

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

Geovani Rodrigo Scolaro

**SISTEMA COMPUTACIONAL AUTOMATIZADO
PARA A IDENTIFICAÇÃO E CONTAGEM
DE EVENTOS EPILEPTIFORMES EM SINAIS
DE ELETROENCEFALOGRAFIA DE LONGA DURAÇÃO**

Florianópolis
2014

Geovani Rodrigo Scolaro

**SISTEMA COMPUTACIONAL AUTOMATIZADO
PARA A IDENTIFICAÇÃO E CONTAGEM
DE EVENTOS EPILEPTIFORMES EM SINAIS
DE ELETROENCEFALOGRAFIA DE LONGA DURAÇÃO**

Tese submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina para a obtenção do Grau de Doutor em Engenharia Elétrica.

Orientador: Prof. Dr. Fernando Mendes de Azevedo

Coorientador: Prof. Dr. Roger Walz

Florianópolis
2014

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Scolaro, Geovani Rodrigo

Sistema Computacional Automatizado para a Identificação
e Contagem de Eventos Epileptiformes em Sinais de
Eletroencefalografia de Longa Duração / Geovani Rodrigo
Scolaro; orientador, Fernando Mendes de Azevedo;
coorientador, Roger Walz. - Florianópolis, SC, 2014.
195 p.

Tese (doutorado) - Universidade Federal de Santa
Catarina, Centro Tecnológico. Programa de Pós-Graduação em
Engenharia Elétrica.

Inclui referências

1. Engenharia Elétrica. 2. Eletroencefalograma. 3.
Processamento de Sinais. 4. Transformada Wavelet. 5.
Filtro. I. Azevedo, Fernando Mendes de. II. Walz, Roger.
III. Universidade Federal de Santa Catarina. Programa de
Pós-Graduação em Engenharia Elétrica. IV. Título.

Geovani Rodrigo Scolaro

**SISTEMA COMPUTACIONAL AUTOMATIZADO
PARA A IDENTIFICAÇÃO E CONTAGEM
DE EVENTOS EPILEPTIFORMES EM SINAIS
DE ELETROENCEFALOGRAFIA DE LONGA DURAÇÃO**

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.

Florianópolis, 17 de dezembro de 2014.

Prof. Carlos Galup Montoro, Dr.
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica.

Banca Examinadora:

Prof. Fernando Mendes de Azevedo, Dr.
Orientador
Universidade Federal de Santa Catarina

Banca Examinadora (continuação):

Prof.^a Daniela Ota Hisayasu Suzuki, Dr.^a
Universidade Federal de Santa Catarina

Prof. Jefferson Luiz Brum Marques, Ph.D.
Universidade Federal de Santa Catarina

Prof.^a Fernanda Isabel Marques Argoud, Dr.^a
Instituto Federal de Santa Catarina - IFSC

Prof. Cairo Lúcio Nascimento Junior, Ph.D.
Instituto Tecnológico da Aeronáutica - ITA

Prof. Rudimar Luís Scaranto Dazzi, Dr.
Universidade do Vale do Itajaí - UNIVALI

Dedico à minha família...

AGRADECIMENTOS

Agradecimentos a minha família pelo apoio e pela compreensão nos muitos momentos em que estive “ausente” no período do doutorado, em especial à minha esposa Milene, por estar sempre ao meu lado e ao meu filhote Enzo, a razão de tudo que eu faço e tudo o que eu sou.

Agradecimentos ao prof. Fernando Mendes de Azevedo pela sua orientação, amizade, paciência e pelos seus ensinamentos, não só os “didáticos”, mas também os da vida, sendo um exemplo de pessoa e de caráter a ser seguido, meu eterno obrigado.

Agradecimentos ao prof. Roger Walz e aos integrantes do CEPESC por me proporcionar um amplo conhecimento em relação à epilepsia, através das suas experiências e dos seus ensinamentos, permitindo com que esse trabalho fosse concluído com êxito.

Agradecimentos aos professores Fernanda, Jefferson, Marino, Renato e Daniela pela amizade, paciência e pelos conhecimentos passados ao longo dos anos do mestrado e do doutorado, obrigado por tudo.

Agradecimentos ao prof. Marco Aurélio Benedetti Rodrigues, pelos seus ensinamentos e por sempre me incentivar a ingressar na área acadêmica.

Agradecimentos aos membros da banca de qualificação e de doutorado pelas contribuições úteis e necessárias para a finalização da tese.

Agradecimentos ao Dr. Alexandre Faleiro Fialho por ter me dado uma nova chance de viver, após duas cirurgias bem sucedidas.

Agradecimentos aos amigos (novos e antigos) pelo companheirismo e pela troca de experiências, em especial aos amigos Vander Vigolo, Yasser Issmail Mohsen, Amauri Fagundes Balotim, Cristiano Rodrigo Azevedo, Christine Fredel Boos e a todos que, direta ou indiretamente, contribuíram com a elaboração desse trabalho.

Agradecimentos ao Wilson e ao Marcelo da PGEEL pela amizade e pelo auxílio e suporte nas questões burocráticas envolvidas ao longo de todo o período do mestrado e doutorado, obrigado a vocês.

Agradecimentos a Capes pelo suporte financeiro no período do doutorado.

“I have no special talents I am only passionately curious”

(Albert Einstein)

RESUMO

Este trabalho teve como objetivo o desenvolvimento de um sistema automatizado para a identificação e contagem de eventos epileptiformes em sinais de eletroencefalografia (EEG) do tipo interictal e de longo termo. Como diferencial este trabalho propôs a utilização da transformada wavelet como um filtro específico para atenuar oscilações de baixa frequência que a atividade de fundo do EEG apresenta, bem como, outras interferências de alta frequência presentes nos sinais de EEG. Foram utilizadas combinações de sinais decompostos e reconstruídos, através das aproximações que a transformada wavelet disponibiliza. O filtro desenvolvido utiliza a função wavelet Db4, como função base para o filtro. Foi proposta uma faixa específica de trabalho para a localização dos eventos epileptiformes entre 5 e 25 Hz. Após o processamento pelo filtro wavelet, os picos dos eventos epileptiformes tem uma amplitude relativamente alta, em relação à atividade normal de fundo do EEG. Dessa forma, a metodologia baseia-se na localização dos picos dos eventos epileptiformes, através do pré-processamento dos sinais de EEG. Depois de processados, os canais de EEG apresentam picos de sinal marcados, e pela comparação em uma janela de amplitudes entre $-40\mu\text{V}$ e $-400\mu\text{V}$, eliminando segmentos de sinal que não compreendam esta faixa. Caso não sejam eliminados, os sinais marcados são direcionados para o classificador neural, responsável por classificar os segmentos de sinal em eventos epileptiformes ou em outra categoria, entre piscadas, atividade normal de fundo do EEG ou ruídos. Através deste estudo foi possível comprovar que a função wavelet mais adequada para o processamento dos registros de EEG é a função Db4. Também foi possível comprovar a viabilidade do desenvolvimento de um sistema classificador de eventos epileptiformes utilizando apenas uma rede neural artificial como classificador, desde que ela seja bem treinada. O classificador neural obtido apresentou uma taxa de sensibilidade de 97,45%, taxa de especificidade de 97,28%, valor preditivo positivo de 98,83%, valor preditivo negativo de 94,21% e um índice de desempenho de 97,40%. A metodologia desenvolvida possibilitou alcançar uma taxa de falsos positivos por minuto de 0,064 FP/min, ficando abaixo de muitas metodologias encontradas na literatura.

Palavras-chave: EEG, processamento de sinais, transformada wavelet, filtro.

ABSTRACT

In this work it was developed a system for the automatic identification and counting of epileptiform events applied in long term electroencephalography signals. This paper proposes the use of the wavelet transform as a digital filter using a combination of decomposed and reconstructed signals through the wavelet transform approximations. Thus, it was possible to create a specific digital filter to attenuate low frequency oscillations in the background activity of the EEG signals, as well as, other high-frequency interferences present in EEG signals. The filter uses the Db4 wavelet function, as the base function for the filter. A specific working range for the filter was proposed, between 5 and 25 Hz for the epileptiform events identification. After processing by wavelet filter, the peaks of epileptiform events has a higher amplitude in relation to the normal EEG background activity. Thus, the method is based on the location of the peaks of epileptiform events through the pre-processing of EEG signals. Once processed, the marked peaks of the EEG signals are compared with a window of amplitudes between $-40\mu\text{V}$ and $-400\mu\text{V}$, eliminating signal segments out of this band. If not eliminated, the marked signals are sent to the neural classifier and the signal segments are classified in epileptiform events, eye blinks, EEG background activity or noise. Through this study it was possible to prove that the Db4 wavelet function is most suitable for processing EEG records and it is also possible to develop a classifier system of epileptiform events using only an artificial neural network as a classifier, since it is well trained. The used neural classifier showed a sensitivity rate of 97.45%, a specificity rate of 97.28%, positive predictive value 98.83%, negative predictive value of 94.21% and a performance index of 97.40 %. The developed methodology achieved a false positive rate of 0,064 FP/min, below of many methodologies reported in the literature.

Keywords: EEG, signal processing, wavelet transform, filter.

LISTA DE FIGURAS

Figura 1 – Ocorrência de eventos epileptiformes nos canais FC1, F3, FC3, C3.	33
Figura 2 – Exemplo do formulário contendo uma contagem de eventos epileptiformes que foram identificados no processo de análise dos registros de EEG realizada por um dos especialistas do CEPESC. Cada um dos hemisférios cerebrais é analisado e os eventos encontrados são acumulados por canal de ocorrência (cedido pelo CEPESC).	34
Figura 3 – Características morfológicas da atividade epileptiforme.	44
Figura 4 – Realizações de espículas seguidas por uma onda lenta, com durações de 55 ms em [a] e 69 ms em [b].	45
Figura 5 – Representação de ondas agudas seguidas por uma onda lenta, com durações de 103 ms em [a] e 91 ms em [b].	45
Figura 6 – Montagem referencial com o eletrodo de referência TP9 indicando atividade epileptiforme com mais intensidade no canal FC1.	46
Figura 7 – Campo de potenciais dos paroxismos apresentados na Figura 6.	46
Figura 8 – Mapas de isopotencial do potencial da Figura 6. Em (a) apenas os eletrodos do sistema 10-20 foram representados, onde o eletrodo F3 mostra o máximo do potencial (100% da amplitude do potencial). Em (b) são incluídos eletrodos adicionais do sistema 10-10, onde o máximo se encontra no eletrodo FC1 (100% da amplitude do potencial).	47
Figura 9 – Comparativo das pesquisas em identificação de eventos epileptiformes realizadas entre 1976 e 2000.	48
Figura 10 – Estrutura de um Neurônio.	55
Figura 11 – Exemplos de ritmos cerebrais típicos presentes nos sinais de EEG.	56
Figura 12 – Eletrodos no sistema 10-20, nas visões (a) temporal e (b) parietal.	58
Figura 13 – Registro de potenciais nas formas (a) bipolar e (b) referencial.	59
Figura 14 – Exemplo de artefato muscular.	61
Figura 15 – Artefato de corrente elétrica (60 Hz).	61
Figura 16 – Artefato de movimento ocular ao abrir e fechar dos olhos.	62
Figura 17 – Artefato de movimento ocular Fp1, Fp2, F7, F8, T3, T4, Z1 e Z2.	63
Figura 18 – Artefato de estouro de eletrodo nos canais F4-C4 e C4-p4.	64
Figura 19 – Artefatos de movimento.	64
Figura 20 – Artefatos produzidos por sudorese.	65
Figura 21 – Artefato de Eletrocardiograma nos eletrodos Z1-Z2.	65
Figura 22 – Exemplos de funções wavelet.	66
Figura 23 – Representação dos processos de deslocamento no tempo [a] e de alteração das escalas [b] em uma função wavelet.	67
Figura 24 – Nesta figura são apresentados a wavelet, o sinal e a transformação do sinal. Pode ser observado que o ponto máximo do sinal transformado é mostrado no plano do domínio da transformada wavelet, representando a escala e a localização atual da alta correlação entre o sinal e a wavelet.	68

Figura 25 – Representação das escalas da transformada wavelet contínua da análise de um evento epileptiforme.	70
Figura 26 – Representação das escalas da transformada wavelet discreta na análise de um evento epileptiforme.	71
Figura 27 – Processo de decomposição do sinal (S), onde são obtidos os níveis de Aproximação (A) e Detalhe (D).....	72
Figura 28 – Aplicação de filtros multirresolução a um sinal $x[n]$. Os filtros $G[n]$ extraem os detalhes $d_i[n]$. Os filtros $H[n]$ extraem as aproximações do sinal $a_i[n]$, em níveis i cada vez menores de refinamento.	72
Figura 29 – Sinal senoidal com frequências de 1, 5, 10, 25 e 50 Hz, utilizados para demonstrar a análise multirresolução wavelet, onde o sinal é decomposto e reconstruído em aproximações e detalhes.	73
Figura 30 – Representação da reconstrução do sinal gerado por dez níveis de aproximação.	74
Figura 31 – Representação da reconstrução do sinal gerado por dez níveis de detalhe.	75
Figura 32 – <i>Denoising</i> da transformada wavelet para a filtragem de sinais.....	76
Figura 33 – Demonstração do método <i>denoising</i> para a filtragem de sinais. Em [a] o sinal decomposto, [b] decomposição por escala e [c] por limiares.....	77
Figura 34 – Neurônio artificial e suas entradas, pesos sinápticos, junção aditiva e função de ativação.	79
Figura 35 – Utilizando os métodos de validação cruzada com a parada antecipada, pode ser observado que as curvas dos erros apresentam um decaimento até uma determinada época de treinamento (traço pontilhado), caracterizando a parada antecipada. Desta época em diante a curva do erro de validação começa a crescer. A partir deste ponto, a rede tende a especializar cada vez mais os padrões treinados, perdendo sua capacidade de generalização.	83
Figura 36 – Exemplo de Curvas ROC onde são apresentadas as formas de discriminação para um classificador.....	87
Figura 37 – Representação dos módulos que compõem o sistema computacional desenvolvido para a identificação e classificação de registros de EEG.	89
Figura 38 – Análise e identificação do canal onde o evento é mais eletronegativo, marcado com a seta. Pode ser observado que o canal T7 apresenta o evento com maior amplitude negativa em relação aos demais canais, com $-291,14\mu V$. Também pode ser observado que a amplitude vem decaindo gradualmente nos demais canais, caracterizando o campo de potencial elétrico.	91
Figura 39 – Visualização do software de aquisição/análise <i>Ceegraph Vision</i> , onde os eventos foram marcados originalmente pelos neurologistas do CEPESC.	92
Figura 40 – Tela de 10 segundos de um traçado de EEG contendo descargas epileptiformes. Pode ser observado que houve a formação e a propagação de um campo de potencial elétrico para cada um dos eventos identificados pelas setas.	93

Figura 41 – Representação do campo de potencial dos eventos epileptiformes destacados pela seta cheia (Figura 40) e pela seta vazia (Figura 40). Pode-se observar que nos dois campos de potencial analisados os eventos mais eletronegativos ocorreram no canal T7.....	93
Figura 42 – Tela de sinal sem processamento e com montagem de aquisição. ..	95
Figura 43 – Tela de sinal com os filtros aplicados.....	96
Figura 44 – Tela de sinal apresentada através de uma montagem referencial em Pz.....	97
Figura 45 – Tela da ferramenta de extração de padrões. A janela de extração destacada em laranja representa a época de sinal que será gravada dentro de um arquivo de padrões.....	98
Figura 46 – Representação dos arquivos de padrões gerados para cada padrão selecionado.....	99
Figura 47 – Representação das quatro classes de padrões definidas para este trabalho. São apresentados três exemplares de cada classe, os quais foram selecionados a partir das marcações efetuadas. São apresentadas apenas 512 das 2048 amostras que cada padrão possui, representando uma época de um segundo de sinal.....	100
Figura 48 – Experimentos com filtros <i>Butterworth</i> utilizados no condicionamento dos sinais no momento da visualização. Configurando o filtro passa-altas para a frequência de 5 Hz, a mesma do limite inferior que abrange os eventos epileptiformes, fica evidente que o sinal filtrado apresenta uma elevada distorção em seus picos máximos, inviabilizando a sua localização.....	102
Figura 49 – Representação do processo de decomposição de um sinal de 512 Hz de frequência de amostragem em dez níveis de decomposição. Podem ser observados os níveis de decomposição, que abrangem os eventos epileptiformes, de acordo com a sua faixa de frequência e duração.....	103
Figura 50 – Exemplo de decomposição wavelet utilizando um evento epileptiforme real e os sinais reconstruídos, a partir de suas respectivas aproximações.....	104
Figura 51 – Exemplo de decomposição wavelet utilizando um evento epileptiforme real e os sinais reconstruídos, a partir de seus respectivos detalhes.....	106
Figura 52 – Processo de decomposição e reconstrução de um sinal qualquer, com 512 Hz de frequência de amostragem.....	108
Figura 53 – Proposta de um filtro wavelet utilizando apenas os detalhes. Neste filtro é proposta uma operação de soma entre níveis de detalhe, se obtendo um sinal livre de interferências, como a de linha de base e oscilações de baixa frequência, bem como, interferências de alta frequência, incluindo o ruído de 60 Hz.....	109
Figura 54 – Proposta de um filtro wavelet utilizando apenas as aproximações. Neste filtro é proposta uma operação de subtração entre níveis de aproximação, onde também se obtém um sinal filtrado, contendo apenas as frequências entre 4 e 32 Hz. Em comparação ao primeiro método de filtragem, este acabou se	

tornando mais eficiente pelo fato de se utilizar apenas dois sinais reconstruídos e não três, como apresentado no primeiro método.....	110
Figura 55 – Proposta de um filtro wavelet utilizando as aproximações e o sinal original. Neste filtro é proposta uma operação de subtração entre o sinal original e o nível de aproximação A6, onde se obtém um sinal filtrado, contendo as frequências acima de 4 Hz. Este filtro é adequado apenas para a eliminação de oscilações de baixas frequências, como o ruído de linha de base do EEG.	111
Figura 56 – Representação das realizações dos eventos selecionados para a escolha da função Wavelet a ser utilizada na filtragem dos sinais.....	112
Figura 57 – Exemplos de filtragem com algumas funções wavelet selecionadas.	113
Figura 58 – Representação das categorias definidas para a análise das funções.	114
Figura 59 – Representação da análise de épocas de sinal de um segundo e a análise do pico do evento desta época de sinal.	115
Figura 60 – Demonstração do funcionamento do filtro wavelet com as quatro funções obtidas, mostrando todos os eventos epileptiformes do conjunto de padrões, após o processamento com o filtro proposto, contrastando com os sinais originais ao fundo.	116
Figura 61 – Sinal de EEG contendo artefatos musculares.	121
Figura 62 – Sinal de EEG contendo oscilação na linha de base.	121
Figura 63 – Sinal de EEG contendo ruídos de alta frequência.	122
Figura 64 – Sinal de EEG contendo eventos epileptiformes.....	122
Figura 65 – Traçado de EEG contendo flutuação da linha de base do sinal. ...	123
Figura 66 – Traçado de EEG processado pelo filtro do método 2.	124
Figura 67 – Traçado de EEG contendo ruídos de altas e baixas frequências... ..	124
Figura 68 – Traçado de EEG processado pelo filtro do método 2.	125
Figura 69 – Traçado de EEG contendo eventos epileptiformes.	125
Figura 70 – Traçado de EEG processado pelo filtro proposto no método 2. ...	126
Figura 71 – Traçado contendo piscadas, artefatos e eventos epileptiformes. ...	126
Figura 72 – Traçado de EEG processado pelo filtro proposto no método 2. ...	127
Figura 73 – Traçado de EEG contendo ruído de 60 Hz e eventos epileptiformes.	127
Figura 74 – Traçado de EEG processado pelo filtro proposto no método 2. ...	128
Figura 75 – Localização dos eventos epileptiformes nos canais de EEG, pela amplitude dos seus picos máximos negativos.....	130
Figura 76 – Tela de sinal com eventos epileptiformes localizados pelas máximas amplitudes negativas que os seus picos apresentam.	130
Figura 77 – Comparação do sinal original com o processado pelo filtro wavelet.	131
Figura 78 – Representação da correção das posições dos picos processados pelo filtro wavelet e as posições originais.	132
Figura 79 – Tela de sinal original com as posições corrigidas dos eventos encontrados.....	133

Figura 80 – Tela inicial da ferramenta computacional criada para o treinamento e validação de redes neurais artificiais.....	135
Figura 81 – Tela de inicialização e de acompanhamento da evolução dos treinamentos das redes neurais.....	136
Figura 82 – Tela de acompanhamento das estatísticas realizadas.....	136
Figura 83 – Ambiente para o reconhecimento de padrões.....	137
Figura 84 – Tela do reconhecimento dos padrões analisados (ANEXO B).	139
Figura 85 – Representação da contagem de eventos epileptiformes.....	141
Figura 86 – Exemplo de listagem do arquivo TXT, gerado com informações detalhadas do processo de contagem de eventos epileptiformes.....	141
Figura 87 – Demonstração das curvas de treinamento e de validação do classificador neural implementado, mostrando que a parada antecipada ocorreu na época de treinamento 415, atingindo um erro mínimo de validação de 0,03359.....	145
Figura 88 – Classificação dos padrões do conjunto de testes com a época 114.....	146
Figura 89 – Classificação dos padrões do conjunto de testes com a época 415.....	147
Figura 90 – Classificação dos padrões do conjunto de testes com a época 976.....	147
Figura 91 – Curvas que representam o índice de eficiência [a] e o índice AUC [b].....	148
Figura 92 – Exemplo de detecção e classificação de eventos epileptiformes em telas de EEG, contendo elevados níveis de ruído.....	150
Figura 93 – Exemplo de detecção e classificação de uma tela de sinal sem a ocorrência de eventos epileptiformes.....	151
Figura 94 – Outro exemplo de detecção e classificação de eventos epileptiformes em telas de EEG contendo elevados níveis de ruído.....	151
Figura 95 – Exemplo de detecção de eventos, sem muitas interferências causadas por ruídos e outras oscilações. Neste exemplo foram detectados e marcados quatro eventos epileptiformes, que tiveram espalhamento do campo de potencial.....	152
Figura 96 – Exemplo de detecção de eventos utilizado na avaliação de um segmento de sinal do paciente PacJ1.....	153
Figura 97 – Gráfico com o total de ocorrências encontradas através da análise.....	153
Figura 98 – Informações complementares dos eventos epileptiformes localizados, através da análise do segmento de sinal de dez minutos, do paciente PacJ1.....	154
Figura 99 – Segmento de sinal contendo eventos epileptiformes ao centro da tela bem definidos e com morfologia característica.....	157
Figura 100 – Tela de sinal contendo três ocorrências de eventos epileptiformes, dois no hemisfério esquerdo e um no hemisfério direito.....	159
Figura 101 – Exemplo de pré-processamento utilizando o nível de detalhe 5 da transformada wavelet para a detecção dos eventos da Figura 100.....	160

Figura 102 – Exemplo de pré-processamento utilizando o nível de detalhe 6 da transformada wavelet para a detecção dos eventos da Figura 100.....	161
Figura 103 – Exemplo de pré-processamento utilizando o filtro wavelet desenvolvido para a detecção dos eventos epileptiformes da Figura 100.....	162
Figura 104 – Conjunto de eventos epileptiformes e de padrões de atividade normal de fundo do EEG, separados por especialistas.	167
Figura 105 – Resultados obtidos através da classificação dos conjuntos de padrões de teste do especialista 1 [a], especialista 2 [b], especialista 3 [c] e dos especialistas 1,2 e 3 juntos [d], utilizando o classificador neural treinado com o conhecimento do especialista 1.	170
Figura 106 – Resultados obtidos através da classificação dos conjuntos de padrões de teste do especialista 1 [a], especialista 2 [b], especialista 3 [c] e dos especialistas 1,2 e 3 juntos [d], utilizando o classificador neural treinado com o conhecimento do especialista 2.	171
Figura 107 – Resultados obtidos através da classificação dos conjuntos de padrões de teste do especialista 1 [a], especialista 2 [b], especialista 3 [c] e dos especialistas 1,2 e 3 juntos [d], utilizando o classificador neural treinado com o conhecimento do especialista 3.	172
Figura 108 – Resultados obtidos através da classificação dos conjuntos de padrões de teste do especialista 1 [a], especialista 2 [b], especialista 3 [c] e dos especialistas 1,2 e 3 juntos [d], utilizando o classificador neural treinado com o conhecimento dos três especialistas juntos.	173

LISTA DE TABELAS

Tabela 1 – Características da atividade epileptiforme.	44
Tabela 2 – Lista de frequências relacionadas a cada nível de decomposição para um sinal de 512 Hz de frequência de amostragem.	73
Tabela 3 – Tabela de contingência utilizada nos testes-diagnósticos.....	84
Tabela 4 – Visualização de dez funções wavelet, que apresentaram os maiores valores de energia e o seu respectivo número de coeficientes, para o conjunto de eventos selecionado.	113
Tabela 5 – Correlação entre os picos dos eventos originais e os filtrados.	117
Tabela 6 – Correlação entre os eventos originais e os filtrados.	117
Tabela 7 – Correlação entre as épocas de 1s originais e as épocas filtradas.	118
Tabela 8 – EMQ entre os picos dos eventos originais e os eventos filtrados.	118
Tabela 9 – EMQ entre os eventos originais e os eventos filtrados.....	119
Tabela 10 – EMQ entre as épocas de 1s originais e as épocas filtradas.	119
Tabela 11 – Funções wavelet obtidas através dos experimentos realizados com um conjunto de sinais contendo 480 eventos epileptiformes.	120
Tabela 12 – Representação do buffer de posições que armazena as máximas amplitudes encontradas, para cada instante de tempo de um segundo, e para cada um dos vinte e oito canais das telas de dez segundos de registro.	131
Tabela 13 – Representação do buffer de posições, mostrando novos valores corrigidos após o processo de correção das posições.....	133
Tabela 14 – Representação do buffer de posições após o reconhecimento dos eventos epileptiformes verdadeiros.....	139
Tabela 15 – Índices obtidos com a avaliação do classificador neural.	146
Tabela 16 – Testes realizados com o classificador implementado.....	149
Tabela 17 – Avaliação dos classificadores neurais por especialista.....	169
Tabela 18 – Índices de desempenho das quatro metodologias avaliadas.	178

LISTA DE ABREVIATURAS E SIGLAS

μV	Microvolts
AUC	<i>Area Under the Curve</i>
Bior3.1	Função wavelet Biortogonal 3.1
CEPESC	Centro de Epilepsia de Santa Catarina
Coif1	Função wavelet Coiflet 1
Coif4	Função wavelet Coiflet 4
CORR	Correlação
CWT	<i>Continue Wavelet Transform</i>
Db4	Função wavelet Daubechies 4
DWT	<i>Discrete Wavelet Transform</i>
EcoG	Eletrocorticograma
EEG	Eletroencefalografia
EMG	Eletromiograma
EMQ	Erro Médio Quadrático
EMQ _{Trein}	Erro Médio Quadrático de Treinamento
EMQ _{Valid}	Erro Médio Quadrático de Validação
FP	Falso-Positivo
FN	Falso-Negativo
FWT	<i>Fast Wavelet Transform</i>
G _D	Filtro Passa-altas de Decomposição
G _R	Filtro Passa-altas de Reconstrução
H _D	Filtro Passa-baixas de Decomposição
H _R	Filtro Passa-baixas de Reconstrução
HGCR	Hospital Governador Celso Ramos
Hz	Hertz
IEB	Instituto de Engenharia Biomédica/UFSC
MLP	<i>Multi-layer Perceptron</i>
ms	Milisegundos
RBio2.8	Função wavelet Biortogonal Reversa 2.8
RNA	Rede Neural Artificial
ROC	<i>Receiver Operating Characteristic</i>
UFSC	Universidade Federal de Santa Catarina
VP	Verdadeiro-Positivo
VN	Verdadeiro-Negativo
TW	Transformada <i>Wavelet</i>

SUMÁRIO

1 INTRODUÇÃO.....	31
1.1 MOTIVAÇÃO	31
1.2 JUSTIFICATIVA	33
1.3 OBJETIVOS	35
1.3.1 Objetivo Geral.....	35
1.3.2 Objetivos Específicos.....	35
1.4 CONTRIBUIÇÕES	35
1.5 PUBLICAÇÕES	37
2 EPILEPSIAS	39
2.1 INTRODUÇÃO	39
2.2 SINTOMAS	39
2.3 DIAGNÓSTICO	40
2.4 TRATAMENTO	41
2.5 INCIDÊNCIA	41
2.6 CENTROS DE TRATAMENTO DA EPILEPSIA NO BRASIL	42
2.7 EVENTOS ELETROENCEFALOGRÁFICOS NA INVESTIGAÇÃO DA EPILEPSIA	42
2.8 MAPAS DE CAMPOS DE POTENCIAL	45
2.9 TRABALHOS CORRELATOS A ÁREA DE PESQUISA	47
2.10 PESQUISAS REALIZADAS NO IEB-UFSC.....	53
3 FUNDAMENTAÇÃO TEÓRICA	55
3.1 CONCEITOS BÁSICOS SOBRE A ELETROENCEFALOGRAFIA	55
3.1.1 Origem dos Sinais Elétricos Encefálicos	55
3.1.2 Ritmos Cerebrais.....	56
3.1.3 Posicionamento dos Eletrodos e Nomenclatura	58
3.1.4 Sistema de Referência dos Sinais de Eletroencefalografia.....	59
3.1.5 Artefatos	60
3.2 CONCEITOS BÁSICOS SOBRE WAVELETS	66
3.2.1 Transformada Wavelet Contínua (CWT).....	68
3.2.2 Transformada Wavelet Discreta (DWT).....	70
3.2.3 Filtragem de sinais utilizando o método Denoising	75
3.3 REDES NEURAIS ARTIFICIAIS	78
3.3.1 O Neurônio Artificial.....	79
3.3.2 Funções de Ativação (φ)	80
3.3.3 Rede Perceptron Multicamadas e Algoritmo Backpropagation	81
3.3.4 Validação Cruzada com Parada Antecipada	82
3.4 AVALIAÇÃO DO DESEMPENHO DE CLASSIFICADORES	84
3.4.1 Índices de Sensibilidade e Especificidade.....	85
3.4.2 Valor Preditivo Positivo e Valor Preditivo Negativo	85
3.4.3 Eficiência	86

3.4.4 Curvas ROC.....	86
4 METODOLOGIA.....	89
4.1 O BANCO DE SINAIS DE EEG	90
4.1.1 Marcação dos Eventos nos Sinais de EEG.....	90
4.1.2 Etapas Realizadas na Análise dos Registros de EEG Adotadas Pelos Neurologistas do CEPESC	92
4.2 ABERTURA E VISUALIZAÇÃO DOS ARQUIVOS DE EEG	94
4.3 ARQUIVOS DE PADRÕES DE EEG GERADOS PARA OS EXPERIMENTOS COM A TRANSFORMADA WAVELET E COM AS REDES NEURAIIS ARTIFICIAIS.....	97
4.4 PRÉ-PROCESSAMENTO DOS SINAIS DE EEG	101
4.4.1 Experimentos com a Transformada Wavelet	102
4.4.2 Proposta de um Filtro para o Processamento de Sinais de EEG Utilizando a Transformada Wavelet	107
4.4.3 Escolha da Função Wavelet para o Filtro Proposto	111
4.4.4 Cálculo das Correlações e dos Erros Médios Quadráticos.....	114
4.4.5 Avaliação das Funções Wavelet Escolhidas	116
4.4.5.1 Avaliação das Funções Wavelet pelo Cálculo das Correlações	117
4.4.5.2 Avaliação das Funções Wavelet pelos Erros Médios Quadráticos	118
4.4.6 Avaliação do Filtro Wavelet Proposto	120
4.4.6.1 Experimentos com os Filtros Propostos Aplicados ao EEG	120
4.4.7 Aplicação do Filtro Proposto em Telas de EEG	123
4.5 LOCALIZAÇÃO E MARCAÇÃO DOS EVENTOS EPILEPTIFORMES.....	128
4.6 REDES NEURAIIS ARTIFICIAIS PARA A CLASSIFICAÇÃO DE EVENTOS EPILEPTIFORMES EM SINAIS DE EEG	134
4.6.1 Ferramenta Computacional para o Treinamento, Validação e Testes de Redes Neurais Artificiais	134
4.6.2 Forma de Classificação dos Eventos Epileptiformes adotado no Sistema Desenvolvido	137
4.7 CONTAGEM DOS EVENTOS EPILEPTIFORMES	140
5 RESULTADOS E DISCUSSÕES.....	143
5.1 AVALIAÇÃO DO CLASSIFICADOR NEURAL TREINADO E ADOTADO PARA O SISTEMA	143
5.2 AVALIAÇÃO DO SISTEMA DESENVOLVIDO	149
5.3 CONSIDERAÇÕES SOBRE TRABALHO	154
5.3.1 Sobre os Registros de EEG Fornecidos pelo CEPESC	156
5.3.2 Sobre as Ferramentas Computacionais Desenvolvidas.....	157
5.3.3 Sobre a Metodologia Desenvolvida	158
5.3.4 Sobre o Software para a Identificação e Contagem Automática de Eventos Epileptiformes nos Registros de EEG de Longo Termo	165
5.3.5 Sobre a Avaliação dos Classificadores Neurais Treinados Conforme o Conhecimento de cada Especialista.....	166
5.3.6 Comparativo de Desempenho.....	175

6 CONCLUSÕES.....	181
7 TRABALHOS FUTUROS	183
REFERÊNCIAS.....	185
ANEXO A – COMITÊS DE ÉTICA	193
ANEXO B – TELA DO SISTEMA DE IDENTIFICAÇÃO E CONTAGEM AUTOMÁTICA DE EVENTOS EPILEPTIFORMES	195

1 INTRODUÇÃO

1.1 MOTIVAÇÃO

A epilepsia é uma doença cerebral crônica sem etiologia definida, caracterizada pela ocorrência de crises epiléticas não provocadas, causando breves distúrbios na atividade normal do cérebro (Blum & Rutkove, 2007).

No processo de diagnóstico da epilepsia a análise visual dos sinais de eletroencefalograma (EEG) ainda é amplamente utilizada pelos especialistas, como apoio ao processo de diagnóstico da epilepsia. Sua importância no diagnóstico é devido ao fato de poder se obter informações sobre as condições do paciente, através do registro do distúrbio epileptiforme causado por disfunção neuronal, no período em que o paciente se encontra assintomático, ou seja, sem crises (Montenegro, et al., 2001). O EEG pode ser utilizado também no auxílio da definição do tipo de síndrome epilética, no fornecimento de informações úteis para o planejamento da terapia medicamentosa aplicada ao paciente e ainda para ajudar na decisão sobre a viabilidade do tratamento cirúrgico da epilepsia (Pillai & Sperling, 2006).

Os elementos eletrográficos mais frequentes em traçados de EEG, de pacientes epiléticos e significativos para o diagnóstico da epilepsia, são as espículas e as ondas agudas. A principal diferença morfológica entre estes dois tipos de eventos é a duração que cada um deles apresenta. As espículas possuem duração entre 40ms e 80ms. As ondas agudas apresentam duração entre 80ms e 200ms (Lüders & Noachtar, 2000) (Montenegro, et al., 2001).

O processo de revisão dos registros de EEG é realizado por especialistas devidamente treinados e experientes. Porém, este processo ainda é uma tarefa exaustiva. Os registros rotineiros de EEG apresentam durações entre 20 e 40 minutos e são registrados através da leitura de 21 a 32 canais e visualizados em telas de 10 a 15 segundos cada (Pillai & Sperling, 2006).

Poucos sistemas computacionais de revisão automática de EEG apresentam aplicação prática. Muitos destes tendem a identificar um número relativamente grande de eventos não epileptiformes (principalmente piscadas palpebrais) como sendo positivos, resultando em pouca ou nenhuma economia efetiva de tempo (Wilson & Emerson, 2002).

Existem vários tipos de padrões não epileptiformes que mais geram falsos positivos no processo da detecção automática de eventos epileptiformes, entre eles destacam-se ruídos de alta frequência, as ondas alfa e principalmente as piscadas palpebrais. Esses padrões ocorrem com frequência nos sinais de EEG e por apresentarem características semelhantes às espículas e ondas agudas, acabam sendo confundidos com eventos epileptiformes.

A baixa especificidade¹ dos sistemas automáticos também ocorre, devido às variações que os sinais de EEG apresentam, pois variam de paciente para paciente. Essa variação também ocorre no mesmo paciente devido a diferentes estados de consciência e de seu comportamento no momento da aquisição destes sinais. Em diferentes tipos de síndrome epiléptica os sinais também apresentam variações. Assim, é difícil estabelecer um modelo computacional adequado que represente os padrões epileptiformes e que seja possível diferenciá-los das demais atividades presentes no EEG.

A sensibilidade² de tais sistemas também pode ser severamente comprometida pela baixa qualidade na aquisição de um sinal de EEG. Isto ocorre devido ao grande número de fontes de artefatos existentes, pela baixa relação sinal-ruído captada no escalpo e também pelo fato de que, em alguns tipos de epilepsia não há o aparecimento dos eventos epileptiformes de forma espontânea, comprometendo os experimentos pela pouca quantidade de eventos obtidos.

No caso dos registros de EEG de longa duração ou de longo termo a probabilidade de se encontrar eventos epileptiformes caso o paciente seja epiléptico é maior. Dessa forma, a especificidade dos sistemas torna-se mais importante que a sensibilidade. Apesar disto, a maioria dos sistemas automáticos propostos até o momento não conseguem apresentar taxas aceitáveis de falso-positivos por minuto (FP/min), ou seja, abaixo de 0,1 FP/min (Wilson & Emerson, 2002).

Este trabalho pretende contribuir com um sistema computacional para automatizar a revisão do EEG interictal de longo termo, através do uso de ferramentas como a transformada wavelet e redes neurais artificiais, para o desenvolvimento de uma metodologia híbrida capaz de identificar, classificar e contar eventos epileptiformes em determinadas regiões do córtex.

¹ Habilidade de um teste indicar os não doentes quando a doença não está presente, a especificidade é definida como (verdadeiro negativo / (verdadeiro negativo + falso positivo)).

² Habilidade de um teste detectar a doença quando ela está presente, a sensibilidade é definida como (verdadeiro positivo / (falso negativo + verdadeiro positivo)).

1.2 JUSTIFICATIVA

O diagnóstico da epilepsia depende da identificação clínica e eletrográfica das crises epiléticas, o que torna a análise visual dos sinais de EEG, um método importante para a identificação de transientes eletrográficos, como as espículas e as ondas agudas (Blum & Rutkove, 2007).

A identificação destes eventos é realizada por um especialista, devidamente treinado e experiente (Sanei & Chambers, 2007). Este processo consiste em analisar telas de 10 a 15 segundos de sinal, contendo até 32 canais, onde é verificada a existência de perturbações nos traçados do EEG, que indiquem a ocorrência de eventos epileptiformes, como apresentado na Figura 1.

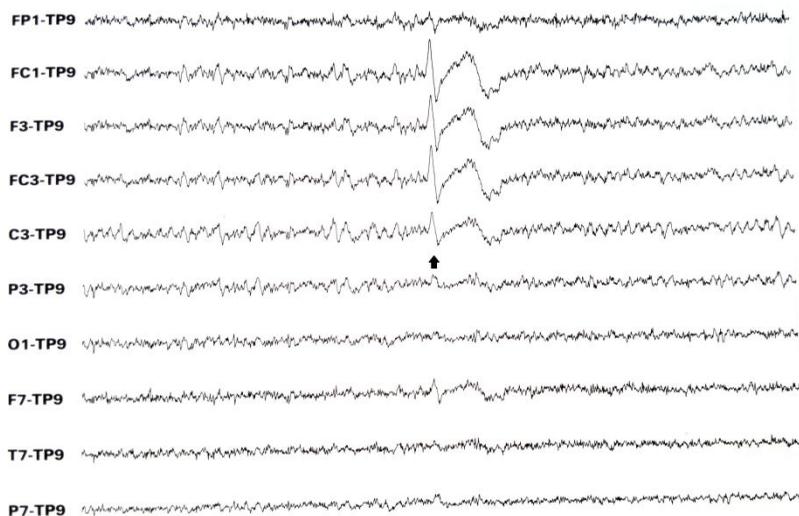


Figura 1 – Ocorrência de eventos epileptiformes nos canais FC1, F3, FC3, C3.
Fonte: (Lüders & Noachtar, 2000).

A busca pelos eventos epileptiformes nos traçados de EEG é uma tarefa repetitiva e exaustiva, devido ao fato dos registros de EEG apresentarem um elevado volume de informações (Blum & Rutkove, 2007). Depois de encontrados, os eventos epileptiformes são acumulados por canal de ocorrência, em ambos os hemisférios do cérebro e os eventos encontrados são totalizados e marcados em um

1.3 OBJETIVOS

1.3.1 Objetivo Geral

O objetivo geral deste trabalho é desenvolver um sistema automatizado para a identificação e contagem de eventos epileptiformes em traçados de EEG, que possa auxiliar no diagnóstico da epilepsia.

1.3.2 Objetivos Específicos

- ✓ Analisar os registros de EEG de longo termo fornecidos pelo CEPESC;
- ✓ Gerar arquivos de eventos epileptiformes e não epileptiformes a partir das marcações dos neurologistas do CEPESC;
- ✓ Formar conjuntos de padrões para o treinamento, validação e testes das redes neurais que forem utilizadas;
- ✓ Aplicar a transformada wavelet no pré-processamento dos eventos epileptiformes;
- ✓ Desenvolver um classificador neural a partir de uma rede neural artificial do tipo *Feedforward* com algoritmo de treinamento *Backpropagation*;
- ✓ Implementar o método de validação cruzada com parada antecipada como método de avaliação dos treinamentos das redes neurais;
- ✓ Utilizar a análise ROC e índices de desempenho como forma de avaliar os melhores classificadores neurais desenvolvidos;
- ✓ Avaliar os resultados obtidos em todo o processo;
- ✓ Desenvolver um sistema automatizado para identificação e contagem automática de eventos epileptiformes.

1.4 CONTRIBUIÇÕES

No decorrer do desenvolvimento deste trabalho foram feitos muitos experimentos e diversas simulações, empregando técnicas e ferramentas matemáticas distintas, que permitiram o desenvolvimento e a finalização da metodologia proposta inicialmente. Essas simulações

permitiram ter uma visão mais abrangente das etapas que compõem a aquisição dos sinais de EEG, o processamento e o reconhecimento dos eventos epileptiformes. Para que as simulações fossem realizadas de forma adequada foram implementadas ferramentas computacionais (softwares) que incorporavam muitas das técnicas e ferramentas matemáticas estudadas no decorrer do desenvolvimento deste trabalho. Tais ferramentas foram desenvolvidas para serem genéricas, o que as tornam importantes na investigação de outros tipos de sinal, e não apenas sinais de EEG, sendo uma grande contribuição gerada por este trabalho.

Foram implementadas cinco ferramentas computacionais e, dentre elas, duas se destacaram. A primeira incorpora técnicas e ferramentas matemáticas necessárias ao processamento de sinais de EEG, incluindo a transformada wavelet. Através desta ferramenta foi possível propor um filtro que utilizasse as aproximações da transformada wavelet, específico para a atenuação da atividade de fundo do EEG, sem distorcer as frequências que caracterizam os eventos epileptiformes (Scolaro, et al., 2012), (Scolaro, et al., 2013a) e (Scolaro, et al., 2013b), outra grande contribuição deste trabalho.

A segunda ferramenta computacional agrega um ambiente para o treinamento, a validação e o teste dos classificadores neurais treinados. Esta ferramenta possibilita a construção de uma rede neural com camadas de neurônios configuráveis, podendo ser escolhido o número de camadas que a rede terá e o número de neurônios que cada camada irá conter, bem como, os demais parâmetros necessários para o seu treinamento.

Para a validação das redes treinadas esta ferramenta agrega a técnica de validação cruzada com parada antecipada entre outros índices estatísticos, os quais evitam a especialização do treinamento das redes neurais. Esta ferramenta permite que os testes com as redes neurais sejam feitos de uma forma muito simples, apenas selecionando um arquivo com diversos padrões, e os mesmos são reconhecidos e apresentados em forma de gráficos de dispersão (Scolaro & Azevedo, 2010), (Scolaro, et al., 2011). Esta ferramenta possibilita também que outros tipos de sinais/padrões sejam treinados e reconhecidos, outra contribuição gerada por este trabalho.

Outra grande contribuição gerada por este trabalho foi observada através da comparação dos resultados dos classificadores treinados entre si. Foi possível observar que a melhor opção para construir uma base de conhecimento para um sistema de detecção automática de eventos epileptiformes, composto por classificadores neurais, seria inserir o

conhecimento do próprio neurologista que irá manipular o sistema. Dessa forma, o próprio especialista estaria “moldando” o conhecimento das redes neurais, de acordo com sua experiência e conforme a sua necessidade.

Como contribuição final, todas as ferramentas desenvolvidas e a metodologia proposta foram agregadas, possibilitando a implementação de um software de alto desempenho para a execução de tarefas complexas de processamento de sinais, com funcionalidades reais e aplicáveis à prática da revisão do EEG de longo termo, que não apenas identifica, mas também realiza a contagem dos eventos epileptiformes encontrados, o qual alcançou uma taxa de falsos positivos por minuto de 0,064 FP/min;

1.5 PUBLICAÇÕES

Os resultados obtidos no decorrer do desenvolvimento desse trabalho proporcionaram a elaboração de um capítulo de livro e quatro artigos científicos publicados em congressos internacionais.

O capítulo de livro (Scolaro, et al., 2013b) descreve a estrutura e o funcionamento do filtro wavelet que foi desenvolvido e os resultados obtidos no processo de filtragem dos registros de EEG.

Os artigos descrevem a criação dos processos envolvidos na identificação e classificação de eventos epileptiformes (Scolaro & Azevedo, 2010), (Scolaro, et al., 2011), avaliação das funções wavelet mais indicadas para a implementação de um filtro wavelet (Scolaro, et al., 2012) e a proposta do filtro wavelet (Scolaro, et al., 2013a) para a filtragem dos sinais de EEG. Cada um dos trabalhos citados descrevem uma etapa da implementação da metodologia criada, que deu origem ao sistema de detecção automática de eventos epileptiformes, atendendo os objetivos estipulados para esse trabalho.

2 EPILEPSIAS

2.1 INTRODUÇÃO

Epilepsia é uma doença cerebral crônica causada por diversas etiologias e caracterizada pela ocorrência de crises epiléticas não provocadas que causam breves distúrbios nas funções elétricas normais do cérebro, afetando pessoas em qualquer idade e em todos os países do mundo. Esta condição tem consequências neurobiológicas, cognitivas, psicológicas e sociais que prejudicam a qualidade de vida do indivíduo afetado (Montenegro, et al., 2001).

De forma prática, as epilepsias podem ser classificadas de acordo com dois grandes eixos: topográfico e etiológico. No eixo topográfico as epilepsias são divididas em focais e generalizadas. Nas epilepsias focais as crises têm início em áreas mais delimitadas do cérebro e os sintomas dependem das áreas afetadas e da velocidade de propagação das descargas epileptiformes. As crises focais se dividem em focais simples e focais complexas. Nas crises focais simples não há o comprometimento da consciência. Já nas crises focais complexas há um comprometimento parcial da consciência do indivíduo. Nas crises epiléticas generalizadas há o envolvimento de ambos os hemisférios cerebrais, sendo geneticamente determinadas e acompanhadas de alterações na consciência.

No eixo etiológico, as epilepsias são divididas em idiopáticas e sintomáticas. Nas epilepsias idiopáticas não há a presença de lesão estrutural subjacente e não apresentam causas conhecidas. Nas epilepsias sintomáticas há lesão estrutural e as causas são conhecidas. As causas mais frequentes de lesão que ocorrem nas epilepsias focais sintomáticas são esclerose temporal mesial, neoplasias cerebrais primárias, anomalias vasculares e malformações do desenvolvimento corticocerebral (Brasil, 2010).

