tempo quanto no domínio da frequência. Detecta-se as frequências em f e determina-se a sua localização no domínio espacial da função.

A STFT de um sinal é multiplicada pela janela móvel para tornar-se uma seqüência de segmentos. Multiplicando-se o sinal pela janela localizada no sinal no domínio do tempo, mas resulta na convolução da transformada de Fourier do sinal com a transformada de Fourier da janela, isto é, embaça o sinal no domínio da frequência. Em uma janela pequena a localização do sinal é boa e a localização do espectro é ruim. A largura Dt da janela no domínio do tempo e o comprimento de faixa Dw da janela no domínio da frequência são definidos respectivamente pelas Equações (C.33) e (C.34), onde o denominador é a energia da janela.

$$\Delta t^2 = \frac{\int t^2 |w(t)|^2 dt}{\int |w(t)|^2 dt} \quad (\text{C.33})$$

$$\Delta w^2 = \frac{\int w^2 |W(wt)|^2 dw}{\int |W(w)|^2 dw} \quad (\text{C.34})$$

A relação entre o comprimento da janela e a largura de faixa é um dos pontos em destaque na análise da STFT. A habilidade da STFT em discriminar as frequências de duas senóides puras, por exemplo, está relacionada aos conceitos de resolução. Os menores valores de Dw e Dt para os quais os dois sinais possam ser distinguidos são definidos como resolução de frequência e resolução de tempo, respectivamente. Uma vez que a janela tenha sido escolhida pela STFT, as resoluções no tempo e na frequência são calculadas pela Equação (C.35) e são fixadas sobre o plano tempo e frequência.

$$\Delta w \Delta t \geq \frac{1}{2} \quad (\text{C.35})$$

O comprimento de faixa e de tempo Dt e Dw podem obedecer ao princípio da incerteza. Pode-se negociar a resolução no domínio do tempo pela resolução no domínio da frequência ou vice-versa. Nestes termos, a melhor opção é considerar a Equação (C.36) como uma igualdade, sendo esta condição satisfeita utilizando-se uma janela gaussiana. Por esta razão Gabor propôs a função gaussiana como uma função janela. A transformada de Fourier da janela Gaussiana é ainda uma gaussiana, que possui um espalhamento mínimo (uma mínima extensão), isto é:

$$w(t) = \frac{1}{x} \exp\left(-\frac{pt^2}{x^2}\right) \quad (\text{C.36})$$

$$W(w) = \frac{1}{\sqrt{p}} \exp\left(-\frac{x^2 w^2}{4p}\right) \quad (\text{C.37})$$

Aplicando-se as Equações (C.31) e (C.34) resulta nos comprimentos Dt e Dw :

$$\Delta t^2 = \frac{x^2}{4p}$$

$$\Delta w^2 = \frac{p}{x^2}$$

Assim, a janela gaussiana possui o mínimo produto do comprimento da faixa e do tempo determinado pelo princípio da incerteza, isto é:

$$\Delta w \Delta t = \frac{1}{2} \quad (\text{C.38})$$

A análise da STFT depende criticamente da escolha da janela. Em aplicações que requerem prioridade na informação a respeito do tempo de evolução das propriedades do sinal, é também prioritária a escolha da janela. Uma vez escolhida a janela, o comprimento da janela ao longo dos eixos de frequência e de tempo é fixado no plano tempo-frequência, mostrado na Figura (C.1.3) E a capacidade de resolução da STFT é fixa ao longo deste plano. Este plano é dividido em retângulos da mesma forma e tamanho.

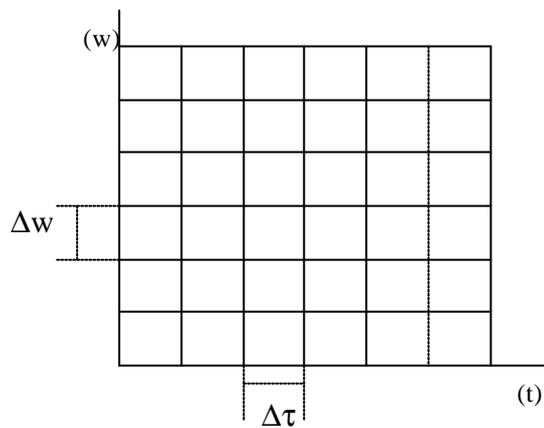


Figura C.1.3- Reticulado do plano tempo e frequência, mostrando uma repartição uniforme para o tempo (t) e a frequência (w).

O uso de janelas para o cálculo da transformada de Fourier permite que se tenha a noção da evolução do espectro de frequência do sinal ao longo do tempo, porém apresenta deficiência em fornecer uma boa resolução simultânea em tempo e em frequência. Fazendo um ajuste adequado do tamanho da janela, pode-se obter resultados satisfatórios na análise do sinal. Para um sinal simples os resultados são bons. Porém, existem sinais cuja decomposição por essa transformada é inadequada. Se um sinal possui frequências de valores muito variados, não é possível obter uma janela de largura adequada que tenha boas propriedades de localização tempo-frequência de todos os valores de frequência envolvidos.

Quando a translação dos fatores da função de Gabor ao longo do eixo de tempo e dos eixos da frequência t e w' toma valores discretos, tais como: $t = n t_0$ e $w' = m w_0$, com

m e n pertencentes aos números complexos, as funções discretas de Gabor podem ser escritas conforme a Equação (C.39) e sua transformada pela Equação (C.40).

$$w_{m,n}(t) = w(t - n\mathbf{t}_0)e^{-jmw_0t} \quad (\text{C.39})$$

$$W_{m,n}(w) = W(w - mw_0)e^{-j(w - mw_0)n\mathbf{t}_0} \quad (\text{C.40})$$

A transformada discreta de Gabor é definida pela Equação (C.41).

$$x(m,n) = \int_{-\infty}^{\infty} x(t)w^*(t - n\mathbf{t}_0)e^{-jmw_0t} dt \quad (\text{C.41})$$

O sinal $x(t)$ pode ser recuperado pelos coeficientes de $x(m,n)$, com a condição de que w_0 e \mathbf{t}_0 sejam adequadamente escolhidos. A escolha original de Gabor foi $w_0\mathbf{t}_0 = 2\mathbf{p}$.

A função janela é normalizada e centrada na origem do espaço tempo e frequência, isto é: $\int t |w(t)|^2 dt = 0$, $\int w |W(w)|^2 dw = 0$.

A localização das funções de Gabor no espaço tempo e frequência é determinada por:

$$\int t |w_{m,n}(t)|^2 dt = \int t |w(t - n\mathbf{t}_0)|^2 dt = n\mathbf{t}_0$$

e

$$\int w |W_{m,n}(w)|^2 dw = \int w |W(w - mw_0)|^2 dw = mw_0$$

O conjunto de funções discretas de Gabor pode ser representado pela grade regular com intervalos iguais w_0 e \mathbf{t}_0 no espaço tempo e frequência.

A STFT pode ser considerada como a análise de Fourier para uma janela de tempo curto do sinal, em uma representação bidimensional de tempo e de frequência. As listas verticais do complexo valem os coeficientes da STFT correspondendo ao espectro de Fourier do janelamento do sinal com a janela deslocando no tempo $\mathbf{t} = \mathbf{t}_1, \mathbf{t}_2, \dots$ [79].

Considerando o módulo ao quadrado da STFT, as listas verticais da junção tempo e frequência representam o espectro de potência dos segmentos quase estacionários do sinal e são referidos como *spectrograma*.

$$|X(w, \mathbf{t})|^2 = \left| \int x(t)w^*(t - \mathbf{t})e^{-jtw'} dt \right|^2 \quad (\text{C.42})$$

A STFT pode também ser considerada como um banco de filtros passa-faixa. As listras horizontais dos coeficientes da STFT correspondem ao produto interno entre todo o tempo do sinal e a função de Gabor, $w^*(t-t)e^{jw't}$, para uma determinada frequência, $w' = w_1, w_2, \dots, w_n$. Multiplicando os dois lados da Equação (C.43), representativa da STFT, por $e^{jw't}$, pode-se escrever que $X(w', t)e^{jtw'}$ como a correlação entre o sinal $x(t)$ e a função básica de Gabor $g(t)e^{jw't}$.

$$X(\mathbf{t}, w^\lambda)e^{jtw^\lambda} = x(t) * [w(t)e^{jtw^\lambda}] \quad (\text{C.43})$$

Portanto, o sinal durante todo o tempo é filtrado por um banco de filtros $W(w-w')$ no domínio da frequência. A transformada de Fourier de $W(w)$ da janela $w(t)$ é usualmente ainda uma janela e é portanto um filtro passa-faixa. O termo $W(w-w')$ é o banco de filtros passa-faixa, $W(w)$, deslocado ao longo do eixo da frequência por w' . Escreve-se a correlação no lado direito da Equação (C.44) no domínio da frequência e levando o módulo ao quadrado dessa equação, produz a Equação (C.44).

$$|X(\mathbf{t}, w^\lambda)e^{jtw^\lambda}|^2 = \left| \int_{-\infty}^{\infty} F(w)W^*(w-w^\lambda)e^{jw't} dw \right|^2 \quad (\text{C.44})$$

Para um dado w' , as listas horizontais da junção tempo e frequência representam a intensidade da correlação do banco de filtros passa-faixa, $W(w-w')$, sendo referida como Espectrograma [71].

C.6 Transformada *Wavelet*

Um relato mais abrangente relacionado à transformada *wavelet* pode ser encontrado nas referências: [69, 70, 79 e 87].

As bases desta transformada não são mais as senóides ortogonais de Fourier, mas um conjunto arbitrário de versões dilatadas (ou comprimidas) e transladadas no tempo de uma função básica conveniente qualquer, podendo-se definir a transformada *wavelet* Contínua (CWT) pela Equação (C.45).

$$cwt_{a,t}[f(t)] = \int_{-\infty}^{\infty} f(t)h_{a,t}^*(t)dt \quad (\text{C.45})$$

Considerando-se $f(t)$ o sinal discreto no tempo a ser transformado e $h^*(t)$ o complexo conjugado da *wavelet-mãe* $h(t)$. A função $h(t)$ é a janela no tempo a partir da qual as outras funções são obtidas pela translação e pela dilatação, segundo:

$$h_{a,t}(t) = \frac{1}{\sqrt{a}} h\left(\frac{t-t}{a}\right) \quad (\text{C.46})$$

Nota-se que a transformada *wavelet* transforma uma função dependente de apenas uma variável em uma função de duas variáveis. Esta representação CWT é redundante e a Transformada de *Wavelet* inversa nem sempre é única.

Ao contrário da Transformada de Fourier e de outras transformadas, a base CWT não é especificada em sua definição. O projetista poderá escolher sua base, ortogonal ou não, ou mesmo criá-la, para uma determinada aplicação específica. As condições para que uma base $h(t)$ possa ser utilizada como conjunto *wavelet* são [69, 70, 79 e 87].

- 1- Condição de Admissibilidade: para que uma função seja aceita como *wavelet*, deve satisfazer à condição de admissibilidade, que é:

$$C_n = \int \frac{|H(\mathbf{w})|^2}{|\mathbf{w}|} d\mathbf{w} < +\infty \quad (\text{C.47})$$

A Equação (C.47) indica que a função candidata a *wavelet* deve oscilar, isto é, possuir valor médio nulo:

$$\overline{h(t)} = \int_{-\infty}^{\infty} h(t) dt = 0 \quad (\text{C.48})$$

A Equação (C.3.49) também mostra que as *wavelets* não podem possuir componentes na frequência zero, sendo, por definição, filtros passa-faixa. Se a condição de admissibilidade for satisfeita, a transformada de *wavelet* possui uma inversa.

- 2- Condição de Conservação de Energia: é equivalente ao Teorema de Parseval, da Transformada de Fourier, para a CWT, ela é:

$$\text{Energia}[h(t)] = \int_{-\infty}^{\infty} |h(t)|^2 dt \quad (\text{C.49})$$

- 3- Condição de Regularidade: as *wavelets* devem possuir decaimento exponencial tal que seus momentos de $n+1$ primeiras ordens sejam iguais a zero. O momento M_p de uma função $h(t)$ é definido por:

$$M_p = \int t^p h(t) dt \quad \text{para } p = 0, 1, 2, \dots \quad (\text{C.50})$$

A velocidade de convergência para zero dos coeficientes de uma CWT, com o decréscimo de a , é determinada pelo primeiro momento não nulo da *wavelet* básica $h(t)$. Se os primeiros $n+1$ momentos forem iguais a zero ($M_p = 0$ para $p = 0, 1, 2, \dots, n$), os coeficientes da transformada *wavelet* para a função $h(t)$ decaem rapidamente (proporcionalmente a a^{n+2}) com o decréscimo de a , levando a uma concentração satisfatória nos domínios do tempo e da frequência.

Uma forma simples de definição espacial do termo escala é obtida mediante sua relação com o tamanho do intervalo de localização das funções no domínio tempo-frequência, como mostrado na Figura C.1.4.

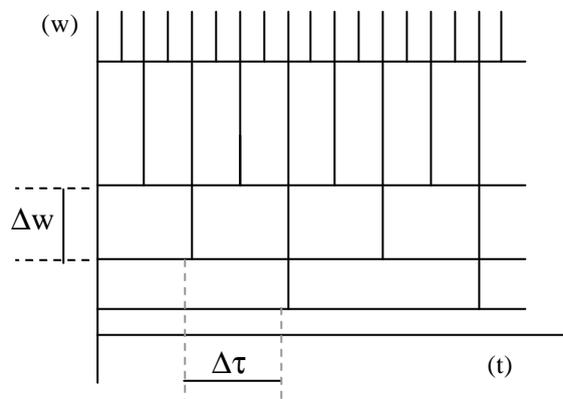


Figura C.1.4- Resolução no plano tempo-frequência para a Transformada *Wavelet*.

Em um escalograma, o eixo vertical representa a escala de a , aumentando no sentido inverso de ω , e o eixo horizontal representa o tempo t e os valores de translação \mathbf{t} , aumentando com t . Os valores das potências relativas de cada componente de escala, para um determinado \mathbf{t} , são obtidos do quadrado do módulo da CWT, isto é:

$$\frac{dt, da}{a^2} |CWT_{a, \mathbf{t}} [f(t)]|^2 \quad (\text{C.51})$$

Para que se possa representar as três variáveis relacionadas à CWT (a, t , potência da componente) utiliza-se geralmente um gráfico 3D, com o eixo z associado aos valores de potência. Usando-se um gráfico 2D, os valores da potência dependem dos valores de a e t , e são representados por cores ou níveis de cinza. Uma representação das duas variáveis, a e t , representam tempo e escala na transformada *wavelet* contínua.

As propriedades da Transformada Wavelet podem ser sintetizadas:

- 1- A transformada *wavelet* preserva os deslocamentos no tempo, isto é, se $W_x(t, a)$ for a transformada *wavelet* de um sinal $x(t)$, então $W_x(t-t_0, a)$ é a transformada *wavelet* do sinal $x(t-t_0)$ deslocado no tempo.
- 2- A transformada *wavelet* preserva a mudança de escala de tempo, isto é, se $W_x(\tau, a)$ for a transformada *wavelet* de um sinal $x(t)$, então a transformada *wavelet* do sinal no tempo $|a_0|^{1/2}x(a_0t)$ mudando a escala é igual a $W_x(a_0t, a/a_0)$.

Observa-se que a transformada *wavelet*, diferente da STFT, não preserva o deslocamento de frequência.

Fixando $p \geq 0$ e sendo $a \neq 0$, é possível a relação:

$$s_a(u) = |a|^{-p} s\left(\frac{u}{a}\right) = \frac{1}{|a|^p} s\left(\frac{u}{a}\right) \quad (\text{C.52})$$

Se s possui largura T , calculada de acordo com o princípio da incerteza, então a largura de s_a é aT . A modulação da função s pelo fator $1/|a|^p$ faz com que sua amplitude aumente quando a escala a diminui, e vice-versa. Para a pequeno s_a possui altas frequências, e à medida que a aumenta a frequência s_a diminui.

Inicialmente, é necessário localizar cada função s_a no tempo. Assim define-se para cada $t \in \mathbb{R}$ a função:

$$s_{a,t}(u) = s_a(u-t) = |a|^{-p} s\left(\frac{u-t}{a}\right) = \frac{1}{|a|^p} s\left(\frac{u-t}{a}\right) \quad (\text{C.53})$$

Pode-se definir uma transformada utilizando-se as funções $s_{a,t}$ como função moduladora de f . Esta transformada é traduzida, conforme as necessidades até então expostas, para se ter a transformada *wavelet*, cuja formulação é expressa na Equação (C.54).

$$\tilde{f}(a, t) = \int_{-\infty}^{\infty} f(u) s_{a,t}(u) du \quad (\text{C.54})$$

Define-se como dilatação de a ($a > 0$) o operador σ_a de estiramento de uma função $f(t)$ no domínio a vezes mais longo.

Considerando-se $\frac{1}{\sqrt{a}}$ a constante de normalização da energia para as *wavelets* e a o fator de dilatação não nulo. Se $a > 1$, a função *wavelet* é dilatada, e se $a < 1$, a função *wavelet* é contraída.

Define-se como translação de τ o operador ϕ_τ de atraso de uma função $f(t)$ no domínio do tempo t :

$$[\mathbf{f}_t f](t) = f(t - \mathbf{t}) \quad (\text{C.55})$$

Considerando-se τ o fator de translação.

A função Gaussiana foi utilizada como *wavelet* pela primeira vez por Martinet, Morlet e Grossman, na análise de padrões de sinais sonoros, e atualmente é conhecida como base de Morlet. A função *wavelet* de Morlet, definida na equação básica é a multiplicação da base de Fourier pela janela Gaussiana:

$$h(t) = e^{j\omega_0 t} \cdot e^{-\frac{t^2}{2}} \quad (\text{C.56})$$

e a sua transformada de Fourier é:

$$H(\omega) = \sqrt{\frac{\mathbf{p}}{2}} \left\{ e^{\left[-\frac{(\omega - \omega_0)^2}{2} \right]} + e^{\left[-\frac{(\omega + \omega_0)^2}{2} \right]} \right\} \quad (\text{C.57})$$

A base de Morlet não atende completamente à condição de admissibilidade porque $H(0)_{\text{Morlet}} \neq 0$ e, portanto, $C_h = +\infty$. Porém, se ω_0 for suficientemente grande, o valor de $H(0)$ torna-se muito próximo de zero. Na verdade, para $\omega_0 = 5$, $H(0) \approx 10^{-6} \approx 0$.

Gabor propôs sua versão, utilizando a Gaussiana como função *wavelet*, na forma de sua derivada de segunda ordem, a *wavelet* Chapéu-Mexicano, devido ao seu formato.

$$h(t) = (1 - t^2) e^{-\frac{t^2}{2}} \quad (\text{C.58})$$

$$H(\omega) = -\omega^2 e^{-\frac{\omega^2}{2}} \quad (\text{C.59})$$

A grande vantagem da *wavelet* de Gabor é que ela é real, par, e satisfaz à condição de admissibilidade.

