

GEOVANI RODRIGO SCOLARO

**CLASSIFICAÇÃO DE EVENTOS EPILEPTIFORMES
EM SINAIS DE ELETROENCEFALOGRAFIA
UTILIZANDO CLASSIFICADOR NEURAL**

**FLORIANÓPOLIS
2009**

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

**CLASSIFICAÇÃO DE EVENTOS EPILEPTIFORMES
EM SINAIS DE ELETROENCEFALOGRAFIA
UTILIZANDO CLASSIFICADOR NEURAL**

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

GEOVANI RODRIGO SCOLARO

Florianópolis, Novembro de 2009.

CLASSIFICAÇÃO DE EVENTOS EPILEPTIFORMES EM SINAIS DE ELETROENCEFALOGRAFIA UTILIZANDO CLASSIFICADOR NEURAL

GEOVANI RODRIGO SCOLARO

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

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

Profa. Fernanda Isabel Marques Argoud, Dra.
Co-Orientadora

Roberto de Souza Salgado, Ph.D.
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica.

Banca Examinadora:

Fernando Mendes de Azevedo, D.Sc.
Presidente

Fernanda Isabel Marques Argoud, Dra.

José Marino Neto, D.Sc.

Jefferson Luiz Brum Marques, Ph.D.

Rudimar Luís Scaranto Dazzi, Dr.

Giselle Lopes Ferrari, Dra.

DEDICATÓRIA

Dedico este trabalho a minha esposa Milene e ao meu filho Enzo.

AGRADECIMENTOS

À Deus, por tornar possível tudo isso.

À minha esposa Milene Cristina de Andrade, pelo carinho e apoio nos momentos difíceis.

Agradecimentos ao orientador, Prof. Fernando Mendes de Azevedo e a co-orientadora, Profa. Fernanda Isabel Marques Argoud, pela confiança e pelas conversas que proporcionaram o desenvolvimento deste trabalho.

Ao Prof. Marino, pelas sugestões que enriqueceram este trabalho.

Ao Prof. Dr. Marco Aurélio Benedetti Rodrigues da Universidade Federal de Pernambuco (UFPE), pela confiança depositada e por incentivar e insistir para que eu realizasse o mestrado.

Agradecimentos aos colegas e amigos, Vander Vigolo e Márcio Duarte Beppler, pelo companheirismo e os laços de amizade criada.

Agradecimentos aos Neurologistas, Prof. Dr. Roger Walz, diretor do Centro de Epilepsia do Estado de Santa Catarina (CEPESC), localizado no Hospital Governador Celso Ramos em Florianópolis, à Dra. Kátia Lin e Dra. Lúcia Sukis, pelas orientações e esclarecimentos sobre eletroencefalografia e marcações de eventos em sinais de EEG.

Agradecimentos a Sumaia Deguer e a todos os integrantes da equipe do CEPESC, pelo companheirismo e por proporcionar o acompanhamento de todo o processo de monitoramento por Video-EEG, desde a preparação dos pacientes, até a coleta dos sinais de EEG.

A todos os colegas de mestrado, que de uma forma ou de outra, auxiliaram no desenvolvimento deste trabalho e pelas amizades construídas durante este período.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

Obrigado.

PUBLICAÇÕES

Scolaro, Geovani Rodrigo, De Azevedo, Fernando Mendes, Argoud, Fernanda Isabel Marques e Walz, Roger, “Classificador Neural Binário para a Detecção de Eventos Espícula-Onda Em Sinais de EEG”, *Jornadas Chilenas de Computacion*, I Chilean Workshop on Pattern Recognition: Theory and Applications, Chile, 2009.

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

CLASSIFICAÇÃO DE EVENTOS EPILEPTIFORMES EM SINAIS DE ELETROENCEFALOGRAFIA UTILIZANDO CLASSIFICADOR NEURAL

Geovani Rodrigo Scolaro

Novembro/2009

Orientador: Fernando Mendes de Azevedo, D.Sc.

Co-Orientador: Fernanda Isabel Marques Argoud, Dra.

Área de Concentração: Engenharia Biomédica.

Palavras-chave: EEG, Epilepsia, Espículas, Transformada *Wavelet*, Redes Neurais Artificiais, Classificador Neural.

Número de Páginas: 88.

Este trabalho teve como objetivo avaliar a capacidade de um classificador neural de realizar a separação entre eventos epileptiformes e não epileptiformes em sinais de eletroencefalografia. Foram utilizados sinais sem pré-processamento e sinais pré-processados pela função *Wavelet Coiflet 1*, nas entradas da rede neural. A partir dos dados obtidos, foram gerados gráficos contendo a dispersão das cinco classes de eventos (espículas, ondas agudas, piscadas palpebrais, atividade de fundo e ruídos), para cada nível de decomposição da função *Coiflet*. Não foi possível estabelecer uma forma de separação entre os agrupamentos de eventos, utilizando apenas a amplitude do sinal resultante da decomposição de cada nível de detalhe. A rede neural utilizada no classificador é do tipo *Feedforward*, multicamadas, onde foram utilizados 685 eventos para o treinamento, validação e testes. Para a avaliação da rede neural utilizou-se o método da validação cruzada, com parada antecipada. Para o classificador neural foram utilizados a análise ROC e os índices de desempenho aplicados aos testes-diagnóstico. Os experimentos realizados mostraram que a utilização das épocas de treinamento, indicadas pelos índices de desempenho (índices AUC e de eficiência), apresentaram resultados aceitáveis, pois as respectivas épocas indicadas, se localizavam próximos à época indicada pela parada antecipada. A avaliação através destes índices, mostrou ser uma forma eficiente de verificar o desempenho do classificador, o qual alcançou os seguintes valores de desempenho: sensibilidade de 97,14%, especificidade de 94,55%, seletividade positiva de 96,59%, seletividade negativa de 95,41% e uma eficiência (ou número de acertos) de 96,14%.

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

CLASSIFICATION OF EPILEPTIFORM EVENTS IN ELECTROENCEPHALOGRAPHY SIGNALS USING NEURAL CLASSIFIER

Geovani Rodrigo Scolaro

November/2009

Advisor: Fernando Mendes de Azevedo, D.Sc.

Co-Advisor: Fernanda Isabel Marques Argoud, Dra.

Area of Concentration: Biomedical Engineering.

Keywords: EEG, Epilepsy, Spikes, *Wavelet* Transform, Artificial Neural Networks, Neural Classifier.

Number of Pages: 88.

This study evaluated the capability of a neural classifier to perform the separation between epileptiform and non-epileptiform events in electroencephalography signals. It was used signals without pre-processing and pre-processed by the *Wavelet* function *Coiflet 1*, as inputs of the network. From the obtained data, graphs were generated containing the spread of the five event classes (spikes, sharp waves, blink, background activity and noise) at each decomposition level of the function *Coiflet 1*. It was not possible to establish a form of separation between groups of events, using only the amplitude of the signal resulting from the decomposition of each detail level. The neural network used in the classifier was Feedforward, multilayer, where were used 685 events for training, validation and testing. For the evaluation of the neural network was used the cross-validation method with early stopping. For the evaluation of the neural classifier was used ROC analysis and performance indices applied to diagnostic tests. The experiments have shown that the use of epochs of training, indicated by performance indices (AUC and Accuracy), showed acceptable results, due the fact that the indicated epochs were located close to the epoch indicated by the early stopping. The evaluation of these indices could be an efficient way to verify the performance of the classifier, which achieved the following performance figures: a sensitivity of 97,14%, specificity of 94,55%, positive selectivity of 96,59%, negative selectivity of 95,41% and Accuracy of 96,14%.

SUMÁRIO

| | |
|--|----------|
| 1. Introdução | 1 |
| 1.1 Motivação..... | 1 |
| 1.2 Justificativa | 3 |
| 1.3 Objetivos | 4 |
| 2. Fundamentação Teórica..... | 5 |
| 2.1 Eletroencefalografia | 5 |
| 2.1.1 Aplicações da Eletroencefalografia | 5 |
| 2.1.2 Origem dos Sinais Elétricos Encefálicos | 6 |
| 2.1.3 Ritmos Cerebrais | 7 |
| 2.1.4 Posicionamento dos Eletrodos e Nomenclatura | 8 |
| 2.1.5 Sistema de Referência dos Sinais de Eletroencefalografia..... | 9 |
| 2.2 Epilepsia..... | 10 |
| 2.2.1 Elementos Eletrográficos da Epilepsia | 10 |
| 2.2.2 Classificação das Crises Epilépticas..... | 12 |
| 2.3 Histórico de Pesquisas no IEB-UFSC..... | 14 |
| 2.4 A Transformada <i>Wavelet</i> | 16 |
| 2.4.1 A Transformada <i>Wavelet</i> Discreta..... | 17 |
| 2.4.2 A Transformada <i>Wavelet</i> Rápida..... | 17 |
| 2.5 Rede Neural Artificial – <i>Perceptron</i> Multicamadas | 21 |
| 2.5.1 O Neurônio Artificial..... | 22 |
| 2.5.2 Funções de Ativação..... | 23 |
| 2.5.3 Rede <i>Perceptron</i> Multicamadas com Algoritmo <i>Backpropagation</i> | 25 |
| 2.6 Validação Cruzada | 25 |
| 2.7 Parada Antecipada..... | 26 |

| | |
|--|-----------|
| 2.8 Avaliação do Desempenho..... | 27 |
| 2.8.1 Sensibilidade e Especificidade | 28 |
| 2.8.2 Valor Preditivo Positivo (VPP) e Valor Preditivo Negativo (VPN)..... | 29 |
| 2.8.3 Eficiência | 30 |
| 2.9 Curvas ROC | 30 |
| 2.9.1 Índice Área Abaixo da Curva ROC (<i>AUC – Area Under the Curve</i>)..... | 31 |
| 3. Metodologia..... | 32 |
| 3.1 Introdução | 32 |
| 3.2 Visão Geral do Trabalho | 32 |
| 3.3 Banco de Sinais de EEG | 34 |
| 3.4 Marcação dos Sinais de EEG | 35 |
| 3.5 Arquivos dos Padrões de EEG | 36 |
| 3.6 Arquivos dos Conjuntos de Padrões de EEG..... | 37 |
| 3.7 Investigação dos Sinais de EEG através da Transformada <i>Wavelet</i> | 40 |
| 3.8 Investigação dos Sinais de EEG através de Redes Neurais Artificiais | 41 |
| 4. Resultados | 48 |
| 4.1 Avaliação dos Sinais de EEG Através da Transformada <i>Wavelet</i> | 48 |
| 4.1.1 Dispersão de eventos | 48 |
| 4.1.2 Deslocamento dos Eventos no Tempo..... | 60 |
| 4.2 Avaliação dos Sinais de EEG Utilizando Redes Neurais Artificiais | 65 |
| 5. Discussões e Conclusão..... | 75 |
| 5.1 Discussões | 75 |
| 5.2 Conclusão..... | 78 |
| 6. Trabalhos Futuros | 80 |
| ANEXO A – Parecer do Comitê de Ética em Pesquisas com Seres Humanos da Universidade Federal de Santa Catarina | 81 |
| ANEXO B – Parecer do Comitê de Ética em Pesquisas com Seres Humanos do Hospital Governador Celso Ramos..... | 83 |

LISTA DE FIGURAS

| | |
|---|----|
| Figura 1 – Estrutura de um Neurônio. | 6 |
| Figura 2 – Exemplos de ritmos cerebrais presentes nos sinais de EEG. | 8 |
| Figura 3 – Colocação de eletrodos no sistema 10-20, nas visões (a) temporal e (b) parietal. | 9 |
| Figura 4 – Registro de potenciais nas formas (a) bipolar e (b) referencial. | 9 |
| Figura 5 – Realizações de espículas seguidas por uma onda lenta, com durações de 55 ms (a) e 69 ms em (b). | 11 |
| Figura 6 – Representação de ondas agudas seguidas por uma onda lenta, com durações de 103 ms (a) e 91 ms em (b). | 11 |
| Figura 7 – Propagação de uma espícula registrada através de 123 eletrodos no escalpo.... | 12 |
| Figura 8 – Processo de filtragem do <i>signal</i> (<i>S</i>) empregado pela FWT, onde são obtidos os níveis de <i>Aproximação</i> (<i>A</i>) e <i>Detalhe</i> (<i>D</i>). | 18 |
| Figura 9 – Aplicação de Filtros Multiresolução 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. | 18 |
| Figura 10 – Acima e à esquerda o sinal original, posteriormente decomposto em 3 níveis através de FWT, componente de detalhe 1 (cd_1), componente de detalhe 2 (cd_2), componente de detalhe 3 (cd_3) e aproximação 3 (ca_3). À direita e de baixo para cima: sinal reconstituído a partir de cd_1 , sinal reconstituído a partir de cd_2 , sinal reconstituído a partir de cd_3 e sinal reconstituído a partir da ca_3 . (modificado de Argoud, 2001) | 19 |
| Figura 11 – Neurônio artificial e suas entradas, pesos sinápticos, junção aditiva e função de ativação. | 22 |
| Figura 12 – Funções de ativação unipolares. | 24 |
| Figura 13 – Funções de ativação bipolares. | 24 |
| Figura 14 – Representação do comportamento das curvas de erro de treinamento e validação. | 26 |
| Figura 15 – Representação do ponto de ocorrência da parada antecipada. | 27 |
| Figura 16 – Exemplo de Curvas ROC. | 31 |
| Figura 17 – Cada época de sinal é direcionada para a Transformada Wavelet onde é analisada, caso o sinal gerado apresente uma morfologia característica para eventos epileptiformes, a época analisada é direcionada para o classificador neural. | 33 |
| Figura 18 – Traçado característico utilizando a montagem referencial do equipamento.... | 34 |
| Figura 19 – Marcação do evento mais eletronegativo ($-125,2 \mu V$), identificado no canal Ft10. | 36 |

| | |
|--|----|
| Figura 20 – Exemplo de eventos de cada uma das classes definidas: (a) espículas (20-70ms), (b) ondas agudas (71-200ms), (c) piscadas palpebrais, (d) atividade de fundo e (e) ruído. | 37 |
| Figura 21 – Representação de todos os eventos selecionados para o conjunto de treinamento. | 38 |
| Figura 22 – Representação de todos os eventos selecionados para o conjunto de validação. | 39 |
| Figura 23 – Representação de todos os eventos selecionados para o conjunto de testes. ... | 39 |
| Figura 24 – Representação da utilização da Transformada Wavelet como forma de pré-processamento das épocas de sinal de EEG. | 40 |
| Figura 25 – Representação da utilização do classificador neural na classificação dos eventos epileptiformes e não epileptiformes das épocas de sinal de EEG analisadas. | 42 |
| Figura 26 – (a) Gráfico de sensibilidade e especificidade e (b) gráfico de seletividade positiva e seletividade negativa, todos em função do limiar de decisão. Foi utilizado um incremento de limiar de decisão de 0,02, gerando 51 pontos no gráfico. | 46 |
| Figura 27 – (a) Gráfico da eficiência em função do limiar de decisão, para uma determinada época e em (b) a curva ROC, também para uma determinada época de treinamento. | 47 |
| Figura 28 – Exemplo de um evento decomposto pelos níveis de detalhe (1 a 10) da função <i>Coiflet 1</i> | 48 |
| Figura 29 – Valor máximo absoluto de cada nível de detalhe, os quais foram utilizados para gerar os gráficos de dispersão de eventos (indicação em vermelho apenas dos níveis de decomposição 5, 7 e 8). | 49 |
| Figura 30 – Dispersão de eventos a partir da função <i>Coiflet 1</i> para o nível de decomposição 1. | 50 |
| Figura 31 – Dispersão de eventos a partir da função <i>Coiflet 1</i> para o nível de decomposição 2. | 51 |
| Figura 32 – Dispersão de eventos a partir da função <i>Coiflet 1</i> para o nível de decomposição 3. | 52 |
| Figura 33 – Dispersão de eventos a partir da função <i>Coiflet 1</i> para o nível de decomposição 4. | 53 |
| Figura 34 – Dispersão de eventos a partir da função <i>Coiflet 1</i> para o nível de decomposição 5. | 54 |
| Figura 35 – Dispersão de eventos a partir da função <i>Coiflet 1</i> para o nível de decomposição 6. | 55 |
| Figura 36 – Dispersão de eventos a partir da função <i>Coiflet 1</i> para o nível de decomposição 7. | 56 |
| Figura 37 – Dispersão de eventos a partir da função <i>Coiflet 1</i> para o nível de decomposição 8. | 57 |

| | |
|---|----|
| Figura 38 – Dispersão de eventos a partir da função <i>Coiflet 1</i> para o nível de decomposição 9. | 58 |
| Figura 39 – Dispersão de eventos a partir da função <i>Coiflet 1</i> para o nível de decomposição 10. | 59 |
| Figura 40 – (a) Ocorrência de eventos no final no instante de tempo, (b) ocorrência de eventos no meio do instante de tempo. | 61 |
| Figura 41 – Deslocamento de uma espícula no tempo (evento original). | 62 |
| Figura 42 – Deslocamento de uma espícula no tempo (evento deslocado 10 amostras).... | 62 |
| Figura 43 – Deslocamento de uma espícula no tempo (evento deslocado 20 amostras).... | 63 |
| Figura 44 – Deslocamento de uma espícula no tempo (evento deslocado 30 amostras).... | 63 |
| Figura 45 – Deslocamento de uma espícula no tempo (evento deslocado 40 amostras).... | 64 |
| Figura 46 – Deslocamento de uma espícula no tempo (evento deslocado 50 amostras).... | 64 |
| Figura 47 – Representação dos Erros Médios Quadráticos de Treinamento e de Validação em função de épocas de treinamento para o classificador de eventos epileptiformes. | 66 |
| Figura 48 – (a) Sensibilidade e especificidade em função do limiar de decisão e em (b) valor preditivo positivo e valor preditivo negativo em função do limiar de decisão para a época 513 de treinamento do classificador neural de eventos epileptiformes. | 67 |
| Figura 49 – Curva dos índices de eficiência calculada em função do limiar de decisão para a época 513 do classificador de eventos epileptiformes. | 68 |
| Figura 50 – Curva ROC para a época 513 de treinamento do classificador neural de eventos epileptiformes. | 68 |
| Figura 51 – Desempenho do índice AUC em função da época de treinamento. | 70 |
| Figura 52 – Desempenho do índice de eficiência em função da época de treinamento. | 70 |
| Figura 53 – Representação do teste realizado com o conjunto de padrões de teste, através da seleção da época 513 (Máximo Índice AUC) de treinamento do classificador neural. | 71 |
| Figura 54 – Representação do teste realizado com o conjunto de padrões de teste, através da seleção da época 312 (Máximo Índice de Eficiência) de treinamento do classificador neural. | 72 |
| Figura 55 – Representação do teste realizado com o conjunto de padrões de teste, através da seleção da época 530 (Parada Antecipada) de treinamento do classificador neural. | 73 |

LISTA DE TABELAS

| | |
|--|----|
| Tabela 1 – Classificação das Epilepsias pela Liga Internacional contra a Epilepsia. | 13 |
| Tabela 2 – Filtros ortogonais de decomposição Wavelet para a família <i>Coiflet 1</i> | 21 |
| Tabela 3 – Tabela de contingência. | 28 |
| Tabela 4 – Representação dos eventos selecionados para cada conjunto de eventos. | 38 |
| Tabela 5 – A tabela de contingência adaptada para as classes de eventos epileptiformes e não epileptiformes e o exame sendo o classificador neural. | 44 |
| Tabela 6 – Pontos característicos da curva ROC para a época 513 de treinamento do classificador neural de eventos epileptiformes. | 69 |
| Tabela 7 – Comparação dos resultados obtidos entre as épocas de treinamento da rede neural. | 74 |

LISTA DE ABREVIATURAS

| | |
|-----------------------------|---|
| μV | Micro volts |
| ms | Milissegundos |
| AUC | <i>Area Under the Curve</i> |
| CEPESC | Centro de Epilepsia do Estado de Santa Catarina |
| DWT | <i>Discrete Wavelet Transform</i> |
| EEG | Eletroencefalografia de Superfície |
| $\text{EMQ}_{\text{Trein}}$ | Erro Médio Quadrático de Treinamento |
| $\text{EMQ}_{\text{Valid}}$ | Erro Médio Quadrático de Validação |
| FWT | <i>Fast Wavelet Transform</i> |
| FP | Falso-Positivo |
| FN | Falso-Negativo |
| 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 |
| IEB | Instituto de Engenharia Biomédica |
| MLP | <i>Multi-layer Perceptron</i> |
| RNA | Rede Neural Artificial |
| ROC | <i>Receiver Operating Characteristic</i> |
| TW | Transformada <i>Wavelet</i> |
| UFSC | Universidade Federal de Santa Catarina |
| VP | Verdadeiro-Positivo |
| VN | Verdadeiro-Negativo |

1. INTRODUÇÃO

1.1 Motivação

A Epilepsia é uma condição crônica, ou um grupo de doenças, de alta prevalência e, no entanto, ainda pouco explicada pela ciência (Guerreiro e Guerreiro, 1993). Já o registro do sinal de eletroencefalograma (EEG) é considerado um exame essencial para investigação das epilepsias, pois serão encontradas alterações eletrográficas significativas nos registros de EEG de pacientes epiléticos (Sörnmo e Laguna, 2005) (Pillai e Sperling, 2006).

A análise visual dos sinais de EEG ainda é amplamente realizada pelos especialistas, como apoio ao processo de diagnóstico da Epilepsia. Pode ser utilizado para confirmar o diagnóstico, auxiliar na definição do tipo de síndrome epilética, fornecer informação para planejamento da terapia medicamentosa e ainda para ajudar na decisão sobre viabilidade de cirurgia (Pillai e 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 (Guerreiro e Guerreiro, 1993) (Pillai e Sperling, 2006). A principal diferença morfológica entre tais eventos, reside na duração de cada um deles, sendo que para as espículas a duração fica entre 20 e 70 ms. Para as ondas agudas a duração fica entre 70 e 200 ms (Sörnmo e Laguna, 2005) (Guerreiro e Guerreiro, 1993).

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

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

Dentre os vários paroxismos não epileptiformes, isto é, que mais geram falsos positivos na detecção automática de eventos epileptiformes, pode-se destacar o ruído de alta frequência, a atividade alfa e, principalmente, os movimentos oculares e piscadas, por serem muito frequentes em sinais de EEG e por apresentarem morfologias bastante semelhantes às das espículas e ondas agudas. A baixa especificidade¹ também ocorre porque os sinais de EEG variam de paciente para paciente; porque variam, no mesmo paciente, sob diferentes estados de consciência e comportamentais; e porque os tipos de descargas variam de síndrome para síndrome epiléptica. Assim, é difícil estabelecer-se um modelo computacional adequado de paroxismo epileptiforme, para que seja possível diferenciá-lo 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; pelo grande número de fontes de artefatos; pela baixa relação sinal-ruído captada no escalpo e porque, em alguns tipos de Epilepsia, os eventos epileptiformes e crises podem ser muito raros ou “disparados” apenas sob circunstâncias especiais, tais como fotoestimulação, hiperventilação, sono, etc.

No caso dos registros de EEG de longa duração (ou EEG de “Longo Termo” - registros com duração prolongada, de horas a semanas), onde aumenta a probabilidade de se encontrar espículas caso o paciente seja epiléptico, a especificidade dos sistemas torna-se mais importante que a sensibilidade. Apesar disto, a maioria dos sistemas automáticos propostos até o presente não conseguem comprovar terem atingido uma taxa de falso-positivos por minuto (FP/min) aceitável (Wilson e Emerson, 2002).

Este trabalho pretende contribuir para o processo de automatização do diagnóstico da epilepsia, verificando a viabilidade da utilização da Transformada *Wavelet*, como ferramenta de processamento de sinais e a capacidade das redes neurais atuarem como classificadores neurais, no processo de classificação de eventos epileptiformes e não epileptiformes em sinais de EEG. Os resultados foram avaliados, utilizando a análise ROC (*Receiver Operating Characteristic*) e índices de desempenho aplicados aos testes-diagnóstico.

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 (Guerreiro e Guerreiro, 1993). O processo de identificação de tais eventos é realizado por um especialista, devidamente treinado e experiente. Tal tarefa é um processo lento, repetitivo, passível de cansaço físico e mental, devido ao fato dos registros de EEG apresentarem um elevado volume de informações.

Este projeto foi desenvolvido através de uma parceria entre o Instituto de Engenharia Biomédica (IEB) da Universidade Federal de Santa Catarina (UFSC) e o Centro de Epilepsia do Estado de Santa Catarina (CEPESC) do Hospital Governador Celso Ramos (HGCR). Tal parceria foi firmada, levando em consideração, a experiência adquirida na área de processamento de sinais de EEG, através das pesquisas realizadas no IEB e as metodologias desenvolvidas ao longo de uma década, na implementação de ferramentas para o auxílio ao diagnóstico da epilepsia. Dessa forma, o CEPESC forneceu sinais de pacientes submetidos à internação e todo o suporte necessário para o entendimento do procedimento de detecção e contagem de eventos epileptiformes.

Devido às dificuldades envolvidas no processo manual de identificação e contagem de eventos epileptiformes no exame de EEG, este projeto apresenta como proposta o desenvolvimento de uma metodologia computacional, que possa contribuir com o desenvolvimento de ferramentas que auxiliem o diagnóstico da epilepsia.

Neste projeto são abordadas duas ferramentas, as quais foram utilizadas no desenvolvimento de uma metodologia computacional de detecção de eventos epileptiformes em sinais de EEG. São elas a Transformada *Wavelet* e as Redes Neurais Artificiais.

A Transformada *Wavelet* foi empregada devido a sua ampla utilização no reconhecimento automático de eventos epileptiformes e por ser adequada ao tratamento de sinais estocásticos que contenham grande número de transientes e por dispor de um algoritmo rápido e de implementação simples (Argoud, 2001). A Transformada *Wavelet* é capaz de ressaltar os eventos epileptiformes, em relação às demais atividades presentes no

sinal de EEG. Porém, não é suficiente para o reconhecimento automático de tais eventos, devido à grande variabilidade dos mesmos. Ou seja, eventualmente a Transformada *Wavelet* pode ressaltar eventos não epileptiformes, o que aumenta a taxa de detecções falso-positivas. Para minimizar este problema, optou-se em utilizar Redes Neurais Artificiais para o reconhecimento propriamente dito dos padrões epileptiformes.

A definição da base *Wavelet* adequada neste estudo foi tomada considerando-se os resultados obtidos na tese defendida por Argoud (2001), seguindo uma das linhas de pesquisas adotadas pelo Instituto de Engenharia Biomédica.

1.3 Objetivos

O objetivo geral deste trabalho é desenvolver um classificador neural para a classificação de eventos epileptiformes e não epileptiformes em sinais de EEG.