2.2 SINTOMAS

Em crises de ausência, o indivíduo aparenta estar “desligado” por alguns instantes, podendo retomar o que estava fazendo em seguida.

Nas crises parciais simples ocorrem sensações estranhas, como distorções na percepção do indivíduo ou descontrole nos movimentos de uma parte do corpo. Pode ainda ocorrer desconforto no estômago, ver ou ouvir de uma forma diferente. Caso o paciente perca a consciência essa crise é chamada de parcial complexa. Logo após a crise a pessoa pode se sentir confusa e com déficits de memória.

Em crises tônico-clônicas o paciente perde a consciência e cai. Em seguida apresenta rigidez e as extremidades do corpo tremem e contraem-se.

Existem outros tipos de crises. Quando elas duram mais de 30 minutos e a pessoa não recupere a consciência, podem ocorrer danos nas funções cerebrais (Brasil, 2010).

2.3 DIAGNÓSTICO

O diagnóstico das crises epilépticas pode ser feito clinicamente através de relatos detalhados das condições do paciente e por meio de exames complementares. Os relatos de testemunhas também são avaliados, pois através deles há uma descrição mais detalhada da manifestação ocorrida no momento das crises.

Outras informações relevantes para o diagnóstico devem ser registradas, como a presença de aura, data e idade de início das crises, a frequência de ocorrência, histórico familiar, eventos pré e perinatais, crises no período neonatal, crises febris, qualquer crise não provocada.

Além das informações da anamnese são necessários exames complementares para um diagnóstico mais preciso da epilepsia. O principal exame é o Vídeo-EEG e com ele o médico consegue avaliar o tipo de epilepsia e a zona epileptogênica através da investigação do vídeo comportamental do paciente e dos traçados de EEG adquiridos. Exames de VEEG em vigília e em sono são obrigatórios para confirmação diagnóstica da epilepsia.

Exames de imagem são de fundamental importância na avaliação de pacientes com epilepsia. Através de exames de ressonância magnética (RM) e tomografia computadorizada (TC) é possível a constatação da existência de anormalidades estruturais, as quais podem embasar a indicação para um tratamento cirúrgico da epilepsia (Brasil, 2010).

2.4 TRATAMENTO

O tratamento da epilepsia normalmente é medicamentoso através do uso de drogas anticonvulsivas, que visam o controle das crises e propiciam uma melhor qualidade de vida aos pacientes. Em 70% dos casos os pacientes são tratados com sucesso. Em determinados casos a cirurgia é indicada.

O início do tratamento anticonvulsivante é baseado em três critérios: risco de recorrência de crises, consequências da continuação de crises para o paciente e na eficácia e efeitos adversos do fármaco escolhido para o tratamento.

Um fator fundamental no tratamento é a determinação do tipo específico de crise e da síndrome epiléptica do paciente, pelo fato de que os mecanismos de geração e propagação da crise diferem de um tipo de epilepsia para outra. Com isso, os fármacos anticonvulsivantes agem por diferentes mecanismos que podem ou não ser favoráveis ao tratamento (Brasil, 2010).

2.5 INCIDÊNCIA

Em todo o mundo a incidência de epilepsia varia conforme a região geográfica e a incidência da epilepsia ativa estejam em torno de 0,5 a 1,0% da população. Destes, cerca de 30% dos pacientes continuam a ter crises. Em países em desenvolvimento o número pode chegar a 2%, devido à deficiência no atendimento médico, subnutrição e enfermidades. Nos países desenvolvidos a incidência é de aproximadamente 1%.

No Brasil a epilepsia é uma condição neurológica que atinge aproximadamente 1,8% da população.

Em Santa Catarina estima-se que existam cerca de 100 mil portadores de epilepsia e de 20 a 30% dos pacientes não controlem as crises epilépticas, mesmo adotando um tratamento medicamentoso adequado (Brasil, 2010).

2.6 CENTROS DE TRATAMENTO DA EPILEPSIA NO BRASIL

Atualmente no Brasil existem 11 centros especializados para o tratamento da epilepsia, são eles³:

- Ambulatório de Epilepsia*, Rio de Janeiro, RJ;
- **Centro de Epilepsia de Santa Catarina (CEPESC)***, Florianópolis, SC;
- Centro de Cirurgia de Epilepsia de Ribeirão Preto (CIREP)*, Ribeirão Preto, SP;
- Hospital das Clínicas da Universidade Federal de Pernambuco (UFPE), Recife, PE;
- Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo (USP)*, São Paulo, SP;
- Hospital de Clínicas da Universidade Federal do Paraná (UFPR)*, Curitiba, PR;
- Hospital de Clínicas de Porto Alegre da Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, RS;
- Hospital Felício Rocho - Núcleo Avançado de Tratamento das Epilepsias*, Belo Horizonte, MG;
- Hospital Universitário Clementino Fraga Filho da Universidade Federal do Rio de Janeiro (UFRJ)*, Rio de Janeiro, RJ;
- Hospital Universitário Professor Edgard Santos da Universidade Federal da Bahia (UFBA), Salvador, BA;
- Serviço de Neurologia do Hospital São Lucas da Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS)*, Porto Alegre, RS.

(*centros com cirurgia)

2.7 EVENTOS ELETRENCEFALOGRÁFICOS NA INVESTIGAÇÃO DA EPILEPSIA

A atividade interictal reflete os sinais de distúrbio epileptiforme causado pela disfunção neuronal do período entre as crises epiléticas.

³ Liga Brasileira de Epilepsia, disponível em www.epilepsia.org.br. Acesso em 18 de set. 2014.

O registro da atividade epileptiforme interictal é o resultado da soma da atividade elétrica pós-sináptica, excitatória ou inibitória, de um grande conjunto de neurônios.

Quando se trata da investigação da epilepsia alguns elementos eletrográficos devem ser levados em consideração. As descargas epileptiformes registradas no EEG de superfície representam a sincronização de pelo menos 6cm^2 de córtex cerebral (Blum & Rutkove, 2007). Durante uma descarga epileptiforme a membrana celular próxima ao corpo neuronal atinge altas amplitudes, produzindo uma despolarização prolongada, o que gera um potencial de ação. Nesse momento o EEG de escapo registra uma atividade em forma de espícula. Ao final da despolarização, ocorre uma hiperpolarização, limitando a duração desse paroxismo interictal e no traçado do EEG é registrada uma onda lenta. Se ao final dessa despolarização não ocorrer uma hiperpolarização, poderão aparecer espículas repetitivas ou crise epilética (Montenegro, et al., 2001).

Os padrões epileptiformes são elementos eletrográficos que se diferenciam claramente da atividade de base e de outros transientes agudos presentes nos traçados de EEG. São considerados relativamente típicos na ocorrência da epilepsia. Fazem parte deste grupo as espículas e as ondas agudas. No significado diagnóstico não existem diferenças entre elas. O que diferencia uma da outra é a duração que cada uma delas apresenta. As espículas apresentam duração entre 40 a 80ms, já as ondas agudas apresentam durações entre 80 e 200ms (medidos na metade da distância entre a linha de base e o pico da onda). Tanto as espículas como as ondas agudas são eventos polifásicos, com a fase negativa mais proeminente e geralmente seguida por uma pós-descarga única de onda lenta (Lüders & Noachtar, 2000). Através da Figura 3[a] podem-se observar as características de uma onda aguda epileptiforme. Ela apresenta uma forma assimétrica, seguida por uma onda lenta e logo abaixo um traçado de EEG contendo várias ondas agudas, seguidas por ondas lentas. Já a Figura 3[b] apresenta uma onda aguda não epileptiforme e logo abaixo é mostrada uma atividade normal de fundo do EEG. Mesmo apresentando morfologia agudizada não apresentam características epileptiformes.

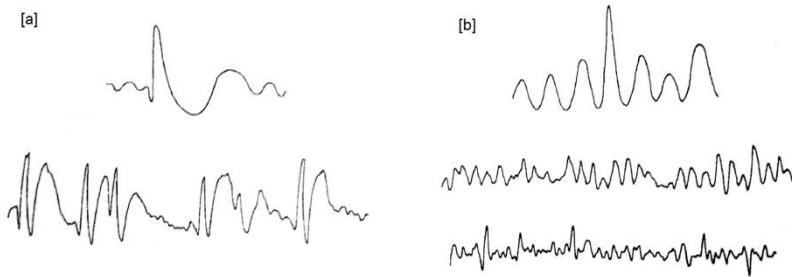


Figura 3 – Características morfológicas da atividade epileptiforme.

Fonte: (Montenegro, et al., 2001)

A Tabela 1 apresenta algumas características dos eventos epileptiformes, que devem ser levadas em consideração, no momento da identificação destes paroxismos nos traçados de EEG (Montenegro, et al., 2001).

Tabela 1 – Características da atividade epileptiforme.

-
- a) Espículas e ondas agudas epileptiformes apresentam assimetria nos dois lados da onda, com elevação aguda na primeira parte e um declínio gradual lento na segunda parte da onda. Espículas e ondas agudas não-epileptiformes apresentam simetria quanto à duração da fase de subida e descida.
 - b) Espículas e ondas agudas epileptiformes são frequentemente seguidas por ondas lentas, podendo ser da mesma polaridade ou de polaridade oposta. O que não ocorre com espículas e ondas agudas não-epileptiformes, as quais raramente apresentam tais características.
 - c) Espículas e ondas agudas epileptiformes geralmente são bifásicas ou trifásicas, enquanto a atividade não-epileptiforme é monofásica.
 - d) Espículas e ondas agudas epileptiformes apresentam duração diferente da atividade de normal de fundo do EEG, conseqüentemente chamam a atenção do eletroencefalografista no momento da análise.
 - e) A atividade de fundo próxima da atividade epileptiforme geralmente é perturbada, formando um “campo” ao redor das ondas agudas.
-

A Figura 4 apresenta duas realizações que caracterizam as espículas.

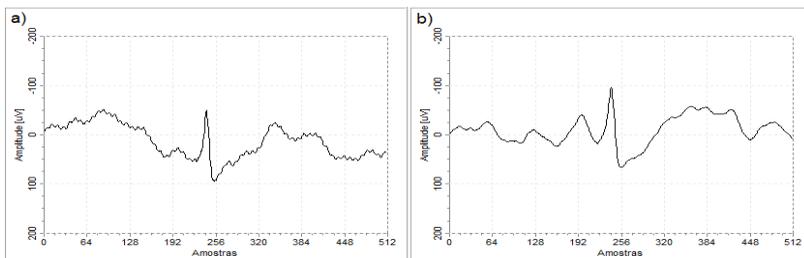


Figura 4 – Realizações de espículas seguidas por uma onda lenta, com durações de 55 ms em [a] e 69 ms em [b].

A Figura 5 mostra duas realizações que caracterizam as ondas agudas.

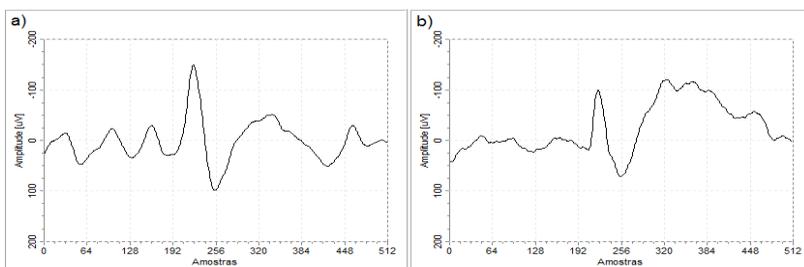


Figura 5 – Representação de ondas agudas seguidas por uma onda lenta, com durações de 103 ms em [a] e 91 ms em [b].

Neste trabalho será utilizado o termo eventos epileptiformes, para a caracterização das espículas e ondas agudas.

2.8 MAPAS DE CAMPOS DE POTENCIAL

Os mapas dos campos de potencial permitem fazer a representação da distribuição dos potenciais por regiões do escalpo. A identificação dos campos de potenciais é de extrema importância para a eletroencefalografia clínica, pois na análise da atividade epileptiforme a definição exata do campo de potencial (Figura 6) pode indicar a localização da zona epileptogênica (Lüders & Noachtar, 2000).

A forma mais simples de se fazer esta representação é através do uso de linhas de isotopotencial. Essas linhas de isotopotencial são definidas em relação ao campo de potencial que os eletrodos apresentam.

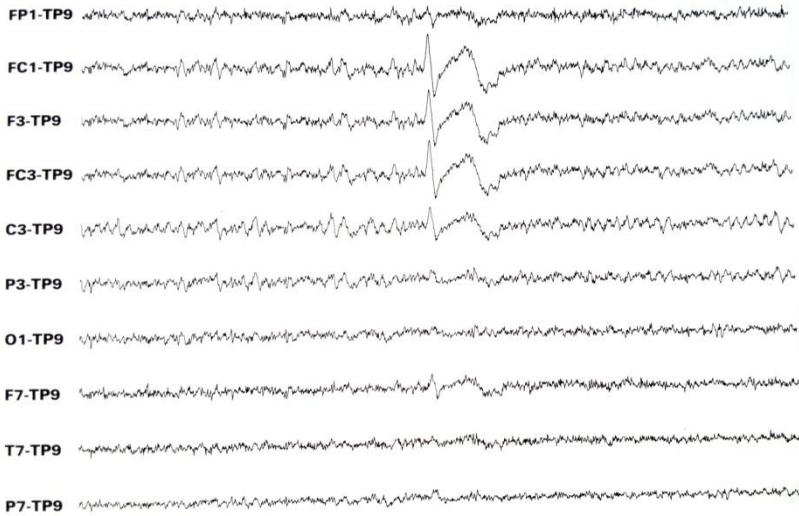


Figura 6 – Montagem referencial com o eletrodo de referência TP9 indicando atividade epileptiforme com mais intensidade no canal FC1.

Fonte: (Lüders & Noachtar, 2000).

A Figura 7 representa o campo de potencial mostrado na Figura 6. Pode ser observado que dentre as amplitudes medidas o canal FC1 apresenta a maior eletronegatividade, o que equivale a 100% da amplitude do potencial. Os demais potenciais podem ser calculados em passos de 10%, gerando assim as linhas de isopotencial que representam a distribuição dos campos de potenciais apresentados na Figura 8.

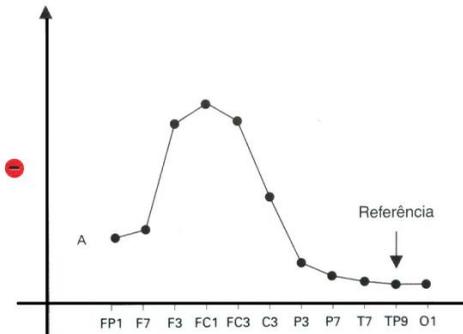


Figura 7 – Campo de potenciais dos paroxismos apresentados na Figura 6.

Fonte: (Lüders & Noachtar, 2000).

Nestes campos de potencial a ocorrência das descargas epileptiformes é claramente destacada da atividade de base do EEG. Assim é possível fazer a correta identificação e contagem dos eventos epileptiformes, apenas identificando o evento que apresenta a maior amplitude deste campo e o seu respectivo canal de ocorrência.

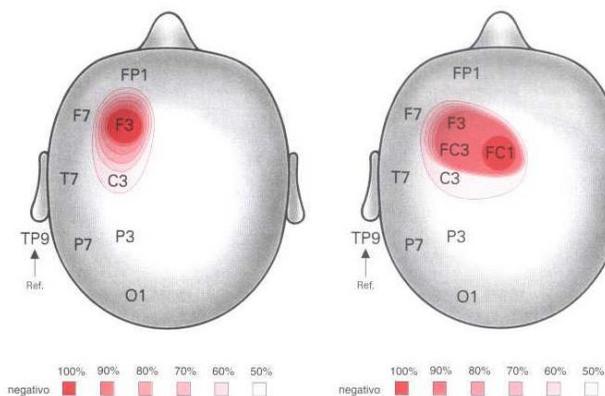


Figura 8 – Mapas de isopotencial do potencial da Figura 6. Em (a) apenas os eletrodos do sistema 10-20 foram representados, onde o eletrodo F3 mostra o máximo do potencial (100% da amplitude do potencial). Em (b) são incluídos eletrodos adicionais do sistema 10-10, onde o máximo se encontra no eletrodo FC1 (100% da amplitude do potencial).

Fonte: (Lüders & Noachtar, 2000).

2.9 TRABALHOS CORRELATOS A ÁREA DE PESQUISA

Esta seção apresenta os trabalhos mais relevantes à área de pesquisa da metodologia proposta, que envolvem algoritmos e métodos diferentes para a detecção e classificação de eventos epileptiformes em sinais de EEG interictal de escalpo.

Inicialmente é citado o trabalho de Wilson e Emerson (2002) onde é apresentado um trabalho completo de revisão na área de identificação de eventos epileptiformes. Foram analisadas e comparadas 24 pesquisas, sendo que a maioria delas utiliza descritores morfológicos na caracterização dos eventos epileptiformes. Tais metodologias não foram explicadas e não há um detalhamento sobre os bancos de sinais e outros parâmetros necessários para comparação. Os principais resultados

destas pesquisas foram agrupados em uma tabela comparativa apresentada na Figura 9.

Author(s)	Year	Patient count	Total duration (min)	Spike count	Algorithm	Sensitivity	Fp/min	Parameters
Gotman et al.	1976	93	186	> 605 ^a	GSD ^c	Unknown	0.33	9
Gotman et al.	1979	34	12240	> 1394 ^b	GSD ^c	Unknown	0.11	9
Guedes de Oliveira et al.	1983	5/5	4,2/4,2	Unknown	Unknown	~ 0.65/-0.66	Unknown	8
Faure	1985	Unknown	Unknown	Unknown	Unknown	Unknown	Unknown	Unknown
Davey et al.	1989	1	5,3	23		0.74	0.38	~ 24
Witte et al.	1991	1	1	50		0.90	4.0	5
Gabor and Seyal	1992	5	63.8	752		0.97	1.5	9
Gotman and Wang	1992	20	2000	Unknown	GSD ^c	Unknown	0.79	14
Hostetler et al.	1992	5	100	1393	GSD ^c	0.76	5.2	9
					Ex vs. Ex	0.87	1.4	
Sankar and Natour	1992	11	29.5	Unknown	Unknown	Unknown	Unknown	3?
Webber et al.	1993	10	40	1739	Ex vs. Ex	0.52	Unknown	Unknown
Pietila et al.	1994	6	360	Unknown	Tampere	0.31	Unknown	12
					GSD ^c	0.17	Unknown	9
Webber et al.	1994	10	40	927		0.73	6.1	15
Senhadji et al.	1995	1?	10	982		0.86	6.8	2?
Feucht et al.	1997	3	90	1509		0.88	1.8	Unknown
Ozdamar and Kalayci	1998	5	75	n/a	n/a	n/a	n/a	20-70
Park et al.	1998	32	n/a	n/a	n/a	n/a	n/a	40
Dumpelmann and Elger	1999	7 ^a	136	2329	2SSD ^d	0.32	9.4	7
					GSD ^c	0.23	14.4	9
					WSD ^f	0.28	12.6	?
					Ex vs. Ex	0.41	10.2	
Hellmann	1999	10 ^g	60	n/a	n/a	n/a	n/a	17
Ramabhadran et al.	1999	6/18	90/270	7982		70.96	70.40	Unknown
Wilson et al.	1999	50	143	1952	MMNN ^h	0.47	2.5	~ 20.9
					GSD ^c	0.15	3.2	
					Ex vs. Ex	0.70	4.1	
Black et al.	2000	521	10380	Unknown	Unknown	Unknown	Unknown	Unknown
Goelz et al.	2000	11	278	298		0.84	Unknown	Unknown
Ko et al.	2000	20	n/a	n/a		n/a	n/a	30

Figura 9 – Comparativo das pesquisas em identificação de eventos epileptiformes realizadas entre 1976 e 2000.

Pang et al. (2003) apresentam uma comparação de desempenho entre quatro algoritmos de detecção de espículas, utilizando o mesmo conjuntos de sinais de EEG, onde são apresentados os algoritmos desenvolvidos por Tarassenko et al. (1998), Webber et al. (1996), Kalayci e Özdamar (1995) e Özdamar e Kalayci (1998). O desempenho dos algoritmos foi avaliado usando os índices de sensibilidade, especificidade, seletividade e taxa média de detecção.

Adeli et al. (2003) apresentam um estudo na análise de registros de EEG onde é utilizada a transformada wavelet como ferramenta de análise, comparando algumas funções wavelet, entre elas a função Db4, a qual foi apontada como a mais apropriada para a análise do EEG.

Hese et al. (2004) apresentam um comparativo entre quatro métodos de detecção de eventos epileptiformes, onde foram levantadas as curvas ROC para cada método implementado, utilizando o índice EER (*Equal-Error Rate*) como indicador de desempenho.

Acir et al. (2005) apresentam uma metodologia baseada em redes neurais para a detecção de eventos epileptiformes em EEG com múltiplos canais. O algoritmo realiza uma pré-classificação inicial separando os sinais em três categorias, evento epileptiforme, não epileptiforme e desconhecido, através de duas redes neurais MLP.

Posteriormente é feita uma nova classificação empregando os padrões das categorias obtidas anteriormente, através de um classificador híbrido que utiliza redes de base radial e máquinas de vetores de suporte. Esta metodologia obteve valores de sensibilidade média de 89,1%, seletividade média de 85,9% e taxa de falsos positivos por hora (FP/hr) de 7,5.

Valenti et al. (2006) apresentam um algoritmo para a detecção de eventos epileptiformes utilizando mineração de dados (*data mining*) usando árvores de decisão (J4.8) e classificador estatístico bayesiano (Naïve Bayes). Os eventos são analisados através da combinação destas duas técnicas com um pré-processamento baseado na transformada de Fourier. Este modelo não necessita de uma clara definição da morfologia dos eventos epileptiformes, somente de um treinamento adequado para o seu funcionamento. Não há índices de desempenho para comparação.

Subasi (2007) apresenta uma metodologia que utiliza wavelets e uma mistura de redes neurais especialistas para a detecção de crises. Neste estudo a função wavelet Db4 também foi apontada como sendo uma das mais adequadas para a análise do EEG. Os sinais apresentam uma taxa de amostragem de 176.61 Hz, com 12 bits de resolução e um sistema de aquisição de 128 canais. Os índices de desempenho obtidos foram 92,6% de sensibilidade e 93,6% de especificidade.

Xu et al. (2007) apresentam uma metodologia para detecção de eventos epileptiformes através de um filtro morfológico baseado em operações complexas com a morfologia do sinal. É feita uma comparação entre o filtro proposto e outras metodologias de filtragem baseada em wavelets e em filtros morfológicos tradicionais. Não apresentam índices de desempenho.

Inan & Kuntalp (2007) apresentam um método de clusterização não-supervisionado, utilizando os algoritmos de clusterização C-means Fuzzy (FCM) e o K-means, para a detecção de eventos epileptiformes. A parametrização dos sinais foi realizada a partir da extração de quatro características dos eventos epileptiformes, baseado nas durações e nas amplitudes dos picos. Foram implementados quatro sistemas classificadores. No primeiro sistema classificador foram utilizados sinais de EEG sem parametrização, junto com o algoritmo FCM. No segundo sistema classificador foram utilizados sinais de EEG parametrizados e o algoritmo FCM. No terceiro sistema foram utilizados sinais parametrizados, uma rede neural MLP para pré-classificação, junto com o algoritmo FCM. No quarto sistema foram utilizados sinais parametrizados, uma rede neural MLP para pré-classificação e o

algoritmo K-means. Os quatro sistemas foram comparados e foram levantadas as curvas ROC para cada um deles. O sistema baseado em dois estágios utilizando o algoritmo FCM (terceiro sistema) mostrou ser a escolha mais adequada na detecção de eventos epileptiformes, apresentando valores de sensibilidade de 93,3%, especificidade de 74.1% e seletividade de 26,4%.

Indarevi et al. (2008) apresentam uma estratégia para a identificação automática de eventos epileptiformes em sinais de EEG com 18 canais e 256 Hz de frequência de amostragem, baseada na análise multirresolução wavelet e em limiares adaptativos. O sinal de cada canal é decomposto em 6 sub-bandas utilizando a transformada wavelet discreta e um limiar adaptativo é aplicado nas sub-bandas 4 e 5 do sinal decomposto. O segmento do sinal que apresenta o evento epileptiforme é extraído do sinal original e sua energia é calculada. O segmento do sinal original que apresentar o maior valor de energia, de acordo com um determinado limiar de decisão, demarca o evento epileptiforme identificado. Este método apresentou índices de sensibilidade de 91,7%, especificidade de 89,3%, seletividade de 78,1% e eficiência de 90,5%.

Wiltschko et al. (2008) apresentam um método de filtragem de sinais de EEG utilizado na detecção de eventos epileptiformes pelo método *denoising* da transformada wavelet. O sinal utilizado apresenta uma frequência de amostragem de 31.25 kHz. Neste método os valores retidos no último nível de aproximação do sinal decomposto são substituídos por zeros. O sinal é então reconstruído sem as respectivas frequências, que geralmente são as frequências mais baixas que o sinal original apresenta. Os autores também apresentam um comparativo entre o método de filtragem implementado e um filtro *Butterworth* de 4ª ordem, demonstrando que a transformada wavelet tem a capacidade de atuar como um filtro digital, gerando um sinal com poucas distorções, em relação aos sinais processados pelos filtros *Butterworth*. Não apresenta índices de desempenho.

Kutlu et al. (2009) apresenta uma metodologia para a otimização de classificadores baseados em redes neurais MLP. São utilizados sinais de EEG com frequência de amostragem de 256 Hz e 19 canais. Neste processo os sinais são pré-processados e as características dos sinais são extraídas de quatro formas diferentes: por normalização, por transformação linear, transformação não linear e por análise de componentes principais. Foram utilizadas variações do algoritmo *backpropagation* com parada antecipada para o treinamento dos classificadores. O melhor classificador implementado alcançou índices

de sensibilidade média de 94,1%, seletividade média de 87,5% e especificidade média de 95,8%.

Nonclercq et al. (2009) apresentam um algoritmo de detecção de eventos epileptiformes adaptativo ao paciente. O algoritmo funciona em três etapas. Na primeira etapa é feita a detecção de alguns eventos epileptiformes utilizando parâmetros genéricos. Na segunda etapa os eventos detectados são utilizados para adaptar o algoritmo de detecção ao paciente. Na terceira etapa o algoritmo adaptado é utilizado para analisar individualmente o paciente através do modelo criado, com características extraídas dos eventos detectados inicialmente. A avaliação do algoritmo foi realizada através da comparação da pontuação obtida no processo de detecção de eventos, com a pontuação obtida com a análise de três especialistas. Neste processo foram analisados 17 registros de EEG e a métrica de avaliação foi através do índice Kappa.

Geng et al. (2010) apresentam uma metodologia de detecção de eventos epileptiformes baseada na morfologia do sinal, onde são obtidas a amplitude e a forma do evento e comparados com um limiar de decisão, baseado no desvio padrão do sinal. São utilizadas multi-wavelets para a extração de características do sinal transformado e um algoritmo hierárquico de clusterização para separar características discriminativas dos eventos. Esta metodologia foi aplicada apenas em sinais simulados e não apresenta índices de desempenho.

Keshri et al. (2011a, 2011b) apresentam um método de detecção baseado num autômato contendo 13 estados, onde cada estado é responsável em analisar determinados parâmetros, como a duração e a inclinação dos ângulos de subida e descida do pico do evento. De acordo com o ângulo obtido são atribuídos valores (-1, 0, 1). O sinal é deslocado entre os estados do autômato e as mudanças nas inclinações do sinal são analisadas por regras de decisão, verificando a ocorrência dos eventos epileptiformes, conforme a mudança rápida na inclinação deste sinal. Segundo os autores, esta metodologia alcançou 99,13% de eficiência na identificação de eventos epileptiformes.

Tzallas et al. (2012) e seus colaboradores apresentam uma revisão de diversos trabalhos a respeito de detecção de eventos epileptiformes e detecção de crises epileptiformes. Não há muitas informações a respeito das metodologias, apenas são informadas as linhas utilizadas para o desenvolvimento das mesmas, indicando apenas o índice de eficiência que cada uma alcançou (entre 85,9% a 100%) e as bases de sinal utilizadas.

Entre os trabalhos mais recentes que abordam técnicas e algoritmos utilizados na detecção automática das epilepsias, destaca-se o estudo realizado por Oroscho et al. (2013). Foi feita uma revisão de vários algoritmos para a detecção de crises epiléticas na última década, abordando de forma geral algumas técnicas baseadas na transformada wavelet, entropia, na decomposição em modo empírico (transformada de Hilbert-Huang), teoria do caos e análise de componentes principais, comparando o desempenho entre eles. Os autores deste trabalho também destacam a falta de implementação das metodologias apresentadas, citando a importância de se desenvolver uma ferramenta que seja realmente confiável e que possa ser aplicada na prática. Outro grande problema observado na literatura e que estes autores criticam é em relação à falta de padronização de métricas e métodos de avaliação no campo da detecção de crises epiléticas, salientando que este problema precisa ser resolvido, para permitir que sejam realizadas comparações homogêneas dos classificadores propostos. Os autores também apresentam uma comparação entre os trabalhos analisados e que utilizaram o índice de eficiência para avaliação dos classificadores descritos. Os valores apresentados variam de 88% a 100% de eficiência, destacando o trabalho realizado por Tzallas et al. (2007). Como observado em muitos trabalhos encontrados na literatura, não fica claro como exatamente os trabalhos foram feitos, sendo apresentados apenas os índices obtidos.

Comentários: A metodologia para a detecção de eventos epileptiformes abordada neste trabalho, leva em conta o período interictal do registro de EEG. O período interictal é o intervalo entre crises epiléticas, ou seja, os eventos epileptiformes ocorrem antes e após a ocorrência de uma crise epilética. Esses eventos possuem características distintas, normalmente uma espícula seguida de uma onda lenta. Esse tipo de evento é bem definido em relação à atividade de fundo do EEG. Outros eventos ocorrem no mesmo instante de tempo em canais adjacentes, formando um campo de potencial, sempre com um dos canais apresentando um evento mais eletronegativo. Os padrões eletrográficos encontrados no período ictal, ou seja, durante uma crise epilética são diferentes daqueles encontrados no período interictal e que foram utilizados neste trabalho. Sendo assim, a metodologia desenvolvida não atende os requisitos para a detecção de crises epiléticas, e sim de eventos epileptiformes. Muitos trabalhos encontrados na literatura abordam formas de detecção automatizada de crises epiléticas. Em relação à detecção de eventos epileptiformes, o número de trabalhos

encontrados é bastante reduzido, sendo que os mais relevantes foram descritos nesta seção. Maiores informações sobre métodos para a detecção automática de eventos epileptiformes podem ser encontrados em (Adeli & Ghosh-Dastidar, 2010) e (Tzallas, et al., 2012).

2.10 PESQUISAS REALIZADAS NO IEB-UFSC

Os trabalhos no Laboratório de Informática Médica do IEB-UFSC, com processamento e análise de sinais de EEG concentram-se basicamente em três linhas de pesquisa: identificação de eventos epileptiformes, identificação de padrões característicos do sono e avaliação da profundidade anestésica. As pesquisas tiveram início em 1994, através do estudo de técnicas para a detecção automática de estágios de sono usando mapas de Kohonen (Coimbra et al., 1994) (Coimbra et al., 1995). Desde então, outros trabalhos foram desenvolvidos através do estudo e análise do EEG como dissertações de mestrado (Rodrigues, 1997), (Toazza, 1998), (Silva, 1998), (Silva Jr., 1998).

Argoud (2001, 2004a, 2004b, 2006) propõe um sistema híbrido para a detecção automática de eventos epileptiformes, baseado em wavelets, em redes neurais e em regras de produção. Esta metodologia alcançou índices de desempenho médio (sensibilidade e especificidade) de 80%.

Rodrigues (2002) desenvolveu em sua tese de doutorado, um sistema para detecção e classificação automática de apnéias do sono a partir de registros polissonográficos.

Tavares (2003) apresentou em sua tese de doutorado um sistema de aquisição de biosinais de pacientes em cirurgia, com anestesia geral, na avaliação da profundidade anestésica.

Pereira (2003) em sua tese de doutorado realizou estudos para o tratamento de sinais bioelétricos para o processamento por redes neurais artificiais, através de funções de janelamento para suavizar as bordas da época do sinal de EEG e a aplicação da Transformada Wavelet. Esse trabalho obteve desempenho médio (entre sensibilidade, especificidade, VPP, VPN) de 73,2 %.

Sala (2005) em sua dissertação de mestrado desenvolveu um trabalho utilizando Mapas de Kohonen na detecção de eventos epileptiformes em sinais de EEG, obtendo um índice de desempenho médio de 70%.

Travessa (2006) realizou a análise de redes neurais complexas na detecção de espículas e piscadas em sinais de EEG, como dissertação de mestrado. Esse trabalho alcançou índice de desempenho médio (sensibilidade e especificidade) de 55%.

Mendonça (2007) desenvolveu em sua dissertação de mestrado, um trabalho sobre identificação automática de complexos K e fusos do sono em sinais de EEG.

Sovierzoski (2009) em sua tese de doutorado propôs uma avaliação de descritores morfológicos, junto com redes neurais artificiais do tipo MLP, na identificação de eventos epileptiformes. Essa metodologia obteve índices de sensibilidade de 91,92%, especificidade de 91,09%, valor preditivo positivo de 91,00% e valor preditivo negativo de 92,00%, alcançando desempenho médio de 91,32%.

Scolaro (2009) em sua dissertação de mestrado realizou uma investigação utilizando sinais de EEG e a transformada wavelet e propôs um classificador neural para a identificação de eventos epileptiformes. Essa metodologia alcançou índice de sensibilidade de 97,14%, especificidade de 94,55%, seletividade positiva de 96,59%, seletividade negativa de 95,41% e eficiência de 96,14%.

Boos (2011) em sua dissertação de mestrado propôs novos tipos de descritores morfológicos para a identificação automática de eventos epileptiformes, alcançando taxas de sensibilidade de 91%, especificidade de 83% e eficiência de 87%.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 CONCEITOS BÁSICOS SOBRE A ELETROENCEFALOGRAFIA

Em 1875, o fisiologista inglês Richard Caton fez registros elétricos a partir da superfície do encéfalo de cães e coelhos, utilizando um mecanismo sensível a tensão, demonstrando que os potenciais elétricos registrados a partir do encéfalo apresentavam flutuações. Mas apenas em 1929 que a atividade elétrica do cérebro em humanos foi descrita pelo psiquiatra alemão Hans Berger, o qual introduziu o termo eletroencefalograma (EEG) e que também observou diferenças entre o EEG da vigília e do sono (Webster, 1998).

O método mais utilizado para o registro da atividade elétrica do cérebro é o não invasivo. Neste método os eletrodos antes de serem posicionados no escalpo (couro cabeludo), recebem uma substância eletrolítica condutora, permitindo que o potencial elétrico presente na superfície do córtex passe pelas várias camadas de tecido e seja captado pelo eletrodo. Quando eletrodos são colocados na superfície exposta do córtex o registro é chamado de eletrocorticograma (EcoG) ou registro de profundidade (Webster, 1998).

3.1.1 Origem dos Sinais Elétricos Encefálicos

O EEG é a medição das correntes elétricas que fluem durante excitações sinápticas, dos dendritos de muitos neurônios piramidais no córtex cerebral. Quando as células cerebrais (neurônios) são ativadas, correntes sinápticas são produzidas dentro dos dendritos (Figura 10).

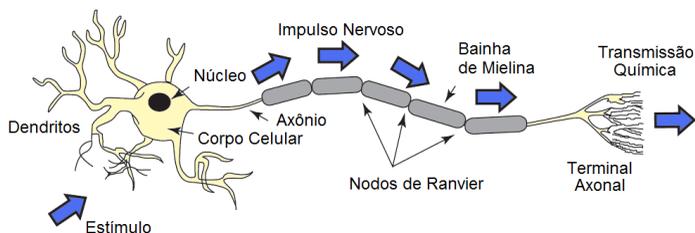


Figura 10 – Estrutura de um Neurônio.

Fonte: Modificado de (Sanei & Chambers, 2007).

As correntes são geradas principalmente através do bombeamento dos íons positivos de sódio (Na^+), potássio (K^+), cálcio (Ca^+) e dos íons negativos de cloro (Cl^-), através das membranas do neurônio na direção indicada pelo potencial de membrana. Essa corrente gera um campo magnético mensurável por eletromiografia (EMG) e um campo elétrico secundário sobre o couro cabeludo, mensurável por sistemas de EEG (Bear, et al., 2002), (Sanei & Chambers, 2007). A diferença de potenciais elétricos é obtida através dos potenciais pós-sinápticos gerados pelas células piramidais, as quais criam dipolos elétricos entre o soma, que é o corpo do neurônio e os dendritos, os quais são responsáveis por levar informações ao corpo celular (Bear, et al., 2002).

Por existir várias camadas de tecido (couro cabeludo, ossos, superfície externa do córtex) na cabeça, ocorre uma atenuação nos potenciais gerados. Apenas grandes populações de neurônios ativos podem gerar potenciais fortes o bastante para serem registrados utilizando eletrodos no escalpo. Os potenciais são depois amplificados para fins de exibição e processamento (Sanei & Chambers, 2007).

3.1.2 Ritmos Cerebrais

No sinal de EEG é possível fazer uma distinção entre os ritmos da atividade cerebral por faixas de frequência, associadas a cada um deles. O EEG registra ondas de várias frequências, sendo as mais comuns, delta, teta, alfa e beta (Montenegro, et al., 2001).

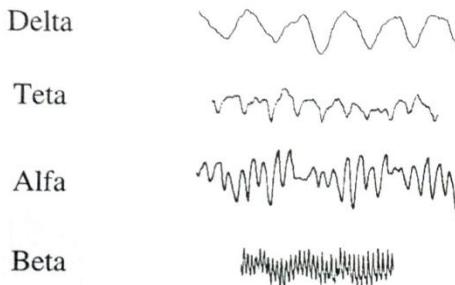


Figura 11 – Exemplos de ritmos cerebrais típicos presentes nos sinais de EEG.
Fonte: (Montenegro, et al., 2001).

As ondas Delta (δ) caracterizam-se pela faixa de frequências de 0,5 a 3 Hz apresentam elevadas amplitudes (até $300\mu\text{V}$) e uma duração aproximada de 0,33 segundos. Introduzido por Walter (1936) o ritmo delta ocorre no estado de sono profundo, sendo rara a sua ocorrência em adultos o qual designa todas as frequências abaixo da faixa de frequências do ritmo alfa (Niedermeyer & Silva, 2004).

As ondas Teta (θ) caracterizam-se pela faixa de frequências de 4 a 7 Hz, ocorrendo nas regiões parietais e temporais. Ocorrem na infância e em adultos jovens (Niedermeyer & Silva, 2004).

As ondas Alfa (α) caracterizam-se pela faixa de frequências de 8 a 13 Hz varia de pessoa para pessoa e a frequência mais proeminente é aproximadamente 10,5 Hz, sendo mais frequente sua ocorrência nas áreas occipitais, com o paciente acordado e com os olhos fechados (Niedermeyer & Silva, 2004).

As ondas Beta (β) caracterizam-se pela faixa de frequências de 13 a 30 Hz, sendo predominantes nas regiões frontal e parietal. Apresentam ondas com baixa amplitude e ocorrem mais nas áreas frontal e central (Niedermeyer & Silva, 2004).

As ondas Gama (γ) foram introduzidas por Jasper e Andrews (1938) para descrever frequências entre 30 a 50 Hz, sendo também denominadas ondas betas rápidas. A faixa de classificação das ondas beta proposta inicialmente por Berger descrevia frequências de 20 a 50 Hz, agora são classificadas como ondas beta de 13 a 30 Hz e ondas gama de 30 a 50 Hz (Niedermeyer & Silva, 2004).

O ritmo Mu (μ) normalmente é registrado nas regiões centrais, preferencialmente nos eletrodos C3 e C4 e geralmente visto na população de adultos mais jovens, em momentos de relaxamento, podendo ser afetado pela movimentação dos olhos. Apresenta amplitudes próximas a $50\mu\text{V}$ e frequências entre 8 Hz e 10 Hz. Essa atividade sofre uma atenuação no momento em que o paciente realiza um ato motor com o membro contralateral. Geralmente o ato de pensar em realizar o movimento motor já é o suficiente para atenuar o ritmo mu (Montenegro, et al., 2001).

O ritmo Phi (ϕ) apresenta frequências menores que 4 Hz e ocorre entre dois segundos com os olhos fechados (Montenegro, et al., 2001).

O ritmo Kappa (κ) é um ritmo alfa temporal anterior. Acredita-se que este ritmo é o resultado de discreta oscilação lateral do globo ocular e é considerado um sinal de artefato (Montenegro, et al., 2001).

O ritmo Sigma (σ) (também conhecido como fuso do sono) apresenta atividades entre frequências de 11 Hz e 15 Hz (Montenegro, et al., 2001).

O ritmo Tau (τ) representa a atividade alfa na região temporal (Montenegro, et al., 2001).

O ritmo Chi (χ) é semelhante ao ritmo mu e acredita-se que esta atividade possa ser um padrão rolândico específico com frequências entre 11 Hz e 17 Hz. Esta atividade foi observada durante exercícios de Hatha Yoga (Montenegro, et al., 2001).

As ondas Lambda (λ) são caracterizadas por transientes agudos, com amplitudes geralmente abaixo de $90\mu\text{V}$ e ocorrem na região occipital durante a exploração visual, de pacientes em vigília (Montenegro, et al., 2001).

3.1.3 Posicionamento dos Eletrodos e Nomenclatura

Em 1958, Herbert Jasper, após vários estudos de diferentes tipos de sistemas para aquisição, sugeriu um sistema que passou a ser amplamente utilizado no registro do EEG, chamado Sistema Internacional de Posicionamento de Eletrodos 10-20 (Figura 12).

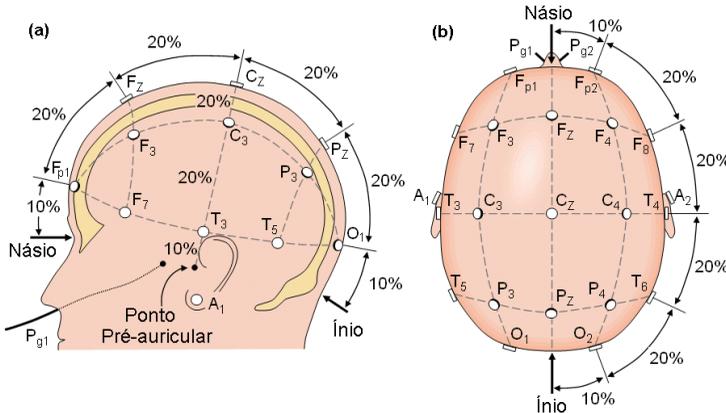


Figura 12 – Eletrodos no sistema 10-20, nas visões (a) temporal e (b) parietal. Fonte: Modificado de (Malmivuo & Plonsey, 1995).

Este sistema é baseado na estrutura anatômica do cérebro, apresentando divisões em hemisférios (direito e esquerdo) e subdivisões em lobos (frontal, parietal, temporal e occipital). Os eletrodos são identificados por uma letra maiúscula correspondente à inicial do lobo onde são fixados, juntamente com um número par, caso o hemisfério

seja o direito e um número ímpar, caso seja o hemisfério esquerdo. Para os eletrodos colocados na região central, na distância média entre o ná시오 e o ínio, os eletrodos são identificados com a letra “C”, sendo que na linha imaginária que liga o ná시오 e o ínio, é acrescentada a letra “z” minúscula, ao invés de números. Já na região auricular os eletrodos são identificados com a letra “A”. Os eletrodos colocados na região frontal próxima no ná시오 são acrescentados da letra “p” minúscula (Malmivuo & Plonsey, 1995), (Webster, 1998).

3.1.4 Sistema de Referência dos Sinais de Eletroencefalografia

Existem métodos distintos de derivações para a montagem dos canais: método bipolar e método referencial. No método bipolar é medida a diferença de potencial entre um par de eletrodos (Figura 13a). No método referencial o potencial de cada eletrodo é comparado com um eletrodo de referência ou à média de todos os eletrodos (Figura 13b) (Webster, 1998).

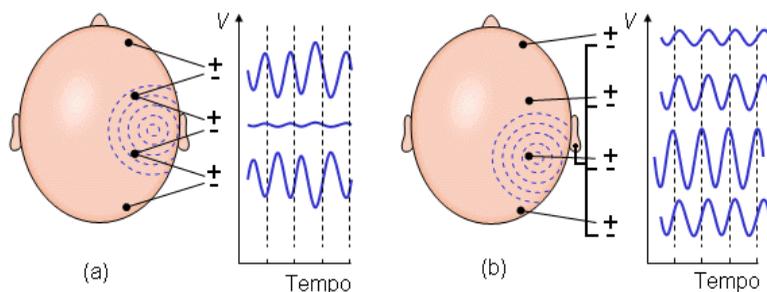


Figura 13 – Registro de potenciais nas formas (a) bipolar e (b) referencial. Fonte: Modificado de (Malmivuo & Plonsey, 1995).

Na Figura 13[a] pode-se observar que a diferença de potencial medida entre eletrodos posicionados em linhas equipotenciais é nula, sendo que os demais sinais estão com reversão de fase, devido à forma de como é feita a aquisição. Na Figura 13[b] pode-se observar que a diferença de potencial é proporcional à propagação do evento, sendo captada por todos os eletrodos e a referência é o potencial do eletrodo posicionado na orelha, devido ao fato desta região apresentar pouca influência da propagação da onda e pouca variação de potencial elétrico.

Outros eletrodos podem ser usados como referência, tais como eletrodos fixados na ponta do nariz, nas pernas, nas mãos, eletrodos posicionados nas regiões Cz e FPz (Chan, et al., 2010), (Sanei & Chambers, 2007). Para este trabalho foi adotada a posição Pz, indicada pelos especialistas do CEPESC, como referência padrão para a análise dos registros de EEG.

3.1.5 Artefatos

O EEG registra a diferença de potencial entre dois pontos do escalpo, podendo sofrer interferências vindas de outras fontes geradoras de atividade elétrica (músculos, coração, rede elétrica, etc.). Os artefatos quando presentes nos sinais coletados podem acabar mascarando os padrões de interesse. Os artefatos podem ser fisiológicos e não fisiológicos.

Os artefatos fisiológicos se originam do próprio corpo do paciente. O movimento do corpo do paciente, contração muscular, movimento ocular, pulsação arterial, deglutição, movimentação da língua, resistência da pele por atividade vasomotora ou sudorese são exemplos bem comuns de artefatos fisiológicos que são encontrados nos traçados do EEG.

Os artefatos não fisiológicos são produzidos por meios externos, como interferência elétrica ou mesmo por defeito do equipamento de registro, como cabos, amplificadores, eletrodos, etc (Montenegro, et al., 2001).

O Artefato muscular é produzido pela contração dos músculos do escalpo, sendo mais frequentes nas regiões frontais e temporais e apresentam amplitudes elevadas. A Figura 14 apresenta um exemplo de artefato muscular ocorrido nas regiões frontais e temporais.

