

Comparação entre Escalogramas e Banco de
Filtros Wavelet utilizados na classificação de
padrões epileptiformes

Eduarda Rosado de Almeida

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

Eduarda Rosado de Almeida

**COMPARAÇÃO ENTRE ESCALOGRAMAS E BANCOS DE
FILTROS WAVELET UTILIZADOS NA CLASSIFICAÇÃO DE
PADRÕES EPILEPTIFORMES**

Florianópolis

2016

Eduarda Rosado de Almeida

**Comparação entre Escalogramas e Bancos de Filtros Wavelet
utilizados na classificação de padrões epileptiformes**

Trabalho submetido ao Programa
de Pós-Graduação em Engenharia
Elétrica da Universidade Federal
de Santa Catarina para a obtenção
do título de Mestre em Engenharia
Elétrica

Orientador: Prof. Fernando Mendes
de Azevedo, Dr.Sc.

Florianópolis

2016

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

Almeida, Eduarda

Comparação entre Escalogramas e Bancos de Filtros Wavelet utilizados na classificação de padrões epileptiformes / Eduarda Rosado de Almeida ; orientador, Fernando Mendes de Azevedo - Florianópolis, SC, 2016.

89 p.

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

Inclui referências

1. Engenharia Elétrica. 2. Eletroencefalograma. 3. Reconhecimento de Padrões. 4. Processamento Digital de Sinal. 5. Transformada Wavelet. I. Azevedo, Fernando Mendes de. II. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

Eduarda Rosado de Almeida

**COMPARAÇÃO ENTRE ESCALOGRAMAS E BANCO DE
FILTROS WAVELET UTILIZADOS NA CLASSIFICAÇÃO DE
PADRÕES EPILEPTIFORMES**

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

Florianópolis, 22 de Setembro de 2016.



Prof. Marcelo Lobo Heldwein, Dr.Sc.
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

Banca Examinadora:



Prof. Fernando Mendes de Azevedo, Dr.Sc.
Universidade Federal de Santa Catarina
Orientador e Presidente da banca

Banca Examinadora (continuação):



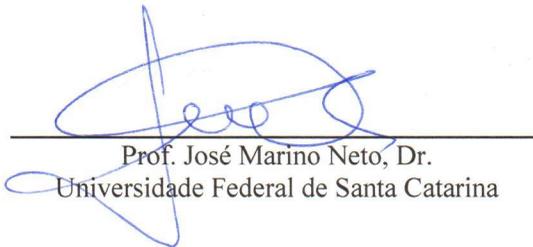
Prof.^a Christine Fredel Boos, Dra.
Universidade Federal de Santa Catarina



Prof.^a Fernanda Isabel Marques Argoud, Dra.
Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina



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



Prof. José Marino Neto, Dr.
Universidade Federal de Santa Catarina

AGRADECIMENTOS

Dedico o presente trabalho a todos aqueles que me apoiaram nesta caminhada, em especial, aos meus familiares que mesmo de longe se fizeram presentes ao longo destes dois anos. Aos meus pais, em especial pelo apoio financeiro e emocional.

Ao meu marido, Leandro Yoshio Morita, por compartilhar dos momentos de felicidade e estresse por conta dos prazos a serem cumpridos em relação à quantidade de trabalhos a serem desenvolvidos.

Ao meu filho Gabriel Takeo Morita, ainda que pela idade não entenda o quão importante esta etapa foi para meu crescimento pessoal e profissional. Gostaria também de pedir desculpas pelas vezes que não pude dedicar meu tempo por conta da carga de trabalho ou mesmo pelo cansaço ao final do dia.

Ao meu orientador, professor Fernando Mendes de Azevedo, pela oportunidade de estudo, pela orientação, pela paciência, pelas conversas e, principalmente pela amizade que construímos.

Aos professores do IEB-UFSC por indicarem o caminho a seguir para alcançar meus objetivos pessoais e acadêmicos.

Ao apoio de Christine Fredel Boos, que sanou as infindáveis dúvidas que surgiam ao longo do desenvolvimento deste trabalho. Obrigada pela dedicação e paciência para explicar quantas vezes fossem necessárias, mesmo que nem sempre eu fosse capaz retribuir.

Agradeço aos amigos que aqui fiz, sejam de laboratório, de pesquisa, ou aos que conheci fora do IEB-UFSC, por compartilharem experiências a apoiarem quando foi preciso, e, sobretudo, por dividirem momentos de descontração e felicidade.

Ao Programa de Pós-Graduação em Engenharia Elétrica da UFSC, IEB-UFSC e CAPES pela oportunidade e apoio financeiro para o desenvolvimento deste trabalho.

RESUMO

A comprovação clínica do diagnóstico da epilepsia é realizada por um neurofisiologista que analisa registros de eletroencefalograma (EEG) do indivíduo com suspeita da doença, resultando em um processo demorado. Embora muitos estudos tenham proposto métodos ou sistemas de automatização da análise dos registros de EEG, ainda não existe um algoritmo ou sistema que realize este tipo de tarefa com o sucesso esperado no ambiente clínico. Uma solução adotada para aumentar o desempenho de tais classificadores é o processamento digital dos sinais de EEG. Dentre os métodos de processamento, a Transformada *Wavelet* tem apresentado resultados promissores. Em continuidade aos estudos desenvolvidos em uma linha de pesquisa do Instituto de Engenharia Biomédica (IEB-UFSC) da Universidade Federal de Santa Catarina (UFSC), este trabalho propõe-se a realizar uma comparação direta entre os dois métodos de aplicação da Transformada *Wavelet*: Banco de Filtros e Escalogramas. As funções *Wavelet* analisadas neste trabalho foram escolhidas de acordo com uma revisão da literatura. Uma base de dados com segmentos de sinais de EEG é processada com banco de filtros e escalogramas. A base de dados processada é aplicada à entrada de redes neurais artificiais para o reconhecimento de padrões eletrográficos característicos de pacientes com Epilepsia. Os resultados são analisados a partir de dois métodos: análise não paramétrica e análise da rede com maior eficiência obtida para cada função *Wavelet*. Utilizando análise não paramétrica, as funções Coif 4 e Db 4, utilizando Banco de Filtros, e Bior 3.1 e Coif 1, utilizando Escalogramas, apresentam bom desempenho. Por sua vez, fazendo análise com base em apenas uma única rede para cada função, a melhor configuração é utilizando a função Bior 3.1 com processamento por Banco de Filtros.

Palavras-chave: eletroencefalograma, Reconhecimento de Padrões, padrão epileptiforme, Processamento Digital de Sinal, Transformada *Wavelet*.

ABSTRACT

The clinical evidence of the diagnosis of epilepsy is performed by a neurophysiologist who analyzes the electroencephalogram (EEG) records of the individual with suspected disease, resulting in a time consuming process. Although many studies have proposed methods or automated systems for EEG record analysis, there is still no algorithm or system that performs this type of task with the expected success in the clinical setting. One solution adopted to increase the performance of such classifiers is the digital processing of the EEG signals. Among the processing methods, the Wavelet Transform has presented promising results. In continuity to the studies developed in a line of research of the Institute of Biomedical Engineering (IEB-UFSC) of the Federal University of Santa Catarina (UFSC), this work proposes to make a direct comparison between the two methods of application of the Wavelet Transform: Bank of Filters and Scalograms. The Wavelet functions analyzed in this work were chosen according to a literature review. A database with segments of EEG signals is processed with Wavelet Filter Banks and Scalograms. The processed database is applied to the input of artificial neural networks for the recognition of electrographic patterns characteristic of patients with Epilepsy. The results are analyzed using two methods: non-parametric analysis and the most efficient network obtained for each Wavelet function. Using non-parametric analysis, the Coif 4 and Db 4 functions, for Filter Banks, and the Bior 3.1 and Coif 1 functions, using Scalograms, perform well. In turn, doing the analysis based only a single network for each function, the best configuration is using the Bior 3.1 function and processing by Filter Bank.

Keywords: electroencephalogram, pattern recognition, epileptiform pattern, Digital Signal Processing, Wavelet Transform.