Para atingir o objetivo geral do trabalho é necessário realizar alguns objetivos específicos:

- ✓ Gerar os arquivos de eventos epileptiformes e não epileptiformes a partir das marcações dos neurologistas do CEPESC;
- ✓ Formar os conjuntos de padrões de eventos para o treinamento, validação e testes da rede neural com os arquivos de eventos gerados;
- ✓ Implementar 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 junto à rede neural para avaliar o seu comportamento no momento do treinamento;
- ✓ Utilizar a análise ROC e índices de desempenho como forma de avaliar a melhor rede neural para o classificador neural;
- ✓ Utilizar a Transformada *Wavelet* para pré-processar os sinais de EEG aplicados ao classificador neural; e
- ✓ Avaliar os resultados obtidos pelo classificador neural implementado.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 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 que facilita com 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).

2.1.1 Aplicações da Eletroencefalografia

O exame de eletroencefalografia é utilizado como: 1) Exame complementar para o diagnóstico da epilepsia (Sörnmo e Laguna, 2005) (Pillai e Sperling, 2006); 2) Exame complementar na identificação de distúrbios do sono (Sörnmo e Laguna, 2005); 3) Exame para o diagnóstico de morte encefálica (Luccas *et al.*, 1998); e 4) Desenvolvimento de interfaces cérebro-computador (Sörnmo e Laguna, 2005).

No auxílio ao diagnóstico da epilepsia, o EEG ambulatorial normalmente apresenta uma duração de aproximadamente 30 minutos, utilizando de 8 a 32 canais. Havendo dificuldades em determinar a localização do foco epiléptico, há a necessidade de se realizar uma monitoração de longo termo. O paciente então é internado na clínica, onde os registros são obtidos durante semanas. Além do registro de EEG, é feita uma monitoração contínua do paciente, através de câmeras de vídeo, as quais registram as possíveis ocorrências de

crises epilépticas e o comportamento patológico associado à epilepsia (Guerreiro e Guerreiro, 1993).

2.1.2 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 1).

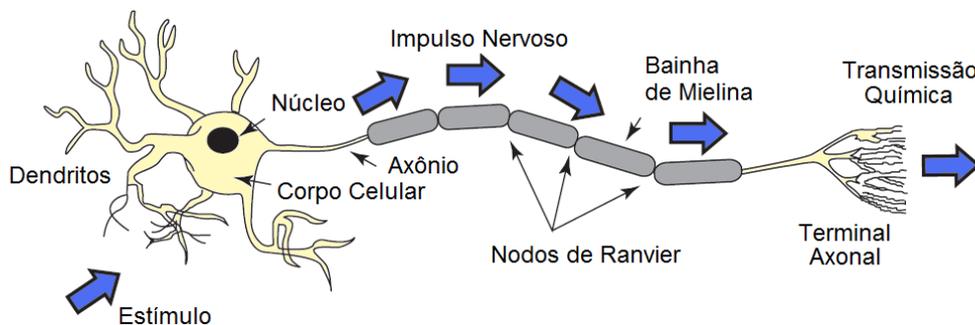


Figura 1 – Estrutura de um Neurônio.

(modificado de Sanei e Chambers, 2007)

As correntes são geradas principalmente através do bombeamento dos íons positivos de sódio (Na^+), potássio (K^+), cálcio (Ca^{2+}) 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, 2002) (Sanei e Chambers, 2007).

A diferença de potenciais elétricos é obtida através dos potenciais pós-sinápticos, gerados por células piramidais, os quais criam dipolos elétricos entre o soma (corpo de um neurônio) e os dendritos (responsáveis por levar informações ao corpo celular) (Bear, 2002).

Por existir várias camadas de tecido na cabeça (couro cabeludo, ossos, superfície externa do córtex), ocorre uma atenuação nos potenciais gerados. Somente grandes

populações de neurônios ativos podem gerar potenciais fortes o bastante, para serem registrados utilizando eletrodos no couro cabeludo. Estes potenciais são depois amplificados para fins de exibição (Sanei e Chambers, 2007).

2.1.3 Ritmos Cerebrais

No sinal de EEG é possível fazer uma distinção entre os ritmos da atividade cerebral pelas faixas de frequência associadas a cada um deles. Os termos que descrevem as ondas *alfa* e *beta* foram inicialmente introduzidas por Berger (1929) (Niedermeyer e Silva, 2004).

As ondas *delta* caracterizam-se pela faixa de frequências de 0,5 a 3Hz apresentam elevadas amplitudes (até 300 μ 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 e Silva, 2004).

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

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

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

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

Alguns dos ritmos cerebrais típicos são apresentados na Figura 2.

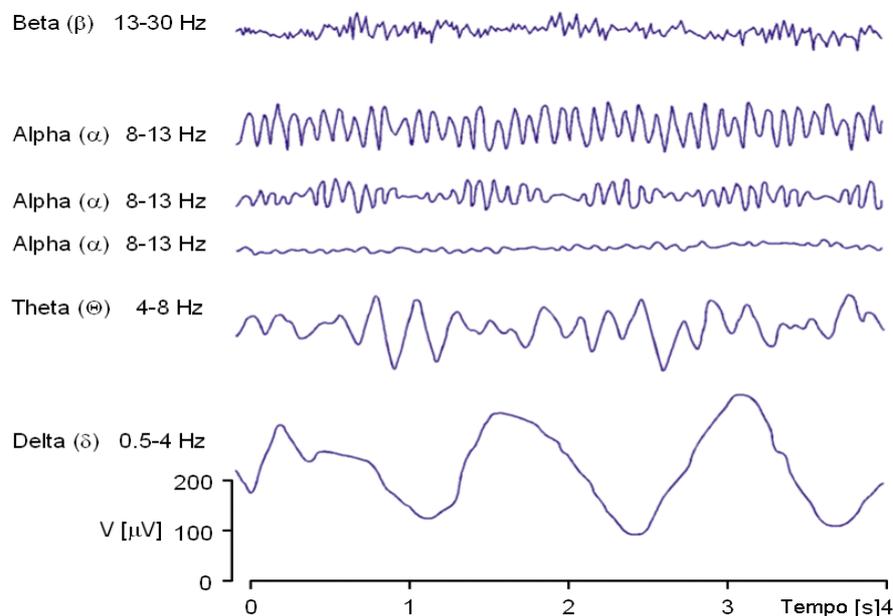


Figura 2 – Exemplos de ritmos cerebrais presentes nos sinais de EEG.

(modificado de Malmivuo e Plonsey, 1995)

2.1.4 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, o qual passou a ser chamado Sistema Internacional de Posicionamento de Eletrodos 10–20 (Figura 3). 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 nábio e o ínio, os eletrodos são identificados com a letra “C”, sendo que na linha imaginária que liga o nábio 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 nariz são acrescentados da letra “p” minúscula (Malmivuo e Plonsey, 1995) (Webster, 1998).

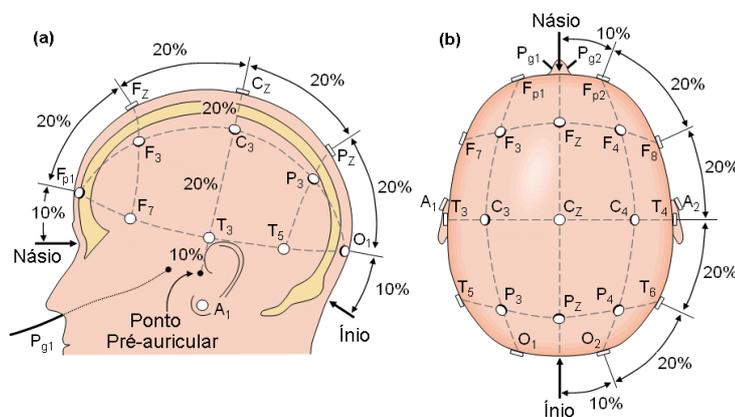


Figura 3 – Colocação de eletrodos no sistema 10-20, nas visões (a) temporal e (b) parietal.

(modificado de Malmivuo e Plonsey, 1995)

2.1.5 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 4a). No método referencial o potencial de cada eletrodo é comparado com um eletrodo de referência ou à média de todos os eletrodos (Figura 4b) (Webster, 1998).

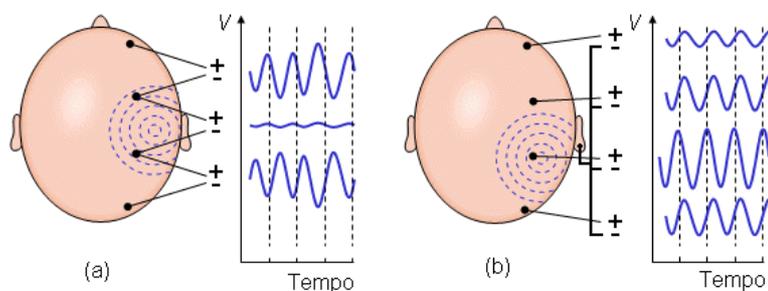


Figura 4 – Registro de potenciais nas formas (a) bipolar e (b) referencial.

(modificado de Malmivuo e Plonsey, 1995)

Na Figura 4(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 4(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 (Sanei e 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.

2.2 Epilepsia

A epilepsia é uma condição crônica, ou um grupo de doenças que tem em comum, crises epiléticas que ocorrem na ausência de doença tóxico-metabólica ou febril (Guerreiro e Guerreiro, 1993).

Crises epiléticas são crises que refletem disfunção temporária de uma pequena parte do cérebro (crises focais) ou de uma área mais extensa envolvendo os dois hemisférios cerebrais (crises generalizadas). Uma crise epilética é uma descarga anormal excessiva e transitória das células nervosas do cérebro, sendo que os sintomas dependem das partes do cérebro afetadas (Guerreiro e Guerreiro, 1993).

2.2.1 Elementos Eletrográficos da Epilepsia

A espícula e a onda aguda são padrões eletrográficos distintos que podem aparecer no EEG, os quais indicam a possibilidade do indivíduo apresentar epilepsia.

A espícula (Figura 5) é um potencial rápido, com formas de onda transitórias, as quais se destacam da atividade de fundo do EEG. A espícula é um evento polifásico, com a fase negativa mais proeminente, com duração entre 20 e 70 ms e geralmente seguida por uma pós-descarga única de onda lenta.

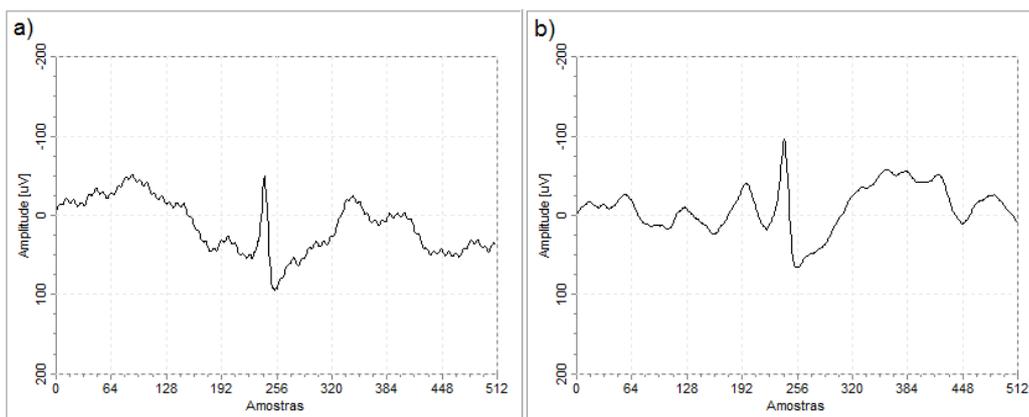


Figura 5 – Realizações de espículas seguidas por uma onda lenta, com durações de 55 ms (a) e 69 ms em (b).

A onda aguda (Figura 6) apresenta um potencial mais lento que a espícula, com formas de onda transitórias, as quais se destacam da atividade de fundo do EEG. A onda aguda é um evento polifásico, com a fase negativa mais proeminente, com duração entre 70 e 200 ms e geralmente seguida por uma pós-descarga única de onda lenta (Guerreiro e Guerreiro, 1993).

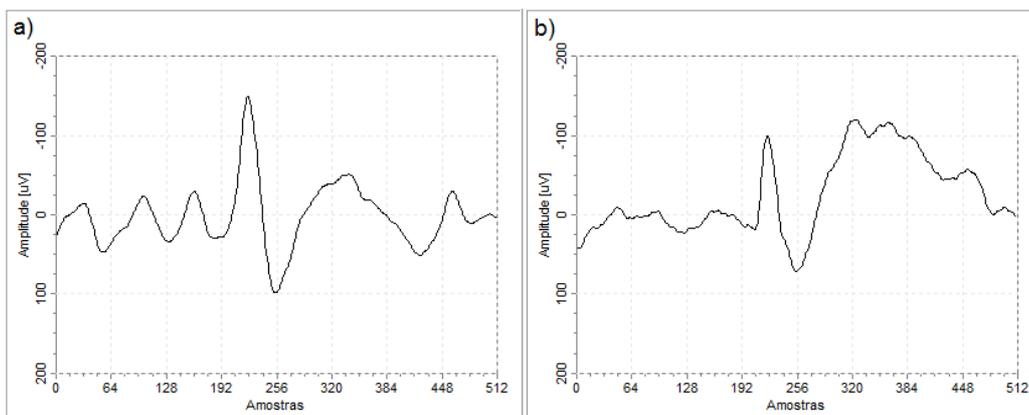


Figura 6 – Representação de ondas agudas seguidas por uma onda lenta, com durações de 103 ms (a) e 91 ms em (b).

A Figura 7 apresenta a propagação de uma espícula, registrada através de 123 eletrodos posicionados no escalpo. Pode-se observar que a máxima amplitude ocorreu nos eletrodos frontais direitos. Houve um amortecimento da propagação nos eletrodos

temporais direitos e centrais, aparecendo novamente com uma amplitude mediana, nos eletrodos temporais esquerdos, parietais e occipitais.

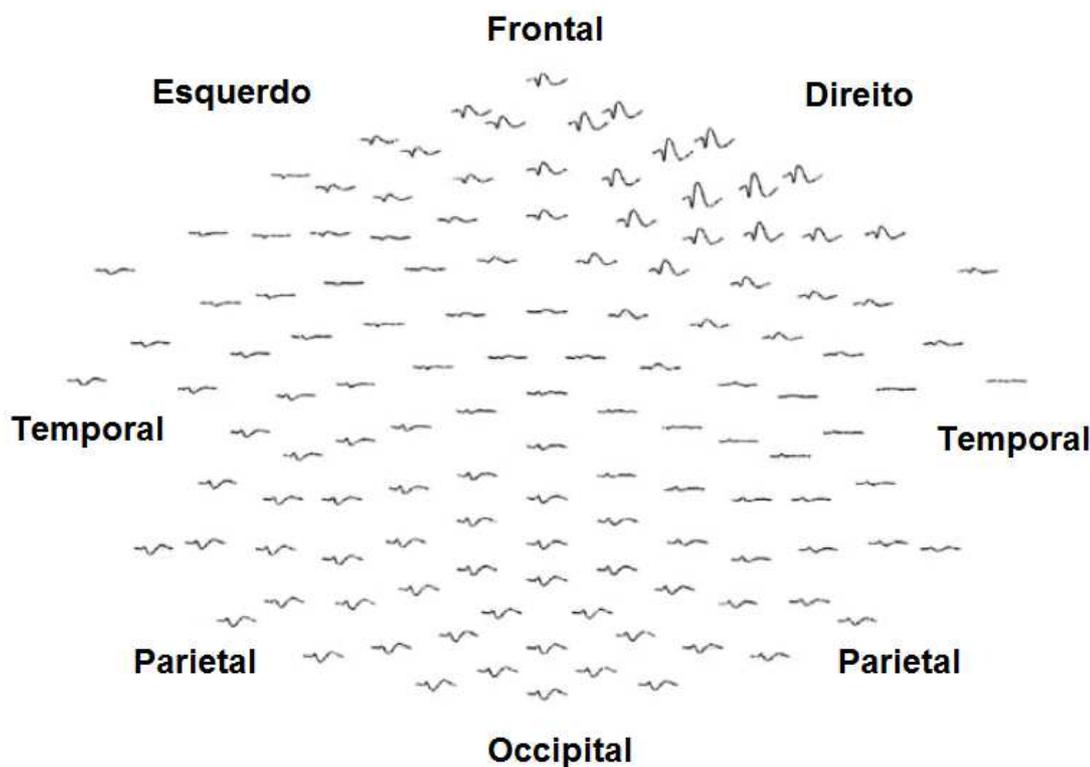


Figura 7 – Propagação de uma espícula registrada através de 123 eletrodos no escalpo.

(modificado de Michel *et al.*, 2004)

2.2.2 Classificação das Crises Epilépticas

A *International League against Epilepsy* (ILAE) contribuiu através do estabelecimento das classificações e da padronização das terminologias para crises epilépticas e síndromes.

A classificação das crises e das síndromes epilépticas fornece, tanto para pacientes quanto para profissionais da área de saúde, o conhecimento sobre epilepsia. Este sistema de classificação (Tabela 1) auxilia profissionais na identificação de tipos de epilepsia e dá competência para fornecer tratamentos apropriados (ILAE, 1989).

Tabela 1 – Classificação das Epilepsias pela Liga Internacional contra a Epilepsia.**1. Síndromes e Epilepsias Localizadas (locais, focais, parciais)**

1.1. Idiopática (início relacionado à idade)

- Epilepsia benigna da infância com espícula contra temporal
- Epilepsia da infância com paroxismos occipitais
- Epilepsia primária da leitura

1.2. Sintomática

- Epilepsia parcial contínua progressiva crônica
- Síndromes com quadros específicos de manifestação
 - Epilepsia lobo temporal
 - Epilepsia lobo frontal
 - Epilepsia lobo parietal
 - Epilepsia lobo occipital

1.3. Criptogênicas

2. Síndromes e Epilepsias Generalizadas

2.1. Idiopáticas

- Convulsão familiar neonatal benigna
- Convulsão neonatal benigna
- Epilepsia mioclônica benigna do lactante
- Epilepsia ausência da infância
- Epilepsia ausência juvenil
- Epilepsia ausência mioclônica
- Epilepsia com crises tônico-clônicas ao despertar
- Outras epilepsias idiopáticas generalizadas
- Epilepsias desencadeadas por modos específicos de ativação

2.2. Criptogênicas ou sintomática

- Síndrome de West
- Síndrome de Lennox-Gastaut
- Epilepsia com crises mioclônicas-astáticas
- Epilepsia com ausências mioclônicas

2.3. Sintomáticas

2.3.1 Etiologia inespecífica

- Encefalopatia mioclônica precoce
- Encefalopatia epiléptica infantil precoce com surto-supressão

| |
|--|
| • Outras epilepsias generalizadas sintomáticas |
| 2.3.2 Síndromes específicas |
| • Crises epiléticas complicando outras doenças |
| 3. Síndromes e Epilepsias Indeterminadas se focais ou generalizadas |
| 3.1. Com crises focais e generalizadas |
| • Crises neonatais |
| • Epilepsia mioclônica severa do lactante |
| • Epilepsia com espícula-onda lenta contínua durante o sono lento |
| • Afasia epilética adquirida |
| • Outras epilepsias indeterminadas |
| 3.2. Crises não caracterizadas como focais ou generalizadas |
| 4. Síndromes Especiais |
| 4.1. Crises circunstanciais |
| • Convulsões febris |
| • Crises isoladas ou estado de mal isolado |
| • Crises ocorrendo somente em evento tóxico ou metabólico |

2.3 Histórico de Pesquisas 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 Jr., 1998), (Silva, 1998), (Bertemes, 1998).

Em sua tese de doutorado Argoud (2001), verificou através de experimentos realizados, que a função *Wavelet Coiflet 1* é a mais adequada para a análise de eventos epileptiformes em sinais de EEG e desenvolveu um sistema híbrido, composto por um módulo detector e um módulo classificador de eventos epileptiformes em sinais de EEG. O módulo detector era composto pela Transformada *Wavelet* e por quatro redes neurais artificiais. O módulo classificador recebia as saídas das redes neurais e a partir de um sistema baseado em regras de produção, realizava a identificação e a classificação dos eventos epileptiformes.

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.

Como tese de doutorado Pereira (2003) 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*.

Em sua dissertação de mestrado, Sala (2005) desenvolveu um trabalho utilizando Mapas de Kohonen na detecção de eventos epileptiformes em sinais de EEG.

Travessa (2006) realizou a análise de redes neurais complexas na detecção de espículas e piscadas em sinais de EEG, como dissertação de mestrado.

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 na identificação de eventos epileptiformes.

2.4 A Transformada *Wavelet*

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* (Equação 1) (Mallat, 1999).

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

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, temos:

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

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

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

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

2.4.1 A Transformada *Wavelet* Discreta

A Transformada *Wavelet* Contínua utiliza os parâmetros de variação do tempo e escalas contínuas. No entanto, na prática, para 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 DWT (*Discrete Wavelet Transform*), descrita pela Equação 5 (Mallat, 1999).

$$DWT(a, b) = \frac{1}{\sqrt{a_0^i}} \int_{-\infty}^{\infty} x(t) \cdot \psi^* \left(\frac{t - kb_0 a_0^i}{a_0^i} \right) dt \quad \text{Equação (5)}$$

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

2.4.2 A Transformada *Wavelet* Rápida

A Transformada *Wavelet* rápida permite uma implementação computacionalmente veloz da transformada *Wavelet* discreta. O algoritmo da Transformada *Wavelet* rápida (FWT) implementa a decomposição de um sinal discreto utilizando bancos de filtros espelho multirresolução em quadratura. Isto é, um conjunto de filtros $H(n)$ que extraem as características médias, definidas como *Aproximações* do sinal (S), sendo somados a um conjunto de filtros $G(n)$ baseados nas funções *Wavelets*, que extraem as características de alta freqüência, definidas como *Detalhes* do sinal (S) (Figura 8). As *Aproximações* são as componentes de alta escala e baixas freqüências do sinal (S) e os *Detalhes* são as componentes de baixa escala e alta freqüência (Argoud, 2001).

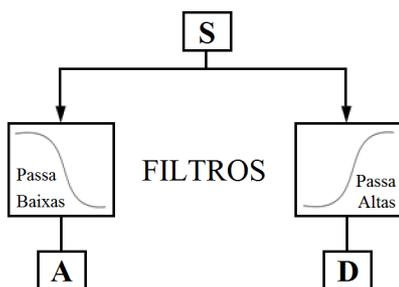


Figura 8 – Processo de filtragem do *signal* (*S*) empregado pela FWT, onde são obtidos os níveis de *Aproximação* (*A*) e *Detalhe* (*D*).

A Figura 9 generaliza a forma de obtenção destas *Aproximações* (*A*) e os *Detalhes* (*D*) utilizando um processo básico de filtragem de um *signal* (*S*), onde para cada nível de decomposição, o sinal é subamostrado ou decimado, normalmente por um fator 2.

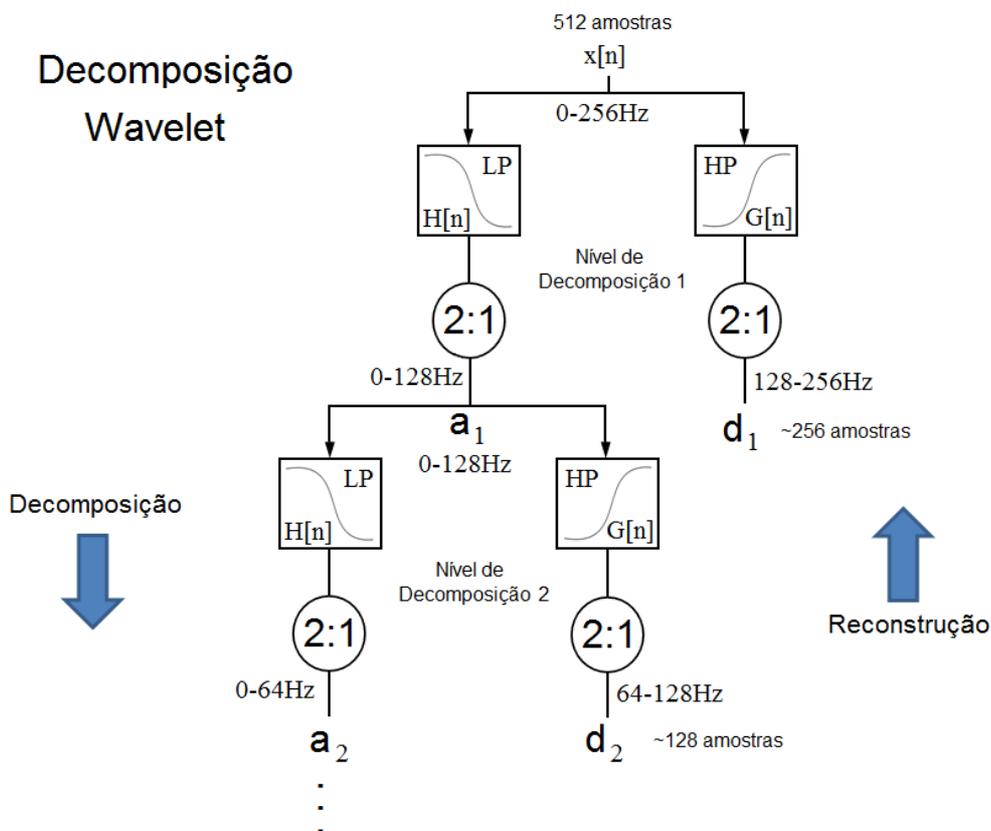


Figura 9 – Aplicação de Filtros Multiresolução a um sinal $x[n]$. Os filtros $G[n]$ extraem os detalhes $d_i[n]$. Os filtros $H[n]$ extraem as aproximações do sinal $a_i[n]$, em níveis i cada vez menores de refinamento.

A origem deste algoritmo remete aos estudos de Stephane Mallat e Yves Meyer, os quais adaptaram um algoritmo de processamento de imagens, conhecido com algoritmo da pirâmide, para a análise *Wavelet* multiresolução (Argoud, 2001). O custo computacional do algoritmo FWT é um dos mais baixos para Transformações, senão o mais baixo. Se O é uma constante (geralmente de valor 2) e N é a dimensão do vetor, em amostras, a ser analisado, pode-se afirmar que o algoritmo FWT exige apenas ON operações, sendo que algumas operações próprias do FWT tornam sua utilização mais rápida, no caso, os passos de subamostragem, que reduzem geometricamente a dimensão dos vetores dos sinais sendo analisados, a cada nível de decomposição (Argoud, 2001).

A Figura 10 ilustra a aplicação da decomposição de um sinal por FWT, as componentes de detalhe e de aproximação geradas e os sinais reconstruídos a partir de cada uma das componentes.