Outra função muito utilizada é a *wavelet* de Haar, introduzida por Haar em 1910, e definida como:

$$h(t) = \begin{cases} 1 & \text{se: } 0 < t < 1/2 \\ -1 & \text{se: } 1/2 < t < 1 \\ 0 & \text{caso contrário} \end{cases} \quad (\text{C.60})$$

Para fins práticos, a *wavelet* de Haar pode ser reescrita como resultado de uma convolução entre a função retangular $rect(2t)$ e duas funções impulsos, ou $\delta(t)$.

$$\begin{aligned} h(t) &= rect\left[2\left(t - \frac{1}{4}\right)\right] - rect\left[2\left(t - \frac{3}{4}\right)\right] \\ &= rect(2t) * \left[\mathbf{d}\left(t - \frac{1}{4}\right) - \mathbf{d}\left(t - \frac{3}{4}\right)\right] \end{aligned} \quad (\text{C.61})$$

Sabendo-se que a função retangular e a função impulso são definidas respectivamente por:

$$rect(t) = \begin{cases} 1 & \text{se: } -1/2 < t < 1/2 \\ 0 & \text{caso contrário} \end{cases} \quad (\text{C.62})$$

$$\mathbf{d}(t) = \begin{cases} 1 & \text{se: } t = 0 \\ 0 & \text{caso contrário} \end{cases} \quad (\text{C.63})$$

A *wavelet* de Haar é uma função real, não simétrica com respeito a $t = 1/2$, e satisfaz à condição de admissibilidade. Sua transformada de Fourier possui amplitude $|H(\mathbf{w})|$ par e é simétrica para $\mathbf{w} = 0$, fato observado mediante a Equação (C.64).

$$H(\mathbf{w}) = 4je^{(-j\frac{\mathbf{w}}{2})} \frac{1 - \cos \frac{\mathbf{w}}{2}}{\mathbf{w}} \quad (\text{C.64})$$

A característica mais interessante da *wavelet* de Haar é que a mesma possui valores de amplitude altos quando ocorrem descontinuidades do sinal, como nos casos dos transientes. Isso ocorre porque a própria *wavelet* de Haar é descontínua no tempo. A maior

desvantagem da transformada de Haar é que ela não satisfaz à condição de regularidade, já que seu momento de primeira ordem é não-nulo. O espectro de Fourier da *wavelet* Haar converge muito lentamente para zero. A base de Haar constitui a base ortogonal mais simples que existe, porém, deve-se lembrar que a mesma oferece uma fraca localização em frequência.

A transformada *wavelet* contínua “mapeia” um sinal unidimensional em uma representação conjunta tempo e frequência, que é extremamente redundante quando a base de *wavelet* não é ortogonal. Em muitas aplicações o interesse maior é na compactação de dados, isto é, representação do sinal $f(t)$ utilizando-se um mínimo possível de parâmetros. Por esta razão desenvolveu-se a Transformada Wavelet *Discreta* (DWT), na qual os valores de translação t e de escala a variam discretamente de forma a se forçar a ortogonalidade das janelas de tempo. Se a largura das janelas T for tal que a largura atual, t^n , seja sempre a metade ($1/2 t^{n-1}$) ou o dobro ($2t^{n-1}$) de t^{n-1} , a ortogonalidade está garantida na maior parte dos casos. Assim:

$$DWT_{a_0, t_0} [f(t)] = \frac{1}{\sqrt{a_0^i}} \int_{-\infty}^{\infty} f(t) h * \left(\frac{t - k t_0 a_0^i}{a_0^i} \right) dt \quad i, k = 0, 1, 2, \dots \quad (\text{C.65})$$

Em que o fator de translação $t = k t_0 a_0^i$ depende do fator de escala a . E $a_0 > 1$ e t_0 são os valores iniciais de escala e de translação. O termo $1/\sqrt{a_0^i}$ é um fator de normalização. A diferenciação da DWT para com a CWT depende da escolha de a_0 e t_0 . Se a_0 é próximo de 1 e t_0 é pequeno, a DWT aproxima-se da CWT. Normalmente utiliza-se $a_0 = 2$, que corresponde ao intervalo de amostragem de Nyquist, em frequência. O fator de translação t_0 normalmente é escolhido como 1.

ANEXO D

FORMULAÇÕES ESTATÍSTICAS

D.1 Média, Correlação e Covariância

As formulações estatísticas desenvolvidas neste estudo podem ser encontradas com mais detalhes nas publicações de Johnson [104], Garcia [105] e Beiguelman [106].

Considera-se o processo randômico especificado pelas amostras conforme a matriz, X , da Equação (D.1). E, considerando-se as n medidas da primeira observação, $x_{11}, x_{21}, \dots, x_{n1}$, [104].

$$X_{jp} = \begin{vmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \dots & \dots & \dots & \dots \\ x_{j1} & x_{j2} & \dots & x_{jp} \end{vmatrix} \quad (\text{D.1})$$

A representação de X como n vetores no espaço n -dimensional consiste em considerar cada vetor, de cada amostra, como uma coordenada. As observações constituem uma amostra randômica, isto é, as medidas consideradas em diferentes itens não possuem relações uma com a outra. A Figura D.1. mostra a representação das coordenadas formadas pela matriz randômica de n linhas e p colunas, observando que cada eixo representa uma coluna dessa matriz [104].

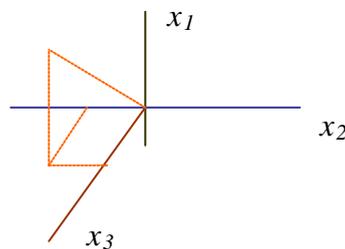


Figura D.1- Representação das coordenadas da matriz randômica no espaço n -dimensional.

Considerando-se o processo randômico especificado pelas amostras conforme a matriz, X , da Equação (D.2). E, considerando-se as n medidas da primeira observação, $x_{11},$

x_{21}, \dots, x_{n1} , o valor médio e o valor da variância dessas medidas podem ser obtidos pelas Equações (D.2) e (D.3), respectivamente [104].

$$\mathbf{m}_k = \frac{1}{n} \sum_{j=1}^n x_{jk} \quad k = 1, 2, \dots, p \quad (\text{D.2})$$

$$S_k^2 = \frac{1}{n} \sum_{j=1}^n (x_{jk} - \mathbf{m}_k)^2 \quad k=1, 2, \dots, p \quad (\text{D.3})$$

No entanto, quando são relacionadas as n medidas de duas observações, seja x_{j1} e x_{j2} , a medida da associação linear entre essas observações é a covariância, definida na Equação (D.4).

$$S_{ik} = \frac{1}{n} \sum_{j=1}^n (x_{ji} - \mathbf{m}_i)(x_{jk} - \mathbf{m}_k) \quad k = 1, 2, \dots, p \text{ e } i = 1, 2, \dots, p \quad (\text{D.4})$$

Para se tratar a covariância entre as variáveis de uma mesma amostra, define-se a autocovariância $S_{kk} = S_k^2$. Porém, a correlação entre a i -ésima e a k -ésima observação é obtida em termo da variância, conforme a Equação (D.5).

$$r_{ik} = \frac{S_{ik}}{\sqrt{S_{ii}}\sqrt{S_{kk}}} \quad (\text{D.5})$$

Observando-se que $r_{ik} = r_{ki}$, quando $k = 1, 2, \dots, p$ e $i = 1, 2, \dots, p$, $r_{ik} = r_{ki}$.

São propostas uma matriz associada à média para cada uma das observações e uma matriz variância. Para a matriz variância utiliza-se o símbolo σ , em que $\sigma_{11} = \text{Var}(X_1)$, $\sigma_{22} = \text{Var}(X_2)$, ... E a matriz covariância é representada pelo símbolo Σ .

$$\mathbf{m} = \begin{bmatrix} \mathbf{m}_1 \\ \mathbf{m}_2 \\ \dots \\ \mathbf{m}_p \end{bmatrix} \quad (\text{D.6})$$

$$\Sigma = \begin{bmatrix} \mathbf{s}_{11} & \mathbf{s}_{12} & \dots & \mathbf{s}_{1p} \\ \mathbf{s}_{21} & \mathbf{s}_{22} & \dots & \mathbf{s}_{2p} \\ \dots & \dots & \dots & \dots \\ \mathbf{s}_{p1} & \mathbf{s}_{p2} & \dots & \mathbf{s}_{pp} \end{bmatrix} \quad (\text{D.7})$$

A correlação, ρ , é obtida dos valores da variância entre as amostras

$$\mathbf{r}_{ik} = \frac{\mathbf{s}_{ik}}{\sqrt{\mathbf{s}_{ii}} \sqrt{\mathbf{s}_{kk}}} \quad (\text{D.8})$$

$$\mathbf{r} = \begin{bmatrix} 1 \cdot \mathbf{r}_{12} \dots \mathbf{r}_{1p} \\ \mathbf{r}_{12} \cdot 1 \dots \mathbf{r}_{2p} \\ \mathbf{r}_{1p} \cdot \mathbf{r}_{2p} \dots 1 \end{bmatrix} \quad (\text{D.9})$$

Em que:

$$\mathbf{r}_{12} = \frac{\mathbf{s}_{12}}{\sqrt{\mathbf{s}_{11}} \sqrt{\mathbf{s}_{22}}}, \quad \mathbf{r}_{1p} = \frac{\mathbf{s}_{1p}}{\sqrt{\mathbf{s}_{11}} \sqrt{\mathbf{s}_{pp}}}, \quad \mathbf{r}_{2p} = \frac{\mathbf{s}_{2p}}{\sqrt{\mathbf{s}_{22}} \sqrt{\mathbf{s}_{pp}}} \quad (\text{D.10})$$

D.2 Teste Estatístico T^2 Aplicado à Definição de uma Janela Adequada

O teste T^2 é destinado essencialmente para a comparação de proporções, que constitui um dos problemas que mais comumente ocorrem no campo das ciências médicas e biomédicas. Encontra-se detalhado por Johnson [104] e Beigelman [106].

O teste estatístico que considera a distância entre os pontos do espectro e sua covariância é baseado na Equação (D.11).

$$T^2 = n(\bar{\mathbf{x}} - \mathbf{m}_0)' \mathbf{S}^{-1} (\bar{\mathbf{x}} - \mathbf{m}_0) > \frac{(n-1)p}{(n-p)} F_{p, n-p}(\alpha) \quad (\text{D.11})$$

onde:

n = número de amostras (número de linhas da matriz de entrada \mathbf{x});

p = número de casos (número de colunas da matriz de entrada \mathbf{x});

$\bar{\mathbf{x}}$ = média das amostras;

μ_0 = valor esperado inicial (média) definido como hipótese no teste;

\mathbf{S}^{-1} = matriz de covariância inversa;

α = nível de significância do teste, depende da distribuição e é encontrado em tabelas;

$F_{p, n-p}(\alpha)$ = distribuição da porcentagem de pontos, depende de α e é encontrado em tabelas.

Para o teste, inicialmente propõe-se a comparação entre duas janelas e obtém-se as distâncias entre os pontos obtidos em seus resultados, e considera-se estas distâncias como

a matriz de entrada x . A distância entre os resultados dos espectros de magnitudes oferecidos por cada janela fornece uma forma de comparação entre os seus resultados. Em resumo, para o cálculo é seguido o seguinte desenvolvimento:

- 1- Escolhe-se duas janelas e, para cada uma, calcula-se o espectro de magnitude para dois trechos do sinal, como EEG1 e EEG2.
- 2- Calcula-se a distância entre os dois resultados de cada uma das duas janelas e considera-se o resultado como a matriz x , isto é:

$$d1 = (\text{espectro do EEG1 com janela 1}) - (\text{espectro do EEG1 com janela 2});$$

$$d2 = (\text{espectro do EEG2 com janela 1}) - (\text{espectro do EEG2 com janela 2}).$$

$$x = \begin{bmatrix} d1 \\ d2 \end{bmatrix}$$

- 3- Gera-se a matriz \bar{x} contendo a média de $d1$ e a média de $d2$, isto é:

$$\bar{x} = \begin{bmatrix} \text{média} & - d1 \\ \text{média} & - d2 \end{bmatrix}$$

- 4- Calcula-se a matriz covariância de x e gera-se sua matriz inversa.
- 5- Usando-se a primeira parte da Equação 1 e calcula-se o valor de T^2 .
- 6- Compara-se o valor obtido em 5 com os parâmetros da distribuição, conforme a segunda parte da Equação (D.11).
- 7- Obtêm-se os resultados para a comparação calculando-se os coeficientes da variância das distâncias nos dois trechos do sinal, conforme a Equação (D.12).

$$d_p = \pm \sqrt{\frac{(n-1)p}{(n-p)} F_{p, n-p}(\mathbf{a})} \sqrt{\frac{\text{var}(d1)}{n}} \quad (\text{D.12})$$

Para a aplicação proposta, inicialmente considera-se os valores de μ_0 para as duas janelas como [0 0] e o valor de α como 0,05 correspondente a uma distribuição normal. O número de amostras é $n=30$, referente ao intervalo de frequência de um evento epileptiforme, e o número de caso $p=2$, referente aos trechos EEG1 e EEG2. Conforme o valor de α o termo $F=3,34$, é obtido na Tabela D.1.

$$T^2 > \frac{2(30-1)}{30-2} * 3,34 = 6,9186$$

D.3 Teste Estatístico T^2 Aplicado à Definição dos Parâmetros Adequados

O teste estatístico considera 5 grupos de eventos encontrados em sinais do EEG. Cada grupo é representado por 10 sinais previamente escolhidos. O primeiro grupo representa os trechos do sinal contendo o evento epileptogênico que será comparado com os outros 4 grupos. Os demais grupos contendo também 10 trechos dos sinais representam o EEG de fundo, as ondas alfa, os ruídos e as piscadas.

Para o caso de definição dos parâmetros adequados relacionados aos sinais do EEG com eventos epileptogênicos, as variáveis da Equação (D.11) são definidas:

$n = 10$; valor relativo ao número de resultados obtidos ao calcular determinado parâmetro para 10 trechos de 1 segundo do sinal do EEG;

$p = 2$; número de casos igual a 2, sendo um sinal como o evento epileptogênico e o outro podendo ser um dos 4 eventos que podem juntamente estarem presentes no sinal;

\bar{x} = média das amostras;

μ_0 = valor esperado inicial (média) definido como hipótese no teste;

S^{-1} = matriz de covariância inversa;

α = nível de significância do teste, depende da distribuição e é encontrado em tabelas;

$F_{p,n-p}(\alpha)$ = distribuição da porcentagem de pontos, depende de α e é encontrado em tabelas.

Para o teste, inicialmente obtêm-se os resultados de cada parâmetro para 10 sinais de cada grupo e considera-os como a matriz de entrada x . Em síntese, são realizados os seguintes procedimentos:

- 1- Calcula-se o parâmetro desejado para o grupo de sinais contendo o evento epileptogênico e para um dos outros 4 grupos.
- 2- Calcula-se a distância entre os dois resultados e considera-se o resultado como a matriz x , isto é:

$$X = (\text{Resultado com o Evento Epileptogênico}) - (\text{Resultado com outro evento})$$
- 3- Gera-se a matriz \bar{x} contendo a média da diferença obtida no passo 2.
- 4- Calcula-se a matriz covariância de x e gera-se sua matriz inversa.
- 5- Usa-se a primeira parte da Equação (D.11) e calcula-se o valor de T^2 .

- 6- Compara-se o valor obtido em 5 com os parâmetros da distribuição, conforme a segunda parte da Equação (D.11).
- 7- Obtêm-se os resultados para comparação calculando-se os coeficientes da variância das distâncias nos dois trechos do sinal.

Para a aplicação proposta, inicialmente considera os valores de μ_0 como [0 0] e o valor de α como 0,05 correspondente a uma distribuição normal. O número de amostras é $n=10$ e o número de caso é $p=2$, referentes aos resultados dos parâmetros relativos aos 2 grupos dos trechos do EEG considerados. Conforme o valor de α o termo $F_{p,n-p}(\alpha) = F_{2,8}(0,05) = 4,46$, é obtida da Tabela D.1. O segundo termo da equação faz:

$$T^2 > \frac{2(10-1)}{10-2} * 4,46 = 10,0350$$

Tabela D.1- Distribuição da porcentagem de pontos ($F_{p,n-p}(\alpha) = F_{2,10}(0,05)$), para $\alpha = 0,05$ [103].

v_1										
v_2	1	2	3	4	5	6	7	8	9	10
1	161,5	199,5	215,5	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,25	19,30	19,33	19,35	19,37	19,38	19,40	19,41
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
...
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19

ANEXO E

TESTES UTILIZADOS NA DEFINIÇÃO DE UMA JANELA ADEQUADA

E.1 Testes para a Detecção de Freqüências Conhecidas nos Sinais Senoidais

Foram propostos neste trabalho como sinais de análise os resultados da soma das senóides com freqüências diferentes e variando conforme os testes de 1 a 16 definidos abaixo. As dimensões consideradas para cada janela seguem a potência de dois, conforme os tamanhos: 32, 64, 128, 256, 512 e 1024 pontos. As Tabelas E.1 e E.2 mostram os resultados desses testes.

1. Detectar freqüências de 50 e 10 Hz de um sinal com amplitude unitária.
2. Detectar freqüências de 20 e 10 Hz de um sinal com amplitude unitária.
3. Detectar freqüências de 20 e 2 Hz de um sinal com amplitude unitária.
4. Detectar freqüências de 10 e 5 Hz de um sinal com amplitude unitária.
5. Detectar freqüências de 5 e 3 Hz de um sinal com amplitude unitária.
6. Detectar freqüências de 3 e 1 Hz de um sinal com amplitude unitária.
7. Detectar freqüências de 2 e 1,5 Hz de um sinal com amplitude unitária.
8. Detectar freqüências de 2 e 2,5 Hz de um sinal com amplitude unitária.
9. Sinal composto por senóides cujas freqüências representam as freqüências que constituem os eventos epileptogênicos nos sinais do EEG. É gerado um sinal constituído das freqüências: 2; 2,5; 3; 6; 10 e 20.
10. Detectar freqüências de 20 Hz com amplitude 0,5 e 2 Hz com amplitude unitária.
11. Detectar freqüências de 20 Hz com amplitude 0,2 e 2 Hz com amplitude unitária.
12. Detectar freqüências de 20 Hz com amplitude 0,1 e 2 Hz com amplitude unitária.
13. Detectar freqüências de 5 Hz com amplitude 0,5 e 3 Hz com amplitude unitária.
14. Detectar freqüências de 5 Hz com amplitude 0,2 e 3 Hz com amplitude unitária.
15. Detectar freqüências de 5 Hz com amplitude 0,1 e 3 Hz com amplitude unitária.
16. Detectar freqüências de 5 Hz com amplitude 0,1 e 3 Hz com amplitude 0,5.