LISTA DE ILUSTRAÇÕES

Figura 1 – Estrutura de um neurônio biológico.....	23
Figura 2 – Alteração do potencial de membrana (acima). Alteração da permeabilidade iônica (abaixo).	25
Figura 3 – Posicionamento dos eletrodos conforme sistema 10-20.	26
Figura 4 – Registros de EEG com montagem do tipo bipolar (esquerda) e referencial (direita).	26
Figura 5 – Exemplos de ritmos cerebrais.	27
Figura 6 – Processo de decomposição do sinal (x) com frequência de amostragem de 512 Hz, onde são obtidos os níveis de aproximação (a_n) e detalhe (d_n).	32
Figura 7 – Decomposição utilizando Banco de Filtros Wavelet de um sinal de EEG em três níveis utilizando a função Bior 3.1, obtendo as aproximações e os detalhes.	33
Figura 8 – Obtenção dos Escalograma <i>Wavelet</i> a partir do conceitos de quadros de Heisenberg.	34
Figura 9 – Modelo geral do neurônio artificial	35
Figura 10 – Etapas que compõem o sistema desenvolvido para classificação dos registros de EEG.....	39
Figura 11 – Tipos de padrões da base de dados utilizada: padrões epileptiformes (A), atividade normal de fundo (B), piscada (C), ruído (D).	41
Figura 12 – Banco de filtros proposto por Scolaro (2014), utilizando apenas aproximações e realizando a diferença entre os níveis A3 e A6.....	44
Figura 13 – Processamento por banco de filtros. Em (A) apresenta-se um exemplo de padrão epileptiforme com e sem processamento (filtragem). Em (B) apresenta-se a resposta em frequência da filtragem para o sinal de (A).	45
Figura 14 – Sinal representativo de padrão epileptiforme em sua forma original e processado utilizando escalogramas da Transformada <i>Wavelet</i> . Sinal original (A), sinal filtrado utilizando 8 escalas diádicas (B), sinal filtrado utilizando 4 escalas diádicas (C).	47
Figura 15 – Sinal representativo de ruído em sua forma original e processado utilizando escalogramas da Transformada <i>Wavelet</i> . Sinal original (A), sinal filtrado utilizando 8	

escalas diádicas (B), sinal filtrado utilizando 4 escalas diádicas (C).....	48
Figura 16 – Exemplo de gráfico representativo da curva da eficiência.....	50
Figura 17 – Exemplo de gráfico representativo das curvas de erro de treinamento e de validação cruzada. Curva de erro de treinamento (sólido), curva de erro de validação (tracejado).....	51
Figura 18 – Valores da média e erro padrão, calculados com o teste de Friedman ANOVA, para a eficiência das redes neurais utilizando banco de filtros.....	54
Figura 19 – Valores da média e erro padrão, calculados com o teste de Friedman ANOVA, para a eficiência das redes neurais utilizando Escalogramas.	56
Figura 20 – Valores da média e erro padrão da eficiência das redes neurais utilizando Banco de Filtros e Escalograma.	59
Quadro 1 – Tabela de Contingência ou Teste Diagnóstico.....	36
Quadro 2 – Características e desempenho de metodologias ou sistemas descritos na literatura sobre automatização no reconhecimento de padrões epileptiformes.....	43

LISTA DE TABELAS

Tabela 1 – Faixa de frequências para cada nível de decomposição de um sinal amostrado a uma frequência de 512 Hz.....	31
Tabela 2 – Conjuntos de treinamento, validação e teste.....	41
Tabela 3 – Escalas contínuas e diádicas e suas faixas de frequência. ...	46
Tabela 4 – Resultados do teste de normalidade Kolmogorov-Smirnov para as eficiências do banco de filtros e dos escalogramas.	53
Tabela 5 – Resultado do teste Wilcoxon <i>Matched pairs</i> para a eficiência das redes neurais utilizando Bancos de Filtros com todas as funções <i>Wavelet</i>	55
Tabela 6 – Resultado do teste de Wilcoxon <i>Matched pairs</i> para os valores de eficiência das redes neurais utilizando Bancos de Filtros sem a função Coif 1.	56
Tabela 7 – Resultado do teste de Wilcoxon <i>Matched pairs</i> para os valores de eficiência das redes neurais utilizando Escalogramas com todas as funções <i>Wavelet</i>	57
Tabela 8 – Resultado do teste de Wilcoxon <i>Matched pairs</i> para a eficiência das redes neurais com Escalogramas das funções Bior 3.1, Rbio 1.3 e Rbio 1.5.	57
Tabela 9 – Resultado (valor p) dos testes de Friedman ANOVA e Wilcoxon para os pares de eficiência média das funções <i>Wavelet</i> analisadas.	58
Tabela 10 – Resultado do teste de Wilcoxon <i>Matched pairs</i> para os valores de eficiência das redes neurais utilizando as funções Coif 1 e Db 4 para Banco de Filtros e Bior 3.1 e Coif 1 para Escalogramas.....	59
Tabela 11 – Comparativo de desempenho entre Banco de Filtros e Escalogramas para as redes de cada função que obtiveram maior valor de eficiência entre as redes analisadas.	60

LISTA DE ABREVIATURAS E SIGLAS

Sigla	Significado
ANOVA	Análise de Variância
BF	Banco de Filtros
Bior X	Família Biortogonal no qual X corresponde à escala
CEPESC	Centro de Epilepsia de Santa Catarina
CEPSH	Comitê de Ética em Pesquisa com Seres Humanos
Coif X	Família Coiflets no qual X corresponde à escala
Db X	Família Daubechies no qual X corresponde à escala
EEG	Eletroencefalograma
Efic	Eficiência
Esp	Especificidade
Rbio X	Família Biortogonal Reversa no qual X corresponde à escala
RNA	Rede Neural Artificial
Sen	Sensibilidade
TF	Transformada de Fourier
TW	Transformada Wavelet
TWC	Transformada Wavelet Contínua
TWD	Transformada Wavelet Discreta
UFSC	Universidade Federal de Santa Catarina
VN	Verdadeiros Negativos
VP	Verdadeiros Positivos

SUMÁRIO

1	Introdução	21
1.1	Objetivos	22
1.1.1	Objetivo geral	22
1.1.2	Objetivos específicos.....	22
2	Fundamentação Teórica	23
2.1	Sinais de EEG e epilepsia.....	23
2.2	Tranformada <i>Wavelet</i>	28
2.2.1	Banco de Filtros da Transformada <i>Wavelet</i>	30
2.2.2	Escalograma <i>Wavelet</i>	33
2.3	Redes Neurais Artificiais	35
2.4	Análise de Desempenho	36
3	Metodologia	39
3.1	Base de Dados	39
3.2	Famílias <i>Wavelet</i>	41
3.3	Banco de Filtros <i>Wavelet</i>	44
3.4	Escalograma <i>Wavelet</i>	46
3.5	Rede Neural Artificial	49
3.6	Avaliação de desempenho	49
3.7	Simulações	50
4	Resultados e Discussão	53
5	Conclusão.....	63
6	Trabalhos Futuros.....	65
	Referências.....	67
	Apêndice A – Fluxograma do processo de treinamento realizado nas redes neurais artificiais desenvolvidas	75
	Apêndice B – Interface gráfica desenvolvida para os treinamentos e testes das redes neurais implementadas.....	77
	Apêndice C – Indicadores de desempenho do classificador neural utilizando banco de filtros	79
	Apêndice D – Indicadores de desempenho do classificador neural utilizando escalograma	83
	Anexo A – Parecer consubstanciado do Comitê de Ética em Pesquisa com Seres Humanos	87

1 INTRODUÇÃO

A Epilepsia é classificada, segundo a Liga Internacional Contra a Epilepsia (*International League Against Epilepsy-ILAE*) como um distúrbio do cérebro no qual há predisposição permanente a crises epiléticas. Como consequências desta condição, têm-se alterações neurobiológicas, sociais, cognitivas e psicológicas (STEPHENSON, 2010).

No tratamento da epilepsia são administradas drogas antiepiléticas para o controle das crises e sintomas, embora, em alguns casos, a intervenção cirúrgica seja uma alternativa viável (ASKAMP; VAN PUTTEN, 2014; SANEI; CHAMBERS, 2007). Estudos indicam que a incidência de novos casos de epilepsia em crianças e jovens adultos manteve-se estável, porém, tem aumentado em indivíduos idosos podendo ser associada à comorbidades¹ da epilepsia (SANDER; KEEZER, 2016).