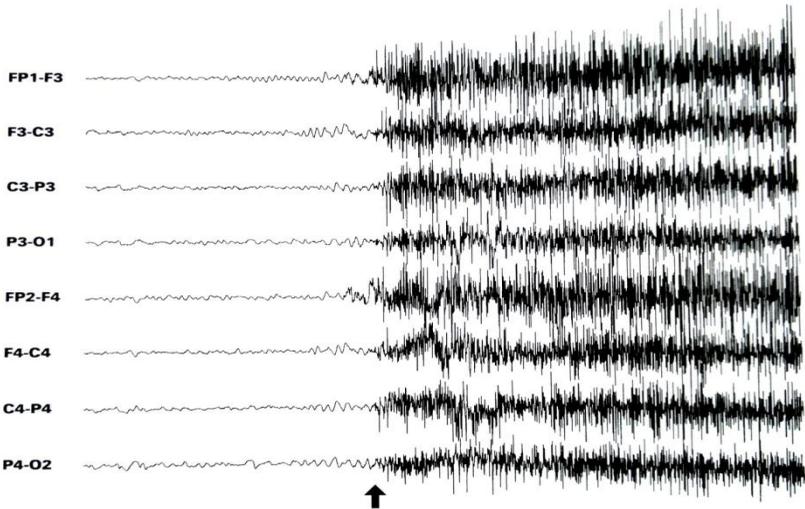


Figura 14 – Exemplo de artefato muscular.
 Fonte: (Lüders & Noachtar, 2000).

O artefato de corrente elétrica (60 Hz) ocorre quando há problemas no aterramento ou quando a impedância no eletrodo está elevada. É caracterizado por uma atividade sinusoidal na frequência de 60 Hz (Figura 15).

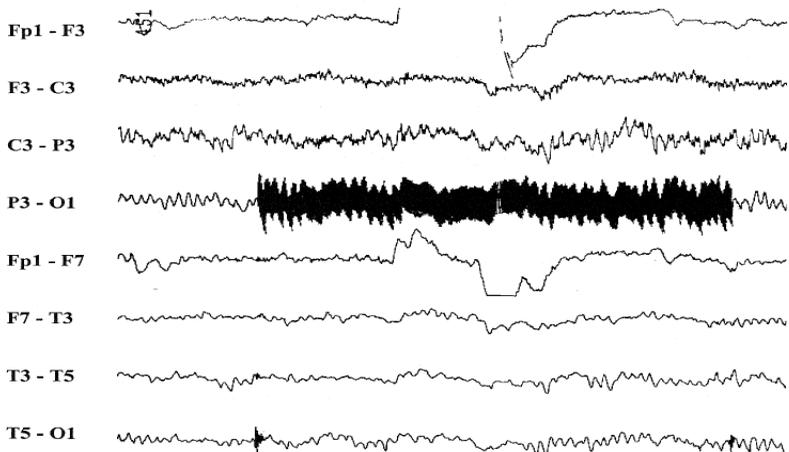


Figura 15 – Artefato de corrente elétrica (60 Hz).
 Fonte: (Montenegro, et al., 2001).

Os Artefatos de movimentação ocular ocorrem devido ao fato da córnea ser carregada positivamente e a retina negativamente, produzindo alterações nos potenciais registrados nos canais próximos aos olhos (Fp1, Fp2, F7, F8), ao abrir e fechar dos olhos e na movimentação lateral do globo ocular. A Figura 16 apresenta um exemplo de artefato de movimentação ocular ao abrir e fechar os olhos.

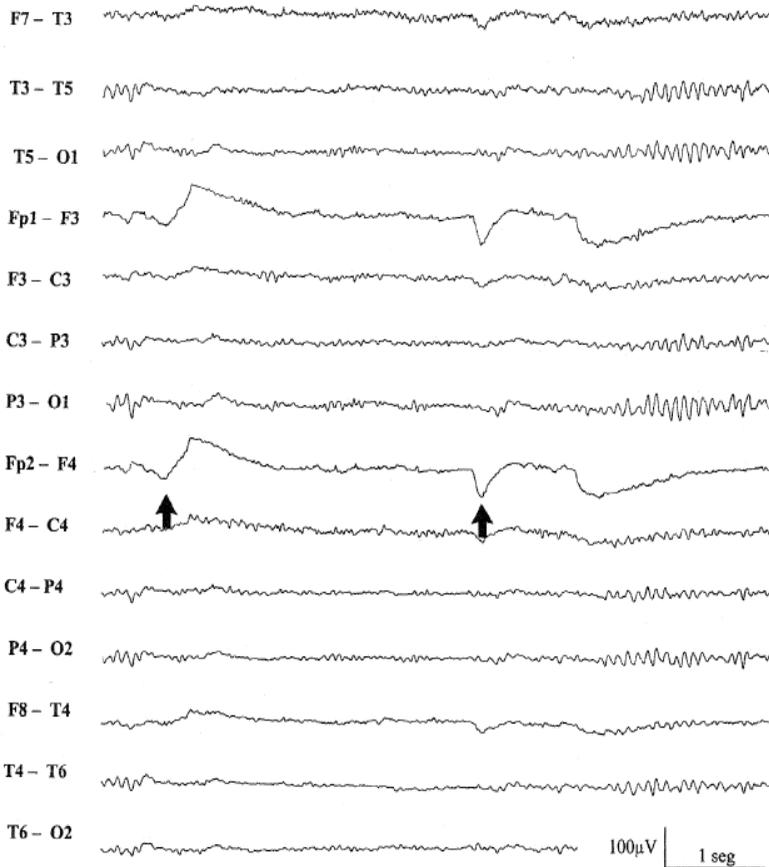


Figura 16 – Artefato de movimento ocular ao abrir e fechar dos olhos.
Fonte: (Montenegro, et al., 2001).

A Figura 17 apresenta um exemplo de artefato de movimentação ocular lateral, registrados nos canais Fp1, Fp2, F7, F8, T3, T4, Z1 e Z2.

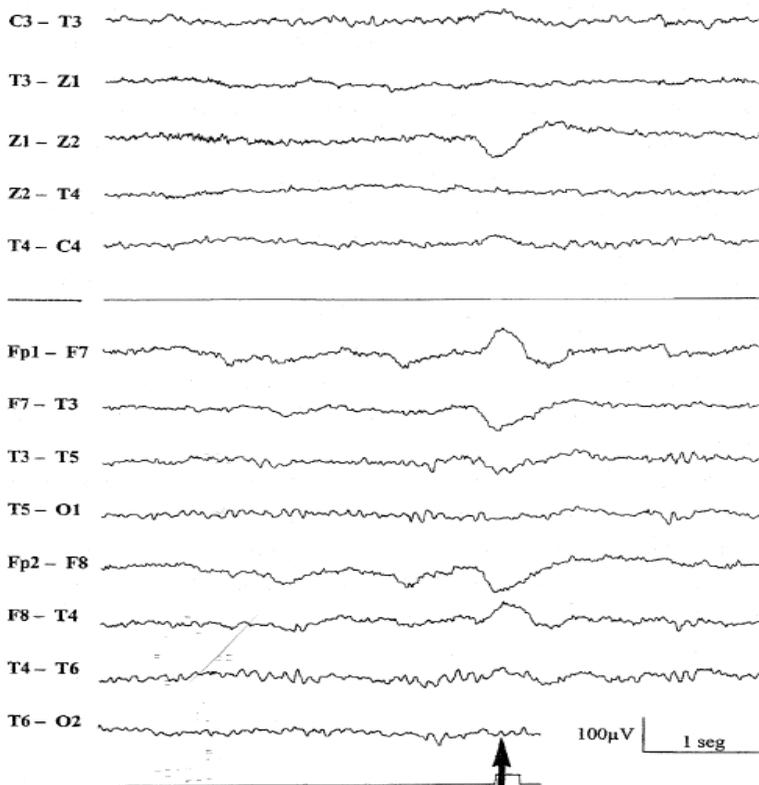


Figura 17 – Artefato de movimento ocular Fp1, Fp2, F7, F8, T3, T4, Z1 e Z2.
Fonte: (Montenegro, et al., 2001).

O artefato de estouro de eletrodo (Pop) é o registro de um potencial, devido a uma mudança súbita do potencial de junção entre o eletrodo e o escalpo, por impurezas no metal do eletrodo ou bolhas de ar no gel condutor. Um exemplo de traçado contendo este tipo de artefato é apresentado na Figura 18.

Os artefatos de movimento são gerados quando o paciente faz movimentos com a cabeça ou com o corpo, gerando interferências dos cabos que ligam os eletrodos ao equipamento (Figura 19).

Os artefatos devido à sudorese alteram a impedância do eletrodo pelo contato com substâncias salgadas produzidas na superfície da pele (Figura 20).

Os artefatos de eletrocardiograma são gerados pelos potenciais elétricos cardíacos e podem ser registrados em qualquer parte do corpo,

apresentando um traçado rítmico e agudizado, onde reflete na maioria das vezes a onda R do eletrocardiograma. Os eletrodos normalmente afetados são os eletrodos A1 e A2. A Figura 21 representa um exemplo de artefatos de eletrocardiograma.

O artefato vascular se um eletrodo estiver próximo a um vaso sanguíneo, ele irá registrar um pequeno potencial elétrico, devido ao movimento mecânico que o vaso realiza no momento em que o sangue é bombeado do coração.

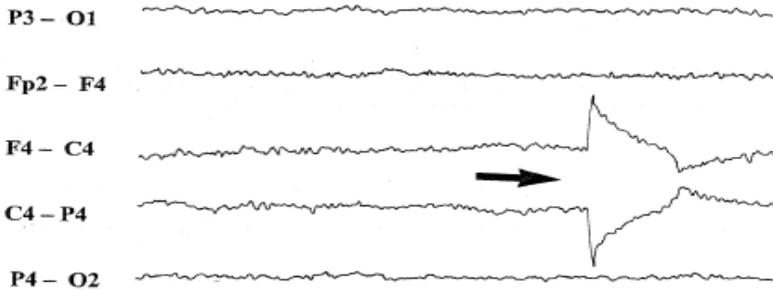


Figura 18 – Artefato de estouro de eletrodo nos canais F4-C4 e C4-p4.
Fonte: (Montenegro, et al., 2001).

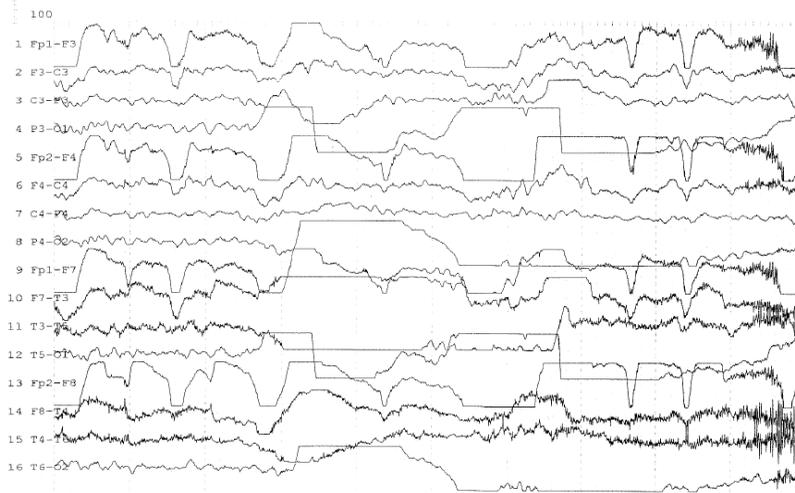


Figura 19 – Artefatos de movimento.
Fonte: (Montenegro, et al., 2001).

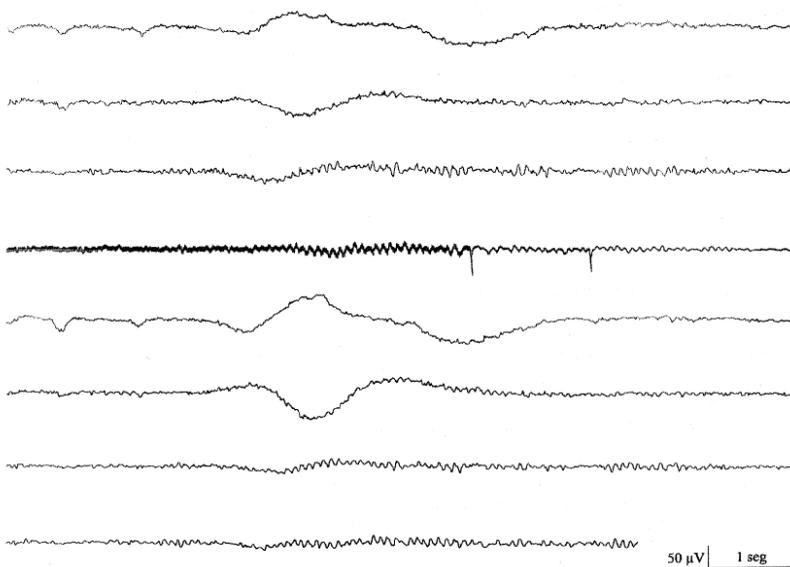


Figura 20 – Artefatos produzidos por sudorese.
 Fonte: (Montenegro, et al., 2001).

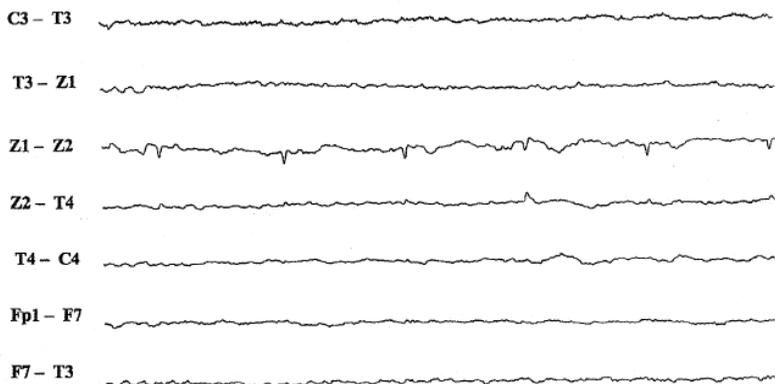


Figura 21 – Artefado de Eletrocardiograma nos eletrodos Z1-Z2.
 Fonte: (Montenegro, et al., 2001).

3.2 CONCEITOS BÁSICOS SOBRE WAVELETS

A transformada wavelet é uma ferramenta que tem sido aplicada na investigação de diversos fenômenos físicos, que vão desde a análise de dados climáticos, índices financeiros, biopotenciais, sinais sísmicos até a filtragem e compressão de imagens e sinais (Addison, 2002).

A ideia por trás da utilização da transformada wavelet existe há muito tempo. No entanto, a metodologia de análise, como se é conhecida hoje, teve início em meados dos anos 80 a partir da análise de sinais sísmicos. Investigações utilizando a transformada wavelet com aplicações em ciências e nas engenharias começaram apenas no início dos anos 90.

Devido ao crescente número de adeptos à sua utilização, até o final da década de 90 houve um aumento significativo no desenvolvimento e publicação de trabalhos científicos aplicando a transformada wavelet (Addison, 2002), o que se estendeu até os dias de hoje.

Na análise feita pela transformada wavelet são utilizadas pequenas funções ondulatórias conhecidas como wavelets (Figura 22).

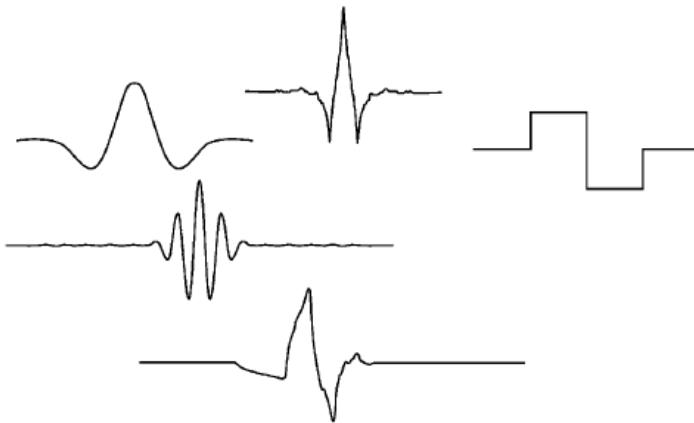


Figura 22 – Exemplos de funções wavelet.
Fonte: (Addison, 2002).

Um grande atrativo da transformada wavelet é a possibilidade de se analisar sinais e imagens no domínio do tempo e frequência, simultaneamente. As wavelets transformam o sinal original em outra

forma de representação, o que possibilita investigar apropriadamente as informações que o sinal apresenta de acordo com a aplicação desejada.

A transformada wavelet pode ser manipulada de duas maneiras diferentes: através do deslocamento no tempo, abrangendo diferentes locais do sinal (Figura 23[a]) e pela dilatação e compressão de suas escalas (Figura 23[b]). Se houver correlação entre a wavelet utilizada e o sinal analisado, num local específico e numa escala específica, o sinal transformado apresentará valores com amplitudes elevadas. Entretanto, se não ocorrer correlação o sinal transformado apresenta valores reduzidos como resultado deste processo.

O cálculo da transformada é feito em diferentes locais do sinal e em diferentes escalas da wavelet, o que gera um plano com as correlações entre a wavelet e o sinal original (Addison, 2002), conforme apresentado na Figura 24.

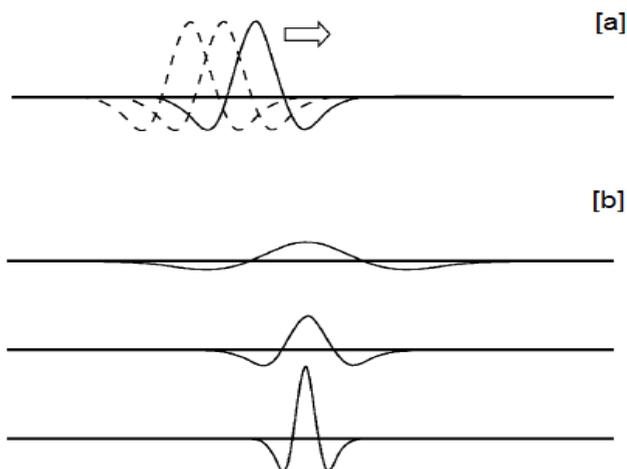


Figura 23 – Representação dos processos de deslocamento no tempo [a] e de alteração das escalas [b] em uma função wavelet.

Fonte: (Addison, 2002).

Este plano de correlações pode ser gerado de uma forma suave e contínua através da transformada wavelet contínua (CWT) ou em passos discretos através da transformada wavelet discreta (DWT). Estas duas formas de utilização da transformada wavelet são descritas nas seções seguintes.

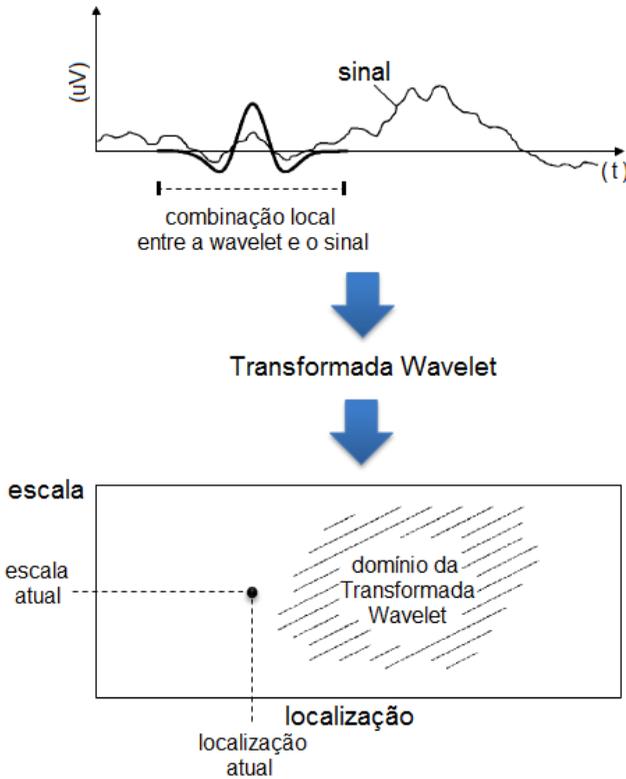


Figura 24 – Nesta figura são apresentados a wavelet, o sinal e a transformação do sinal. Pode ser observado que o ponto máximo do sinal transformado é mostrado no plano do domínio da transformada wavelet, representando a escala e a localização atual da alta correlação entre o sinal e a wavelet.

Fonte: (Addison, 2002).

3.2.1 Transformada Wavelet Contínua (CWT)

A análise no domínio tempo-frequência através da Transformada Wavelet (TW) é realizada adotando-se uma função Wavelet protótipo, denominada wavelet-mãe. Esta wavelet-mãe sofre escalonamentos e translações, formando as wavelets-filhas conforme a Equação 1 (Mallat, 1999), (Addison, 2002).

$$\psi(t) = \frac{1}{\sqrt{a}} \cdot \psi\left(\frac{t-b}{a}\right) \quad \text{Equação (1)}$$

onde $\psi(t)$ é a wavelet-mãe e $\psi_{a,b}$ é a wavelet-filha, $a^{-1/2}$ é a constante de normalização da energia para as wavelets, b é o fator de translação e a é o fator de dilatação não-nulo. Se $a > 1$ a função wavelet é expandida e se $a < 1$, a wavelet é contraída.

Para que uma função possa ser uma wavelet é preciso que esta satisfaça algumas condições:

1. Condição de Admissibilidade: para que uma função seja aceita como Wavelet, deve satisfazer à condição de admissibilidade, que é:

$$C_\psi = \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty \quad \text{Equação (2)}$$

onde C_ψ é uma constante e $\Psi(\omega)$ a função candidata a *wavelet-mãe* $\psi(t)$. Essa condição de admissibilidade equivale a exigir que a função $\Psi(\omega)$ se anule na origem.

Assim, tem-se:

$$\Psi(0) = \int_{-\infty}^{\infty} \psi(t) dt = 0 \quad \text{Equação (3)}$$

significando que $\psi(t)$ deve ser oscilante e de média nula.

2. Energia Finita: Condição descrita através da Equação 4.

$$\text{Energia} = \int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad \text{Equação (4)}$$

Para ilustrar o uso da transformada wavelet na análise de eventos epileptiformes, foi utilizada a wavelet-mãe chapéu mexicano ou segunda derivada da função de distribuição gaussiana, representada pela Equação 5.

$$\psi(t) = (1 - t^2)e^{-t^2/2} \quad \text{Equação (5)}$$

A Figura 25 mostra a representação da análise de um evento epileptiforme, através da transformada wavelet contínua em 64 escalas. Pode ser observado que o pico do evento é marcado no escalograma em pelo menos 20 escalas diferentes, tornando difícil a escolha de uma escala que compreenda toda a faixa de frequências que os eventos epileptiformes apresentam.

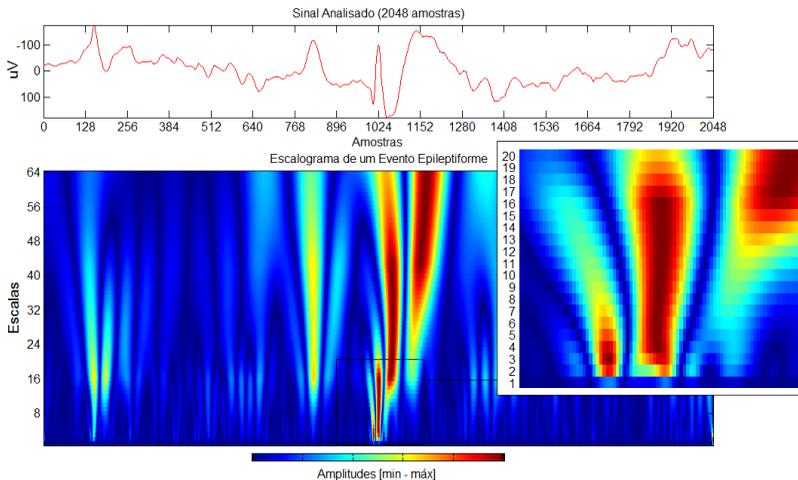


Figura 25 – Representação das escalas da transformada wavelet contínua da análise de um evento epileptiforme.

3.2.2 Transformada Wavelet Discreta (DWT)

A transformada wavelet contínua utiliza os parâmetros de variação do tempo e escalas contínuas. No entanto, na prática, para a computação da transformada wavelet estes parâmetros são discretizados. O emprego de valores discretos para a e b (com $a \geq 1$ e $b \geq 1$) na transformada wavelet contínua determina a transformada wavelet discreta, descrita pela Equação 6 (Mallat, 1999), (Addison, 2002).

$$\psi(t) = \frac{1}{\sqrt{a_0^i}} \psi\left(\frac{t - kb_0 a_0^i}{a_0^i}\right) \quad \text{Equação (6)}$$

onde k e i são inteiros, b_0 e a_0 são os parâmetros de translação e escalonamento, respectivamente. Na maior parte das aplicações para DWT emprega-se a sequência diádica, onde a_0 varia em potências inteiras de 2 ($a_0 = 2$) e o valor escolhido para b_0 é 1.

A Figura 26 mostra a representação da análise do evento epileptiforme utilizado anteriormente, através da transformada wavelet discreta em 10 escalas. Pode ser observado que o pico do evento é marcado no escalograma em pelo menos quatro escalas diferentes, tornando mais fácil a escolha de escalas, que compreendam a faixa de frequências que os eventos epileptiformes apresentam.

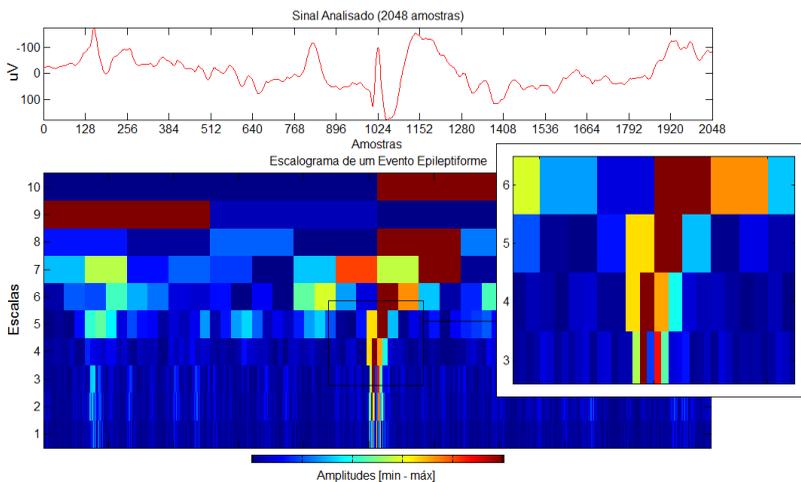


Figura 26 – Representação das escalas da transformada wavelet discreta na análise de um evento epileptiforme.

Escolhas comuns para os parâmetros a_0 e b_0 da DWT são 2 e 1, respectivamente. Esta escala logarítmica na potência de 2 para ambos os passos de translação e dilatação da wavelet é conhecido como sequência diádica, caracterizando a análise multirresolução wavelet.

Na análise multirresolução wavelet os sinais discretos são decompostos utilizando bancos de filtros espelho multirresolução em quadratura (Figura 27). Isto é, um conjunto de filtros $H(n)$ extraem as características médias do sinal (Aproximações), sendo somados a um conjunto de filtros $G(n)$, baseados nas funções wavelets, que extraem as características de alta frequência (Detalhes), como apresentado na Figura 28. As aproximações são as componentes de alta escala e baixas

frequências do sinal (S), já os detalhes são as componentes de baixa escala e altas-frequências do sinal (S) (Addison, 2002).

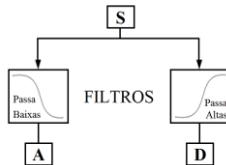


Figura 27 – Processo de decomposição do sinal (S), onde são obtidos os níveis de Aproximação (A) e Detalhe (D).

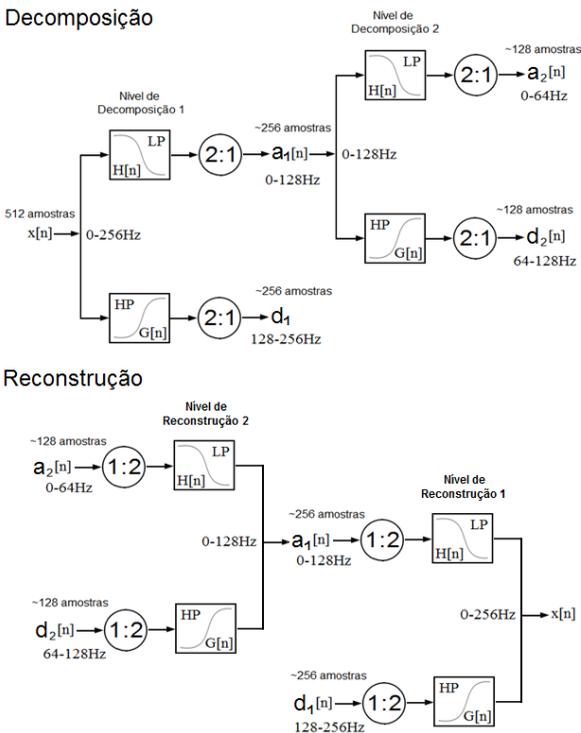


Figura 28 – Aplicação de filtros multirresolução a um sinal $x[n]$. Os filtros $G[n]$ extraem os detalhes $d_i[n]$. Os filtros $H[n]$ extraem as aproximações do sinal $a_i[n]$, em níveis i cada vez menores de refinamento.

Para um melhor entendimento, do que acontece na análise multirresolução wavelet, a Tabela 2 contém frequências relacionadas a dez níveis de decomposição, para um sinal com 512 Hz de frequência de amostragem.

Tabela 2 – Lista de frequências relacionadas a cada nível de decomposição para um sinal de 512 Hz de frequência de amostragem.

Nível de decomposição	Aproximações (Hz)	Detalhes (Hz)
1	0 – 128	128 – 256
2	0 – 64	64 – 128
3	0 – 32	32 – 64
4	0 – 16	16 – 32
5	0 – 8	8 – 16
6	0 – 4	4 – 8
7	0 – 2	2 – 4
8	0 – 1	1 – 2
9	0 – 0,5	0,5 – 1
10	0 – 0,25	0,25 – 0,5

Para os conceitos descritos anteriormente foi gerado um sinal senoidal com as frequências de 1, 5, 10, 25 e 50 Hz, o qual será utilizado para demonstrar a decomposição wavelet (Figura 29). O sinal foi decomposto em dez níveis de decomposição e reconstruído pelas aproximações A10 a A1 (Figura 30) e pelos detalhes D10 a D1 (Figura 31).

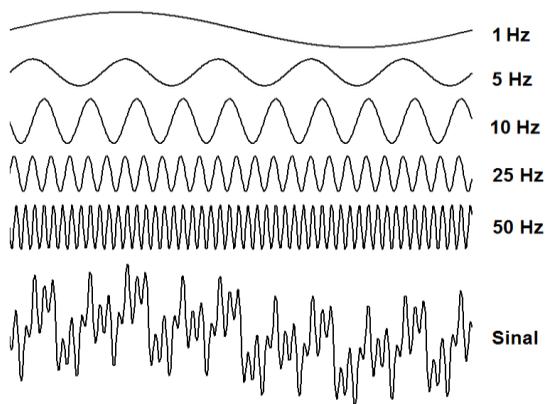


Figura 29 – Sinal senoidal com frequências de 1, 5, 10, 25 e 50 Hz, utilizados para demonstrar a análise multirresolução wavelet, onde o sinal é decomposto e reconstruído em aproximações e detalhes.

Observando a Figura 30, à medida que os níveis de aproximação aumentam, há uma perda das componentes de frequências que compõem este sinal. Por exemplo, o sinal gerado apresenta frequências até 50 Hz, as quais são mantidas até o segundo nível de aproximação (A2), por este

abranger frequências de 0 a 64 Hz. A partir do terceiro nível de aproximação (A3) o sinal começa a perder as componentes de frequência de 50 Hz, pelo fato deste nível abranger apenas frequências entre 0 e 32 Hz. Esta característica faz com que as aproximações se comportem como um filtro passa-baixas.

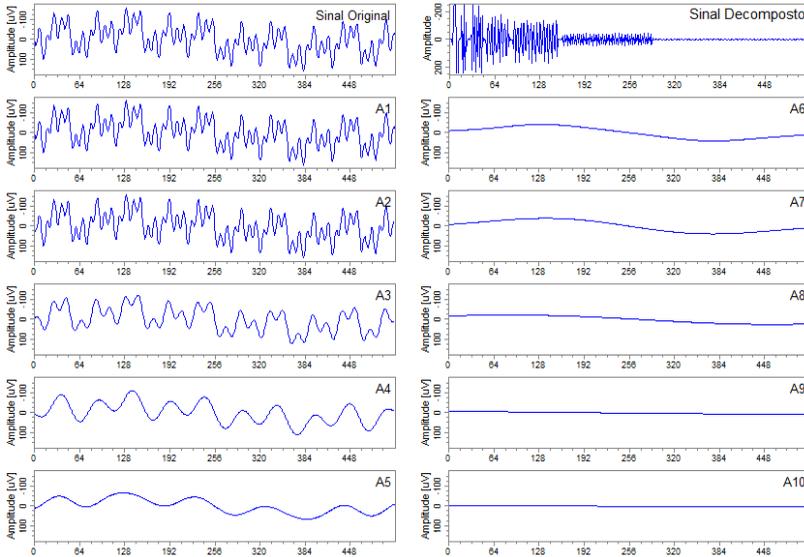


Figura 30 – Representação da reconstrução do sinal gerado por dez níveis de aproximação.

Da mesma forma, que o sinal de teste gerado, foi submetido à decomposição e reconstrução pelos níveis de aproximação, o mesmo também foi decomposto e reconstruído pelos níveis de detalhe. Pela Figura 31 pode ser observado que os níveis de detalhes retêm faixas de frequência específicas do sinal, o que caracteriza um filtro passa-bandas. As componentes de frequência de 50 Hz e 25 Hz são observadas no terceiro (D3) e quarto (D4) níveis de detalhe, respectivamente. Já a componente de frequência de 10 Hz fica mais evidente no quinto nível de detalhe (D5). Nos níveis de detalhe D6 e D8, as frequências de 5 Hz e 1 Hz, respectivamente, se tornam mais visíveis.

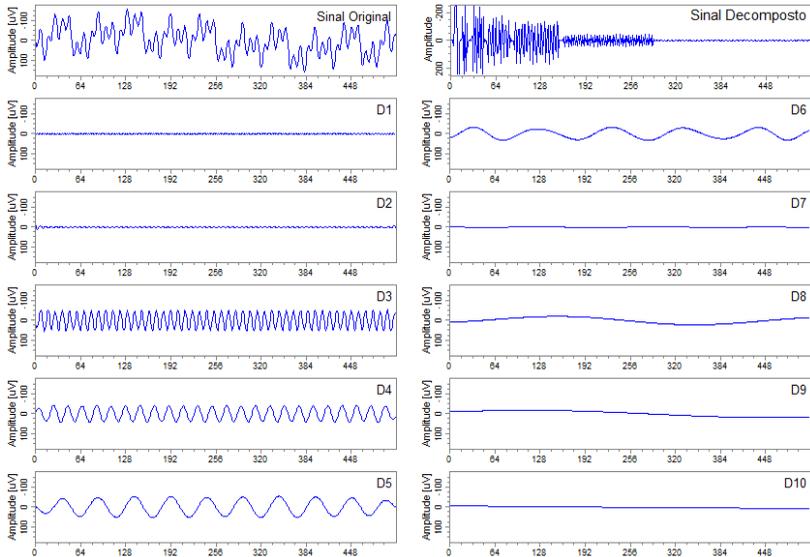


Figura 31 – Representação da reconstrução do sinal gerado por dez níveis de detalhe.

3.2.3 Filtragem de sinais utilizando o método *Denoising*

O método de *denoising* é um recurso que pode ser utilizado no processo de decomposição da transformada wavelet, permitindo que sinais ou imagens possam ser filtrados através da manipulação dos coeficientes do sinal decomposto no domínio wavelet, antes de serem novamente reconstruídos. Neste processo os coeficientes do sinal decomposto podem ser modificados ou mesmo eliminados dependendo da aplicação (Addison, 2002). Por exemplo, é possível eliminar grupos individuais de coeficientes de um determinado nível de escala, apenas substituindo seus respectivos valores por zero, como mostra a Figura 32[a], ou estes coeficientes podem ser manipulados através do uso de um limiar de decisão (λ), como mostra a Figura 32[b]. Neste segundo método as amplitudes dos coeficientes do sinal decomposto são analisadas e não as escalas. Caso as amplitudes ultrapassem o limiar definido, elas podem ser mantidas ou removidas dependendo da aplicação.

Essas duas formas de manipulação dos coeficientes do sinal decomposto caracterizam formas alternativas do uso da transformada wavelet como um filtro digital, pois a manipulação dos coeficientes do sinal reflete diretamente nas frequências que o sinal vai apresentar, após sua reconstrução.

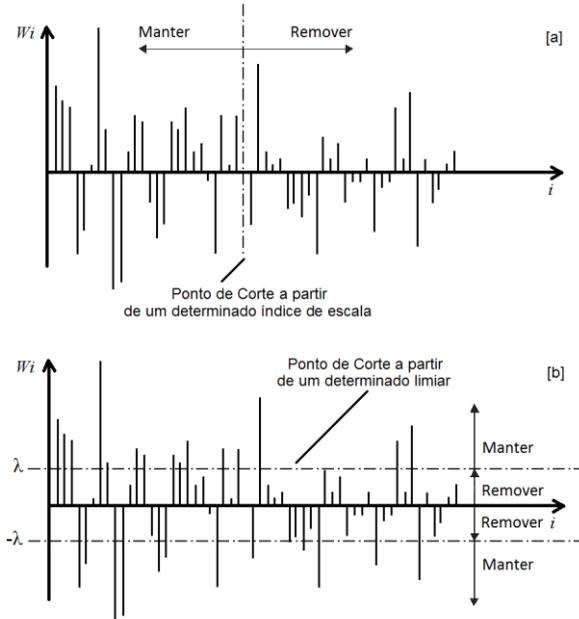


Figura 32 – *Denoising* da transformada wavelet para a filtragem de sinais.
Fonte: Modificado de (Addison, 2002).

Para demonstrar o comportamento de um sinal processado pelo método *denoising* foi utilizado um evento epileptiforme decomposto em 6 níveis, gerando os níveis A6 e D6, D5, D4, D3, D2 e D1 (Figura 33[a]). Para uma melhor visualização os sinais originais (em preto) e os sinais processados (em azul) foram sobrepostos, como forma de contrastar as modificações efetuadas entre eles.

Na Figura 33[b] é apresentada a primeira forma de filtragem através da escolha de um determinado nível de decomposição. O nível A6 foi removido do sinal decomposto, aplicando-se zeros aos coeficientes correspondentes (início do sinal até a marca vermelha). Ao eliminar este nível de aproximação, as frequências mais baixas do sinal também serão eliminadas após a sua reconstrução. O sinal resultante

deste processo (azul) em comparação com o sinal original (preto) apresenta uma redução das oscilações de baixa frequência, ressaltando o pico do evento epileptiforme.

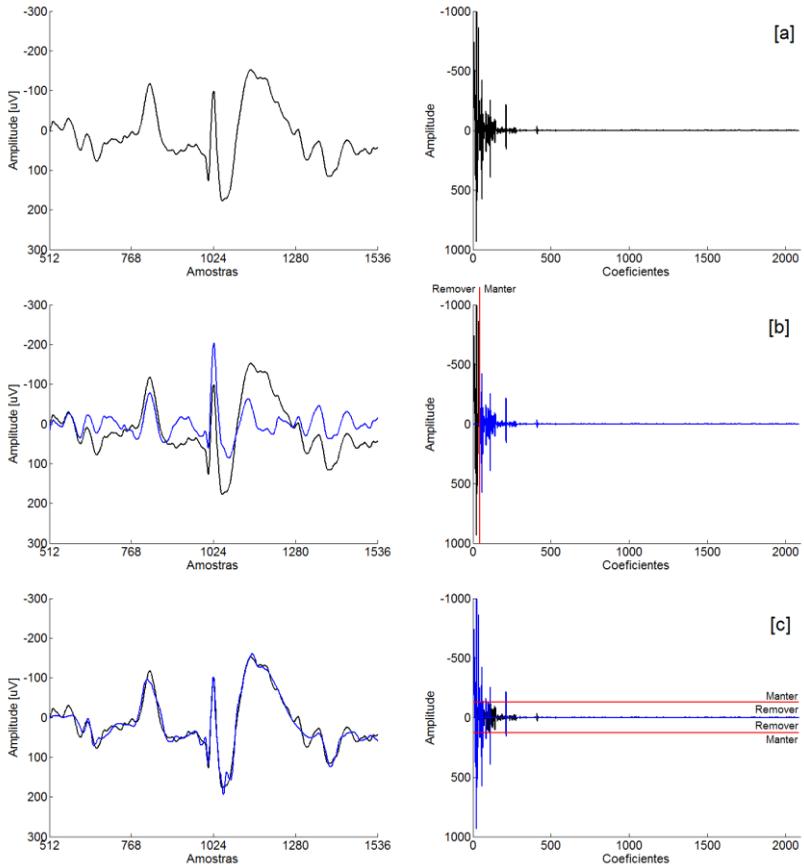


Figura 33 – Demonstração do método *denoising* para a filtragem de sinais. Em [a] o sinal decomposto, [b] decomposição por escala e [c] por limiares.

Na Figura 33[c] é apresentada a segunda forma de filtragem decorrente da escolha de um determinado limiar de decisão (neste caso quatro desvios padrão). Ao remover os coeficientes compreendidos entre os limiares (demarcados em vermelho), substituindo os respectivos valores por zero, as altas frequências do sinal sofreram alterações. As altas frequências serão cada vez mais atenuadas, à medida que este limiar aumentar, fazendo deste processo um filtro passa-baixas. Ao

remover os coeficientes que ultrapassarem o limiar estipulado, as baixas frequências do sinal serão atenuadas, tornando este processo um filtro passa-altas.

O filtro proposto neste trabalho é baseado na primeira forma de filtragem dos sinais, onde as frequências desnecessárias que compõem os sinais de EEG são eliminadas através da manipulação de níveis específicos do sinal decomposto, o qual será mais bem explicado no Capítulo 4.

Comentários: Maiores informações sobre a transformada wavelet, na decomposição e reconstrução de sinais pela análise multirresolução wavelet podem ser encontrados em (Addison, 2002), (Burrus, et al., 1998), (Mallat, 1999).

3.3 REDES NEURAIAS ARTIFICIAIS

Haykin (2001) define uma Rede Neural Artificial (RNA) como um processador maciça e paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso.

O desenvolvimento de uma RNA está fundamentado no do poder de processamento e reconhecimento que o cérebro humano apresenta, exercendo tarefas complexas de modo eficiente e rápido. Tem habilidade de aprender e generalizar, produzindo saídas adequadas para entradas não presentes durante o treinamento, o que possibilita a resolução de problemas complexos (Haykin, 2001).

As RNAs consistem basicamente de um ou mais conjuntos de neurônios artificiais interconectados e dispostos em camadas formando uma rede. Quando devidamente treinadas são capazes de processar matematicamente dados apresentados à camada de entrada. Tais dados são propagados ao longo das demais camadas, atingindo a camada de saída, onde será disponibilizada a resposta da rede (Haykin, 2001).

Nos itens a seguir são descritos os principais elementos que compõem a estrutura de uma RNA, entre elas o neurônio artificial, as funções de ativação e o algoritmo de treinamento *Backpropagation*. Serão apresentadas também as técnicas de validação cruzada e parada antecipada que, incorporadas ao processo de treinamento, auxilia no correto funcionamento do treinamento da RNA.

3.3.1 O Neurônio Artificial

O neurônio artificial (Figura 34) é uma unidade de processamento de informações, o qual é formado por três elementos básicos: um conjunto de sinapses, um somador e uma função de ativação. Apresenta ainda um elemento que tem o efeito de aumentar ou diminuir a entrada da função de ativação, denominado *bias*. O conjunto de sinapses forma a conexão entre as entradas da rede e os neurônios. Cada sinapse é caracterizada por um peso ou força própria, estando presente em um intervalo que inclui valores positivos e negativos.

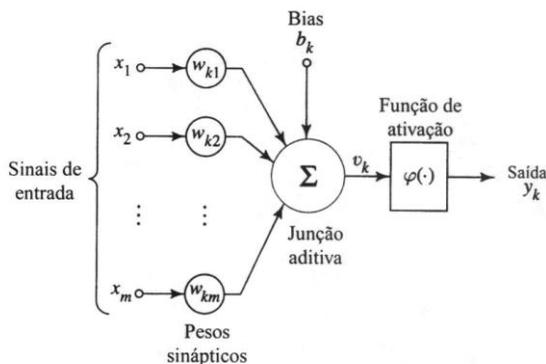


Figura 34 – Neurônio artificial e suas entradas, pesos sinápticos, junção aditiva e função de ativação.

Fonte: (Haykin, 2001).

O somador soma os sinais de entrada, ponderado pelas respectivas sinapses do neurônio (Equação 7).

$$net_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad \text{Equação (7)}$$

onde o índice k representa o neurônio em questão e o j representa a entrada vinda de outros neurônios, net_k é a soma ponderada das sinapses do neurônio, b_k é o termo de polarização da rede (*bias*). A função de ativação é responsável pela ativação ou inibição do neurônio artificial. Também conhecida como função restritiva a função de ativação

restringe a amplitude de saída de um neurônio a um valor finito (Equação 8).

$$y_k = \varphi(\text{net}_k) \quad \text{Equação (8)}$$

onde y_k é a função de saída do neurônio e φ é a função de ativação.

3.3.2 Funções de Ativação (φ)

As funções mais comumente utilizadas como função de saída de um neurônio são: a função linear (Equação 9), a função logística (Equação 10) e a função tangente hiperbólica (Equação 11).

A função linear normalmente é utilizada nas camadas de saída da rede e apresenta seguinte forma:

$$y(x) = ax + b \quad \text{Equação (9)}$$

onde a e b são constantes escalares.

A função logística assume valores entre 0 a 1 e novas funções podem ser derivadas apenas com o ajuste da constante k .

$$y(x) = \frac{1}{1 + e^{-kx}} \quad \text{Equação (10)}$$

onde k é um escalar positivo.

A função tangente hiperbólica assume valores entre -1 a 1 e outras funções também podem ser derivadas ajustando a constante k .

$$y(x) = \frac{e^{kx} - e^{-kx}}{e^{kx} + e^{-kx}} \quad \text{Equação (11)}$$

onde k é um escalar positivo.

3.3.3 Rede *Perceptron* Multicamadas e Algoritmo *Backpropagation*

A rede tipo *Feedforward* ou *Perceptron* multicamadas, como também é conhecida, utiliza o algoritmo de treinamento supervisionado *Backpropagation* e acabou se transformando em sinônimo para Rede Neural Artificial. O treinamento supervisionado por retropropagação do erro consiste na apresentação e propagação de um padrão de treinamento pela rede e o seu respectivo valor de saída é determinado e comparando com um valor desejado de saída. É então calculado o erro ε através de uma função de custo representada pela Equação 12.

$$\varepsilon(n) = \frac{1}{2N} \sum_{n=1}^N (d(n) - y(n))^2 \quad \text{Equação (12)}$$

onde $d(n)$ são os valores de saída desejados para cada padrão, $y(n)$ é o valor da função de saída da rede e N o total de padrões apresentados à rede.

No treinamento da RNA os pesos adaptativos devem ser atualizados após o cálculo dos erros de propagação. Neste processo os pesos adaptativos podem ser atualizados a cada padrão apresentado ou a cada época de padrões apresentada.

Na atualização por padrão o erro de cada padrão é retropropagado pela rede e a atualização dos pesos sinápticos é realizada. Esse processo se repete até a apresentação do último padrão de treinamento.

Na atualização por época todos os padrões de treinamento são apresentados à rede e os seus respectivos erros são acumulados e o erro médio da época é então avaliado. O erro médio da época é retropropagado pela rede, e os pesos das conexões sinápticas são atualizados uma única vez por época. O algoritmo de treinamento tem como base o gradiente descendente, fazendo com que o erro diminua, o que indica a convergência do treinamento da rede.