Na Tabela E.1 o resultado definido com o valor 1 representa a detecção das frequências e quando é definido com o valor 1* a janela conseguiu detectar as frequências, porém estas não estão bem definidas, e com o valor zero as frequências não são detectadas.

Tabela E.1- Resultados referentes aos testes realizados para detectar as frequências cujos valores são da ordem de grandeza de um sinal do EEG apresentando os eventos epileptogênicos.

Janela	1	2	3	4	5	6	7	8	9	10	11	12	3	4	5	6	Acertos
Retangular 32	1*	1*	1*	0	0	0	0	0	0	1*	1*	1*	0	0	0	0	6*
etangular 64	1*	1*	1*	1*	0	0	0	0	0	1	1	1	1*	0	0	0	5* e 3
Retangular 128	1	1	1*	1*	1*	1*	0	0	0	1	1	1	1*	1*	1*	1	7* e 6
Retangular 256	1	1	1	1	1	1	0	0	0	1	1	1	1	1	1	1	13
Retangular 512	1	1	1	1	1	1	1	1	1	1	1	1*	1	1	1	1	1* e 15
Retangular 1024	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1*	1	1* e 14
Triangular 32	1*	1*	1*	0	0	0	0	0	0	1*	1*	1*	0	0	0	0	6*
Triangular 64	1*	1*	1*	1*	0	0	0	0	0	1	1	1	1*	0	0	0	5* e 3
Triangular 128	1	1	1	1*	1*	1*	0	0	0	1	1	1	1*	0	0	0	4* e 6
Triangular 256	1	1	1	1	1	1	0	0	0	1	1	1	1	1	1	1	13
Triangular 512	1	1	1	1	1	1	1	1	1	1	1	1*	1	1	1	1	1* e 15
Triangular 1024	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1*	1	1* e 14
Barllet 32	1*	1*	1*	0	0	0	0	0	0	1*	1*	1*	0	0	0	0	6*
Barllet 64	1*	1*	1*	1*	0	0	0	0	0	1	1	1	1*	0	0	0	5* e 3
Barllet 128	1	1	1	1*	1*	1*	0	0	0	1	1	1	1*	0	0	0	4* e 6
Barllet 256	1	1	1	1	1	1	0	0	0	1	1	1	1	1	1	1	13
Barllet 512	1	1	1	1	1	1	1	1	1	1	1	1*	1	1	1	1	1* e 15
Barllet 1024	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1*	1	1* e 14
Hamming 32	1*	1*	0	0	0	0	0	0	0	1*	1*	1*	0	0	0	0	5*
Hamming 64	1*	1*	1*	1*	0	0	0	0	0	1	1	1	1*	0	0	0	5* e 3
Hamming 128	1	1	1	1*	1*	1*	0	0	0	1	1	1	1*	0	0	0	4* e 6
Hamming 256	1	1	1	1	1	1	0	0	0	1	1	1	1	1	1	1	13
Hamming 512	1	1	1	1	1	1	1	1	1	1	1	1*	1	1	1	1	1* e 15
Hamming 1024	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1*	1	1* e 14
Hanning 32	1*	1*	0	0	0	0	0	0	0	1*	1*	1*	0	0	0	0	5*
Hanning 64	1*	1*	1*	1*	0	0	0	0	0	1	1	1	1*	0	0	0	5* e 3
Hanning 128	1	1	1	1	1*	1*	0	0	0	1	1	1	1*	0	0	0	3* e 7
Hanning 256	1	1	1	1	1	1	0	0	0	1	1	1	1	1	1	1	13
Hanning 512	1	1	1	1	1	1	1	1	1	1	1	1*	1	1	1	1	1* e 15
Hanning 1024	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1*	1	1* e 14
Blackman 32	1*	1*	0	0	0	0	0	0	0	1*	1*	1*	0	0	0	0	5*
Blackman 64	1*	1*	1*	1*	0	0	0	0	0	1	1	1	0	0	0	0	4* e 3
Blackman 128	1	1	1	1	1*	1*	0	0	0	1	1	1	1*	0	0	0	3* e 7
Blackman 256	1	1	1	1	1	1	0	0	0	1	1	1	1	1	1	1	13
Blackman 512	1	1	1	1	1	1	1	1	1	1	1	1*	1	1	1	1	1* e 15
Blackman 1024	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1*	1	1* e 14

Os resultados mostrados na Tabela E.3 representam os testes usando os sinais senoidais de frequências diferentes ocorridas em tempos diferentes, isto é, a frequência varia ao longo do sinal. Para este teste foram consideradas as frequências:

1. Detectar frequências de 50 e 10 Hz de um sinal com amplitude unitária.
2. Detectar frequências de 20 e 10 Hz de um sinal com amplitude unitária.
3. Detectar frequências de 20 e 2 Hz de um sinal com amplitude unitária.
4. Detectar frequências de 10 e 5 Hz de um sinal com amplitude unitária.
5. Detectar frequências de 5 e 3 Hz de um sinal com amplitude unitária.
6. Detectar frequências de 3 e 1 Hz de um sinal com amplitude unitária.

Tabela E.3- Testes realizados para detectar as frequências da ordem de grandeza de um sinal do EEG apresentando os eventos epileptogênicos e variando ao longo do sinal.

Janela	T 1	T 2	T 3	T 4	T 5	T 6	Acertos
Retangular 128	1	0	0	0	0	0	1
Retangular 256	1	1	0	0	0	0	2
Retangular 512	1	1	1	1	0	0	4
Retangular 1024	1	1	1	1	1	1	6
Triangular 128	1	0	0	0	0	0	1
Triangular 256	1	1	0	0	0	0	2
Triangular 512	1	1	1	1	0	0	4
Triangular 1024	1	1	1	1	1	0	5
Barlet 128	1	0	0	0	0	0	1
Barlet 256	1	1	0	0	0	0	2
Barlet 512	1	1	1	1	0	0	4
Barlet 1024	1	1	1	1	1	0	5
Hamming 128	1	0	0	0	0	0	1
Hamming 256	1	0	0	0	0	0	1
Hamming 512	1	1	1	1	0	0	4
Hamming 1024	1	1	1	1	1	0	5
Hanning 128	1	0	0	0	0	0	1
Hanning 256	1	0	0	0	0	0	1
Hanning 512	1	1	1	1	0	0	4
Hanning 1024	1	1	1	1	1	0	5
Blackman 128	1	0	0	0	0	0	1
Blackman 256	1	0	0	0	0	0	1
Blackman 512	1	1	1	1	0	0	4
Blackman 1024	1	1	1	1	1	0	5
Kaiser 128	1	0	0	0	0	0	1
Kaiser 256	1	1	0	0	0	0	2
Kaiser 512	1	1	1	1	0	0	4
Kaiser 1024	1	1	1	1	1	1	6
Chebyshev 128	1	0	0	0	0	0	1
Chebyshev 256	1	1	0	0	0	0	2
Chebyshev 512	1	1	1	1	0	0	4
Chebyshev 1024	1	1	1	1	1	0	5
FFT	1	1	1	1	1	0	5

E.2 Espectros dos Sinais do EEG com o Evento Epileptogênico

As Tabelas E.4 a E.6 mostram os valores das magnitudes dos espectros fornecidos pelas janelas de Hamming, de Kaiser e de Chebyshev nos pontos x_{n-1} , x_n e x_{n+1} , juntamente com a distância entre estes pontos. Os espectros foram obtidos do trecho entre os pontos 800 a 900 do canal 31 do registro “lap_3510”. As seqüências dos pontos recebem o valor 1 quando: $x_{n-1} < x_n$ e $x_{n+1} < x_n$, considerando que a formação dos três pontos em questão provavelmente pode detectar as frequências no espectro. Para todas as janelas são considerados 1024 pontos.

Tabela E.4- Valores das magnitudes dos espectros fornecidos por uma janela de Hamming e a distância relativa entre seus pontos.

X_{n+1} 1.0e+004	X_n 1.0e+004	X_{n-1} 1.0e+004	Casos onde: $x_{n-1} < x_n$ e $x_{n+1} > x_n$	Distância: x_{n+1} a x_n 1.0e+004	Distância: X_{n-1} a X_n 1.0e+004
0,7039	0,1822	0,0698	1 (1° caso)	0,5217	0,1124
0,1822	0,0698	0,4721	0	0,1124	0,4023
0,0698	0,4721	0,0967	1	0,4023	0,3754
0,4721	0,0967	0,0504	0	0,3754	0,0464
0,0967	0,0504	0,2207	0	0,0464	0,1703
0,0504	0,2207	0,3210	0	0,1703	0,1003
0,2207	0,3210	1,3856	0	0,1003	1,0645
0,3210	1,3856	1,6021	0	1,0645	0,2165
1,3856	1,6021	1,5012	1	0,2165	0,1009
1,6021	1,5012	0,8230	0	0,1009	0,6782
1,5012	0,8230	1,7130	0	0,6782	0,8900
0,8230	1,7130	1,0121	1	0,8900	0,7009
1,7130	1,0121	0,5852	0	0,7009	0,4269
1,0121	0,5852	1,5358	0	0,4269	0,9506
0,5852	1,5358	0,0208	1	0,9506	1,5150
1,5358	0,0208	0,0531	0	1,5150	0,0323
0,0208	0,0531	0,1371	0	0,0323	0,0840
0,0531	0,1371	0,5533	0	0,0840	0,4162
0,1371	0,5533	0,2693	1	0,4162	0,2840
0,5533	0,2693	1,9189	0	0,2840	1,6495
0,2693	1,9189	0,3345	1	1,6495	1,5844
1,9189	0,3345	0,3069	0	1,5844	0,0276
0,3345	0,3069	0,2060	0	0,0276	0,1009
0,3069	0,2060	0,1928	0	0,1009	0,0132
0,2060	0,1928	0,7040	0	0,0132	0,5112
0,1928	0,7040	0,1356	1	0,5112	0,5684
0,7040	0,1356	0,9848	0	0,5684	0,8492
0,1356	0,9848	0,7867	1	0,8492	0,1980

Tabela E.5- Valores das magnitudes dos pontos do espectro fornecidos por uma janela de Kaiser ($\beta=1$) e a distância relativa entre estes pontos.

X_{n+1} 1.0e+004	X_n 1.0e+004	X_{n-1} 1.0e+004	Casos onde: $x_{n-1} < x_n$ e $x_{n+1} > x_n$	Distância: x_{n+1} a x_n 1.0e+004	Distância: X_{n-1} a X_n 1.0e+004
0,5723	0,1012	0,0830	1 (1º caso)	0,4711	0,0182
0,1012	0,0830	0,4202	0	0,0182	0,3372
0,0830	0,4202	0,1769	1	0,3372	0,2433
0,4202	0,1769	0,7975	0	0,2433	0,6206
0,1769	0,7975	1,5970	0	0,6206	0,7995
0,7975	1,5970	0,8314	1	0,7995	0,7655
1,5970	0,8314	0,4097	0	0,7655	0,4217
0,8314	0,4097	1,5784	0	0,4217	1,1686
0,4097	1,5784	0,5087	1	1,1686	1,0697
1,5784	0,5087	1,7647	0	1,0697	1,2560
0,5087	1,7647	2,9752	0	1,2560	1,2105
1,7647	2,9752	0,6178	1	1,2105	2,3574
2,9752	0,6178	0,3247	0	2,3574	0,2931
0,6178	0,3247	2,4809	0	0,2931	2,1562
0,3247	2,4809	0,5373	1	2,1562	1,9436
2,4809	0,5373	0,0461	0	1,9436	0,4912
0,5373	0,0461	0,0922	0	0,4912	0,0461
0,0461	0,0922	0,5538	0	0,0461	0,4616
0,0922	0,5538	0,3127	1	0,4616	0,2412
0,5538	0,3127	3,9934	0	0,2412	3,6808
0,3127	3,9934	0,1194	1	3,6808	3,8740
3,9934	0,1194	0,6877	0	3,8740	0,5683
0,1194	0,6877	0,0042	1	0,5683	0,6836
0,6877	0,0042	0,5656	0	0,6836	0,5615
0,0042	0,5656	1,6717	0	0,5615	1,1061
0,5656	1,6717	0,5947	1	1,1061	1,0770
1,6717	0,5947	1,6621	0	1,0770	1,0673
0,5947	1,6621	0,8232	1	1,0673	0,8389

Tabela E.6- Valores das magnitudes dos pontos do espectro fornecidos por uma janela de Chebyshev ($\alpha=20$) e a distância relativa entre estes pontos.

X_{n+1} 1.0e+004 *	X_n 1.0e+004 *	X_{n-1} 1.0e+004 *	Casos onde: $x_{n-1} < x_n$ e $x_{n+1} > x_n$	Distância: x_{n+1} a x_n 1.0e+004 *	Distância: X_{n-1} a X_n 1.0e+004 *
0,0728	1,3047	1,0668	1	1,2319	0,2379
1,3047	1,0668	0,4850	0	0,2379	0,5818
1,0668	0,4850	0,6341	0	0,5818	0,1491
0,4850	0,6341	1,9166	0	0,1491	1,2825
0,6341	1,9166	3,1870	0	1,2825	1,2704
1,9166	3,1870	1,8635	1	1,2704	1,3235
3,1870	1,8635	1,0310	0	1,3235	0,8324
1,8635	1,0310	4,2319	0	0,8324	3,2008
1,0310	4,2319	1,7406	1	3,2008	2,4913
4,2319	1,7406	2,7042	0	2,4913	0,9636
1,7406	2,7042	6,2843	0	0,9636	3,5801
2,7042	6,2843	0,1642	1	3,5801	6,1200
6,2843	0,1642	0,1339	0	6,1200	0,0303
0,1642	0,1339	5,4938	0	0,0303	5,3599
0,1339	5,4938	1,4148	1	5,3599	4,0790
5,4938	1,4148	0,7005	0	4,0790	0,7142
1,4148	0,7005	0,6791	0	0,7142	0,0214
0,7005	0,6791	0,1979	0	0,0214	0,4812
0,6791	0,1979	1,3428	0	0,4812	1,1449
0,1979	1,3428	6,6524	0	1,1449	5,3096
1,3428	6,6524	0,5408	1	5,3096	6,1117
6,6524	0,5408	2,3707	0	6,1117	1,8299
0,5408	2,3707	0,2552	1	1,8299	2,1155
2,3707	0,2552	1,5967	0	2,1155	1,3414
0,2552	1,5967	4,0902	0	1,3414	2,4935
1,5967	4,0902	1,2600	1	2,4935	2,8302
4,0902	1,2600	4,0905	0	2,8302	2,8305
1,2600	4,0905	0,1621	1	2,8305	3,9284

A Tabela E.7 faz uma síntese dos resultados relativos a diferença das magnitudes do espectro e a distância entre seus pontos, calculadas para 9 trechos de 1 segundo dos sinais do EEG.

Na Tabela E.7 o teste T1 define o número de casos onde: $x_{n-1} < x_n < x_{n+1}$. O teste T2 analisa a distância relativa entre os pontos x_{n-1} a x_n e x_{n+1} a x_n , totalizando o número de casos onde as distâncias encontradas não contribuem para a definição do espectro. E como resultado final o total dos pontos onde a magnitude espectral corresponde ao caso onde $x_{n-1} < x_n$ e $x_{n+1} < x_n$, e cuja distância entre os pontos esteja dentro de um limite no qual possa diferenciar um ponto do outro.

Tabela E.7- Resultados obtidos pelas janelas clássicas em 9 trechos dos sinais do EEG.

Janelas		Retangular	Bartlett	Hanning	Hamming	Blackman	Kaiser	Chebyshev
EEG 1	T1	11	10	11	9	8	11	11
	T2	4	5	6	5	6	2	5
	Total	4	9	8	8	8	11	9
EEG 2	T1	2	12	9	9	10	12	11
	T2	8	9	10	10	8	8	8
	Total	8	7	6	7	6	9	8
EEG 3	T1	12	13	13	12	12	11	13
	T2	4	3	3	4	4	2	4
	Total	9	11	11	9	10	10	11
EEG 4	T1	12	10	10	10	9	12	10
	T2	2	5	5	3	5	3	4
	Total	10	8	8	8	6	10	8
EEG 5	T1	10	7	7	7	7	8	9
	T2	10	16	10	11	11	8	12
	Total	4	3	4	3	4	6	4
EEG 6	T1	12	6	6	7	6	12	8
	T2	4	3	1	2	2	3	2
	Total	8	5	5	1	5	9	6
EEG 7	T1	10	9	10	10	10	10	10
	T2	3	1	1	1	2	2	4
	Total	8	8	9	9	9	8	7
EEG 8	T1	9	6	7	7	6	8	7
	T2	1	2	4	4	5	2	2
	Total	8	5	4	5	3	8	5
EEG 9	T1	7	7	7	7	7	8	7
	T2	7	2	2	2	3	5	3
	Total	6	7	7	7	5	8	7

ANEXO F

BASES WAVELETS

A Figura F.1 mostra a função gaussiana base de Morlet.

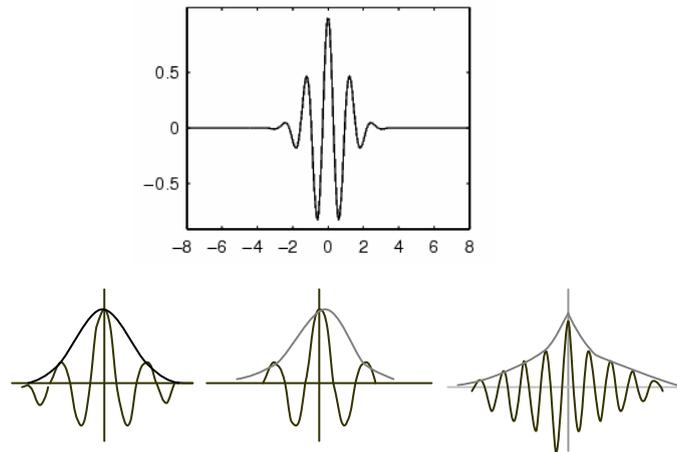


Figura F.1- Função Gaussiana base de Morlet.

A Figura F.2 mostra a *wavelet* chapéu-mexicano.