A comprovação clínica do diagnóstico dessa doença é realizada por um neurofisiologista que analisa registros de eletroencefalograma (EEG) de pacientes com suspeita de epilepsia. Essa análise de traçados de EEG busca identificar elementos eletrográficos denominados padrões epileptiformes. Dentre os padrões epileptiformes, os mais frequentes são as chamadas espículas e ondas agudas. Estas se diferenciam pela duração, que varia de 20 a 70 ms para as espículas e 70 a 200 ms para as ondas agudas (SCHOMER; DA SILVA, 2011).

Os registros de EEG analisados são adquiridos por longos períodos de tempo (mais de 24 horas) utilizando de 24 a 128 canais simultâneos, tornando o processo de identificação dos padrões epileptiformes muito desgastante e demorado (MONTENEGRO *et al.*, 2001).

Apesar de existirem muitos trabalhos baseados na automatização dessa análise do EEG, nenhum deles possui ampla utilização ou desempenho ótimo. Muitos destes trabalhos identificam um número grande de padrões não epileptiformes² como positivos (WILSON; EMERSON, 2002).

¹ Corresponde a associação de pelo menos duas patologias num mesmo paciente.

² Padrão não epileptiforme, neste trabalho, corresponde a sinais classificados como ruído, atividade normal de fundo e piscadas palpebrais.

Conforme a literatura, dentre os vários métodos de processamento digital de sinais aplicados à registros de EEG, a Transformada Wavelet tem apresentado bons resultados (ALOTAIBY *et al.*, 2015).

Apesar de ser vastamente utilizada no processamento de sinais de EEG, não existem estudos suficientes que realizem comparações entre os tipos de aplicação da Transformada *Wavelet*, bem como estudos comparativos entre as funções *Wavelet*.

1.1 OBJETIVOS

O presente trabalho norteia-se pelos seguintes objetivos.

1.1.1 Objetivo geral

O objetivo geral deste trabalho é realizar uma comparação direta entre a utilização dos escalogramas e dos bancos de filtros da Transformada *Wavelet* como método de processamento digital de sinal aplicado à entrada de classificadores neurais utilizados para o reconhecimento automático de padrões epileptiformes em sinais de eletroencefalograma.

1.1.2 Objetivos específicos

- Análise comparativa entre bancos de filtros e escalogramas da Transformada *Wavelet*;
- Análise comparativa das funções *Wavelet* utilizadas.

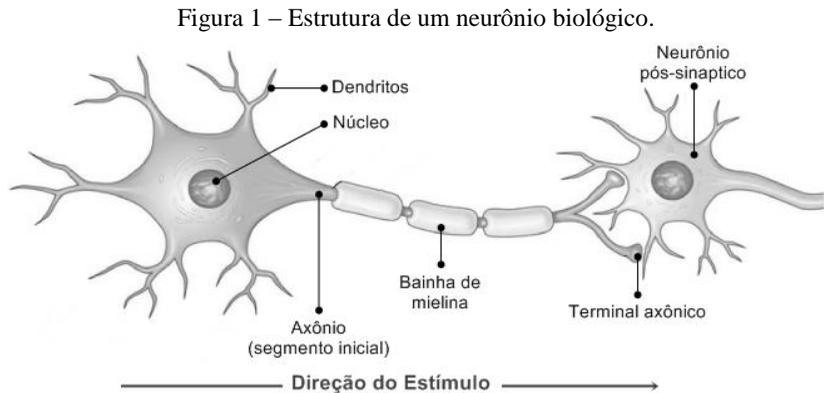
2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão apresentadas as bases teóricas utilizadas no desenvolvimento deste trabalho.

2.1 SINAIS DE EEG E EPILEPSIA

Em 1875 o cientista inglês Richard Caton utilizou um galvanômetro e eletrodos sob o escalpo de um indivíduo para captar os sinais provenientes da atividade elétrica cerebral. Por sua vez, em 1929, o psiquiatra alemão Hans Berger introduziu o conceito de diagnóstico psiquiátrico utilizando a eletroencefalografia (EEG). As flutuações dos potenciais no cérebro foram obtidas a partir da colocação de eletrodos no escalpo (WEBSTER, 2010). Tais flutuações são resultado da atividade elétrica cerebral a qual tem por unidade elementar a estrutura denominada neurônio biológico.

Neurônios são as menores estruturas que realizam funções no sistema nervoso. Eles possuem a capacidade de propagar sinais elétricos em resposta a um estímulo. Assim, os sinais de entrada passam pelos dendritos em direção ao terminal axônico que faz sinapse com neurônios vizinhos, conforme Figura 1.



Fonte: Modificado de Silverthorn (2010).

Em estado de repouso, o potencial de membrana da célula é definido pela concentração de potássio (K^+) e pela permeabilidade ao sódio (Na^+), ao potássio (K^+) e ao cloro (Cl^-) através dos canais iônicos. No entanto, quando há mudança em algum destes fatores, ocorre uma despolarização ou hiperpolarização da membrana celular gerando um sinal elétrico.

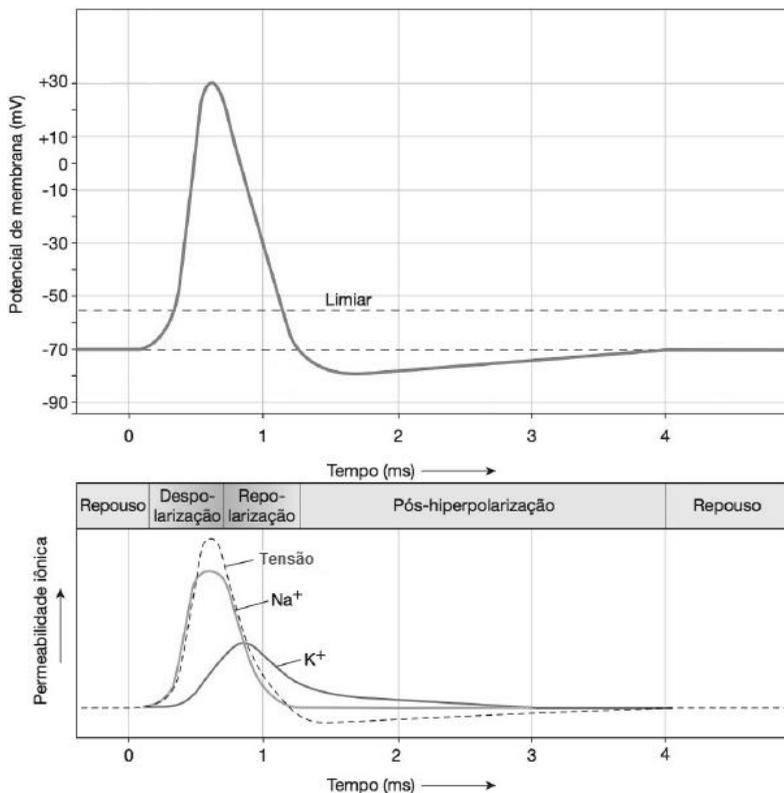
Os sinais elétricos são classificados de acordo com as suas intensidades. Potenciais graduados equivalem a sinais de intensidade variável, que diminuem mesmo tempo em que percorrem curtas distâncias. Já potenciais de ação alcançam longas distâncias sem perder intensidade.

Na Figura 2, pode-se observar a alteração da permeabilidade iônica e do potencial desde o momento em que a membrana se encontra em repouso (-70 mV) até o momento em que ela sofre um estímulo despolarizante. Com a entrada de Na^+ e saída de K^+ , a célula retorna à sua permeabilidade iônica e potencial de membrana de repouso.

A partir de então, o eletroencefalograma (EEG) tem sido utilizado para denotar a atividade elétrica do cérebro (SANEI; CHAMBERS, 2007). A aquisição dos sinais de EEG pode ser realizada de três formas: introduzindo eletrodos no tecido cerebral (registro de profundidade); introduzindo eletrodos na superfície externa do córtex (Eletrocorticograma-ECOG) ou, na superfície do couro cabeludo (Eletroencefalograma de superfície-sEEG)

O método de aquisição de sinais EEG menos invasivo e mais utilizado no ambiente clínico é o EEG superficial, que pode ser um EEG de rotina ou ambulatorial (com duração de 20 minutos) ou um EEG de longo período (com duração de, no mínimo, 24 horas) (PANAYIOTOPOULOS, 2010).

Figura 2 – Alteração do potencial de membrana (acima). Alteração da permeabilidade iônica (abaixo).