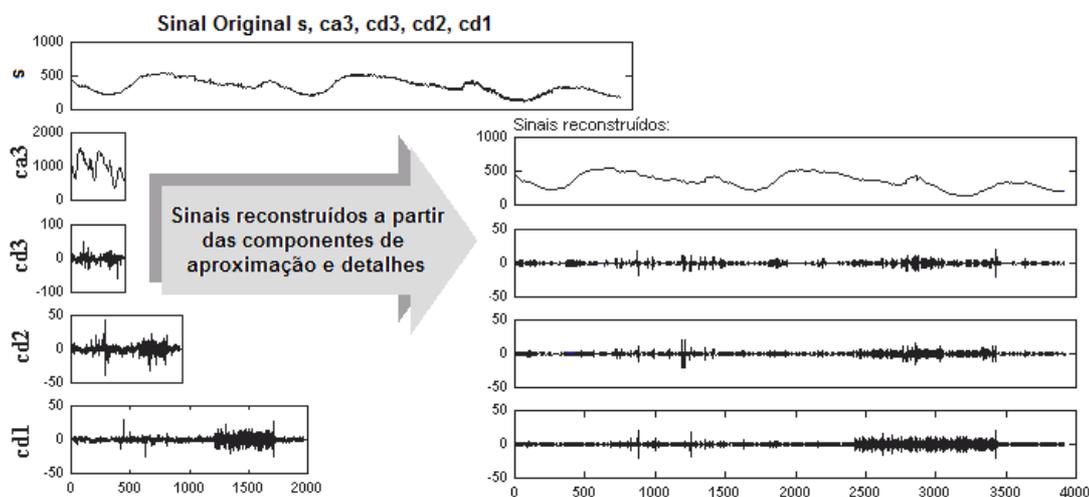


Figura 10 – Acima e à esquerda o sinal original, posteriormente decomposto em 3 níveis através de FWT, componente de detalhe 1 (cd_1), componente de detalhe 2 (cd_2), componente de detalhe 3 (cd_3) e aproximação 3 (ca_3). À direita e de baixo para cima: sinal reconstruído a partir de cd_1 , sinal reconstruído a partir de cd_2 , sinal reconstruído a partir de cd_3 e sinal reconstruído a partir da ca_3 .

(modificado de Argoud, 2001)

Descrição do algoritmo básico da FWT.

Seja $\phi(j)$, com $j=1, \dots, J$, a função escala correspondente à função *Wavelet* ψ que se deseja aplicar ao sinal $s(i)$, com $i=1, \dots, I$. Os passos a serem seguidos para implementação do algoritmo da FWT podem ser sumarizados como segue.

1. Computar os filtros de reconstrução H_R (passa-baixas), G_R (passa-altas) e de decomposição H_D (passa-baixas) e G_D (passa-altas), a partir de ϕ .

- a) Normalizar ϕ .

$$\phi_N(n) = \frac{\phi(n)}{\sum_{j=1}^J \phi(j)} \quad \text{para } n=1, \dots, J \quad \text{Equação (6)}$$

- b) Calcular os filtros em quadratura de reconstrução:

$$H_R = \sqrt{2} \cdot \phi_N \quad \text{para } n=1, \dots, J \quad \text{Equação (7)}$$

$$G_R(n) = (-1)^{n-1} \cdot H_R(J - n + 1) \quad \text{para } n=1, \dots, J \quad \text{Equação (8)}$$

- c) Calcular os filtros em quadratura de decomposição:

$$H_D(n) = H_R(J - n + 1) \quad \text{para } n=1, \dots, J \quad \text{Equação (9)}$$

$$G_D(n) = G_R(J - n + 1) \quad \text{para } n=1, \dots, J \quad \text{Equação (10)}$$

2. Para cada nível de decomposição k , repita os passos 3 a 6.
3. Faça a convolução do sinal (s) com o Filtro de decomposição Passa-baixas H_D (Filtragem FIR digital). Analiticamente:

$$FirH(n - J) = H_D(1) * s(n) + H_D(2) * s(n-1) + \dots + H_D(J+1) * s(n-J) \quad \text{Equação (11)}$$

com $n=J+1, \dots, (J+I-1)$

4. Compute o vetor de coeficientes de aproximação fazendo a decimação (subamostragem por um fator de 2) de $FirH$:

$$Ck(n) = FirH(2n), \text{ com } n=1, \dots, (J+I-1)/2 \quad \text{Equação (12)}$$

5. Faça a convolução do sinal (s) com o Filtro de decomposição Passa-altas G_D :

$$FirG(n - J) = G_D(1)*s(n) + G_D(2)*s(n-1) + \dots + G_D(J+1)*s(n-J) \quad \text{Equação (13)}$$

com $n=J+1, \dots, (J+I-1)$

6. Compute o vetor de coeficientes de detalhe fazendo a decimação (subamostragem por um fator de 2) de *FirG*:

$$Dk(n) = FirG(2n), \text{ com } n=1, \dots, (J+I-1)/2 \quad \text{Equação (14)}$$

As funções de escala podem ser obtidas em muitas referências bibliográficas relacionadas à construção e utilização de *Wavelets*. Porém a

Tabela 1 Tabela 2 fornece diretamente os filtros em quadratura, derivado da função *Wavelet* e função escala da família *Coiflet 1*, utilizada neste trabalho (dispensando a implementação do passo 1 do algoritmo) (Argoud, 2001).

Tabela 2 – Filtros ortogonais de decomposição *Wavelet* para a família *Coiflet 1*.

| Filtro | Coeficientes | | | | | |
|----------|--------------|---------|---------|--------|--------|---------|
| $H_d(t)$ | -0.0157 | -0.0727 | 0.3849 | 0.8526 | 0.3379 | -0.0727 |
| $G_d(t)$ | 0.0727 | 0.3379 | -0.8526 | 0.3849 | 0.0727 | -0.0157 |

Os filtros de Reconstrução H_R e G_R têm os mesmos valores que os filtros de Decomposição H_D e G_D em ordem invertida, ou seja: $H_R(J - j + 1) = H_D(j)$, onde J é o comprimento do vetor H_D e $G_R(J - j + 1) = G_D(j)$.

2.5 Rede Neural Artificial – *Perceptron* Multicamadas

Segundo Haykin (2001) uma Rede Neural é 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 das Redes Neurais Artificiais (RNAs) está fundamentado no reconhecimento do poder de processamento do cérebro humano, realizando 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).

2.5.1 O Neurônio Artificial

O neurônio artificial (Figura 11) 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*.

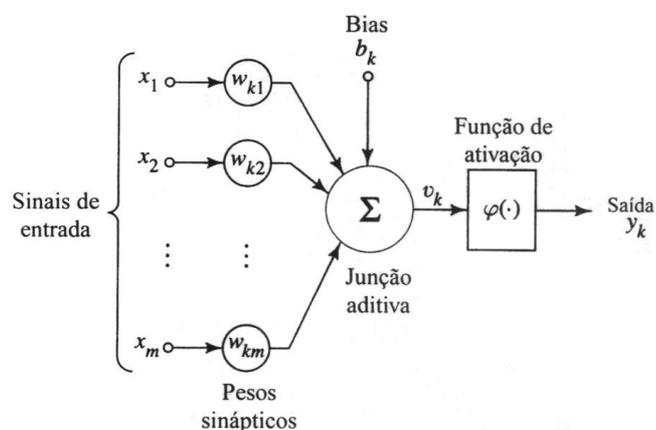


Figura 11 – Neurônio artificial e suas entradas, pesos sinápticos, junção aditiva e função de ativação.

(modificado de Haykin, 2001)

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.

O somador soma os sinais de entrada, ponderado pelas respectivas sinapses do neurônio (Equação 15).

$$net_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad \text{Equação (15)}$$

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 16).

$$y_k = \varphi(net_k) \quad \text{Equação (16)}$$

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

2.5.2 Funções de Ativação

As funções mais comumente utilizadas como função de saída de um neurônio são: a função linear (Equação 17), a função logística (Equação 18) e a função tangente hiperbólica (Equação 19).

A Função Linear:

$$y(x) = ax + b \quad \text{Equação (17)}$$

onde a e b são constantes escalares.

A Função Logística:

$$y(x) = \frac{1}{1 + e^{-kx}} \quad \text{Equação (18)}$$

onde k é um escalar positivo.

Novas funções podem ser derivadas apenas com o ajuste da constante k . A Figura 12 mostra as funções logísticas de ativação para $k = 0.5, 1, 2, 4, 8$.

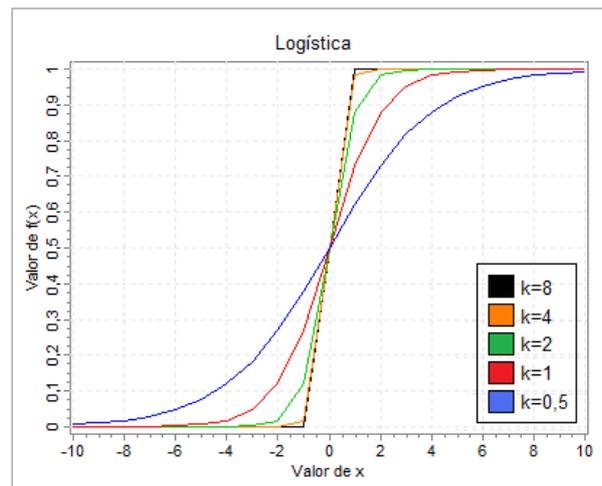


Figura 12 – Funções de ativação unipolares.

A Função Tangente Hiperbólica:

$$y(x) = \frac{e^{kx} - e^{-kx}}{e^{kx} + e^{-kx}} \quad \text{Equação (19)}$$

onde k é um escalar positivo.

Outras funções podem ser derivadas pelo ajuste da constante k . Quanto maior for k , mais abrupta será a função nas proximidades de $x = 0$. A Figura 13 ilustra a função tangente hiperbólica para $k = 0.5, 1, 2, 4, 8$.

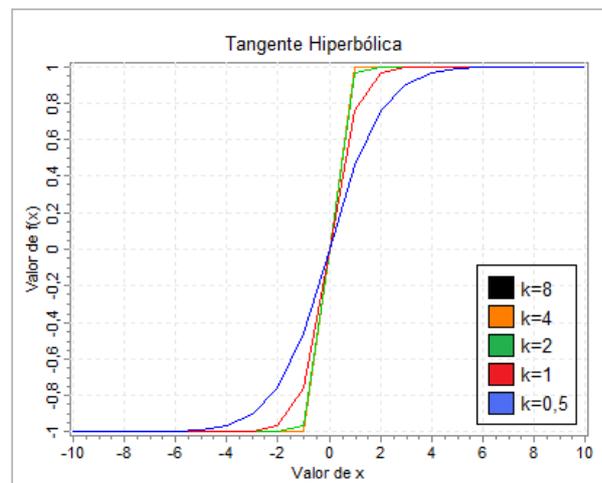


Figura 13 – Funções de ativação bipolares.

2.5.3 Rede *Perceptron* Multicamadas com Algoritmo *Backpropagation*

A rede tipo *Feedforward*, ou Direta, ou ainda “*Perceptron*”, que utiliza o algoritmo de treinamento supervisionado *Backpropagation*, se transformou em sinônimo de Rede Neural Artificial. Sistemas que utilizam o Paradigma Conexionista, o qual se inspira no modelo biológico do cérebro humano, devido principalmente à facilidade de implementação da mesma e à disponibilidade de ampla bibliografia de referência.

O treinamento supervisionado de uma rede neural artificial por retropropagação do erro, consiste da apresentação de um padrão de treinamento, propagando-o pela rede. 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 (Equação 20).

$$\varepsilon(n) = \frac{1}{2N} \sum_{n=1}^N (d(n) - y(n))^2 \quad \text{Equação (20)}$$

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.

Os pesos adaptativos são atualizados por padrão ou época. 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 a 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, atualizando os pesos das conexões sinápticas uma única vez por época. O algoritmo de treinamento tem como base o gradiente descendente, fazendo com que o erro diminua, indicando a convergência do treinamento (Eberhart e Bobbins, 1990) (De Azevedo *et. al.*, 1997) (Haykin, 2001).

2.6 Validação Cruzada

A aprendizagem por retropropagação visa um mapeamento entrada-saída de pesos sinápticos e limiares, tornando a rede bem treinada, de modo que aprenda o suficiente sobre o passado para poder generalizar no futuro. O processo de aprendizagem se “transforma” em uma escolha de parametrização, onde cada época de treinamento é vista

como um modelo candidato. De acordo com um critério, o modelo que melhor apresente as características de generalização será o escolhido (Eberhart e Bobbins, 1990) (Haykin, 2001).

Uma forma de avaliar o treinamento de uma rede neural é através da utilização de uma ferramenta estatística denominada Validação Cruzada (Figura 14). 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 início do excesso de treinamento da rede, permitindo definir o melhor ponto de parada do processo de aprendizagem (Eberhart e Bobbins, 1990) (Haykin, 2001).

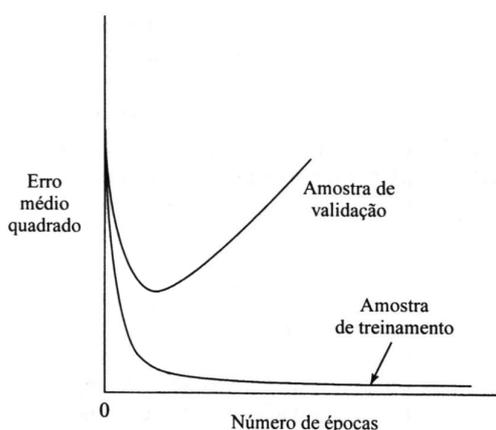


Figura 14 – Representação do comportamento das curvas de erro de treinamento e validação.

(modificado de Haykin, 2001)

2.7 Parada Antecipada

Em busca de uma boa generalização, é difícil perceber o melhor momento de encerrar o processo de aprendizado da rede neural, tendo apenas como referência a curva de aprendizagem. Se o processo de treinamento não for finalizado no momento certo, a rede poderá ser ajustada excessivamente e acabar especializando os dados apresentados para o seu treinamento.

Para identificar o melhor ponto de parada do processo de aprendizagem da rede, utiliza-se a validação cruzada. O conjunto de dados é dividido em dois conjuntos, um de treinamento e um de validação. No final da apresentação do conjunto de treinamento à rede, o processo é interrompido, os pesos sinápticos e os níveis de bias são fixados para todas as camadas e a rede opera no modo direto para frente. O conjunto de validação é apresentado e a rede é testada e o erro de validação é então obtido. Apresentados 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. O melhor ponto de generalização está entre a época que apresentou o menor valor para o erro de validação (Eberhart e Bobbins, 1990) (Haykin, 2001). Este procedimento é denominado de “método de treinamento com parada antecipada” (Figura 15).

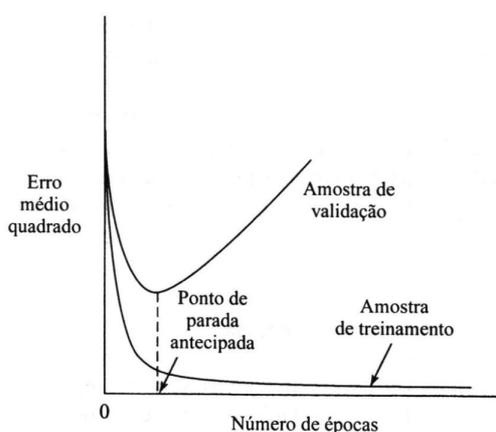


Figura 15 – Representação do ponto de ocorrência da parada antecipada.

(modificado de Haykin, 2001)

2.8 Avaliação do Desempenho

A avaliação do desempenho é uma etapa importante do processamento de sinais biomédicos (Sörnmo e 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 e 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 de 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 e Mulley, 2009).

Tabela 3 – Tabela de contingência.

| | | Doença | | Total |
|-------|----------|------------------------------|------------------------------|----------------------|
| | | Positivo | Negativo | |
| Teste | Positivo | Verdadeiro-positivos (VP) | Falso-positivos (FP) | Positivos (VP+FP) |
| | Negativo | Falso-negativos (FN) | Verdadeiro-negativos (VN) | Negativos (FN+VN) |
| Total | | Positivos (VP+FN) | Negativos (FP+VN) | |

2.8.1 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 e Fletcher, 2005) (Fischbach e Dunning, 2009) (Goroll e Mulley, 2009). A sensibilidade é calculada a partir da Equação 21.

$$\text{sensibilidade}(\%) = \frac{VP}{VP + FN} \times 100 \quad \text{Equação (21)}$$

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 e Fletcher, 2005) (Fischbach e Dunning, 2009) (Goroll e Mulley, 2009). A especificidade é calculada a partir da Equação 22.

$$\text{especificidade}(\%) = \frac{VN}{FP + VN} \times 100 \quad \text{Equação (22)}$$

2.8.2 Valor Preditivo Positivo (VPP) e Valor Preditivo Negativo (VPN)

O índice Valor Preditivo Positivo, também conhecido como Seletividade Positiva, indica a probabilidade de um resultado positivo corresponder ao verdadeiro positivo, ou seja, ajuda a prever qual a probabilidade de se ter a doença, se o resultado do teste for positivo (Goroll e Mulley, 2009). O VPP é calculado a partir da equação (Equação 23).

$$\text{VPP}(\%) = \frac{VP}{VP + FP} \times 100 \quad \text{Equação (23)}$$

O índice Valor Preditivo Negativo, 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 e Mulley, 2009). O VPN é calculado a partir da equação (Equação 24).

$$VPN(\%) = \frac{VN}{FN + VN} \times 100 \quad \text{Equação (24)}$$

2.8.3 Eficiência

A eficiência se refere à habilidade 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 25).

$$\text{eficiência}(\%) = \frac{VP + VN}{VP + FP + FN + VN} \times 100 \quad \text{Equação (25)}$$

2.9 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 e Dobbins, 1990). O gráfico ROC é uma técnica para visualizar, organizar e selecionar classificadores, baseada na sua performance (Fawcett, 2005).

Por definição, uma curva ROC é a representação gráfica dos pares, sensibilidade (ordenadas) e 1.0 - 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.

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 (Fawcett, 2005).

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 (Braga, 2000).

Na Figura 16 são apresentados três graus de discriminação, obtidos através das curvas ROC.

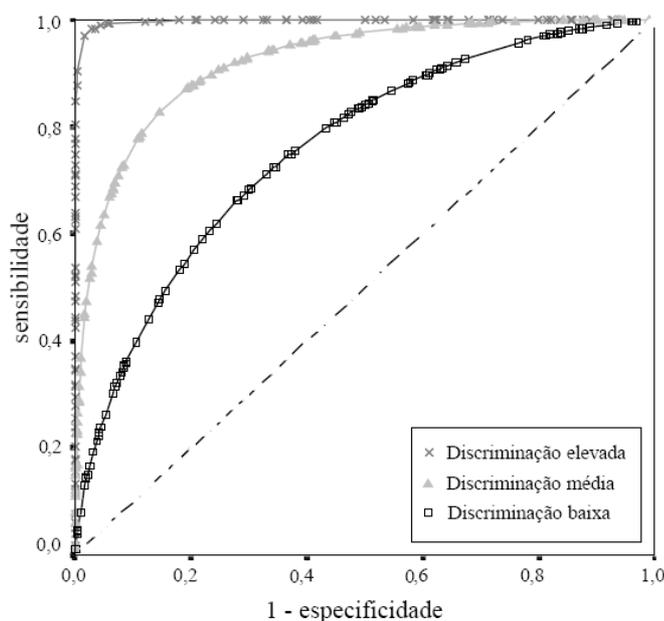


Figura 16 – Exemplo de Curvas ROC.

(modificado de Braga, 2000)

2.9.1 Índice Área Abaixo da Curva ROC (*AUC – Area Under the Curve*)

O índice AUC é uma medida sumária da curva ROC, que pode ser 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 (Fawcett, 2005) (Braga, 2000).

3. METODOLOGIA

3.1 Introdução

Este capítulo descreve detalhadamente todas as etapas realizadas no desenvolvimento deste trabalho.

A primeira etapa realizada foi a separação dos eventos necessários para os experimentos e para a formação de um banco de sinais. Os eventos selecionados pelos especialistas foram indicados em cada um dos registros de EEG, sendo marcados o instante de tempo da ocorrência e o canal que apresentou o potencial mais eletronegativo no momento da ocorrência. Cada um dos eventos foi gravado separadamente em arquivos, com época fixa de quatro segundos de duração e o evento centralizado na época. Os sinais apresentam frequência de amostragem de 512Hz e foram registrados através de uma montagem referencial.

Experimentos foram realizados empregando a transformada *Wavelet* e redes neurais artificiais na identificação e classificação de eventos epileptiformes. Foi feita uma investigação através da utilização da função *Wavelet Coiflet 1*, por ser a mais adequada para a análise de eventos epileptiformes em sinais de EEG (Argoud, 2001). Em seguida foram feitos experimentos utilizando redes neurais do tipo MLP como classificadores. As redes treinadas foram avaliadas através da utilização do método de validação cruzada, com parada antecipada. Já o classificador neural foi avaliado através dos índices de desempenho como: sensibilidade, especificidade, seletividade positiva, seletividade negativa, curvas ROC e índice de eficiência.

Os procedimentos e experimentos descritos anteriormente são abordados detalhadamente ao longo deste capítulo e os resultados alcançados são apresentados no capítulo 4.

3.2 Visão Geral do Trabalho

Basicamente, a proposta deste trabalho é a utilização da transformada *Wavelet* em conjunto com redes neurais, como forma de classificar ou separar os agrupamentos de eventos epileptiformes (espículas e ondas agudas) dos não epileptiformes (piscadas palpebrais, atividade normal de fundo e ruídos).

A Transformada *Wavelet* funciona como um “filtro”, analisando época por época, canal por canal, indicando as épocas que poderiam apresentar eventos epileptiformes. Cada época de sinal é analisada pela Transformada *Wavelet*. Caso não ultrapasse um limiar de decisão definido, ou seja, caso a época em análise não apresente uma “sensibilidade” a um determinado nível de decomposição da função *Wavelet*, esta época é automaticamente descartada e então, uma nova época é analisada. Caso ultrapasse o limiar de decisão estipulado, esta época é direcionada ao classificador, o qual verifica se a época em questão, trata-se de um evento epileptiforme ou não. Os eventos são direcionados ao classificador, o qual deve ser capaz de classificar corretamente as épocas analisadas. Após a classificação, uma nova época é analisada deslocando a janela da época amostra a amostra e todo o processo se repete.

Uma representação geral do trabalho, contendo todo o fluxo das informações é apresentada na Figura 17.

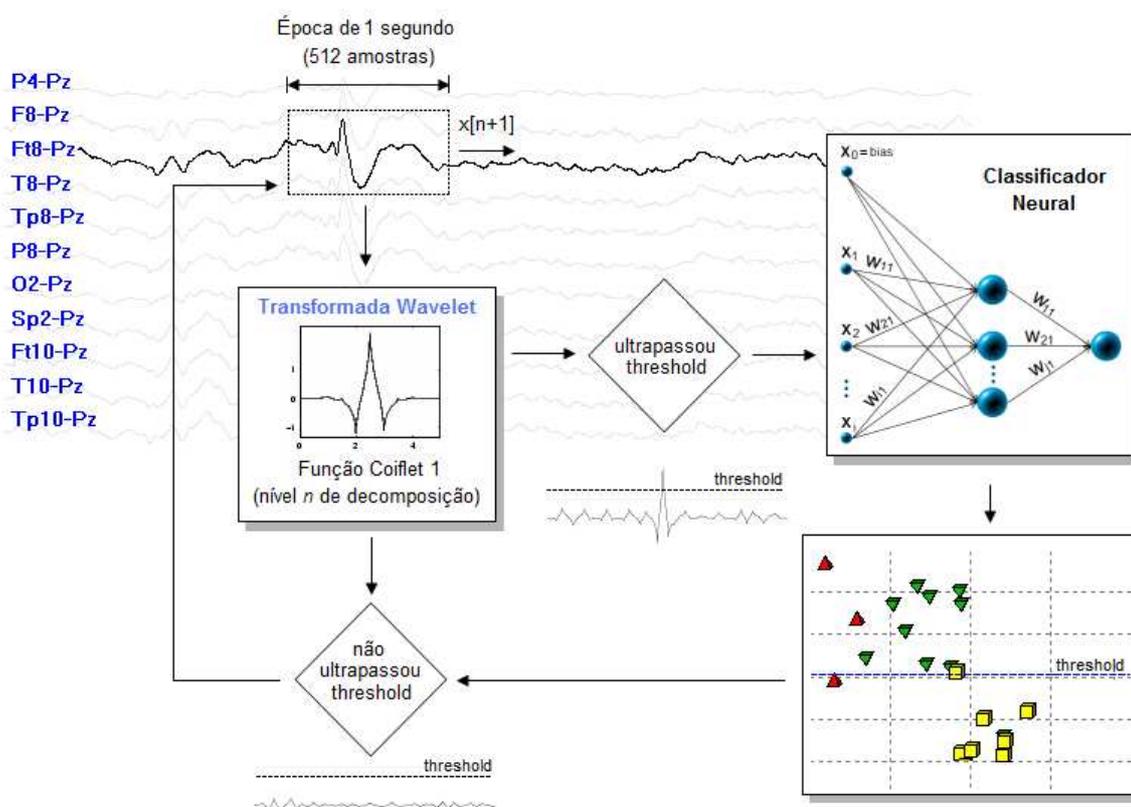


Figura 17 – Cada época de sinal é direcionada para a Transformada *Wavelet* onde é analisada, caso o sinal gerado apresente uma morfologia característica para eventos epileptiformes, a época analisada é direcionada para o classificador neural.

3.3 Banco de Sinais de EEG

Os sinais de EEG que compõem o banco de sinais gerado para este trabalho foram fornecidos pelo CEPESC, a partir da monitoração de pacientes internados na clínica. O banco é composto por registros de dez pacientes comprovadamente epiléticos e um registro de um paciente sem epilepsia, totalizando 16 horas de registro. Os sinais foram adquiridos pelo sistema *CEEgraph VISION EEG* da *Natus Bio-logic Systems Corp.*, utilizando 32 canais com uma montagem referencial (referencia do equipamento). Um traçado característico da montagem referencial utilizada no registro dos sinais de EEG é visualizado na Figura 18.