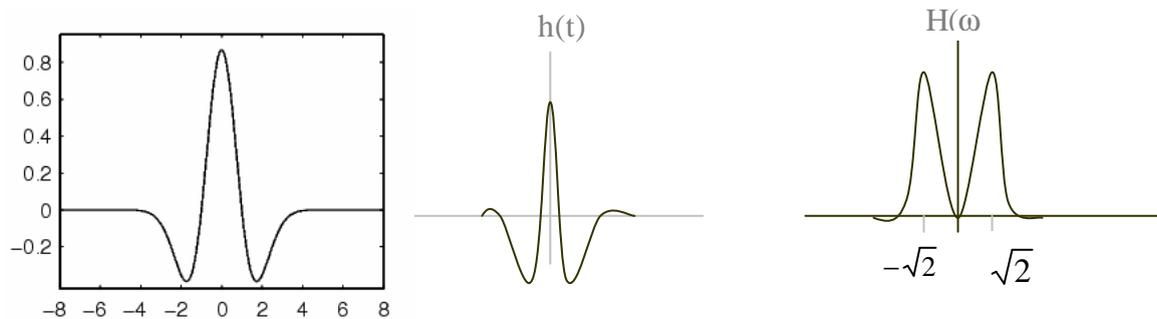


Figura F.2- *Wavelet* chapéu-mexicano.

A *wavelet* de Haar foi introduzida por Haar em 1910. É uma função real, não simétrica com respeito a $t = 1/2$ e satisfaz à condição de admissibilidade, como mostrado na Figura F.3. Esta função pode ser encontrada como resultado de uma convolução entre a função retangular e duas funções impulsos e é também conhecida como “função de Dirac”. Uma característica da *wavelet* de Haar é possuir valores altos de amplitude quando

ocorrem descontinuidades do sinal, como nos casos dos transientes. Isto ocorre porque a própria *wavelet* de Haar é descontínua no tempo. A maior desvantagem da transformada de Haar é que ela não satisfaz à condição de regularidade, já que seu momento de primeira ordem é diferente de zero. O espectro de Fourier da *wavelet* de Haar converge muito lentamente para zero. A base de Haar constitui a base ortogonal mais simples que existe, porém oferece uma fraca localização na frequência, em comparação às demais *wavelets* [91].

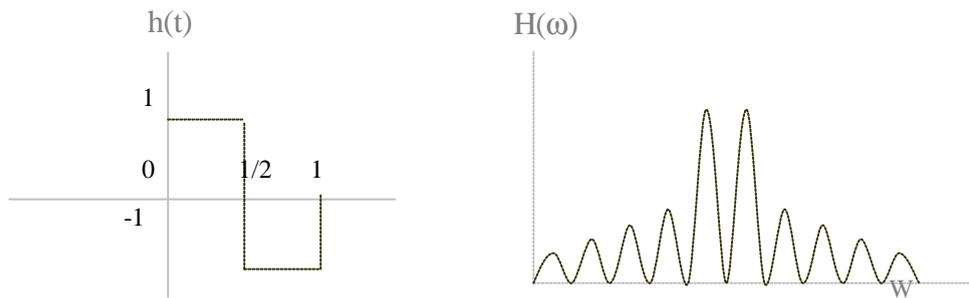


Figura F.3- *Wavelet* de Haar.

As *wavelets de Daubechies* são uma família de *wavelets* ortogonais que possuem a máxima regularidade e não são fornecidas na forma analítica. Cada membro desta família é diferenciado por uma ordem N , isto é, db1, db2, db3, ... Cada membro se diferencia do outro pela escala e pela amplitude. As curvas da família de *wavelets de Daubechies* são mostradas na Figura F.4. Para $N = 1$, as funções de *Daubechies* são iguais às funções de Haar.

A *wavelet biortogonal* é uma família de *wavelets* que possui a propriedade de fase linear, que é necessária para a reconstrução do sinal e da imagem. Ela utiliza duas *wavelets*, uma para a decomposição e outra para a reconstrução em um mesmo sinal. A Figura 7.5 mostra algumas formas de curvas pertencentes a esta família.

A *wavelet Coiflets* possui $2N$ momentos iguais a 0 e sua função escala tem $2N-1$ momentos iguais a zero. Utiliza-se um filtro passa-alta e um passa-baixa para a reconstrução e um filtro passa-alta e um passa-baixa para a decomposição. Para uma mesma escala, utiliza um maior número de pontos que as outras bases, fato que pode aumentar sua resolução. A Figura F.6 mostra as curvas pertencentes à esta família, onde pode-se observar as divisões de pontos utilizados em sua formação, para determinada escala considerada.

A *wavelet Symlets* possui propriedades semelhantes às da família *Daubechies*. Aparentemente as formas das curvas para as duas famílias são iguais, diferindo em uma certa inversão de fase com relação às formas da curva. Uma curva de ordem N de uma família é a mesma curva de ordem N invertida da outra família. A Figura F.7 mostra algumas formas das curvas pertencentes a esta família.

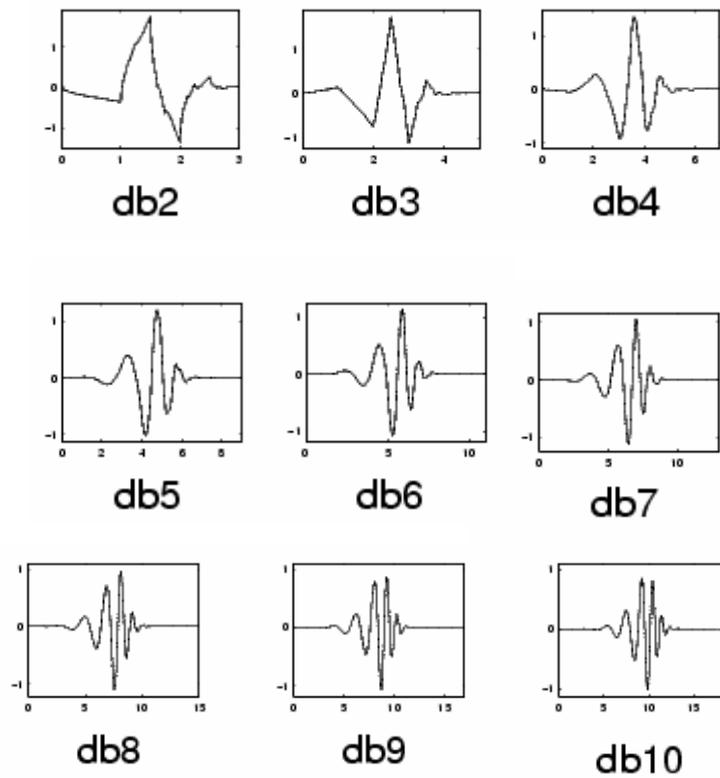


Figura F.4- Família de *wavelet* de Daubechies. Considera db1 igual a *wavelet* de Haar [91].

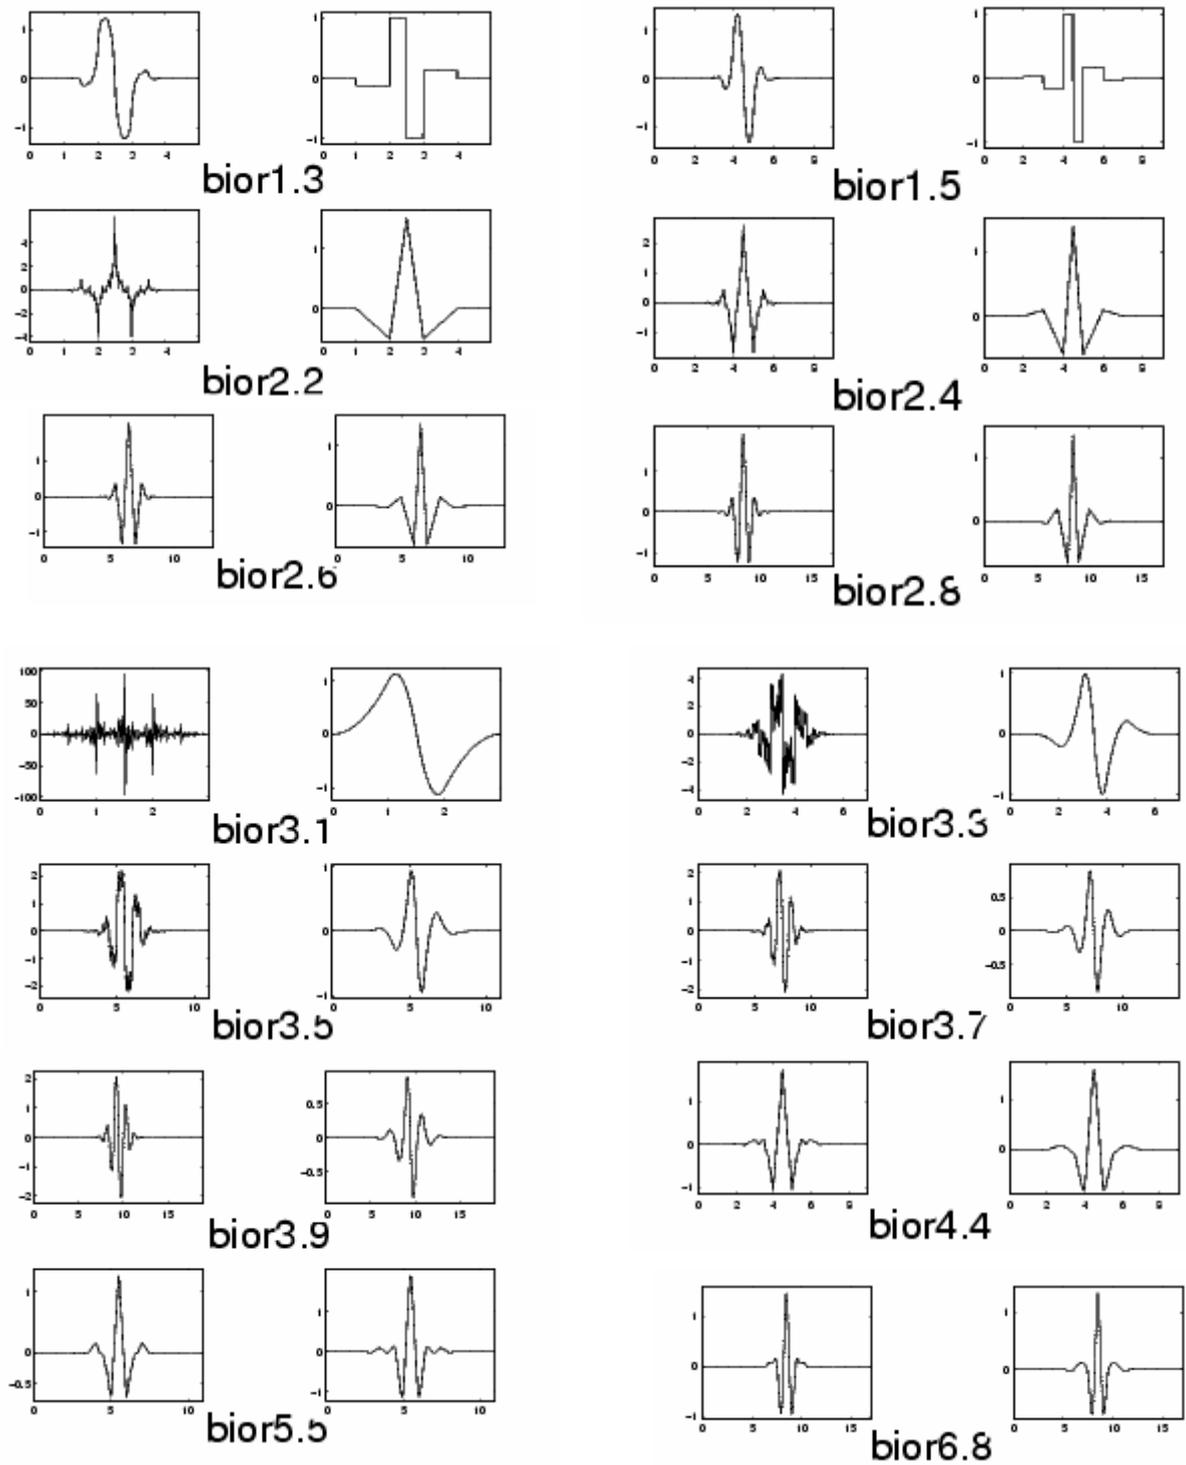


Figura F.5- Famílias de *wavelet* biortogonal [91].

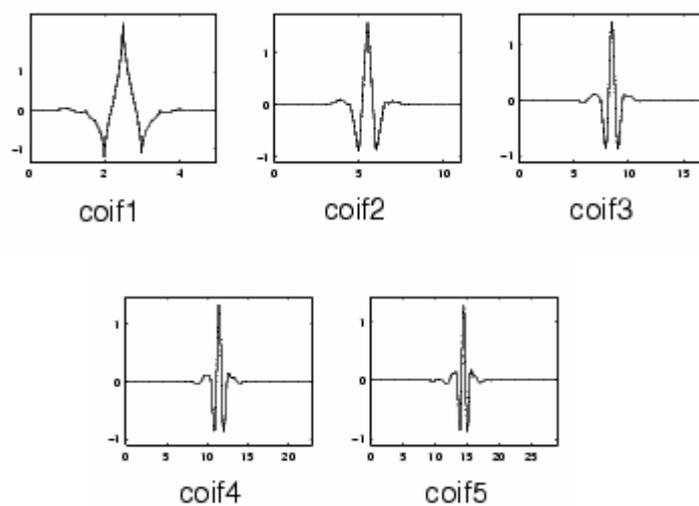


Figura F.6- Famílias de *wavelet Coiflets* [91].

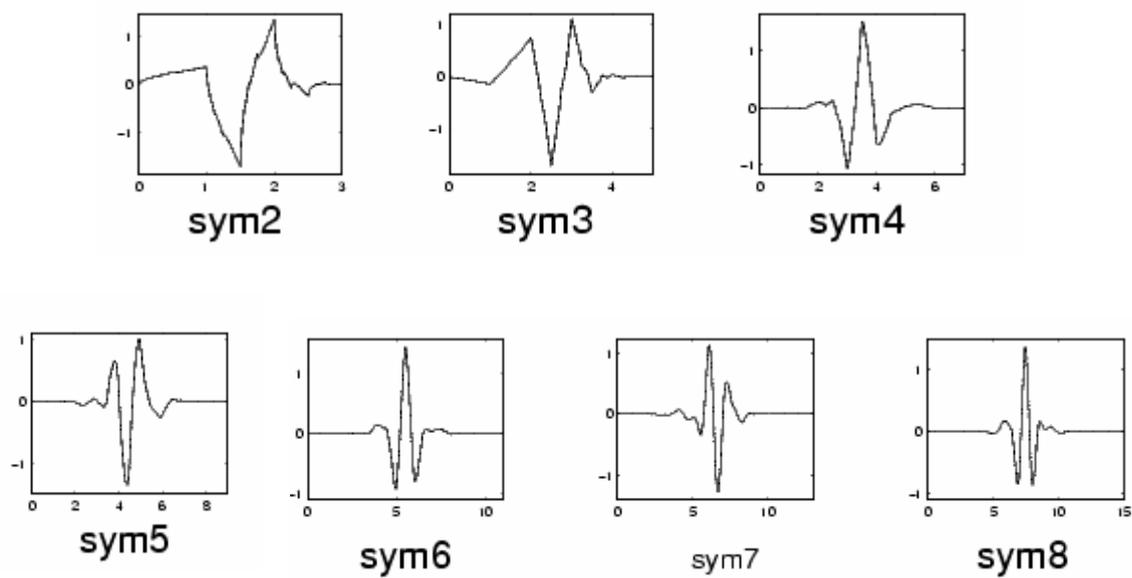


Figura F.7- Famílias de *wavelet Symlets* [91].

ANEXO G PARÂMETROS

G.1. Principais Parâmetros

Os parâmetros relacionados nas Tabela G.1 a G.21 foram obtidos para dez sinais de EEG com os respectivos eventos.

Tabela G.1- Amplitude máxima positiva (Amax) e negativa (Bmin).

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
Amax [µv]	Bmin [µv]	Amax [µv]	Bmin [µv]	Amax [µv]	Bmin [µv]	Amax [µv]	Bmin [µv]	Amax [µv]	Bmin [µv]
21,4844	-13,6719	105,4687	-82,0312	17,5781	-21,4844	80,0780	-119,1405	35,1562	-261,7185
7,8125	-5,8594	164,0624	-126,9530	7,8125	-13,6719	146,4842	-103,5155	80,0781	-242,1873
17,5781	-9,7656	132,8124	-60,5468	21,4844	-15,6250	66,4062	-60,5468	234,3748	-343,7497
23,4375	-7,8125	85,9374	-62,4999	9,7656	-13,6719	234,3748	-97,6562	46,8750	-337,8903
15,6250	-13,6719	37,1093	-111,3280	15,6250	-11,7187	62,4999	-39,0625	52,7343	-246,0935
5,8594	-9,7656	52,7343	-111,3280	50,7812	-31,2500	183,5936	-101,5624	76,1718	-210,9373
23,4375	-13,6719	91,7968	-107,4218	27,3437	-54,6875	52,7343	-203,1248	33,2031	-269,5310
11,7187	-9,7656	66,4062	-89,8437	21,4844	-29,2968	56,6406	-232,4217	156,2499	-201,1717
9,7656	-21,4844	126,9530	-35,1562	31,2500	-19,5312	107,4218	-119,1405	42,9687	-269,5310
15,6250	-19,5312	101,5624	-46,8750	39,0625	-29,2969	66,4062	-85,9374	35,1562	-519,5308

Tabela G.2- Amplitude máxima positiva (Amax_pts) e negativa (Bmin_pts) destacadas no trecho de 30 pontos centrados no ponto de máximo positivo.

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
Amax_pts [µv]	Bmin_pts [µv]	Amax_pts [µv]	Bmin_pts [µv]	Amax_pts [µv]	Bmin_pts [µv]	Amax_pts [µv]	Bmin_pts [µv]	Amax_pts [µv]	Bmin_pts [µv]
21,4844	-13,6719	105,4687	-82,0312	17,5781	-21,4844	-29,2968	-119,1405	35,1562	-261,7185
7,8125	-5,8594	164,0624	-126,9530	7,8125	-13,6719	146,4842	0	80,0781	-242,1873
17,5781	-9,7656	132,8124	-60,5468	21,4844	-15,6250	66,4062	-9,7656	234,3748	-343,7497
23,4375	-7,8125	85,9374	-62,4999	9,7656	-13,6719	234,3748	-97,6562	46,8750	-337,8903
15,6250	-13,6719	37,1093	-111,3280	15,6250	-11,7187	62,4999	-39,0625	52,7343	-246,0935
5,8594	-9,7656	52,7343	-111,3280	50,7812	-9,7656	183,5936	-101,5624	76,1718	-210,9373
23,4375	-13,6719	91,7968	-107,4218	-11,7187	-54,6875	52,7343	-203,1248	33,2031	-269,5310
11,7187	-9,7656	42,9687	-89,8437	21,4844	-29,2968	56,6406	-232,4217	156,2499	-201,1717
9,7656	-21,4844	126,9530	-35,1562	31,2500	-17,5781	107,4218	-119,1405	42,9687	-269,5310
15,6250	-19,5312	101,5624	-46,8750	39,0625	11,7187	39,0625	-85,9374	35,1562	-519,5308

Tabela G.3- Diferença (DifAB) e distância (Tdif) entre as amplitudes máximas (positiva e negativa).