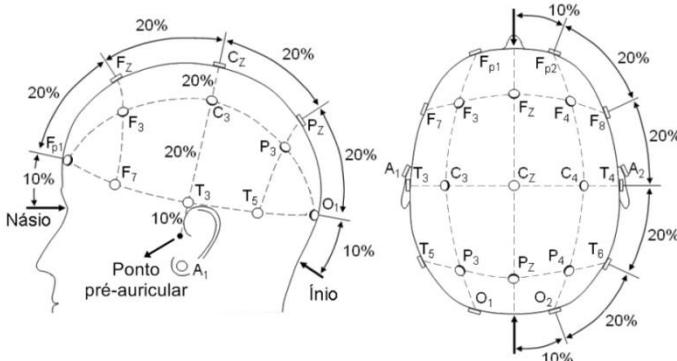
Fonte: Modificado de Silverthorn (2010).

Quanto à disposição dos eletrodos sobre o escalpo, em 1958 foi proposto por Herbert Jasper um sistema para monitoração de EEG chamado Sistema Internacional 10-20. Este sistema, amplamente utilizado, se baseia em pontos de colocação dos eletrodos de aquisição de acordo com as estruturas anatômicas do cérebro, tais como hemisférios (direito e esquerdo) e lobos (frontal, parietal, temporal e occipital).

Conforme ilustrado na Figura 3, os pontos de colocação dos eletrodos são identificados utilizando uma letra e um número. Para o hemisfério esquerdo são adotados números ímpares e para o direito são adotados números pares. Já as letras adotadas seguem segundo sua área

anatômica: central (C), frontal (F), frontopolar (Fp), occipital (O), parietal (P) e temporal (T) (MONTENEGRO *et al.*, 2001).

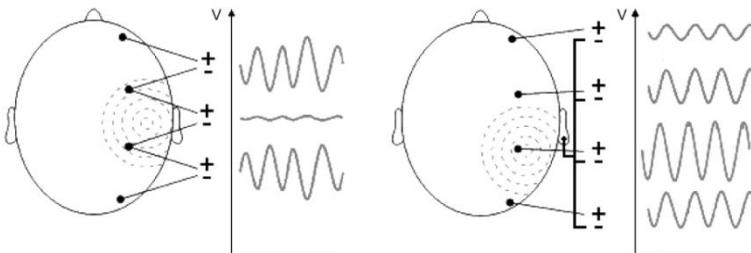
Figura 3 – Posicionamento dos eletrodos conforme sistema 10-20.



Fonte: Adaptado de Malmivuo e Plonsey (1995).

Quanto ao tipo de montagem de eletrodos, existem dois métodos chamados bipolar e referencial, ilustrados na Figura 4. O método bipolar utiliza a diferença existente entre a atividade elétrica captada a partir de um par de eletrodos. Já o método referencial, como o nome diz, compara a atividade elétrica obtida dos demais eletrodos com um de referência.

Figura 4 – Registros de EEG com montagem do tipo bipolar (esquerda) e referencial (direita).



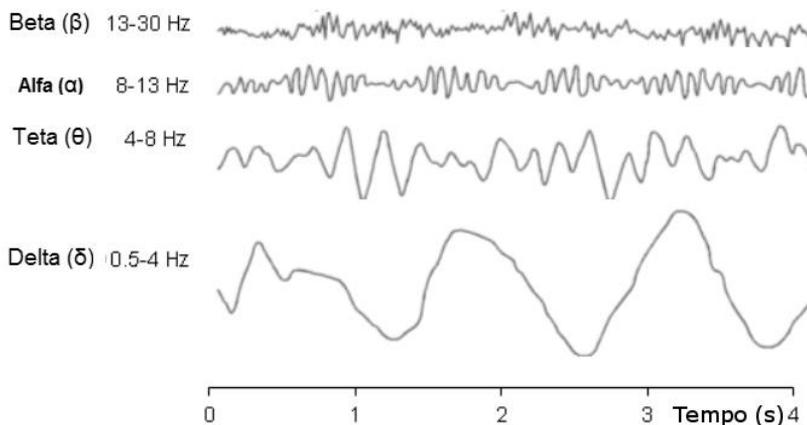
Fonte: Adaptado de Malmivuo e Plonsey (1995).

O sinal de EEG ocupa bandas de frequência que variam geralmente de 0,5 a 60 Hz e possui amplitude média de 50 μ V. Porém, essa variação pode alcançar valores entre 0 e 100 Hz para faixa de

frequência e entre 2 e 200 μV para amplitude (SCHOMER; DA SILVA, 2011).

Em geral, estes sinais apresentam uma regularidade em frequência e amplitude para alguns estados comportamentais. As ondas do tipo Alfa (α), por exemplo, são encontradas em pacientes normais quando acordados, relaxados e de olhos fechados. As ondas Beta (β) também são percebidas em pacientes normais, porém, durante o estado de vigília. As ondas Delta (δ) podem ser observadas em crianças quando em estado de sono profundo. Quando observadas ondas tipo delta em pacientes adultos em estado de alerta se tem indícios de anormalidades. As ondas do tipo Teta (θ), por sua vez, são geralmente observadas em crianças em estágios iniciais de sono (MALMIVUO; PLONSEY, 1995).

Figura 5 – Exemplos de ritmos cerebrais.



Fonte: Adaptado de Malmivuo e Plonsey (1995).

Dentre as várias aplicações da análise do registro de EEG estão o monitoramento do estado de vigília, verificação de danos cerebrais ocasionados por lesões, determinação de coma e morte cerebral, investigação clínica como, por exemplo, da epilepsia podendo indicar a localização dos focos das crises (SANEI; CHAMBERS, 2007).

Na análise e investigação da epilepsia são identificados, nos registros de EEG, padrões eletrográficos denominados padrões epileptiformes, que são fortes indicadores para a presença da patologia.

Os padrões epileptiformes podem apresentar-se com diferentes morfologias, sendo as espículas, as ondas agudas e os complexos

espícula-onda as mais comumente encontradas no EEG. Para diferenciar ondas agudas e espículas são analisadas características morfológicas do sinal, como a duração e a amplitude. A duração das espículas está compreendida entre 20 e 70 ms, enquanto que ondas agudas estão entre 70 e 200 ms (SCHOMER; DA SILVA, 2011).

Os padrões epileptiformes, conforme Montenegro *et al.* (2001), se diferenciam dos padrões não epileptiformes por:

- Apresentarem aspecto assimétrico com ascensão aguda e descida lenta. Os padrões não epileptiformes apresentam aspecto simétrico.
- Serem geralmente seguidas por ondas lentas de mesma ou oposta polaridade. Os padrões não epileptiformes raramente são seguidas por ondas lentas.
- Serem geralmente bifásicas ou trifásicas, enquanto que padrões não epileptiformes são monofásicos.
- Possuírem duração diferente das atividades normais de fundo, chamando atenção do especialista.
- Alterarem a atividade normal de fundo próxima de sua ocorrência, formando um “campo”.

2.2 TRANSFORMADA WAVELET

Proposta no início do século XIX por Joseph Fourier, a chamada Transformada de Fourier realiza uma expansão do sinal original através do uso de funções senos e cossenos. Este tipo de análise é própria para sinais estacionários, ou seja, aqueles cuja frequência é invariante ao longo do tempo pois este tipo de transformada possui uma alta resolução no domínio da frequência, porém possui resolução nula no domínio do tempo. Desta forma é possível descobrir todas as componentes de frequência de um sinal, porém é impossível saber quando, no tempo, elas ocorrem.

Como forma de solucionar este problema de resolução no tempo, em 1946 Denis Gabor propôs a Transformada de Gabor, também denominada Transformada de Fourier de Tempo Curto. Neste tipo de transformada é utilizado o conceito de janelas, dentro das quais é aplicado o conceito tradicional da Transformada de Fourier. Assim, passa a ser introduzido o conceito de análise no domínio do tempo. Para sinais cuja frequência é baixa, é indicada a adoção de janelas largas visto que a transição da informação ocorre de forma lenta. No entanto,

para sinais cuja frequência de interesse é alta, é indicada a adoção de janelas estreitas, pois a informação se altera de forma rápida ao longo do tempo. No entanto, uma vez adotada a largura da janela, é impossível modifica-la.

Assim, desenvolvida como uma alternativa à Transformada de Fourier de Tempo Curto, a Transformada *Wavelet* (TW) visa solucionar o problema da resolução, dividindo a função em diferentes componentes de frequência utilizando janelas de largura variável (OLIVEIRA, 2007).