A aprendizagem por retropropagação visa um mapeamento entrada-saída, obtendo assim um conjunto de pesos sinápticos e limiares considerados “ideais”. Isso permite com que a rede aprenda o suficiente sobre o passado para poder generalizar no futuro. Cada época de treinamento é vista como um modelo candidato. De acordo com os parâmetros obtidos, o modelo que melhor apresentar características de generalização será o escolhido. Para se alcançar um modelo com boas

características de reconhecimento dos padrões deve-se evitar com que a RNA ultrapasse o momento ideal de parada do seu respectivo treinamento e acabe perdendo o poder de generalização. Para evitar com que esse tipo de problema ocorra é utilizada uma técnica de avaliação do aprendizado da rede chamada de Validação Cruzada com Parada Antecipada. Esta técnica indica o momento ideal de parada do treinamento, evitando com que a rede fique especializada, ou seja, que a rede seja capaz de reconhecer apenas padrões muito próximos aos aprendidos (Eberhart & Dobbins, 1990), (Haykin, 2001).

3.3.4 Validação Cruzada com Parada Antecipada

Em busca de uma boa generalização é difícil perceber o melhor momento de encerrar o processo de aprendizado da RNA, tendo apenas como referência a curva de aprendizagem. Se o processo de treinamento não for finalizado no momento apropriado, a rede poderá ser ajustada excessivamente e acabar especializando os padrões apresentados no treinamento. Para evitar esse tipo de problema e avaliar o momento mais apropriado de parada do processo de aprendizagem da rede, deve-se utilizar uma técnica denominada validação cruzada com parada antecipada.

Na validação cruzada o conjunto de dados disponível é dividido em dois conjuntos de dados distintos, um conjunto de treinamento e um conjunto de validação. O conjunto de treinamento é utilizado para avaliar o desempenho de diversos modelos e assim escolher o melhor deles. Já o conjunto de validação é utilizado no processo de identificação do ponto de início da especialização do treinamento da rede (Eberhart & Dobbins, 1990), (Haykin, 2001).

Esta técnica é agregada ao processo de aprendizado e funciona da seguinte forma. No início do treinamento da rede todos os padrões do conjunto de treinamento são apresentados à rede e os erros correspondentes, os pesos e bias são calculados e atualizados. Neste momento há uma pausa no processo de aprendizado e estes parâmetros são fixados e a rede opera no modo direto para frente, dando início ao processo de validação cruzada. O conjunto de validação é apresentado à rede e o erro de validação é então obtido. Após a apresentação de todos os padrões do conjunto de validação o processo de aprendizado é então reinicializado, repetindo-o para as demais interações. O erro de treinamento decresce monotonamente, enquanto que o erro de validação

acompanha o decrescimento do erro de treinamento, até a época que apresentar o menor erro de validação. A partir de um determinado número de épocas o erro de validação começa a ter um acréscimo em seu valor, indicando o início da especialização da rede (Figura 35).

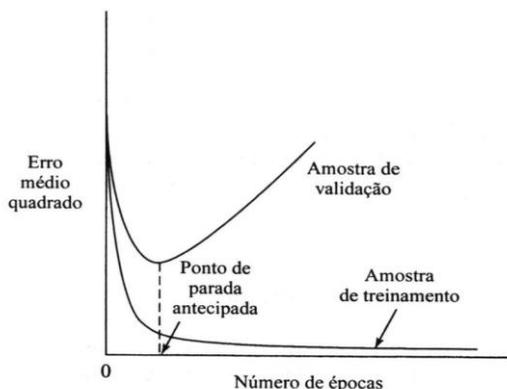


Figura 35 – Utilizando os métodos de validação cruzada com a parada antecipada, pode ser observado que as curvas dos erros apresentam um decaimento até uma determinada época de treinamento (traço pontilhado), caracterizando a parada antecipada. Desta época em diante a curva do erro de validação começa a crescer. A partir deste ponto, a rede tende a especializar cada vez mais os padrões treinados, perdendo sua capacidade de generalização. Fonte: (Haykin, 2001).

O melhor ponto de generalização do treinamento da rede ocorre próximo às redondezas da época que apresentou o menor valor de erro de validação (Eberhart & Dobbins, 1990) (Haykin, 2001).

A validação cruzada apenas indica uma época de treinamento em que se deve parar o processo de aprendizagem. Não necessariamente que a época de treinamento indicada represente o melhor modelo de classificador neural.

Para encontrar o classificador neural mais adequado para aplicações de reconhecimento de padrões em sinais de EEG, na seção seguinte serão apresentados dois métodos que podem auxiliar neste processo. O primeiro se baseia em testes diagnósticos, onde índices de desempenho como a sensibilidade, especificidade e eficiência são obtidos e avaliados. O segundo método utiliza as curvas ROC (*Receiver Operating Characteristic*), onde é obtido o índice que mede a área sobre a curva ROC. Este índice também é bastante utilizado como forma de avaliação de sistemas classificadores.

3.4 AVALIAÇÃO DO DESEMPENHO DE CLASSIFICADORES

A avaliação do desempenho é uma etapa importante do processamento de sinais biomédicos (Sörnmo & Laguna, 2005), requerida antes que qualquer algoritmo possa ser implementado com fins de auxílio ao diagnóstico médico. A avaliação do desempenho torna-se um processo complicado quando o objetivo é desenvolver um algoritmo que avalie um conjunto de parâmetros, que discrimine eficientemente sinais obtidos de sujeitos saudáveis e de pacientes que sofrem de uma determinada patologia. Nesse caso, o desempenho pode ser avaliado através da habilidade do algoritmo discriminar entre os dois grupos de sujeitos saudáveis e de sujeitos doentes. Os índices de desempenho mais comuns, utilizados na avaliação de processos que envolvem processamento de sinais biomédicos são a sensibilidade, especificidade, valor preditivo positivo, valor preditivo negativo e a eficiência (Sörnmo & Laguna, 2005), (Jekel, et al., 2001). Estes índices são calculados através dos dados relacionados aos sujeitos em estudo e os resultados dos testes realizados, representados pelos indicadores verdadeiro-positivos (VP), verdadeiro-negativos (VN), falso-positivos (FP) e falso-negativos (FN), os quais são colocados numa tabela de contingência de tamanho 2x2, representada pela Tabela 3 (Jekel, et al., 2001), (Goroll & Mulley, 2009).

Tabela 3 – Tabela de contingência utilizada nos testes-diagnósticos.

		Indicação do Especialista		Total
		Doentes	Saudáveis	
Teste	Positivo	Verdadeiro-Positivos (VP)	Falso-Positivos (FP)	Positivos (VP + FP)
	Negativo	Falso-Negativos (FN)	Verdadeiro-Negativos (VN)	Negativos (FN + VN)
Total		Doentes (VP + FN)	Saudáveis (FP + VN)	

3.4.1 Índices de Sensibilidade e Especificidade

A sensibilidade e especificidade são dois índices importantes dos testes diagnósticos (Jekel, et al., 2001). A sensibilidade indica a habilidade de um teste, detectar a doença, quando ela está presente. Caso o teste apresente uma taxa de sensibilidade baixa, não será capaz de detectar a doença em alguns dos sujeitos verdadeiramente doentes. Quando ocorre uma falsa classificação, a taxa de falso-negativos aumenta, devido ao fato de todos aqueles que estão doentes não serem considerados como doentes (Jekel, et al., 2001), (Fletcher & Fletcher, 2005), (Fischbach & Dunning, 2009), (Goroll & Mulley, 2009). A sensibilidade é calculada a partir da Equação 13.

$$\text{sensibilidade}(\%) = \frac{VP}{VP + FN} \times 100 \quad \text{Equação (13)}$$

A especificidade refere-se à habilidade de um teste, indicar os não doentes, quando a doença não esta presente. Se um teste apresenta uma baixa especificidade, ele indicará a presença da doença em sujeitos não doentes, sendo classificados como falsos positivos (Jekel, et al., 2001), (Fletcher & Fletcher, 2005), (Fischbach & Dunning, 2009), (Goroll & Mulley, 2009). A especificidade é calculada a partir da Equação 14.

$$\text{especificidade}(\%) = \frac{VN}{FP + VN} \times 100 \quad \text{Equação (14)}$$

3.4.2 Valor Preditivo Positivo e Valor Preditivo Negativo

O índice Valor Preditivo Positivo (VPP), também conhecido como Seletividade Positiva, indica a probabilidade de um resultado positivo corresponder ao verdadeiro positivo, ou seja, ajuda a predizer qual a probabilidade de se ter a doença, se o resultado do teste for positivo (Goroll & Mulley, 2009). O VPP é calculado a partir da equação (Equação 15).

$$VPP(\%) = \frac{VP}{VP + FP} \times 100 \quad \text{Equação (15)}$$

O índice Valor Preditivo Negativo (VPN), também conhecido como Seletividade Negativa, indica a probabilidade de um resultado negativo corresponder ao verdadeiro negativo, ou seja, ajuda a prever qual a probabilidade de não se ter a doença, se o resultado do teste for negativo (Goroll & Mulley, 2009). O VPN é calculado a partir da equação (Equação 16).

$$VPN(\%) = \frac{VN}{FN + VN} \times 100 \quad \text{Equação (16)}$$

3.4.3 Eficiência

A eficiência indica a probabilidade de uma medida estar correta. É a concordância global dos resultados verdadeiros positivos e negativos em indivíduos com e sem a doença (Jekel, et al., 2001). O índice de eficiência é calculado a partir da equação (Equação 17).

$$\text{eficiência} (\%) = \frac{VP + VN}{VP + FP + FN + VN} \times 100 \quad \text{Equação (17)}$$

3.4.4 Curvas ROC

A análise ROC (*Receiver Operating Characteristic*) teve origem na teoria de decisão estatística e foi desenvolvida entre 1950 e 1960 para avaliar a detecção de sinais em radar e na psicologia sensorial. Mas obteve grande sucesso a partir da sua aplicação a uma grande variedade de testes de diagnóstico e em particular no diagnóstico de imagem médica (Braga, 2000).

As curvas ROC fornecem um meio de quantificar a exatidão de sistemas automatizados de diagnóstico, comparando as formas de classificação daqueles sistemas que utilizam redes neurais como

ferramenta através de padrões pré-definidos (Eberhart & Dobbins, 1990). O gráfico ROC é uma técnica para visualizar, organizar e seleccionar classificadores, baseada no seu desempenho.

Por definição, uma curva ROC é a representação gráfica dos pares, sensibilidade (ordenadas) e $1.0 - \text{especificidade}$ (abscissas), resultantes da variação do valor do ponto de corte ao longo de um eixo de limiares de decisão, descrevendo assim o poder de discriminação do sistema de diagnóstico.

No que diz respeito ao desempenho de diferentes sistemas de diagnóstico, considera-se o sistema com maior capacidade de discriminação, aquele que apresente a curva ROC mais próxima do canto superior esquerdo. O gráfico ROC apresenta uma linha diagonal entre (0,0) e (1,1), que representa a aleatoriedade do classificador. Nenhum classificador pode apresentar área abaixo de 0,5, sendo que os valores (0,1) representam o classificador ideal.

A medida da área sob a curva ROC (índice AUC) é utilizada para avaliar o desempenho de um sistema de diagnóstico. O índice AUC compreende valores entre 0,0 e 1,0. Quanto mais próximo de 1,0 for o índice, maior será o poder discriminante do classificador (Braga, 2000).

Na Figura 36 são apresentados três graus de discriminação, obtidos através das curvas ROC.

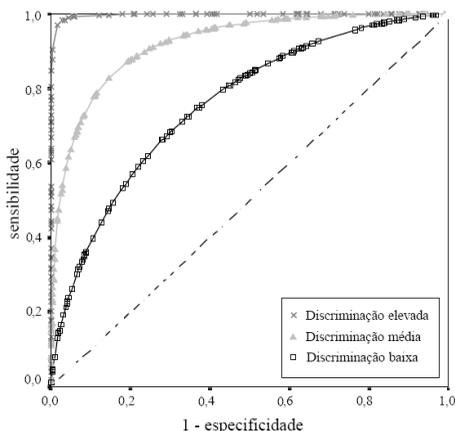


Figura 36 – Exemplo de Curvas ROC onde são apresentadas as formas de discriminação para um classificador.

Fonte: Modificado de (Braga, 2000).

Comentários: Este capítulo apresentou a base teórica necessária para o entendimento da proposta deste trabalho. No próximo capítulo será apresentada metodologia desenvolvida e como as ferramentas e métodos matemáticos foram utilizados, junto às redes neurais, resultando num sistema automatizado de identificação e contagem de eventos epileptiformes.

4 METODOLOGIA

Os processos de localização, classificação e contagem de eventos epileptiformes, adotados para o desenvolvimento deste trabalho, foram observados através dos procedimentos realizados pela equipe de neurologistas do CEPESC. As etapas envolvidas neste processo são de alta complexidade, pois se tratam de pacientes diferentes, diferentes tipos de sinais, os quais correspondem a diferentes estados que o mesmo paciente apresenta, entre outros fatores que influenciam na correta localização e contagem dos eventos epileptiformes.

Ferramentas específicas foram estudadas, para o pré-processamento dos registros de EEG e para automatizar a localização e a classificação de eventos, bem como, as demais tarefas envolvidas nesse processo. Todas as etapas da metodologia desenvolvida, representada pela Figura 37 serão descritas detalhadamente no decorrer deste capítulo, a qual resultou num sistema computacional automatizado para a identificação e contagem de eventos epileptiformes.

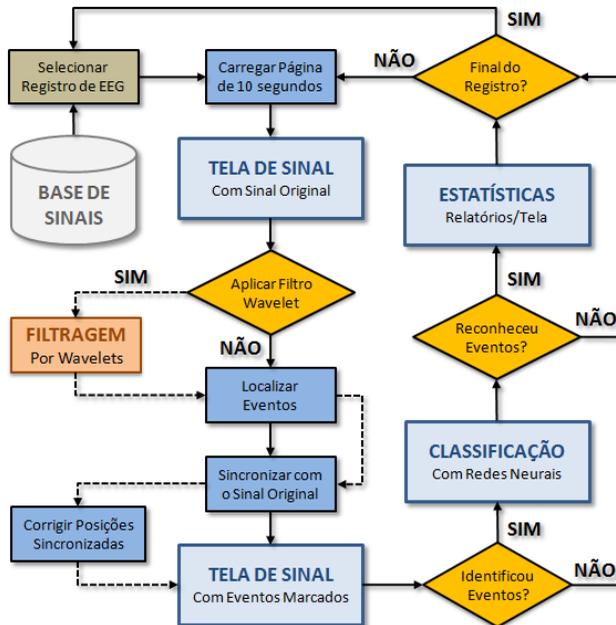


Figura 37 – Representação dos módulos que compõem o sistema computacional desenvolvido para a identificação e classificação de registros de EEG.

4.1 O BANCO DE SINAIS DE EEG

O banco de sinais gerado para este trabalho é composto por registros de EEG de 30 pacientes comprovadamente epiléticos, as quais foram fornecidos pelo CEPESC. A identificação de cada paciente foi feita, atribuindo um rótulo “Pac” mais uma letra do alfabeto e um número correspondente à quantidade de sinais. Exemplo: “PacA1.eeg”.

Os sinais foram adquiridos pelo sistema *Ceegrath Vision EEG* da *Natus Bio-logic Systems Corporation*. Este equipamento realiza a monitoração do paciente através de Vídeo-EEG. O sistema faz a captura simultânea do vídeo e do sinal de EEG de todo o período de internação ao qual o paciente é submetido. Apenas os sinais de EEG, devidamente analisados e marcados, foram usados no desenvolvimento deste trabalho.

Os sinais gerados pelo sistema *Ceegrath* apresentam as seguintes características:

- Arquivos de EEG segmentados de hora em hora (registro de um dia equivale a 24 arquivos de uma hora);
- 32 canais de aquisição em montagem referencial (do equipamento);
- 28 canais utilizados (Fp1, F3, C3, P3, F7, Ft7, T7, Tp7, P7, O1, Sp1, Ft9, T9, Tp9, Fp2, F4, C4, P4, F8, Ft8, T8, Tp8, P8, O2, Sp2, Ft10, T10, Tp10 com referencia em Pz);
- Frequência de amostragem de 512 Hz;
- Resolução de 16 bits;
- Arquivos sem pré-processamento.

Para a utilização destes sinais foi elaborado um projeto para os **Comitês de Ética em Pesquisa com Seres Humanos da Universidade Federal de Santa Catarina**⁴ e do **Hospital Governador Celso Ramos**⁵, sendo aprovados em ambos (ANEXO A).

4.1.1 Marcação dos Eventos nos Sinais de EEG

Todos os padrões selecionados para formar o banco de sinais, foram marcados individualmente por três neurologistas do CEPESC. A

⁴ Processo n° 252/08 FR-229734 Data: 10/10/2008

⁵ Processo n° 025/08 FR-218051 Data: 25/11/2008

marcação é feita, analisando telas de dez segundos de sinal, ao longo dos registros de EEG, utilizando uma montagem referencial em Pz. O neurologista verifica atentamente possíveis perturbações que alterem os traçados do EEG, que indiquem a presença de descargas epileptiformes (Figura 38).

Nas telas que apresentam tais descargas o neurologista verifica a propagação do campo do potencial elétrico, em busca do evento mais eletronegativo. Supostamente, o canal que apresenta o evento com a maior amplitude negativa está mais próximo da zona epileptogênica (Lüders & Noachtar, 2000).

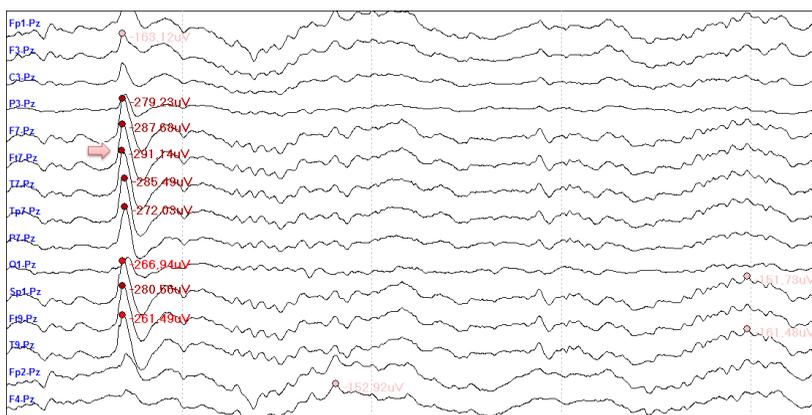


Figura 38 – Análise e identificação do canal onde o evento é mais eletronegativo, marcado com a seta. Pode ser observado que o canal T7 apresenta o evento com maior amplitude negativa em relação aos demais canais, com $-291,14\mu\text{V}$. Também pode ser observado que a amplitude vem decaindo gradualmente nos demais canais, caracterizando o campo de potencial elétrico.

O evento identificado é então marcado no próprio sistema de aquisição *Ceegraph Vision*, apenas posicionando um “rotulo” em cima do canal e no instante de tempo onde o evento ocorreu.

Depois de marcados, todos os sinais foram gravados em discos e disponibilizados para as pesquisas. A Figura 39 apresenta o processo de identificação/marcação realizado pelos neurologistas, utilizando o sistema *Ceegraph Vision*. Pode ser visto um rótulo em determinada posição da tela, onde este indica que o canal F8 apresentou maior amplitude negativa no instante de tempo 00:43:45.

O mesmo procedimento se repetiu para os demais padrões (piscadas, ruídos, atividade normal), se obtendo registros de EEG com todas as marcações prontas para a utilização.



Figura 40 – Tela de 10 segundos de um traçado de EEG contendo descargas epileptiformes. Pode ser observado que houve a formação e a propagação de um campo de potencial elétrico para cada um dos eventos identificados pelas setas.

A Figura 41[a] apresenta as amplitudes do campo de potencial indicado na Figura 40 pela seta cheia. Já a Figura 41[b] apresenta as amplitudes do campo de potencial indicado na Figura 40 pela seta vazia. Após a análise dos campos de potencial é feita a indicação do hemisfério e do canal que apresentou o evento epileptiforme com a maior amplitude negativa (Figura 41). Esse procedimento se repete até o final de cada registro de EEG.

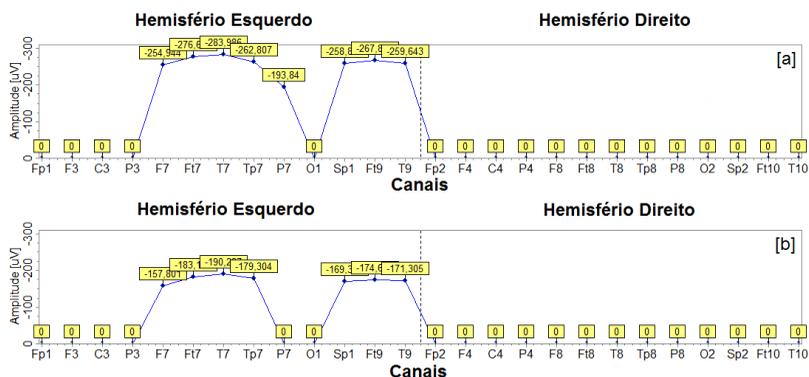


Figura 41 – Representação do campo de potencial dos eventos epileptiformes destacados pela seta cheia (Figura 40) e pela seta vazia (Figura 40). Pode-se observar que nos dois campos de potencial analisados os eventos mais eletronegativos ocorreram no canal T7.

Ao final da análise é feito o agrupamento de todos os eventos epileptiformes identificados, por canal e por hemisférios, ao longo de todo o registro, como representa a Figura 2 do Capítulo 1.

Tendo como base as informações complementares que a análise do EEG oferece, o neurologista consegue quantificar o número de descargas acumuladas e delimitar a possível região do foco, apontado pelo acúmulo de eventos em determinados canais.

4.2 ABERTURA E VISUALIZAÇÃO DOS ARQUIVOS DE EEG

Todo o processo envolvido na detecção e classificação de eventos epileptiformes começa com a decodificação dos arquivos de EEG. Para obter as amostras referentes aos sinais de EEG, dos arquivos fornecidos pelo CEPESC, foi preciso fazer a interpretação da estrutura destes arquivos, e posteriormente efetuar a manipulação dos mesmos. Estes arquivos são organizados em 32 canais sequenciais, com resolução de 16 bits, frequência de amostragem de 512 Hz e são coletados por meio de uma montagem referencial, utilizando uma referencia comum do equipamento. Após a identificação da estrutura dos arquivos foi possível ter acesso às amostras que compõem os sinais de EEG. Para o desenvolvimento desta metodologia optou-se em trabalhar com os arquivos em seu formato original, gerados pelos equipamentos de EEG disponíveis no CEPESC, evitando custo computacional desnecessário para a conversão em outro formato conhecido como o TXT, toda vez que um arquivo fosse aberto para análise. Dessa forma, o sistema computacional desenvolvido pode ser executado no mesmo equipamento de monitoração, utilizados para coleta e análise dos registros de EEG do CEPESC, pela compatibilidade com a abertura dos arquivos no formato original.

Para ter acesso às amostras dos sinais de EEG, houve a necessidade de desenvolver um sistema para a abertura e visualização destes arquivos, da mesma forma que o sistema existente no CEPESC, os disponibiliza para visualização. Foi então implementado um software em C++ Builder para a abertura dos sinais de EEG, o qual permite fazer a visualização dos 32 canais de sinal, em telas de 10 segundos, ao longo de todo o registro. No entanto, os sinais lidos diretamente do arquivo, não apresentam características apropriadas para a sua correta interpretação, devido à montagem em que os canais estão organizados, ser diferente daquela normalmente utilizada pelos neurologistas. Outro

fator importante observado na abertura dos arquivos é que os sinais não são pré-processados no momento da aquisição, sendo armazenados no arquivo sem qualquer tipo de filtragem (Figura 42).

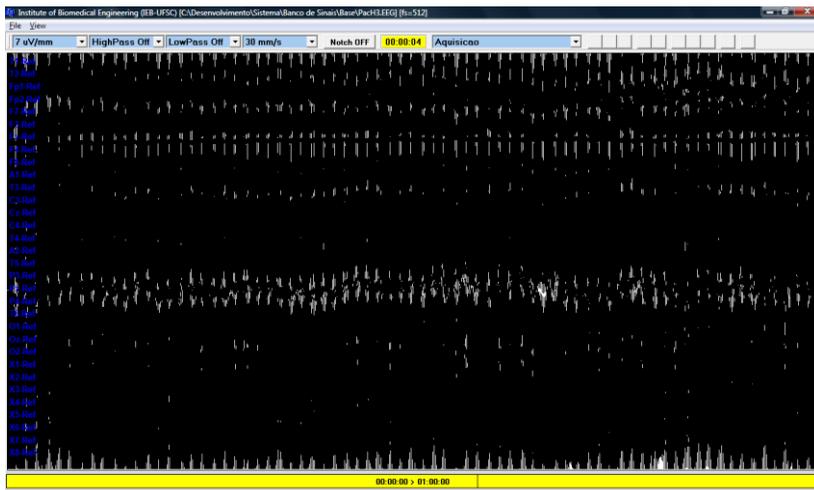


Figura 42 – Tela de sinal sem processamento e com montagem de aquisição.

Para a correta interpretação dos registros de EEG foi necessário agregar filtros digitais ao sistema de visualização, permitindo o processamento e a correta apresentação dos sinais de EEG, conforme utilizados pelos neurologistas (Figura 43). As frequências de corte utilizadas para visualização e análise dos registros de EEG são: 0,3 Hz para o filtro passa-altas e de 35 Hz para o filtro passa-baixas.

Os filtros digitais agregados ao sistema de visualização foram projetados, de acordo com os tipos e frequências de corte disponíveis no sistema de aquisição do CEPESC. Para o filtro passa-baixas foram definidas as frequências de corte em 15, 30, 70 e 100 Hz. Para o filtro passa-altas foram definidas as frequências de corte 0,1, 0,3, 0,5, 1, 2, 3, 10 e 15 Hz. Também foi implementado um filtro rejeita-banda de 60 Hz para atenuar as interferências da rede elétrica. Ambos os filtros são do tipo *Butterworth* de 4º ordem e foram projetados, utilizando a ferramenta matemática Matlab e codificados utilizando a linguagem C.

A leitura das amostras de sinal de dentro dos arquivos de EEG é feita, canal a canal, instante a instante, até preencher o tamanho da tela estipulada, neste caso dez segundos.

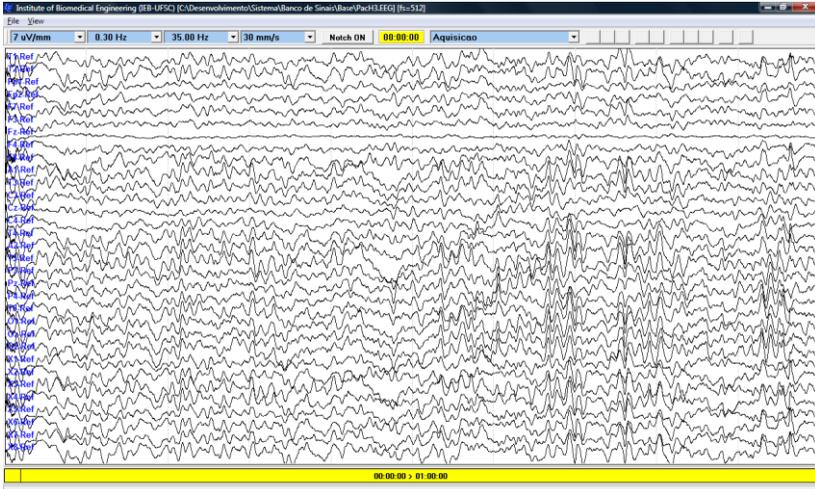


Figura 43 – Tela de sinal com os filtros aplicados.

Depois de posicionado o ponteiro de leitura no início do arquivo (com *offset* de 43.716 bytes), devem ser lidas as amostras de cada canal individualmente, ou seja, para o canal 1, ler a amostra 1, para o canal 2, ler a amostra 1, para o canal 32, ler a amostra 1. Após a leitura dos 32 canais, o processo se repete, para o canal 1, ler a amostra 2, para o canal 2, ler a amostra 2, para o canal 32, ler a amostra 2, e assim por diante, lendo as 512 amostras que cada canal apresenta por segundo.

Para armazenar esse volume de informação foram criados três buffers de 5120 x 32. O primeiro buffer sempre armazenará a tela de dez segundo de sinal original do arquivo, até que seja efetuada a leitura de uma nova tela. Isso permite com que diversas configurações nas operações de filtragem e manipulação de montagens sejam feitas, sem a necessidade de fazer uma nova leitura desta mesma tela no arquivo. O segundo buffer armazena as telas processadas, resultantes da filtragem dos sinais armazenados no primeiro buffer. O terceiro buffer armazena os sinais filtrados e configurados numa montagem específica, pois há a necessidade de fazer somas ou subtrações de canais, gerando novos canais. Os dados armazenados neste buffer são os dados que são apresentados na tela do computador, prontos para interpretação e análise.

Além dos filtros digitais foi agregada uma opção para a troca das montagens, permitindo visualizar cada tela de sinal em uma montagem específica, conforme a necessidade do neurologista. A Figura 43

apresenta os primeiros dez segundos de sinal com a montagem de aquisição. Já a Figura 44 mostra a mesma tela de sinal, utilizando uma montagem referencial, em relação ao eletrodo Pz.

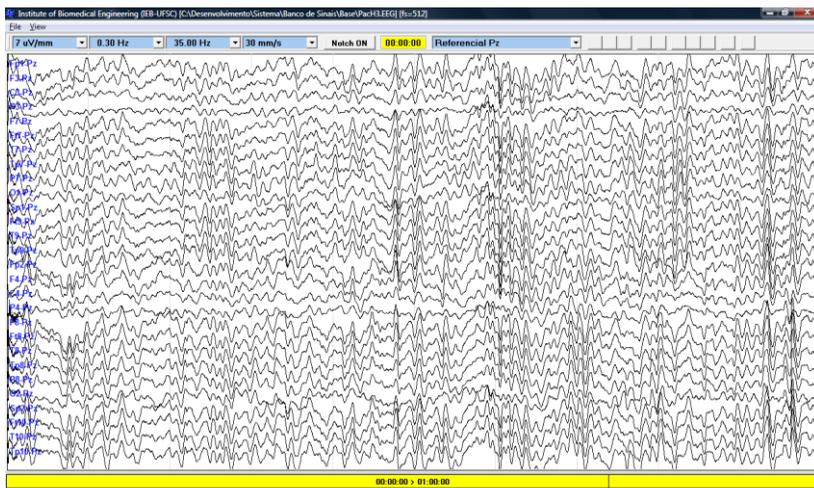


Figura 44 – Tela de sinal apresentada através de uma montagem referencial em Pz.

O software de visualização de sinais de EEG, conta com recursos de pré-processamento e a possibilidade de utilizar montagens distintas, que favoreceram a manipulação e visualização dos registros de EEG.

Posteriormente, a metodologia desenvolvida neste trabalho foi agregada a este software, resultando em um sistema computacional automatizado para a identificação e contagem de eventos epileptiformes em sinais de EEG.

4.3 ARQUIVOS DE PADRÕES DE EEG GERADOS PARA OS EXPERIMENTOS COM A TRANSFORMADA WAVELET E COM AS REDES NEURAIS ARTIFICIAIS

A correta localização dos eventos epileptiformes depende do pré-processamento dos sinais de EEG. Todas as formas de interferência, que possam gerar distorções no sinal, devem ser atenuadas ou corrigidas, preservando da melhor maneira possível, os picos dos eventos epileptiformes, necessários para a sua posterior localização.

No pré-processamento dos sinais de EEG foi preciso selecionar e extrair segmentos de sinal dos registros originais de EEG, pois não seria possível estar manipulando esses registros diretamente, devido ao grande volume de dados que eles apresentam. Dessa forma, para realizar determinados experimentos, com os métodos e ferramentas matemáticas selecionadas, foi necessário separar os padrões marcados pelos neurologistas em arquivos menores. Cada um dos arquivos gerados contém um segmento de sinal, com duração de quatro segundos, ou como será citado diversas vezes no texto, épocas de sinal com quatro segundos de duração. Em experimentos específicos, como no caso do treinamento das redes neurais artificiais, foram utilizadas épocas de sinal com duração de um segundo.

As épocas de sinal, contendo os eventos epileptiformes marcados pelos neurologistas, foram extraídas utilizando uma ferramenta computacional, criada para realizar esta tarefa, de uma forma simples e rápida, apenas movimentando uma janela de amostras com tamanho variável. Esta ferramenta foi criada a partir de modificações na ferramenta de abertura e visualização dos arquivos de EEG descrita anteriormente. O software permite escolher o tamanho (em amostras) que os arquivos de padrões serão gerados e o tipo de evento que vai ser gravado dentro dele. A Figura 45 apresenta uma tela da ferramenta desenvolvida para a extração das amostras de sinais.

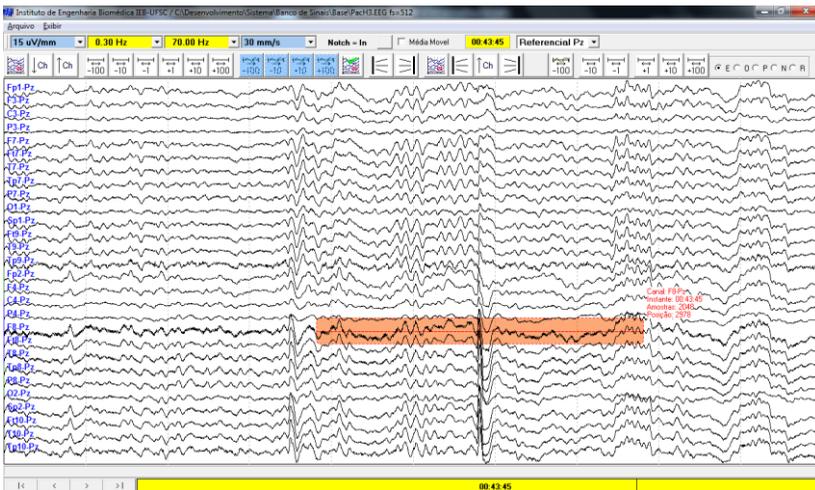


Figura 45 – Tela da ferramenta de extração de padrões. A janela de extração destacada em laranja representa a época de sinal que será gravada dentro de um arquivo de padrões.

Os arquivos de padrões foram gerados de acordo com as informações do paciente e da localização de cada evento dentro do arquivo original: paciente de origem, o canal de ocorrência, o instante de tempo de ocorrência, número de amostras gravadas e a duração que o evento apresenta (duração se aplica apenas a eventos epileptiformes e piscadas). Cada padrão foi armazenado de forma centralizada em arquivos distintos, contendo quatro segundos de sinal (2048 amostras), o que permitiu sua manipulação em diversos experimentos, apenas alterando o tamanho da janela de tempo (1, 2, 3 ou 4s).

Os arquivos foram nomeados com a sua localização e quantidade de amostras extraídas mais a extensão (“.pdr”). Por exemplo, o paciente rotulado com a sigla H3 apresentou o evento mais eletronegativo no canal Sp2-Pz, no instante de tempo 00:43:45, com 2048 amostras, apresentando 98ms de duração. A partir destas informações o nome do arquivo de padrões epileptiformes apresenta a seguinte forma: **“EspiculaOnda_Pach3_Sp2-Pz_004345_2048_98ms.pdr”**, conforme é apresentado na Figura 46. Esse procedimento se repetiu para todos os padrões utilizados neste trabalho.

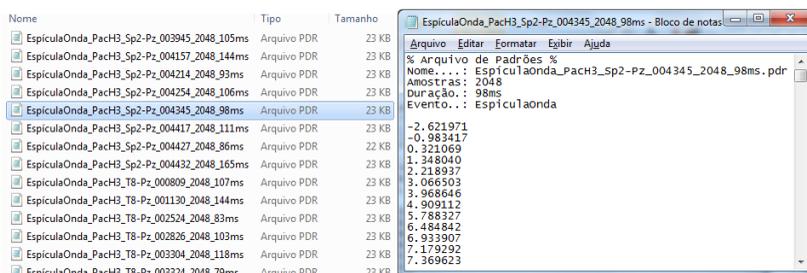


Figura 46 – Representação dos arquivos de padrões gerados para cada padrão selecionado.

Os arquivos de padrões gerados foram separados em quatro classes: eventos epileptiformes, piscadas, atividade de fundo normal de EEG e ruído. A Figura 47 apresenta três exemplares de cada classe de padrões definida. Todos os padrões selecionados foram armazenados em arquivos distintos, o que facilitou a análise do comportamento individual de cada um deles, a partir das ferramentas utilizadas nos experimentos iniciais.

Quanto ao tamanho dos arquivos de padrões gerados foi utilizado um número maior de amostras, daquele que havia sido definido no início dos experimentos. Inicialmente, foram gerados arquivos de padrões com

apenas 512 amostras, o que equivale a um segundo de sinal. No entanto, pequenas épocas de sinal não foram suficientes para uma completa visualização do comportamento dos padrões (análise pela transformada wavelet e treinamento das redes neurais).

Por esse motivo foi definido que os padrões utilizados neste estudo teriam no mínimo quatro segundos de sinal para poderem ser analisados corretamente. Utilizando épocas maiores de sinal foi possível investigar o comportamento da transformada wavelet, possibilitando utilizar esta ferramenta de diferentes maneiras no processamento dos sinais de EEG.

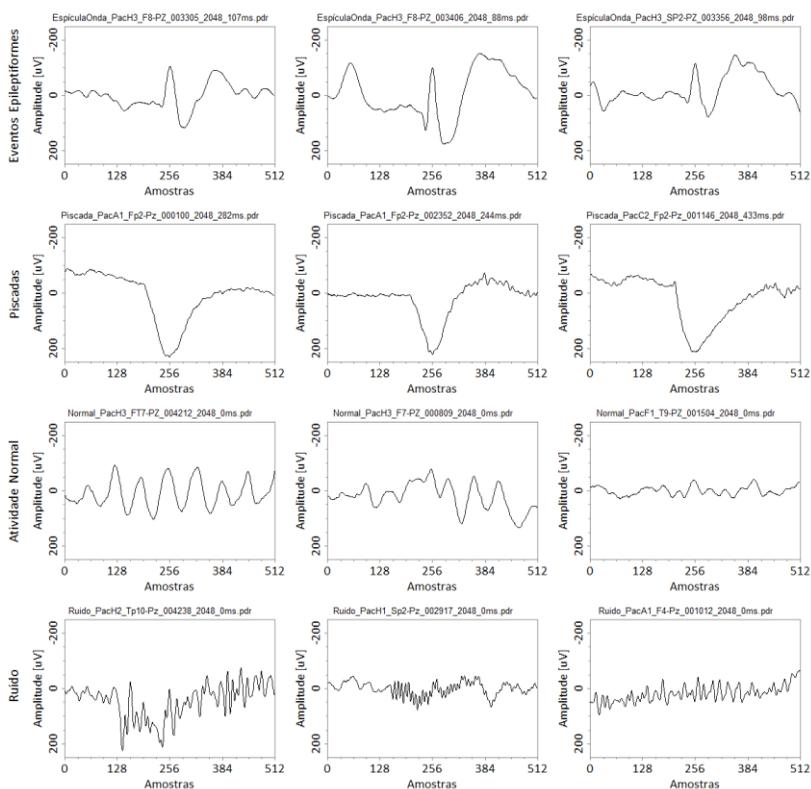


Figura 47 – Representação das quatro classes de padrões definidas para este trabalho. São apresentados três exemplares de cada classe, os quais foram selecionados a partir das marcações efetuadas. São apresentadas apenas 512 das 2048 amostras que cada padrão possui, representando uma época de um segundo de sinal.

Na próxima seção serão descritas as formas de pré-processamento e condicionamento dos sinais de EEG adotados neste trabalho. Serão apresentados alguns experimentos realizados com a transformada wavelet e o filtro wavelet desenvolvido, o qual foi utilizado para atenuar, principalmente, as atividades de fundo do EEG, sem distorcer os picos dos eventos epileptiformes. Posteriormente, também serão descritos os métodos adotados para o condicionamento das telas de sinal após o processamento, as técnicas envolvidas no desenvolvimento do classificador neural e na contagem de eventos epileptiformes.

4.4 PRÉ-PROCESSAMENTO DOS SINAIS DE EEG

A metodologia desenvolvida neste trabalho baseia-se na localização dos eventos epileptiformes, através da análise das máximas amplitudes negativas, onde são verificados os picos que estes eventos apresentam. Levando em consideração que, as espículas possuem duração de 40 a 80ms e as ondas agudas possuem duração entre 80 e 200ms (Lüders & Noachtar, 2000), foram definidas faixas de trabalho em tempo e frequência, que caracterizam os dois tipos de eventos epileptiformes. A faixa de trabalho definida apresenta durações entre 40 e 200ms, o que corresponde a uma faixa de frequências entre 5 e 25 Hz.

No pré-processamento dos arquivos de EEG, os sinais são filtrados, de acordo com uma faixa de frequências entre 0,3 e 35 Hz, a qual os neurologistas do CEPESC estão acostumados a visualizar e analisar os registros de EEG.

Inicialmente foram feitos experimentos com os filtros digitais implementados no próprio sistema (filtros *Butterworth*), utilizados para o condicionamento dos sinais, após a abertura dos arquivos. Entretanto, verificou-se que, ao utilizar os filtros implementados, na faixa de frequências estipulada, houve uma elevada distorção nos picos dos eventos epileptiformes, o que inviabilizaria sua utilização na localização dos eventos e no pré-processamento dos sinais de EEG.

Dessa forma, os filtros implementados no sistema são utilizados apenas para limitar frequências abaixo de 0,3 Hz e acima de 35 Hz, faixa de utilização padrão, estabelecida pelos neurologistas que acompanharam o trabalho. A Figura 48 apresenta um segmento de uma tela de dez segundos de sinal, mostrando seis canais de EEG, contendo eventos epileptiformes, antes e depois do filtro passa-altas. O filtro foi configurado com frequência de corte em 5 Hz, limite inferior da faixa de

freqüências, que os eventos epileptiformes apresentam. Nos experimentos realizados, foi observado que as oscilações de baixa freqüência sofreram a atenuação esperada. Entretanto, os picos dos eventos epileptiformes apresentaram elevada distorção após a filtragem, inviabilizando a utilização deste filtro para o pré-processamento dos sinais, antes de serem aplicados ao módulo localizador de eventos.

Explorando os conceitos descritos por Addison (2002), o qual apresenta uma forma de filtragem sem distorções, utilizando o método *denoising* da transformada wavelet, foram feitos experimentos a fim de comprovar tais afirmações e a possível utilização para o processamento dos sinais de EEG. Estes experimentos são descritos a seguir.

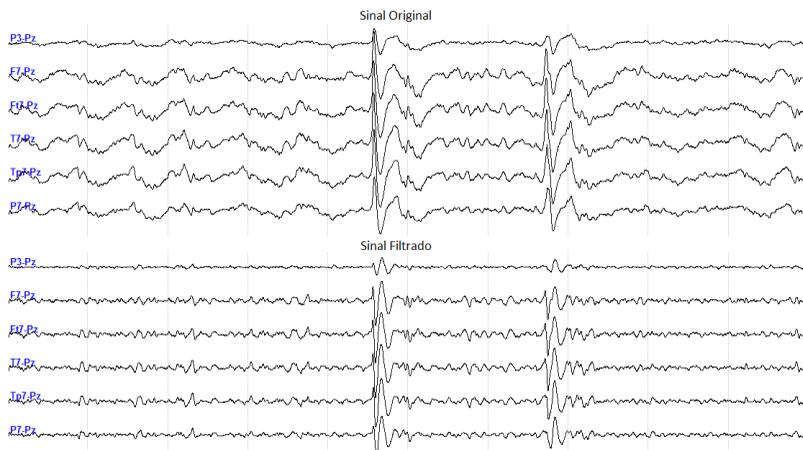


Figura 48 – Experimentos com filtros *Butterworth* utilizados no condicionamento dos sinais no momento da visualização. Configurando o filtro passa-altas para a freqüência de 5 Hz, a mesma do limite inferior que abrange os eventos epileptiformes, fica evidente que o sinal filtrado apresenta uma elevada distorção em seus picos máximos, inviabilizando a sua localização.

4.4.1 Experimentos com a Transformada Wavelet

Os experimentos iniciais com a transformada wavelet foram feitos, levando em consideração, a duração e a freqüência que os eventos epileptiformes apresentam, como descrito anteriormente. A faixa de trabalho definida apresenta durações entre 40 e 200ms, o que corresponde a uma banda de freqüências entre 5 e 25 Hz.

Inicialmente, não se tinha certeza de quais níveis de decomposição, as aproximações e os detalhes abrangeriam ou seriam mais sensíveis às frequências que caracterizam os eventos epileptiformes.

Dessa forma, empregando os conceitos da decomposição wavelet descrita no capítulo três foi elaborada a Tabela 2 contendo as faixas de frequências para 10 níveis de decomposição (escolha empírica), tanto para as aproximações, quanto para os detalhes. Os valores apresentados foram feitos com base numa frequência de amostragem de 512 Hz, a mesma dos sinais de EEG selecionados para este trabalho.

Para complementar o entendimento deste conceito a Figura 49 apresenta uma estimativa gráfica dos níveis de aproximação e dos níveis de detalhe, que em teoria devem abranger as faixas de duração e frequência, definidas para os eventos epileptiformes. A partir desta estimativa gráfica que foi possível ter uma percepção mais concreta da possibilidade de se manipular os níveis de decomposição, gerando sinais filtrados apenas utilizando determinados níveis das aproximações e dos detalhes, se confirmando posteriormente com os experimentos realizados.

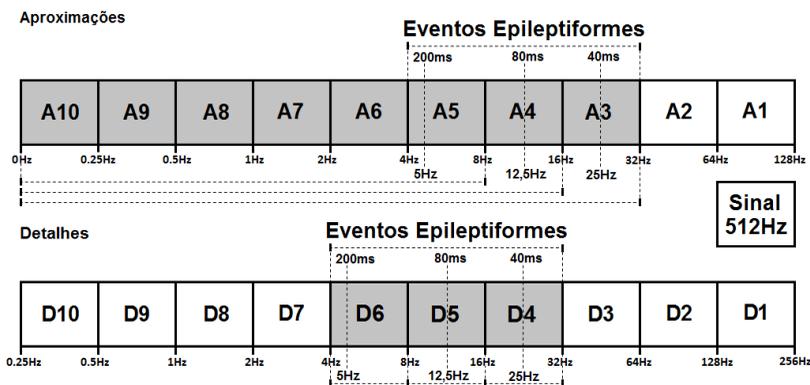


Figura 49 – Representação do processo de decomposição de um sinal de 512 Hz de frequência de amostragem em dez níveis de decomposição. Podem ser observados os níveis de decomposição, que abrangem os eventos epileptiformes, de acordo com a sua faixa de frequência e duração.

Nos experimentos realizados para a investigação da decomposição wavelet, foram utilizados diversos arquivos de eventos epileptiformes, onde foram observados seus respectivos comportamentos, no momento da decomposição. Para ilustrar todo o

processo envolvido nos experimentos realizados, utilizou-se o arquivo “EspículaOnda_PacH3_T7-Pz_001327_2048_117ms.pdr”. Este arquivo contém uma época de quatro segundos de sinal, que corresponde a uma onda aguda de 117ms de duração (~8,54 Hz), com ocorrência no canal T7-Pz e no instante de tempo 13:27. Este evento foi aplicado à transformada wavelet, sendo decomposto e reconstruído em 10 níveis pelas aproximações e pelos detalhes.

A função wavelet utilizada foi a função Biortogonal 3.1 (Bior 3.1), a qual foi escolhida inicialmente, por conter poucos coeficientes. Lembrando que, quanto maior o número de coeficientes de filtro for utilizado na função wavelet escolhida, maior o esforço computacional aplicado ao processo de decomposição de um sinal. Foram obtidos alguns gráficos, contendo os sinais reconstruídos das aproximações e dos detalhes, descrevendo basicamente o que ocorre em cada nível de decomposição e qual o comportamento do sinal gerado.