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
Tdif [pts]	DifAB [μ v]	Tdif [pts]	DifAB [μ v]	Tdif [pts]	DifAB [μ v]	Tdif [pts]	DifAB [μ v]	Tdif [pts]	DifAB [μ v]
34	35,1562	8	187,4998	11	39,0625	19	199,2186	57	296,8748
17	13,6719	3	291,0154	58	21,4844	25	249,9997	30	322,2653
31	27,3437	5	193,3592	21	37,1093	47	126,9530	16	578,1245
25	31,2500	4	148,4374	44	23,4375	30	332,0309	28	384,7653
48	29,2969	4	148,4374	55	27,3437	4	101,5624	27	298,8279
76	15,6250	5	164,0624	80	82,0312	14	285,1560	37	287,1091
42	37,1093	5	199,2186	40	82,0312	28	255,8591	46	302,7341
37	21,4844	27	156,2499	5	50,7812	43	289,0623	38	357,4216
65	31,2500	2	162,1092	64	50,7812	2	226,5623	33	312,4997
61	35,1562	8	148,4374	24	68,3593	46	152,3436	58	554,6870

Tabela G.4- Diferença (DifAB_pts) e distância (Tdif_pts) entre as amplitudes máximas, destacadas no trecho de 30 pontos centrados no ponto de máximo positivo.

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
Tdif_pts [pts]	DifAB [μ v]	Tdif_pts [pts]	DifAB [μ v]	Tdif_pts [pts]	DifAB [μ v]	Tdif_pts [pts]	DifAB [μ v]	Tdif_pts [pts]	DifAB [μ v]
34	35,1562	8	187,4998	11	39,0625	9	128,9061	57	296,8748
17	13,6719	3	291,0154	58	21,4844	4	146,4842	30	322,2653
31	27,3437	5	193,3592	21	37,1093	1	76,1718	16	578,1245
25	31,2500	4	148,4374	44	23,4375	30	332,0309	28	384,7653
48	29,2969	4	148,4374	55	27,3437	4	101,5624	27	298,8279
76	15,6250	5	164,0624	6	60,5468	14	285,1560	37	287,1091
42	37,1093	5	199,2186	8	52,7343	28	255,8591	46	302,7341
37	21,4844	4	132,8124	5	50,7812	43	289,0623	38	357,4216
65	31,2500	2	162,1092	9	48,8281	2	226,5623	33	312,4997
61	35,1562	8	148,4374	9	29,2968	9	124,9999	58	554,6870

Tabela G.5- Duração do evento (T) em destaque no trecho em análise.

EEG NORMAL [pts]	EEG COM EVENTO EPILEPTOGÊNICO [pts]	EEG COM ONDA ALFA [pts]	EEG COM RUÍDO [pts]	EEG COM PISCADA [pts]
54	26	26	6	72
26	8	65	17	74
44	18	30	5	78
55	12	53	40	86
68	17	64	8	42
31	13	25	25	76
54	20	6	35	86
53	11	15	64	72
73	9	21	9	63
76	21	6	16	76

Tabela G.6- Lado oposto do ângulo do vértice positivo (dpos) e negativo (dneg) correspondente ao trecho entre a amplitude máxima e seu extremo.

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
dpos [pts]	dneg [pts]	dpos [pts]	dneg [pts]	dpos [pts]	dneg [pts]	dpos [pts]	dneg [pts]	dpos [pts]	dneg [pts]
17	3	11	7	9	6	1	15	3	12
4	5	1	4	2	5	12	1	18	26
8	5	5	8	4	5	3	1	47	15
28	2	3	5	5	4	7	3	18	40
6	14	6	7	6	3	2	2	6	9
1	1	6	2	16	3	9	2	19	20
8	4	3	12	1	13	3	4	8	32
8	8	4	3	4	6	2	19	23	11
4	4	5	2	10	2	3	4	9	21
7	8	5	8	15	1	2	5	2	16

Tabela G.7- Ângulo do vértice do evento em destaque.

EEG NORMAL Angulo q	EEG COM EVENTO EPILEPTOGÊNICO Angulo q	EEG COM ONDA ALFA Angulo q	EEG COM RUÍDO Angulo q	EEG COM PISCADA Angulo q
24,7524	9,7549	31,2072	3,9099	5,2504
54,2249	0,6985	28,7187	9,3664	12,2550
48,9417	4,3120	21,0934	5,1733	4,9972
28,7187	3,9987	32,6160	3,4215	13,5027
42,0136	7,1957	28,7187	3,6657	4,1889
11,6934	2,0584	34,1539	2,2563	10,8326
32,6160	3,7436	-9,7549	2,2563	13,5415
68,6401	3,8249	21,0934	4,0446	6,2596
21,0934	4,5108	12,9822	3,1994	8,9102
44,5480	5,6369	9,7549	5,8620	3,5280

Tabela G.8- Tangente do ângulo do vértice positivo (tgp) e negativo (tgn) do evento em destaque

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COMPISCADA	
tgp	tgn	tgp	tgn	tgp	tgn	tgp	tgn	tgp	tgn
0,7913	0,2194	0,1043	0,0853	0,5120	0,2793	0,0341	0,1259	0,0853	0,0459
0,5120	0,8533	0,0061	0,0315	0,2560	0,3657	0,0819	1,0000	0,2248	0,1074
0,4551	0,5120	0,0376	0,1321	0,1862	0,3200	0,0452	0,1024	0,2005	0,0436
1,1947	0,2560	0,0349	0,0800	0,5120	0,2926	0,0299	0,0307	0,3840	0,1184
0,3840	1,0240	0,1617	0,0629	0,3840	0,2560	0,0320	0,0512	0,1138	0,0366
0,1707	0,1024	0,1138	0,0180	0,3151	0,3072	0,0490	0,0197	0,2494	0,0948
0,3413	0,2926	0,0327	0,1117	-0,0853	0,2377	0,0569	0,0197	0,2409	0,1187
0,6827	0,8192	0,0931	0,0334	0,1862	0,2048	0,0353	0,0817	0,1472	0,0547
0,4096	0,1862	0,0394	0,0569	0,3200	0,1138	0,0279	0,0336	0,2095	0,0779
0,4480	0,4096	0,0492	0,1707	0,3840	0,0853	0,0512	0,0582	0,0569	0,0308

Tabela G.9- Distância em pontos (tA_i) e diferença em amplitude (DifA_i) entre o ponto de máximo positivo e um segundo ponto de máximo positivo encontrado na região inicial do trecho considerado.

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
DifA _i [μv]	tA _i [pts]	DifA _i [μv]	tA _i [pts]	DifA _i [μv]	tA _i [pts]	DifA _i [μv]	tA _i [pts]	DifA _i [μv]	tA _i [pts]
1,9531	22	74,2187	19	3,9062	16	-109,3749	28	35,1562	69
9,7656	27	181,6405	10	5,8594	10	11,7187	14	52,7343	34
7,8125	52	101,5624	20	3,9062	22	23,4375	3	248,0467	34
9,7656	52	58,5937	25	5,8594	68	101,5624	11	7,8125	29
5,8594	25	29,2969	60	0,0000	60	7,8125	11	1,9531	52
0	43	37,1093	45	50,7812	16	74,2187	17	70,3124	71
19,5312	46	60,5468	15	-35,1562	30	29,2968	6	17,5781	9
7,8125	27	-23,4375	31	9,7656	21	15,6250	78	95,7030	75
5,8594	10	111,3280	32	5,8594	29	66,4062	65	5,8594	55
7,8125	74	74,2187	20	19,5312	30	-27,3437	55	27,3437	86

Tabela G.10- Distância em pontos (tB_i) e diferença em amplitude (DifB_i) entre o ponto de máximo negativo e um segundo ponto de máximo negativo encontrado na região inicial do trecho considerado.

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
DifB _i [μv]	tB _i [pts]	DifB _i [μv]	tB _i [pts]	DifB _i [μv]	tB _i [pts]	DifB _i [μv]	tB _i [pts]	DifB _i [μv]	tB _i [pts]
-13,6719	69	-66,4062	68	-7,8125	52	-97,6562	17	-234,3748	18
-1,9531	8	-83,9843	16	-5,8594	72	104,5155	29	-230,4685	52
-7,8125	18	-13,6719	40	-3,9062	73	39,0625	41	-324,2185	16
-3,9062	9	-23,4375	7	-3,9062	12	-76,1718	40	-353,5153	53
-7,8125	62	-83,9843	42	-17,5781	8	0,0000	16	-193,3592	18
-0,0000	58	-101,5624	45	0,0000	24	-3,9062	42	-199,2186	43
-7,8125	6	-27,3437	8	-52,7343	29	-187,4998	32	-277,3435	54
-1,9531	56	-93,7499	8	-1,9531	13	-214,8436	36	-216,7967	11
-15,6250	69	-13,6719	43	1,9531	73	-39,0625	4	-240,2341	50
-11,7187	20	-39,0625	13	25,3906	68	-19,5312	40	-486,3277	20

Tabela G.11- Distância em pontos (tA_f) e diferença em amplitude (DifA_f) entre o ponto de máximo positivo e um segundo ponto de máximo positivo encontrado na região final do trecho considerado.

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
DifA_f [µv]	tA_f [pts]	DifA_f [µv]	tA_f [pts]	DifA_f [µv]	tA_f [pts]	DifA_f [µv]	tA_f [pts]	DifA_f [µv]	tA_f [pts]
-1,9531	-76	-93,7499	68	-1,9531	-40	-42,9687	-21	-287,1091	-33
0	14	-103,5155	50	-3,9062	-53	-14,6250	-42	-158,2030	-64
-5,8594	4	-27,3437	50	-9,7656	-73	50,7812	1	-312,4997	0
-3,9062	-25	-3,9062	1	-5,8594	-12	-15,6250	-57	-60,5468	-55
-7,8125	-62	-83,9843	59	0	16	-3,9062	13	-281,2498	-63
0	-70	-50,7812	27	21,4844	46	-15,6250	-97	-257,8123	-29
-7,8125	30	-54,6875	31	-23,4375	-22	-123,0468	-33	-234,3748	-49
-5,8594	-74	-72,2656	5	-13,6719	-41	-187,4998	-31	-238,2810	-25
-9,7656	-66	-19,5312	12	1,9531	-85	-138,6717	-43	-265,6247	-51
-7,8125	-21	-23,4375	22	41,0156	-56	-7,8125	-36	-501,9527	-38

Tabela G.12- Distância em pontos (tB_f) e diferença em amplitude (DifB_f) entre o ponto de máximo negativo e um segundo ponto de máximo negativo encontrado na região final do trecho considerado.

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
DifB_f [µv]	tB_f [pts]	DifB_f [µv]	tB_f [pts]	DifB_f [µv]	tB_f [pts]	DifB_f [µv]	tB_f [pts]	DifB_f [µv]	tB_f [pts]
21,4844	-44	50,7812	-48	0	-36	-82,0312	3	1,9531	-86
1,9531	15	107,4218	22	3,9062	-14	56,6406	-65	70,3124	-27
3,9062	-51	130,8593	-30	1,9531	-59	0,0000	-39	230,4685	-29
7,8125	-36	60,5468	-29	1,9531	-63	167,9686	-44	37,1093	-18
7,8125	-19	31,2500	-39	1,9531	-58	0	-18	0	-84
0	-28	23,4375	-7	17,5781	-5	269,5310	-83	5,8594	-80
11,7187	-35	60,5468	-51	-39,0625	-14	1,9531	44	44,9218	3
3,9062	-30	27,3437	19	0	-29	3,9063	-62	33,2031	-75
1,9531	-9	117,1874	-41	33,2031	-69	9,7656	-63	7,8125	-79
15,6250	-84	58,5937	-12	27,3437	-61	-15,6250	-56	0	-85

Tabela G.13- Desvio padrão calculado para o trecho de 30 pontos (desvio) e de 100 pontos (1 segundo).

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
desvio	desvioC	desvio	desvioC	desvio	desvioC	desvio	desvioC	desvio	desvioC
8,1155	8,1155	48,3023	32,3758	9,5903	9,5903	31,8861	43,1734	79,6632	79,6632
3,0870	3,0870	62,6482	40,7474	4,9565	4,9565	42,2327	58,3930	81,6824	81,6824
5,2868	5,2868	41,9944	29,6556	9,4437	9,4437	22,0847	30,6027	135,5955	135,5955
6,1945	6,1945	31,0355	24,5426	5,3856	5,3856	62,8526	62,8526	118,0018	118,0018
7,1818	7,1818	30,3683	17,8780	6,3915	6,3915	30,1207	28,3483	65,8099	65,8099
3,6939	3,6939	32,4310	28,1504	15,9510	17,0729	53,5307	53,5307	79,2243	79,2243
5,7839	5,7839	43,2613	30,8104	15,0767	18,1046	44,2063	44,2063	74,7647	74,7647
5,1612	5,1612	25,4452	25,4452	11,7002	11,7002	67,3999	67,3999	99,6896	99,6896
6,1754	6,1754	29,8980	19,2400	13,7434	12,1852	65,1003	43,7621	102,5110	102,5110
7,3715	7,3715	38,9843	25,3923	7,6682	14,6514	32,4007	33,2671	127,0029	127,0029

Tabela G.14- Média calculada para o trecho de 30 pontos (media) e de 100 pontos (1 segundo).

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
media	mediaC	media	mediaC	media	mediaC	media	mediaC	media	mediaC
7,2266	7,2266	34,6522	23,6328	8,0273	8,0273	67,6153	34,6289	57,3242	57,3242
2,4414	2,4414	41,6456	29,9218	4,9219	4,9219	88,2686	48,4179	57,5781	57,5781
5,3125	5,3125	28,9188	22,0703	7,8711	7,8711	35,1562	27,3828	104,3944	104,3944
6,7578	6,7578	23,3115	19,1406	4,6289	4,6289	44,7265	44,7265	96,0546	96,0546
6,3086	6,3086	20,9173	13,0664	5,6445	5,6445	26,4617	24,9219	42,5781	42,5781
3,1055	3,1055	17,3261	20,9570	22,8074	16,4453	41,7968	41,7968	57,4023	57,4023
5,0586	5,0586	32,6991	23,1640	25,8789	14,3164	32,9297	32,9297	54,2187	54,2187
4,0430	4,0430	18,9844	18,9844	9,4726	9,4726	59,1796	59,1796	89,6874	89,6874
5,2930	5,2930	17,9561	10,6055	14,2299	10,6055	56,7666	35,6445	82,2851	82,2851
6,0156	6,0156	27,9738	21,6015	22,0424	11,8164	28,2258	27,1094	73,9062	73,9062

Tabela G.15- Coeficiente de variação calculado para o trecho de 30 pontos (coef) e de 100 pontos (1 segundo).

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
coef	coefC	coef	coefC	coef	coefC	coef	coefC	coef	coefC
1,1230	1,1230	1,3939	1,3700	1,1947	1,1947	0,4716	1,2467	1,3897	1,3897
1,2644	1,2644	1,5043	1,3618	1,0070	1,0070	0,4785	1,2060	1,4186	1,4186
0,9952	0,9952	1,4521	1,3437	1,1998	1,1998	0,6282	1,1176	1,2989	1,2989
0,9166	0,9166	1,3313	1,2822	1,1635	1,1635	1,4053	1,4053	1,2285	1,2285
1,1384	1,1384	1,4518	1,3682	1,1323	1,1323	1,1383	1,1375	1,5456	1,5456
1,1895	1,1895	1,8718	1,3432	0,6994	1,0382	1,2807	1,2807	1,3802	1,3802
1,1434	1,1434	1,3230	1,3301	0,5826	1,2646	1,3424	1,3424	1,3789	1,3789
1,2766	1,2766	1,3403	1,3403	1,2352	1,2352	1,1389	1,1389	1,1115	1,1115
1,1667	1,1667	1,6651	1,8142	0,9658	1,1490	1,1468	1,2277	1,2458	1,2458
1,2254	1,2254	1,3936	1,1755	0,3479	1,2399	1,1479	1,2271	1,7184	1,7184

Tabela G.16- Variância calculada para o trecho de 30 pontos (vari) e de 100 pontos (1 segundo).

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
vari	variC	vari 1.0e+003 *	variC	vari	variC	vari 1.0e+003 *	variC 1.0e+003 *	vari 1.0e+004 *	variC 1.0e+004 *
24,7762	24,7762	1,1350	646,8405	27,7351	27,7351	0,8856	0,7597	0,5067	0,5067
3,5739	3,5739	2,2416	893,7844	10,2095	10,2095	1,7836	1,7183	0,4049	0,4049
16,1126	16,1126	0,9634	402,2380	31,0150	31,0150	0,4066	0,3225	0,8848	0,8848
27,8526	27,8526	0,4054	289,6853	8,9900	8,9900	2,1143	2,1143	0,9228	0,9228
13,7834	13,7834	0,6277	244,6561	16,3296	16,3296	0,3751	0,2971	0,2621	0,2621
6,5578	6,5578	0,7741	500,2913	196,6822	132,3335	1,2434	1,2434	0,2967	0,2967
15,2661	15,2661	0,8952	457,2250	227,3058	139,5680	0,8940	0,8940	0,4595	0,4595
11,6564	11,6564	0,3664	366,3706	47,0382	47,0382	2,8905	2,8905	0,2614	0,2614
15,6668	15,6668	0,7574	272,1343	65,2857	41,4803	1,0943	0,7136	0,8184	0,8184
18,0084	18,0084	0,7742	324,4275	58,8007	82,1796	0,4788	0,3695	1,5343	1,5343

Tabela G.17- Fator de crista (CF) calculado para o trecho de 30 pontos e de 100 pontos (1 segundo).

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
FC	FCC	FC	FCC	FC	FCC	FC	FCC	FC	FCC
4,3320	4,3320	3,8818	5,7914	4,0731	4,0731	4,0427	4,6144	3,7266	3,7266
4,4289	4,4289	4,6452	7,1419	4,3346	4,3346	3,4685	4,2813	3,9453	3,9453
5,1721	5,1721	4,6044	6,5202	3,9295	3,9295	3,4491	4,1484	4,2636	4,2636
5,0448	5,0448	4,7828	6,0482	4,3518	4,3518	5,2827	5,2827	3,2607	3,2607
4,0793	4,0793	4,8879	8,3028	4,2781	4,2781	3,3718	3,5827	4,5408	4,5408
4,2300	4,2300	5,0588	5,8281	3,7958	4,8048	5,3270	5,3270	3,6240	3,6240
6,4160	6,4160	4,6050	6,4660	3,4977	4,5309	5,7878	5,7878	4,0492	4,0492
4,1627	4,1627	6,1406	6,1406	4,3402	4,3402	4,2888	4,2888	3,5853	3,5853
5,0604	5,0604	5,4221	8,4256	3,5528	4,1674	3,4802	5,1771	3,0485	3,0485
4,7692	4,7692	3,8076	5,8458	3,8206	4,6657	3,8579	4,5794	4,3675	4,3675

Tabela G.18- Entropia (entrop_log e entrop_nor) calculada para o trecho de 30 pontos.