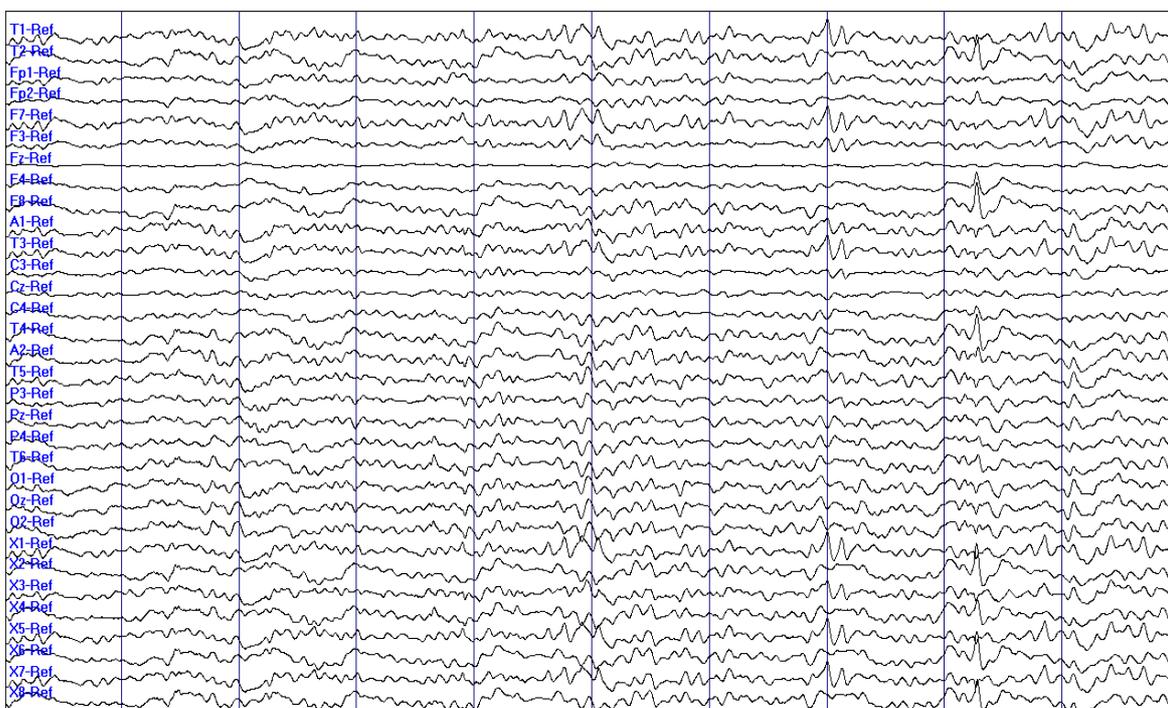


Figura 18 – Traçado característico utilizando a montagem referencial do equipamento.

Através dessa forma de aquisição é possível a configuração de diferentes tipos de montagem (referenciais e bipolares). Os sinais foram registrados com as seguintes configurações: filtro passa-altas de 1Hz, filtro limitador de banda com frequência de 35Hz, filtro rejeita-banda de 60Hz, para eliminar interferências causadas pela rede elétrica e uma frequência de amostragem de 512Hz (máxima permitida pelo equipamento). Pelo fato de

se tratar de seres humanos foi elaborado um projeto para a sua utilização, o qual foi submetido e **aprovado** pelos **Comitês de Ética em Pesquisa com Seres Humanos da Universidade Federal de Santa Catarina³** e do **Hospital Governador Celso Ramos⁴**.

3.4 Marcação dos Sinais de EEG

Todos os eventos epileptiformes utilizados para formar o banco de sinais foram marcados por três neurologistas, os quais são membros do CEPESC.

Após o período de internação é feita a análise de cada um dos registros de EEG pelo neurologista responsável por aquele paciente, onde é emitido um laudo com as informações do exame realizado, indicando se houve ou não alterações nos traçados de EEG. No processo de análise, o neurologista observa atentamente telas de 10 segundos de sinal, utilizando uma montagem referencial em Pz (tendo o canal Pz como referência para os demais), um hemisfério de cada vez, na procura de descargas epileptiformes. É identificado o hemisfério (esquerdo com canais ímpares ou direito com canais pares), o instante de ocorrência e o canal que apresenta o potencial elétrico mais eletronegativo (Figura 19), acumulando o número de ocorrências de espículas por canal ao longo do registro. O laudo sobre a situação do paciente é feito a partir da identificação da região que apresentou maior número de descargas contadas em cada canal.

³ Processo n° 252/08 FR-229734 Data: 10/10/2008

⁴ Processo n° 025/08 FR-218051 Data: 25/11/2008

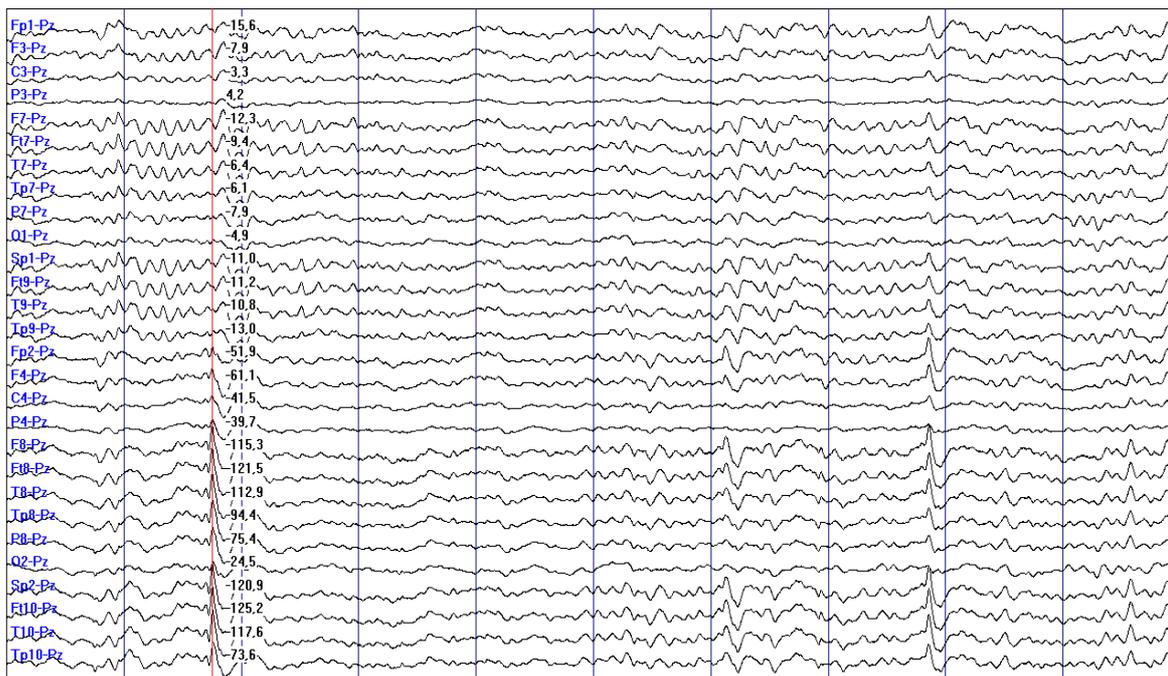


Figura 19 – Marcação do evento mais eletronegativo (-125,2 μ V), identificado no canal Ft10.

3.5 Arquivos dos Padrões de EEG

Dos eventos selecionados pelos especialistas dos CEPESC, foram separados 685 eventos, dos quais 71 são espículas, 305 são ondas agudas, 108 são piscadas, 145 são atividade de fundo e 56 são ruídos. Os arquivos de eventos foram separados em cinco classes: arquivo de espículas, arquivos ondas agudas, arquivo de piscadas, arquivo de atividade de fundo de EEG e arquivo de ruído (Figura 20). Cada arquivo de evento recebeu uma extensão “.pdr” e apresenta um tamanho fixo de 2048 amostras (época de 4 segundos), tendo o evento centrado na posição 1024 do arquivo (dois segundos), o que permite a sua manipulação em processamentos futuros, apenas diminuindo ou aumentando a janela de tempo. Dentro de cada arquivo há informações da frequência de amostragem do sinal, tamanho do arquivo (número de amostras), e para as classes de espículas e piscadas, contém a duração do respectivo evento em milissegundos, para os demais eventos a duração é igual a zero.

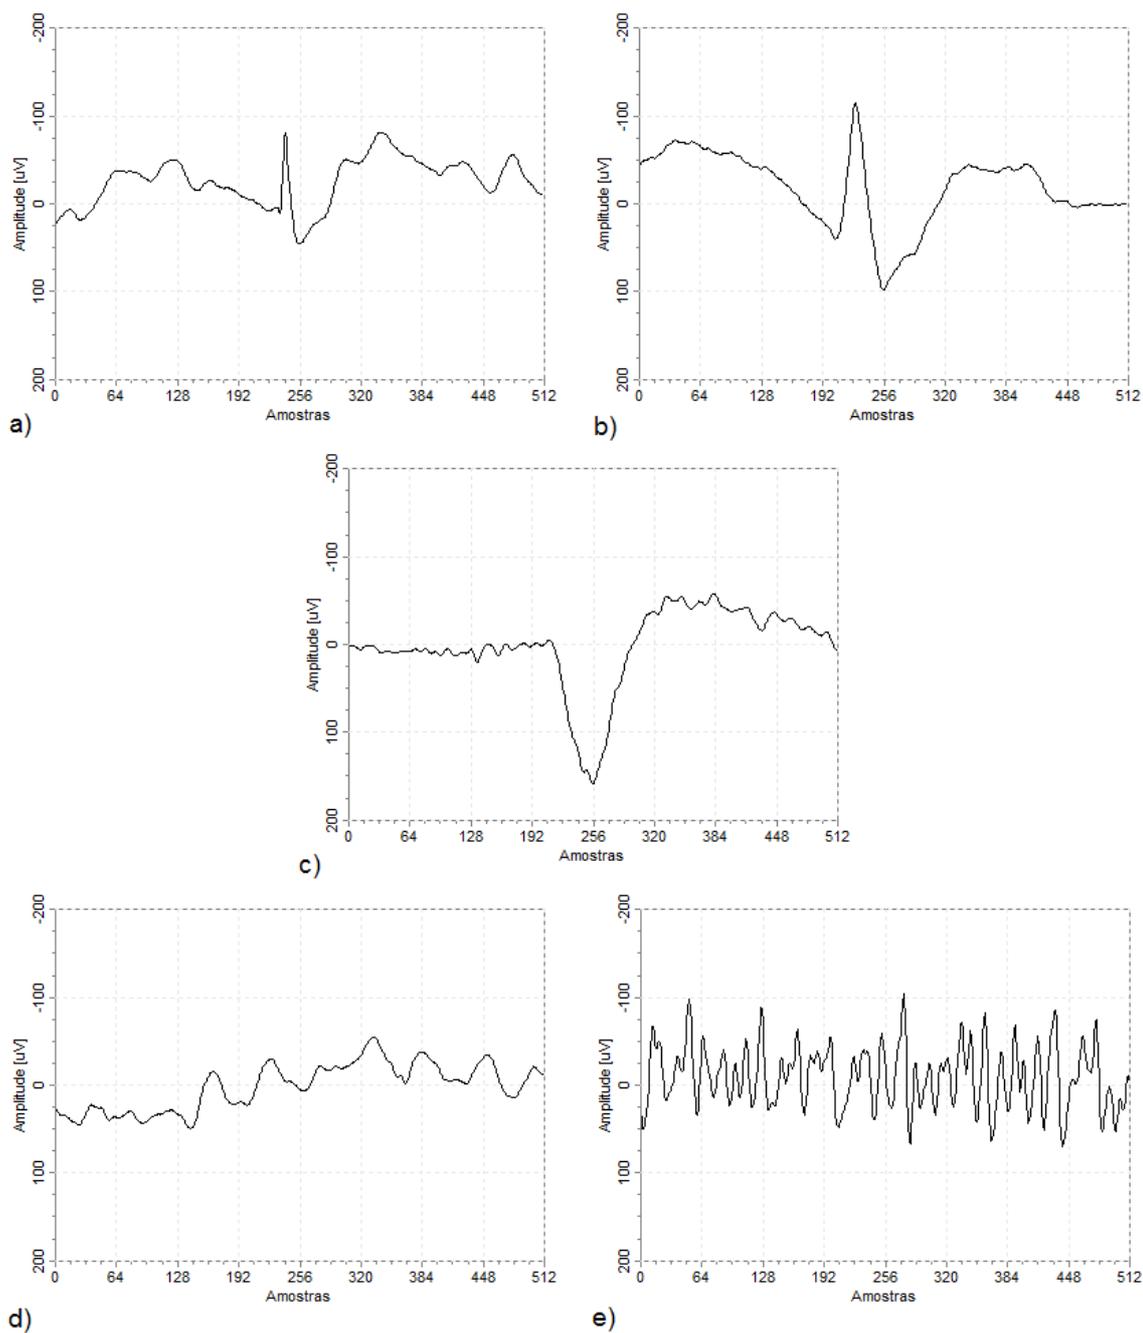


Figura 20 – Exemplo de eventos de cada uma das classes definidas: (a) espículas (20-70ms), (b) ondas agudas (71-200ms), (c) piscadas palpebrais, (d) atividade de fundo e (e) ruído.

3.6 Arquivos dos Conjuntos de Padrões de EEG

Após a marcação e a separação de todos os eventos em arquivos, foram gerados três conjuntos de padrões: conjunto de treinamento, conjunto de validação e conjunto de testes,

onde os eventos foram selecionados aleatoriamente e não se repetem em cada conjunto, sendo completamente distintos entre si.

A Tabela 4 apresenta a quantidade de cada classe de eventos selecionados para cada conjunto de padrões.

Tabela 4 – Representação dos eventos selecionados para cada conjunto de eventos.

| Conjunto de Padrões | Espículas | Ondas Agudas | Piscadas Palpebrais | Atividade de Fundo | Ruído | Total |
|---------------------|-----------|--------------|---------------------|--------------------|-------|-------|
| Treinamento | 29 | 71 | 31 | 40 | 29 | 200 |
| Validação | 13 | 87 | 41 | 49 | 10 | 200 |
| Teste | 29 | 147 | 36 | 56 | 17 | 285 |
| Total | 71 | 305 | 108 | 145 | 56 | 685 |

A Figura 21 representa a distribuição de todos os padrões divididos por classe. O gráfico apresenta cada padrão selecionado para o conjunto de treinamento, onde podem ser visualizados os eventos com suas amplitudes máximas (para piscadas, atividade normal e ruído) e mínimas (para espículas e ondas agudas) em função da duração do evento.

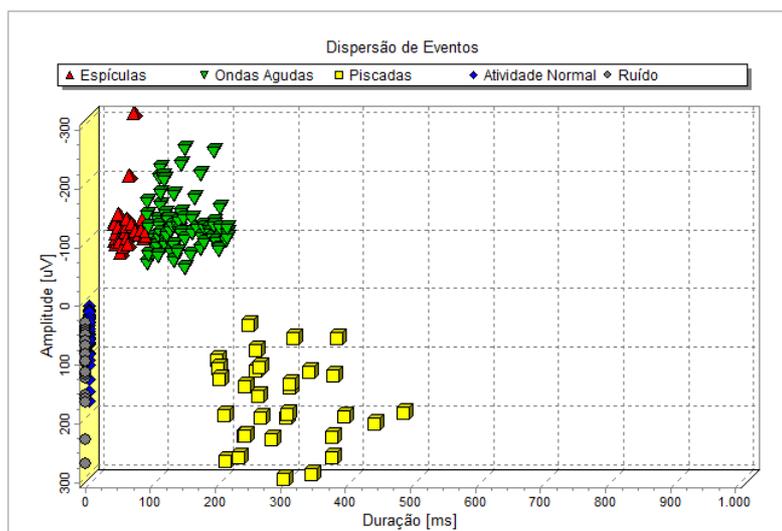


Figura 21 – Representação de todos os eventos selecionados para o conjunto de treinamento.

O gráfico representado pela Figura 22 apresenta a distribuição de todos os padrões selecionados para o conjunto de validação. Já a Figura 23 apresenta a distribuição para o conjunto de testes, onde podem ser visualizados os eventos com suas amplitudes máximas e mínimas em função da duração do evento

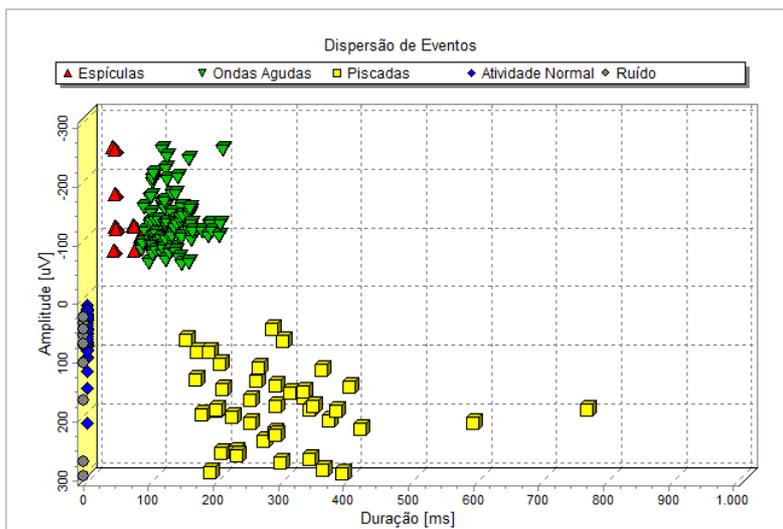


Figura 22 – Representação de todos os eventos selecionados para o conjunto de validação.

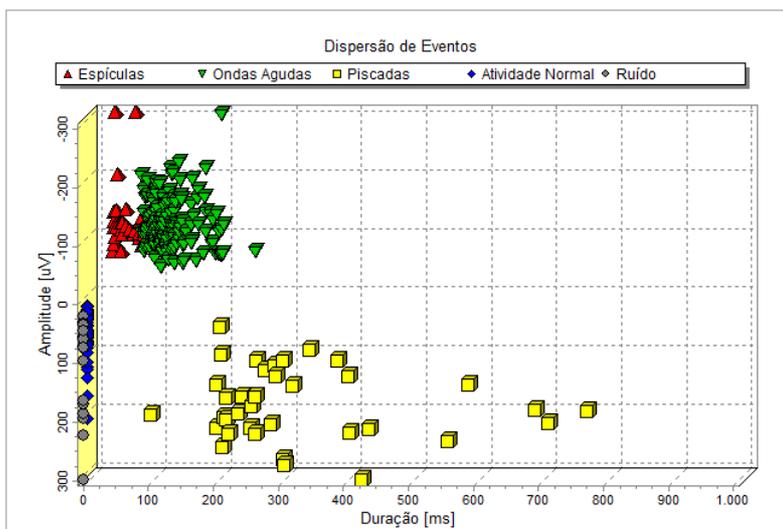


Figura 23 – Representação de todos os eventos selecionados para o conjunto de testes.

Após a seleção dos eventos e a separação deles em conjuntos de padrões, foi feita uma investigação preliminar através da Transformada *Wavelet* e das Redes Neurais Artificiais. Tais procedimentos são descritos nas seções seguintes.

3.7 Investigação dos Sinais de EEG através da Transformada *Wavelet*

O propósito da utilização da Transformada *Wavelet* é extrair características a partir dos seus níveis de decomposição que possam de alguma forma distinguir os eventos epileptiformes (espículas e ondas agudas), dos demais tipos de eventos (piscadas palpebrais, atividade de fundo e ruído) que compõem os sinais de EEG. Um esboço da funcionalidade atribuída à Transformada *Wavelet* é apresentada na Figura 24.

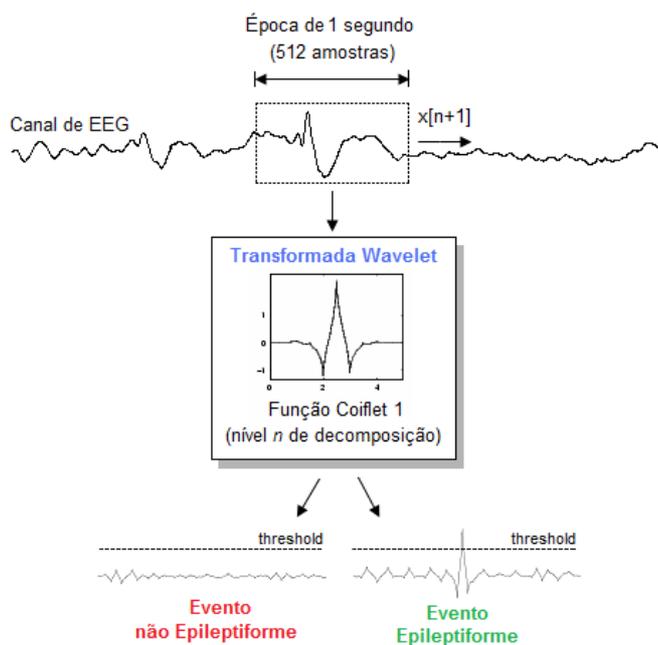


Figura 24 – Representação da utilização da Transformada *Wavelet* como forma de pré-processamento das épocas de sinal de EEG.

Tais características podem ser empregadas como forma de separação entre as classes de eventos, antes que uma época de sinal selecionada seja analisada pelo classificador neural. Agindo como um “filtro”, a Transformada *Wavelet* “decide” qual época de sinal vai ser analisada pelo classificador, de acordo com um limiar de decisão.

O IEB/UFSC tem realizado pesquisas e desenvolvido metodologias na área da epilepsia. Foram desenvolvidas ferramentas para o auxílio ao diagnóstico da epilepsia, onde se destacam os trabalhos realizados por Argoud (2001) e por Pereira (2003), os quais utilizaram a função *Coiflet 1*, nos níveis de decomposição 2 e 3.

A Transformada *Wavelet* foi utilizada neste trabalho para processar as entradas da rede neural. Caso o sinal resultante da decomposição feita pela função *Coiflet 1*, apresente a forma característica para as espículas e supere um limiar de decisão, este evento é direcionado para o classificador neural. Caso contrário, o evento é descartado.

Inicialmente, dois experimentos foram realizados. O primeiro experimento foi realizado deslocando épocas de sinal, devido ao fato, da janela do sinal se deslocar, amostra a amostra, em busca de eventos epileptiformes, em todos os canais dos registros de EEG, como apresentado na Figura 24. Esse experimento serviu para verificar o comportamento dos dez níveis de decomposição, quando uma janela de sinal é deslocada no tempo.

No segundo experimento as classes de padrões (espículas, ondas agudas, piscadas palpebrais, atividade de fundo e ruídos) foram aplicadas à função *Coiflet 1*, nos níveis de decomposição de um a dez, onde foram observadas algumas características sobre a morfologia das diferentes classes de eventos. Foram realizados experimentos simples, apenas para verificar como seriam as formas de onda, resultantes dos sinais decompostos pela função *Coiflet 1*.

Os resultados obtidos através dos experimentos realizados são apresentados no Capítulo 4.

3.8 Investigação dos Sinais de EEG através de Redes Neurais Artificiais

O propósito do classificador neural é o de distinguir eventos epileptiformes (espículas e ondas agudas), dos demais tipos de eventos (piscadas palpebrais, atividade de fundo e ruído) que compõem os sinais de EEG, a partir de sinais processados e não processados. Um esboço da funcionalidade atribuída ao classificador neural é apresentado na Figura 25.

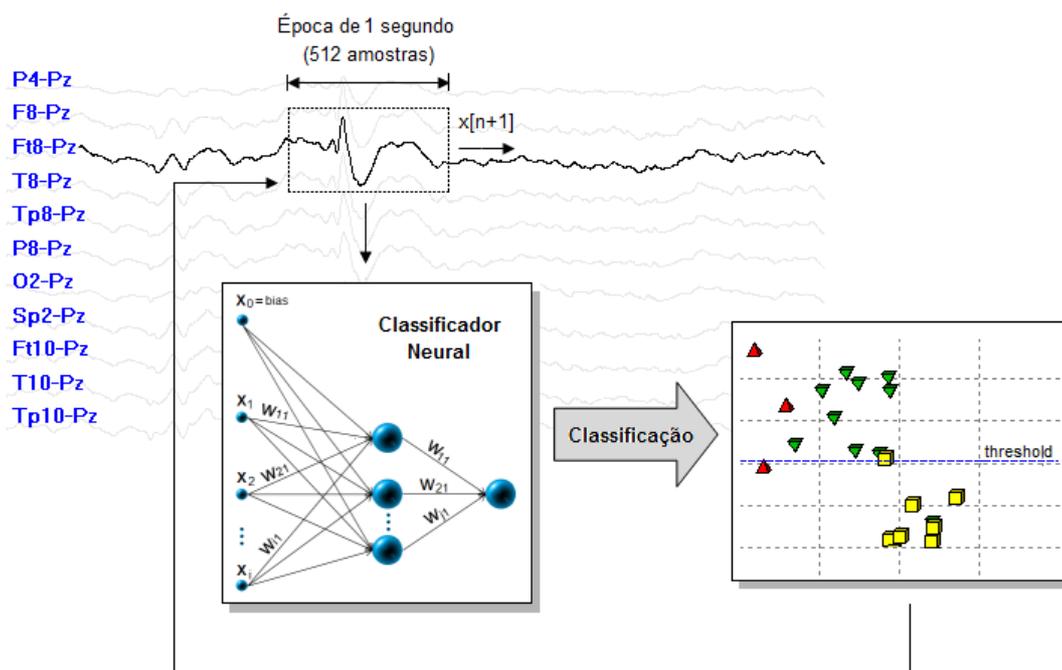


Figura 25 – Representação da utilização do classificador neural na classificação dos eventos epileptiformes e não epileptiformes das épocas de sinal de EEG analisadas.

A rede neural é composta por três camadas. A camada de entrada da rede apresenta 512 neurônios, a camada interna apresenta 10 neurônios e a camada de saída apresenta apenas 1 neurônio de saída. A camada de entrada foi configurada com 512 neurônios pelo fato de estar sendo utilizada uma época de um segundo de sinal, com frequência de amostragem de 512Hz, o que equivale a 512 amostras. Foram testadas outras configurações com valores diferentes de neurônios para a camada intermediária. Porém, um número mais elevado de neurônios (15 a 50) apenas deixou o processo de treinamento mais lento e apresentou resultados muito parecidos ou mesmo piores que a configuração adotada com 10 neurônios. Com um número menor de neurônios (abaixo de 10) a rede perdia a capacidade de generalizar os eventos apresentados a ela. Com os experimentos realizados, adotou-se a quantidade de 10 neurônios na camada intermediária. Na camada de saída foi utilizado apenas 1 neurônio pois a saída do classificador é binária.

A rede neural implementada é do tipo *feedforward* multicamadas, devido à vasta bibliografia encontrada sobre o assunto e pela simplicidade de implementação do algoritmo.

Foram treinadas em torno de 140 redes neurais e para cada uma delas os pesos sinápticos tiveram valores aleatórios entre $\pm 0,01$. O valor inicial para a taxa de aprendizagem foi de 0,1, decrescendo a cada rede treinada. Observou-se que os melhores treinamentos foram com o valor de 0,002 para a taxa de aprendizagem. O mesmo procedimento ocorreu para o termo de momento, onde foi estipulado um valor inicial de 0,99 e decrescendo 0,01 entre os treinamentos das redes. Os melhores resultados foram obtidos com o valor em torno de 0,70, o qual foi adotado como padrão para todos os treinamentos. Valores abaixo deste valor, fizeram com que as redes convergissem mais lentamente, ou em alguns casos, nem convergissem.