A Figura 50 apresenta o sinal original, o sinal decomposto e os sinais reconstruídos a partir dos dez níveis de aproximação.

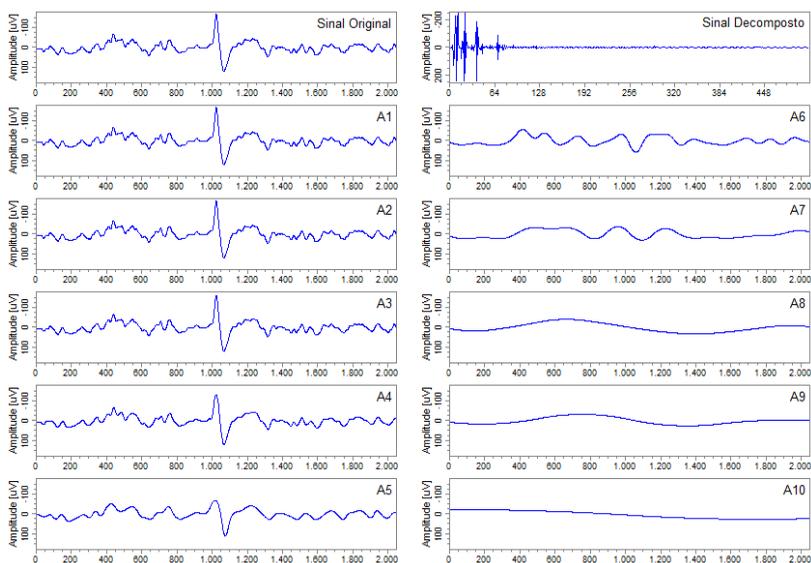


Figura 50 – Exemplo de decomposição wavelet utilizando um evento epileptiforme real e os sinais reconstruídos, a partir de suas respectivas aproximações.

Pode ser observado que a morfologia do sinal original se mantém, até o nível de aproximação A4 (0-16 Hz), com o mínimo de perda de

suas componentes de frequência. Isso ocorre devido ao fato do evento analisado apresentar uma frequência aproximada de 8,54 Hz, ficando dentro da faixa de frequências que os níveis A1-A4 abrangem. A partir do nível A5 (0-8 Hz) a morfologia do sinal começa a apresentar distorções, devido ao fato deste nível de aproximação abranger apenas as frequências entre 0 e 8 Hz, ficando abaixo das frequências que o evento apresenta. Com o aumento dos níveis das aproximações o sinal é reconstruído com menos componentes de frequência, até que fiquem apenas as frequências muito próximas de 0 Hz.

Dependendo da aplicação, determinadas frequências de um sinal podem ser atenuadas, utilizando apenas o processo de reconstrução pelas aproximações da transformada wavelet. Por exemplo, se um sinal de 512 Hz de frequência de amostragem conter um ruído de 60 Hz e as frequências de interesse deste sinal é de até 32 Hz, uma alternativa simples, para a atenuação desta interferência, seria decompor este sinal pela transformada wavelet e o reconstruir a partir do nível de aproximação A3. Este nível em específico abrange apenas as frequências entre 0 e 32 Hz, o que eliminaria instantaneamente do sinal reconstruído, as altas frequências acima de 32 Hz, incluindo a componente de 60 Hz.

Da mesma forma como realizado com as aproximações, foram feitos experimentos com os níveis de detalhe do sinal. Os mesmos procedimentos que foram aplicados às aproximações, incluindo o arquivo de sinal do evento epileptiforme e a função wavelet, também foram os mesmos. O sinal analisado apresenta uma frequência aproximada de 8,54 Hz, como mencionado no experimento anterior. Observando os gráficos da Figura 51 os sinais reconstruídos dos níveis de detalhe D1 (128-256 Hz), D2 (64-128 Hz) e D3 (32-64 Hz) não apresentaram grandes alterações em sua amplitude, devido ao fato do sinal analisado não possuir componentes de frequência significativas nestes três níveis. Nos níveis D4 (16-32 Hz), D5 (8-16 Hz) e D6 (4-8 Hz), os sinais reconstruídos apresentam componentes de frequência, que pertencem a estes três níveis, mas com intensidades diferentes entre eles.

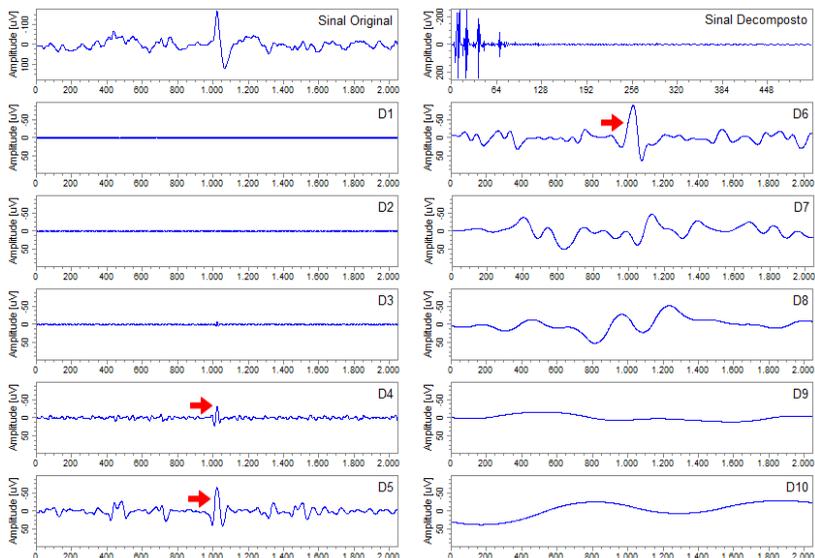


Figura 51 – Exemplo de decomposição wavelet utilizando um evento epileptiforme real e os sinais reconstruídos, a partir de seus respectivos detalhes.

O Nível D4 apresenta uma pequena variação no sinal reconstruído, indicando que há componentes de frequência que pertencem a este nível em específico. Nos níveis D5 e D6 o sinal reconstruído apresenta uma amplitude mais elevada, sendo mais intensa em D6, mostrando que o evento analisado pertence a estas faixas de frequências, abrangendo estes três níveis de detalhe.

Nos demais níveis de detalhe o sinal já não apresenta componentes de frequência significativos para caracterizar os eventos epileptiformes, sendo desconsiderados do processo de análise. Este método é muito semelhante a um filtro passa-bandas, pois só nos níveis de detalhe que continham frequências correspondentes ao evento epileptiforme apresentaram morfologias e amplitudes significativas ao evento analisado. Este experimento serviu para levantar informações adicionais, sobre o processo de decomposição e reconstrução de um sinal real de EEG, analisando o comportamento destes sinais.

Outro fato interessante observado foi que, as faixas de trabalho em tempo e frequência, definidas para os eventos epileptiformes são válidas, comprovadas através dos gráficos obtidos neste experimento.

Foi possível ainda obter informações de como utilizar o processo de decomposição wavelet, para extrair componentes de frequência de

um sinal, utilizando as aproximações e os detalhes através do processo de reconstrução dos sinais analisados.

Um ponto interessante que vale a pena destacar é a flexibilidade na utilização da transformada wavelet. Dependendo da aplicação podem ser utilizados apenas os coeficientes de aproximação, apenas os coeficientes de detalhes ou mesmo a combinação dos dois conjuntos de coeficientes para o processamento dos sinais, como será demonstrado nos itens a seguir.

4.4.2 Proposta de um Filtro para o Processamento de Sinais de EEG Utilizando a Transformada Wavelet

Uma característica interessante da transformada wavelet observada, através dos experimentos realizados, é que esta ferramenta quando utilizada adequadamente, há a possibilidade de se manipular um sinal, mantendo ou extraindo determinadas componentes de frequência, sem grandes distorções. A Figura 52 representa as etapas do processo de decomposição e reconstrução de um sinal qualquer. Neste exemplo, o sinal foi decomposto e reconstruído em 6 níveis, gerando um nível de aproximação A6 e seis níveis de detalhe D6, D5, D4, D3, D2 e D1. O sinal decomposto apresenta todas as componentes de frequência do sinal original, agrupadas por nível de decomposição. Ao se reconstruir um sinal, a partir de um determinado nível de aproximação ou de detalhe, apenas as frequências que este nível em específico abrange serão utilizadas para gerar o sinal reconstruído. Ou seja, têm-se bandas específicas do sinal original fragmentadas em sinais “secundários” reconstruídos (A6, D6, D5, D4, D3, D2 e D1).

Ao realizar a manipulação algébrica (somadas ou diferenças) entre estes sinais secundários, se chegará ao sinal original novamente ou a um sinal sem determinadas frequências, dependendo da aplicação. A partir destas considerações foram levantadas três hipóteses para a implementação de um filtro com a transformada wavelet. Este filtro será utilizado no pré-processamento dos sinais de EEG, antes das etapas de localização e identificação de eventos epileptiformes.

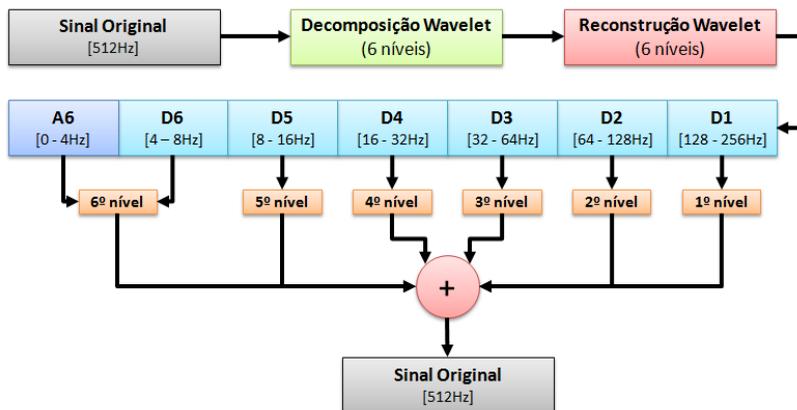


Figura 52 – Processo de decomposição e reconstrução de um sinal qualquer, com 512 Hz de frequência de amostragem.

Primeira Hipótese: utilizando apenas os níveis de detalhe.

No início dos experimentos com os eventos epileptiformes os sinais eram decompostos e reconstruídos em 6 níveis, gerando o nível de aproximação A6 e os níveis de detalhe D6 a D1. Cada um dos níveis de detalhe foi analisado individualmente. Foram observadas algumas particularidades em relação à morfologia do sinal gerado, a amplitude e a repetibilidade do nível de detalhe, que apresentasse o maior número de sinais reconstruídos, morfologicamente semelhantes ao sinal original. Foi observado um padrão de repetição nos níveis de detalhe D4, D5 e D6, os quais coincidem com a faixa de frequências definida para os eventos epileptiformes. Após a realização de diversos experimentos observou-se que as baixas frequências do sinal original ficavam retidas na aproximação A6 (0-4 Hz). Já as altas frequências do sinal original, que não são de interesse, inclusive a frequência de 60 Hz, ficavam retidas nos detalhes D3 a D1 (32-256 Hz). Tais observações levam a crer que, ao se realizar uma operação de soma entre os sinais reconstruídos dos detalhes D6, D5 e D4, obtém-se um sinal livre de interferências, vindo a ser comprovado posteriormente com alguns experimentos realizados. O sinal resultante deste processo possui apenas as frequências de 4 a 32 Hz. As faixas de frequência dos eventos epileptiformes vão de 5 a 25 Hz, sendo assim, o sinal gerado possui todas as frequências necessárias para a correta identificação dos eventos epileptiformes (Figura 53).

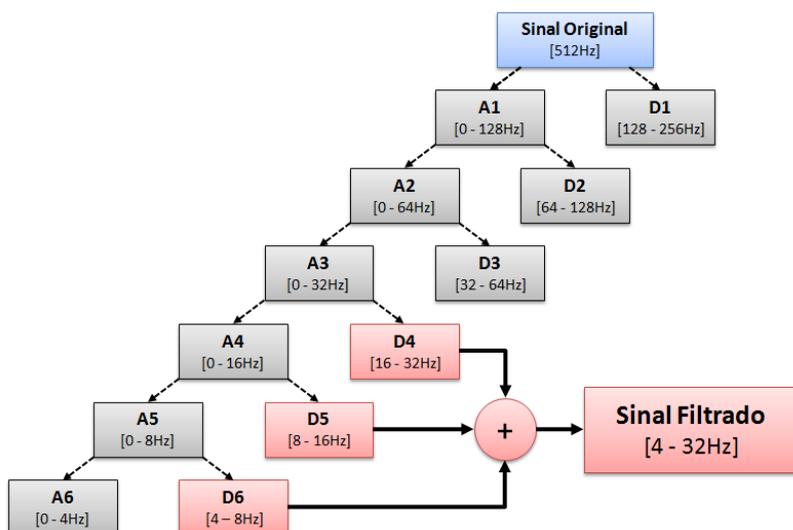


Figura 53 – Proposta de um filtro wavelet utilizando apenas os detalhes. Neste filtro é proposta uma operação de soma entre níveis de detalhe, se obtendo um sinal livre de interferências, como a de linha de base e oscilações de baixa frequência, bem como, interferências de alta frequência, incluindo o ruído de 60 Hz.

Segunda Hipótese: utilizando apenas os níveis de aproximação.

Neste experimento os eventos epileptiformes utilizados, também foram decompostos e reconstruídos em 6 níveis, obtendo-se o nível de aproximação A6 e os níveis de detalhe D6 a D1. À medida que o sinal original era decomposto, para cada nível gerado, as aproximações foram armazenadas, o que não é comum nesse processo de decomposição de um sinal pela transformada wavelet, pois são apenas os detalhes e um único nível de aproximação (o último), que são obtidos ao final do processo. Neste experimento foram utilizadas apenas as aproximações armazenadas em cada nível de decomposição. Através delas é possível se obter um sinal filtrado, combinando as aproximações entre si. Por exemplo, a aproximação A3 abrange frequências de 0 a 32 Hz do sinal original. Já a aproximação A6 abrange as frequências de 0 a 4 Hz. Fazendo a diferença entre estes dois níveis, na ordem A3-A6, obtém-se um sinal com frequências entre 4 e 32 Hz, pois as frequências de 0 a 4 Hz presentes na aproximação A3 se anulam com as mesmas

frequências presentes na aproximação A6. Neste método de filtragem são reconstruídos (ou utilizados) apenas dois sinais reconstruídos (A3 e A6), proporcionando maior desempenho no processo de filtragem se comparado ao primeiro método, onde são reconstruídos três sinais (Figura 54).

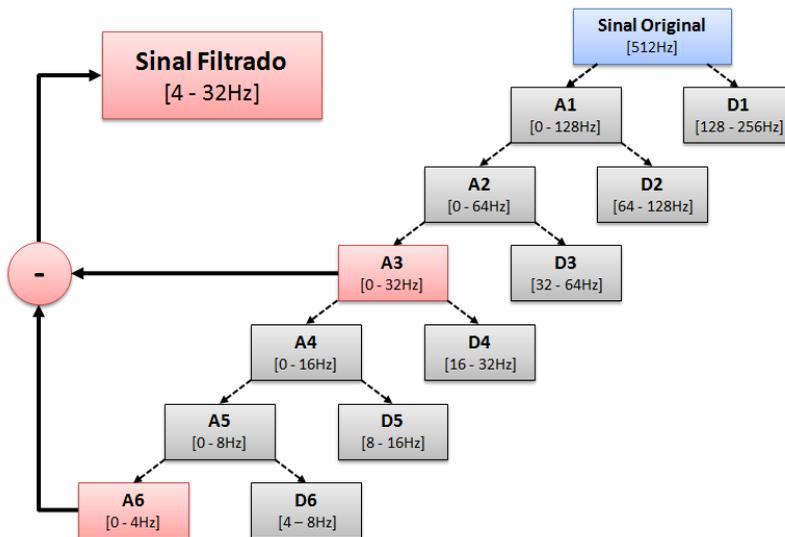


Figura 54 – Proposta de um filtro wavelet utilizando apenas as aproximações. Neste filtro é proposta uma operação de subtração entre níveis de aproximação, onde também se obtém um sinal filtrado, contendo apenas as frequências entre 4 e 32 Hz. Em comparação ao primeiro método de filtragem, este acabou se tornando mais eficiente pelo fato de se utilizar apenas dois sinais reconstruídos e não três, como apresentado no primeiro método.

Terceira Hipótese: utilizando as aproximações e o sinal original.

Neste método é proposta uma forma mais simples de filtragem dos sinais de EEG, utilizando apenas um nível de aproximação. Este método é indicado para a atenuação apenas das oscilações de baixa frequência, existentes na atividade de fundo do EEG, preservando as frequências acima de 4 Hz. Neste método é proposta a diferença entre o sinal original e o nível de aproximação A6. O nível A6 retém as baixas frequências que o sinal de EEG apresenta, incluindo linha de base e oscilações de baixa frequência. Subtraindo A6 (0-4 Hz) do sinal original (0-256 Hz), se obtém um sinal filtrado com frequências entre 4 e

256 Hz. A vantagem de se utilizar este método é que a morfologia dos picos dos eventos epileptiformes é preservada, por apresentarem frequências acima de 4 Hz. No entanto, o sinal dependerá de outros filtros para eliminar ruídos de alta frequência, como o ruído de 60 Hz.

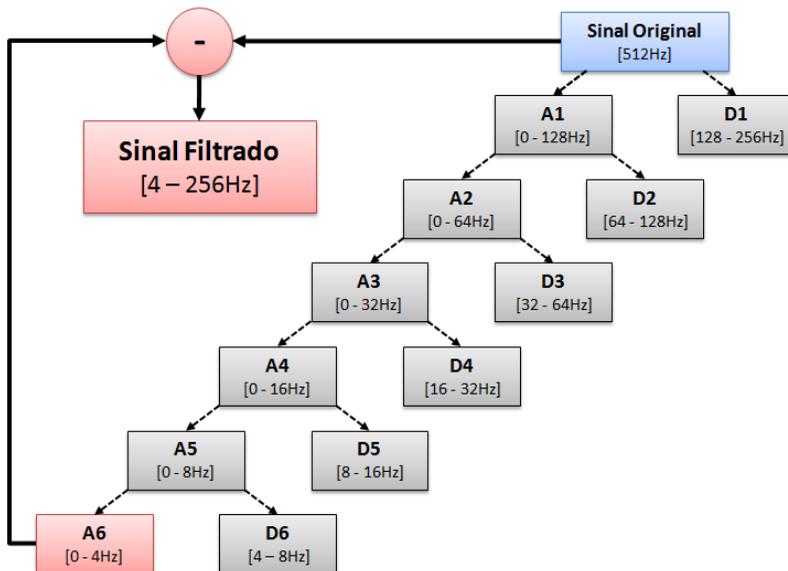


Figura 55 – Proposta de um filtro wavelet utilizando as aproximações e o sinal original. Neste filtro é proposta uma operação de subtração entre o sinal original e o nível de aproximação A6, onde se obtém um sinal filtrado, contendo as frequências acima de 4 Hz. Este filtro é adequado apenas para a eliminação de oscilações de baixas frequências, como o ruído de linha de base do EEG.

O filtro escolhido e adotado neste trabalho para a filtragem das oscilações da atividade de fundo e das altas frequências presentes nos sinais de EEG foi o filtro apresentado na segunda hipótese (método 2), o qual utiliza apenas as aproximações no processo de filtragem.

4.4.3 Escolha da Função Wavelet para o Filtro Proposto

Neste trabalho a transformada wavelet está sendo empregada como um filtro e não como ferramenta de detecção. Dessa forma, decidiu-se fazer uma investigação para tentar identificar a função

wavelet mais apropriada para a utilização com o filtro proposto, que apresentasse poucos coeficientes e pouca distorção do sinal após o processo de filtragem.

Nos experimentos iniciais foi utilizada a energia de cada função wavelet como critério de escolha. A função que apresentasse a maior média de energia acumulada e um número reduzido de coeficientes seria a função escolhida. O experimento consistiu em aplicar um conjunto de eventos epileptiformes em funções wavelet conhecidas. Foram utilizadas as famílias de funções wavelet: Daubechies, Symlets, Coiflets, Biortogonal e Biortogonal Reversa, totalizando 65 funções. Foi elaborado um conjunto de padrões contendo 480 eventos epileptiformes com diversas durações e amplitudes, como mostra a Figura 56.

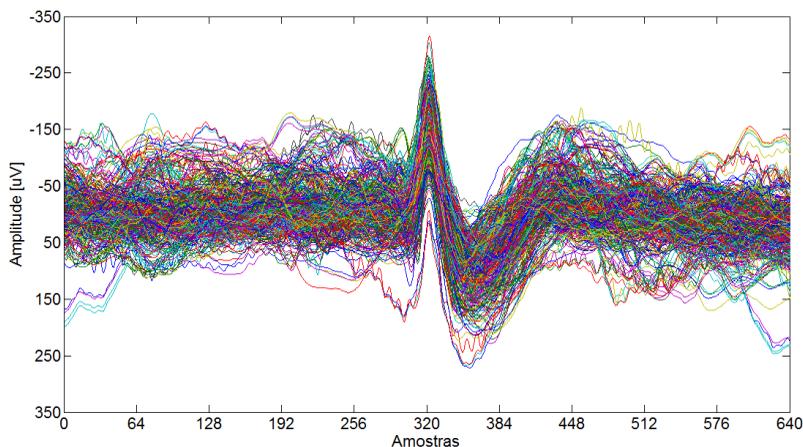


Figura 56 – Representação das realizações dos eventos selecionados para a escolha da função Wavelet a ser utilizada na filtragem dos sinais.

Todos os eventos epileptiformes do conjunto de padrões selecionados para este estudo foram aplicados em cada uma das funções wavelet descritas anteriormente. Foi calculada a energia de cada evento epileptiforme decomposto, as quais foram acumuladas e utilizadas para se obter a energia média de cada uma das funções wavelet utilizadas. Para a realização dos testes com o filtro proposto foram escolhidas 10 funções com os maiores valores de energia média acumulada. Os valores obtidos são apresentados na Tabela 4.

Tabela 4 – Visualização de dez funções wavelet, que apresentaram os maiores valores de energia e o seu respectivo número de coeficientes, para o conjunto de eventos selecionado.

Função Wavelet	Coeficientes	Energia [%]
bior3.1	4	89,57
sym14	28	79,46
sym15	30	79,40
sym13	26	79,34
sym12	24	77,45
coif5	30	76,53
rbio3.9	20	76,49
rbio2.8	18	75,51
sym10	20	75,18
sym11	22	75,16

Para testar as funções obtidas foi utilizada uma época de sinal de cinco segundos de um traçado de EEG, contendo um evento epileptiforme, oscilações de baixa frequência e ruídos de alta frequência. Esta época de sinal foi aplicada em quatro funções da Tabela 4 e os sinais filtrados são apresentados na Figura 57.

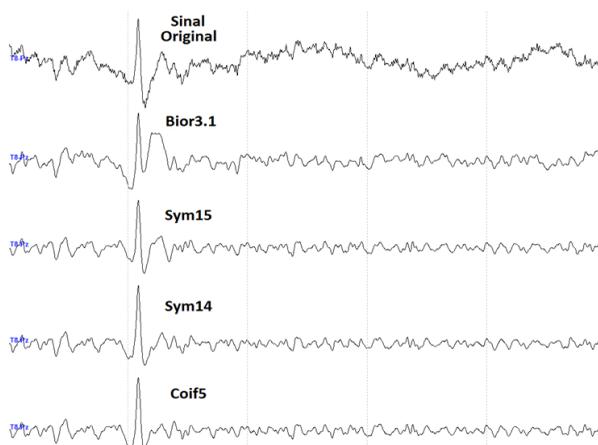


Figura 57 – Exemplos de filtragem com algumas funções wavelet selecionadas.

Pode ser observado que as oscilações de baixa frequência e os ruídos de alta frequência, presentes no sinal original foram atenuados, ficando apenas os eventos epileptiformes em destaque. Porém, dependendo da função wavelet utilizada o evento apresenta formas distintas, devido às características que cada função wavelet apresenta.

Outros experimentos foram realizados para encontrar a função wavelet que mais preservasse a morfologia dos eventos epileptiformes após o processamento, mas que também atenuassem de forma satisfatória as oscilações de baixa frequência e os ruídos de alta frequência.

Como forma de avaliar, o quanto foi alterado e o erro associado a essa alteração, na morfologia dos sinais processados pelo filtro wavelet, foram calculados a correlação e o erro médio quadrático (EMQ), entre cada um dos eventos epileptiformes originais e os eventos epileptiformes filtrados. O item a seguir descreve as formas adotadas, para a investigação da função wavelet, mais adequada para o processamento dos sinais de EEG.

4.4.4 Cálculo das Correlações e dos Erros Médios Quadráticos

Para este experimento foram analisados épocas de sinal de um segundo, o evento epileptiforme (complexo espícula e onda-lenta) e o pico isolado (apenas a espícula). Essas três categorias de sinais são representados pela Figura 58.

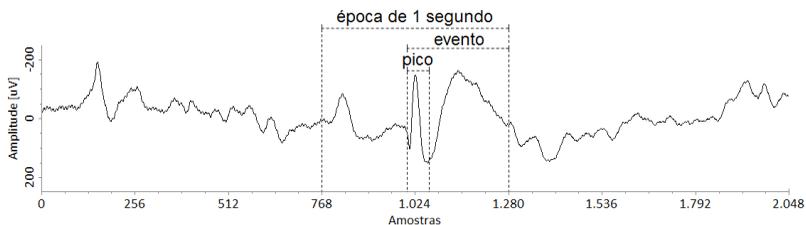


Figura 58 – Representação das categorias definidas para a análise das funções.

Todos os eventos do conjunto de padrões foram aplicados em cada uma das funções wavelet. Foram calculados os erros médios quadráticos e as correlações para cada uma das categorias definidas anteriormente. Esta divisão em partes permitiu a realização de uma análise mais detalhada das funções wavelet.

A Figura 59 apresenta o procedimento realizado com as funções wavelet selecionadas, para o cálculo do EMQ e da correlação entre os sinais originais e filtrados. Apenas para fins ilustrativos foram utilizadas as funções Coif4, Bior3.1, Db4 e RBio2.8, as quais foram identificadas como sendo as funções mais adequadas para o filtro proposto.

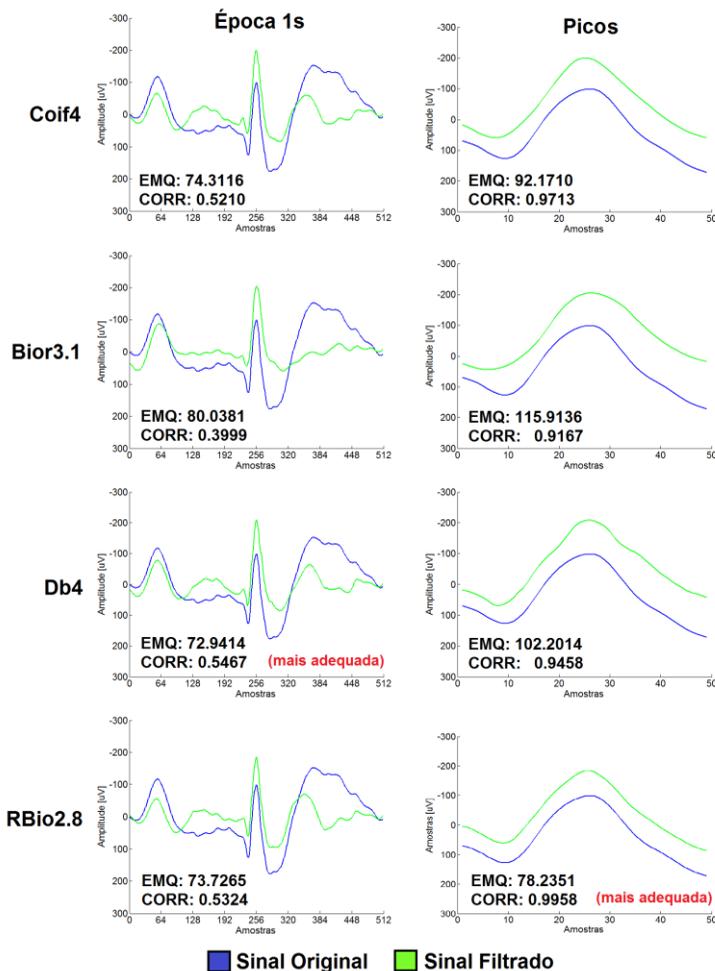


Figura 59 – Representação da análise de épocas de sinal de um segundo e a análise do pico do evento desta época de sinal.

Após a realização dos experimentos, outras três funções wavelet foram consideradas adequadas, para a utilização com o filtro proposto, as funções Rbio2.8, Coif4 e Db4. Estas funções foram escolhidas por apresentarem, os maiores valores de correlação e os menores valores de erro médio quadrático por categoria analisada, em relação às demais selecionadas. Consequentemente, sendo as funções wavelet que mais preservaram a morfologia dos sinais analisados. A Figura 60 apresenta

uma demonstração de antes e depois da filtragem, utilizando as funções wavelet obtidas. Pode ser observado que, em cada um dos gráficos, há uma sobreposição das envoltórias dos sinais originais (ao fundo) e das envoltórias dos sinais filtrados (em frente), demonstrando o comportamento de cada função wavelet escolhida e o filtro proposto neste trabalho.

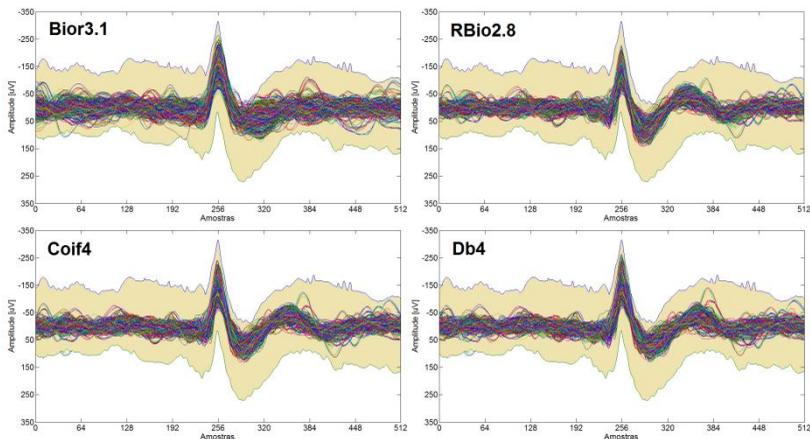


Figura 60 – Demonstração do funcionamento do filtro wavelet com as quatro funções obtidas, mostrando todos os eventos epileptiformes do conjunto de padrões, após o processamento com o filtro proposto, contrastando com os sinais originais ao fundo.

4.4.5 Avaliação das Funções Wavelet Escolhidas

A avaliação consistiu em aplicar um conjunto de eventos epileptiformes e calcular as correlações e os EMQs, entre os picos individuais dos eventos epileptiformes originais e os filtrados, os eventos epileptiformes dos sinais originais filtrados e as épocas dos sinais originais e filtrados.

Os resultados foram agrupados em tabelas, as quais mostram os valores alcançados por cada categoria analisada.

4.4.5.1 Avaliação das Funções Wavelet pelo Cálculo das Correlações

A Tabela 5 apresenta os resultados obtidos pela correlação entre os picos dos sinais originais e os picos dos eventos processados, onde a função RBio2.8 obteve o maior valor de correlação.

Tabela 5 – Correlação entre os picos dos eventos originais e os filtrados.

Função Wavelet	Coefficientes	Energia [%]	Correlação entre Picos
rbio2.8	18	75,51	0,985988
coif2	12	63,90	0,985208
rbio2.6	14	70,53	0,984620
bior2.8	18	68,32	0,984608
bior2.6	14	64,56	0,984165
rbio6.8	18	73,29	0,984156
bior6.8	18	73,47	0,983519
sym8	16	71,83	0,982686
sym6	12	67,04	0,982597
sym4	8	59,07	0,982411

A Tabela 6 apresenta os valores obtidos através do cálculo das correlações entre os eventos epileptiformes originais e os eventos epileptiformes filtrados. Das dez funções obtidas a função Db4 foi a que apresentou o maior valor de correlação média entre elas na análise do complexo espícula-onda.

Tabela 6 – Correlação entre os eventos originais e os filtrados.

Função Wavelet	Coefficientes	Energia [%]	Correlação entre Eventos
db4	8	48,30	0,833480
sym7	14	67,69	0,824208
db8	16	59,38	0,820907
db12	24	65,23	0,812157
coif5	30	76,53	0,810064
rbio1.3	6	55,36	0,803467
coif4	24	74,03	0,795365
bior3.1	4	89,57	0,779477
db15	30	67,40	0,775226
coif3	18	70,16	0,771351

A Tabela 7 apresenta os valores obtidos com o cálculo da correlação média entre as épocas de sinal original e as épocas de sinal filtrado. Novamente a função Db4 apresentou o maior valor de correlação entre o sinal original e o filtrado.

Tabela 7 – Correlação entre as épocas de 1s originais e as épocas filtradas.

Função Wavelet	Coefficientes	Energia [%]	Correlação entre Épocas de 1s
db4	8	48,30	0,717658
coif5	30	76,53	0,693210
sym7	14	67,69	0,692088
coif4	24	74,03	0,690788
rbio1.3	6	55,36	0,690375
db8	16	59,38	0,690320
sym4	8	59,07	0,682411
coif3	18	70,16	0,679416
db12	24	65,23	0,675012
db15	30	67,40	0,673080

Através do uso do índice de correlação como forma de avaliar a distorção das morfologias dos sinais processados, chegou-se a duas funções wavelet. A função RBio2.8 se destacou pelo fato de apresentar o maior valor de correlação na avaliação dos picos (espículas) dos eventos epileptiformes. Já a função Db4 obteve os maiores valores de correlação, tanto na avaliação do complexo espícula onda-lenta, quanto na avaliação da época de sinal de um segundo.

4.4.5.2 Avaliação das Funções Wavelet pelos Erros Médios Quadráticos

A Tabela 8 apresenta o EMQ calculado entre os picos dos eventos epileptiformes originais e os picos dos eventos epileptiformes filtrados. Neste experimento a função que obteve o menor valor de erro foi a função Coif4.

Tabela 8 – EMQ entre os picos dos eventos originais e os eventos filtrados.

Função Wavelet	Coefficientes	Energia [%]	EMQ entre Picos
coif4	24	74,03	30,496005
coif5	30	76,53	31,265593
coif3	18	70,16	31,537512
db4	8	48,30	31,725582
db15	30	67,40	31,763431
db11	22	64,09	31,833546
sym12	24	77,45	31,937828
sym4	8	59,07	32,571695
sym10	20	75,18	32,621571
db7	14	56,47	32,666603

A Tabela 9 apresenta os valores obtidos através do cálculo do EMQ entre os complexos espícula onda-lenta entre os sinais originais e dos filtrados. A função wavelet que obteve o menor valor de erro foi a Db4.

Tabela 9 – EMQ entre os eventos originais e os eventos filtrados.

Função Wavelet	Coefficientes	Energia [%]	EMQ entre Eventos
db4	8	48,30	37,659730
sym7	14	67,69	38,648321
db8	16	59,38	38,897637
coif5	30	76,53	39,530448
db12	24	65,23	39,739856
rbio1.3	6	55,36	40,126242
coif4	24	74,03	40,473673
bior3.1	4	89,57	40,847805
db15	30	67,40	41,935201
coif3	18	70,16	42,023981

A Tabela 10 apresenta os valores obtidos com a análise das épocas de 1s dos sinais originais e dos sinais filtrados. A função que apresentou o menor valor de erro foi a função Db4.

Tabela 10 – EMQ entre as épocas de 1s originais e as épocas filtradas.

Função Wavelet	Coefficientes	Energia [%]	EMQ entre Épocas de 1s
db4	8	48,30	36,799603
coif5	30	76,53	37,957277
coif4	24	74,03	38,034667
sym7	14	67,69	38,061023
db8	16	59,38	38,129404
rbio1.3	6	55,36	38,243990
sym4	8	59,07	38,353757
coif3	18	70,16	38,511218
db15	30	67,40	38,828296
db11	22	64,09	38,835923

De acordo com os experimentos realizados, a função Db4 provou ser a melhor escolha para a utilização com o filtro proposto, tanto pelos valores de correlação, quanto os valores de erro médio quadrático. Esta função é indicada quando há a necessidade de preservar a morfologia da época inteira do sinal filtrado.

Quando há a necessidade de preservar apenas os picos do sinal filtrado as funções wavelet mais adequadas são a RBio2.8 e Coif4.

Caso seja necessário apenas atenuar a atividade normal de fundo do EEG, sem a preocupação de preservar a morfologia da época de sinal a função mais adequada é a bior3.1. Devido ao fato desta função em particular apresentar poucos coeficientes, sua utilização na filtragem dos sinais de EEG oferece um desempenho superior às demais funções apresentadas. Porém, esta função apresenta maior distorção do sinal após a filtragem do que as demais.

A Tabela 11 apresenta os valores obtidos de correlação e de EMQ para uma época de sinal de 1s, categoria adotada para a realização de todos os métodos e processamentos envolvidos nesta metodologia.

Tabela 11 – Funções wavelet obtidas através dos experimentos realizados com um conjunto de sinais contendo 480 eventos epileptiformes.

Função	Coefs.	Energia [%]	Correlação Época 1s	EMQ Época 1s
db4	8	48,30	0,717658	36,799603
coif4	24	74,03	0,690788	38,034667
rbio2.8	18	75,51	0,666828	39,029143
bior3.1	4	89,57	0,666274	39,463159

4.4.6 Avaliação do Filtro Wavelet Proposto

Nesta seção serão apresentadas telas de traçados de EEG originais contendo linha de base, ruídos de alta frequência, oscilações de baixa frequência e eventos epileptiformes. Também serão mostrados para cada tela de sinal original, os seus respectivos sinais filtrados pelos três filtros propostos utilizando a função Db4, a qual foi definida para este trabalho.

4.4.6.1 Experimentos com os Filtros Propostos Aplicados ao EEG

A Figura 61 apresenta um segmento de sinal de EEG contaminado por artefatos musculares. São apresentados o sinal original e os três sinais processados pelos filtros propostos. Pode ser observado que os métodos 1 e 2 atenuaram as oscilações de baixas frequências presentes no sinal.

Houve também atenuação nas frequências de alta frequência geradas por artefatos musculares.

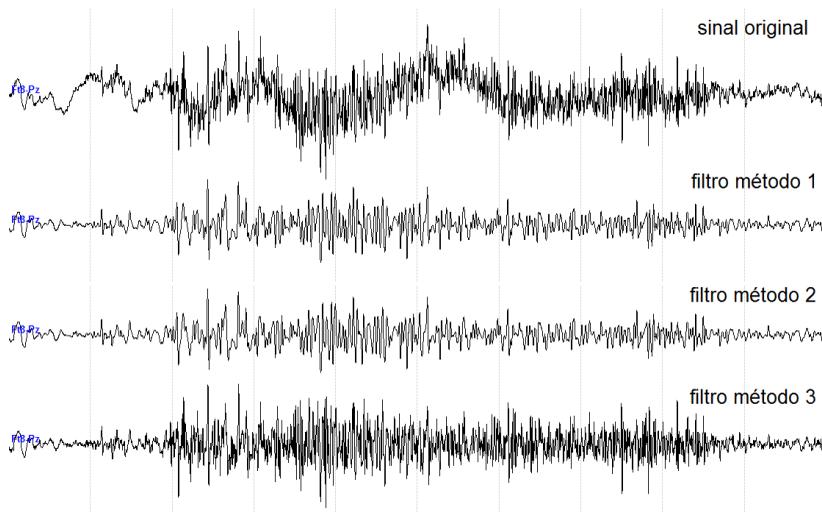


Figura 61 – Sinal de EEG contendo artefatos musculares.

A Figura 62 apresenta um segmento de sinal de EEG que apresenta grandes flutuações de linha de base. Pode ser observado que a filtragem pelos métodos 1 e 2 atenuou as oscilações da linha de base do sinal apresentava. Pequenas oscilações apresentando baixas frequências aparentes no início do sinal original também foram atenuadas.

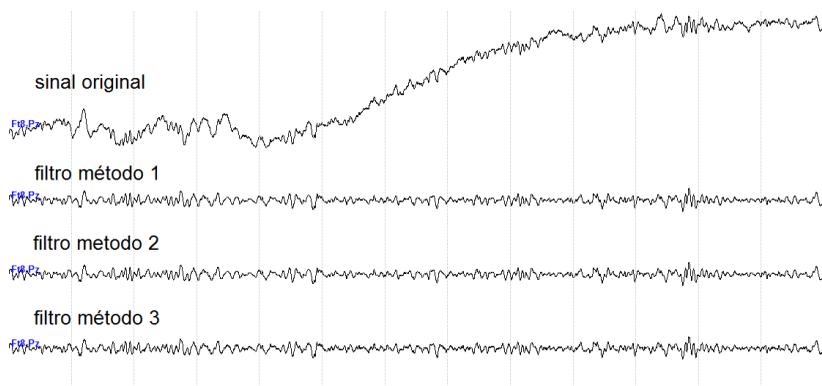


Figura 62 – Sinal de EEG contendo oscilação na linha de base.

A Figura 63 apresenta um segmento de sinal de EEG contendo ruídos de alta frequência. Os métodos 1 e 2 apresentaram boa atenuação pelo fato de apresentarem uma banda restrita entre 4 Hz e 32 Hz. Já o

método 3 apenas atenuou as pequenas oscilações de baixa frequência, pelo fato deste filtro apresentar uma banda de frequências entre 4 Hz e 256 Hz, deixando as frequências mais altas permanecerem no sinal analisado.

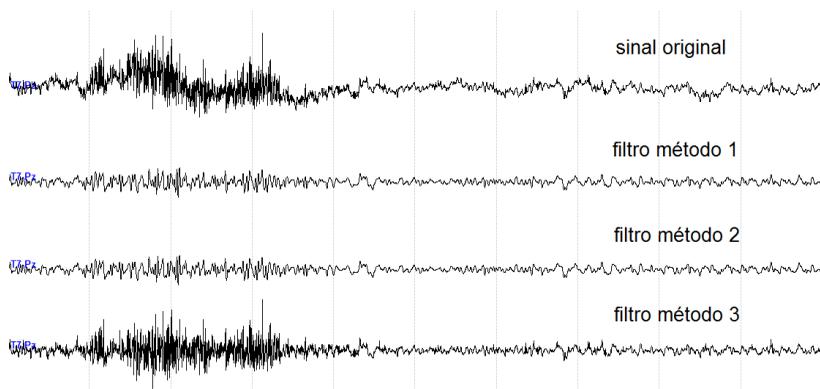


Figura 63 – Sinal de EEG contendo ruídos de alta frequência.

A Figura 64 apresenta um segmento de EEG contendo eventos epileptiformes e pequenas oscilações de baixas frequências. Pode ser observado que as oscilações de baixas frequências foram atenuadas e os três métodos apresentaram resultados semelhantes. Como o sinal original não apresenta grandes variações nas altas frequências, o filtro do método 3 apresentou um sinal filtrado semelhante aos demais.

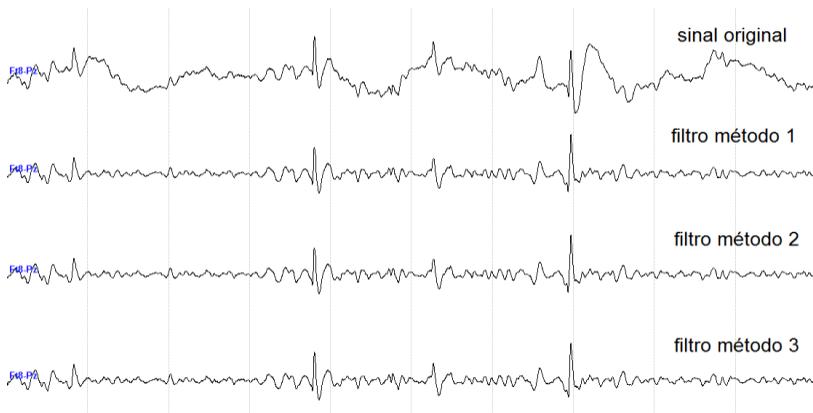


Figura 64 – Sinal de EEG contendo eventos epileptiformes.

4.4.7 Aplicação do Filtro Proposto em Telas de EEG

No item anterior foram mostradas figuras contendo segmentos de sinais de EEG e os mesmos sinais processados pelos três métodos utilizados para filtragem.

A seguir serão mostradas telas individuais de dez segundos de traçados de EEG, contendo as mais diversas condições encontradas nos registros utilizados. Serão mostradas oscilações de sinal, ruídos de alta e baixa frequência, flutuações de linha de base e também telas com eventos epileptiformes. As telas de sinal foram processadas com a função wavelet db4, a qual foi escolhida para a metodologia proposta. O filtro utilizado foi o filtro proposto no método 2 (Hipótese 2), considerado o mais eficiente dos três propostos.

A Figura 65 apresenta um traçado de EEG contendo grandes flutuações de linha de base. No canto superior direito há a presença de alguns eventos epileptiformes, caracterizando um campo de potencial.

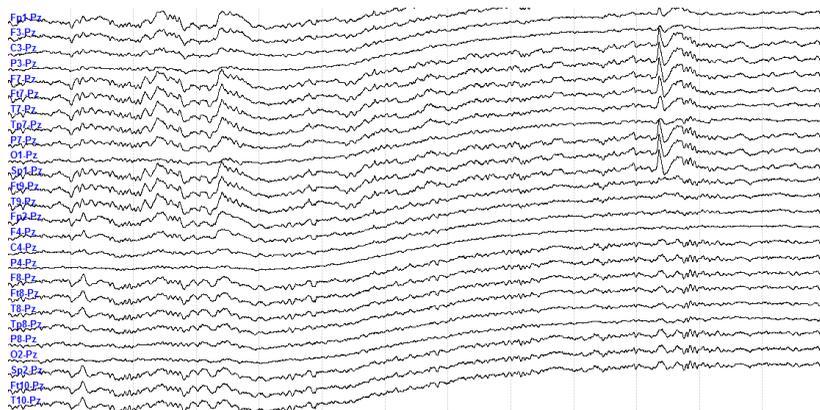


Figura 65 – Traçado de EEG contendo flutuação da linha de base do sinal.

Pode ser observado que houve atenuação nas flutuações de linha de base e outras oscilações presentes no sinal original, ficando em evidência apenas os eventos epileptiforme no traçado do EEG (Figura 66).

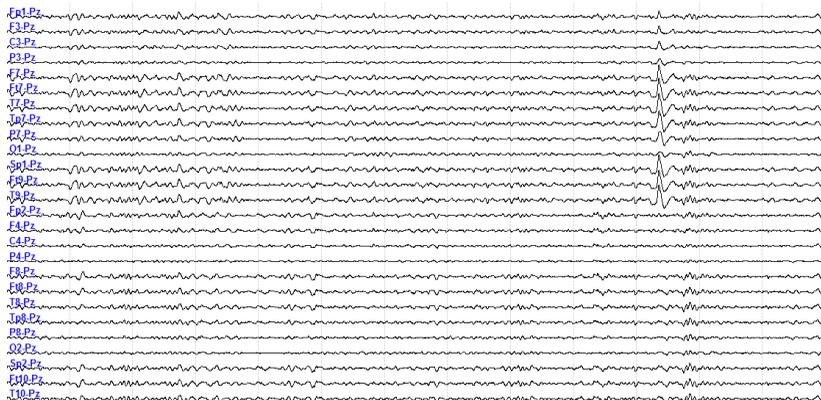


Figura 66 – Traçado de EEG processado pelo filtro do método 2.

A Figura 67 apresenta um traçado de EEG contendo muitas oscilações de baixas frequências, bem como muito ruído de alta frequência.