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
entrop_log	entrop_nor	entrop_log	entrop_nor 1.0e+003 *	entrop_log	entrop_nor 1.0e+003 *	entrop_log	entrop_nor 1.0e+003 *	entrop_log	entrop_nor 1.0e+004 *
340,0325	905,3756	176,2971	1,6099	364,0112	1,0134	171,3610	2,1883	665,0369	0,9172
160,6734	276,8394	191,8305	1,9822	277,6363	0,5920	263,2387	4,3446	667,9703	0,9130
282,6043	648,0901	183,3583	1,3136	353,4105	0,9957	137,5983	1,0748	779,4068	1,7399
319,8875	845,1875	169,8766	1,0259	267,9136	0,5536	637,4216	6,8753	813,5769	1,5895
329,9640	773,6423	156,3939	0,9269	294,5145	0,6917	178,1492	1,1736	633,6088	0,6546
193,5798	362,0755	120,8146	0,7813	176,0567	0,9879	665,5037	6,2835	661,7809	0,9016
276,8188	613,0079	193,4238	1,4918	146,4594	0,8753	624,0887	4,8337	648,3350	0,8639
226,4753	484,9516	485,3621	2,6714	390,1060	1,2201	718,5216	9,2661	854,8989	1,4321
284,6542	644,5003	134,2780	0,8038	102,4865	0,3970	232,6949	2,6895	740,3142	1,3555
308,2076	743,2071	170,3379	1,2680	127,4386	0,6346	180,1909	1,2623	640,2600	1,2536

Tabela G.19- Entropia (entrop_log e entrop_nor) calculada para o trecho de 100 pontos (1 segundo).

EEG NORMAL		EEG COM EVENTO EPILEPTOGÊNICO		EEG COM ONDA ALFA		EEG COM RUÍDO		EEG COM PISCADA	
entrop_log	entrop_nor 1.0e+003 *	entrop_log	entrop_nor 1.0e+003 *	entrop_log	entrop_nor 1.0e+003 *	entrop_log	entrop_nor 1.0e+003 *	entrop_log	entrop_nor 1.0e+004 *
340,0325	905,3756	479,1972	3,4380	364,0112	1,0134	635,3085	5,0964	665,0369	0,9172
160,6734	276,8394	601,0749	4,3744	277,6363	0,5920	678,0733	7,4130	667,9703	0,9130
282,6043	648,0901	552,5651	3,1097	353,4105	0,9957	593,3921	3,9091	779,4068	1,7399
319,8875	845,1875	508,2340	2,6693	267,9136	0,5536	637,4216	6,8753	813,5769	1,5895
329,9640	773,6423	434,2619	1,7711	294,5145	0,6917	571,6631	3,5341	633,6088	0,6546
193,5798	362,0755	482,4584	2,9965	496,6564	2,2345	665,5037	6,2835	661,7809	0,9016
276,8188	613,0079	541,6904	3,2976	456,8549	1,9323	624,0887	4,8337	648,3350	0,8639
226,4753	484,9516	485,3621	2,6714	390,1060	1,2201	718,5216	9,2661	854,8989	1,4321
284,6542	644,5003	367,9320	1,4364	428,7002	1,3709	645,4826	5,2450	740,3142	1,3555
308,2076	743,2071	546,0165	3,0314	421,7320	1,5619	588,0938	3,8772	640,2600	1,2536

G.2. Resultados da Correlação entre os Parâmetros e o Teste T^2

Observação: As abreviaturas utilizadas na Tabela G.20 e G.21 correspondem aos parâmetros utilizados no Capítulo 7, que possuem os significados relacionados abaixo:

- 1- Amax: amplitude máxima do trecho de 1 segundo, 100 pontos;
- 2- Bmin: amplitude mínima do trecho de 1 segundo, 100 pontos;
- 3- Tdif: distância entre Amax e Bmin do trecho de 1 segundo, 100 pontos;
- 4- DdifAB: diferença entre Amax e Bmin do trecho de 1 segundo, 100 pontos;
- 5- Amax_pts: amplitude máxima do trecho centrado no evento, 30 pontos;
- 6- Bmin_pts: amplitude mínima do trecho centrado no evento, 30 pontos;
- 7- Tdif_pts: distância entre Amax_pts e Bmin_pts do trecho centrado no evento;
- 8- DifAB_pts: diferença entre Amax_pts e Bmax_pts do trecho centrado no evento;
- 9- T: duração do evento;
- 10- d_{base} : base do evento, relativa a sua amplitude máxima relativa;
- 11- dpos: lado oposto ao ângulo do pico positivo;
- 12- dneg: lado oposto ao ângulo do pico negativo;
- 13- trp: distância da amplitude máxima ao extremo do evento/amplitude máxima positiva;
- 14- trn: distância da amplitude máxima ao extremo do evento/amplitude máxima negativa;
- 15- tgp: tangente do ângulo positivo;
- 16- tgn: tangente do ângulo negativo;
- 17- θ_p : ângulo positivo;
- 18- θ_n : ângulo negativo;
- 19- θ : ângulo do pico, relativo ao vértice de maior amplitude do evento;
- 20- Amax_i: amplitude máxima da região inicial do sinal;
- 21- Bmin_i: amplitude mínima da região inicial do sinal;
- 22- DifA_i: diferença em amplitude entre Amax e Amax_i;
- 23- tA-i: diferença em distância entre Amax e Amax_i;
- 24- DifB_i: diferença em amplitude entre Bmin e Bmin_i;
- 25- tB-i: diferença em distância entre Amin e Amin_i;

- 26- A_{max_f} : amplitude máxima da região final do sinal;
- 27- B_{min_f} : amplitude mínima da região final do sinal;
- 28- $DifA_f$: diferença em amplitude entre A_{max} e A_{max_f} ;
- 29- tA_f : diferença em distância entre A_{max} e A_{max_f} ;
- 30- $DifB_f$: diferença em amplitude entre B_{min} e B_{min_f} ;
- 31- tB_f : diferença em distância entre A_{min} e A_{min_f} ;
- 32- desvio: desvio padrão do trecho centrado no evento, 30 pontos;
- 33- desvioC: desvio padrão do trecho de 1 segundo, 100 pontos;
- 34- média: média do trecho centrado no evento, 30 pontos;
- 35- médiaC: média do trecho de 1 segundo, 100 pontos;
- 36- coef: coeficiente de variação do trecho centrado no evento, 30 pontos;
- 37- coefC: coeficiente de variação do trecho de 1 segundo, 100 pontos;
- 38- vari: variância do trecho centrado no evento, 30 pontos;
- 39- variC: variância do trecho de 1 segundo, 100 pontos;
- 40- CF: fator de crista do trecho centrado no evento, 30 pontos;
- 41- CFC: fator de crista do trecho de 1 segundo, 100 pontos;
- 42- entrop_{lgC}: entropia do trecho de 1 segundo, 100 pontos;
- 43- entrop_{norC}: entropia do trecho de 1 segundo, 100 pontos;
- 44- entrop_{log}: entropia do trecho centrado no evento, 30 pontos;
- 45- entrop_{nor}: entropia do trecho centrado no evento, 30 pontos.

Tabela G.20- Correlação entre 10 trechos de 100 pontos (1 segundo) dos sinais contendo o evento epileptogênico e 10 trechos dos sinais contendo os demais eventos (ondas alfa, piscadas e ruídos), calculada para os 45 parâmetros propostos.

Parâmetros	Evento Epileptogênico e Normal	Evento Epileptogênico e Onda Alfa	Evento Epileptogênico e Piscada	Evento Epileptogênico e Ruído
Amax	-0,0711	-0,3049	0,1711	0,0219
Bmin	-0,6133	0,1693	-0,6213	0,1408
Tdif	-0,0199	-0,6470	0,2177	0,4776
DifAB	-0,4489	-0,2660	-0,1360	0,0731
Amáx_pts	-0,0316	-0,1942	0,0864	0,0064
Bmin_pts	-0,6133	0,3432	0,6213	-0,0498
Tdif	0,0891	-0,3836	0,7180	-0,0329
DifAB	-0,3857	-0,2890	-0,1236	-0,3174
T	0,3018	-0,3751	0,0594	0,3450
d _{base}	0,3082	-0,1284	0,1067	-0,3467
dpos	0,1259	0,4802	-0,2796	-0,5585
dneg	0,1713	0,5926	0,0926	-0,1220
trp	-0,1351	0,2966	-0,4344	-0,4883
trn	-0,2317	-0,3996	-0,3766	-0,3103
tgp	-0,1242	0,3039	-0,4366	-0,4892
tgn	-0,1896	-0,4000	-0,3766	-0,3021
θ_p	-0,1242	0,3039	-0,4366	-0,4892
θ_n	-0,1896	-0,4000	-0,3766	-0,3021
θ	-0,2585	0,0057	-0,2976	-0,6459
Amax_i	0,3013	0,2778	0,1101	-0,5192
Bmin_i	0,1572	-0,2142	0,2365	0,1060
DifA_i	0,1229	-0,0532	-0,2647	0,0645
tA_i	-0,2647	0,4349	0,3237	0,0387
DifB_i	-0,5773	-0,0643	-0,5780	-0,0376
tB_i	0,7028	0,2200	-0,2955	-0,5093
Amax_f	-0,3374	-0,3298	-0,2630	0,1936
Bmin_f	-0,6385	-0,3729	0,2181	0,4699
DifA_f	0,0270	0,1381	0,5382	-0,2764
tA_f	-0,0675	0,2473	-0,2744	-0,6967
DifB_f	-0,4369	0,2415	-0,0786	0,0826
tB_f	0,3520	-0,2871	-0,3722	-0,4112
desvio	-0,2912	-0,3217	-0,1564	-0,4485
desvioC	-0,4967	-0,0750	-0,1164	0,2930
media	-0,1119	-0,1709	-0,2095	0,4867
mediaC	-0,3872	-0,0390	-0,1245	0,2367
coef	0,2663	-0,1588	-0,0379	0,0696
coefC	0,0712	-0,1875	-0,4023	-0,1148
vari	-0,4920	-0,1425	-0,1535	-0,0596
VariC	-0,4240	-0,0545	-0,3299	0,1710
CF	0,1064	-0,2166	-0,4183	0,0525
CFC	-0,0293	-0,3447	0,0093	-0,3034
entrop_log	0,2254	0,0121	-0,3716	-0,4224
entrop_logC	-0,3703	-0,2194	-0,1011	0,0221
entrop_nor	-0,0657	-0,1165	-0,2616	-0,3503
entrop_norC	-0,3848	-0,0306	-0,1409	0,2429

A Tabela G.21 mostra os resultados do teste estatístico T^2 calculado para os 45 parâmetros propostos. Observa-se que o valor obtido deve ser maior do que 10,3550.

Tabela G.21- Teste estatístico T^2 entre 10 trechos de 100 pontos (1 segundo) de sinais contendo o evento epileptogênico e 10 trechos dos sinais contendo ondas alfa, piscadas e ruídos.

Parâmetros	Evento Epileptogênico e Onda Alfa	Evento Epileptogênico e Piscada	Evento Epileptogênico e Ruído
Amax	26,3833	0,1595	0,5955
Bmin	35,3272	2,7082	32,3848
Tdif	12,3737	16,9378	47,2493
DdifAB	58,8915	2,4727	24,1982
Amax_ptsB	23,8865	0,0061	0,3954
Amin_pts	48,7165	0,4339	32,3848
Tdif_pts	6,5051	4,3554	71,2550
DifAB_pts	73,2664	0,2811	24,6097
T	3,9291	1,0430	175,0958
d _{base}	1,7445	1,0730	59,4783
dpos	2,5583	0,0802	5,2893
dneg	1,1538	0,0074	20,1451
trp	33,9513	1,5489	9,9547
trn	20,4326	0,5412	0,0599
tgp	36,9740	1,5405	10,1120
tgn	20,5074	0,4411	0,0579
θ_p	36,9740	1,5405	10,1120
θ_n	20,5074	0,4411	0,0579
θ	35,4247	0,0474	4,0179
desvio	54,4255	0,7246	43,0018
desvioC	38,6927	20,6652	72,4534
média	13,4444	15,1884	35,8038
médiaC	25,4041	25,2156	53,8551
coef:	19,7733	14,5052	1,8730
coefC	11,1100	4,9714	2,1371e-004
vari	24,1176	0,9923	17,0916
variC	34,1936	6,5939	20,5195
CF	8,4779	1,2901	8,4190
CFC	42,9392	20,5392	65,3808
entrop_lgC	6,7298	7,2351	333,7051
entrop_norC	5,6176	8,8814	77,8012
entrop_log	12,1881	29,4734	37,1846
entrop_nor	26,6042	23,1633	52,5071
Amax_i	2,4929	8,1060	0,0038
Bmin_i	3,3863	2,4794	1,4720
DifA_i	10,8935	3,8623	0,2564
tA-i	0,1830	0,0130	9,5959
DifB_i:	13,7384	0,0242	37,3382
tB-i	1,8579	0,0054	0,2005
Amax_f	2,1277	0,3586	0,0184
Bmin_f	2,7251	3,0400	1,9445e-004
DifA_f	14,6338	0,1350	0,4082
tA-f	2,8586	0,5088	4,4821
DifB_f	23,9849	0,0186	29,5359
tB-f	14,6338	0,1350	0,4082

ANEXO H

ALGORITMO PARA CÁLCULO DOS PARÂMETROS

1- Leitura do trecho desejado do sinal do EEG no banco de dados.

canal = trecho de 1 segundo (100 pontos) do sinal.

Canal=canal(pto_inic(sinal):pto_inic(sinal)+99,canal(sinal))

2- Cálculo do ponto máximo e mínimo. Define-se os pontos de máximo positivo e negativo, pois um destes pontos pode pertencer ao ápice do evento epileptogênico.

2.1- Calcula-se o ponto de máximo e mínimo e o instante de suas ocorrências:

Amax = [A,ta] = max(canal)

Bmin = [B,tb]= min(canal)

2.2-. Se o ápice do evento estiver nos pontos extremos ele deve ser centralizado.

SE Amax>=abs(Bmin)

SE ta<=15

sinal1_r = canal(1:33)

sinal2_r = canal(34:66)

sinal3_r = canal(67:100)

canal = [sinal3_r;sinal1_r;sinal2_r]

FIM SE

SE ta>=85

sinal1_r = canal(1:33)

sinal2_r = canal(34:66)

sinal3_r = canal(67:100)

canal = [sinal2_r;sinal3_r;sinal1_r]

FIM SE

FIM SE

SE abs(B)>A

SE tb<=15

sinal1_r = canal(1:33)

sinal2_r = canal(34:66)

sinal3_r = canal(67:100)

canal = [sinal3_r;sinal1_r;sinal2_r]

FIM SE

SE tb>=85

sinal1_r = canal(1:33)

sinal2_r = canal(34:66)

sinal3_r = canal(67:100)

canal = [sinal2_r;sinal3_r;sinal1_r]

FIM SE

FIM SE

$$[A_{max}, ta] = \max(\text{canal})$$

$$[B_{min}, tb] = \min(\text{canal})$$

3- Cálculo da diferença entre a amplitude máxima e mínima (D_{difAB}), bem como a diferença no tempo de ocorrência (T_{dif}).

$$\text{SE } ta > tb$$

$$T_{dif} = (\text{abs}(ta - tb))$$

$$\text{SENÃO}$$

$$T_{dif} = (\text{abs}(tb - ta))$$

$$\text{FIM SE}$$

$$D_{ifAB} = A_{max} - B_{min}$$

4- Cálculo do ponto máximo (A_{max_pts}) e mínimo (B_{min_pts}) centralizado no evento e os correspondentes pontos de ocorrência máximo ($tapm$) e mínimo ($tbpm$). Observa-se qual ponto possui valor absoluto máximo, A_{max} ou B_{min} . Define-se o ponto máximo ($ptmax$). Se a amplitude máxima do evento encontra dentro dos limites considerados para os eventos epileptogênicos, isto é, entre 30 a 200 μV , o trecho entre o ponto máximo é centralizado. É provável que tenha um evento epileptogênico no sinal analisado. Para focalizar este evento destaca-se um trecho do sinal formado por 15 pontos antes e 15 pontos após o ponto máximo.

4.1- Se a amplitude máxima positiva (A_{max}) for maior do que a amplitude máxima negativa (B_{min}), define-se o trecho de 30 pontos a partir de ta .

$$\text{SE } A_{max} > \text{abs}(B_{min})$$

$$\text{SE } A_{max} < 30 \text{ OU } A_{max} > 170$$

$$ptmax_pts = \text{canal}$$

$$\text{SENÃO}$$

$$ptmax_pts = \text{canal}(ta - 15 : ta + 15)$$

$$[A_{max_pts}, tapm] = \max(ptmax_pts)$$

$$[B_{min_pts}, tbpm] = \min(ptmax_pts)$$

$$D_{ifAB_pts} = A_{max_pts} - B_{min_pts}$$

$$\text{SE } tapm < tbpm$$

$$T_{dif_pts} = (tbpm - tapm)$$

$$\text{SENÃO}$$

$$T_{dif_pts} = (tapm - tbpm)$$

$$\text{FIM SE}$$

$$\text{FIM SE}$$

4.2- Se a amplitude máxima negativa (B_{min}) for maior do que a amplitude máxima positiva (A_{max}), define-se o trecho de 30 pontos a partir de tb .

$$\text{SE } \text{abs}(B_{min}) > A_{max}$$

$$\text{SE } \text{abs}(B_{min}) < 30 \text{ OU } \text{abs}(B_{min}) > 170$$

```

ptmax_pts=canal
SENÃO
ptmax_pts=canal(tb-15:tb+15)
[Amax_pts,tapm]=max(ptmax_pts)
[Bmin_pts,tbpm]=min(ptmax_pts)
DifAB_pts=Amax_pts-Bmin_pts
SE tapm<tbpm
Tdif_pts=(tbpm-tapm)
SENÃO
Tdif_pts=(tapm-tbpm)
FIM SE
FIM SE
FIM SE

```

5- Cálculo da duração do evento. A Figura H.1 mostra a duração do evento epileptogênico conforme as morfologias mais frequentes. Para o cálculo da duração do evento define-se primeiramente qual é o ponto de máximo que acontece primeiro no sinal, $Amax$ ou $Bmin$, observa-se se ta é maior ou menor que tb .