O procedimento de treinamento supervisionado da rede neural é o algoritmo de retropropagação do erro na forma original (*backpropagation error*), desenvolvido na área de redes neurais artificiais. O procedimento de avaliação do treinamento da rede neural artificial é o processo de **validação cruzada**, com **parada antecipada**. O procedimento de avaliação do desempenho do classificador neural foi à **análise ROC**, inicialmente apresentada na área da detecção de sinais. No processo de treinamento da rede foi implementado parcialmente o algoritmo de avaliação do classificador neural sugerido por Sovierzoski (2009), onde são agregados os procedimentos anteriormente citados. 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 uma época de validação é apresentada à rede, aproveitando toda a configuração momentânea de pesos sinápticos e *bias* desse ciclo de treinamento em específico. Ao término da apresentação da época de validação os procedimentos de validação cruzada e análise ROC 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 até o final do treinamento da rede neural.

Os conjuntos de treinamento, de validação e de teste, utilizados em todos os treinamentos, são descritos em detalhes na sessão 3.6.

A função logística (Equação 26) foi utilizada, devido ao fato de se tratar da implementação de um classificador neural binário. A convenção utilizada foi que a saída

em nível alto (1) representa os eventos epileptiformes e a saída em nível baixo (0) representa os eventos não epileptiformes.

$$\varphi(x) = \frac{1}{1 + e^{-x}} \quad \text{Equação (26)}$$

Os eventos de entrada, para a 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.

Para a avaliação do classificador neural é feita uma comparação entre o resultado da classificação e a indicação do especialista, conforme é apresentada na Tabela 5. Esta comparação com a tabela de contingência também é conhecida como teste - diagnostico, muito utilizado nas Ciências Médicas.

Tabela 5 – A tabela de contingência adaptada para as classes de eventos epileptiformes e não epileptiformes e o exame sendo o classificador neural.

| | | Eventos | | |
|-------------------------|----------|--|---|----------------------|
| | | Epileptiformes (Espículas e Ondas Agudas) | Não epileptiformes (Piscada, Ruído e Atividade de fundo) | Total |
| Classificador Neural | Positivo | VP | FP | Positivos (VP+FP) |
| | Negativo | FN | VN | Negativos (FN+VN) |
| Total | | Eventos Detectados (VP+FN) | Eventos não Detectados (FP+VN) | |

Através do conjunto de padrões de validação apresentado à rede, são levantados os indicadores estatísticos (VP, VN, FP, FN) para todos os limiares de decisão. Em seguida são calculados os índices de desempenho para cada época de treinamento.

Os indicadores verdadeiros, positivo (VP) e negativo (VN) representam a concordância na classificação das decisões corretas do exame. Os indicadores falsos, positivo (FP) e negativo (FN) representam a discordância na classificação.

Totalizando os índices acima descritos, ao final de cada época de treinamento, calcula-se a sensibilidade e a especificidade, através da Equação 27 e Equação 28, sendo funções da época de treinamento (e) e do limiar de decisão (t).

A sensibilidade é a capacidade do classificador de identificar os eventos positivos entre os verdadeiramente positivos. Quanto menor o número de falsos negativos, maior será a sensibilidade do classificador.

$$sensibilidade(e,t) = \frac{\sum VP(e,t)}{\sum VP(e,t) + \sum FN(e,t)} \quad \text{Equação (27)}$$

A especificidade é a capacidade do classificador de identificar os negativos entre os verdadeiramente negativos, variando seu valor de 0 (VN=0) até 1 (quando FP=0). Quanto menor o número de falsos positivos, maior será a especificidade do classificador.

$$especificidade(e,t) = \frac{\sum VN(e,t)}{\sum VN(e,t) + \sum FP(e,t)} \quad \text{Equação (28)}$$

O índice de eficiência mede o desempenho do classificador neural, expressa a capacidade do classificador indicar corretamente os verdadeiros positivos e os verdadeiros negativos, representado pela Equação 29.

$$efici\tilde{e}ncia = \frac{VP + VN}{VP + VN + FP + FN} \quad \text{Equação (29)}$$

Os índices acima descritos foram utilizados para medir o desempenho do classificador neural implementado.

A Figura 26 apresenta em (a) o gráfico de sensibilidade e especificidade e (b) gráfico de seletividade positiva e seletividade negativa, todos em função do limiar de decisão. Foi utilizado um incremento de limiar de decisão de 0,02, gerando 51 pontos no gráfico.

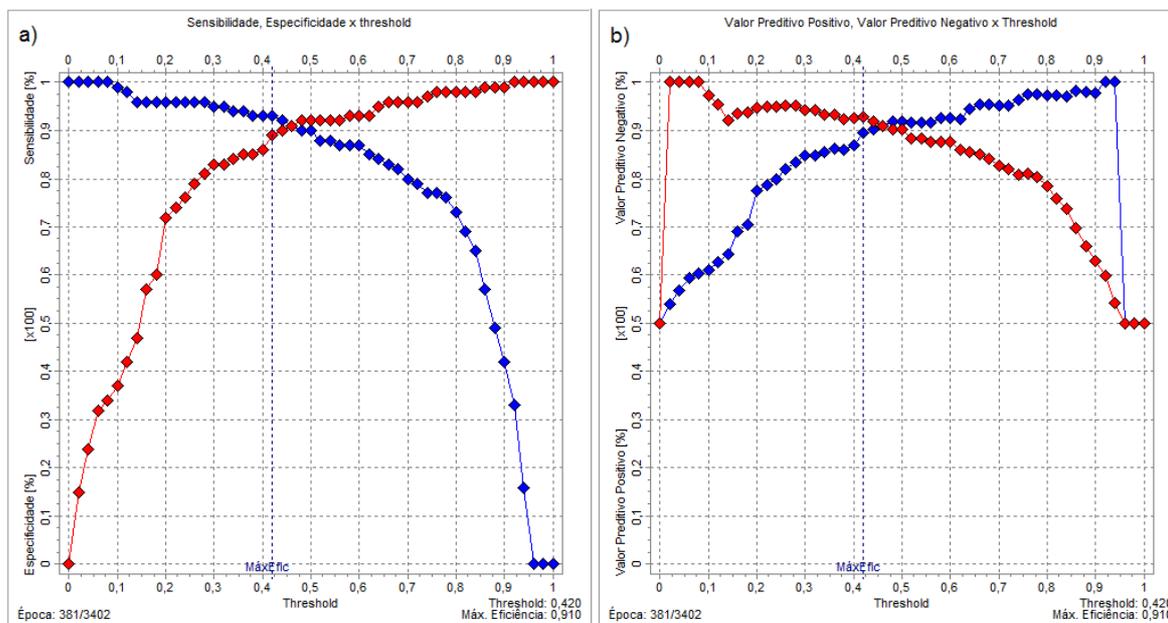


Figura 26 – (a) Gráfico de sensibilidade e especificidade e (b) gráfico de seletividade positiva e seletividade negativa, todos em função do limiar de decisão. Foi utilizado um incremento de limiar de decisão de 0,02, gerando 51 pontos no gráfico.

Eberhart e Dobbins (1990) e Wilson e Emerson (2002) descreveram o uso da curva ROC como sendo uma medida de desempenho para sistemas classificadores e sistemas diagnósticos, independente de sua aplicação, sendo possível sua utilização em sistemas especialistas e em redes neurais artificiais.

Sendo um gráfico cartesiano a curva ROC apresenta no eixo das ordenadas os valores da sensibilidade. Já no eixo das abscissas apresenta os valores de $(1,0 - \text{especificidade})$.

Para medir o desempenho da curva ROC utilizou-se o índice AUC (*Area Under the ROC Curve*), assumindo valores entre 0,5 (sem discriminação) e 1,0 (discriminação total dos padrões), apresentados na Figura 27.

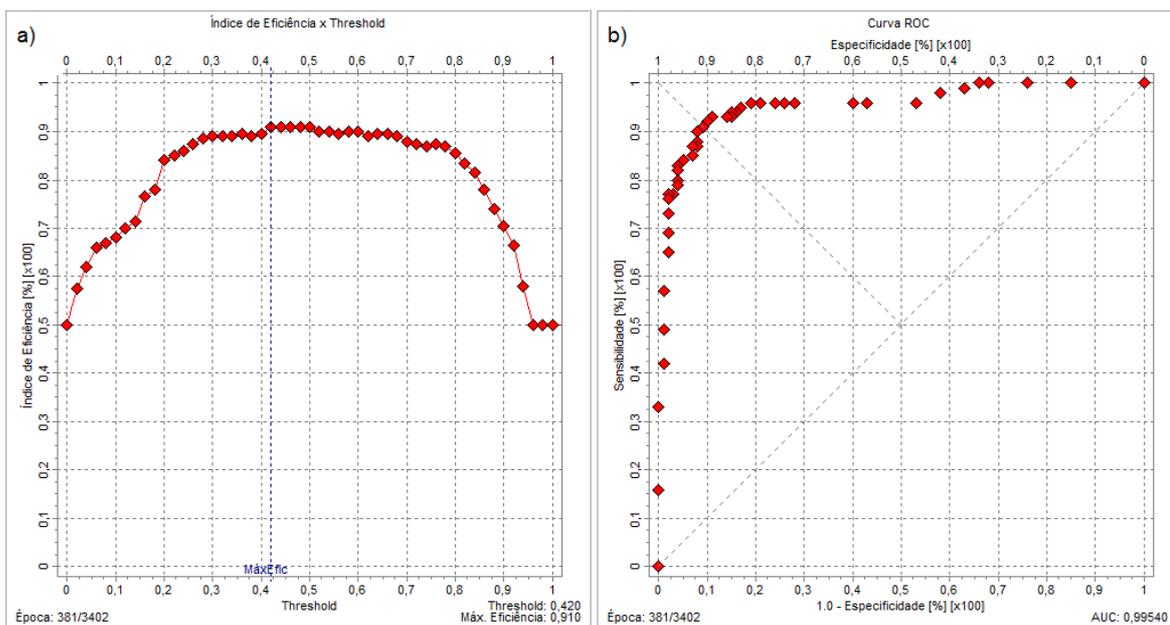


Figura 27 – (a) Gráfico da eficiência em função do limiar de decisão, para uma determinada época e em (b) a curva ROC, também para uma determinada época de treinamento.

4. RESULTADOS

Ao longo deste capítulo são apresentados os resultados obtidos com o desenvolvimento deste trabalho. Com a finalidade de facilitar a análise dos mesmos, os resultados são abordados de modo separado, enquadrando-os de acordo com a fase do trabalho as quais pertencem.

4.1 Avaliação dos Sinais de EEG Através da Transformada *Wavelet*

4.1.1 Dispersão de eventos

Inicialmente foram realizados experimentos para extrair características dos sinais de EEG, decompondo o sinal através de funções *Wavelet* e dos seus respectivos níveis de detalhe (Figura 28).



Figura 28 – Exemplo de um evento decomposto pelos níveis de detalhe (1 a 10) da função *Coiflet 1*.

Todos os sinais que compõem a base de dados gerada, foram submetidos à Transformada *Wavelet*. Através do sinal resultante da decomposição de cada nível de detalhe, foi identificado o seu respectivo valor máximo absoluto (Figura 29), gerando assim os gráficos de dispersão. Os gráficos de dispersão proporcionaram a verificação da dispersão de cada agrupamento de eventos, permitindo avaliar se haveria uma forma de separação entre as espículas e os demais eventos presentes nos sinais de EEG, antes deles serem analisados pelo classificador neural.

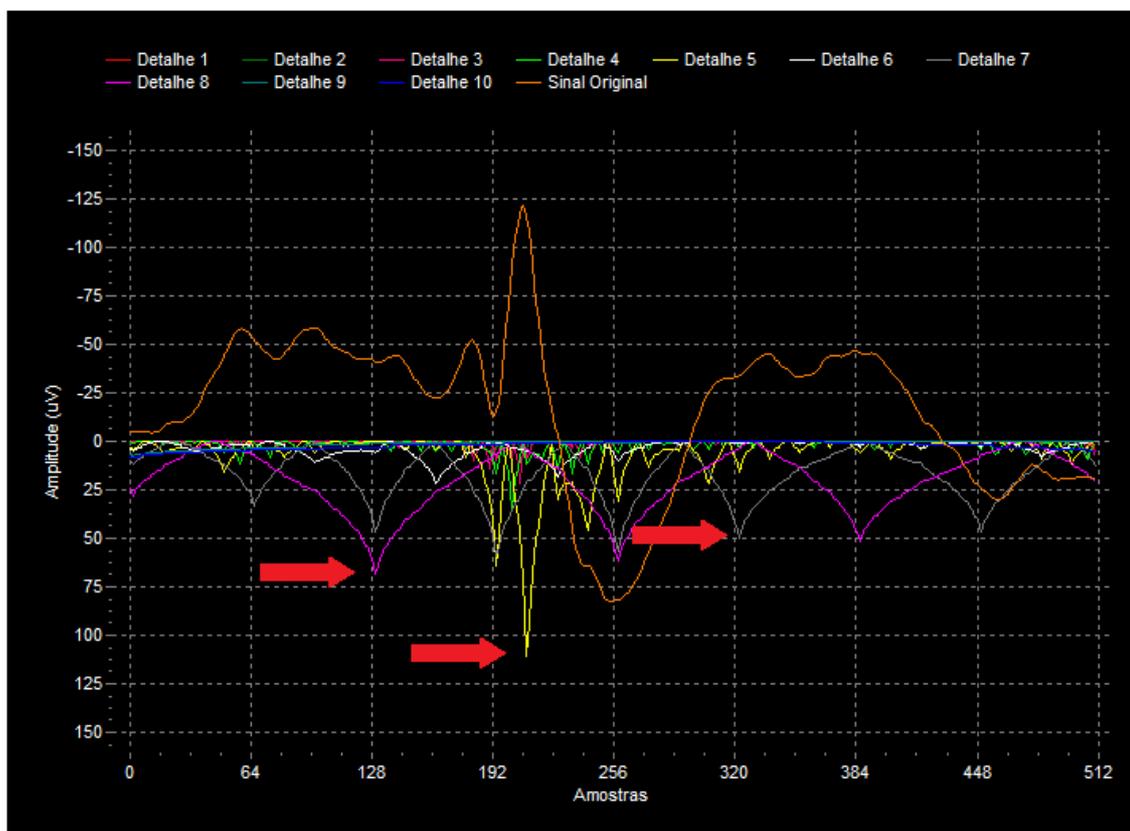


Figura 29 – Valor máximo absoluto de cada nível de detalhe, os quais foram utilizados para gerar os gráficos de dispersão de eventos (indicação em vermelho apenas dos níveis de decomposição 5, 7 e 8).

No nível de detalhe 1 todos os agrupamentos de eventos apresentam baixas amplitudes. Parece não haver distinção entre os grupos. Fica visível que apenas as espículas apresentaram poucos eventos com amplitude um pouco mais elevada, em relação aos demais. O agrupamento das piscadas palpebrais apresentou amplitudes próximas de zero, bem como, a grande parte dos eventos relacionados à atividade de fundo e ruído, sendo que alguns destes apresentaram amplitudes próximas às das espículas. Dessa forma, o nível de detalhe 1 parece ser um pouco sensível as espículas e a alguns eventos relacionados à atividade normal e ruído, como é apresentado na Figura 30. Através deste nível de detalhe não se pôde definir uma forma de separação entre os agrupamentos.

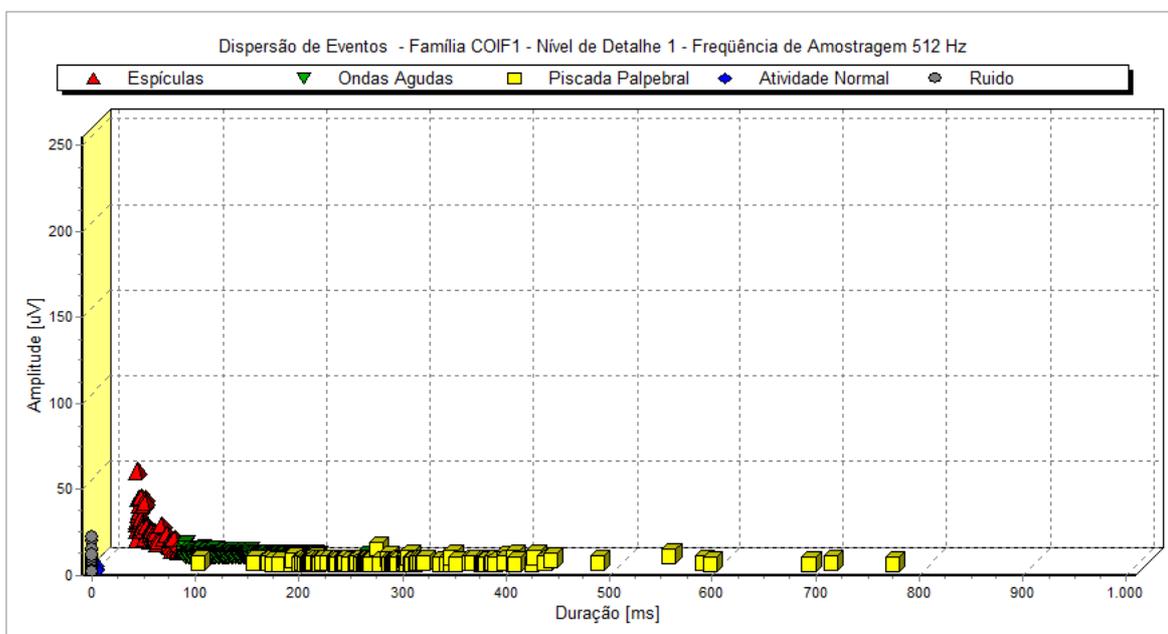


Figura 30 – Dispersão de eventos a partir da função *Coiflet 1* para o nível de decomposição 1.

No nível de detalhe 2 os agrupamentos de ruído e espículas apresentaram amplitudes mais altas em relação aos agrupamentos de piscadas palpebrais, ondas agudas e ruído (Figura 31). O agrupamento de ruídos apresenta alguns poucos eventos com amplitudes mais altas, mas a grande maioria destes eventos ficou na mesma faixa de amplitude das espículas. O nível de detalhe 2 mostrou que houve um aumento na amplitude de quase todos os eventos. Porém, mostrou-se mais sensível aos agrupamentos de atividade normal, ruído e espículas, mas sem a possibilidade de fazer uma separação entre os grupos.

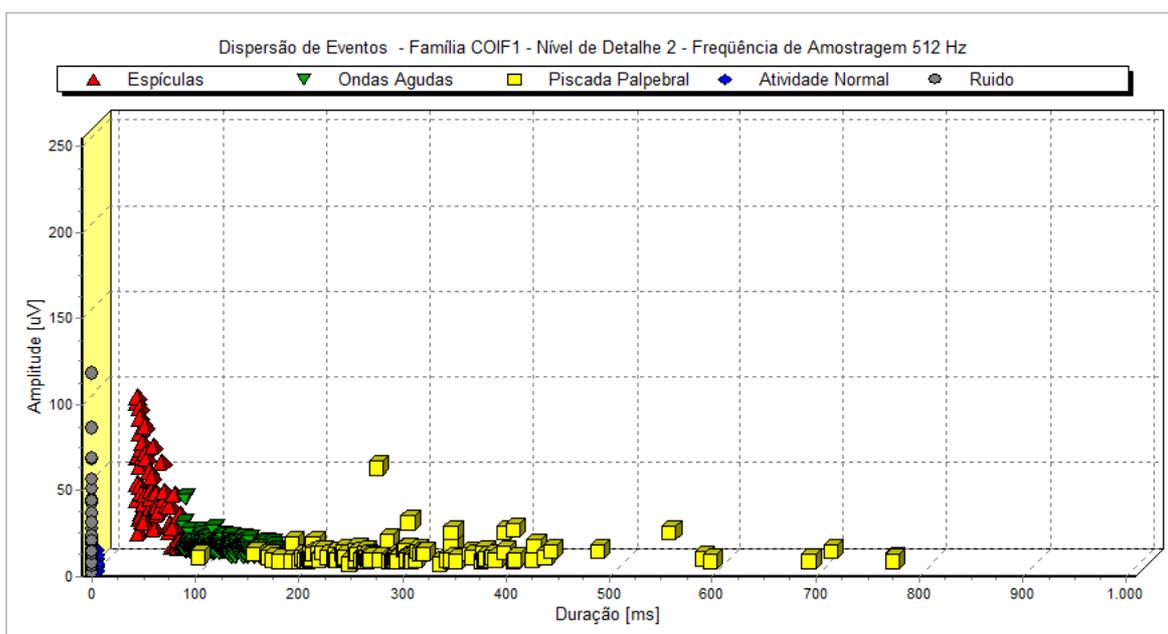


Figura 31 – Dispersão de eventos a partir da função *Coiflet 1* para o nível de decomposição 2.

Através do nível de detalhe 3 (Figura 32) observou-se um aumento na amplitude de quase todos os eventos, em relação ao nível de detalhe 2. Grande parte dos eventos que compõem o agrupamento de ruídos mantém a amplitude próxima ao grupo de espículas, restando apenas alguns poucos eventos de ruído com amplitudes altas. Houve uma dispersão maior do agrupamento de espículas, em relação à amplitude, mostrando que este nível de detalhe foi mais sensível a elas, do que os anteriores. Sendo assim, não há uma forma de separação do agrupamento de espículas, dos demais agrupamentos, através da utilização do nível de detalhe 3.

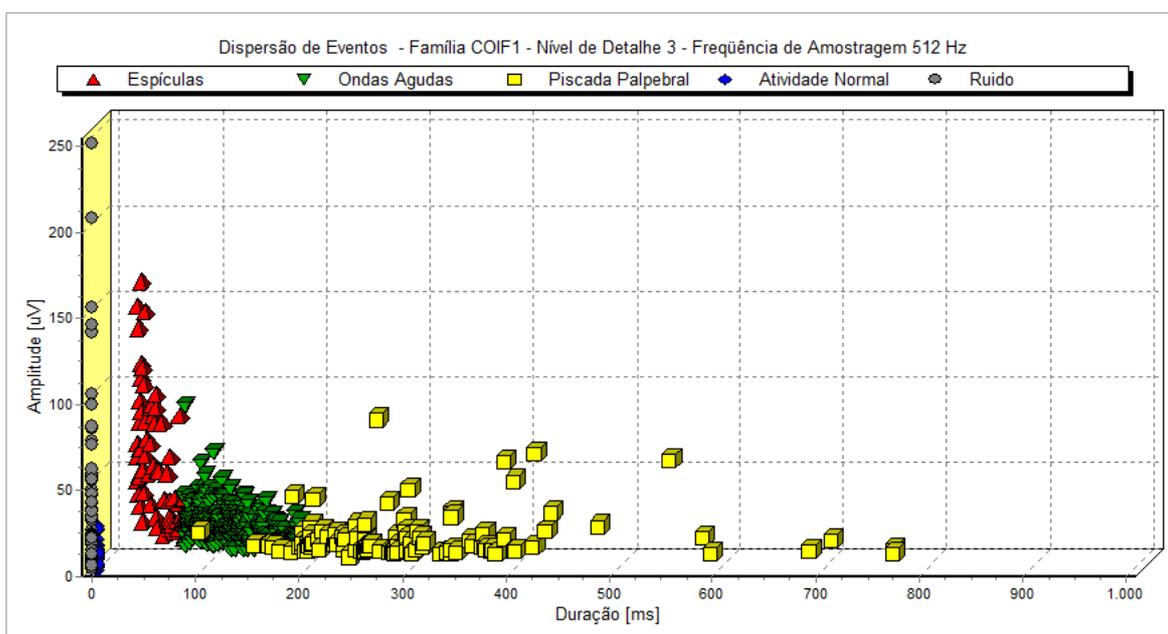


Figura 32 – Dispersão de eventos a partir da função *Coiflet 1* para o nível de decomposição 3.

Como visto nos níveis de detalhe anteriores o agrupamento de ruído apresenta alguns eventos com amplitudes superiores aos demais apresentados. Porém, é visível um aumento significativo nas amplitudes de ambos os grupos de espículas, mostrando que houve uma maior dispersão desses dois grupos em relação aos níveis de detalhe anteriores (Figura 33). O agrupamento de piscadas palpebrais também apresentou alguns poucos eventos com amplitudes elevadas, mas a grande parte deles fica na mesma faixa dos agrupamentos das espículas. O nível de detalhe 4 mostrou que, não há a possibilidade de fazer uma separação entre os eventos.

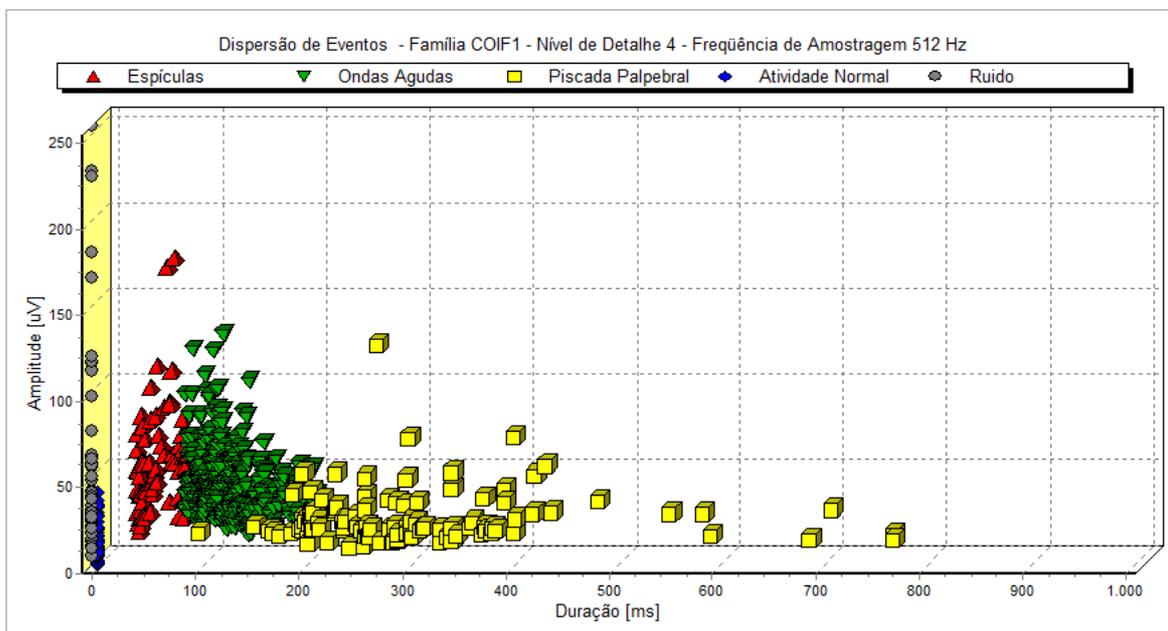


Figura 33 – Dispersão de eventos a partir da função *Coiflet 1* para o nível de decomposição 4.