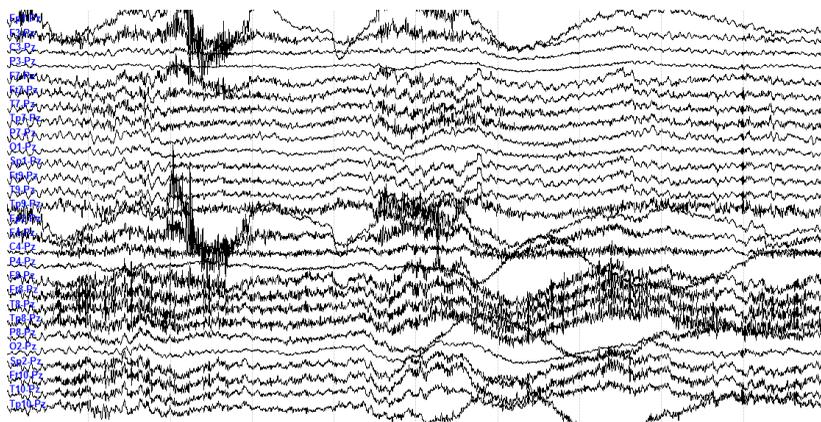


Figura 67 – Traçado de EEG contendo ruídos de altas e baixas frequências.

Através da Figura 68 pode ser observado que as oscilações de baixa frequência foram atenuadas, porém, algumas frequências abaixo de 32 Hz permaneceram no sinal processado.

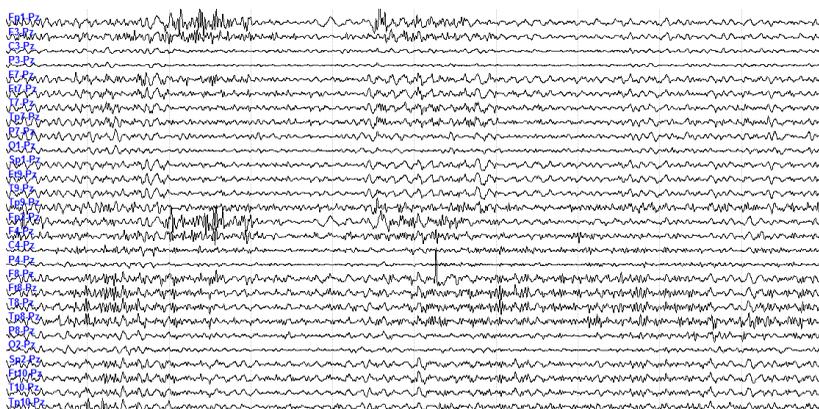


Figura 68 – Traçado de EEG processado pelo filtro do método 2

A Figura 69 apresenta uma tela contendo eventos epileptiformes em dois instantes de tempo distintos. São perceptíveis pequenas oscilações de baixa frequência nos canais superiores

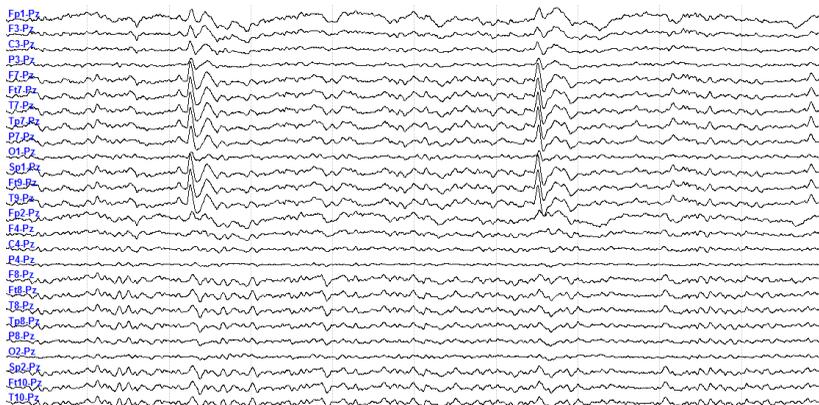


Figura 69 – Traçado de EEG contendo eventos epileptiformes.

Na Figura 70 pode ser observado que os eventos epileptiformes ficam mais destacados no traçado do EEG, devido ao fato do filtro atenuar todas as oscilações presentes no sinal.

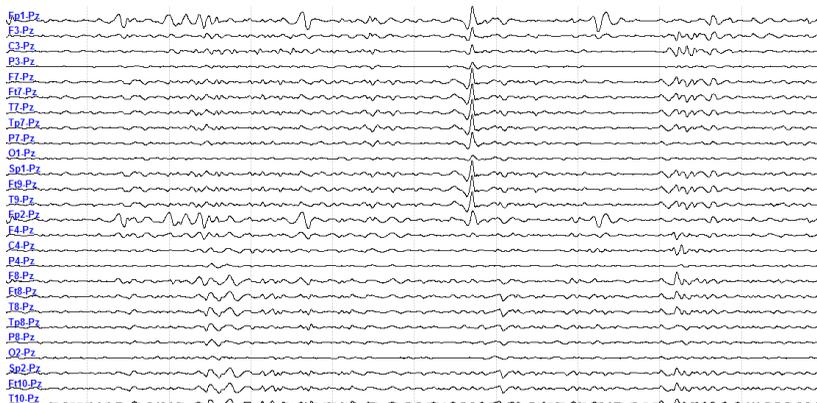


Figura 72 – Traçado de EEG processado pelo filtro proposto no método 2.

A Figura 73 apresenta um traçado contaminado por ruído de 60 Hz, piscadas palpebrais, algumas oscilações e mais ao centro da tela eventos epileptiformes (seta em preto), obviamente mascarados devido ao ruído.

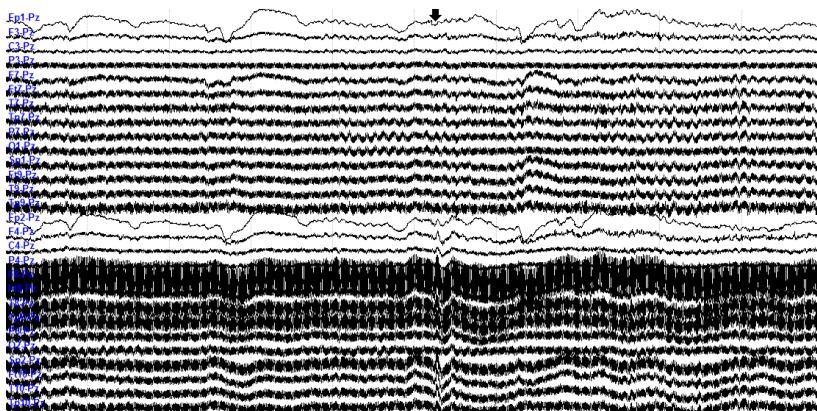


Figura 73 – Traçado de EEG contendo ruído de 60 Hz e eventos epileptiformes.

Na Figura 74 pode-se observar que o ruído da rede elétrica foi atenuado, as oscilações e as piscadas palpebrais também, evidenciando os eventos epileptiformes que antes não apareciam.

Pelo fato dos sinais de EEG apresentarem oscilações de baixa frequência, característica na atividade normal de fundo, a utilização da

transformada wavelet demonstrou grande capacidade de atenuação dessas frequências, sem distorcer os picos dos eventos epileptiformes.

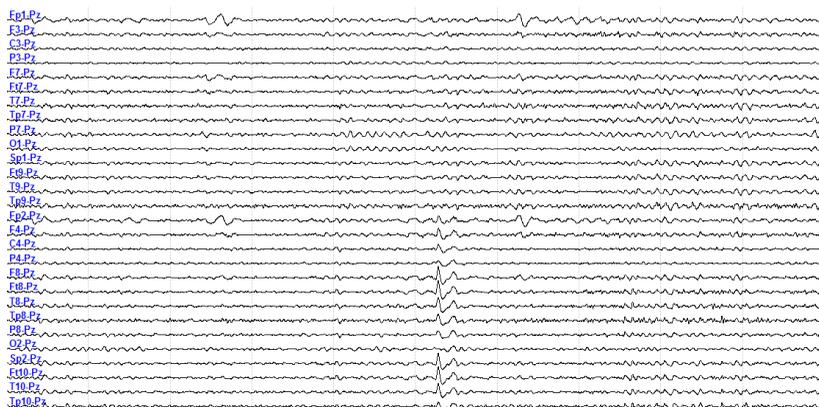


Figura 74 – Traçado de EEG processado pelo filtro proposto no método 2.

Dessa forma, o filtro wavelet desenvolvido foi utilizado para o pré-processamento dos sinais de EEG, antes de executar o processo de localização dos eventos epileptiformes, através da verificação das máximas amplitudes negativas que os canais apresentam. As próximas etapas do desenvolvimento do sistema são descritas a seguir.

4.5 LOCALIZAÇÃO E MARCAÇÃO DOS EVENTOS EPILEPTIFORMES

A localização dos eventos epileptiformes, nas telas de dez segundos de sinal é um processo bastante simples. Consiste em aplicar o filtro wavelet a cada tela e após todos os canais processados, avaliar cada canal individualmente de 512 em 512 amostras, ou seja, de um em um segundo, armazenando as posições dos picos de sinal, que estejam dentro de uma faixa de amplitudes, definida entre $-40\mu\text{V}$ e $-400\mu\text{V}$.

Os valores definidos para a faixa de amplitudes foram escolhidos, pelo fato de que os eventos epileptiformes selecionados para as diversas experiências realizadas apresentaram amplitudes até $-350\mu\text{V}$. Caso algum evento analisado posteriormente, apresente amplitudes acima de $-350\mu\text{V}$ fica uma margem de $-50\mu\text{V}$, para que ele não seja descartado, para posterior classificação. Valores abaixo de $-40\mu\text{V}$ e acima de

-400 μ V são descartados automaticamente, pois em alguns registros de EEG analisados, observaram-se ruídos com amplitudes entre -400 μ V e -3V. Sinais da atividade normal de fundo do EEG, que apresentem frequências até 5 Hz são atenuados, restando apenas os picos com frequências maiores. Dependendo das amplitudes que esses picos remanescentes apresentam, caso não ultrapassem -40 μ V, também serão descartados. Dessa forma, consegue-se limitar ou localizar picos de sinal, que possam vir a ser um evento epileptiforme, verificando as amplitudes que eles apresentam após o processamento pelo filtro wavelet e não pela morfologia em si.

Fazendo uma varredura nas 5120 posições (512 amostras \times 10 segundos) que cada canal apresenta, as amostras de sinal são verificadas individualmente. Caso sua respectiva amplitude, esteja compreendida na faixa de amplitudes estipulada, a posição que a amostra se encontra no buffer de dados é então armazenada num buffer de posições e a sua amplitude é armazenada em outro buffer de amplitudes. Ambos os buffers apresentam dimensões de 10 \times 28, correspondendo a dez segundos de sinal, por vinte e oito canais existentes na tela. Lembrando que os buffers de dados, que armazenam os sinais lidos e processados, apresentam dimensões de 5120 \times 28 posições. Para cada segundo de sinal é armazenada a posição do máximo pico de sinal que apresentou a maior amplitude negativa, seja ele um evento epileptiforme ou outro sinal qualquer com amplitudes próximas as dos eventos. Caberá ao classificador neural, realizar a separação ou classificação dos possíveis eventos, marcados neste processo.

O método de localização pode ser visualizado através da Figura 75, onde é apresentado o processamento de um canal de EEG pelo filtro wavelet. É perceptível que houve uma diminuição nas amplitudes do sinal processado, pelo fato, que as oscilações de baixa frequência com amplitudes maiores foram atenuadas, ficando apenas os picos com frequência entre 5 e 25 Hz, que na maioria das vezes, correspondem com os eventos epileptiformes. Dessa maneira, fica fácil buscar as máximas amplitudes que “restaram” após o processamento, aplicando um limiar de corte, guardando as respectivas posições encontradas na tela, devendo repetir este processo para os vinte e sete canais restantes.

A Figura 76 representa uma tela de dez segundos de sinal de EEG, processada pelo filtro wavelet e todos os possíveis eventos epileptiformes encontrados e marcados pela máxima amplitude negativa. No momento da varredura de cada um dos canais processados, os eventos que estavam dentro da faixa de amplitudes entre -400 μ V e

Tabela 12 – Representação do buffer de posições que armazena as máximas amplitudes encontradas, para cada instante de tempo de um segundo, e para cada um dos vinte e oito canais das telas de dez segundos de registro.

Canais	1s	2s	3s	4s	5s	6s	7s	8s	9s	10s
FP1	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
F3	0/0,0	577/-75,88	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
C3	0/0,0	581/-79,99	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
P3	0/0,0	584/-41,40	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
F7	0/0,0	576/-136,72	1038/-42,02	0/0,0	2523/-56,68	2996/-48,05	0/0,0	0/0,0	0/0,0	0/0,0
FT7	0/0,0	578/-142,39	1037/-47,87	0/0,0	2521/-83,90	2998/-50,60	3118/-41,56	3603/-41,65	0/0,0	0/0,0
T7	40/-43,34	582/-162,62	1034/-47,49	0/0,0	2520/-109,88	2998/-48,92	0/0,0	0/0,0	0/0,0	0/0,0
TP7	0/0,0	583/-153,41	1035/-40,60	0/0,0	2522/-114,29	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
P7	0/0,0	588/-87,29	0/0,0	0/0,0	2526/-95,58	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
O1	0/0,0	596/-41,34	0/0,0	0/0,0	2526/-41,45	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
SP1	0/0,0	577/-129,07	1035/-50,65	0/0,0	2522/-81,34	2998/-47,08	0/0,0	3604/-40,05	0/0,0	0/0,0
FT9	0/0,0	577/-135,28	1036/-48,22	0/0,0	2522/-78,11	2996/-49,35	0/0,0	3604/-41,35	0/0,0	0/0,0
T9	0/0,0	579/-128,46	1035/-55,37	0/0,0	2521/-95,42	2880/-46,99	0/0,0	0/0,0	0/0,0	0/0,0
TP9	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
FP2	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
F4	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
C4	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
P4	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
F8	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	4931/-46,07
FT8	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	4934/-41,31
T8	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
TP8	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
P8	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
O2	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
SP2	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0
FT10	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	4935/-40,20
T10	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	4934/-43,10
TP10	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0	0/0,0

Depois de processados e previamente localizados, os possíveis eventos devem ser sincronizados com o sinal original, pois as redes neurais dos classificadores foram treinadas com a morfologia do sinal original, e não com a morfologia dos sinais processados pelo filtro wavelet. Entretanto, no momento da sincronização, pode não haver um sincronismo perfeito, entre as posições obtidas com o sinal processado e as posições reais do sinal original, como apresentado pela Figura 77.

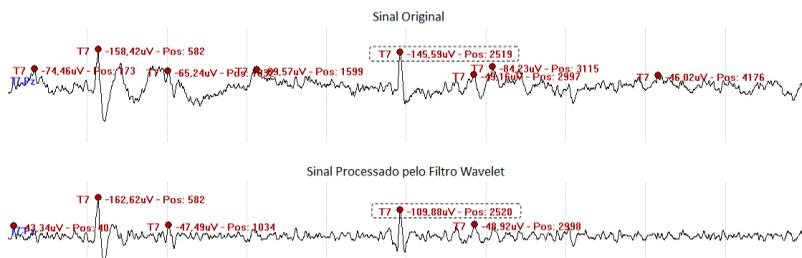


Figura 77 – Comparação do sinal original com o processado pelo filtro wavelet.

A Figura 77 apresenta essa relação entre o sinal processado e o sinal original. Pode ser observado que o pico encontrado na posição 582

coincide com a posição no sinal original, diferente dos picos encontrados nas posições 2520 do sinal processado e da posição 2519 do sinal original. Para corrigir as posições marcadas, que não coincidiram com os picos originais após o processamento, foi pego como ponto de referencia a posição marcada e foi feita a leitura de n amostras, antes e depois da posição indicada, verificando quais delas é a mais negativa. A amostra que tiver a máxima amplitude, próxima a posição encontrada anteriormente, será a posição original do evento, pois quando se faz o processamento pelo filtro wavelet, ocorre uma defasagem de uma ou duas amostras, dependendo do caso, em relação ao sinal original. Após encontrada a máxima amplitude corrigida, os valores referentes à nova posição e amplitude são alteradas nos respectivos buffers de posição e de amplitudes.

O procedimento de correção das posições é necessário, pois as redes neurais foram treinadas com os picos máximos dos eventos epileptiformes, posicionados sempre ao centro da janela de 512 amostras de sinal. Dessa forma, se obtém a posição original do máximo negativo, a partir da amostra que não coincidiu com a posição, fazendo um ajuste fino nas posições de máxima amplitude, como representa a Figura 78.

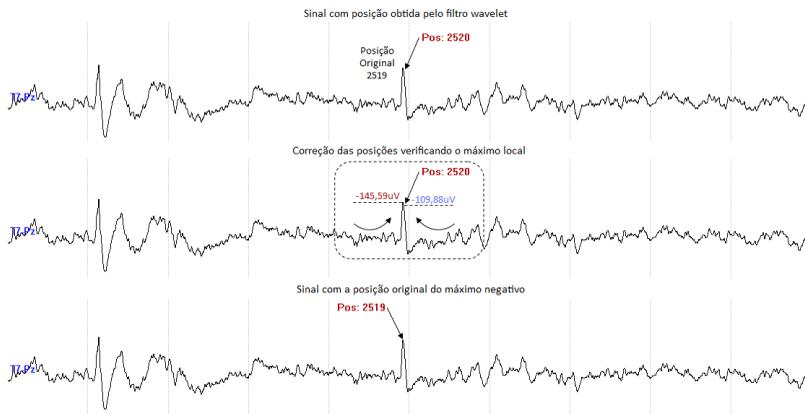


Figura 78 – Representação da correção das posições dos picos processados pelo filtro wavelet e as posições originais.

Caso o sinal fique defasado e sem correção, poderão ocorrer problemas com a classificação dos sinais passados às redes neurais, pois elas não foram treinadas com sinais defasados no tempo. A Figura 79 apresenta a mesma tela processada anteriormente com as posições corrigidas e prontas para serem encaminhadas para as redes.

Pode ser visto ainda que na tela de sinal, estão presentes apenas duas concentrações de eventos epileptiformes reais, os demais são segmentos de sinal que apresentaram amplitudes dentro da faixa estipulada, que posteriormente serão classificadas como não sendo eventos epileptiformes.

Depois de corrigidos, tem-se um mapa da tela de dez segundos de sinal, com as posições de possíveis eventos epileptiformes. A partir destas coordenadas (canal \times instante), posiciona-se uma janela para extração do padrão a ser classificado, e tendo como centro desta janela, a posição do pico do evento localizado anteriormente. Estendem-se 256 posições antes da posição marcada e 256 posições após a posição marcada, totalizando 512 amostras de sinal, com o padrão ao centro da janela. Cada uma das janelas extraídas é direcionada aos classificadores neurais para classificação do padrão extraído. O processo de classificação de padrões será descrito na próxima seção.

4.6 REDES NEURAIS ARTIFICIAIS PARA A CLASSIFICAÇÃO DE EVENTOS EPILEPTIFORMES EM SINAIS DE EEG

A classificação dos eventos epileptiformes foi feita a partir de redes neurais artificiais MLP (*Multi Layer Perceptron*), do tipo *feedforward*, utilizando o método da validação cruzada, com parada antecipada. Para a implementação das redes, foi criada uma ferramenta computacional para realizar as tarefas de treinamento e validação das redes neurais criadas, que conta com ferramentas estatísticas como curvas ROC, índices estatísticos diversos e métodos para teste diagnóstico, utilizado na validação dos classificadores neurais.

A seguir será apresentada a ferramenta computacional para o treinamento das redes neurais artificiais e os processos envolvidos no treinamento, validação e testes que o sistema disponibiliza.

4.6.1 Ferramenta Computacional para o Treinamento, Validação e Testes de Redes Neurais Artificiais

Para o treinamento e validação das redes neurais utilizadas neste trabalho foi implementada uma ferramenta computacional, através do ambiente de desenvolvimento C++ Builder. Essa ferramenta possibilitou

realizar toda a manipulação necessária para configuração, treinamento, validação e testes das redes neurais, gerando índices estatísticos como curvas ROC, índices de sensibilidade, especificidade, índices de eficiência, entre outros.

A Figura 80 apresenta a tela inicial da ferramenta de treinamento e validação de redes neurais. Nesta tela podem ser observados todos os parâmetros de configuração da rede, entre eles as camadas da rede, taxas de aprendizado, momentum, erro mínimo de treinamento, conjuntos de treinamento e validação, entre outros parâmetros.

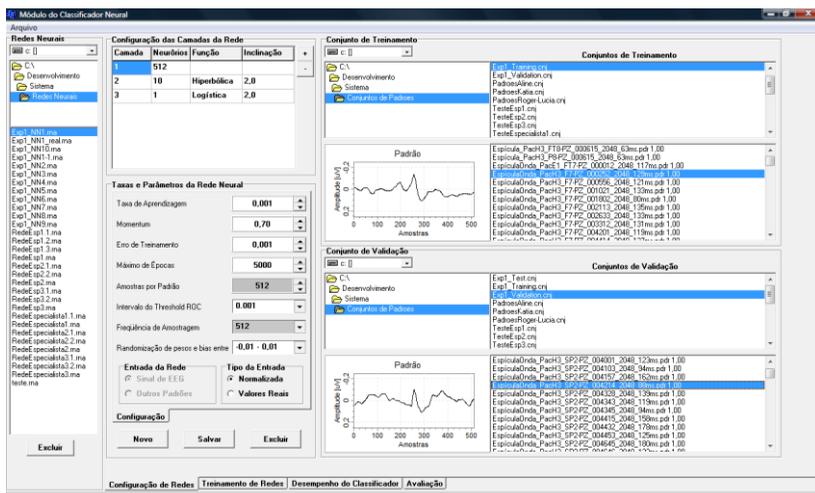


Figura 80 – Tela inicial da ferramenta computacional criada para o treinamento e validação de redes neurais artificiais.

Fonte: (Scolaro & Azevedo, 2010),(Scolaro, et al., 2011).

A segunda tela da ferramenta de treinamento é onde se faz a inicialização do treinamento e o acompanhamento da evolução do treinamento da rede neural, representado pela Figura 81.

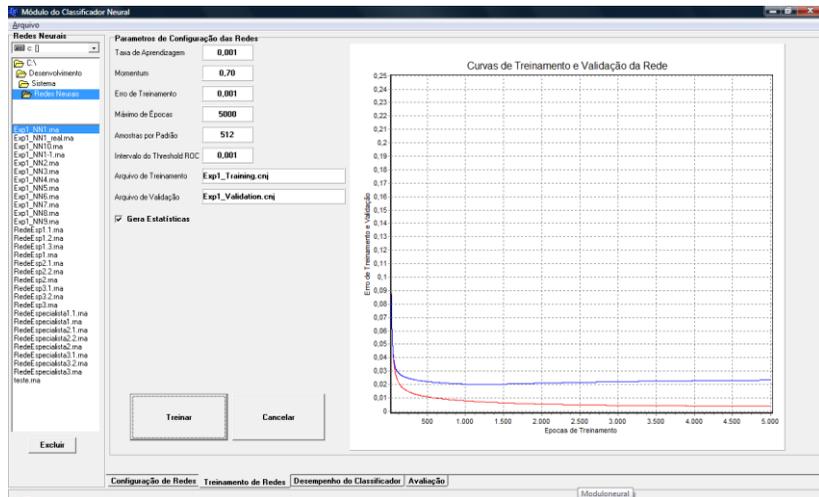


Figura 81 – Tela de inicialização e de acompanhamento da evolução dos treinamentos das redes neurais.

Fonte: (Scolaro & Azevedo, 2010),(Scolaro, et al., 2011).

A tela apresentada através da Figura 82 mostra o ambiente desenvolvido para a geração dos testes estatísticos com a rede treinada.

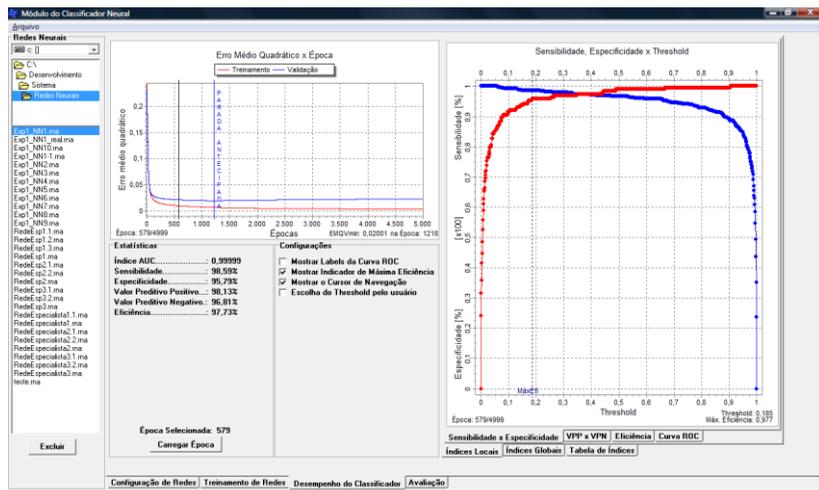


Figura 82 – Tela de acompanhamento das estatísticas realizadas.

Fonte: (Scolaro & Azevedo, 2010),(Scolaro, et al., 2011).

A Figura 83 mostra o ambiente de teste com arquivos de padrões diversos, onde são geradas estatísticas de desempenho para cada arquivo selecionado.

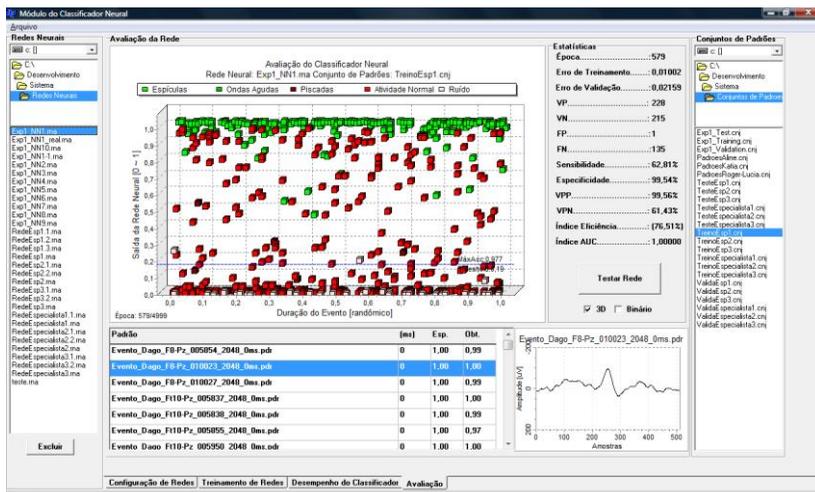


Figura 83 – Ambiente para o reconhecimento de padrões.

Fonte: (Scolaro & Azevedo, 2010),(Scolaro, et al., 2011).

4.6.2 Forma de Classificação dos Eventos Epileptiformes adotado no Sistema Desenvolvido

A classificação dos eventos epileptiformes, marcados pelo processo de localização e marcação de eventos, descrita na seção 4.5 é feita a partir do buffer de posições de 10 x 28. Cada espaço de memória do buffer fornece três coordenadas na tela de sinal. Caso exista uma época de sinal que foi marcada, como possível evento epileptiforme, a própria indexação dessa posição no buffer já fornece duas coordenadas do tipo linha x coluna, indicando o instante de tempo e o canal de ocorrência. A outra informação é a posição no canal que foi marcado o possível evento epileptiforme.

O buffer de posições contém todas as posições dos picos dos possíveis eventos epileptiformes encontrados. Para classificar os eventos marcados, inicialmente seleciona-se a rede neural que será utilizada na identificação dos padrões, juntamente com a época de treinamento correspondente ao classificador neural. Cada época de treinamento é um

classificador neural em potencial, apenas deve ser selecionada a época que mais se adéqua às necessidades do usuário que está utilizando o sistema, em relação às taxas de sensibilidade e especificidade.

Depois de selecionado o classificador, o processo se inicia percorrendo o buffer de posições, verificando o instante de tempo de cada canal, ou seja, é percorrido o primeiro instante do canal 1, o primeiro instante do canal 2, e assim por diante, até verificar o primeiro instante do canal 28. Para cada canal verificado, a posição armazenada, caso ela exista, é o centro da janela de leitura do sinal original para ser direcionada ao classificador neural para análise. As 512 amostras, centradas pela posição armazenada no buffer de posições, lhes são atribuídas um valor entre zero e um, como resposta do classificador neural. Quanto mais próximo de um, o classificador estará indicando que o padrão analisado é um evento epileptiforme. De forma geral, as 512 amostras lidas do sinal original, centradas na posição armazenada no buffer de posições é inserida nas entradas do classificador neural, o qual informará um valor correspondente de reconhecimento. Mais próximo de zero, o padrão não foi reconhecido, mais próximo de um o padrão foi reconhecido.

Para aproveitar a estrutura montada com buffers, o mesmo buffer de posições serve como meio de armazenamento dos padrões classificados. Pois, no momento que o padrão anteriormente marcado como possível evento, está informando ao sistema que há um possível evento epileptiforme em tal posição, armazenada no buffer. Cabe ao classificador apenas validar essa posição, verificando se o pico do evento que está na posição lida apresenta um valor de reconhecimento próximo de um. Em caso afirmativo, o sistema mantém o valor armazenado na posição, pois ali existe um evento epileptiforme válido e reconhecido. Caso o sistema não gere uma resposta aceitável, ou um valor de reconhecimento próximo de zero, o sistema apenas atribui o valor zero à posição que armazena o pico que foi lido e direcionado para o classificador verificar. Um processo simples e funcional. Caso o sistema reconheça o evento, o qual o pico foi armazenado em buffer, mantém essa posição, caso contrário, atribui zero, indicando que o padrão verificado não foi reconhecido.

A Figura 84 apresenta a tela de sinal, que representa o processo de reconhecimento dos eventos epileptiformes executado pelo sistema, o qual anteriormente mostrou através da Figura 76 e da Figura 79, a evolução das etapas de processamento, localização dos eventos epileptiformes, respectivamente.

A Tabela 13, visualizada anteriormente, apresenta vários instantes de tempo preenchidos, após a correção das posições de possíveis eventos epileptiformes. A Tabela 14 mostra como o buffer de posições ficou estruturado, após o reconhecimento dos eventos epileptiformes verdadeiros, mostrando que nem todas as posições anteriormente indicadas eram de eventos epileptiformes. Os eventos verdadeiros estão presentes apenas nos instantes de tempo, dois e cinco segundos.

Para que o reconhecimento dos padrões seja efetivado, ainda devem ser seguidas algumas regras de produção, estipuladas pelos neurologistas, para validar a identificação da ocorrência dos eventos epileptiformes. Podem ocorrer descargas isoladas, sem o espalhamento do campo nos canais adjacentes ao da ocorrência. Dessa forma, esse tipo de padrão é ignorado, pois só é considerada como ocorrência de eventos epileptiformes, se pelo menos, três canais sequenciais sofreram uma perturbação por uma descarga epileptiforme. Caso tenham ocorrido três descargas, que caracterizem o campo de potencial, as posições dos eventos epileptiformes continuam no buffer de posições, para serem contadas posteriormente. Caso contrário, se não há a ocorrência de pelo menos três eventos sequenciais, as posições são zeradas, caracterizando eventos isolados.

Depois de feitas as manipulações necessárias, este buffer é apagado para o processamento da próxima tela de sinal que será analisada.

Este buffer é utilizado também para mais uma tarefa, que é auxiliar na contagem dos eventos epileptiformes. O processo de contagem dos eventos epileptiformes será descrito na próxima seção.

4.7 CONTAGEM DOS EVENTOS EPILEPTIFORMES

A contagem dos eventos é realizada no momento que o sistema está fazendo o reconhecimento dos padrões, através da varredura do buffer de posições.

Conforme descrito anteriormente, a varredura desse buffer é realizada verificando todos os canais de um único instante por vez, justamente para verificar se as posições armazenadas não são descargas isoladas. Caso estas descargas tenham ocorrido sequencialmente, caracterizando o espalhamento do campo de potencial, a contagem dos canais é feita, verificando as amplitudes do buffer de amplitudes, em conjunto com o buffer de posições. Se há mais que cinco canais que

tiveram perturbações, são verificados qual deles apresentou a amplitude mais eletronegativa. Depois de identificado, foram criados acumuladores por canal, onde é somado o valor um a cada canal que apresente maior amplitude negativa, por instante de tempo. Para cada conjunto de posições remanescentes no buffer de posições, as mesmas posições são cruzadas com o buffer de amplitudes. Verifica-se qual canal obteve maior amplitude, acumula-se um a este canal, gerando um gráfico como o apresentado na Figura 85.

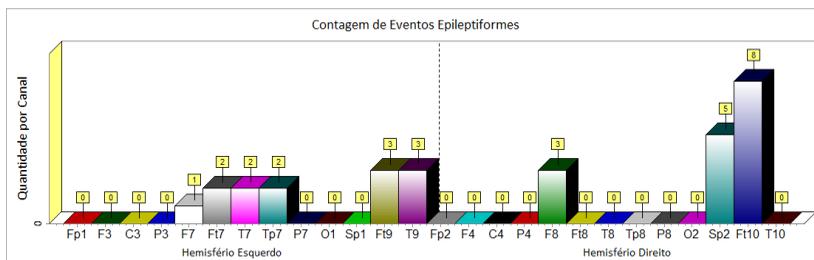


Figura 85 – Representação da contagem de eventos epileptiformes.

O processo de contagem, além de gerar o gráfico anterior, gera um arquivo no formato TXT, com uma listagem de eventos que ocorreram, indicando exatamente, o instante de tempo, a posição dentro do canal analisado, o canal e a amplitude de cada evento mais eletronegativo, como apresentado através da Figura 86.

```
-----
Nome do Arquivo Processado.....: PacH3.EEG
Página Inicial/Página Final.....: 1-361
Tamanho da janela em segundos.....: 10
Nome do arquivo de montagem utilizado: Referencial Pz - A1-2.mtg
-----
```

Instante	Posição	Canal	Amplitude Máx
00:00:01	829	Sp2	-63.209660
00:00:07	3769	Tp7	-178.987572
00:00:21	582	T7	-158.424641
00:00:24	2521	Tp7	-153.519254
00:00:33	1731	T7	-115.318833
00:00:34	2185	F8	-109.038537
00:00:38	4134	Sp2	-86.248903
00:01:10	121	F8	-83.352176
00:01:14	2541	Ft10	-142.215851
00:01:19	4845	Ft9	-231.910361
00:01:49	5020	Ft10	-71.814093
00:01:57	3807	Ft7	-277.245051
00:02:01	613	T9	-189.477982

```
-----
```

Figura 86 – Exemplo de listagem do arquivo TXT, gerado com informações detalhadas do processo de contagem de eventos epileptiformes.

Essas informações são de grande importância, pois auxiliam o neurologista a isolar a área que apresenta o maior número de descargas epileptiformes, possibilitando com que ele direcione os demais exames para a área indicada pela elevada ocorrência de eventos.

5 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados alcançados com o sistema computacional implementado, utilizado para a identificação e contagem automática de eventos epileptiformes em sinais de EEG de longo termo. Também são apresentadas as considerações sobre as etapas realizadas no desenvolvimento deste trabalho. Considerações em relação às dificuldades encontradas e as soluções desenvolvidas para a finalização da metodologia proposta inicialmente.

5.1 AVALIAÇÃO DO CLASSIFICADOR NEURAL TREINADO E ADOTADO PARA O SISTEMA

Para avaliar o sistema de identificação e contagem de eventos epileptiformes foram treinadas diversas redes neurais e com diversas configurações possíveis. Dentre elas, foi escolhida a rede que apresentou os melhores resultados nos testes executados, a qual alcançou índices de sensibilidade de 97,45%, especificidade de 97,28%, índice AUC de 0,99995 e índice de eficiência de 97,40%.

Para as configurações da rede neural, os parâmetros da estrutura da rede foram configurados da seguinte maneira: 512 neurônios na camada de entrada, 10 neurônios na camada oculta e 1 neurônio na camada de saída. A função de ativação utilizada para a primeira camada da rede foi a tangente hiperbólica, para fazer o ajuste dos valores positivos e negativos que os padrões de EEG apresentam. Para a segunda camada da rede foi utilizada a função de ativação logística, pois a ideia era fazer um classificador binário, o qual informaria apenas se encontrou um evento ou não encontrou um evento, sinalizando com valores zero e um.

Outros parâmetros de configuração da rede foram escolhidos depois de vários experimentos realizados. A taxa de momentum foi configurada em 0,70. A taxa de aprendizado foi fixada em 0,001. Como critérios de parada foram estipulados para a taxa de erro mínimo de treinamento o valor de 0,001 e para o número máximo de épocas de treinamento o valor 5.000.

Para o treinamento das redes neurais foi feita uma base de padrões, contendo em torno de 4.100 padrões distintos. Em todo o processo de treinamento, validação e testes do classificador escolhido

foram utilizados três conjuntos de padrões. Para o conjunto de treinamento foram selecionados 426 eventos epileptiformes, 60 sinais de piscadas, 60 sinais de atividade normal e 70 sinais de ruído. Para o conjunto de validação foram selecionados 428 eventos epileptiformes, 62 sinais de piscadas, 60 sinais de atividade normal de EEG e 78 sinais de ruídos. Para o conjunto de testes foram selecionados 426 eventos epileptiformes, 60 sinais de piscadas, 60 sinais de atividade normal de fundo e 70 sinais de ruído.

Os eventos de entrada da rede neural foram os sinais de EEG no tempo. Cada amostra do sinal é atribuída a uma entrada da rede. Como as épocas de sinal apresentam 512 amostras, a camada de entrada da rede neural foi configurada com 512 neurônios.

O procedimento de treinamento supervisionado da rede neural é feito utilizando o algoritmo de retropropagação do erro (*backpropagation*), em sua forma original. A avaliação do treinamento da rede neural foi feita através do processo de validação cruzada com parada antecipada. Basicamente, o funcionamento deste algoritmo se dá, da seguinte forma. Ao término da apresentação de uma época de treinamento, o processo de treinamento é interrompido e o conjunto de padrões de validação é apresentado à rede, aproveitando toda a configuração momentânea de pesos sinápticos e bias desse ciclo de treinamento em específico. Ao término da apresentação do conjunto de validação os procedimentos de validação cruzada, análise ROC e análise dos índices estatísticos são executados. O erro de validação é calculado e acrescentado na curva de validação e alguns indicadores estatísticos são sumarizados e armazenados para gerar posteriormente as curvas e índices de desempenho. Todo esse procedimento é repetido para cada ciclo de treinamento, até o final do treinamento da rede neural seja finalizado ou um dos critérios de parada sejam alcançados.

A Figura 87 apresenta as curvas de treinamento do classificador escolhido para a classificação de eventos epileptiformes, utilizado no sistema implementado. A rede foi treinada com 5.000 épocas. A parada antecipada foi indicada na época de treinamento 415, se obtendo um erro médio quadrático de 0,03359. Pode ser visualizado que as curvas de treinamento e de validação decrescem até a época 415. Entretanto, após a época 415, a curva de validação começa a crescer novamente, indicando que a rede neural não está mais generalizando, e sim especificando (decorando) os padrões de treinamento. Ou seja, este é o momento ideal para encerrar o treinamento da rede. O treinamento prosseguiu até as 5.000 épocas por questões de estatística, as quais foram realizadas posteriormente.

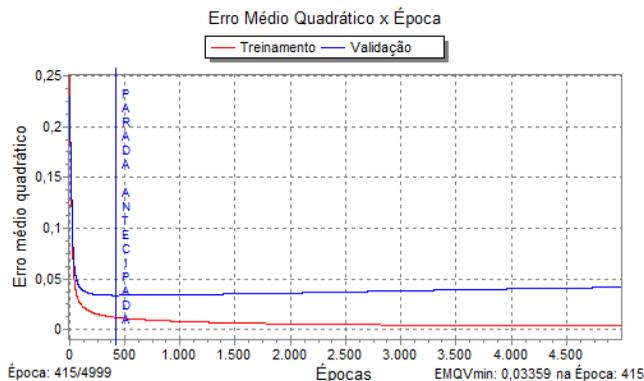


Figura 87 – Demonstração das curvas de treinamento e de validação do classificador neural implementado, mostrando que a parada antecipada ocorreu na época de treinamento 415, atingindo um erro mínimo de validação de 0,03359.

A ferramenta de treinamento desenvolvida possui dois índices que avaliam a qualidade de todas as épocas de treinamento, indicando a melhor época, através dos resultados obtidos pelo índice AUC e pelos resultados alcançados através do índice de eficiência.

Neste trabalho foi adotado o índice de eficiência para fazer a avaliação dos classificadores neurais, utilizados no sistema de classificação automática. Este índice basicamente indica o nível de acertos globais que o classificador atinge e indica um *threshold* para executar regras de produção, dentro do sistema de classificação, devendo ser implementado via código de programação.

Os valores obtidos pelo índice AUC também serão mostrados, para fins de comparação.

Os melhores resultados para a rede neural treinada foram obtidos na época de treinamento de número 976, indicada pelo índice de eficiência. Também é mostrada a curva ROC para esta época de treinamento, a qual alcançou um índice bem próximo de um.

A Tabela 15 apresenta uma comparação entre as três épocas de treinamento avaliadas, a época de treinamento indicada pela parada antecipada, a época de treinamento indicada pelo índice AUC e a época de treinamento indicada pelo índice de eficiência.

A época 114 foi indicada pelo maior índice AUC obtido na avaliação do classificador. No entanto, esta época obteve o menor índice de eficiência para este classificador, como pode ser observado pela alta

dispersão dos padrões, através do processo de classificação. A época 415 indicada pela parada antecipada obteve o índice mediano de eficiência. Já a época 976 obteve o melhor índice de eficiência, vindo a ser adotada como o classificador utilizado no sistema de identificação e classificação automática de eventos epileptiformes.

Tabela 15 – Índices obtidos com a avaliação do classificador neural.

Época	Sensibilidade	Especificidade	VPP	VPN	AUC	Eficiência
114	98,80%	92,04%	96,24%	97,37%	1,00000	96,59%
415	99,04%	92,54%	96,48%	97,89%	0,99998	96,92%
976	97,45%	97,28%	98,83%	94,21%	0,99995	97,40%

A Figura 88 apresenta o resultado da classificação do conjunto de padrões de teste, gerado para os experimentos com as redes neurais, utilizando a época de treinamento 114 como classificador. Pode ser observado que há grande dispersão entre os padrões classificados, não havendo um acúmulo uniforme nas extremidades do gráfico.

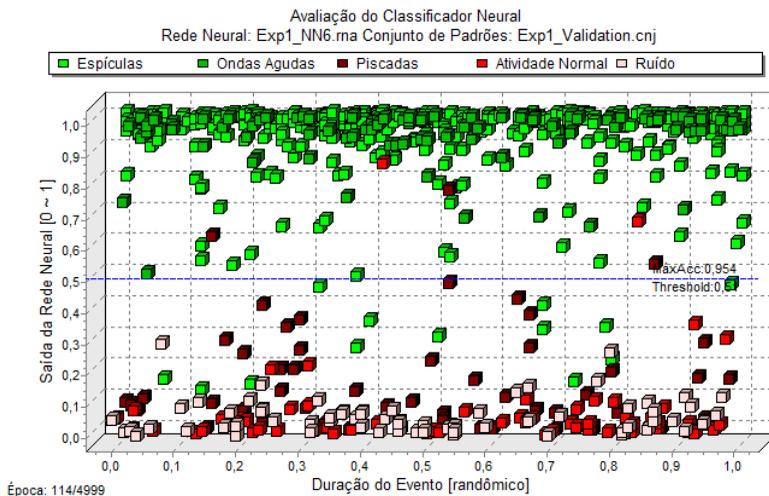


Figura 88 – Classificação dos padrões do conjunto de testes com a época 114.

A Figura 89 apresenta a classificação utilizando a época de treinamento 415 como classificador neural, indicada pela parada antecipada. Pode ser observado que houve uma melhora no agrupamento dos padrões nas extremidades do gráfico, indicando que a eficiência deste classificador é melhor que o anterior, utilizando a época 114.

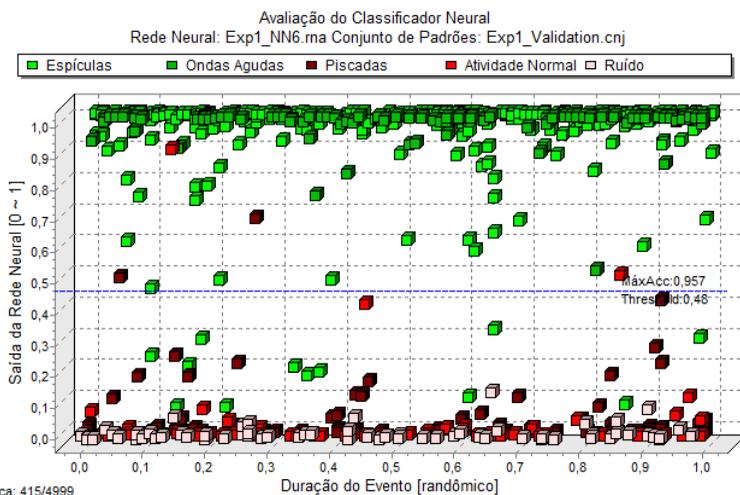


Figura 89 – Classificação dos padrões do conjunto de testes com a época 415.

A Figura 90 apresenta a classificação dos padrões utilizando a época de treinamento 976, a qual foi adotada para o classificador.

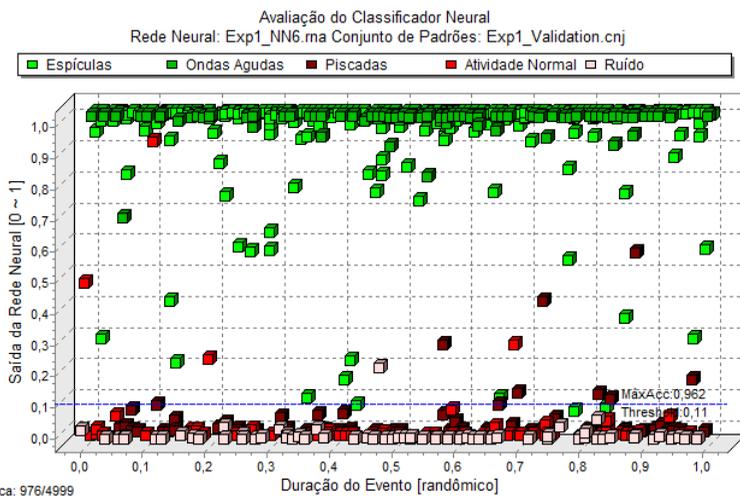


Figura 90 – Classificação dos padrões do conjunto de testes com a época 976.

Pode ser observado que, além dos padrões estarem mais bem agrupados nas extremidades do gráfico, o *threshold* para as regras de

produção está mais baixo, em relação aos demais classificadores apresentados anteriormente. Isso mostra que o índice de eficiência indicou um valor mais baixo para começar a detectar eventos, mostrando a alta taxa de acertos globais que ele tem.

A Figura 91 apresenta as curvas dos índices estatísticos de eficiência e da curva ROC, os quais foram utilizados para avaliar o classificador neural utilizado no sistema de classificação.

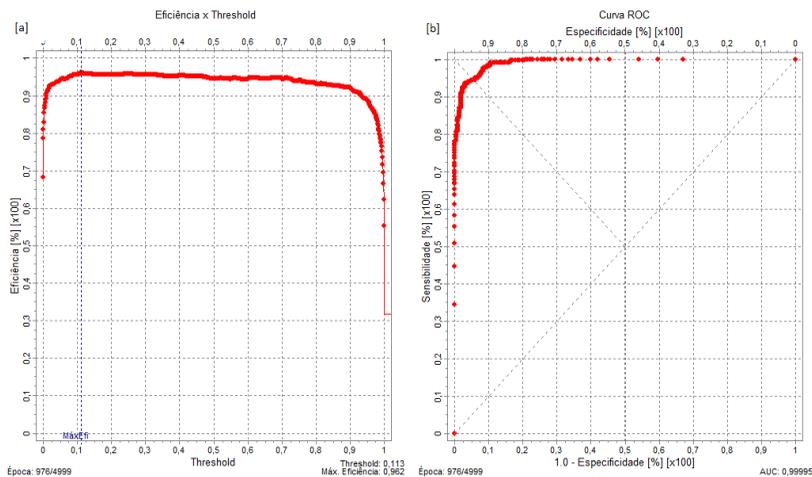


Figura 91 – Curvas que representam o índice de eficiência [a] e o índice AUC [b].