Esta ferramenta tem sido bastante utilizada para investigar diversos fenômenos físicos como análise de dados climáticos, biopotenciais, filtragem de imagens e sinais, entre outros (KUMAR; KUMAR; SINGH, 2015; SOON *et al.*, 2014; ZHANG; ZHANG, 2016).

Conforme a literatura, a TW tem sido utilizada com bastante sucesso para o processamento de EEG em sistemas e metodologias de automatização do processo de análise para a comprovação clínica do diagnóstico da epilepsia, além da detecção de crises epiléticas (ABIBULLAEV; KIM; SEO, 2010; ACHARYA *et al.*, 2012; MEIER *et al.*, 2008).

Ao contrário da análise utilizando a Transformada de Fourier (TF) em que é apresentada apenas a resolução no domínio da frequência, a TW permite a análise também no domínio do tempo (análise multiresolução) tornando o uso da Transformada *Wavelet* muito interessante. Existem dois métodos de análise da TW, em tempo contínuo e em tempo discreto.

Na análise utilizando a Transformada *Wavelet* Contínua (TWC) adota-se um protótipo *Wavelet*, chamado “*Wavelet* analisadora” ou “*Wavelet*-mãe” $\psi(t)$. A partir da “*Wavelet*-mãe” são geradas versões com parâmetros de escala (frequência) e deslocamento modificados originando as “*Wavelets*-filhas” (OLIVEIRA, 2007).

A Equação 1 descreve a operação de escalonamento a partir de uma função “*Wavelet*-mãe” $\psi(t)$. O parâmetro de escala a determina se a TW será comprimida (caso $a < 1$) ou dilatada (caso $a > 1$).

$$\psi_a(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t}{a}\right), a \neq 0 \quad (1)$$

Por sua vez, a Equação 2 descreve a operação de deslocamento a partir de uma função “*Wavelet*-mãe” $\psi(t)$, no qual b é o fator de deslocamento.

$$\psi_b(t) = \psi(t - b) \quad (2)$$

Assim, considerando simultaneamente as modificações de escala e deslocamento obtém-se a Equação 3.

$$\psi_{a,b}(t) = \psi_a(t - b) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t - b}{a}\right) \quad (3)$$

$$\{\psi(t)\} \rightarrow \{\psi_{a,b}(t)\} (\forall a, a \neq 0) (\forall b \in \mathbb{R})$$

Enquanto a TWC é calculada realizando translações e escalonamentos contínuos de uma função sobre um sinal, tornando-se altamente redundante, a Transformada *Wavelet* Discreta (TWD) translada e escalona as funções em intervalos discretos. Assim, a TWD foi introduzida com o intuito de mapear um sinal de forma mais eficiente.

A Equação 4 descreve a TWD, na qual m e n são inteiros, $a_0 > 1$ é um parâmetro de dilatação fixo, b_0 é o fator de translação fixo e b depende do fator de dilatação.

$$\psi_{m,n}(t) = \frac{1}{\sqrt{|a_0^m|}} \psi\left(\frac{t - nb_0a_0^m}{a_0^m}\right) \quad (4)$$

No entanto, na maioria das aplicações é utilizada a Transformada *Wavelet* Diádica, também chamada de Transformada *Wavelet* Discreta de Translação Invariante. Na Transformada *Wavelet* Diádica o parâmetro de escala é discreto, no qual a_0 varia em potências inteiras de 2 (2^j , no qual $j \in \mathbb{Z}$) e b_0 é adotado como 1.

Além dos dois tipos, contínua e discreta, a literatura também divide a TW em duas categorias, de acordo com a forma de utilização desta transformada: banco de filtros (Hw) e escalogramas.

2.2.1 Banco de Filtros da Transformada *Wavelet*

O *denoising* é um método bastante utilizado para a filtragem digital de sinais, permitindo a manipulação das componentes de frequência em sinais de interesse. Com este método é possível decompor um dado sinal em diferentes níveis, remover coeficientes do sinal e reconstruí-lo (OLIVEIRA, 2007).

Na aplicação da Transformada *Wavelet* por banco de filtros é aplicado o mesmo princípio do *denoising*, ou seja, é feita uma decomposição em faixas de frequência. Para tanto, são utilizados conjuntos de filtros $H(n)$ e $G(n)$ que extraem características de baixas e altas frequências, respectivamente. As características de baixa frequência do sinal são denominadas aproximações enquanto que as de alta frequência são denominadas detalhes.

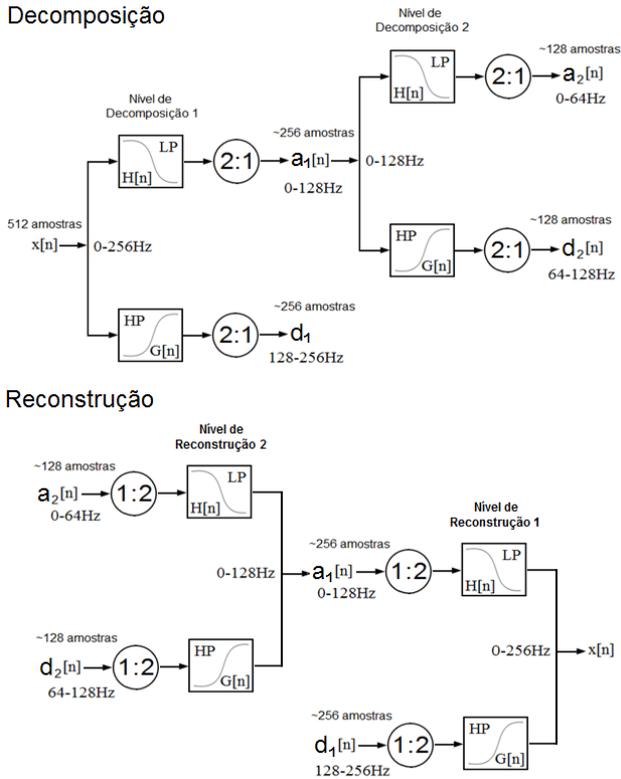
Na parte superior da Figura 6 é possível observar um sinal x amostrado a 512 Hz sendo decomposto em dois níveis, obtendo-se as aproximações a_1 e a_2 e os detalhes d_1 e d_2 . Já na parte inferior da Figura 6, é possível observar a etapa de reconstrução do sinal decomposto.

No banco de filtros, cada nível de decomposição de um sinal está relacionado a um intervalo de frequências, tanto para as aproximações quanto para os detalhes. Como exemplo disso, a Tabela 1 apresenta as faixas de frequência de dez níveis de decomposição de um sinal amostrado a 512 Hz.

Tabela 1 – Faixa de frequências para cada nível de decomposição de um sinal amostrado a uma frequência de 512 Hz.

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

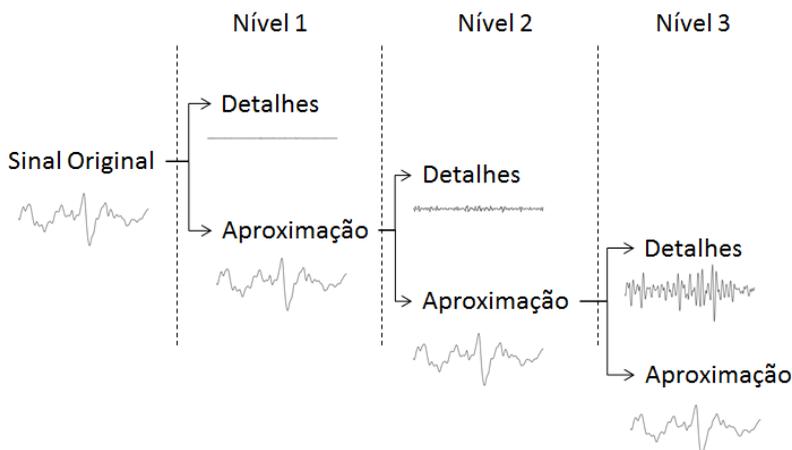
Figura 6 – Processo de decomposição do sinal (x) com frequência de amostragem de 512 Hz, onde são obtidos os níveis de aproximação (a_n) e detalhe (d_n).



Fonte: Scolaro (2014).