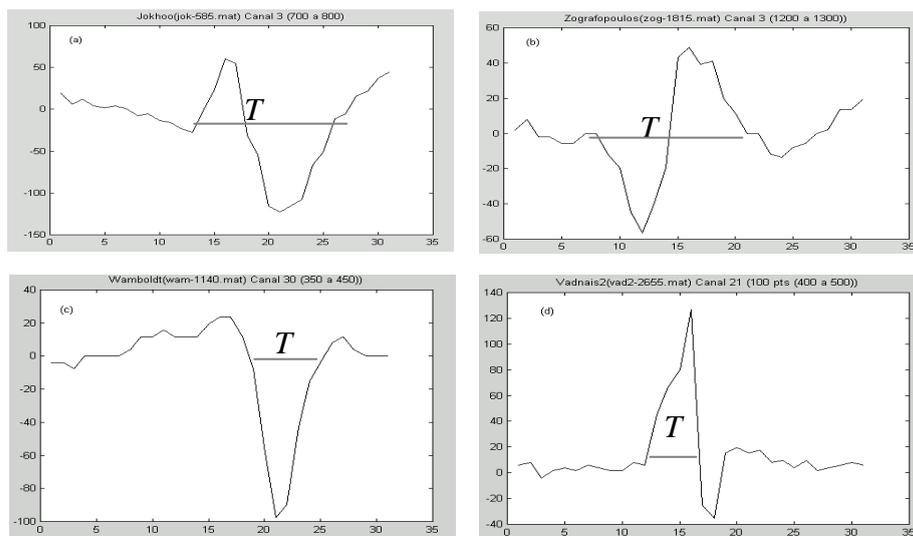


Figura H.1- Duração do evento epileptogênico (T) considerando as suas 4 morfologias básicas.

A duração do evento considera seu ponto inicial como o primeiro ponto a cruzar o eixo zero a esquerda do ponto máximo positivo ou negativo, conforme o que ocorrer primeiro. E, considera-se seu ponto final como o primeiro ponto a cruzar o eixo zero a direita do ponto máximo positivo ou negativo que ocorreu em segundo lugar. Nos casos onde o sinal não corta o eixo zero considera-se o ponto onde o sinal muda de direção, isto é, se estava decrescente torna-se crescente ou se estava crescente torna-se decrescente.

5.1- Se o ponto de máximo positivo (A_{max_pts}) ocorrer primeiro que o ponto de máximo negativo (B_{min_pts}) o valor da duração do evento (T) é calculado conforme as funções abaixo.

SE tapm < tbpm

Calcula-se a distância do início do sinal ao início do evento;

$y = ptmax_pts(tapm:-1:1)$ Trecho do início do sinal ao primeiro ponto de máximo;

$[ym, ty] = min(y)$

SE ym > 0

$jy = ty$

SENÃO

$iy = find(y <= 0)$ Obtém-se um conjunto de valores de y menores ou iguais a zero;

$jy = iy(1,1)$ Destaca-se o primeiro valor do conjunto;

FIM SE

$Tpa = tapm - jy$ Início do evento;

Calcula-se a distância do final do sinal ao final do evento;

$x = ptmax_pts(tbpm:end)$ Trecho do final do sinal ao segundo ponto de máximo;

$[xm, tx] = max(x)$

SE xm < 0

$jx = tx$

$Tpb = tbpm + jx$

SENÃO

$ix = find(x >= 0)$ Obtém-se um conjunto de valores de x menores ou iguais a zero;

$jx = ix(1,1)$ Destaca-se o primeiro valor do conjunto;

FIM SE

$Tpb = tbpm + jx$ Final do evento

Duração do evento é a diferença entre o ponto final e o ponto inicial;

$T = Tpb - Tpa$

FIM SE

5.2 - Se o ponto de máximo negativo (B_{min_pts}) ocorrer primeiro que o ponto de máximo positivo (A_{max_pts}) o valor da duração do evento (T) é calculado conforme as funções abaixo.

SE tbpm < tapm

Calcula-se a distância do final do sinal ao final do evento;

$y = ptmax_pts(tapm:end)$ Trecho do final do sinal ao segundo ponto de máximo;

$[ym, ty] = min(y)$

SE ym > 0

$jy = ty$

$Tpa = tapm + jy$

SENÃO

$iy=find(y \leq 0)$ Obtém-se um conjunto de valores de y menores ou iguais a zero;
 $jy=iy(1,1)$ Destaca-se o primeiro valor do conjunto;
FIM SE
 $Tpa=tapm+jy$ Final do evento;

Calcula-se a distância do início do sinal ao início do evento;
 $x=ptmax_pts(tbpm:-1:1)$ Trecho do início do sinal ao primeiro ponto de máximo;
 $[xm,tx]=max(x)$

SE $xm < 0$

$jx=tx$

$Tpb=tbpm-jx$

SENÃO

$ix=find(x \geq 0)$ Obtém-se um conjunto de valores de x menores ou iguais a zero;

$jx=ix(1,1)$ Destaca-se o primeiro valor do conjunto;

FIM SE

$Tpb=tbpm-jx$ Início do evento;

Duração do evento é a diferença entre o ponto final e o ponto inicial;

$T=Tpa-Tpb$;

FIM SE

6- Cálculo dos parâmetros relacionados aos ângulos dos vértices positivo e negativo do evento. Define-se como vértices os pontos de máximo e mínimo.

6.1- Cálculo do lado oposto ao ângulo de pico positivo ($dpos$) e negativo ($dneg$).

Se o ponto de máximo positivo acontecer primeiro que o ponto de máximo negativo;

SE $tapm < tbpm$:

$dpos=abs(tapm-Tpa)$: lado oposto ao ângulo do pico positivo;

$dneg=abs(Tpb-tbpm)$: lado oposto ao ângulo do pico negativo;

SENÃO: o ponto de máximo negativo acontece primeiro que o ponto de máximo positivo;

$dpos=abs(Tpa-tapm)$;

$dneg=abs(tbpm-Tpb)$;

FIM SE

6.2- Cálculo de trp , isto é, a relação obtida pela distância da amplitude máxima ao extremo do evento/amplitude máxima positiva. Cálculo de trn , isto é, a relação calculada pela distância da amplitude máxima ao extremo do evento / amplitude máxima negativa.

$trp=abs((dpos)/Amax_pts)$

$trn=abs((dneg)/abs(Bmin_pts))$

6.3- Cálculo da tangente do ângulo positivo (tgp) e negativo (trn).

$tgp=atan(trp)$

$tgn=atan(trn)$

6.4- Cálculo dos ângulos positivo (q_p) e negativo (q_n) e ângulo de pico, relativo ao vértice de maior amplitude do evento.

$$q_p = \text{tg}p * (180/\pi)$$

$$q_n = \text{tg}n * (180/\pi)$$

SE $q_p > q_n$
 $q = \text{ang}n * 2;$
 SENÃO
 $q = \text{ang}p * 2;$
 FIN SE

6.5- Cálculo da base do evento (d_{base}).

Se amplitude máxima é maior que a mínima;

SE $A_{max_pts} > \text{abs}(B_{min_pts})$

SE $tapm < tbpm$
 $canalpm = ptmax_pts(tapm:tbpm)$

E, se a amplitude máxima ocorre primeiro;
 Trecho central entre o ponto de máximo e de mínimo;

$[hpmed, thpmed] = \text{min}(canalpm)$

SE $hpmed > 0$

$ptpm = thpmed$

SENAO

$cpm = \text{find}(canalpm <= 0)$ Define-se o ponto onde o trecho central corta o eixo zero;

$ptpm = cpm(1,1)$

FIM SE

$ptbase = tapm + ptpm$

$d_{base} = \text{abs}(ptbase - Tpa)$

Define-se o trecho entre a ocorrência do ponto de máximo e o ponto onde o trecho central corta o eixo zero;
 Base do evento

SENAO

$canalpm = ptmax_pts(tbpm:tapm)$

Ou se a amplitude mínima ocorre primeiro;
 Trecho central entre o ponto de máximo e de mínimo;

$[hnmed, thnmed] = \text{max}(canalpm)$

SE $hnmed < 0$

$ptpm = thnmed$

SENAO

$cpm = \text{find}(canalpm >= 0)$ Define-se o ponto onde o trecho central corta o eixo zero.

$ptpm = cpm(1,1)$

FIM SE

$ptbase = tapm - ptpm$

$d_{base} = \text{abs}(Tpa - ptbase)$

Define-se o trecho entre a ocorrência do ponto de máximo e o ponto onde o trecho central corta o eixo zero;
 Base do evento;

FIM SE

FIM SE

Se a amplitude mínima é maior que a máxima;

SE $\text{abs}(B_{min_pts}) > A_{max_pts}$

SE $tapm < tbpm$
 $canalpm = ptmax_pts(tapm:tbpm)$

E, se a amplitude máxima ocorre primeiro;

$[hpmed, thpmed] = \text{min}(canalpm)$

SE $hpmed > 0$

$ptpm = thpmed$

SENAO

$cpm = \text{find}(canalpm <= 0)$

$ptpm=cpm(1,1)$
 FIM SE
 $ptbase=tbpm-ptpm$
 $d_{base}=abs(Tpb-ptbase)$

Base do evento;

SENÃO

Ou se a amplitude mínima ocorre primeiro;

$canalpm=ptmax_pts(tbpm:tapm)$
 $[hnmed,thnmed]=max(canalpm)$
 SE $hnmed<0$

$ptpm=thnmed$

SENÃO

$cpm=find(canalpm>=0)$

$ptpm=cpm(1,1)$

FIM SE

$ptbase=tbpm+ptpm$

$d_{base}=abs(ptbase-Tpb)$

Base do evento;

FIM SE

FIM SE

7- Cálculo dos parâmetros relacionados à distância entre os pontos de máximo positivo e negativo. Divide-se o sinal no trecho inicial e final.

SE $ta<tb$
 negativa;

Se a amplitude máxima positiva ocorre primeiro que a

$tapt=ta-dpos$

Define-se região inicial

SE $(tb+dneg)>=99$

$tbpt=(tb+dneg)-15$

SENÃO

$tbpt=tb+dneg$

Define-se região final

FIM SE

$[Amax_i,tati]=max(canal(1:tapt))$

Trecho entre o ponto máximo positivo e o início do evento e seus pontos de máximo e mínimo;

$[Bmin_i,tbti]=min(canal(1:tapt))$

Diferença em amplitude e distancias entre os pontos de máximos da região inicial;

$DifA_i=Amax-Amax_i$

$tA_i=(ta-tati)$

Diferença em amplitude e distancias entre os pontos de mínimos da região inicial;

$DifB_i=Bmin-Bmin_i$

$tB_i=(tb-tbti)$

$[Amax_f,tatf]=max(canal(tbpt:end))$

Trecho entre o ponto de máximo positivo e fim do evento e seus pontos de máximo e mínimo;

$[Bmin_f,tbtf]=min(canal(tbpt:end))$

Diferença em amplitude e distancias entre os pontos de máximos da região final;

$DifA_f=Amax-Amax_f$

$tA_f=(tatf-ta)$

Diferença em amplitude e distancias entre os pontos de mínimos da região final;

$DifB_f=Bmin-Bmin_f$

$tB_f=(tbtf-tb)$

FIM SE

SE $tb<ta$

Se a amplitude máxima negativa ocorre primeiro que a positiva;

$tbpt=tb-dneg$

Define-se a região inicial

SE $(ta+dpos)>=99$

$$tapt=(ta+dpos)-15$$

SENÃO

$$tapt=ta+dpos$$

Define-se a região final

FIM SE

$$[Amax_i,tati]=max(canal(1:tbpt))$$

$$[Bmin_i,tbti]=min(canal(1:tbpt))$$

Trecho entre o ponto de máximo negativo e o início do evento e seus pontos de máximo e de mínimo;

$$DifA_i=Amax-Amax_i$$

$$tA_i=(ta-tati))$$

$$DifB_i=Bmin-Bmin_i;$$

$$tB_i=(tb-tbti)$$

Diferença em amplitude e distâncias entre os pontos de máximos da região inicial;
Diferença em amplitude e distâncias entre os pontos de mínimos da região inicial;

$$[Amax_f,tatf]=max(canal(tapt:end))$$

$$[Bmin_f,tbtf]=min(canal(tapt:end))$$

$$DifA_f=Amax-Amax_f$$

$$tA_f=(tatf-ta)$$

Trecho entre o ponto de máximo negativo e fim

Diferença em amplitude e distâncias entre os pontos de mínimos e de máximos da região final;

$$DifB_f=Bmin-Bmin_f$$

$$tB_f=(tbtf-ta)$$

FIM SE

8- Cálculo dos parâmetros relacionados aos dados estatísticos.

8.1- Cálculo do desvio padrão sobre o trecho de 100 pontos do canal (*desvioC*) e 30 pontos centrados no evento (*desvio*).

$$desvioC = std(canal)$$

$$desvio = std(ptmax_pts)$$

8.2- Cálculo do fator de crista sobre o trecho de 100 pontos do canal (*CFC*) e 30 pontos centrados no evento (*CF*).

$$CFC=(DifAB)/desvioC$$

$$CF=(DifAB_pts)/desvio$$

8.3- Cálculo da média sobre o trecho de 100 pontos do canal (*mediaC*) e 30 pontos centrados no evento (*media*).

$$mediaC=mean(abs(canal))$$

$$media=mean(abs(ptmax_pts))$$

8.4- Cálculo do coeficiente de variação sobre o trecho de 100 pontos do canal (*coefC*) e 30 pontos centrados no evento (*coef*).

$$coefC=desvioC/mediaC$$

$$coef=desvio/media$$

8.5- Cálculo da variância sobre o trecho de 100 pontos do canal (*variC*) e 30 pontos centrados no evento (*vari*).

```
variC=var(abs(canal));  
vari=var(abs(ptmax_pts));
```

9- Cálculo dos parâmetros relacionados à Entropia.

```
entrop_log=wentropy(ptmax_pts,'log energy');  
entrop_nor=wentropy(ptmax_pts,'norm',1.1);  
entrop_logC=wentropy(canal,'log energy');  
entrop_norC=wentropy(canal,'norm',1.1);
```

Referências Bibliográficas

- [1] ARGOUD, F. I. M. *Contribuição ao Estudo da Automatização da Detecção e Análise de Eventos Epileptiformes em Eletroencefalograma*, Tese de Doutorado, Universidade Federal de Santa Catarina, Instituto de Engenharia Biomédica, Florianópolis, 2001.
- [2] GOTMAN, J.; GLOOR, P. Automatic Recognition and Quantification of Interictal Epileptic Activity in the Human Scalp EEG, *Electroencephalography and Clinical Neurophysiology*, vol. 41, pp. 513 – 529, 1976.
- [3] GOTMAN, J. Automatic Recognition of Epileptic Seizures in the EEG, *Electroencephalography and Clinical Neurophysiology*, vol.54, pp. 530 – 540, 1982.
- [4] BOKEHI, J. B.; SIMPSON, D. M.; INFANTOSI, A. F. Análise Espectral de Sinais EEG Utilizando Modelagem Auto-Regressiva. *RBE: Caderno de Engenharia Biomédica*, vol.(9)2,pp. 5-21, 1994.
- [5] MUTHUSWAMY, J.; THAKOR, N. V. Spectral Analysis Methods for Neurological Signals, *Journal of Neuroscience Methods*, vol. 83, pp. 1-14, 1998.
- [6] KONG, X.; BRAMBRINK, A.; HANLEY, D. F.; THAKOR, N. V. Quantification of Injury-Related EEG Signal Changes Using Distance Measures. *IEEE Transactions on Biomedical Engineering*, vol. (46)7, pp. 899-901, 1999.
- [7] BLANCO S.; QUIROGA, R.Q.; ROSSO, O. A.; KOCHEN, S. Time-Frequency Analysis of Electroencephalogram Series. *Physical Review*, vol(51), 3, pp. 2624-2631, 1995.
- [8] WENDLING, F.; SHAMSOLLAHI, M. B.; BADIÉ, J.M.; BELLANGER, J. J. Time-Frequency Matching of Warped Depth-EEG Seizure Observations. *IEEE Transactions on Biomedical Engineering*, vol. (46)5, pp. 601-605, 1999.
- [9] BARANIUK, R. G.; COATES, M.; STEEGHS, P. Hybrid Linear/Quadratic Time-Frequency Attributes. *TNO Physics and Electronics Laboratory*, vol. 96864, pp. 1-15, 2001.
- [10] QUIROGA, R. Q. *Quantitative Analysis of EEG Signals: Time-Frequency Methods and Chaos Theory*. These (PhD), Institute of Physiology, Medical University Lübeck and Institute of Signal Processing, Medical University Lübeck, 1998.
- [11] PETROSIAN, A.; PROKHOROV, D.; HOMAN. R.; DASHEIFF, R.; WUNSH, D. Recurrent Neural Network Based Prediction of Epileptic Seizures in Intra- and Extracranial EEG. *Neurocomputing*, vol. 30, pp. 201-218, 2000.

- [12] GEVA, A. B.; KEREM, D. H. Forecasting Generalized Epileptic Seizures from the EEG Signal by Wavelet Analysis and Dynamic Unsupervised Fuzzy Clustering. *IEEE Transactions on Biomedical Engineering*, vol (45)10, pp. 1205-1215, 1998.
- [13] WALCZAK, S.; NOWACK, W. J. An Artificial Neural Network Approach to Diagnosing Epilepsy Using Lateralized Bursts of Theta EEGs. *Journal of Medical Systems*, Vol. (25), 1, pp.1-22, 2000.
- [14] MATSUMOTO, Y. M.; OKAZAKI, K., *et. al.* Visualization of Epileptogenic Phenomena Using Cross-Correlation Analysis: Localization of Epileptic Foci and Propagation of Epileptiform Discharges. *IEEE Transactions on Biomedical Engineering*, vol. (46)3, pp. 271-279, 1999.
- [15] KANEKO, H.; SUZUKI, S. S.; AKAMATSU, M. Multineuronal Spike Classification Based on Multisite Electrode Recording, Whole-Waveform Analysis, and Hierarchical Clustering. *IEEE Transactions on Biomedical Engineering*, vol. (46)3, pp. 280-290, 1999.
- [16] ESTELLER, R. *Detection of Seizure Onset in Epileptic Patients from Intracranial EEG Signal*. These, School of Electrical and Computer Engineering Georgia Institute of Technology, 1999.
- [17] GUYTON, A. C. *Tratado de Fisiologia Médica*. Editora Interamericana, 1984.
- [18] LENT, R. *Cem Bilhões de Neurônios*. Editora Atheneu, 2002.
- [19] NIEDERMEYER, E.; SILVA F. L. *Electroencephalography Basic Principles, Clinical Applications, and Related Fields*. Williams & Wilkins, 1993.
- [20] GUERREIRO, C. A. M.; GUERREIRO, M. M. *Epilepsia*, Editora Lemos, 1993.
- [21] LOMBROSO, C. T. Crises Convulsivas Neonatais: Uma Visão do Clínico. *Brazilian Journal of Epilepsy and Clinical Neurophysiology*. vol. 2(3), pp. 143-166, 1996.
- [22] WENDLING, F.; BADIÉ J. M. Clinical Engineering in Neurophysiology: an Object-Oriented Platform for Signal Visualization and Processing. *Journal of Clinical Engineering*, vol. (23)3, pp.189-194, 1998
- [23] OHTAHARA, S.; OKA, E., YAMATOIGI, Y. A Epidemiologia da Epilepsia. *Brazilian Journal of Epilepsy and Clinical Neurophysiology*. vol. 4(1), pp. 13-19, 1998.
- [24] DEVULAPALLI, S. *Non-linear Principal Component Analysis and Classification of EEG during Mental Tasks*. These, Colorado State University, Department of Computer Science, 1996.