O nível de detalhe 5 (Figura 34) apresenta uma dispersão maior entre as ondas agudas, devido ao fato de apresentarem amplitudes maiores que as espículas. Mesmo assim, ainda há eventos de outros grupos, como piscadas palpebrais, atividade de fundo e ruído que permanecem na mesma faixa de amplitude das espículas, o que dificulta ainda estabelecer um limiar de decisão para a separação entre as classes.

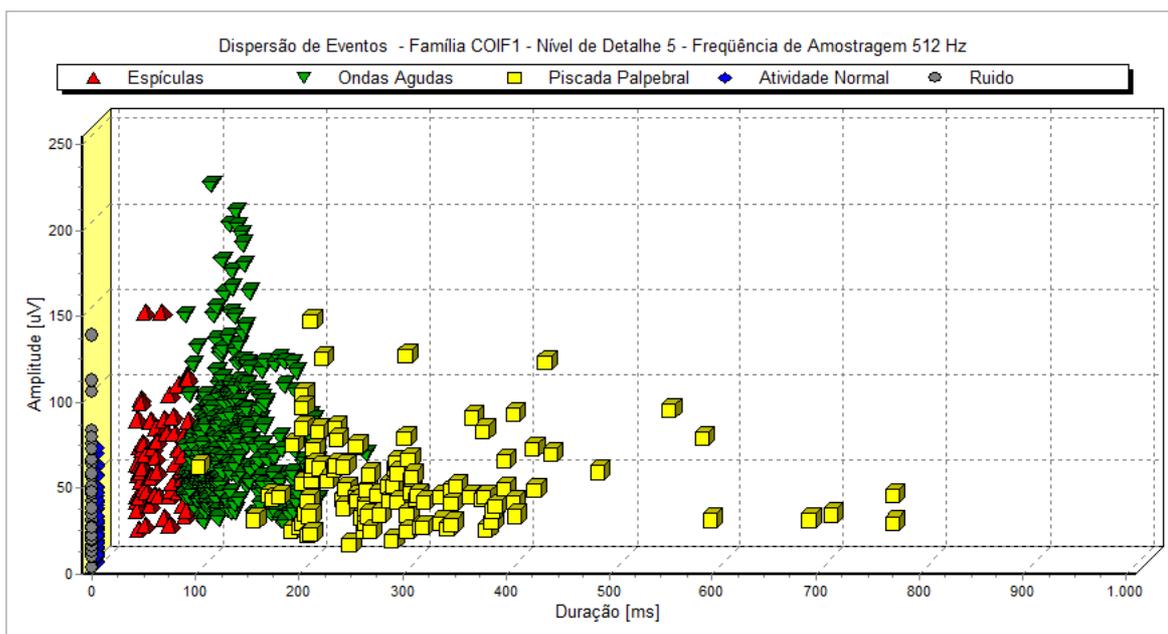


Figura 34 – Dispersão de eventos a partir da função *Coiflet 1* para o nível de decomposição 5.

O nível de detalhe 6 (Figura 35) apresenta um aumento na amplitude tanto das espículas, quanto das ondas agudas. Os eventos de atividade de fundo e ruído, bem como, as piscadas palpebrais mantiveram sua amplitude, ficando ainda na mesma faixa das espículas. Sendo assim, ainda não foi possível estabelecer um limiar de decisão para a separação entre os grupos.

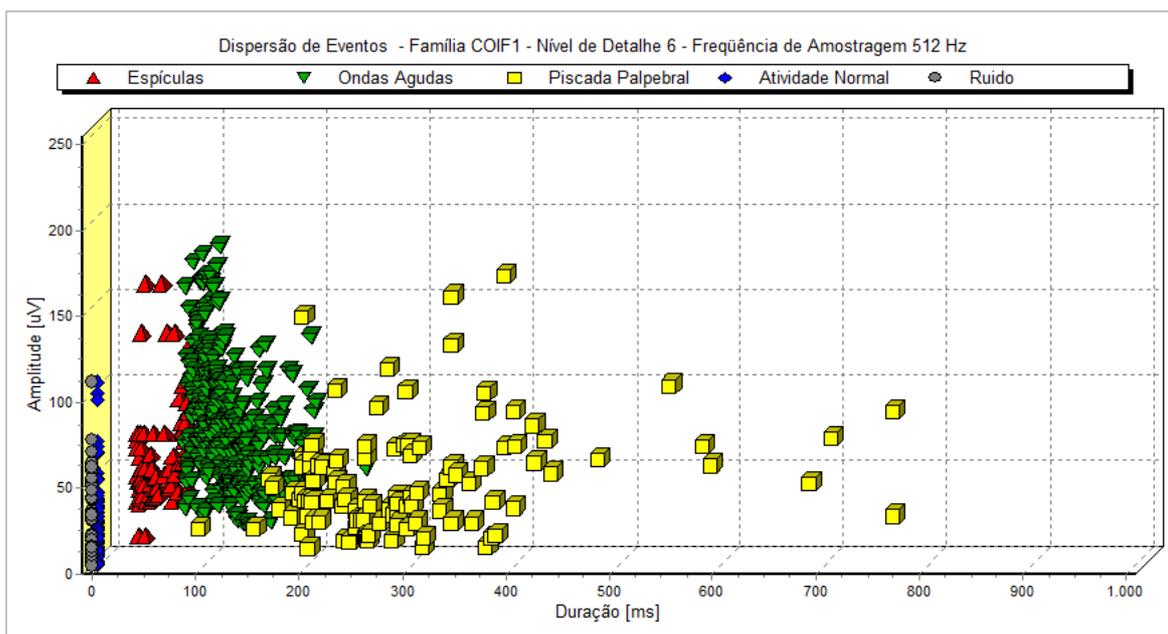


Figura 35 – Dispersão de eventos a partir da função *Coiflet 1* para o nível de decomposição 6.

Como visto nos níveis de decomposição anteriores, não foi possível definir uma forma de separação entre as classes de eventos. O nível de detalhe 7 (Figura 36) não apresenta grandes mudanças, em termos de separação dos agrupamentos, seguindo a mesma tendência dos níveis de detalhe apresentados anteriormente. Houve um aumento na amplitude das piscadas palpebrais, dispersando ainda mais este grupo de eventos. Todos os agrupamentos apresentam a mesma faixa de amplitudes. Sendo assim, a partir do nível de detalhe 7 também não foi possível estabelecer um limiar de decisão para a separação de eventos epileptiformes dos demais tipos de eventos.

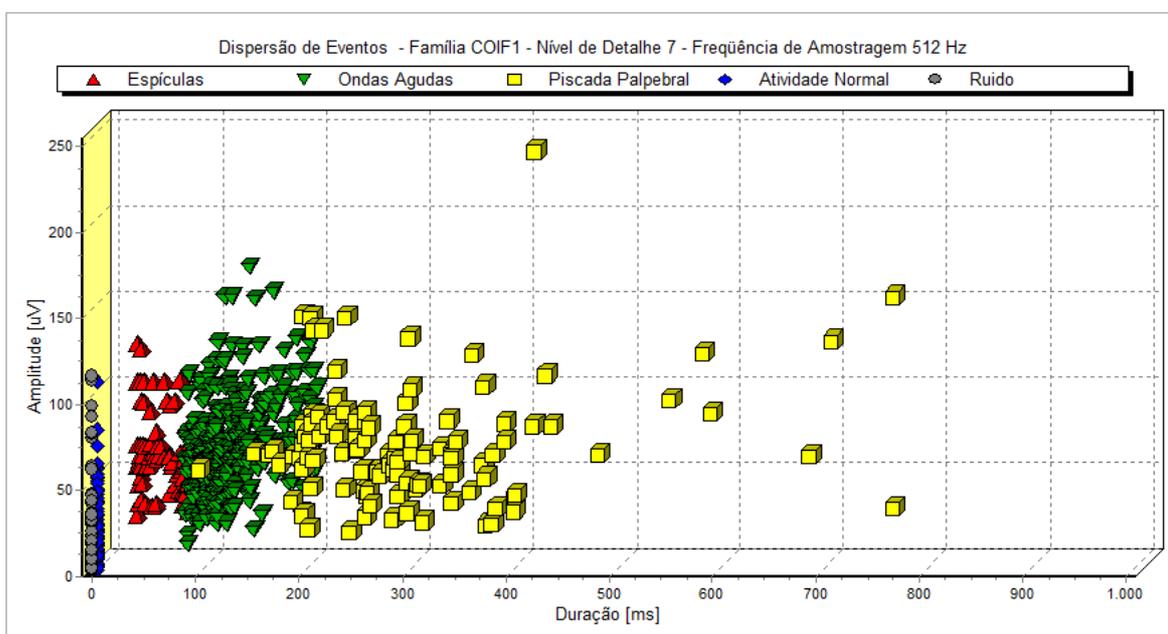


Figura 36 – Dispersão de eventos a partir da função *Coiflet 1* para o nível de decomposição 7.

O nível de detalhe 8 (Figura 37) apresenta grande espalhamento dos eventos de piscadas palpebrais. Tais eventos apresentaram um aumento em sua amplitude, bem como, para os eventos de atividade normal e ruído. O que não acontece para as classes de espículas, pois houve uma diminuição em suas amplitudes. O nível de detalhe 8 também não oferece uma forma de separação de eventos epileptiformes dos demais tipos de eventos.

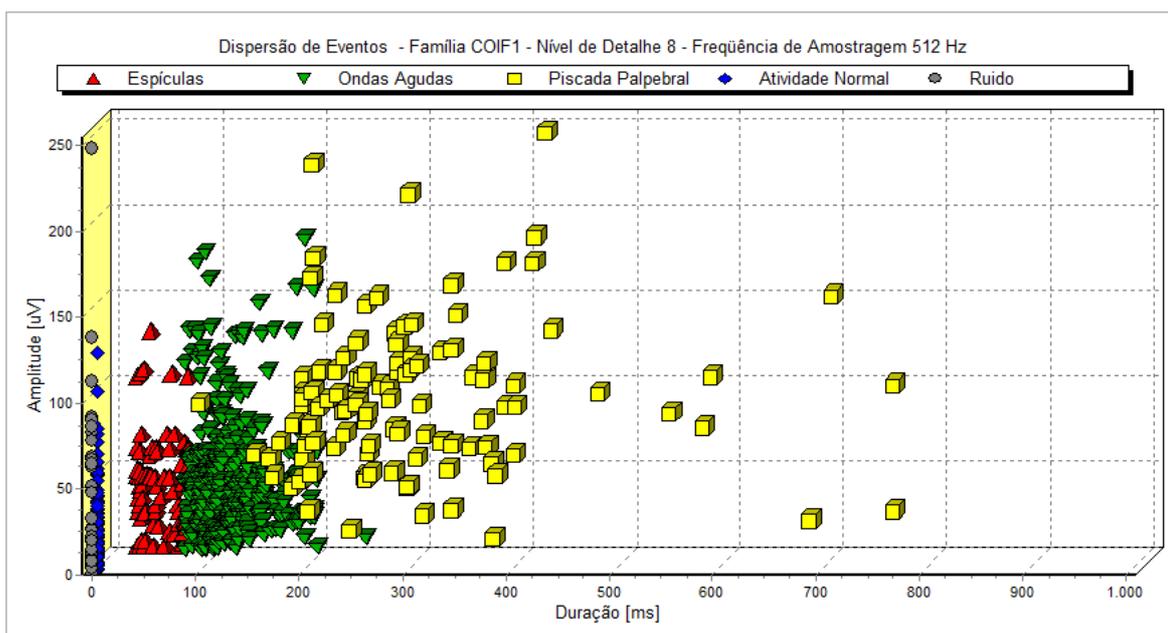


Figura 37 – Dispersão de eventos a partir da função *Coiflet 1* para o nível de decomposição 8.

No nível de detalhe 9 (Figura 38), pode ser visualizado um aumento significativo das amplitudes das piscadas palpebrais. Há uma diminuição das amplitudes dos eventos de atividade normal e ruído. Para o agrupamento de espículas, fica evidente uma diminuição das amplitudes, maior que o nível de detalhe anterior. O nível de detalhe 9 foi mais sensível às piscadas palpebrais, pois apresentou amplitudes maiores que os demais eventos. Seguindo a tendência dos níveis de detalhe anteriores, este também não ofereceu uma forma de separação de eventos epileptiformes dos demais tipos de eventos.

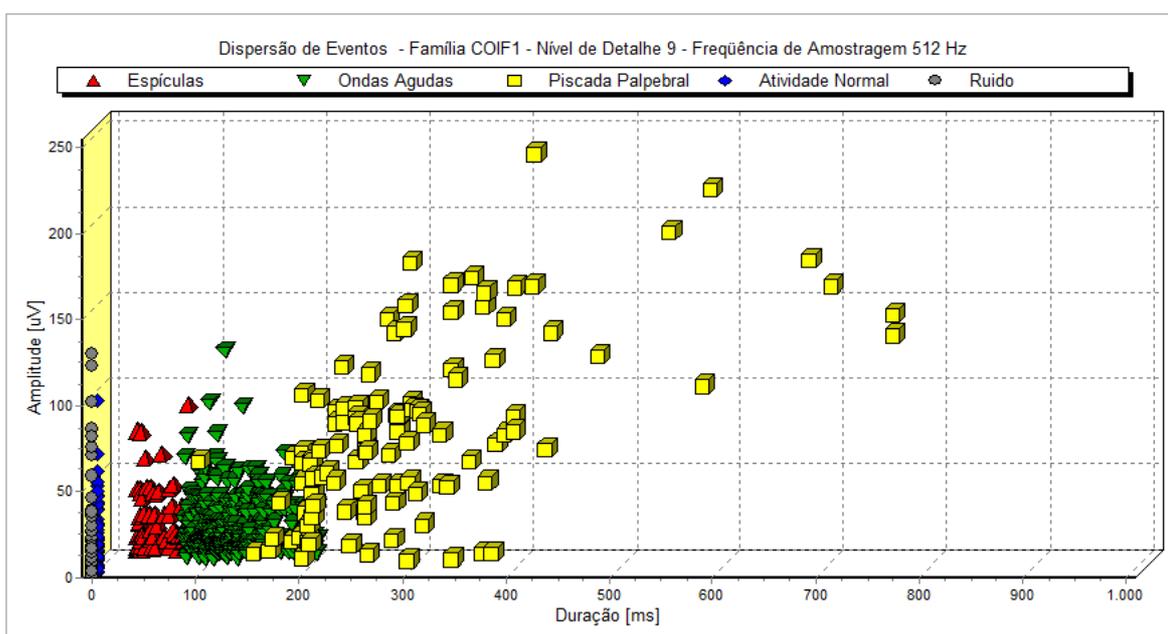


Figura 38 – Dispersão de eventos a partir da função *Coiflet 1* para o nível de decomposição 9.

No nível de detalhe 10 (Figura 39), houve uma redução nas amplitudes de todos os agrupamentos de eventos. Todos os eventos situam se na mesma faixa de amplitudes, demonstrando que este nível de detalhe também não apresentou uma forma de separação ente os grupos de eventos.

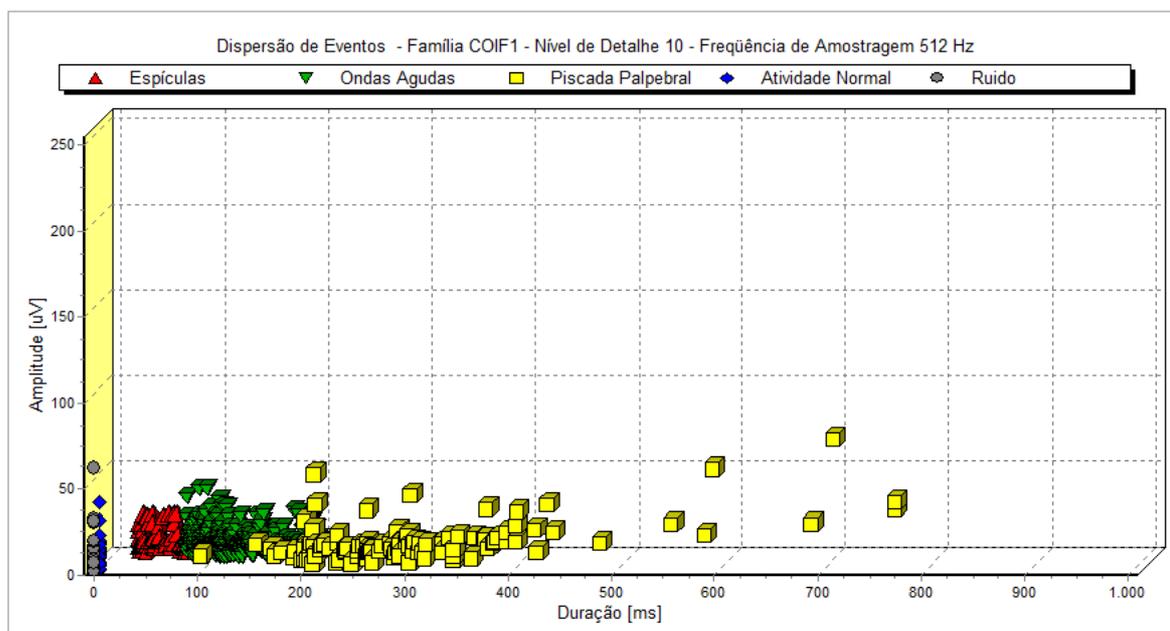


Figura 39 – Dispersão de eventos a partir da função *Coiflet 1* para o nível de decomposição 10.

Em resumo, pode-se observar que alguns níveis de detalhe são mais sensíveis para cada tipo de agrupamento. Porém, mesmo sendo sensível para um agrupamento, sempre haverá eventos de outros agrupamentos que também se destacam. Por exemplo, no nível de detalhe 2 (Figura 31) ficou visível o aumento das amplitudes dos eventos do grupo de espículas, mostrando que este nível foi sensível a esses eventos. Os demais agrupamentos de eventos mantiveram suas amplitudes mais baixas, em relação às espículas, exceto o agrupamento de eventos de ruído. Grande parte deles apresentou amplitudes iguais ou superiores aos das espículas. Para o nível de detalhe 5 (Figura 34), houve um aumento nas amplitudes das ondas agudas, mas houve certa sensibilidade aos eventos de piscadas palpebrais e aos eventos de atividade de fundo e ruído. O nível de detalhe 9 (Figura 38) foi mais sensível as piscadas palpebrais, mas seguindo a tendência dos níveis de detalhe

anteriores, alguns dos eventos que compõem os demais grupos também foram sensíveis a este nível de detalhe.

O objetivo da Transformada *Wavelet* é fazer o papel de um “filtro”, pré-processando as épocas de sinal antes de serem analisadas pelas redes neurais, indicando as épocas que podem ou não apresentar espículas, facilitando e agilizando o processamento do classificador. Porém, não houve uma forma de estabelecer um limiar de separação entre os agrupamentos de eventos, pois ocorre uma sobreposição entre eles. Dessa forma, as épocas de sinal foram aplicadas diretamente ao classificador, pois mesmo que fosse estabelecido um limiar de decisão, os eventos que seriam analisados pelo classificador neural não seriam apenas as espículas, e sim, eventos pertencentes aos demais grupos, como se pôde observar através dos gráficos descritos e apresentados anteriormente.

4.1.2 Deslocamento dos Eventos no Tempo

Outra observação importante sobre a Transformada *Wavelet*, que deve ser abordada, é em relação ao deslocamento dos eventos no tempo. Este experimento foi realizado com o objetivo de verificar o comportamento da Transformada *Wavelet*, ao deslocar uma janela de tamanho fixo (do mesmo tamanho da época do sinal), amostra a amostra, analisando assim um canal por inteiro do registro de EEG. Utilizando a forma de deslocamento de época em época, possíveis eventos epileptiformes, que possam ocorrer justamente nas bordas das épocas da página em análise, podem passar despercebidos pelo classificador neural. Deslocando a janela de sinal de amostra em amostra, todo o sinal será analisado e todos os eventos poderão ser identificados.



Figura 40 – (a) Ocorrência de eventos no final no instante de tempo, (b) ocorrência de eventos no meio do instante de tempo.

Para tentar resolver este problema foram realizados experimentos, deslocando eventos no tempo. Foi observado que, quando um evento é submetido a uma função *Wavelet*, determinado nível de detalhe se torna mais sensível a esse tipo de evento em especial, fazendo com que o sinal decomposto resultante desse processo, apresente um pico de amplitude elevada. O mesmo evento, deslocado algumas amostras no tempo, outros níveis de detalhe se tornam mais sensíveis. Por exemplo, na Figura 46 é apresentada uma espícula que foi submetida à Transformada *Wavelet*, e para este evento em específico, o nível de detalhe 6 foi mais sensível (Figura 41), apresentando um sinal decomposto com amplitude mais elevada que os demais níveis de detalhe. Deslocando o mesmo evento no tempo, o nível de detalhe 6, antes mais sensível, passa a apresentar amplitude mais baixa, devido ao fato de outros níveis de detalhe apresentar maior sensibilidade, neste caso, o nível de detalhe 5 (Figura 43 e Figura 46). Em vários experimentos realizados, que seguiram esse mesmo procedimento, foi observada uma variabilidade entre os níveis de detalhe, os quais seriam utilizados como forma de distinção entre eventos.

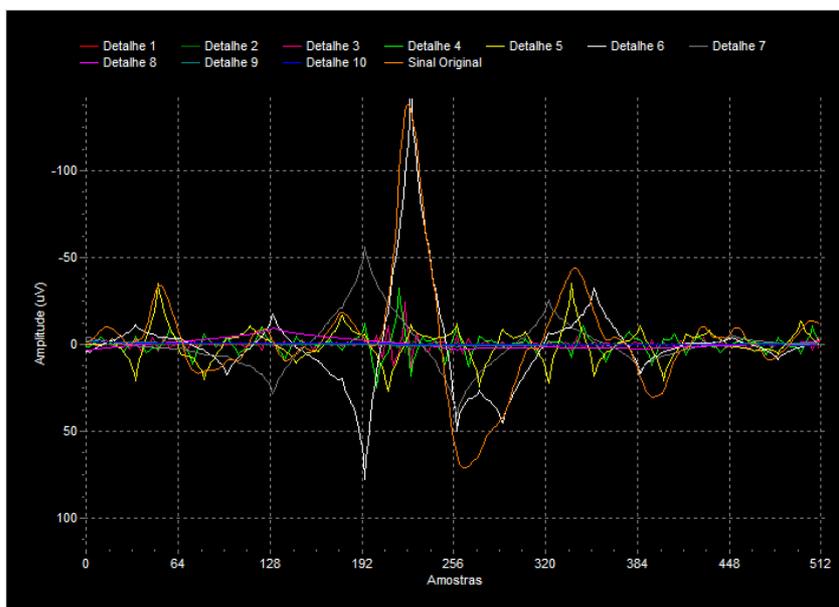


Figura 41 – Deslocamento de uma espícula no tempo (evento original).

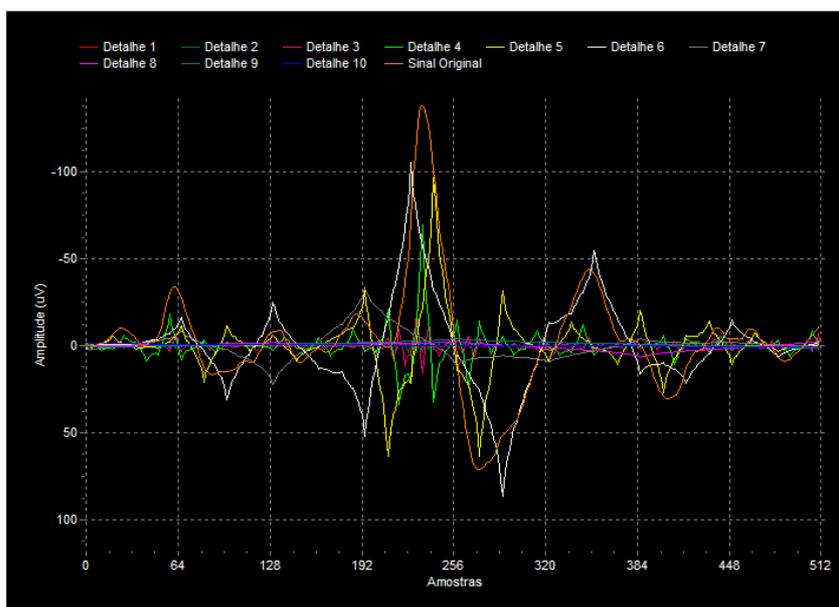


Figura 42 – Deslocamento de uma espícula no tempo (evento deslocado 10 amostras).

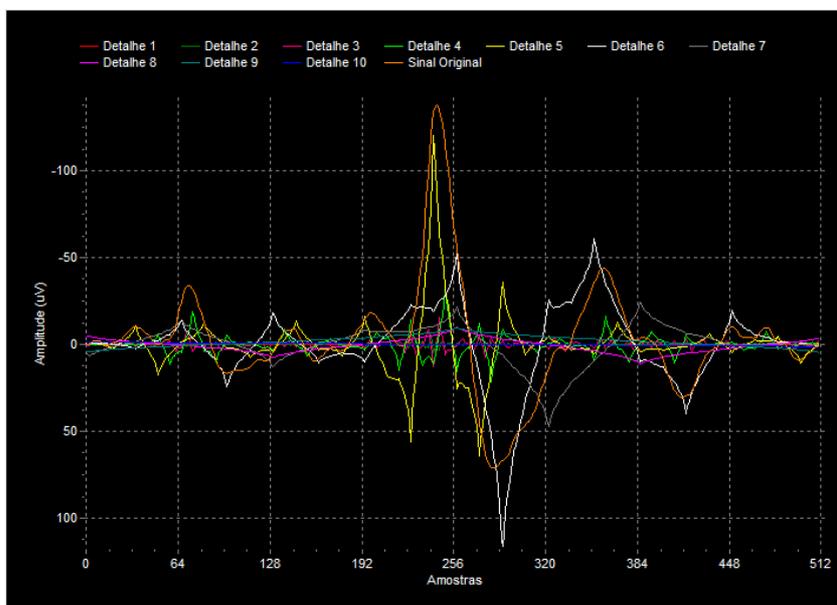


Figura 43 – Deslocamento de uma espícula no tempo (evento deslocado 20 amostras).