Na Figura 7 pode-se observar um exemplo da decomposição de um sinal de EEG, mais especificamente, um padrão epileptiforme, em três níveis. Neste exemplo utilizou-se a função Biortogonal 3.1 e optou-se por apresentar a morfologia do sinal no decorrer da decomposição ao invés dos valores de intervalos de frequência como na Figura 6.

Figura 7 – Decomposição utilizando Banco de Filtros Wavelet de um sinal de EEG em três níveis utilizando a função Bior 3.1, obtendo as aproximações e os detalhes.



Fonte: próprio autor.

No contexto deste trabalho, existem muitos estudos que aplicam banco de filtros para remoção de determinadas frequências na tentativa de aprimorar o reconhecimento dos padrões epileptiformes, melhorando assim o desempenho de classificadores computacionais (HARNER, 2009; MORAES; CALLEGARI, 2014; TZALLAS *et al.*, 2012).

2.2.2 Escalograma *Wavelet*

Os escalogramas da Transformada *Wavelet* correspondem a mapas da densidade espectral de energia no plano escala *versus* deslocamento. Em representações utilizando escalogramas, os *pixels*³ indicam a intensidade da densidade local de energia de um sinal (OLIVEIRA, 2007). O escalograma é utilizado em diversas aplicações, dentre elas na caracterização de sinais acústicos, estudo de séries temporais como, por exemplo, o fenômeno El Niño (HE; LIU, 2011; TORRENCE; COMPO, 1998).

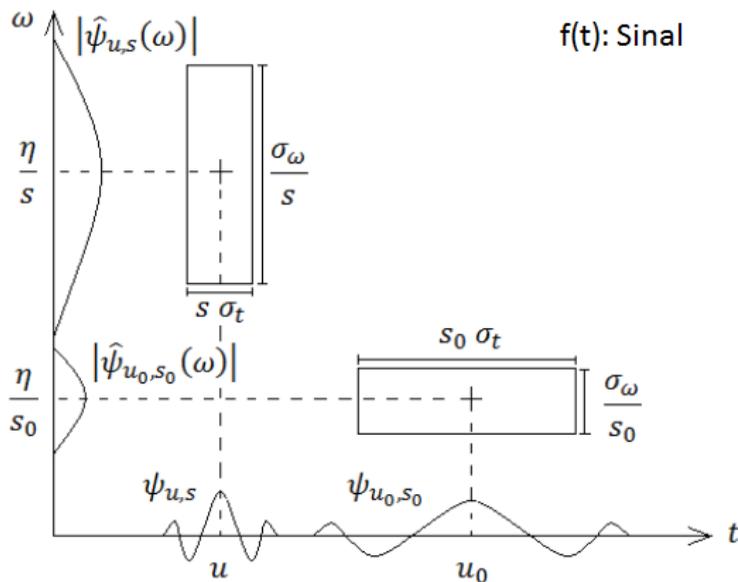
³ Pixel é o menor elemento num dispositivo de exibição ao qual é possível atribuir-se uma cor.

Para obtenção do gráfico da densidade de energia P_{TWf} , a Equação 5 é aplicada sobre o sinal de interesse f , na qual η e ξ são as frequências original e escalada, respectivamente.

$$P_{TWf}(u, \xi) = |TW_{f(u,s)}|^2 = |TW_{f(u,\eta/\xi)}|^2 \quad (5)$$

Logo, o gráfico do escalograma é dado pelo quadrado do valor absoluto dos coeficientes dados pela Transformada *Wavelet*. Para cada função átomo $\psi_{u,s}$, com centro em $u, \xi = \eta/s$, será produzido um retângulo de Heisenberg, conforme Figura 8, com dimensões $s\sigma_t$ no tempo e σ_ω/s na frequência o qual produz um retângulo de área $\sigma_t\sigma_\omega$, no qual σ_t e σ_ω representam os desvios padrão da função átomo $\psi_{u,s}$ no tempo e na frequência, respectivamente (MALLAT, 2008).

Figura 8 – Obtenção dos Escalograma *Wavelet* a partir do conceitos de quadros de Heisenberg.



Fonte: Adaptado de MALLAT, (2008).

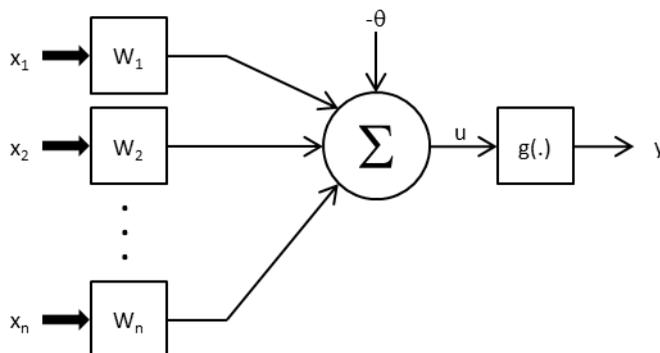
2.3 REDES NEURAIS ARTIFICIAIS

Rede Neural Artificial (RNA), no contexto da computação, se refere a um modelo computacional inspirado no sistema nervoso central de animais que possuem a capacidade de aprender e reconhecer padrões (SILVA; SPATTI; FLAUZINO, 2010).

As RNAs são utilizadas para a realização de diversas tarefas, dentre elas, as que são difíceis de solucionar utilizando programação baseada em regras comuns, tais como, reconhecimento de padrões de voz, de sinais biológicos (diagnóstico médico), de face, entre outros (AIBINU; SALAMI; SHAFIE, 2012; DAI; ZHAO; CAO, 2015; YU; YE; XIANG, 2014). Na comprovação clínica da epilepsia as redes neurais são utilizadas como classificadores computacionais que identificarão os padrões epileptiformes presentes em sinais de EEG.

A rede neural artificial é representada por um sistema de neurônios artificiais interligados capazes de computar valores de entradas (x) e calcular uma saída (y), conforme ilustrado na Figura 9.

Figura 9 – Modelo geral do neurônio artificial



Fonte: Adaptado de Silva; Spattie Flauzino (2010).

A unidade básica de processamento da RNA é o neurônio artificial (*perceptron*) os quais realizam conexões sinápticas com outros neurônios artificiais compondo uma rede.

A RNA pode ser classificada de acordo com diferentes parâmetros. Quanto ao tipo de aprendizado, a rede pode ser: supervisionada ou não supervisionada. Na aprendizagem supervisionada existe um agente externo que indica a resposta desejada à rede para o

padrão apresentado, de forma e corrigi-la. Já no aprendizado não supervisionado (também chamada rede auto-organizável) não existe tal agente, logo, a aprendizagem é realizada por reforço, agrupando os padrões em classes de acordo com suas características. Quanto ao número de camadas, uma RNA pode ser classificada como única camada (*single layer*) ou múltiplas camadas (*multilayer*). Por fim, pode-se classificar uma rede de acordo com a associação de seus neurônios como: direta (*feedforward*) ou recursiva (*feedback*) (SILVA; SPATTI; FLAUZINO, 2010).

Para que uma rede neural atinja um aprendizado generalizado para uma determinada classe de problema é necessário que ocorra um processo iterativo de ajustes nos pesos de treinamento. Dentre as regras de aprendizado existentes, tem-se: regra de Hebb, do Perceptron, do Error Backpropagation, entre outras (FAUSETT, 1994).

2.4 ANÁLISE DE DESEMPENHO

A análise de desempenho de um classificador como, por exemplo, a rede neural artificial, é uma etapa tão importante quanto à determinação dos parâmetros utilizados na sua implementação. O desempenho de um classificador pode ser definido como a habilidade de um algoritmo discriminar grupos de pacientes saudáveis e de pacientes doentes (CASSON; LUNA; RODRIGUEZ-VILLEGAS, 2009).

Existem diversas métricas para quantificar o desempenho. A sensibilidade, especificidade, valor preditivo positivo, valor preditivo negativo e eficiência são as mais utilizadas em análise de redes neurais artificiais. Para o cálculo destas métricas são utilizados os valores contidos na chamada Tabela de Contingência ou Teste Diagnóstico (MYATT; JOHNSON, 2009), apresentado no Quadro 1.

Quadro 1 – Tabela de Contingência ou Teste Diagnóstico.

		Resultado Desejado	
		Positivo	Negativo
Resultado Encontrado	Positivo	Verdadeiro Positivo (VP)	Falso Positivo (FP)
	Negativo	Falso Negativo (FN)	Verdadeiro Negativo (VN)

Fonte: próprio autor.