- [25] KLÖPPEL B. Neural Networks as a New Method for EEG Analysis. *Pharmacoelectroencephalography*, Main Editor: W. M. Herrmann, Berlin, 1994.
- [26] KLÖPPEL B. Application of Neural Networks for EEG Analysis. *Pharmacoelectroencephalography*, Main Editor: W. M. Herrmann, Berlin, 1994.
- [27] KLÖPPEL B. Classification by Neural Networks of Evoked Potentials. *Pharmacoelectroencephalography*, Main Editor: W. M. Herrmann, Berlin, 1994.
- [28] COIMBRA, A. J. F.; MARINO, J.; AZEVEDO, F. M.; FREITAS, C. G.; BARRETO J. M. Electrographic Analysis of Brain State Using Neural Networks. *Word Congress on Medical Physics and Biomedical Engineering*, pp. 21-26, R. J. 1994.
- [29] KOPRINSKA, I.; PFURTSCHELLER, G; FLOTZINGER D. Sleep Classification in Infants by Decision Tree-Based Neural Networks. *Artificial intelligence in Medicine*, vol. 8, pp. 387-401, 1996.
- [30] SIREGAR, P.; SINTEFF, J. P. Introducing Spatio-Temporal Reasoning into the Inverse Problem in Electroencephalography. *Artificial intelligence in Medicine*, vol.8, pp. 97-122, 1996.
- [31] LENGELLÉ, R.; DENCEUX, T. Training MLPs Layer by Layer Using an Objective Function for Internal Representations. *Neural Networks*, vol. (9)1, pp. 83-97, 1996.
- [32] KALCHER, J.; FLOTZINGER, D.; NEUPER, C.; GÖLLY S.; PFURTSCHELLER G. Graz Brain-Computer Interface II: Towards Communication Between Humans and Computers Based on Online Classification of Three Different EEG Patterns. *IFMBE:1996 Medical & Biomedical Engineering & Computing*, pp. 382-388, 1996.
- [33] STEUER, D.; SCHACK, B.; GRIESZBACH, G.; KRAUSE, W. Single-Trial Classification of Elementary Cognitive Processes by Neural Networks. *Proceedings of the EMBEC'99, Biosignal Processing*, pp. 422-423, 1999.
- [34] RODRIGUES, M. A. B. – *Sistemas para Detecção e Classificação Automática de Apnéias do Sono a partir de Registros Polissonográficos*. Exame de Qualificação, IEB, UFSC, 1999.
- [35] PILLA, V. J.; LOPES, H. S., Pattern Recognition in Electroencephalographic Signals Using LVQ Neural Networks. *Relatório Interno do Laboratório de Eletrônica e Bioinformática-CEFET-PR*, pp. 1-6, 2001.
- [36] ARGOUD, F. I. M.; AZEVEDO, F. M.; NETO, M.; BITTENCOURT P. T. Development of an Automatic System of Detection and Classification of Epileptiform

- Events in EEG. *Proceedings of the EMBEC '99/EMBECE; Biosignal Processing*, pp. 490-491, 1999.
- [37] KIM, K. H.; KIM, S. J. Neural Spike Sorting Under Nearly 0-dB Signal-to-Noise Ratio Using Nonlinear Energy Operator and Artificial Neural-Network Classifier. *IEEE Transactions on Biomedical Engineering*, vol. (47)10, pp. 1406-1411, 2000.
- [38] LITT, B.; *et. al.*, Epileptic Seizures May Begin Hours in Advance of Clinical Onset: a Report of Five Patients. *Neuron*, vol(30), pp. 51-64, 2001.
- [39] HAYKIN, S. *Redes Neurais Princípios e Prática*, Editora Bookman, 1999.
- [40] FREEMAN, J. A.; SKAPURA, D. M., *Redes Neuronales Algoritmos, Aplicaciones y Técnicas de Programación*. Editora Addison-Wesley, 1993.
- [41] AZEVEDO, F. M. Uma Proposta de Modelos Formais de Neurônios e Redes Neurais Artificiais. *III Congresso Brasileiro de redes Neurais*, Florianópolis, 1997.
- [42] AZEVEDO, F. M.; BRASIL; L.M.; OLIVEIRA R. C. L. *Redes Neurais com Aplicações em Controle e em Sistemas Especialistas*, Editora Visual Books, Florianópolis, 2000.
- [43] DE AZEVEDO, F. M.; BARRETO, J. M. A Neural Network approach for expert system. In: *World Congress on Medical Physics and Biomedical Engineering*. Rio de Janeiro, RJ, 1994, p. PS17-18, 446.
- [44] DEMUTH, H.; BEALE, M. *Neural Network Toolbox for Use with MATLAB*. Math Works, Inc, 1998.
- [45] BARRETO, J. M.; AZEVEDO, F. M.; LIMA, W.C. Internal Model Construction Using Feedforward Neural Networks: the Case of a Second Order System. In: *11th BENELUX Meeting on System and Control, Veldhoven, Holanda*, p. 6, 1992.
- [46] BARRETO, J. M. Redes Neurais: Aspectos Matemáticos e Computacionais. *Anais Sociedade Brasileira de Matemática Aplicada e Computacional (SBMAC)*, 1996.
- [47] DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*, John Wiley & sons, Inc, 2000.
- [48] NASCIMENTO, C. L.; YONEYAMA, T. *Inteligência Artificial em Controle e Automação*, FAPESP Editora Edgard Blücher, 2000.
- [49] CARVALHO, L. F.; CARVALHO, H. T.; AZEVEDO, F. M.; NASSAR, S. M. Um Sistema de Auxílio ao Diagnóstico Clínico, *XVI Congresso de Engenharia Biomédica*, Curitiba, 1998.

- [50] LUO, F. L.; UNBEHAUEN, R. *Applied Neural Networks for Signal Processing*, Cambridge University Press, 1998.
- [51] HU, Y. H.; HWANG, J. N. *Handbook of Neural Network Signal Processing*. CRC PRESS, 2002.
- [52] WISBECK, J. O. *Técnicas Híbridadas de Processamento de Sinais Biomédicos Implementadas com Redes Neurais Artificiais*, Tese de Doutorado, Universidade Federal de Santa Catarina, CTC, Engenharia Elétrica, Florianópolis, 2000.
- [53] SILVA, A. O. *Sistema de Classificação de Sinais Eletrocardiográficos para Detecção de Anormalidades do Sistema Condutor Cardíaco Utilizando Redes Neurais Artificiais*”, Dissertação Apresentada na Universidade Federal de Uberlândia, Centro de Ciências Exatas e Tecnologia, Novembro, 1999.
- [54] PINNA, G. D.; *et all.* The Accuracy of Power-Spectrum Analysis of Heart-Rate Variability from Annotated RR Lists Generated by Holter Systems. *Physiol. Meas.*, vol. 15, pp. 163-179, 1994.
- [55] CHEN, K. M.; HUANG, Y.; ZHANG, J.; NORMAN, A. Microwave Life-Detection Systems for Searching Human Subjects Under Earthquake Rubber or Behind Barrier, *IEEE Transactions on Biomedical Engineering*, vol. 27, N° 1, pp. 105-113, January, 2000.
- [56] BRENNAN, M.; PALANISWAMI, M.; KAMEN, P. Distortion Properties of the Interval Spectrum of IPFM Generated Heartbeats for Heart Rate Variability Analysis, *IEEE Transactions on Biomedical Engineering*, vol. 48, n° 11, pp. 1251-1264, November, 2001.
- [57] MINAMI, K. I.; NAKAJIMA, H.; TOYOSHIMA, T. Real-Time Discrimination of Ventricular Tachyarrhythmia with Fourier-Transform Neural Network, *IEEE Transactions on Biomedical Engineering*, vol. 46, n° 2, pp. 170-185, February, 1999.
- [58] GLARIA, A.; MURRAY, A. Evaluation During Surgery of Different Techniques of Electroencephalographic Monitoring, *8° Congresso Brasileiro de Engenharia Biomédica*, Florianópolis, pp. 161-169, Novembro, 1983.
- [59] SIMPSON, D. M.; VIEIRA, M. H. B. Data Windows and Mean Removal in Spectral Estimation, *I Fórum Nacional de Ciência e Tecnologia em Saúde*, pp. 249-252, 1992.
- [60] FERDJALLAH, M.; BARR, R. E. Enhanced Period-peak Analysis of Electroencephalograms Using a Fast Sinc Function, *Medical & Biological Engineering & Computing*, pp. 431-435, November, 1996.

- [61] GAROOSI V.; JANSEN, B. H. Development and Evaluation of the Piecewise Prony Method for Evoked Potential Analysis, *IEEE Transactions on Biomedical Engineering*, vol. 47, nº 12, pp. 1549-1554, December, 2000.
- [62] HANSSON, M.; LINDGREN, M. Multiple-Window Spectrogram of Peaks due to Transients in the Electroencephalogram, *IEEE Transactions on Biomedical Engineering*, vol. 48, nº 3, pp. 284-293, March, 2001.
- [63] CELKA, P.; COLDITZ, P. A Computer-Aided Detection of EEG Seizures in Infants: A Singular-Spectrum Approach and Performance Comparison, *IEEE Transactions on Biomedical Engineering*, vol. 49, nº 5, pp. 455-462, May, 2002.
- [64] RAMOS, E. G.; *et al.* Identificação Objetiva no Domínio da Frequência da Resposta à Fotoestimulação Repetitiva, *Fórum Nacional de Ciência e Tecnologia em Saúde*, pp. 539-540, R.J., 1996.
- [65] RAMOS, E. G., *et al.* Avaliação Preliminar de um Método de Detecção Objetiva da Resposta Auditiva no EEG de Crianças, *Fórum Nacional de Ciência e Tecnologia em Saúde*, pp. 435-436, Curitiba, 1998.
- [66] ORTOLANI, O. *et al.* Automatic Intravenous Anaesthesia Delivery by Means of EEG Signal Processing and Control, *Proceedings of the EMBEC' 99, Biosignal Processig*, pp. 428-429, Novembro, 1999.
- [67] REZEK, I., *et al.* Complexity Features for Sleep Stage Analysis, *Proceedings of the EMBEC' 99*, pp. 1650-1651, 1999.
- [68] CONRADT, R.; PENZEL, T.; BRANDENBURG, U.; PETER, J. H. Description of Vigilance in the EEG During Reaction Time Test in Patients with Sleep Apnea, *Proceedings of the EMBEC' 99*, pp. 414-415, 1999.
- [69] AKAY, M. *Detection and Estimation Methods for Biomedical Signals*. Academic Press, Inc, 1996.
- [70] COHEN, A. *Biomedical Signal Processing, Vol. II, Compression and Automatic Recognition*. CRC Press, Inc, Boca Raton, Florida, 1986.
- [71] HAYKIN, S.; VEEN B. V. *Sinais e Sistemas*, Bookman, 2001
- [72] KRANIAUSKAS, P. *Transforms in Signals and Systems*, Addison-Wesley,
- [73] OPPENHEIM; ALAN, V. E.; SCHAFER, R. W. *Digital Signal Processing*. Englewood Cliffs, New Jersey: Prentice-Hall.
- [74] POULARIKAS, A. *The Transforms and Applications Handbook*. CRC Press. Inc., 1996.

- [75] TOMPKINS, W. J. *Biomedical Digital Signal Processing*, Prentice Hall, 1993
- [76] INGLE, V. K.; PROAKIS J. G. *Digital Signal Processing*. Brooks/Cole, 2000.
- [77] KRAUSS, T. P.; SHURE, L.; LITTLE, J. N. *Signal Processing Toolbox*, Math Works Inc. 1996.
- [78] SIQUEIRA, J. C. G. *Tópicos de Matemática Aplicada (E 703/803)*. Escola Federal de Engenharia de Itajubá.
- [79] GOMES, J.; VELHO, L.; GOLDENSTEIN, S. Wavelets: Teoria, Software e Aplicações. *21º Colóquio Brasileiro de Matemática – IMPA*, 1997.
- [80] HAYKIN, S. *Adaptive Filter Theory*, Prentice Hall, Inc, 1996.
- [81] COHEN, A. *Biomedical Signal Processing, Vol. I, Compression and Automatic Recognition*. CRC Press, Inc, Boca Raton, Florida, 1986.
- [82] BERGERY, G. K.; FRANASZCZUK P. J. Epileptic Seizures are Characterized by Changing Signal Complexity, *Johns Hopkins University School of Medicine*, Baltimore, 2002.
- [83] QUIROGA, R. Q.; BLANCO, S.; ROSSO, O. A.; GARCIA, H.; RABINOWICZ, A. Searching for Hidden Information with Gabor Transform in Generalized Tonic-Clonic Seizures, *ELSEVIER: Electroencephalography and Clinical Neurophysiology*, vol. 103, pp. 434-439, 1997.
- [84] OSORIO, I.; FREI, M. G.; WILKINSON, S. B. Real-Time Automated Detection and Quantitative Analysis of Seizures and Short-Term Prediction of Clinical Onset. *Epilepsia*, vol. 39, nº 6, pp. 615-627, 1998.
- [85] WENDLING, F.; SHAMSOLLAHI, M. B.; BADIÉ, J. M.; BELLANGER, J. J. Time-Frequency Matching of Warped Depth-EEG Seizure Observations, *IEEE Transactions on Biomedical Engineering*, vol. 46, nº 5, pp. 601-605, May, 1999.
- [86] XU, Y.; HAYKIN, S.; RACINE, R. J. Multiple Window Time-Frequency Distribution and Coherence of EEG Using Slepian Sequences and Hermite Functions, *IEEE Transactions on Biomedical Engineering*, vol. 46, nº 7, pp. 861-865, July, 1999.
- [87] ARGOUD, F. I. M. *Detecção e Reconhecimento Automático de Atividades Epileptiformes no Encefalograma*. Exame de Qualificação, UFSC, GPEB, Florianópolis, 1998.
- [88] KIM, T.; ADALI, T. Fully Complex Multi-Layer Perceptron Network for Nonlinear Signal Processing. *Journal of VLSI Signal Processing*, vol. 32, pp. 29-43, 2002.

- [89] NITTA, T. An Extension of the Back-Propagation Algorithm to Complex Numbers, *Neural Networks*, vol 10, no 8, pp. 1391-1415, Elsevier Science Ltda, 1997.
- [90] JARGON, J. A.; GUPTA, K. C. Artificial Neural Network Modeling for Improved On-Wafer Line-Reflect-Match Calibrations, *31 st European Microwave Conference Proceedings*, vol. 2, pp 229-232, London, England, 2001.
- [91] MISITI, M.; MISITI, Y.; OPPENHEIM, G.; POGGI, J. M. *Wavelet Toolbox for Use with Matlab*, 2001.
- [92] DIAMBRA, L.; FIQUEIREDO, J.C.B.; MALTA, C.P. *Epileptic Activity Recognition in EEG Recording*, Universidade de São Paulo, 2001.
- [93] ACCARDO, A. P.; Turchet F. Wavelet-Based Algorithm for the Compression de EEG Signals, *Proceedings, EMBEC*, pp. 476-477, 1999.
- [94] BARRETO, A.; CHIN, N.; ADRIAN, J.; RILEY, J. *Multiresolution Characterization of Interictal Epileptic Spikes Based on a Wavelet Transformation*, University Park, Miami, Florida, pp. 1-7, 2001.
- [95] GEVA, A. B.; PRATT, H.; ZEEVI, Y. Y. Multichannel Wavelet-Type Decomposition of Evoked Potentials: Model-Based Recognition of Generator Activity. *Medical & Biomedical Engineering & Computing*, pp. 40-46, 1997.
- [96] MASON, S. G.; BIRCH, G. E. A Brain-Controlled Switch for Asynchronous Control Applications, *IEEE Transactions on Biomedical Engineering*, vol. 47, n° 10, pp. 1297-1306, 2000.
- [97] KIM, J. H. The Classification of Visual Stimulus Using Wavelet Transform from EEG Signal. <http://bme.inje.ac.kr/~kjh91/paper02/Isoes.htm>, pp 1-9.
- [98] WEBBER, W. R. S.; LITT, B.; WILSON, K.; LESSER, R. P., Practical Detection of Epileptiform Discharges (EDs) in the EEG Using an Artificial Neural Network: a Comparison of Raw and Parameterized EEG Data. *Electroencephalography and Clinical Neurophysiology*, vol. 91, pp. 194-204, 1994.
- [99] LUO, Q. Classification of Epileptic Clinical Seizures and Subclinical Seizures. pp. 1-11, 2001.
- [100] MARCHESI, B; STELLE, A. L.; LOPES, H. S., Detection of Epileptic Events Using Genetic Programming. *19th International Conference, IEEE/EMBS*, Chicago, USA, pp. 1198-1201, 1997.

- [101] COIMBRA, A. J. F.; MARINO J.; FREITAS, C. G.; AZEVEDO, F. M., BARRETO, J. M. Automatic Detection of Sleep-Waking States Using Kohonen Neural Networks. *1º Congresso Brasileiro de Redes Neurais*, Itajubá, pp. 327-331, 1994.
- [102] GALHANONE, P. R.; INFANTOSI, A. F. C.; SIMPSON D. M. Análise de Discriminante de Padrões Eletrográficos do Ciclo Sono-Vigília Neonatal. *Fórum Nacional de Ciência e Tecnologia em Saúde*, pp. 535-536, Campos do Jordão, 1996.
- [103] MUTHUSWAMY, J.; SHERMAN D. L.; THAKOR, N. V. Higher-Order Spectral Analysis of Burst Patterns in EEG. *IEEE Transactions on Biomedical Engineering*, vol. (46)1, pp. 92-98, 1999.
- [104] JOHNSON, R. A.; WICHERN, D. W., *Applied Multivariate Statistical Analysis*. Prentice-Hall, 1998.
- [105] GARCIA, A. L. *Probability and Random Processes for Electrical Engineering*. Addison-Wesley, 1994.
- [106] BEIGUELMAN, B. *Bioestatística*, FUNPEC Editora, 2002.
- [107] WILSON, S. B.; EMERSON, R. Spike Detection: a Review and Comparison of Algorithms. *Clinical Neurophysiology*, vol. 113, pp. 1873-1881, 2002.