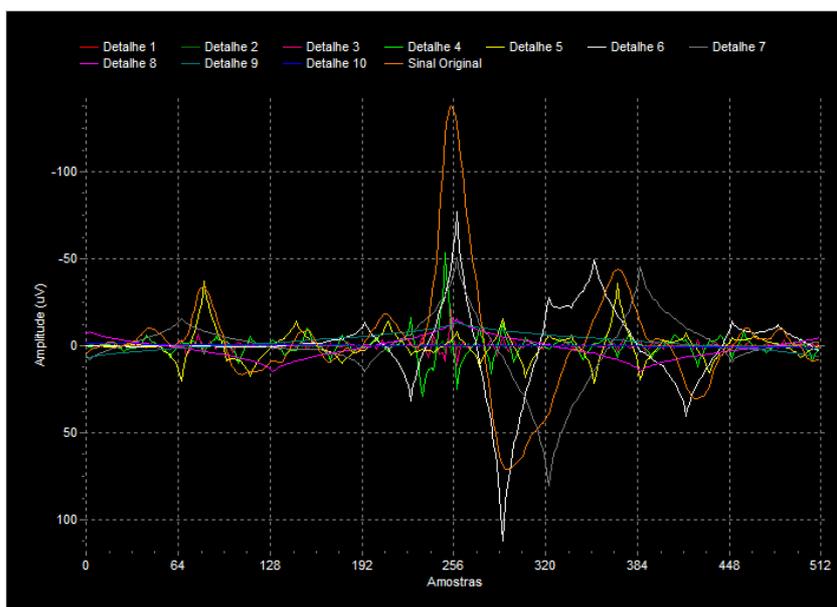


Figura 44 – Deslocamento de uma espícula no tempo (evento deslocado 30 amostras).

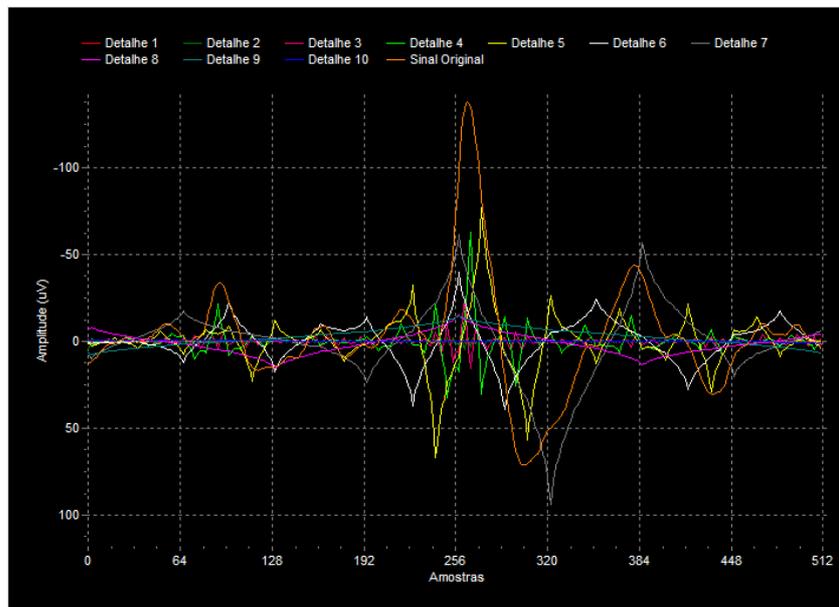


Figura 45 – Deslocamento de uma espícula no tempo (evento deslocado 40 amostras).

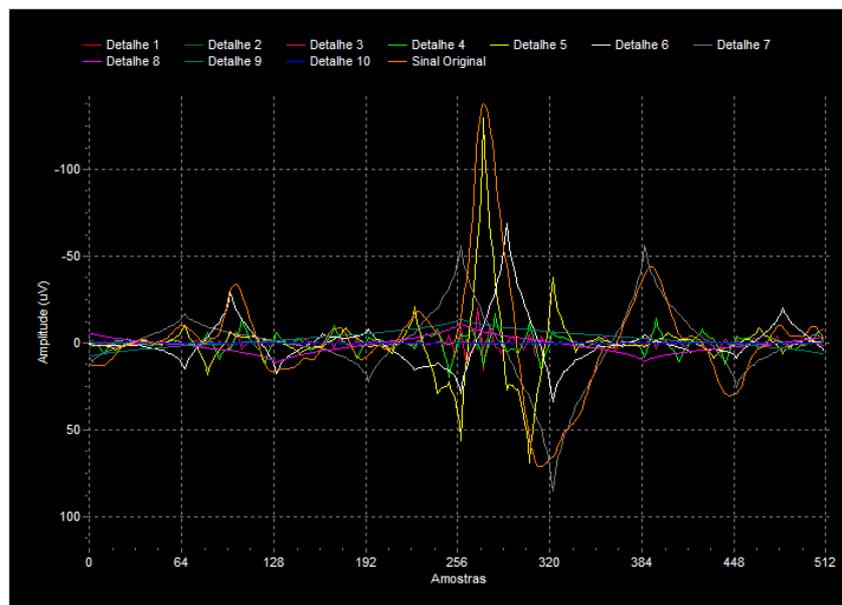


Figura 46 – Deslocamento de uma espícula no tempo (evento deslocado 50 amostras).

A partir dos resultados obtidos pela investigação realizada, ficou claro que deve ser feito um estudo mais abrangente, em relação à Transformada *Wavelet*, como forma de pré-processar as entradas do classificador neural, utilizando este conjunto de padrões em específico.

Quanto à questão do deslocamento da janela de sinal, com o objetivo de fazer uma análise completa de cada canal por inteiro, devem ser feitos mais experimentos, levando em consideração as características apresentadas pela Transformada *Wavelet*, em relação ao sinal resultante dos níveis de decomposição para a função *Coiflet 1*.

Quanto aos gráficos de dispersão, utilizando apenas a amplitude do sinal reconstruído de cada nível de detalhe, não houve uma forma prática de efetuar a separação entre os agrupamentos de eventos.

4.2 Avaliação dos Sinais de EEG Utilizando Redes Neurais Artificiais

Os eventos de entrada para o classificador neural foram os sinais de EEG no tempo. Para o treinamento da rede neural foram utilizados os conjuntos de padrões de treinamento, validação e teste descritos detalhadamente na sessão 3.6.

Após a verificação dos melhores treinamentos, adotou-se a seguinte configuração: inicialização aleatória de pesos sinápticos com valores entre $\pm 0,01$, taxa de aprendizagem de 0,002 e termo de momento de 0,7. Foi estipulado que a saída em nível alto (1) representa os eventos epileptiformes e a saída em nível baixo (0), representa os eventos não epileptiformes.

Durante o processo de treinamento da rede neural é calculado o erro médio quadrático, para o conjunto de padrões de treinamento e para o conjunto de padrões de validação. A Figura 47 apresenta a evolução da curva do Erro Médio Quadrático de Treinamento (EMQ_{Trein}) e da curva do Erro Médio Quadrático de Validação (EMQ_{Valid}). Pode-se observar que o erro médio quadrático para o conjunto de padrões de treinamento apresentou um decaimento contínuo, indicando a convergência do treinamento. Para o conjunto de padrões de validação houve um decaimento do erro médio quadrático de validação até a **época 530**, atingindo um valor mínimo ($EMQ_{\text{Valid}}=0,05180$), e ocorrendo

um aumento gradativo do erro, indicando a especialização da rede neural no reconhecimento dos padrões do conjunto de validação.

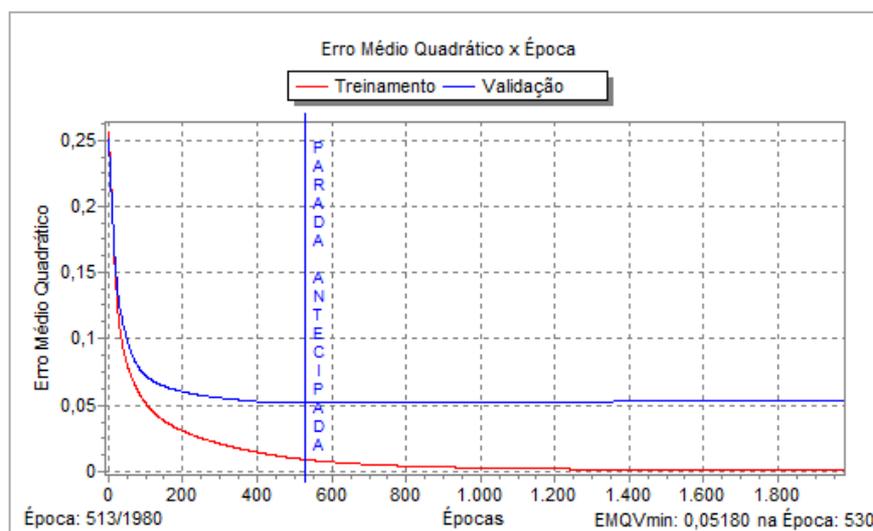


Figura 47 – Representação dos Erros Médios Quadráticos de Treinamento e de Validação em função de épocas de treinamento para o classificador de eventos epileptiformes.

Após o término do treinamento da rede neural foram obtidas as curvas que apresentam o comportamento da sensibilidade e da especificidade em função do limiar de decisão (Figura 48a) e as curvas de seletividade positiva e seletividade negativa em função do limiar de decisão (Figura 48b) para a época 513 do treinamento, a qual corresponde à época de maior valor do índice AUC da curva ROC.

Os indicadores estatísticos obtidos através do treinamento da rede neural possibilitaram o cálculo de outros índices de desempenho, os quais auxiliaram no processo de avaliação do classificador. Um dos índices utilizados, além do **índice AUC** da curva ROC, foi o **índice de Eficiência** do classificador.

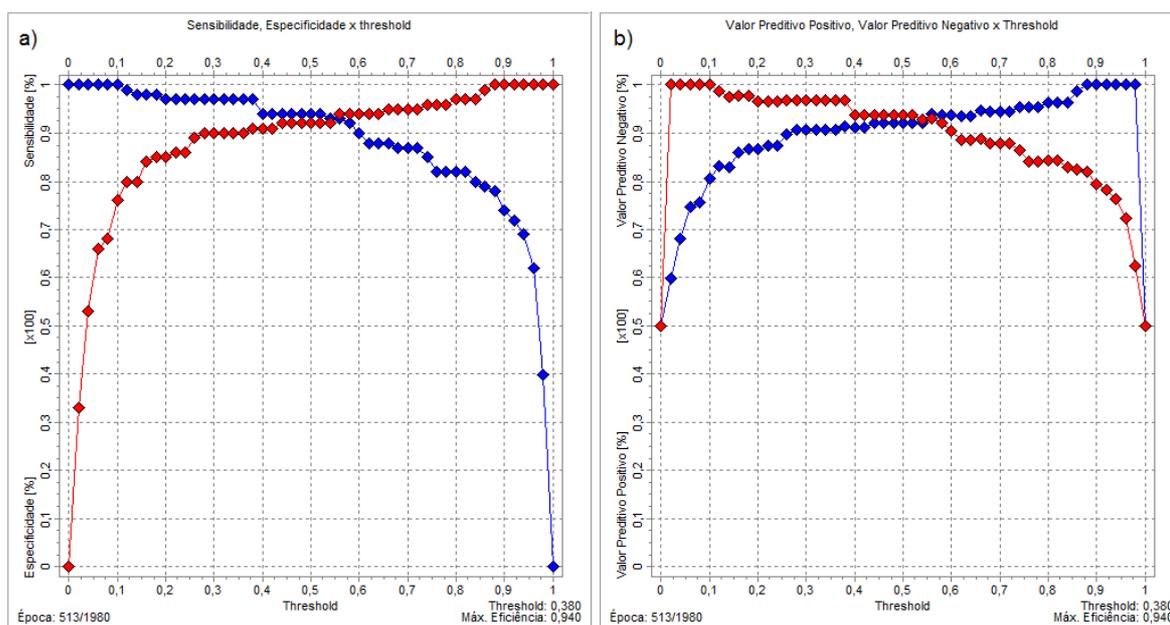


Figura 48 – (a) Sensibilidade e especificidade em função do limiar de decisão e em (b) valor preditivo positivo e valor preditivo negativo em função do limiar de decisão para a época 513 de treinamento do classificador neural de eventos epileptiformes.

Este índice é calculado em função do limiar de decisão, e indica ao classificador o ponto de corte que apresentou maior índice de eficiência, de acordo com os índices de sensibilidade e especificidade calculados anteriormente. A Figura 49 apresenta a curva de eficiência em função do limiar de decisão, para a época 513 de treinamento do classificador neural, onde se pode observar que o maior índice de eficiência ocorreu no limiar de decisão 0,38, atingindo 94% de eficiência. Isto quer dizer que, ajustado o ponto de corte do classificador para 0,38, os padrões acima deste valor foram classificados como eventos epileptiformes, abaixo deste valor os padrões foram classificados como eventos não epileptiformes, apresentando uma taxa de acertos de 94%. A partir deste índice de eficiência, o classificador apresentou índices de sensibilidade de 97,00%, especificidade de 91,00%, seletividade positiva de 91,51%, seletividade negativa de 96,81%, conforme apresentado pela Tabela 6.

A Figura 50 apresenta a curva ROC para a época 513 de treinamento, a qual apresentou o índice máximo $AUC_{Máx}=0,99910$. O classificador é representado pelos pesos sinápticos calculados para a época 513 do treinamento da rede neural.

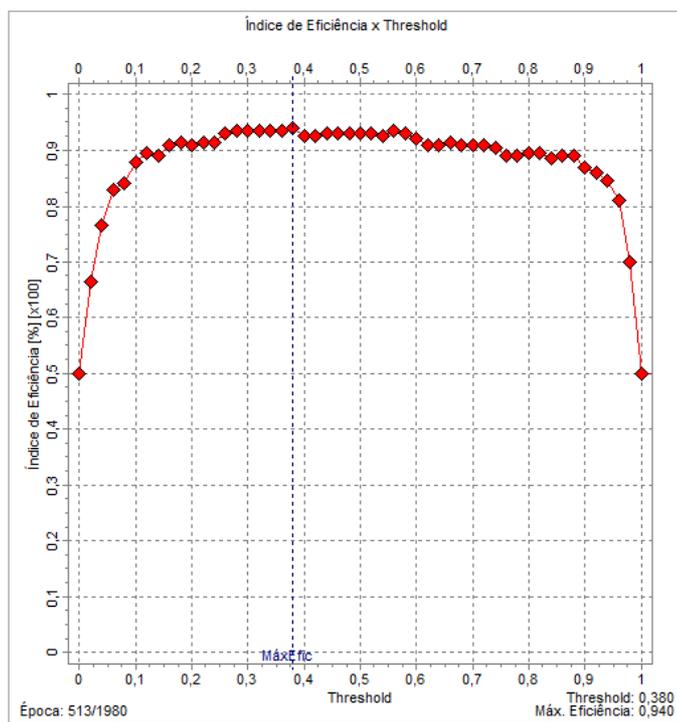


Figura 49 – Curva dos índices de eficiência calculada em função do limiar de decisão para a época 513 do classificador de eventos epileptiformes.

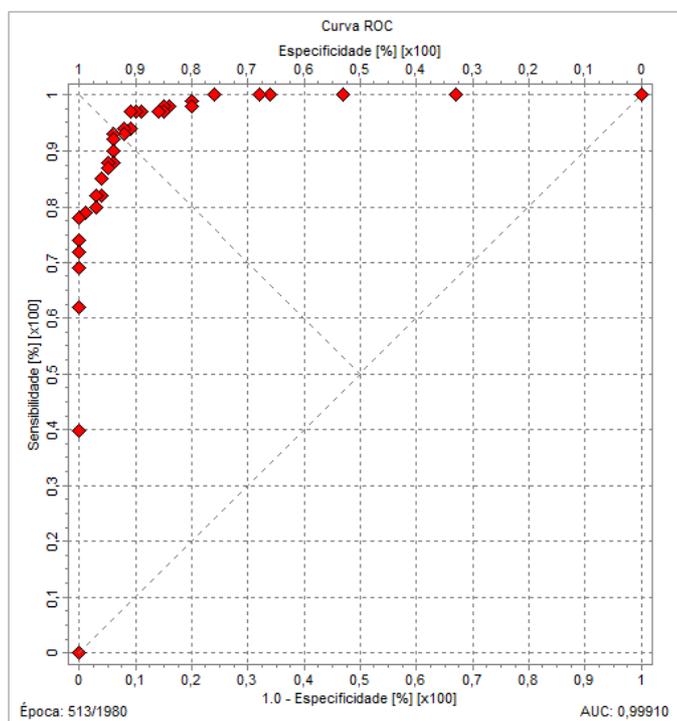


Figura 50 – Curva ROC para a época 513 de treinamento do classificador neural de eventos epileptiformes.

Os pontos que representam a curva ROC da Figura 50 foram obtidos através do ajuste do limiar de decisão, apresentado na Tabela 6.

Tabela 6 – Pontos característicos da curva ROC para a época 513 de treinamento do classificador neural de eventos epileptiformes.

| Limiar de Decisão | Sensibilidade [%] | Especificidade [%] | Seletividade Positiva [%] | Seletividade Negativa [%] | Índice de Eficiência [%] |
|-------------------|-------------------|--------------------|---------------------------|---------------------------|--------------------------|
| 0,00 | 100,00 | 0,00 | 50,00 | 0,00 | 50,00 |
| 0,04 | 100,00 | 53,00 | 68,03 | 100,00 | 76,50 |
| 0,08 | 100,00 | 68,00 | 75,76 | 100,00 | 84,00 |
| 0,10 | 100,00 | 76,00 | 80,65 | 100,00 | 88,00 |
| 0,14 | 98,00 | 80,00 | 83,05 | 97,56 | 89,00 |
| 0,18 | 98,00 | 85,00 | 86,73 | 97,70 | 91,50 |
| 0,20 | 97,00 | 85,00 | 86,61 | 96,59 | 91,00 |
| 0,24 | 97,00 | 86,00 | 87,39 | 96,63 | 91,50 |
| 0,28 | 97,00 | 90,00 | 90,65 | 96,77 | 93,50 |
| 0,30 | 97,00 | 90,00 | 90,65 | 96,77 | 93,50 |
| 0,34 | 97,00 | 90,00 | 90,65 | 96,77 | 93,50 |
| 0,38 | 97,00 | 91,00 | 91,51 | 96,81 | 94,00 |
| 0,40 | 94,00 | 91,00 | 91,26 | 93,81 | 92,50 |
| 0,44 | 94,00 | 92,00 | 92,16 | 93,88 | 93,00 |
| 0,48 | 94,00 | 92,00 | 92,16 | 93,88 | 93,00 |
| 0,50 | 94,00 | 92,00 | 92,16 | 93,88 | 93,00 |
| 0,54 | 93,00 | 92,00 | 92,08 | 92,93 | 92,50 |
| 0,58 | 92,00 | 94,00 | 93,88 | 92,16 | 93,00 |
| 0,60 | 90,00 | 94,00 | 93,75 | 90,38 | 92,00 |
| 0,64 | 88,00 | 94,00 | 93,62 | 88,68 | 91,00 |
| 0,68 | 87,00 | 95,00 | 94,57 | 87,96 | 91,00 |
| 0,70 | 87,00 | 95,00 | 94,57 | 87,96 | 91,00 |
| 0,74 | 85,00 | 96,00 | 95,51 | 86,49 | 90,50 |
| 0,78 | 82,00 | 96,00 | 95,35 | 84,21 | 89,00 |
| 0,80 | 82,00 | 97,00 | 96,47 | 84,35 | 89,50 |
| 0,84 | 80,00 | 97,00 | 96,39 | 82,91 | 88,50 |
| 0,88 | 78,00 | 100,00 | 100,00 | 81,97 | 89,00 |
| 0,90 | 74,00 | 100,00 | 100,00 | 79,37 | 87,00 |
| 0,94 | 69,00 | 100,00 | 100,00 | 76,34 | 84,50 |
| 0,98 | 40,00 | 100,00 | 100,00 | 62,50 | 70,00 |
| 1,00 | 0,00 | 100,00 | 0,00 | 50,00 | 50,00 |

Ao longo do treinamento da rede neural foram calculados os valores máximos para o índice AUC e para o índice de eficiência. A Figura 51 mostra o comportamento do índice AUC, para todas as épocas do treinamento, onde pode ser observado que o valor máximo ocorreu na época 513 ($AUC_{Máx}=0,99910$).

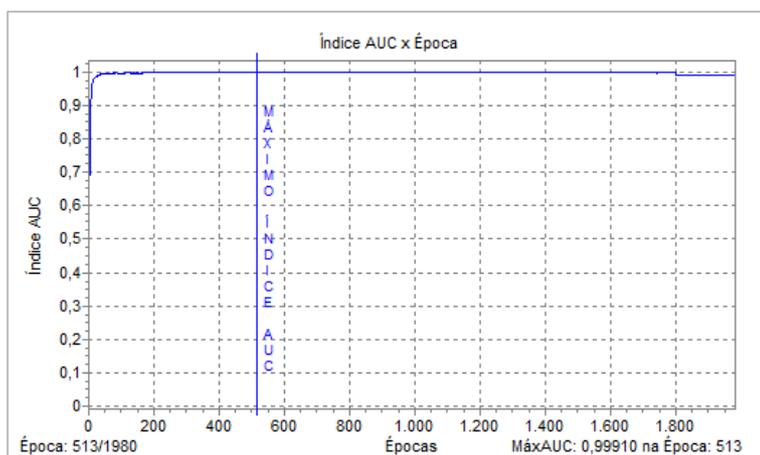


Figura 51 – Desempenho do índice AUC em função da época de treinamento.

A Figura 52 mostra o comportamento do índice de eficiência, para todas as épocas do treinamento, onde pode ser observado que o valor máximo ocorreu na época 312 ($eficiência_{Máx}=94,00\%$).

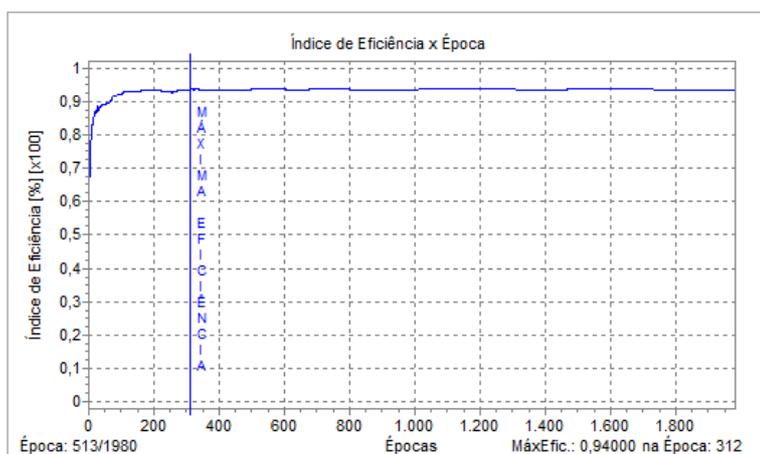


Figura 52 – Desempenho do índice de eficiência em função da época de treinamento.

Depois da avaliação do classificador neural e de seus índices de desempenho, um teste final foi realizado selecionando a **época 513**, a qual apresentou o maior índice AUC ($AUC_{Máx}=0,99910$), a **época 312**, a qual apresentou o maior índice de eficiência ($eficiência_{Máx}=94,00\%$) e a **época 530**, onde esta representa a época que ocorreu o menor erro de validação ($EMQ_{Valid}=0,05180$), caracterizando a parada antecipada do treinamento. Foi utilizado um conjunto de testes, composto por 285 eventos, todos diferentes dos demais conjuntos de padrões de treinamento e validação usados no processo de treinamento da rede, sendo que 176 deles correspondem a 29 espículas entre 20 e 70ms e 147 espículas entre 71 e 200ms. Os 109 eventos restantes são divididos em 36 eventos de piscadas, 56 eventos de atividade de fundo e 17 eventos contendo ruído.

A Figura 53 apresenta a classificação realizada pelo classificador neural, a partir da seleção da época 513 de treinamento, levando em consideração o limiar de decisão (**0,38**) que apresentou o maior índice de eficiência com o valor de **94,00%** de acertos.

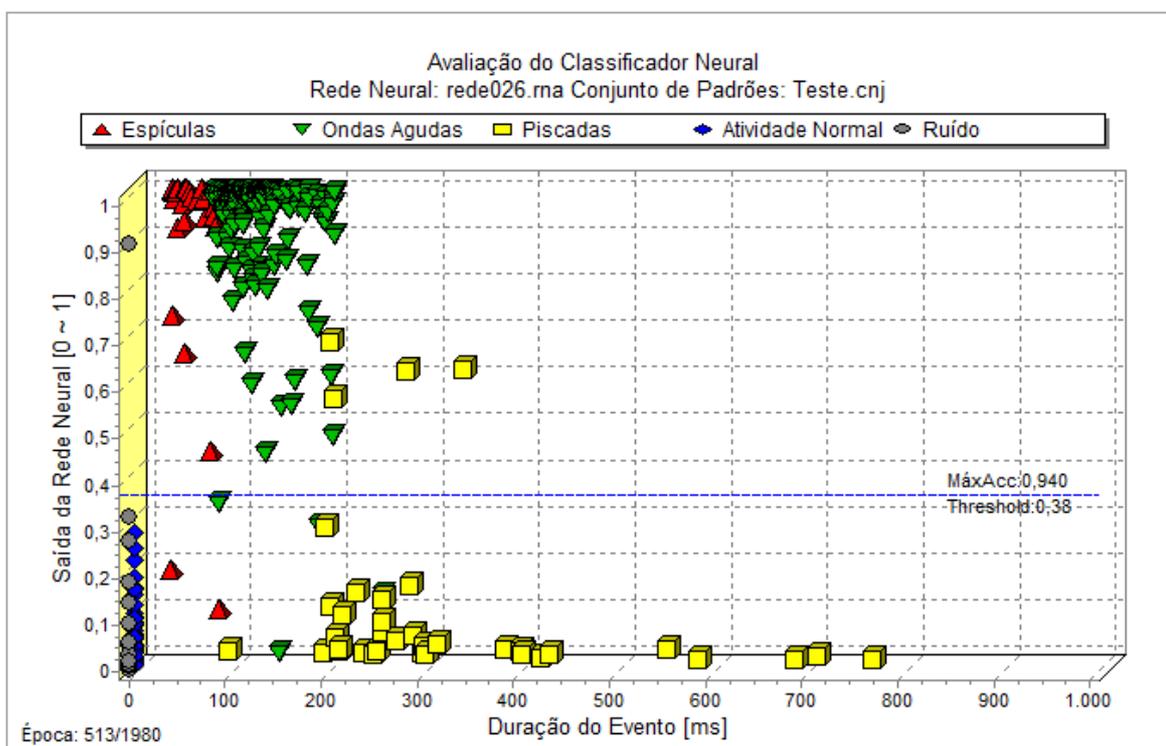


Figura 53 – Representação do teste realizado com o conjunto de padrões de teste, através da seleção da época 513 (Máximo Índice AUC) de treinamento do classificador neural.

Os resultados obtidos mostraram que, para a **época 513**, houve uma boa separação entre os eventos epileptiformes e não epileptiformes. Os eventos que representam os agrupamentos de espículas, cujo valor desejado é **igual a um**, concentraram-se na parte superior do gráfico, próximos de um. Para os eventos que representam os demais agrupamentos de eventos, cujo valor desejado é **igual a zero**, concentraram-se na parte inferior do gráfico, próximos de zero.

A Figura 54 apresenta a classificação realizada pelo classificador neural, a partir da seleção da **época 312** de treinamento, levando em consideração o limiar de decisão (**0,34**) que apresentou o maior índice de eficiência de **94,00%** de acertos.