Os gráficos do índice de eficiência sempre mostrará um valor máximo, entre todos os analisados. A amostra com o maior valor de amplitude indicará o *threshold* que deve ser aplicado dentro do sistema, sendo o critério de corte entre os padrões classificados. Acima do *threshold*, o padrão é considerado reconhecido, abaixo é considerado não reconhecido.

O classificador depois de avaliado, foi codificado dentro do sistema e utilizado em todo o processo de classificação dos eventos epileptiformes. A avaliação do sistema utilizando o classificador neural implementado é apresentado na próxima seção.

5.2 AVALIAÇÃO DO SISTEMA DESENVOLVIDO

O sistema de identificação e contagem automática de eventos epileptiformes foi avaliado, escolhendo o classificador neural que apresentou melhores índices de desempenho, o qual foi identificado pela época de treinamento de número 976.

O procedimento adotado para avaliar todo o sistema, foi escolher aleatoriamente segmentos de sinal, com duração de dez minutos ou sessenta telas de dez segundos de sinal. Foi verificada a capacidade da metodologia desenvolvida em localizar e marcar os eventos epileptiformes e de classificá-los de forma coerente, contabilizando o número de falsos positivos por minuto que o classificador venha a marcar. Foram utilizados dez segmentos de sinal, com duração de dez minutos, totalizando uma hora e quarenta minutos de análise ou seiscentas telas de dez segundos de sinal. Os valores obtidos com a análise dos registros foram agrupados na Tabela 16. Através desta tabela pode ser observado o número de falsos positivos marcados pelo sistema, obtendo se uma média de 0,064 falsos positivos por minuto.

Tabela 16 – Testes realizados com o classificador implementado.

Paciente	Início	Fim	Duração	Telas	VP	VN	FP	FN
PacH3	00:00:40	00:10:40	00:10:00	60	87	0	29	0
PacI1	00:00:00	00:10:00	00:10:00	60	0	0	5	0
PacI1	00:25:00	00:35:00	00:10:00	60	3	0	6	0
PacJ1	00:44:50	00:54:50	00:10:00	60	3	0	0	0
PacK1	00:15:10	00:25:10	00:10:00	60	3	0	1	0
PacK1	00:27:40	00:37:40	00:10:00	60	6	1	0	0
PacK1	00:39:00	00:49:00	00:10:00	60	5	2	0	0
PacK1	00:52:30	01:02:30	00:10:00	60	7	1	3	0
PacL1	00:00:19	00:10:19	00:10:00	60	19	0	16	0
PacM1	00:06:20	00:16:20	00:10:00	60	0	0	4	0
Total	-	-	01:40:00	600	133	4	64	0
Taxa de Falsos Positivos por Minuto							0,064 FP/min	

Para a validação da metodologia e do sistema como um todo, foram utilizadas telas de dez segundo de sinal, contendo as mais variadas situações, em relação a ruídos, oscilações de baixa frequência, ou mesmo telas de sinal sem nenhuma perturbação. A Figura 92, apresenta um tela de sinal contendo eventos epileptiformes localizados ao centro da tela. Também pode ser observado um ruído, contendo picos

de alta frequência, junto com oscilações de baixa frequência, o que em teoria, poderia prejudicar a busca dos eventos epileptiformes, através da verificação dos seus respectivos picos máximos. No entanto, a metodologia desenvolvida consegue isolar essas perturbações ocorridas no canal Sp2-Pz e detectar os eventos epileptiformes, classificando-os de forma correta. Caso sejam identificados, cinco ou mais canais, contendo eventos epileptiformes, o sistema irá automaticamente acumular os eventos encontrados, nos canais que apresentaram a maior amplitude negativa. Esse processo se repete para as demais telas de dez segundo do sinal, até o final do registro.

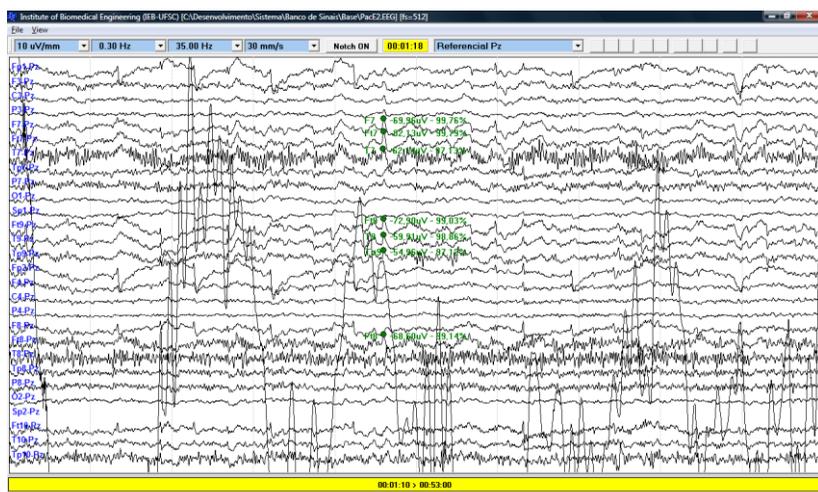


Figura 92 – Exemplo de detecção e classificação de eventos epileptiformes em telas de EEG, contendo elevados níveis de ruído.

A Figura 93 apresenta outra tela de sinal, contendo grandes níveis de ruído. Diferente da tela anterior, esta não apresenta eventos epileptiformes. O sistema tem a capacidade de isolar determinadas condições, em relação a ruídos e outras variações que as telas de sinal podem apresentar. Quando uma tela com essas características é analisada o sistema pode até identificar possíveis espículas isoladas, que caracterizam ruídos de alta frequência. No entanto, estes eventos não são acumulados, pois não há a ocorrência de cinco eventos semelhantes, para serem contabilizados e acumulados nos canais. Dessa forma, o sistema indica que foi feita uma detecção, devido a um falso positivo encontrado com características semelhantes às das espículas, vindo a

serem descartados posteriormente pela não ocorrência do campo de potencial nos canais adjacentes.

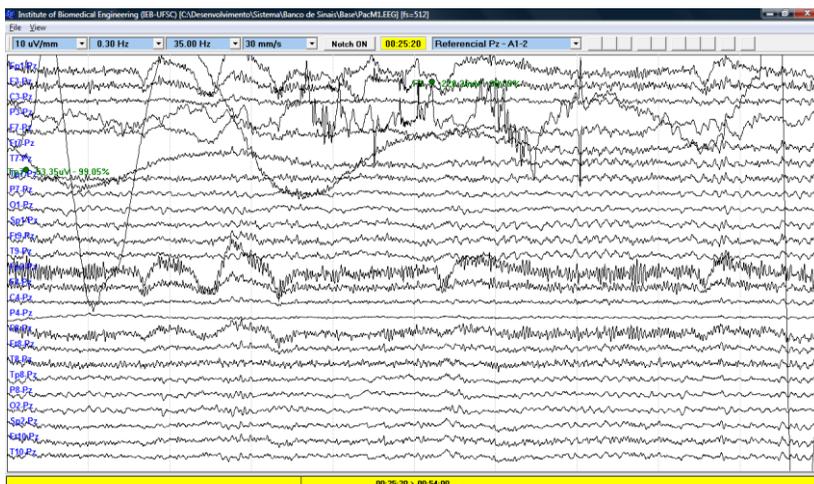


Figura 93 – Exemplo de detecção e classificação de uma tela de sinal sem a ocorrência de eventos epileptiformes.

A Figura 94 apresenta outro exemplo de tela, contendo grandes variações na linha de base e picos de alta frequência.

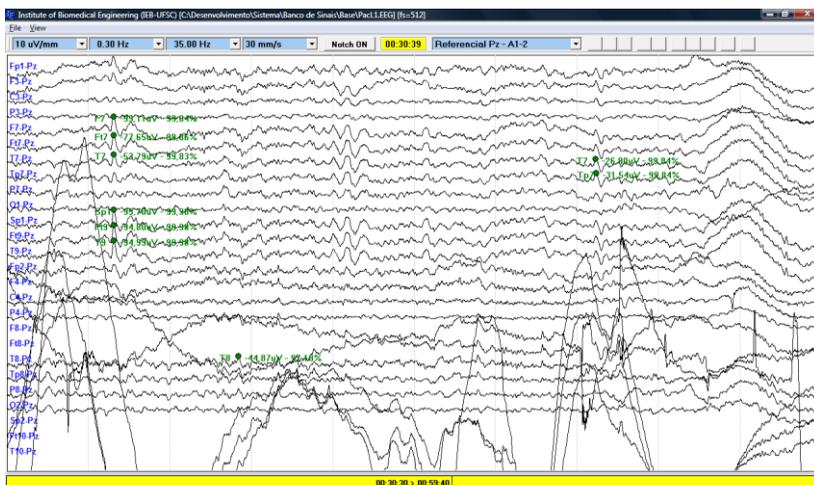


Figura 94 – Outro exemplo de detecção e classificação de eventos epileptiformes em telas de EEG contendo elevados níveis de ruído.

O sistema desenvolvido foi capaz de reconhecer apenas os eventos epileptiformes localizados no canto esquerdo da tela. Os eventos que foram marcados e reconhecidos no canto direito da tela foram ignorados, pelo fato de não haver cinco eventos que caracterizem o espalhamento do campo de potencial. Dessa forma, os dois eventos marcados como eventos epileptiformes, não são acumulados nos canais, para posterior visualização, mesmo sendo eventos reais.

A Figura 95 mostra uma condição mais equilibrada de detecção e classificação de eventos, onde é apresentada uma tela contendo poucas oscilações e ruídos, que venham a interferir no funcionamento do sistema de detecção. Pode ser observado que nesta tela há quatro tipos de eventos epileptiformes que foram detectados, e conseqüentemente, acumulado em seus respectivos canais com amplitudes mais eletronegativas. Esta é uma condição perfeita esperada nos registros de EEG. No entanto, não é isso o que acontece na prática, pois há uma grande variedade de telas, com diversas formas de interferência que prejudicam os sistemas computacionais, na tarefa de detecção de eventos, como as telas anteriores apresentaram.

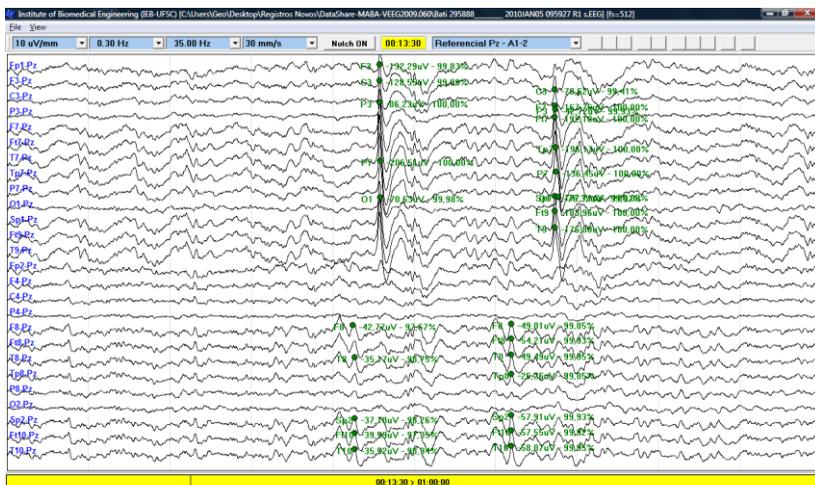


Figura 95 – Exemplo de detecção de eventos, sem muitas interferências causadas por ruídos e outras oscilações. Neste exemplo foram detectados e marcados quatro eventos epileptiformes, que tiveram espalhamento do campo de potencial.

Um dos segmentos de sinal utilizados para fazer a avaliação do sistema desenvolvido, foi extraído do arquivo do paciente PacJ1,

iniciando no instante de tempo 00:44:50 e terminando em 00:54:50, totalizando dez minutos de sinal ou sessenta telas de dez segundos de sinal que foram processadas. Na análise realizada foram encontrados três eventos epileptiformes, que coincidiram com as marcações feitas pelos neurologistas.

A Figura 96 apresenta o primeiro evento localizado, dos três existentes no segmento de sinal analisado do paciente PacJ1.



Figura 96 – Exemplo de detecção de eventos utilizado na avaliação de um segmento de sinal do paciente PacJ1.

A Figura 97 apresenta o gráfico gerado através das três marcações, feitas pela detecção dos eventos epileptiformes, do segmento de sinal analisado do paciente PacJ1. Pode ser visualizado que nos dez minutos de sinal analisado, houve maior ocorrência de descargas epileptiformes no hemisfério direito e no canal F8.

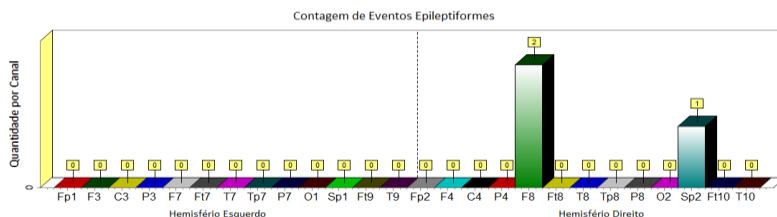


Figura 97 – Gráfico de barras mostrando o total de ocorrências encontradas através da análise do segmento de sinal de dez minutos do paciente PacJ1.

Complementando a análise deste segmento de sinal, a Figura 98 apresenta uma listagem dos eventos localizados, a sua respectiva posição dentro do canal de EEG e a máxima amplitude negativa que o evento apresenta.

```

Nome do Arquivo Processado: PacJ1.EEG
Página Inicial/Página Final: 270-369
Tamanho da janela em segundos: 10
Nome do arquivo de montagem utilizado: Referencial Pz - A1-2.mtg

```

Instante	Posição	Canal	Amplitude Máx
00:49:51	751	F8	-122.008733
00:50:56	3129	F8	-117.355150
00:52:56	3105	Sp2	-108.389490

Figura 98 – Informações complementares dos eventos epileptiformes localizados, através da análise do segmento de sinal de dez minutos, do paciente PacJ1.

O sistema desenvolvido necessita de ajustes para que funcione de forma eficaz. Ajustes no sentido de melhorar a interface, relatórios, entre outras pequenas melhorias. Entretanto, o sistema mostrou-se capaz de detectar eventos epileptiformes, realizar a contagem destes eventos, apresentando uma baixa taxa de falsos positivos.

5.3 CONSIDERAÇÕES SOBRE TRABALHO

O processo de revisão dos sinais de EEG, realizado pelos neurologistas do CEPESC, seguem alguns protocolos, em relação aos sinais utilizados, montagens configuradas, tamanho (em segundos) das telas de revisão, morfologia do sinal, taxa de amostragem, se o sinal foi coletado antes ou depois de determinado medicamento, entre outras condições. Todas essas características foram levadas em consideração, no momento do desenvolvimento deste trabalho. Quando finalizada a metodologia acaba se tornando única, em relação às existentes, pois apresenta muitas particularidades desenvolvidas para a resolução de um problema específico, que neste caso, é a revisão dos registros de EEG de longa duração do período interictal, de candidatos ao tratamento cirúrgicos da epilepsia avaliados pelo CEPESC.

Dessa forma, a metodologia desenvolvida acabou sendo direcionada para as necessidades existentes no CEPESC, isso por si só,

já dificulta o processo de avaliação e comparação com outras metodologias, uma vez que, não é comum se encontrar na literatura trabalhos finalizados que geraram um produto (software), como esta metodologia o fez.

Para efeitos de comparação, este trabalho utilizou metodologias para a detecção de eventos epileptiformes desenvolvidas em pesquisas anteriores realizadas no IEB/UFSC, pelo fato de seguirem a mesma linha de pesquisa, a qual este trabalho foi iniciado.

A parceria realizada entre o IEB/UFSC e o CEPESC resultou num sistema computacional automatizado capaz de fazer a detecção e a contagem de eventos epileptiformes em registros de EEG de longa duração.

Devido à grande demanda de pacientes que o CEPESC atende e pelo grande volume de informações que são gerados semanalmente, através da monitoração contínua dos pacientes internados, houve a necessidade de criar uma ferramenta que auxiliasse os especialistas deste centro no processo de revisão dos registros de EEG de longa duração.

O sistema desenvolvido processa os sinais de EEG do período interictal (período entre crises epiléticas), os quais são analisados e os possíveis eventos epileptiformes são identificados e contados automaticamente pelo sistema, gerando dados úteis aos neurologistas, sobre as condições de um paciente, num determinado período de tempo.

Para a análise do EEG do período ictal a abordagem deve ser diferente, pois a atividade epileptogênica gerada no momento da crise epilética apresenta características diferentes e bem definidas, em relação aos padrões utilizados no desenvolvimento desse trabalho. Portanto, esta metodologia não é indicada para a detecção de crises epiléticas, e sim, detecção de eventos epileptiformes.

Todo o suporte para o entendimento do processo envolvido na análise dos registros de EEG foi prestado pelos profissionais do CEPESC, bem como, o fornecimento dos registros de EEG para o desenvolvimento das ferramentas e dos métodos necessários para a implementação e finalização deste trabalho.

5.3.1 Sobre os Registros de EEG Fornecidos pelo CEPESC

Os registros de EEG utilizados em todas as etapas do desenvolvimento desse trabalho foram gerados por dispositivos existentes no CEPESC do modelo *CEEGraph Vision* da *Biologic*.

Os registros de EEG fornecidos apresentam as seguintes características: taxa de amostragem de 512 Hz, resolução de 16 bits, 32 canais de monitoração e todos os registros foram coletados utilizando uma montagem referencial comum do equipamento. Os neurologistas do CEPESC utilizam uma montagem referencial, tendo como referencia o eletrodo Pz. Tais características apresentadas pelos registros de EEG não foram encontradas na literatura, o que comprometeu a comparação direta com outras metodologias. Muitos dos trabalhos encontrados sobre detecção de eventos epileptiformes apresentaram taxas de amostragem, para a aquisição dos sinais de EEG, entre 100 Hz e 256 Hz, as mais comuns. Outra situação observada é em relação à montagem utilizada para a análise dos sinais. Não foram encontrados trabalhos que utilizassem a montagem referencial, tendo o eletrodo em PZ como referencia. Dos trabalhos encontrados grande parte apresentaram montagens bipolares longitudinais (dupla banana), o que também acaba comprometendo a comparação entre as metodologias, e consequentemente, com os resultados obtidos.

Quanto aos registros de EEG fornecidos, ocorreram alguns contratemplos em relação às marcações dos eventos epileptiformes dentro dos registros de EEG, que seriam utilizados como padrões de referencia para o treinamento dos classificadores neurais. No início das pesquisas, três especialistas estavam realizando as marcações dos eventos epileptiformes necessários para o trabalho. Foi estipulado um protocolo a ser seguido, em relação às características dos eventos epileptiformes que seriam marcados. Quanto à morfologia, os eventos deveriam ser bem destacados, em relação à atividade de fundo do EEG, como mostra a Figura 99.

No entanto, apenas um dos especialistas pôde finalizar as marcações necessárias (identificado como especialista 3). Outros especialistas foram contatados para dar suporte às novas marcações dos eventos epileptiformes. Dessa forma, os últimos registros fornecidos e utilizados para validar a metodologia acabaram sendo marcados com padrões epileptiformes ligeiramente diferentes daqueles recomendados pelo protocolo estipulado.

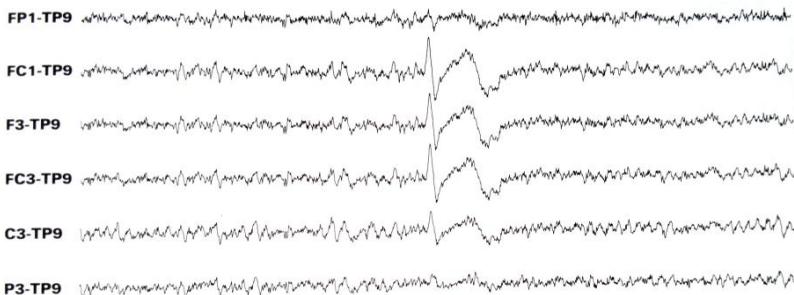


Figura 99 – Segmento de sinal contendo eventos epileptiformes ao centro da tela bem definidos e com morfologia característica.

Fonte: (Lüders & Noachtar, 2000).

Apesar de tudo, foi possível concluir com êxito a metodologia proposta inicialmente e finalizar o sistema computacional para a detecção e contagem de eventos epileptiformes.

5.3.2 Sobre as Ferramentas Computacionais Desenvolvidas

No decorrer do período do doutorado, para auxiliar os diversos experimentos realizados e que contribuíram com o desenvolvimento da metodologia proposta, foram desenvolvidas cinco ferramentas computacionais. Todas foram desenvolvidas utilizando a linguagem de programação C++ e codificadas utilizando o ambiente de desenvolvimento C++ Builder.

Cinco ferramentas computacionais foram criadas. A primeira ferramenta foi utilizada para o treinamento e validação de redes neurais. A segunda ferramenta faz o processamento dos sinais dos registros de EEG. A terceira ferramenta realiza a extração de eventos epileptiformes dos registros de EEG, separando os em arquivos distintos. A quarta ferramenta foi desenvolvida para gerar conjuntos de padrões de treinamento e validação das redes neurais. A quinta e última ferramenta desenvolvida abre os registros de EEG de longa duração para a visualização e processamento dos sinais utilizando filtros digitais.

Essas ferramentas foram projetadas para serem genéricas, ou seja, para serem utilizadas em outras aplicações e não apenas para a detecção de eventos epileptiformes. Dessas cinco ferramentas, duas em particular são consideradas as mais importantes, pois através delas foi possível

desenvolver o sistema de identificação e contagem de eventos epileptiformes.

A ferramenta desenvolvida para o treinamento e avaliação de classificadores neurais foi projetada para ser genérica. Sendo assim, ela pode ser utilizada para o treinamento de outros tipos de padrões, apenas adequando as entradas da rede, com os padrões a serem treinados. Esta ferramenta foi de fundamental importância no desenvolvimento da metodologia, pois através dela foi possível verificar a melhor forma de se avaliar um classificador neural (Scolaro & Azevedo, 2010), (Scolaro, et al., 2011), sendo uma importante **contribuição deste trabalho**.

A ferramenta de processamento de sinais desenvolvida possibilitou ter uma visão mais abrangente, de como manipular um sinal através da transformada wavelet, outra grande **contribuição deste trabalho**. Dessa forma foi possível propor a utilização dessa transformada como um filtro digital específico para a atenuação da atividade de fundo do EEG (Scolaro, et al., 2013a), que em muitas vezes tem grande influência nas altas taxas de falso-positivos que os sistemas automatizados apresentam.

5.3.3 Sobre a Metodologia Desenvolvida

Toda a metodologia baseia-se na busca das máximas amplitudes negativas dos picos dos eventos epileptiformes. Esta tarefa parece ser muito simples, entretanto, identificar um evento epileptiforme em meio aos traçados de EEG, contendo os tipos mais variados de sinal e ruído, acaba se tornando uma tarefa não tão simples assim.

O sistema desenvolvido utiliza registros de EEG de longo termo. Esse tipo de registro é gerado a partir do monitoramento contínuo de pacientes, candidatos ao tratamento cirúrgico da epilepsia que é realizado pelo CEPESC.

Os registros de EEG apresentam características voltadas para esse tipo de tratamento. A colocação dos eletrodos para a aquisição dos sinais segue o padrão internacional 10-20, no entanto, a montagem para a aquisição dos sinais de EEG foi configurada pelos neurologistas do CEPESC utilizando o eletrodo Pz como referencia comum para os demais eletrodos. Essa configuração facilita a visualização da propagação do campo de potencial elétrico, no momento que o evento epileptiforme ocorre. O evento com maior amplitude negativa pode indicar a localização da zona epileptogênica (Lüders & Noachtar, 2000).

Além da máxima amplitude negativa, a faixa de frequências que os eventos epileptiformes apresentam, serviu como parâmetro para a implementação de ferramentas capazes de auxiliar a busca por esses eventos. Foi explorada uma faixa de frequências entre 5 e 25 Hz, a qual corresponde à duração que um evento epileptiforme pode apresentar variando entre 40 e 200ms (Lüders & Noachtar, 2000). A Figura 100 apresenta uma tela de dez segundos de sinal contendo três ocorrências de eventos epileptiformes.

Para facilitar a busca dos eventos epileptiformes nos registros de EEG foi desenvolvido um filtro específico para atenuar componentes de frequência abaixo de 5 Hz e acima de 25 Hz, caracterizando um filtro passa-banda, feito com a transformada wavelet(Scolaro, et al., 2013a),(Scolaro, et al., 2013b). Essa transformada decompõe um sinal no domínio tempo-frequência, gerando sinais que são decompostos em um determinado número de níveis, e reconstruídos em aproximações e detalhes.

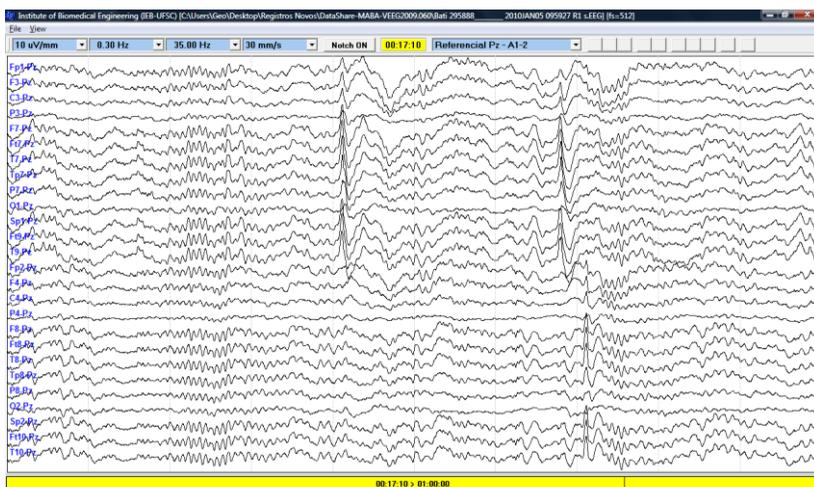


Figura 100 – Tela de sinal contendo três ocorrências de eventos epileptiformes, dois no hemisfério esquerdo e um no hemisfério direito.

A forma mais comum de utilização da transformada wavelet é através da escolha entre níveis de aproximação ou níveis de detalhe para a decomposição do sinal em estudo. Cada um dos níveis de aproximação ou de detalhe contém bandas de frequências específicas, decompostas do sinal original. Dependendo da aplicação, utilizam-se as aproximações ou os detalhes para o pré-processamento dos sinais de EEG.

A Figura 100 apresenta uma tela de dez segundos de sinal, com 28 canais, contendo três ocorrências de eventos epileptiformes. A Figura 101 mostra como seria esta mesma tela de sinal, se ela fosse decomposta pela transformada wavelet, utilizando apenas o nível de detalhe 5, por exemplo, o qual abrange frequências entre 8 e 16 Hz. A tela de sinal processada não está nada parecida com o sinal original, pois a característica da transformada wavelet é decompor os sinais, conforme uma base wavelet ou uma função wavelet específica (Addison, 2002). Conseqüentemente, a morfologia do sinal decomposto tende a se parecer com a função wavelet escolhida, que neste caso é a Db4 (Daubechies 4).

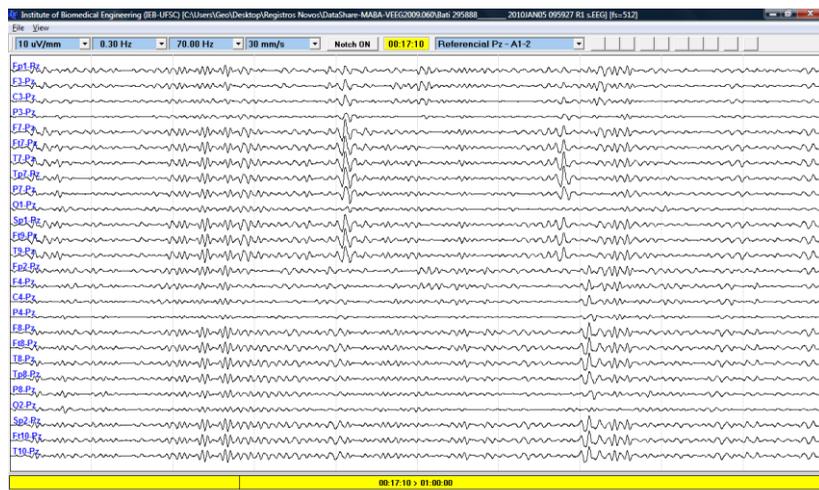


Figura 101 – Exemplo de pré-processamento utilizando o nível de detalhe 5 da transformada wavelet para a detecção dos eventos da Figura 100.

Pode ser observado ainda através da Figura 101 que os sinais decompostos apresentam uma baixa amplitude, e a morfologia nem se parece com o sinal original.

A Figura 102 mostra como seria o sinal decomposto apenas pelo nível de detalhe 6, o qual abrange apenas as frequências entre 4 e 8 Hz da tela dos sinais exibidos na Figura 100. Observando a Figura 102 o sinal ainda se parece com a função wavelet escolhida. A única diferença visível é o aumento da amplitude na posição que se encontra o primeiro evento epileptiforme exibido pela Figura 100.

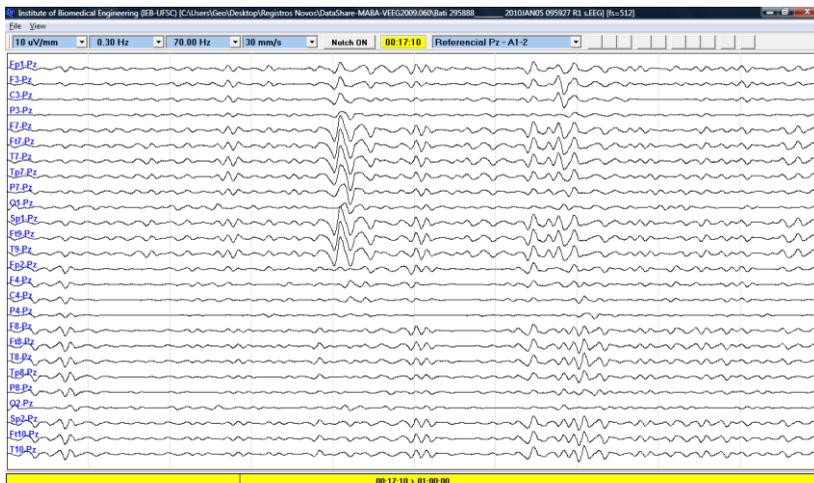


Figura 102 – Exemplo de pré-processamento utilizando o nível de detalhe 6 da transformada wavelet para a detecção dos eventos da Figura 100.

Trabalhando com níveis individuais de aproximação e de detalhes, acaba dificultando o desenvolvimento de algoritmos para a detecção dos eventos epileptiformes, pois o trabalho para a manipulação dos níveis decompostos em aproximações e detalhes acaba se tornando mais complexo, pelo processamento computacional envolvido. Em determinados casos, pode inviabilizar toda a metodologia, pois os especialistas necessitam de ferramentas que os auxiliem na redução do tempo da revisão do EEG. Se uma determinada metodologia leva o mesmo tempo ou um tempo mais elevado para a revisão destes registros é óbvio que um sistema como esse jamais será utilizado na prática, ainda mais se a metodologia tiver uma alta taxa de falsos positivos, que gere dúvidas ao neurologista, forçando-o a verificar o que realmente foi marcado.

Trabalhos observados na literatura utilizam níveis individuais de aproximação ou de detalhes para o pré-processamento dos sinais de EEG. Os trabalhos desenvolvidos por Argoud (2001) e Pereira (2003), utilizados os níveis de detalhe dois e três da função Coiflet 1, para detectar a ocorrência de eventos epileptiformes, verificando se os sinais resultantes desse processo ultrapassam um *threshold* estipulado. Outros trabalhos desenvolvidos no IEB/UFSC utilizam esta mesma forma de utilização da transformada wavelet. No entanto, são aplicados no processamento de sinais de eletrocardiograma, auxiliando na busca de complexos QRS.

Neste trabalho, o filtro desenvolvido utiliza combinações de níveis de aproximação, somando ou subtraindo componentes de frequência dos sinais reconstruídos, caracterizando uma forma diferente e eficaz de eliminar componentes de frequência desnecessárias, através da transformada wavelet. O filtro desenvolvido preserva uma faixa de frequências entre 4 e 32 Hz, ou seja, as baixas frequências que ocasionam deslocamento de linha de base do sinal (componente DC) e as altas frequências acima de 32 Hz, incluindo o ruído de 60 Hz da rede elétrica são atenuadas. Como resultado, tem-se um sinal com oscilações de baixa frequência reduzidas e picos de eventos epileptiformes em evidência, facilitando muito o trabalho de busca e identificação destes eventos. Depois de encontrados, os eventos são submetidos aos classificadores neurais, os quais verificam se os segmentos de sinais apresentados em suas entradas são mesmo eventos epileptiformes ou outro evento qualquer, com frequências entre 4 e 32 Hz. A Figura 103 apresenta o processamento da tela de sinal, exibida na Figura 100, pelo filtro desenvolvido neste trabalho.



Figura 103 – Exemplo de pré-processamento utilizando o filtro wavelet desenvolvido para a detecção dos eventos epileptiformes da Figura 100.

O filtro desenvolvido apenas tira frequências indesejadas e preserva uma faixa de frequências específica (entre 5 e 25 Hz), abrangendo apenas as componentes de frequência que caracterizam os eventos epileptiformes, através da manipulação dos sinais reconstruídos da decomposição wavelet.

A busca dos possíveis eventos epileptiformes em cada canal de EEG é feita através da análise das amplitudes mais eletronegativas, presentes em cada instante de tempo. Em relação a esse procedimento, caso existam dois eventos epileptiformes no mesmo instante de tempo, apenas o mais eletronegativo será detectado, pois o instante de tempo é visto pelo sistema como um único segmento de sinal, contendo 512 amostras. Esse procedimento foi adotado para que o sistema possa ser utilizado futuramente, como uma funcionalidade agregada à aquisição dos sinais de EEG, sendo uma alternativa para o processo de revisão desses registros em tempo real.

O sistema implementado possibilita que o instante de tempo a ser analisado possa ser dividido ainda em duas partes de 256 amostras ou em quatro partes de 128 amostras. Essa flexibilidade possibilita a análise de quatro segmentos de sinal no mesmo instante de tempo. Dessa forma, caso ocorram mais eventos epileptiformes no mesmo instante de tempo, ou ocorram espículas repetitivas (padrões encontrados no período ictal do EEG), também possam ser detectadas, adequando a metodologia desenvolvida neste trabalho para outro fim, que seria a da detecção de crises epilépticas. No entanto, aumentando a divisão das partes dentro de um instante de tempo, o tempo de processamento destes novos segmentos de sinais também aumentará.

Finalmente, o classificador neural desenvolvido neste trabalho consiste de uma rede neural artificial do tipo multicamadas (MLP), estrutura *feedforward* e utiliza o algoritmo *Backpropagation*. A rede é composta por três camadas, uma camada de entrada com 512 neurônios, uma camada intermediária com 10 neurônios e uma camada de saída contendo apenas um neurônio.

A estrutura do classificador adotado para este trabalho é composta por apenas uma rede neural, aplicada ao processo de classificação dos eventos epileptiformes. A rede treinada foi capaz de realizar a separação entre quatro classes distintas de padrões encontrados em sinais de EEG, conforme os resultados obtidos por (Scolaro, 2009).

O treinamento da rede neural foi avaliado através do método de validação cruzada, com a parada antecipada. Este método de avaliação utiliza um segundo conjunto de padrões, diferentes dos aplicados no treinamento da rede. Tal forma de avaliação indicou o melhor ponto de generalização do treinamento, através do cálculo do menor erro médio quadrático de validação, evitando que a rede especializasse os padrões de treinamento que lhe foram apresentados. Os dados obtidos mostraram que os melhores pontos de generalização ocorreram perto da época

indicada pela parada antecipada, o que ocorreu sempre abaixo de 2.000 ciclos de treinamento. Segundo Sala (2005), com o aumento considerável no número de ciclos (50.000 a 100.000), o sistema aumenta a capacidade de aprendizado. A mesma metodologia adotada para o treinamento de redes foi observada no trabalho desenvolvido por Pereira (2003). Na verdade, com o aumento do número de ciclos do treinamento, a rede vai perdendo gradativamente o poder de generalização. Passado do ponto indicado pela parada antecipada a rede só tende a especializar (decorar) os padrões de treinamento que lhe foram apresentados. Quanto maior o número de épocas de treinamento, maior é a especialização da rede (Scolaro, 2009).

Após o treinamento de diversas redes neurais, o classificador neural obtido apresentou uma taxa de sensibilidade de 97,45%, taxa de especificidade de 97,28%, valor preditivo positivo de 98,83%, valor preditivo negativo de 94,21% e um índice de eficiência (desempenho global) de 97,40%. Este classificador utilizou os padrões marcados pelo especialista 3, pelo fato dos padrões deste especialista apresentar as características morfológicas recomendadas para a identificação dos eventos epileptiformes.

A avaliação da metodologia desenvolvida foi feita através da escolha aleatória de segmentos de sinal, com duração de dez minutos ou o equivalente a sessenta telas de dez segundos, em diferentes registros de EEG. De trinta registros disponíveis, foram selecionados dez registros, onde foram selecionados seiscentas telas de dez segundos de sinal, totalizando uma hora e quarenta minutos de análise. Os índices estatísticos foram calculados a partir das detecções válidas efetuadas pelo sistema, onde foram acumulados os índices VP, VN, FP e FN. Através do número de falsos positivos marcados pelo sistema, chegou-se a uma média de falsos positivos de **0,064/min**, ou seja, a cada 90 telas analisadas, um falso positivo é marcado pelo sistema.

Este trabalho vem contribuir, não só com uma nova metodologia para a detecção de eventos epileptiformes, mas também mostrar um software funcional, que pode ser utilizado para a resolução de um problema existente, que são os grandes volumes de dados gerados pelo monitoramento contínuo de pacientes.

5.3.4 Sobre o Software para a Identificação e Contagem Automática de Eventos Epileptiformes nos Registros de EEG de Longo Termo

O sistema computacional desenvolvido foi implementado utilizando o ambiente de desenvolvimento C++ Builder 6. Este ambiente de desenvolvimento gera softwares de alto nível, através da compilação de algoritmos escritos em C++, o que torna a execução do software final muito mais rápida, do que os códigos interpretados e executados pelo Matlab.

Todas as ferramentas e funções matemáticas que o software apresenta foram codificadas através de algoritmos escritos e compilados na linguagem C++, incluindo todas as funções de manipulação dos arquivos de sinal, para o processamento dos sinais de EEG, para a implementação das redes neurais e para os algoritmos necessários para a junção de todas as funcionalidades que o software agrega. A escolha desta linguagem de programação em específico, gerou um software estável, confiável e com tempo de execução reduzido, em tarefas como o processamento dos sinais de EEG e o treinamento das redes neurais.

O software desenvolvido agrega funcionalidades semelhantes, ao software de análise que os especialistas do CEPESC utilizam para a revisão dos registros de EEG. O sistema desenvolvido apresenta, por exemplo, uma interface semelhante a aquela que os especialistas estão acostumados a trabalhar, gerando menor resistência, em relação à utilização deste novo software. Os filtros para o pré-processamento dos sinais também foram projetados com as mesmas faixas de frequência utilizadas por eles. A opção de alteração das montagens de visualização e a manipulação das amplitudes também foram implementadas de forma semelhante. Esse cuidado teve o propósito de evitar o desinteresse por parte dos especialistas em utilizar o sistema.

O software agrega outras funcionalidades que outras metodologias não apresentam, como por exemplo, a contagem dos eventos epileptiformes detectados e a geração de relatórios, contendo o acúmulo dos eventos detectados, por canal e por registro de EEG. Este relatório ainda descreve o instante de tempo de ocorrência de cada evento, o canal de ocorrência deste evento, e sua máxima amplitude negativa. O relatório apresenta um gráfico de barras contendo, os valores acumulados por canal e por hemisférios. Não foi possível implementar um gráfico de superfície, o que representaria graficamente a distribuição da ocorrência dos eventos detectados, por cores, ficando como implementações futuras.

O sistema desenvolvido é totalmente compatível com os equipamentos de revisão e aquisição do CEPESC. Essa compatibilidade é pelo fato deste sistema abrir de forma transparente os arquivos gerados pelos equipamentos do CEPESC, o que veio a contribuir também em termos de desempenho no sistema desenvolvido. Não há a necessidade de realizar a conversão dos dados para um formato de arquivo conhecido no meio científico, como os arquivos com extensão EDF ou TXT.

5.3.5 Sobre a Avaliação dos Classificadores Neurais Treinados Conforme o Conhecimento de cada Especialista

Antes da escolha do classificador neural definitivo para o sistema de identificação e contagem automática de eventos epileptiformes, foram feitos diversos treinamentos com conjuntos de padrões selecionados a partir das marcações que cada um dos especialistas realizou.

Para cada especialista foram gerados três conjuntos distintos de padrões, um conjunto de treinamento, um conjunto de validação e um de testes, ou seja, três arquivos contendo os padrões necessários para o treinamento das redes neurais e todos diferentes entre si. Os padrões que estão no arquivo de treinamento, por exemplo, são diferentes dos padrões que estão nos arquivos de validação e de testes. Da mesma forma, os padrões que estão no arquivo de validação são diferentes dos padrões que estão nos arquivos de testes e de treinamento. Os padrões que estão no arquivo de testes são diferentes dos padrões que estão nos arquivos de treinamento e validação.

O objetivo desta avaliação é verificar o comportamento individual de cada classificador neural treinado, contendo as características de cada especialista. No decorrer da separação dos eventos utilizados para o desenvolvimento da metodologia proposta, ficou evidente que as características de marcação de cada especialista eram diferentes, como pode ser visualizado através da Figura 104.

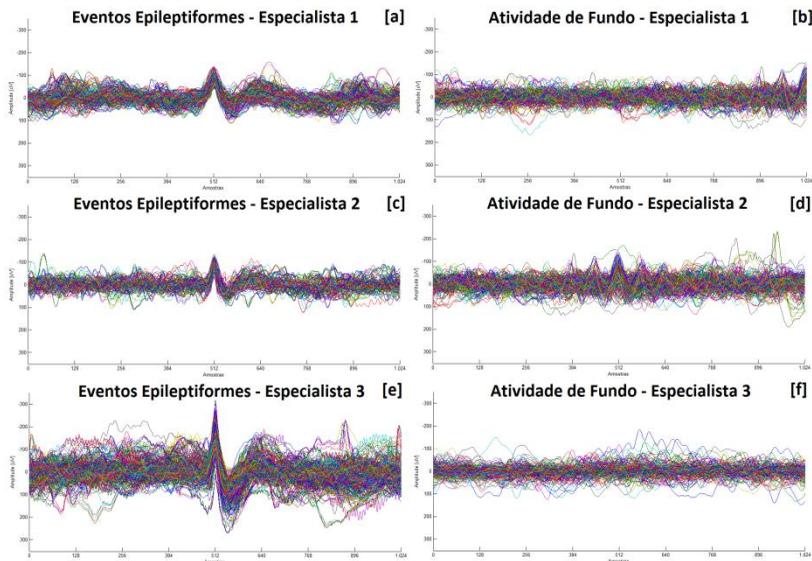


Figura 104 – Conjunto de eventos epileptiformes e de padrões de atividade normal de fundo do EEG, separados por especialistas.

Para verificar as características dos sinais que cada um dos especialistas marcaram foram gerados dois conjuntos de padrões para cada um deles, um contendo apenas eventos epileptiformes e o outro contendo apenas atividade normal de fundo do EEG. Os padrões representados na Figura 104[a] e Figura 104[b], são respectivamente, os eventos epileptiformes e a atividade normal de fundo do EEG, marcados pelo especialista 1. Os padrões representados em Figura 104[c] e Figura 104[d] são respectivamente, os eventos epileptiformes e atividade normal de fundo do EEG, marcados pelo especialista 2. Os padrões representados em Figura 104[e] e Figura 104[f] são respectivamente, os eventos epileptiformes e atividade de fundo do EEG, marcados pelo especialista 3.

Os padrões marcados pelo especialista 3 possuem características bem definidas, em relação à morfologia e à amplitude que os eventos epileptiformes apresentam. Comparando com a atividade de fundo do EEG, existe uma boa diferenciação entre estas duas classes de padrões, o que facilita o aprendizado das redes neurais no momento do treinamento. Essas características não são observadas nos conjuntos de sinais dos outros dois especialistas. Os eventos epileptiformes marcados não apresentam amplitudes e morfologias significativas, que permitam

fazer uma boa diferenciação desses padrões, em relação à atividade normal de fundo do EEG.

A diferença morfológica observada entre os registros de EEG dos três especialistas é perfeitamente compreensível, pois nem todos os especialistas aprendem a revisar registros de EEG da mesma forma. Na academia cada especialista aprende a visualizar determinadas características de um determinado tipo de sinal, conforme a experiência dos seus respectivos professores, responsáveis por passar o conhecimento no momento de sua aprendizagem.

Dessa forma, dois especialistas podem observar características diferentes para um mesmo padrão, como por exemplo, os eventos epileptiformes. Foi o que aconteceu em relação aos últimos registros de EEG fornecidos para a finalização deste trabalho (sinais dos especialistas 1 e 2). Foram feitos alguns experimentos que comprovam essa teoria.

Inicialmente, foram treinadas diversas redes neurais para cada especialista e selecionadas as redes que apresentaram os melhores índices de sensibilidade, especificidade e de eficiência de cada especialista individualmente. Também foram treinadas redes neurais com o conhecimento dos três neurologistas juntos. A rede treinada com o conhecimento do especialista 1 foi avaliada com o arquivo de padrões de teste do próprio especialista 1. Utilizando esta mesma rede neural foram aplicados os conjuntos de padrões de teste dos especialistas 2 e 3 e também o conjunto de padrões de teste contendo as marcações dos três especialistas juntos, calculando os índices estatísticos para cada uma das situações. O mesmo procedimento se repetiu para o especialista 2, onde a rede treinada com o seu respectivo conhecimento foi avaliada com o arquivo de padrões do próprio especialista 2. Utilizando esta mesma rede neural foram aplicados os conjuntos de padrões de teste dos especialistas 1 e 3 e também o conjunto de padrões de teste contendo as marcações dos três especialistas juntos, onde foram calculados os índices estatísticos para cada uma das situações. Da mesma forma, a rede treinada com o conhecimento do especialista 3 foi avaliada com o arquivo de padrões do especialista 3. Para essa mesma rede neural foram aplicados os conjuntos de padrões de teste dos especialistas 1 e 2 e também o conjunto de padrões de teste contendo as marcações dos três especialistas juntos, calculando-se os índices estatísticos para cada uma das situações. Para a rede treinada com o conhecimento dos três neurologistas juntos o procedimento foi o mesmo. A rede foi avaliada com o conjunto de testes, contendo padrões de treinamento dos três neurologistas. Também foram feitos os testes com os três conjuntos de

padrões de teste distintos de cada especialista e os índices estatísticos foram calculados para cada situação. Todos os resultados foram avaliados e agrupados na Tabela 17.

Tabela 17 – Avaliação dos classificadores neurais por especialista.