Um resultado positivo, encontrado pelo classificador, que coincide com o resultado desejado determina um Verdadeiro Positivo (VP). Um resultado desejado positivo que não coincida com o resultado encontrado determina um Falso Negativo (FN).

Um resultado negativo, encontrado pelo classificador, que coincide com o resultado desejado determina um Verdadeiro Negativo (VN). Um resultado desejado negativo que não coincida com o resultado encontrado determina um Falso Positivo (FP).

A sensibilidade, também chamada de taxa de verdadeiros positivos, é classificada como a probabilidade de encontrar um resultado positivo em pacientes que possuem a doença. A sensibilidade é definida pela Equação 6.

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (6)$$

A especificidade, ou taxa de verdadeiros negativos, por sua vez, é classificada como a probabilidade de encontrar um resultado negativo em pacientes que não possuem a doença e é definida pela Equação 7.

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (7)$$

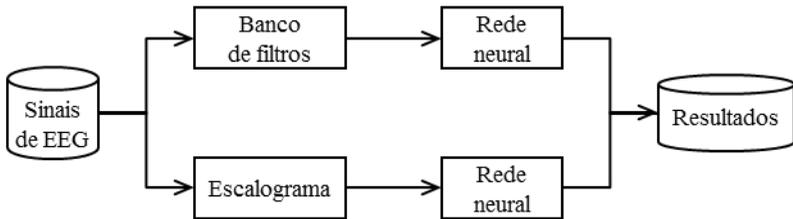
Já a eficiência é classificada como a taxa de acertos e é calculada através da razão entre a quantidade de padrões classificados de forma correta e a quantidade total de padrões analisados, conforme a Equação 8.

$$\text{Eficiência} = \frac{VP + VN}{VP + VN + FP + FN} \quad (8)$$

3 METODOLOGIA

Nesta seção serão apresentados os materiais e métodos utilizados neste trabalho. A visão geral da metodologia proposta é ilustrada na Figura 10.

Figura 10 – Etapas que compõem o sistema desenvolvido para classificação dos registros de EEG.



Fonte: próprio autor.

Inicialmente os segmentos de sinal de EEG contidos na base de dados são processados utilizando os dois métodos de aplicação da Transformada *Wavelet* (banco de filtros e escalograma). Um conjunto de sinais processados são aplicados à entrada de redes neurais artificiais implementadas para a etapa de treinamento delas. Depois de treinadas, as redes são testadas utilizando outro conjunto de sinais processados. Os resultados dos testes são analisados utilizando três métricas de desempenho. Por fim, são comparados os resultados utilizando os dois diferentes métodos de aplicação da TW (banco de filtros e escalogramas) e comparados os resultados encontrados para cada função *Wavelet* utilizada.

3.1 BASE DE DADOS

A base de dados utilizada neste trabalho foi obtida no Centro de Epilepsia de Santa Catarina (CEPESC), a partir da monitoração de nove pacientes comprovadamente epiléticos e um paciente sem epilepsia, gerando um total de 16 horas de registro. O uso da base de dados foi autorizado pelo Comitê de Ética em Pesquisas com Seres Humanos

(CEPSH) da Universidade Federal de Santa Catarina (UFSC), no parecer consubstanciado número 1.183.201 (Anexo A).

Os sinais da base de dados correspondem a segmentos de 1 segundo extraídos de registros de EEG de longa duração adquiridos com o sistema CEEGraph Vision EEG[®] da Natus Bio-logic Systems Corp. As características dos segmentos de sinal desta base de dados são:

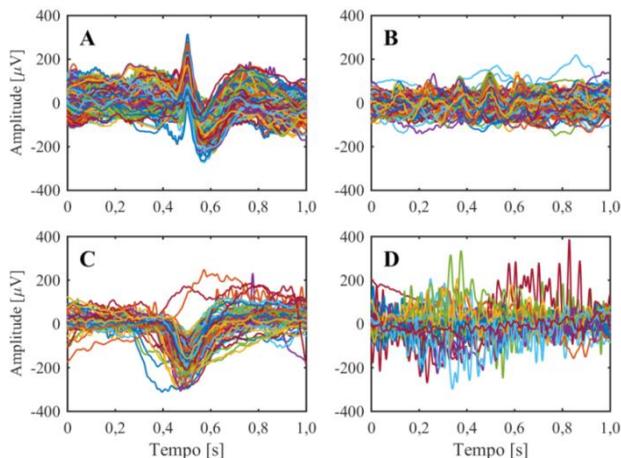
- Frequência de amostragem de 512 Hz;
- Aquisição por 32 canais na montagem referencial (com referência no eletrodo Pz) e sistema internacional 10-10;
- Filtragem digital para isolamento do espectro de frequências entre 1 e 35 Hz.

Os registros de EEG contidos na base de dados foram analisados e marcados por três neurologistas membros do CEPESC. Informações demográficas como idade e sexo dos pacientes não foram fornecidas para preservar o sigilo da identidade dos mesmos.

Posteriormente, os segmentos de sinais foram divididos em quatro classes diferentes: padrões epileptiformes (espículas e ondas agudas), atividade normal de fundo, piscada palpebral e ruído.

Para as análises e simulações, os sinais selecionados foram divididos em três grupos chamados de Treinamento, Validação e Teste. A divisão nestes grupos foi realizada de forma a manter um equilíbrio na quantidade de cada classe de sinal para os grupos de treinamento e validação. Após esta divisão, o restante dos sinais de cada classe foi adicionado ao grupo de teste. A quantidade de sinais presentes nos conjuntos pode ser observada na Tabela 2 e na Figura 11 podem ser observados todos os sinais da base de dados divididos nas quatro classes citadas anteriormente. Apesar dos grupos de Treinamento e Validação apresentarem a mesma quantidade para cada classe de sinal, o conteúdo de cada um dos conjuntos é único, ou seja, não foram utilizados os mesmos sinais nestes conjuntos.

Figura 11 – Tipos de padrões da base de dados utilizada: padrões epileptiformes (A), atividade normal de fundo (B), piscada (C), ruído (D).



Fonte: próprio autor.

Tabela 2 – Conjuntos de treinamento, validação e teste.

Conjunto	Padrão Epileptiforme	Atividade Normal	Piscada	Ruído	Total
Treinamento	118	74	27	17	236
Validação	118	74	27	17	236
Teste	241	345	54	22	662
Total	477	493	108	56	1.134

3.2 FAMÍLIAS WAVELET

Primeiramente foi necessário determinar quais funções (famílias escaladas) da Transformada *Wavelet* seriam utilizadas neste estudo. Para tanto, foi realizada uma revisão da literatura sobre a utilização da Transformada *Wavelet* no processamento de sinais de EEG para identificar quais funções obtiveram melhores resultados. Também foram utilizados os resultados obtidos nos trabalhos anteriormente desenvolvidos na linha de pesquisa do IEB-UFSC. A pesquisa de trabalhos relacionados foi realizada através das plataformas de pesquisa *Science Direct* e *PubMed* utilizando como principais palavras-chave: *spike*, *epileptiform*, *Wavelet*, *EEG*, *scalogram* e *neural network*. Dentre os trabalhos encontrados optou-se por selecionar preferencialmente

aqueles cujo objetivo principal era a classificação de padrões e não a detecção da doença, visto que para realização da detecção podem ser utilizadas também outras formas de onda além das espículas. No entanto, apenas 13 trabalhos indicavam claramente a utilização de espículas sendo necessária a utilização de outros trabalhos. Além disso, alguns trabalhos inicialmente selecionados tiveram de ser removidos, pois não descreviam qual função *Wavelet* teria sido utilizada no processamento de sinais.

Dentre os trabalhos encontrados, a maioria (23 trabalhos) tem como objetivo principal analisar o desempenho de classificadores diversos. Além destes, foram encontrados trabalhos cujo objetivo principal é a comparação do uso da Transformada *Wavelet* Discreta e da Transformada *Wavelet* Contínua. Apenas um dos trabalhos encontrados apresenta a proposta de analisar as funções *Wavelet* como objetivo principal (MALAVER; BOOS; AZEVEDO, 2015). Os resultados desta revisão de literatura podem ser observados no Quadro 2. Alguns trabalhos analisados apresentam métricas de análise não relevantes a este estudo, tais como energia do sinal, correlação, entre outros, ao invés de métricas como sensibilidade, especificidade e eficiência. Assim, as lacunas não preenchidas da tabela correspondem a informações não encontradas nos trabalhos selecionados.