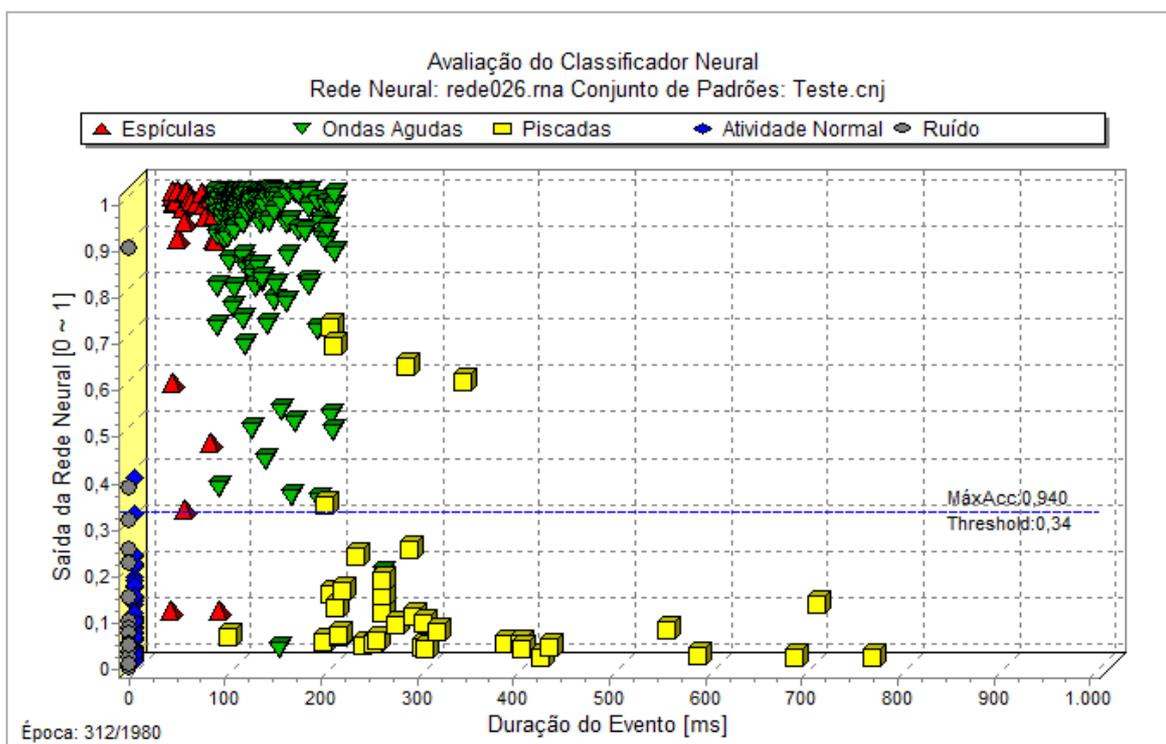


Figura 54 – Representação do teste realizado com o conjunto de padrões de teste, através da seleção da época 312 (Máximo Índice de Eficiência) de treinamento do classificador neural.

Os resultados obtidos mostraram que, para a **época 312**, também houve uma boa separação entre os eventos epileptiformes e não epileptiformes, mesmo apresentando um limiar de decisão um pouco mais baixo (**0,34**), sendo que a eficiência para esta época também chegou a **94,00%** de acertos.

Por fim, como último teste para o classificador, selecionou-se a época 530, a qual representa a parada antecipada, através do método de validação cruzada.

A Figura 55 apresenta a classificação realizada pelo classificador neural, a partir da seleção da **época 530** de treinamento, seguindo a tendência da **época 513**, por serem próximas uma da outra, o limiar de decisão obtido foi de **0,38**, o qual também apresentou o índice de eficiência com **94,00%** de acertos.

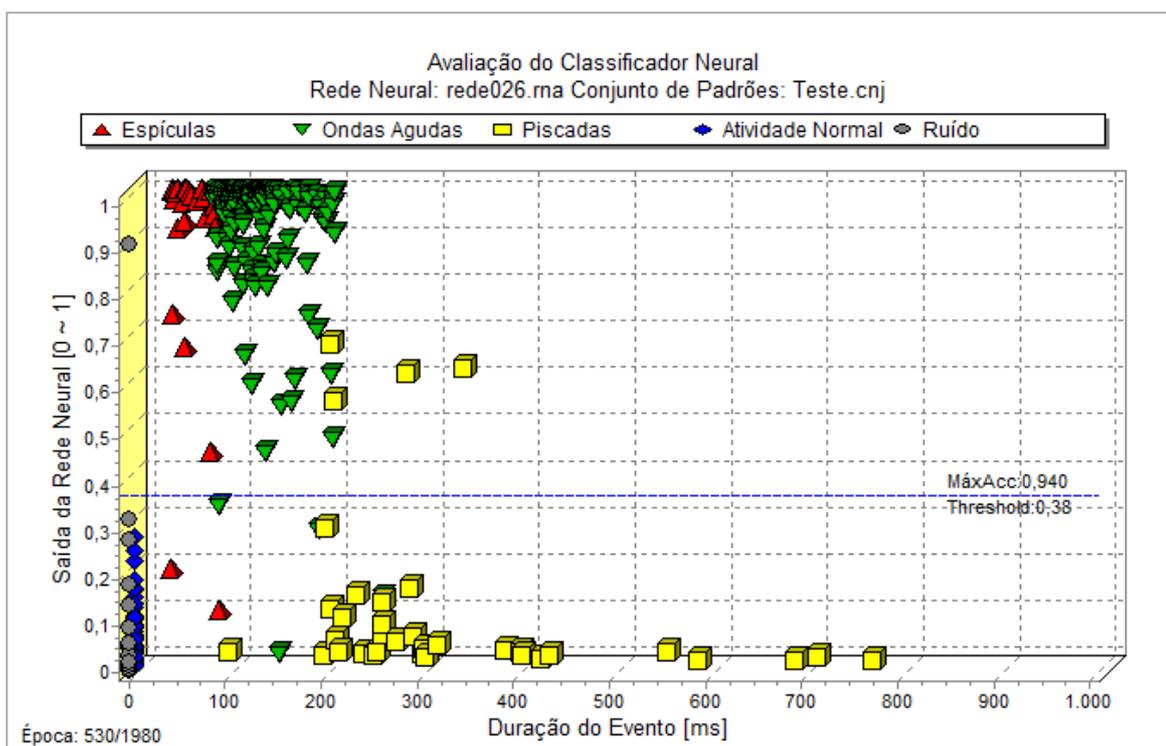


Figura 55 – Representação do teste realizado com o conjunto de padrões de teste, através da seleção da época 530 (Parada Antecipada) de treinamento do classificador neural.

Para facilitar o entendimento do quão importante é a utilização do método de validação cruzada, com parada antecipada, foi feita uma tabela comparativa com os principais índices de desempenho do classificador neural, **por época de treinamento**. Algumas épocas de treinamento da rede neural foram selecionadas e os seus respectivos índices de desempenho foram comparados. A **época 530** representou o ponto de ocorrência da **parada antecipada**. Já a **época 513** representou o ponto de ocorrência do **índice AUC**

máximo e a **época 312** representou o ponto de ocorrência do **índice de eficiência máxima** do classificador neural.

A Tabela 7 apresenta os índices de desempenho obtidos para o classificador neural. A **época 513** apresentou os maiores valores para a sensibilidade e especificidade, conseqüentemente, apresentou também os maiores valores para os índices de desempenho. A **época 600** apresentou valores de desempenho semelhantes à **época 513**, exceto para o **índice AUC máximo** ($AUC_{Máx}=0,99760$), ficando evidente que os melhores resultados foram obtidos na vizinhança da **época 530**, a qual foi o ponto de ocorrência da **parada antecipada**.

Tabela 7 – Comparação dos resultados obtidos entre as épocas de treinamento da rede neural.

| Época | EMQ _{trein} | EMQ _{valid} | VP | VN | FP | FN | Sens. [%] | Espec. [%] | VPP [%] | VPN [%] | Eficiência Máxima [%] | AUC Máximo |
|------------|----------------------|----------------------|------------|------------|----------|----------|--------------|--------------|--------------|--------------|-----------------------|----------------|
| 1 | 0,24992 | 0,24581 | 60 | 95 | 116 | 14 | 81,08 | 45,02 | 34,09 | 87,16 | 54,39 | 0,62150 |
| 50 | 0,08106 | 0,09933 | 156 | 95 | 20 | 14 | 91,76 | 82,61 | 88,64 | 87,16 | 88,07 | 0,99500 |
| 100 | 0,05138 | 0,07236 | 165 | 93 | 11 | 16 | 91,16 | 89,42 | 93,75 | 85,32 | 90,53 | 0,99600 |
| 312 | 0,02028 | 0,05528 | 169 | 102 | 7 | 7 | 96,02 | 93,58 | 96,02 | 93,58 | 95,09 | 0,99790 |
| 450 | 0,01221 | 0,05211 | 172 | 101 | 4 | 8 | 95,56 | 96,19 | 97,73 | 92,66 | 95,79 | 0,99830 |
| 513 | 0,00973 | 0,05180 | 170 | 104 | 6 | 5 | 97,14 | 94,55 | 96,59 | 95,41 | 96,14 | 0,99910 |
| 530 | 0,00918 | 0,05180 | 170 | 104 | 6 | 5 | 97,14 | 94,55 | 96,59 | 95,41 | 96,14 | 0,99850 |
| 600 | 0,00734 | 0,05186 | 170 | 104 | 6 | 5 | 97,14 | 94,55 | 96,59 | 95,41 | 96,14 | 0,99760 |
| 850 | 0,00394 | 0,05228 | 171 | 101 | 5 | 8 | 95,53 | 95,28 | 97,16 | 92,66 | 95,44 | 0,99770 |
| 1730 | 0,00123 | 0,05324 | 170 | 102 | 6 | 7 | 96,05 | 94,44 | 96,59 | 93,58 | 95,44 | 0,99630 |

A seleção das épocas de treinamento, correspondentes à ocorrência dos índices de desempenho do classificador neural, ou mesmo, épocas próximas ao ponto de ocorrência da parada antecipada, forneceram bons resultados no processo de classificação entre eventos epileptiformes e eventos não epileptiformes nos sinais de EEG. Com isso, conclui-se que a utilização do método de validação cruzada, com parada antecipada, auxilia o processo de treinamento da rede neural, o que proporciona a identificação das melhores épocas de treinamento.

5. DISCUSSÕES E CONCLUSÃO

5.1 Discussões

O classificador neural implementado neste trabalho consiste de uma rede neural artificial, a qual foi treinada a partir de **cinco** classes de eventos distintas: **espículas, ondas agudas, piscadas palpebrais, atividade de fundo de EEG e ruídos**, sendo que os sinais de entrada da rede não foram pré-processados.

Inicialmente optou-se em utilizar a Transformada *Wavelet*, como forma de pré-processamento das épocas de sinal, antes que as mesmas fossem apresentadas as entradas do classificador. Dessa forma o classificador neural, analisaria apenas as épocas que tivessem eventos com morfologia semelhante aos eventos epileptiformes, verificando se os eventos analisados seriam mesmo eventos epileptiformes ou não, o que agilizaria o processo de classificação. Porém, os dados obtidos através dos experimentos realizados não apresentaram os resultados esperados, ou seja, não foi possível fazer uma distinção entre os eventos epileptiformes e não epileptiformes.

A definição da base *Wavelet* adequada neste estudo foi tomada considerando-se os resultados obtidos na tese defendida por Argoud (2001), na qual é indicada a função *Wavelet Coiflet 1*, nos níveis de decomposição 2 e 3. Os níveis indicados geram sinais com formas características e com altas amplitudes durante a ocorrência das espículas e das ondas agudas. Para os demais tipos de eventos presentes nos sinais de EEG, os sinais gerados apresentam baixas amplitudes, destacando assim os eventos epileptiformes dos não epileptiformes, comprovado posteriormente por Pereira (2003) em sua tese.

Experimentos foram realizados, submetendo os eventos do banco de sinais aos níveis de decomposição 1 a 10, da função *Coiflet 1*. Foram gerados os gráficos de dispersão, um para cada nível de detalhe. Através da análise visual dos gráficos, ficou claro que não haveria uma forma de separar os agrupamentos de eventos, utilizando apenas a amplitude dos sinais processados e reconstruídos, resultante da decomposição de cada níveis de detalhe. Os níveis de detalhe que apresentaram maiores amplitudes do sinal decomposto, para os agrupamentos de espículas foi o nível de detalhe 3 e para as ondas agudas foram os níveis de detalhe 5 e 6. Porém, observou-se também, que outros eventos apresentaram faixas de amplitude do sinal decomposto, próximas ou até superiores as

amplitudes do agrupamento das espículas e ondas agudas. Numa aplicação prática, não seria possível definir um limiar de decisão, para realizar a separação dos eventos, apenas utilizando as amplitudes dos sinais decompostos.

Os dados obtidos sugerem que, um dos fatores que influenciaram em tamanha discrepância, entre os resultados apresentados neste trabalho e os resultados obtidos por Argoud (2001) e Pereira (2003), foi em relação à frequência de amostragem dos sinais utilizados. O banco de sinais deste trabalho, apresenta sinais com frequência de amostragem de 512Hz, diferente dos sinais utilizados nos trabalhos citados anteriormente, os quais apresentavam uma frequência de amostragem de apenas 100Hz.

Em relação ao classificador, foi utilizada apenas **uma** rede neural no processo de classificação dos eventos epileptiformes. A rede treinada foi capaz de realizar a separação entre **cinco** classes **distintas** de padrões encontrados em sinais de EEG. Tais afirmações discordam com os dados obtidos por Pereira (2003), a qual afirma que, o treinamento de uma **única** rede neural para diferenciar espículas, piscadas, ruídos e ondas alfa, isto é, **quatro** padrões diferentes mostrou-se **inadequado**. Pereira (2003) também propôs o treinamento de uma rede neural para o reconhecimento específico de cada um destes padrões, o que deveria teoricamente facilitar os processos de treinamento. Os dados obtidos neste estudo, mostram que é possível a classificação de cinco classes distintas de padrões e sugerem também que os resultados foram influenciados pela alta taxa da frequência de amostragem dos sinais utilizados. Quanto mais características forem passadas a rede, melhor será a discriminação entre os padrões, o que justifica a correta classificação entre as classes de eventos.

Os sinais de EEG no tempo e sem pré-processamento foram aplicados diretamente nas entradas da rede neural em épocas de um segundo. Cada amostra do sinal foi atribuída a cada uma das 512 entradas que a rede apresenta.

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.

Na avaliação do classificador, foram empregados os índices de desempenho, os quais são aplicados na avaliação dos testes-diagnósticos. Os experimentos realizados mostraram que a utilização das épocas de treinamento, indicadas pelos índices de desempenho, **AUC** e de **eficiência**, apresentaram bons resultados, pois ambos se localizam próximos à época indicada pela parada antecipada. Através da avaliação utilizando os índices de desempenho citados, conseguiu-se obter um classificador neural capaz de separar eventos epileptiformes (**espículas e ondas agudas**) dos eventos não epileptiformes (**piscadas palpebrais, atividade normal de fundo e ruído**), apresentando um **total de acertos de 96,14%**.

Na questão da avaliação do desempenho entre os sistemas anteriormente citados, não foi possível realizar uma comparação adequada, com os resultados obtidos neste trabalho, devido ao fato, dos sinais apresentarem características diferentes, em relação à montagem, resolução e frequência de amostragem. Argoud (2001), Pereira (2003) e Sala (2005), utilizaram **quatro** redes em paralelo, o que impossibilitou a comparação entre os resultados obtidos por apenas uma rede neural, como é o caso deste trabalho.

Por outro lado, Travessa (2006) utilizou uma rede neural do tipo MLP, para a classificação de eventos epileptiformes e comparou os resultados com uma rede neural complexa. A rede MLP apresentou 100 neurônios de entrada, 27 neurônios na camada intermediária e 1 neurônio na camada de saída. Os sinais foram aplicados diretamente nas entradas da rede. Foram utilizados cerca de 120 eventos para o treinamento da rede, obtendo índices estatísticos de sensibilidade e especificidade com taxas simultâneas de

55%. Em comparação com o classificador implementado neste trabalho, utilizou-se uma rede neural do tipo *feedforward* multicamadas, para a classificação de eventos epileptiformes, com 512 neurônios de entrada, 10 neurônios na camada intermediária e 1 neurônio na camada de saída. Os sinais no tempo foram aplicados diretamente nas entradas da rede sem pré-processamento. Foram utilizados cerca de 200 eventos para o treinamento da rede, 200 para a validação e 285 eventos para os testes, todos diferentes entre si. O classificador obteve os seguintes índices: sensibilidade de **97,14%**, especificidade de **94,55%**, seletividade positiva de **96,59%**, seletividade negativa de **95,41%** e eficiência (ou taxa de acertos) de **96,14%**.

5.2 Conclusão

Os dados obtidos sugerem que houve influência da frequência de amostragem, dos sinais utilizados neste trabalho, em muitos dos resultados alcançados. A Transformada *Wavelet* obteve resultados inesperados, a partir da utilização da função *Coiflet 1*. Os experimentos mostraram que não foi possível estabelecer uma forma de distinção entre as espículas e ondas agudas, dos demais tipos de eventos. Talvez utilizando outras funções *Coiflet* de ordem maior, ou mesmo outras famílias de funções *Wavelet*, ou ainda a combinação entre famílias, possa fornecer uma forma eficaz de distinção entre os eventos, para esta frequência de amostragem em específico.

Quanto ao processo de treinamento da rede, utilizou-se o algoritmo *backpropagation* e o método de **validação cruzada** com **parada antecipada** em conjunto com o **algoritmo integrado de avaliação do classificador**, proposto por Sovierzoski (2009).

A validação cruzada mostrou ser uma forma eficiente de interromper antecipadamente o processo de treinamento. Os resultados mostraram que, as épocas que obtiveram os melhores índices de desempenho, ficaram **próximas** (algumas poucas épocas antes ou depois) da época identificada pela parada antecipada, garantindo que o treinamento não se prolongue por centenas de milhares de épocas de treinamento, evitando a especialização da rede e o processamento desnecessário.

O algoritmo integrado de avaliação do classificador agilizou o processo de avaliação do classificador neural, pois ao final do treinamento da rede, os índices **AUC** (*Area Under the Curve*) e de **Eficiência** são calculados, cabendo apenas ao usuário, escolher os valores de sensibilidade e especificidade, que ele gostaria que o classificador atuasse.

Em conclusão, é possível a utilização de apenas **uma** rede neural artificial no processo de **classificação** de eventos epileptiformes (**espículas e ondas agudas**) e de eventos não epileptiformes (**piscadas palpebrais, atividade de fundo e ruídos**) em sinais de EEG, sem pré-processamento dos sinais aplicados as entradas da rede neural, pois a metodologia implementada apresentou resultados quantitativos aceitáveis.

6. TRABALHOS FUTUROS

Propõem-se uma investigação mais aprofundada em relação às diferentes famílias *Wavelet*, quanto às altas frequências de amostragem dos sinais. Poderiam ser estudadas outras formas de processamento estatístico e proposta a sua utilização em conjunto com as funções *Wavelet*, na tentativa de estabelecer uma forma de separação entre as classes de eventos.

Deve ser feita uma investigação mais abrangente, em relação ao deslocamento no tempo, das épocas em análise. Através dos resultados apresentados ficou claro que, quando há um deslocamento no tempo, os níveis de detalhe mudam, constantemente, o que dificulta na escolha de um ou mais níveis de detalhe como fator de decisão, na indicação de qual nível de detalhe é mais sensível a um determinado tipo de evento.

Propõem-se também o desenvolvimento de um sistema para a classificação de sinais de EEG, onde o classificador neural desenvolvido, poderia ser incorporado e testado mais a fundo, para avaliar o seu desempenho na identificação de eventos epileptiformes, em traçados de EEG de outros pacientes.

**ANEXO A – PARECER DO COMITÊ DE ÉTICA EM
PESQUISAS COM SERES HUMANOS DA
UNIVERSIDADE FEDERAL DE SANTA CATARINA**



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

CERTIFICADO N° 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.º0584/GR/99 de 04 de novembro de 1999, com base nas normas para a constituição e funcionamento do CEPSH, considerando o contido 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 Scolaro.

DPTO.: CTC/UFSC

FLORIANÓPOLIS, 25 de novembro de 2008.

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

**ANEXO B – PARECER DO COMITÊ DE ÉTICA EM
PESQUISAS COM SERES HUMANOS DO HOSPITAL
GOVERNADOR CELSO RAMOS**



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

| | |
|---|-------------------------|
| PROCOLO 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 submetidos 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

REFERENCIAS BIBLIOGRÁFICAS

Argoud, F.I.M., Contribuição ao Estudo da Automatização da Detecção e Análise de Eventos Epileptiformes em Eletroencefalograma, Tese de Doutorado, Universidade Federal de Santa Catarina, Florianópolis, Brasil, Engenharia Elétrica, 2001.

Bear, M.F., Connors, B.W., Paradiso, M.A., *Neurociências: Desvendando o Sistema Nervoso*, 2ª edição, Artmed, Porto Alegre, 2002.

Bertemes Filho, P., Uma Proposta de Um Sistema Telemétrico para Registro de Potenciais Bioelétricos, Dissertação de Mestrado, Florianópolis, Brasil, UFSC, Engenharia Elétrica Opção Engenharia Biomédica, 1998.

Braga, A.C.S., Curvas ROC: Aspectos Funcionais e Aplicações, Tese de Doutorado, Universidade do Minho, Braga, Portugal, 2000.

Coimbra, A.J.F., Marino Neto, J., De Azevedo, F.M., Freitas, C.G., Barreto, F.M., “Automatic Detection of Sleep-Waking States Using Kohonen Neural Networks”. I Congresso Brasileiro de Redes Neurais, Itajubá, MG, 24-27, Outubro 1994, Anais pp: 327-331.

Coimbra, A.J.F., Marino Neto, J., De Azevedo, F.M., Freitas, C.G., Barreto, F.M., “Brain Electrographic State Detection Using Combined Unsupervised and Supervised Neural Networks”. In: Artificial Neural Nets and Genetic Algorithms, Spring Verlag, D.W. Pearson & N.C. Steele & R.F. Albrecht (Eds), 1995, pp: 76-79.

De Azevedo, F.M., Brasil, L.M., Oliveira, R.C.L., *Redes Neurais com aplicação em Sistemas Especiais*, Visual Book, 1997.

Eberhart, R.C., Dobbins, R.W., *Neural Networks PC Tools. A Practical Guide*, Academic Press, 1990.

Fischbach, F.T., Dunning; M.B., *A Manual of Laboratory and Diagnostic Tests, eighth Edition*, Lippincott Williams e Wilkins, 2009, p.1-13.

Fletcher, R.W., Fletcher, S.W., *Clinical Epidemiology: the essentials*, 4th Edition, Lippincott Williams e Wilkins, 2005, p.35-58.

Goroll, A.H., Mulley, A.G., *Primary Care Medicine: Office Evaluation and Management of the Adult Patient*, 6th Edition, Lippincott Williams e Wilkins, 2009, p.9-13.

Guerreiro, C.A.M., Guerreiro, M.M., *Epilepsia*, 2^o ed., Lemos Editorial, São Paulo, 1993.

ILAE, Commission on Classification and Terminology of the International League Against Epilepsy, "Proposal for Revised Classification of Epilepsies and Epileptic Syndromes", *Epilepsia*, vol. 30, pp. 389-399, 1989.

Jekel, J.F., Katz, D.L., Elmore, Joann G., *Epidemiology, Biostatistics and Preventive Medicine*, Second Edition, W. B. Saunders Company, 2001, p.108-109.

Luccas, F.J.C., Braga, N.I.O., Silvado, C.E.S., "Recomendações Técnicas para o Registro de Eletroencefalograma (EEG) na Suspeita da Morte Encefálica", *Arquivos de Neuropsiquiatria*, vol. 56, (3-B), 1998.

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

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

Mendonça, G.A., 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, Florianópolis, Brasil, Engenharia Elétrica, 2007.

Michel, C.M., Murray, M.M., Lantz, G., Gonzalez, S., Spinelli, L., Peralta, R.G. “EEG source imaging”, *Clinical Neurophysiology*, vol. 115, 2004.

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

Pereira, M.C.V. Tratamento de Sinais Biomédicos para Processamento por Redes Neurais Artificiais, Tese de Doutorado, Universidade Federal de Santa Catarina, Florianópolis, Brasil, Engenharia Elétrica, 2003.

Pillai, J., Sperling, M.R., “*Interictal EEG and the Diagnosis of Epilepsy*”, *Epilepsia*, v. 47 (Suppl. 1): 14-22, Blackwell Pub./ ILAE, 2006.

Rodrigues, M.A.B., Desenvolvimento de um instrumento virtual para aquisição e análise de sinais bioelétricos, Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis, Brasil, Engenharia Elétrica, 1997.

Rodrigues, M.A.B., Sistema para Detecção e Classificação Automática de Apnéias do Sono A partir de Registros Polissonográficos, Tese de Doutorado, Universidade Federal de Santa Catarina, Florianópolis, Brasil, Engenharia Elétrica, 2002.

Sala, F.A., Mapas de Kohonen na Detecção de Eventos Epileptogênicos, Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis, Brasil, Engenharia Elétrica, 2005.

Sanei, S., Chambers, J.A., *EEG Signal Processing*, Centre of Digital Signal Processing, Cardiff University, John Wiley & Sons Ltd, UK, 2007.

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

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

Sörnmo, L., Laguna, P., *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. Elsevier Academic Press, USA, 2005.

Sovierzoski, M.A., Avaliação de Descritores Morfológicos na Identificação de Eventos Epileptiformes, Tese de Doutorado, Universidade Federal de Santa Catarina, Florianópolis, Brasil, Engenharia Elétrica, 2009.

Tavares, M.C., Aquisição e Processamento de Sinais Bioelétricos Neurofisiológicos Intra-operatórios, Tese de Doutorado, Universidade Federal de Santa Catarina, Florianópolis, Brasil, Engenharia Elétrica, 2003.

Toazza, A.L., Sistema Microcontrolado para Medição de Impedância Pele-eletrodo em Registradores Bioelétricos, Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis, Brasil, Engenharia Elétrica, 1998.

Travessa, S.S., Análise das Redes Neurais Complexas na Detecção de Espículas e Piscadas em Sinais de EEG, Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis, Brasil, Engenharia Elétrica, 2006.

Tyner, F.S., Knott, J.R., Mayer, W.B.. *Fundamentals of EEG Technology, Volume 1 – Basic Concepts and Methods*, 1ª edição, Raven Press, 1983.

Wilson, S.B., Emerson R., “Spike Detection: a review and comparison of algorithms”, *Clinical Neurophysiology*, Vol. 113, pp. 1873-1881, 2002.