	Índices Estatísticos	Classificador do Especialista 1 [época 278]	Classificador do Especialista 2 [época 844]	Classificador do Especialista 3 [época 1873]	Classificador dos Especialistas 1, 2 e 3 [época 420]
Arquivo de padrões de Teste do Especialista 1	Sensibilidade	89,66%	96,15%	47,95%	76,81%
	Especificidade	95,82%	88,47%	99,52%	96,17%
	Eficiência	94,24%	89,80%	71,62%	90,24%
Arquivo de padrões de Teste do Especialista 2	Sensibilidade	86,21%	94,67%	53,06%	78,95%
	Especificidade	84,56%	94,74%	97,70%	96,57%
	Eficiência	84,93%	94,72%	72,02%	90,02%
Arquivo de padrões de Teste do Especialista 3	Sensibilidade	99,68%	99,70%	94,87%	98,54%
	Especificidade	62,38%	66,56%	98,33%	89,40%
	Eficiência	80,73%	83,92%	95,86%	95,38%
Arquivo de padrões de Teste dos Especialistas 1, 2 e 3	Sensibilidade	96,79%	98,38%	81,26%	93,49%
	Especificidade	73,42%	76,96%	97,74%	91,64%
	Eficiência	83,13%	86,40%	86,48%	92,68%

Os dados obtidos mostram que uma rede neural treinada com o conhecimento individual de um especialista e avaliada com padrões gerados a partir do conhecimento deste mesmo especialista, alcança índices de eficiência relativamente altos, quando comparado com os conjuntos de padrões de teste dos demais especialistas. O classificador neural treinado com o conhecimento do especialista 1 foi avaliado com o conjunto de padrões do próprio especialista 1, alcançando um índice de eficiência de 94,24%. Avaliando este mesmo classificador neural com os demais conjuntos de teste dos especialistas 2 e 3, foram obtidos índices de eficiência de 89,93% e 80,73%, respectivamente. Apresentando a este mesmo classificador neural, o conjunto de testes contendo os padrões marcados pelos três especialistas juntos, o índice de eficiência alcançou 83,13%, ficando abaixo do valor obtido com o conjunto de padrões de teste do próprio especialista 1. Os resultados dos experimentos realizados são apresentados na Figura 105.

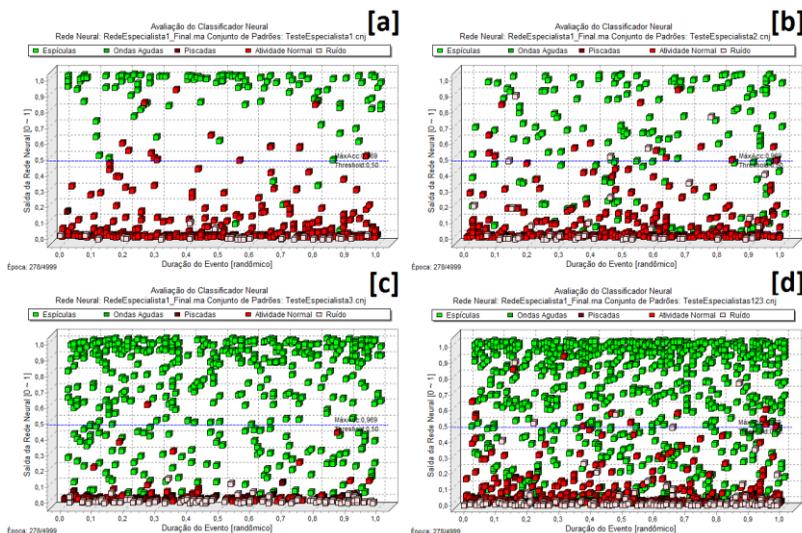


Figura 105 – Resultados obtidos através da classificação dos conjuntos de padrões de teste do especialista 1 [a], especialista 2 [b], especialista 3 [c] e dos especialistas 1,2 e 3 juntos [d], utilizando o classificador neural treinado com o conhecimento do especialista 1.

Os gráficos da Figura 105 mostram o resultado da avaliação dos conjuntos de padrões de cada especialista individualmente, pelo classificador contendo o conhecimento de apenas um especialista, que neste caso é o especialista 1. Pode ser observado que o conjunto de teste contendo as marcações do próprio especialista 1 (Figura 105 [a]) apresentou melhor separação entre as classes de padrões, em relação aos conjuntos de teste do especialista 2 (Figura 105 [b]) e do especialista 3 (Figura 105 [c]). Aplicando o conjunto de padrões de testes com os eventos selecionados pelos três especialistas (Figura 105 [d]) foi observado que existe uma clara distinção entre as classes de padrões. No entanto, também existem muitos padrões que estão próximos da linha do *threshold*, indicando que o treinamento deste classificador não foi suficiente para generalizar os padrões marcados pelos demais especialistas.

Seguindo o mesmo procedimento, o classificador neural treinado com o conhecimento do especialista 2 foi avaliado com o conjunto de padrões de teste do próprio especialista 2 e o índice de eficiência alcançou 94,72%. Avaliando o mesmo classificador neural com os demais conjuntos de teste dos especialistas 1 e 3 foram obtidos índices

de eficiência de 89,80% e 83,92%, respectivamente. Apresentando o conjunto de testes contendo os padrões marcados pelos três especialistas à esse mesmo classificador o índice de eficiência alcançou 86,40%, ficando abaixo do valor obtido com o conjunto de padrões de teste do próprio especialista 2. Os resultados dos experimentos realizados são apresentados na Figura 106.

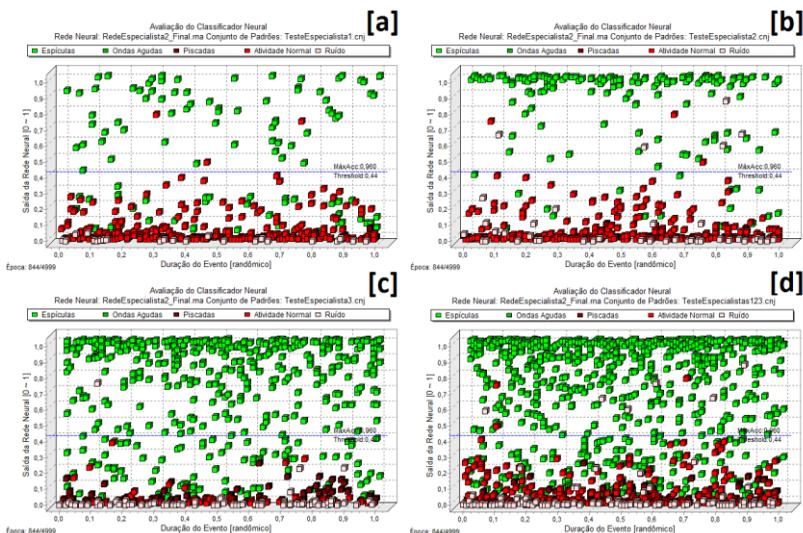


Figura 106 – Resultados obtidos através da classificação dos conjuntos de padrões de teste do especialista 1 [a], especialista 2 [b], especialista 3 [c] e dos especialistas 1,2 e 3 juntos [d], utilizando o classificador neural treinado com o conhecimento do especialista 2.

Os gráficos da Figura 106 mostram o resultado da avaliação dos conjuntos de padrões de cada especialista individualmente, pelo classificador contendo o conhecimento de apenas do especialista 2. Pode ser observado que o conjunto de teste contendo as marcações do próprio especialista 1 (Figura 106 [a]) apresentou melhor separação entre as classes de padrões, em relação aos conjuntos de teste do especialista 2 (Figura 106 [b]) e do especialista 3 (Figura 106 [c]). Aplicando o conjunto de padrões de testes com os eventos selecionados pelos três especialistas (Figura 106 [d]) foi observado que existe uma clara distinção entre as classes de padrões. No entanto, também existem muitos padrões que estão próximos da linha do *threshold*, indicando que o treinamento deste classificador não foi suficiente para generalizar os padrões marcados pelos demais especialistas.

O classificador neural treinado com o conhecimento do especialista 3 foi avaliado com o conjunto de padrões de testes do próprio especialista 3. O índice de eficiência alcançado foi de 95,86%. Avaliando este mesmo classificador com os demais conjuntos de teste dos especialistas 1 e 2, foram obtidos índices de eficiência de 71,62% e 72,02%, respectivamente. Apresentando a este mesmo classificador o conjunto de testes contendo os padrões marcados pelos três neurologistas, o índice de eficiência alcançou 86,48%, ficando abaixo do valor obtido com o conjunto de padrões de teste do próprio especialista 3. Os resultados dos experimentos são apresentados na Figura 107.

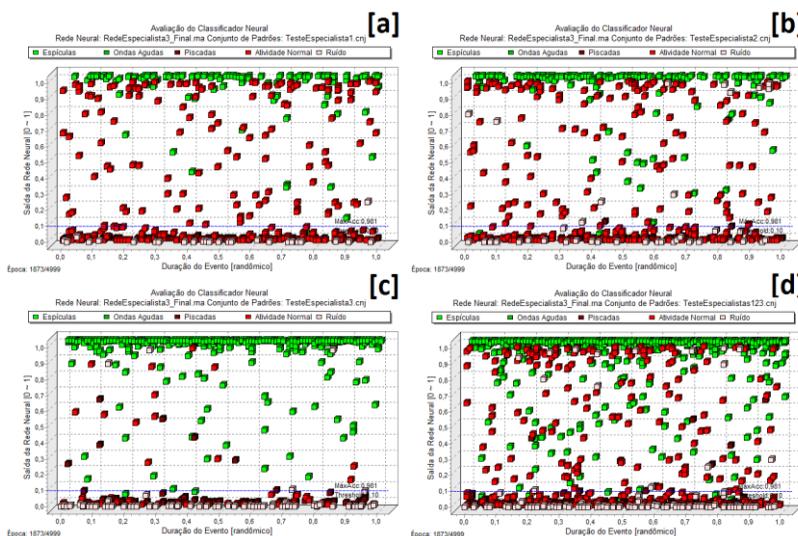


Figura 107 – Resultados obtidos através da classificação dos conjuntos de padrões de teste do especialista 1 [a], especialista 2 [b], especialista 3 [c] e dos especialistas 1,2 e 3 juntos [d], utilizando o classificador neural treinado com o conhecimento do especialista 3.

Observando os gráficos obtidos na Figura 107 ficou claro que este classificador neural apresentou os melhores resultados, em termos de distinção das classes de eventos. Avaliando este classificador com o próprio conjunto de testes, há uma grande distinção entre os padrões (Figura 107 [c]Figura 106). Os eventos epileptiformes foram classificados com valores 1 ou próximos de 1. Já os demais tipos de padrões foram classificados com valores 0 ou bem próximos de 0. Esse comportamento foi reproduzido na avaliação deste classificador com o conjunto de padrões contendo os padrões selecionados dos três

especialistas, onde este comportamento também é visível (Figura 107 [d]). Os demais padrões que não estão nas extremidades do gráfico, provavelmente são alguns dos eventos selecionados dos outros especialistas.

Finalmente, a rede neural treinada com o conhecimento dos três especialistas foi avaliada com o conjunto de padrões de teste, contendo os padrões marcados pelos três especialistas e o índice de eficiência alcançou 92,68%. Avaliando esta mesma rede neural com os conjuntos de teste dos especialistas 1, 2 e 3 foram obtidos os índices de eficiência de 90,24%, 90,02% e 95,38%, respectivamente. Os resultados obtidos dos experimentos realizados são apresentados na Figura 108.

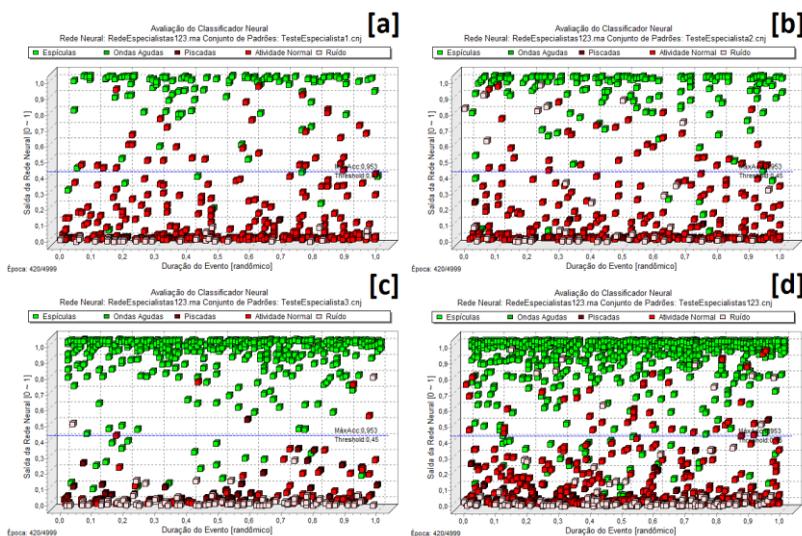


Figura 108 – Resultados obtidos através da classificação dos conjuntos de padrões de teste do especialista 1 [a], especialista 2 [b], especialista 3 [c] e dos especialistas 1,2 e 3 juntos [d], utilizando o classificador neural treinado com o conhecimento dos três especialistas juntos.

Os resultados obtidos através da avaliação do classificador neural contendo o conhecimento dos três neurologistas mostrou melhor distinção na classificação dos padrões, em relação aos demais classificadores. O que era de se esperar, pois este classificador agregou o conhecimento dos três especialistas individualmente, e consequentemente, conseguiu distinguir os três conjuntos de teste distintos. Entretanto, pode ser observado que o conjunto de padrões do especialista 3 (Figura 108 [c]) foi mais bem classificado. Houve boa

distinção entre as classes, comparando com os outros conjuntos de padrões. Isso vem comprovar que os padrões deste especialista são mais definidos e apresentam melhores características de morfologia e amplitude, em comparação aos demais conjuntos. Mesmo sendo um terço dos padrões treinados para o classificador com o conhecimento dos três neurologistas, esses padrões tiveram participação maior no treinamento do que os demais, ou seja, apresentaram características mais marcantes em relação à morfologia dos eventos epileptiformes, marcados pelos especialistas 1 e 2.

A partir destes resultados, surgiram alguns pontos que devem ser discutidos, em relação aos conjuntos de padrões gerados e os treinamentos realizados para os classificadores neurais.

Os resultados sugerem que, se o próprio especialista treinar o classificador neural do seu sistema classificador e conforme o seu conhecimento individual do processo de revisão, o classificador neural alcançará altos valores de eficiência, quando utilizado para a revisão dos seus próprios registros de EEG. Essa teoria foi comprovada através dos resultados apresentados na Tabela 17.

Como os resultados mostraram o classificador treinado com o conhecimento do especialista 3, obteve a melhor taxa de eficiência entre todos os testes. Avaliando este classificador com o próprio conjunto de testes do especialista 3, obteve-se uma taxa de eficiência de 95,86%. Avaliando também este mesmo classificador com o conjunto de testes, contendo os padrões dos três especialistas, obteve-se uma taxa de eficiência de 95,38%.

Estes resultados sugerem que o conjunto de padrões deve apresentar características apropriadas ao problema que se está querendo resolver, neste caso, a detecção de eventos epileptiformes. Apenas as marcações do especialista 3, ou seja, um terço dos eventos epileptiformes foram suficientes para gerar uma taxa de eficiência maior, que aquela obtida avaliando o classificador neural treinado com o conhecimento dos três neurologistas juntos.

Avaliando os resultados do reconhecimento deste classificador, com os conjuntos de testes individuais de cada especialista, pôde ser observado que os eventos epileptiformes marcados pelo especialista 3, influenciaram diretamente no treinamento do classificador neural, devido a esses padrões apresentarem características mais marcantes, se comparados com os outros dois conjuntos de padrões.

Como contribuição deste trabalho, os resultados obtidos sugerem que, a melhor opção para construir uma base de conhecimento para um sistema de detecção automática de eventos epileptiformes,

composto por classificadores neurais, seria inserir o conhecimento do próprio neurologista que irá manipular o sistema. Dessa forma, o próprio especialista estaria “moldando” o conhecimento das redes neurais, de acordo com sua experiência e conforme a sua necessidade. A probabilidade de o sistema detectar os eventos epileptiformes com as características esperadas pelo neurologista seria elevada, pois os classificadores seriam previamente treinados com características que o especialista foi acostumado a visualizar na marcação dos eventos epileptiformes, no momento da revisão dos registros de EEG.

Como os experimentos mostraram o classificador neural treinado com o conhecimento de três especialistas, os índices de eficiência apresentaram uma média de 90,08%, ficando abaixo dos índices de eficiência obtidos individualmente pelos classificadores treinados com o conhecimento de cada especialista.

Os classificadores neurais treinados com os conjuntos de padrões contendo as marcações do especialista 3, conseguiram obter os melhores resultados de generalização, entre todas as redes testadas. Dessa forma, o classificador neural que apresentou o melhor resultado foi adotado para o software de identificação e contagem de eventos epileptiformes implementado, pelo fato de possuir padrões bem distintos, em termos de morfologia e amplitude, de acordo com a literatura encontrada.

5.3.6 Comparativo de Desempenho

Poucos trabalhos puderam ser utilizados para comparação. Oroscho et al. (2013) e seus colaboradores realizaram uma revisão de vários algoritmos para a detecção de crises epiléticas na última década, relatando a falta de padronização de métricas e métodos de avaliação no campo da detecção de crises epiléticas que dificultam a realização de comparações homogêneas dos classificadores propostos.

Algumas comparações puderam ser feitas entre trabalhos desenvolvidos no IEB/UFSC, pelo fato de seguirem a mesma linha de pesquisa.

Em relação aos trabalhos correlatos que utilizaram classificadores neurais para classificação de eventos epileptiformes foram escolhidas as metodologias de Argoud (2001), Pereira (2003) e Sovierzoski (2009).

A metodologia desenvolvida por Argoud (2001) utilizou sinais com frequência de amostragem de 100 Hz, montagem bipolar

longitudinal e utilizou quatro classes de padrões diferentes (atividade normal, espículas, ruído e piscadas) para o treinamento das redes.

As redes neurais utilizadas são do tipo MLP (Perceptron Multicamada), as quais apresentaram 100 neurônios na camada de entrada, 10 neurônios na camada escondida e 1 neurônio na camada de saída. A função de ativação utilizada foi a tangente hiperbólica nas duas camadas e taxa de momentum de 0,97. Foram treinadas quatro redes neurais especialistas distintas, uma para cada classe de padrões.

A metodologia realiza um pré-processamento dos sinais de EEG antes de apresentá-los para as redes neurais, utilizando a transformada wavelet. Essa transformada foi utilizada como um detector, onde foram empregados os níveis de detalhe 1, 2 e 3 da função coiflet, em épocas de sinal de 1 segundo, para realizar a detecção dos eventos epileptiformes, tornando suas características particulares mais evidentes.

Posteriormente, as saídas das redes são analisadas por regras de produção. A metodologia apresentou índices de sensibilidade de 48,70%, especificidade de 98,40%, valor preditivo positivo de 47,30%, valor preditivo negativo de 97,40% e uma taxa de acertos de 96,20%.

O trabalho desenvolvido por Pereira (2003) teve como objetivo avaliar formas de pré-processamento mais adequadas para processar os eventos epileptiformes e depois de processados, utilizá-los como entradas das redes neurais para a classificação. Foram utilizados sinais com frequência de amostragem de 100 Hz, montagem bipolar longitudinal e os padrões foram divididos entre quatro classes de distintas (atividade normal, espículas, ruído e piscadas) para o treinamento das redes. A função de ativação utilizada foi a tangente hiperbólica nas duas camadas, taxa de momentum de 0,9 e taxa de aprendizado de 0,01.

Foram testadas quatro formas de pré-processamento, entre elas, uma que utiliza a transformada wavelet para o processamento dos eventos epileptiformes, a qual será empregada para efeitos de comparação entre as metodologias.

A função wavelet adotada foi a função Coiflet 1 e os níveis de detalhe escolhidos foram os níveis D1, D2 e D3.

As redes neurais utilizadas são do tipo MLP (Perceptron Multicamada), as quais apresentaram 100 neurônios na camada de entrada, 12 neurônios na camada escondida e 1 neurônio na camada de saída. Os padrões epileptiformes foram processados pelos níveis D1, D2 e D3 da transformada wavelet e os sinais resultantes eram inseridos nas entradas das redes individuais para serem reconhecidos.

Foram testadas varias combinações de redes neurais, desde a utilização individual de cada uma delas, até a utilização delas em conjunto, sendo aplicadas a um conjunto de regras de produção para a classificação dos eventos epileptiformes.

As redes com entradas tratadas pela transformada wavelet obtiveram cerca de 80% de acertos, taxa de sensibilidade em torno de 95% e especificidade em torno de 70%.

O trabalho desenvolvido por Soviersoski (2009) propôs descritores morfológicos para o reconhecimento de padrões epileptiformes. Foram criados dois classificadores, um treinado com padrões epileptiformes na sua forma original e outro treinado com os descritores morfológicos propostos no trabalho, que descrevem características importantes dos eventos epileptiformes.

Para efeitos de comparação, a atenção será voltada para o classificador treinado com os sinais na sua forma original, pois este classificador apresenta características semelhantes ao desenvolvido neste trabalho.

Soviersoski (2009) utilizou sinais de EEG com frequência de amostragem de 100 Hz, montagem bipolar longitudinal. Dessa forma, o classificador neural apresenta 101 entradas na primeira camada, 7 neurônios na camada escondida e 1 neurônio na camada de saída. Com um único neurônio de saída o classificador é binário, ou seja, caso apresente um valor 1 na saída, o padrão foi reconhecido como epileptiforme, caso a saída apresente o valor 0, o padrão não foi reconhecido. Em todos os neurônios foi utilizada a função logística como função de ativação. Os pesos sinápticos utilizados foram randomizados entre os valores $\pm 0,1$. A taxa de momentum utilizada apresenta o valor de 0,7 e a taxa de aprendizado configurada é de 0,002.

Os conjuntos de treinamento e validação utilizados no processo de treinamento e testes do classificador foram compostos por 100 padrões epileptiformes (60 ondas agudas e 40 espículas) e 100 padrões não epileptiformes (piscada palpebral).

Após a avaliação do treinamento do classificador, o mesmo apresentou um erro médio quadrático de 0,09384756 na época de treinamento 229, indicada pela parada antecipada. Já o índice ROC atingiu uma taxa de 0,92920106 na época 147 e o índice de eficiência atingiu uma taxa de 90,00% na época 74. A época de treinamento adotada para o classificador foi a de número 147 a qual produziu um classificador com índices de sensibilidade de 90,91%, especificidade de 89,11%, seletividade positiva de 89,11% e seletividade negativa de 90,91%.

O classificador neural desenvolvido nesta metodologia utilizou sinais de EEG com 512 Hz de frequência de amostragem, com 28 canais de monitoramento e montagem referencial. O classificador foi configurado com 512 entradas na primeira camada, 10 neurônios na camada escondida e 1 neurônio na camada de saída, formando um classificador binário. Caso a saída apresente um valor 1, o padrão foi reconhecido como epileptiforme, caso a saída apresente o valor 0, o padrão não foi reconhecido. Os neurônios da camada escondida utilizaram a função tangente hiperbólica, para adequar os valores positivos e negativos que o sinal de EEG apresenta, e a função logística na camada de saída, para adequar os valores de saída entre 0 e 1. Os pesos sinápticos utilizados foram randomizados entre os valores $\pm 0,01$. A taxa de momentum utilizada apresenta o valor de 0,7 e a taxa de aprendizado configurada é de 0,001.

Para o conjunto de treinamento foram selecionados 426 eventos epileptiformes, 60 sinais de piscadas, 60 sinais de atividade normal de fundo e 70 sinais de ruído. Para o conjunto de validação foram selecionados 428 eventos epileptiformes, 62 sinais de piscadas, 60 sinais de atividade normal de EEG e 78 sinais de ruídos. Para o conjunto de testes foram selecionados 426 eventos epileptiformes, 60 sinais de piscadas, 60 sinais de atividade normal de fundo e 70 sinais de ruído.

Após o treinamento o classificador alcançou índices de sensibilidade de 97,45%, especificidade de 97,28%, valor preditivo positivo de 98,83%, e valor preditivo negativo de 94,21%, alcançando um desempenho médio de 96,96% e um índice de eficiência de 97,40%.

Os principais índices de desempenho obtidos, pela avaliação das quatro metodologias descritas, foram agrupados na Tabela 18 para fins de comparação. Pode ser observado que esta metodologia alcançou um índice de acertos de 97,40%, em relação às demais metodologias avaliadas, assim como, os demais índices de desempenho também apresentaram valores elevados, comparando com os outros trabalhos.

Tabela 18 – Índices de desempenho das quatro metodologias avaliadas.

Metodologias	Sen [%]	Esp [%]	VPP [%]	VPN [%]	Eficiência [%]
Argoud (2001)	48,70	98,40	47,30	97,40	96,20
Pereira (2003)	95,00	70,00	-	-	80,00
Soviersoski (2009)	90,91	89,11	89,11	90,91	90,00
Este Trabalho	97,45	97,28	98,83	94,21	97,40

Acredita-se que a frequência de amostragem dos sinais utilizados no treinamento dos classificadores neurais, implementados neste trabalho, influenciou diretamente nos resultados obtidos. A frequência de amostragem utilizada é de 512 Hz, ou seja, aproximadamente cinco vezes a frequência de amostragem empregada na coleta dos sinais utilizados pelos demais trabalhos. Dessa forma, cinco vezes mais amostras de sinal foram passadas para os classificadores no momento do treinamento, e conseqüentemente, mais características sobre os padrões treinados foram incorporados no aprendizado, uma vez que, as topologias e os parâmetros de configuração entre as redes neurais dos trabalhos avaliados são muito próximos.

Dos trabalhos que empregaram a transformada wavelet como forma de pré-processamento, e mais precisamente, como um filtro digital para atenuar a atividade de fundo do EEG, o mais relevante é o trabalho desenvolvido por Wiltschko et al. (2008), onde o método *denoising* da transformada wavelet foi utilizado para a eliminação de determinadas componentes de frequência antes da reconstrução do sinal, ou seja, ainda no domínio wavelet. Essa forma de processamento elimina coeficientes do sinal decomposto que ultrapassem um *threshold* definido pelo usuário e após a eliminação desses coeficientes, o sinal resultante é reconstruído, dando origem às aproximações e detalhes sem determinadas componentes de frequência. Mas esse processo não garante que componentes de frequência foram tratadas individualmente.

A metodologia desenvolvida neste trabalho realiza um processo diferente para a eliminação de componentes de frequência do sinal de EEG. O sinal decomposto pela transformada wavelet é reconstruído, conforme os níveis de reconstrução desejados e dessa forma, as aproximações geradas retêm faixas de frequência específicas. Esse processo permite que determinadas componentes de frequência possam ser tratadas ou eliminadas de forma individual, ou seja, as componentes de frequência desnecessárias dos sinais de EEG são retiradas após a reconstrução dos sinais decompostos, garantindo que não haverá distorção do sinal obtido neste processo. Essa forma de tratamento dos sinais de EEG proporcionou uma forma diferenciada de processamento, deixando basicamente, as componentes de frequência que realmente caracterizam os eventos epileptiformes em evidencia dos traçados de EEG, facilitando bastante o trabalho dos classificadores neurais na tarefa do reconhecimento desses padrões.

6 CONCLUSÕES

Este trabalho vem a contribuir com um software funcional, que pode ser utilizado para a resolução de um problema existente, que é a revisão de grandes volumes de dados gerados pelos registros de EEG, através do monitoramento contínuo de pacientes candidatos ao tratamento cirúrgico da epilepsia.

O sistema desenvolvido conta com um classificador neural constituído apenas por uma rede neural artificial, o qual foi capaz de distinguir quatro classes de padrões distintos, encontrados nos registros de EEG de longa duração, sendo compatível com os resultados obtidos por Sclaro (2009).

Como forma de pré-processamento dos sinais de EEG foi proposto um filtro digital, gerado a partir da manipulação das aproximações da transformada wavelet, para a atenuação de frequências específicas e desnecessárias, que interferem na correta localização dos eventos epileptiformes.

O filtro desenvolvido com a transformada wavelet apresentou resultados satisfatórios na atenuação de sinais da atividade de fundo do EEG, proporcionando pouca distorção dos sinais após o processamento, sendo compatível com os resultados obtidos por Wiltschko et al. (2008).

A função wavelet mais adequada para o processamento dos eventos epileptiformes foi a função Db4 (Daubechies 4), sendo compatível com os resultados obtidos por Adeli et al., (2003) e por Subasi (2007). Esta função foi a base para o desenvolvimento do filtro wavelet implementado.

Contudo, conclui-se que o objetivo proposto foi alcançado através da implementação de um sistema computacional automatizado para a identificação e contagem de eventos epileptiformes, o qual alcançou taxas de sensibilidade, especificidade e eficiência aceitáveis para a prática da revisão dos registros de EEG de longo termo do período interictal, apresentando uma taxa de falsos positivos por minuto de 0,064 FP/min.

7 TRABALHOS FUTUROS

Como trabalhos futuros são sugeridas melhorias em relação à interface do sistema computacional implementado e o melhoramento das regras de produção, inseridas no módulo detector dos eventos epileptiformes, na tentativa de baixar ainda mais a taxa de falsos positivos.

Sugere-se a implementação de relatórios mais elaborados, com gráficos que representem a região que apresentou maiores índices de descargas ocorridas, que venham a auxiliar na interpretação das condições do paciente monitorado.

Uma sugestão de utilização dos dados gerados pelo sistema de detecção e contagem de eventos epileptiformes desenvolvido, seria a análise e cruzamento desses dados, com as quantidades de descargas epileptiformes contadas de cada paciente individualmente e com o número de pacientes já submetidos à cirurgia no CEPESC. Seriam utilizados os registros dos pacientes que foram “curados”, os que apresentaram alguma melhora no seu estado e aqueles que a cirurgia não teve influencia nenhuma na sua melhora. Caso fosse possível “prever” conforme o número de descargas epileptiformes que um determinado paciente apresentou no período de monitoramento, os especialistas poderiam ter uma expectativa sobre o sucesso da cirurgia, sem ter que fazê-la para descobrir se ela seria ou não bem sucedida. Um sistema automatizado que realize uma análise e gere uma probabilidade sobre uma cirurgia ser ou não bem sucedida, a partir da análise do número de descargas contadas, não foi encontrado na literatura, no período de revisão da literatura, sendo uma opção para implementações futuras.

REFERÊNCIAS

- Acir, N., Öztura, Ö., Kuntalp, M., Baklan, B., & Güzelis, C. (2005). *Automatic Detection of Epileptiform Events in EEG by a Three-Stage Procedure Based on Artificial Neural Networks*. *IEEE Transactions on Biomedical Engineering*, *52*, 30-40.
- Addison, P. S. (2002). *The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science, Engineering, Medicine and Finance*. New York: Taylor & Francis Group.
- Adeli, H., Zhou, Z., & Dadmehr, N. (2003). Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of Neuroscience Methods*, *123*, 69-87.
- Adeli, H., & Ghosh-Dastidar, S. (2010). *Automated EEG-Based Diagnosis of Neurological Disorders - Inventing the Future of Neurology*. Boca Raton, FL: CRC Press/Taylor & Francis Group.
- Argoud, F. I. (2001). *Contribuição ao Estudo da Automatização da Detecção e Análise de Eventos Epileptiformes em Eletroencefalograma*. Tese de Doutorado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.
- Argoud, F. I., Azevedo, F. M., & Marino Neto, J. (2004). Estudo comparativo entre funções wavelet e suas diferentes aplicabilidades em reconhecimento de padrões epileptogênicos em eletroencefalograma. *Revista Brasileira de Engenharia Biomédica*, *20*, 49-59.
- Argoud, F. I., Azevedo, F. M., & Marino Neto, J. (2004). Sistema de Detecção Automática de Paroxismos Epileptogênicos em Sinais de Eletroencefalograma. *Revista Controle & Automação*, *15*, 467-475.
- Argoud, F. I., Azevedo, F. M., Marino Neto, J., & Grillo, E. (2006). *sdfs. Medical & Biological Engineering & Computing*, *44*, 459-470.
- Bear, M. F., Connors, B. W., & Paradiso, M. A. (2002). *Neurociências: Desvendando o Sistema Nervoso* (2ª Edição ed.). Porto Alegre: Artmed.

Blum, A. S., & Rutkove, S. B. (2007). *The Clinical Neurophysiology Primer*. Totowa, New Jersey: Humana Press Inc.

Boos, C. F. (2011). *Avaliação de descritores morfológicos de eventos epileptiformes utilizando análise de componentes principais*. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.

Braga, A. C. (2000). *Curvas ROC: Aspectos Funcionais e Aplicações*. Tese de Doutorado, Braga, Portugal.

Brasil. Ministério da Saúde. Normas e Manuais Técnicos (2010). *Protocolos Clínicos e Diretrizes Terapêuticas Volume 2*. Brasília, DF.

Burrus, C. S., Gopinath, R. A., & Guo, H. (1998). *Introduction to Wavelets and Wavelet Transforms: A Primer*. Upper Saddle River, New Jersey: Prentice Hall.

Chan, H.-L., Wu, T., Lee, S.-T., Lin, M.-A., He, S.-M., Chao, P.-K., et al. (2010). Unsupervised wavelet-based spike sorting with dynamic code book searching and replenishment. *Neurocomputing* , 73, 1513-1527.

Coimbra, A. J., Marino Neto, J., & De Azevedo, F. M. (1994). Automatic Detection of Sleep-Waking States Using Kohonen Neural Networks. *I Congresso Brasileiro de Redes Neurais* , 327-331.

Coimbra, A. J., Marino Neto, J., De Azevedo, F. M., Freitas, C. G., & Barreto, F. M. (1995). Brain Electrographic State Detection Using Combined Unsupervised and Supervised Neural Networks. *Artificial Neural Nets and Genetic Algorithms* , 76-79.

Eberhart, R. C., & Dobbins, R. W. (1990). *Neural Network PC Tools: A Practical Guide*. San Diego: Academic Press.

Fischbach, F., & Dunning, M. B. (2009). *A Manual of Laboratory and Diagnostic Tests* (8th Edition ed.). Lippincott Williams & Wilkins.

Fletcher, R. W., & Fletcher, S. W. (2005). *Clinical Epidemiology: the essentials* (4th Edition ed.). Lippincott Williams e Wilkins.

- Geng, X., Hu, G., & Tian, X. (2010). Neural spike sorting using mathematical morphology, multiwavelets transform and hierarchical clustering. *Neurocomputing* , 73, 707-715.
- Goroll, A. H., & Mulley, A. G. (2009). *Primary Care Medicine: Office Evaluation and Management of the Adult Patient* (6th Edition ed.). Lippincott Williams e Wilkins.
- Haykin, S. (2001). *Redes Neurais: Princípios e Prática*. Porto Alegre: Bookman.
- Hese, P. et al., 2004. Evaluation of Temporal and Spacial EEG Spike Detection Algorithms. *The Fifth FTW PhD Symposium, Faculty of Engineering, Ghent University*.
- Inan, Z. H., & Kuntalp, M. (2007). A study on fuzzy C-means clustering-based systems in automatic spike detection. *Computers in Biology and Medicine* , 37, 1160–1166.
- Indiradevi, K. P., Elias, E., Sathidevi, P. S., Dinesh Nayak, S., & Radhakrishnan, K. (2008). A multi-level wavelet approach for automatic detection of epileptic spikes in the electroencephalogram. *Computers in Biology and Medicine* , 38, 805-816.
- Jekel, J. F., Katz, D. L., & Elmore, J. G. (2001). *Epidemiology, Biostatistics and Preventive Medicine* (Second Edition ed.). W. B. Saunders Company.
- Kalayci, T., Ozdamar, O. (1995). “Wavelet processing for automated neural network detection of EEG spikes”. *IEEE Eng. Med. Biol. Mag.*, pp. 160–166.
- Keshri, A. K., Sinha, R. K., Singh, A., & Das, B. N. (2011a). DFAspike:A new computational proposition for efficient recognition of epileptik spike in EEG. *Computers inBiologyandMedicine* , 41, 559-564.
- Keshri, A. K., Das, B. N., Mallick, D. K., & Sinha, R. K. (2011b). Parallel Algorithm to Analyze the Brain Signals: Application on Epileptic Spikes. *Journal of Medical Systems* , 35, 93-104.

Kutlu, Y., Kuntalp, M., & Kuntalp, D. (2009). Optimizing the performance of an MLP classifier for the automatic detection of epileptic spikes. *Expert Systems with Applications*, 36, 7567–7575.

Lüders, H. O., & Noachtar, S. (2000). *Atlas e Classificação em Eletroencefalografia: Introdução à Avaliação do Eletroencefalograma*. São Paulo: Lemos Editorial.

Mallat, S. (1999). *A Wavelet Tour of Signal Processing*. USA: Academic Press.

Malmivuo, J., & Plonsey, R. (1995). *Bioelectromagnetism - Principles and Applications of Bioelectric and Biomagnetic Fields*. New York: Oxford University Press.

Mendonça, G. A. (2007). *Proposta para Identificação Automática de Complexos K e Fusos do Sono Através de Redes Neurais Artificiais e Processamento de Sinais*. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.

Montenegro, M. A., Cendes, F., Guerreiro, M. M., & Guerreiro, C. A. (2001). *EEG na Prática Clínica*. São Paulo: Lemos Editorial.

Niedermeyer, E., & Silva, F. L. (2004). *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Lippincott Williams e Wilkins.

Nonclercq, A., Foulon, M., Verheulpen, D., De Cock, C., Buzatu, M., Mathys, P., et al. (2009). Spike detection algorithm automatically adapted to individual patients applied to spike and wave percentage quantification. *Neurophysiologie Clinique/Clinical Neurophysiology*, 39, 123-131.

Oroscho, L., Garcés, A. and Laciár, E. (2013). Review: A Survey of Performance and Techniques for Automatic Epilepsy Detection. *Journal of Medical and Biological Engineering*, 33(6): 526-537.

Ozdamar, O., Kalayci, T. (1998). “Detection of spikes with artificial neural networks using raw EEG,” *Computer Biomedical Research*, vol. 31, pp. 122–142.

- Pang, C. C., Upton, A. R., Shine, G., & Kamath, M. V. (2003). A Comparison of Algorithms for Detection of Spikes in the Electroencephalogram. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, 50, 521-526.
- Pereira, M. C. (2003). *Tratamento de Sinais Biomédicos para Processamento por Redes Neurais Artificiais*. Tese de Doutorado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.
- Pillai, J., & Sperling, M. R. (2006). *Interictal EEG and the Diagnosis of Epilepsy, Epilepsia* (Vol. 47). Blackwell Pub./ ILAE.
- Rodrigues, M. A. (1997). *Desenvolvimento de um instrumento virtual para aquisição e análise de sinais bioelétricos*. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.
- Rodrigues, M. A. (2002). *Sistema para Detecção e Classificação Automática de Apnéias do Sono A partir de Registros Polissonográficos*. Tese de Doutorado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.
- Sala, F. A. (2005). *Mapas de Kohonen na Detecção de Eventos Epileptogênicos*. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.
- Sanei, S., & Chambers, J. A. (2007). *EEG Signal Processing*. England: John Wiley & Sons Ltd.
- Scolaro, G. R. (2009). *Detecção de Eventos Epileptiformes em Sinais de Eletroencefalografia Utilizando Classificador Neural*. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.
- Scolaro, G. R., Azevedo, F. M. (2010). *Classification of Epileptiform Events in Raw EEG Signals using Neural Classifier*. In: The 3rd IEEE International Conference on Computer Science and Information Technology, Chengdu. Proceedings 2010 3rd IEEE International Conference on Computer Science and Information Technology. Beijing,

China: Institute of Electrical and Electronics Engineers, Inc., v. 5. p. 368-372.

Scolaro, G. R., Boos, C. F., Azevedo, F. M. (2011). *Neural Classifier for Detection and Classification of Spikes and Sharp Waves*. In: Biostec 2011 (4^o International Joint Conference on Biomedical Engineering Systems and Technologies), Roma, Itália. Biostec 2011 Final Program and Book of Abstracts. Portugal: SciTePress - Science and Technology Publications, 2011. p. 504-509.

Scolaro, G. R., Azevedo, F. M., Boos, C. F. (2012). *Evaluation of Different Wavelet Functions Applied in the Development of Digital Filters to Attenuate the Background Activity in EEG Signals*. In: World Congress on Medical Physics and Biomedical Engineering, Beijing, China. IFMBE Proceedings, v. 39. p. 340-343.

Scolaro, G. R., Boos, C. F., Azevedo, F. M. ., (2013a). *Wavelet Filter Proposal to Attenuate the Background Activity and High Frequencies in EEG Signals*. In: Biomedical Engineering, Innsbruck, Austria. Biomedical Engineering. Calgary: ACTAPRESS. v. 1. p. 243-249.

Scolaro, G. R., Azevedo, F. M., Boos, C. F., Walz, R. (2013b). *Wavelet Filter to Attenuate the Background Activity and High Frequencies in EEG Signals Applied in the Automatic Identification of Epileptiform Events*. Practical Applications in Biomedical Engineering. 1ed.India: InTech, p. 81-102.

Silva Jr., S. M. (1998). *Sistema Microcontrolado de Estimulação e Análise de Potenciais Evocados para Utilização com Eletroencefalografia Computadorizada*. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.

Silva, M. R. (1998). *ANAMOD - Módulo de controle para o sistema de aquisição e análise de sinais bioelétricos SAASBIO II*. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.

Sörnmo, L., & Laguna, P. (2005). *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. Burlington, MA: Elsevier Academic Press.

- Sovierzoski, M. A. (2009). *Avaliação de Descritores Morfológicos na Identificação de Eventos Epileptiformes*. Tese de Doutorado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.
- Subasi, A. (2007). EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications*, 32, 1084–1093.
- Tarassenko, L., Khan, Y. U., Holt, M. R. G. (1998). “Identification of inter-ictal spikes in the EEG using neural network analysis,” *Inst. Elect. Eng. - Proc. Sci. Meas. Technol.*, vol. 145, no. 6, pp. 270–278.
- Tavares, M. C. (2003). *Aquisição e Processamento de Sinais Bioelétricos Neurofisiológicos Intra-operatórios*. Tese de Doutorado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.
- Toazza, A. L. (1998). *Sistema Microcontrolado para Medição de Impedância Pele-eletrodo em Registradores Bioelétricos*. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.
- Travessa, S. S. (2006). *Análise das Redes Neurais Complexas na Detecção de Espículas e Piscadas em Sinais de EEG*. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Engenharia Elétrica, Florianópolis.
- Tzallas, A. T., Tsipouras, M. G. and Fotiadis, D. I. (2007). Automatic seizure detection based on time-frequency analysis and artificial neural networks. *Computational Intelligence and Neuroscience*.
- Tzallas, A. T., Tsipouras, M. G., Tsalikakis, D. G., Karvounis, E. C., Astrakas, L., Konitsiotis, S., Tzaphlidou, M. (2012). Automated Epileptic Seizure Detection Methods: A Review Study. *Epilepsy - Histological, Electroencephalographic and Psychological Aspects*. InTech.

- Valenti, P., Cazamajou, E., Scar, M., Aizemberg, A., Silva, W., & Kochen, S. (2006). Automatic detection of interictal spikes using data mining models. *Journal of Neuroscience Methods* , 150, 105-110.
- Webber, W. R. S., Lesser, R. P., Richardson, R. T., Wilson, K. (1996). "An approach to seizure detection using an artificial neural network (ANN)," *Electroenceph. Clin. Neurophysiol.*, vol. 98, pp. 250-272.
- Webster, J. (1998). *Medical Instrumentation*. New York: John Wiley and Sons.
- Wilson, S. B., & Emerson, R. (2002). Spike Detection: a review and comparison of algorithms. *Clinical Neurophysiology* , 113, 1873-1881.
- Wiltschko, A. B., Gage, g. J., & Berke, J. D. (2008). Wavelet filtering before spike detection preserves waveform shape and enhances single-unit discrimination. *Journal of Neuroscience Methods* , 173, 34-40.
- Xu, G., Wang, J., Zhang, Q., Zhang, S., & Zhu, J. (2007). A spike detection method in EEG based on improved morphological filter. *Computers in Biology and Medicine* , 37, 1647-1652.

ANEXO A – COMITÊS DE ÉTICA



UNIVERSIDADE FEDERAL DE SANTA CATARINA
Pró-Reitoria de Pesquisa e Extensão
Comitê de Ética na Pesquisa em Seres Humanos

CERTIFICADO Nº 305

O Comitê de Ética na Pesquisa em Seres Humanos (CEPSH) da Pró-Reitoria de Pesquisa e Extensão da Universidade Federal de Santa Catarina, instituído pela PORTARIA N.º584/GR/99 de 04 de novembro de 1999, com base nas normas para a constituição e funcionamento do CEPSH, considerando o conteúdo no Regimento Interno do CEPSH, **CERTIFICA** que os procedimentos que envolvem seres humanos no projeto de pesquisa abaixo especificado estão de acordo com os princípios éticos estabelecidos pela Comissão Nacional de Ética em Pesquisa - CONEP

APROVADO

PROCESSO: 252/08 FR- 229734

TÍTULO: Desenvolvimento de uma Metodologia para a Identificação Automática de Eventos Epileptiformes em Sinais de Eletroencefalografia.

AUTOR: Fernando Mendes de Azevedo, Fernanda Isabel Marques Argoud, Roger Walz e Geovani Rodrigo Scolari.

DPTO.: CTC/UFSC

FLORIANÓPOLIS, 25 de novembro de 2008.

Coordenador do CEPSH/UFSC - Prof.º Washington Portela de Souza



ESTADO DE SANTA CATARINA
SECRETARIA DE ESTADO DA SAÚDE
HOSPITAL GOVERNADOR CELSO RAMOS
COMITÊ DE ÉTICA EM PESQUISA - CEP

PROTOCOLO Nº

2008/0025

DE: COMITÊ DE ÉTICA EM PESQUISA

DATA: 10/10/2008

PARA PESQUISADORES: FERNANDO MENDES DE AZEVEDO ;
GIOVANI RODRIGO SCOLARO

ASSUNTO: PARECER CONSUBSTANCIADO

PROJETO DE PESQUISA: DESENVOLVIMENTO DE UMA METODOLOGIA PARA A IDENTIFICAÇÃO AUTOMÁTICA DE EVENTOS EPILEPTIFORMES EM SINAIS DE ELETROENCEFALOGRAFIA.

PARECER: Trata-se de um projeto de pesquisa para desenvolvimento de uma metodologia para identificação automática de eventos epileptiformes em sinais de eletroencefalografia através da leitura de dados do equipamento de EEG do CEPESC, utilizando técnicas de processamento digital de sinais nos registros de EEG em montagens referencial e bipolar para desenvolver um módulo de treinamento para as redes neurais artificiais o qual deverá apresentar telas para marcação de padrões de treinamento/validação e funções de análise estatística básica para os dados obtidos. Implementar redes neurais artificiais do tipo perceptron Multi-camadas (Multi-Layer Perceptron – MLP) para treinamento do classificador do sistema. Implementar rotinas estatísticas de validação do classificador (Curvas ROC), como forma de garantir e otimizar a convergência do treinamento das redes [8] [9]; Serão estudadas amostras de seis pacientes submetidas a monitorização de EEG. O TCLE atende as normas da Resolução 196/96..

Diante do exposto classificamos o Projeto de Pesquisa como: **APROVADO.**

ORIENTAÇÕES GERAIS: Salientamos a necessidade de encaminhar ao CEP relatórios trimestrais sobre o andamento da pesquisa e ao término do trabalho **uma cópia impressa e uma cópia CD com extensão em PDF (conversor de arquivo Word para PDF)** deverá ser disponibilizada a este Comitê. As alterações no protocolo e notificações de eventos adversos que possam trazer prejuízo ao sujeito da pesquisa devem ser notificadas imediatamente ao CEP para análise e tomadas as devidas providências.

CARLA PAULI

Coordenadora do CEP/Hospital Governador Celso Ramos