Dentre as funções *Wavelet* mais recorrentes na literatura destaca-se a Daubechies 4 (MORAES; CALLEGARI, 2014). Esta função é bastante utilizada, por possuir uma maior correlação dos seus coeficientes com as espículas (ADELI; ZHOU; DADMEHR, 2003; JING ZHOU *et al.*, 2013).

Por meio da revisão da literatura realizada foi possível observar que a maioria dos trabalhos (71,42%) encontrados utilizaram a função Db 4 para o processamento dos sinais de EEG, seguida da função Coif 1 (4 dos 28 trabalhos). Assim, considerando que o trabalho é uma continuação de trabalhos anteriormente desenvolvidos na linha de pesquisa do IEB-UFSC (ARGOUD, 2001; MALAVER, 2014; SCOLARO, 2009, 2014) e a literatura encontrada, foram escolhidas as funções *Wavelet* Bior 3.1, Bior 3.7, Bior 3.9, Coif 1, Coif 4, Db 4, Rbio 1.3, Rbio 1.5 e Rbio 2.8.

Quadro 2 – Características e desempenho de metodologias ou sistemas descritos na literatura sobre automatização no reconhecimento de padrões epileptiformes.

Estudo	Objetivo Principal ^a	Classificação ^b	Família/função wavelet ^c	Classificador ^d	Sensibilidade	Especificidade	Eficiência
Chaibi <i>et al.</i> (2015)	Comparação entre TWC e TWD	EEG	Db 4	Correlação			
Malaver; Boos e Azevedo (2015)	Comparação de famílias Wavelet	EEG	Db, Coif	RNA	Coif 1: 97,90%	Coif 1: 98,48%	Coif 1: 98,24%
Nunes <i>et al.</i> (2014)	Desempenho de classificadores	EEG	Coif, Sym, Db, Haar	OPF	Coif: >80,00%	Coif: >80,0%	Coif: 89,2%
Scolaro (2014)	Desempenho de classificadores	EEG	Bior, Sym, Coif, Rbio, Db	RNA	Db 4: 97,50%	Db 4: 97,3%	Db 4: 97,4%
Malaver (2014)	Desempenho de classificadores	EEG	Db, Bior, Rbio, Sym, Coif	RNA	Rbio 1.5: 89,03%	Rbio 1.5: 89,33%	Rbio 1.5: 89,20%
Halford <i>et al.</i> (2013)	Desempenho de classificadores	EEG	Db 4	RNA			
Song e Zhang (2013)	Desempenho de classificadores	EEG	Db 4	MAE+AG	96,00%	93,6%	94,8%
Xie e Krishnan (2013)	Desempenho de classificadores	Crise	Haar	SVM, k-NN e FLD			
Suresh e Balasubramanyam (2012)	Desempenho de classificadores	EEG	Db 4	RNA + EN			
Acharya <i>et al.</i> (2012)	Desempenho de classificadores	Crise	Rbio 6.8	GMM	99,0%	99,0%	99,0%
Guo <i>et al.</i> (2011)	Desempenho de classificadores	Crise	Db 4	GP + k-NN			99,2%
Haydari; Zhang e Soltanian-Zadeh (2011)	Desempenho de classificadores	EEG	Db 4	AG + Correlação			
Arab; Suratgar e Ashtiani (2010)	Desempenho de classificadores	Crise	Bior 3.3	LVQ			≈80%
Gandhi <i>et al.</i> (2010)	Desempenho de classificadores	Crise	Db 4	PNN	99,6%	99,0%	99,3%
Guo <i>et al.</i> (2010)	Desempenho de classificadores	Crise	Db 4	RNA	99,4%	100%	99,6%
Zandi <i>et al.</i> (2010)	Análise da TWD	Crise	Db 6	Energia do sinal	90,5%		
Lima; Coelho e Chagas (2009)	Desempenho de classificadores	Crise	Db 4	RVM			
Übeyli (2009)	Desempenho de classificadores	Crise	Sym, Coif, Db	RNA(dois níveis)			Db 2: 94,83%
Magosso <i>et al.</i> (2009)	Análise da TWD	Crise	Db 4	Energia do sinal			
Indiradevi <i>et al.</i> (2008)	Desempenho de classificadores	EEG	Db 4	Threshold	91,70%	89,3%	90,5%
Ghosh-Dastidar; Adeli e Dadmehr (2008)	Desempenho de classificadores	Crise	Db 4	PCA + RBFNN			96,2%
Ocak (2008)	Desempenho de classificadores	Crise	Db 2	AG + LVQ			98%
Übeyli (2008)	Desempenho de classificadores	Crise	Db 2	ME			93,17%
Subasi (2007)	Desempenho de classificadores	EEG	Db 4	ME	95,0%	94,0%	
Argoud <i>et al.</i> (2006)	Desempenho de classificadores	EEG	Bior, Coif, Sym e Db	Correlação+RNA	Coif 1: 70,9%	Coif 1: 99,9%	
Subasi e Erçelebi (2005)	Desempenho de classificadores	Crise	Db 4	RNA + RL	89,2%	90,3%	89,0%
Subasi (2005)	Desempenho de classificadores	Crise	Db 4	RNA	92,8%	93,1%	
Adeli; Zhou e Dadmehr (2003)	Análise da TWD	EEG	Db 4	Energia do sinal			

a Objetivo principal no desenvolvimento do estudo.

b Tipo de base de dados utilizado. EEG (espículas, principalmente). Crise (demais padrões presentes no EEG que possam indicar que o paciente está em crise epilética).

c Tipos de classificador: correlação (utilizou apenas a correlação para fazer a comparação entre a Transformada Wavelet Contínua e Discreta), OPF (*Optimum Path Forest*), RNA, MAE (Máquina de Aprendizagem Extrema), AG (algoritmos genéticos), RNA (Rede Neural Artificial), LVQ (*Learning Vector Quantization*), EM (Estimativa de energia), RVM (*Relevance Vector Machine*), ME (*Mixture of Experts*), SVM (*Support Vector Machine*), FLD (*Fisher's Linear Discriminant*), k-NN (*k-Nearest Neighbor algorithm*), GMM (*Gaussian Mixture Model*), GP (*Genetic Programming*), PNN (*Probabilistic Neural Network*), PCA (*Principal Component Analysis*), RBFNN (*Radial Basis Function Neural Network*), *Threshold*.

d Bior (*Biorthogonal*), Coif (Coiflet), Db (Daubechies), Haar, Rbio (*Reverse Biorthogonal*), Sym (Symlets).

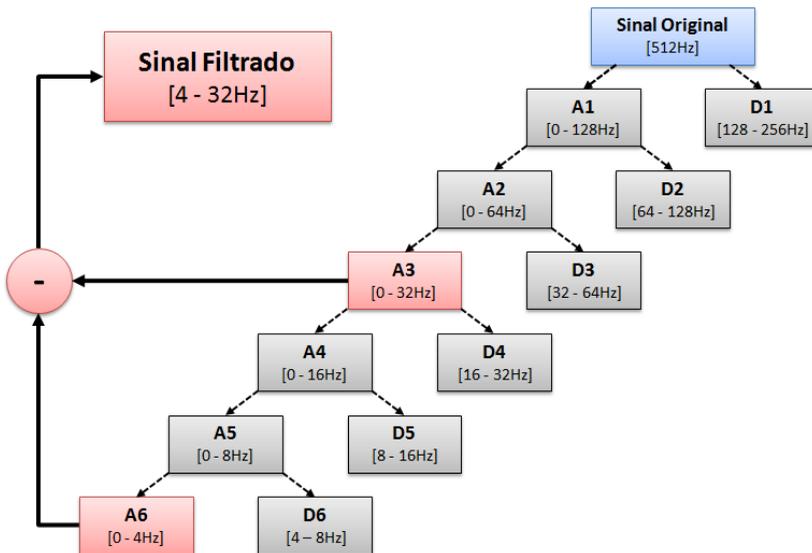
3.3 BANCO DE FILTROS *WAVELET*

No processamento dos sinais da base de dados pelos bancos de filtros *Wavelet* foram consideradas as características do espectro de frequências dos padrões epileptiformes.

De acordo com a literatura, espículas possuem duração de 20 a 70 ms e ondas agudas possuem duração de 70 a 200 ms. Considerando que, de acordo com a aplicação clínica, estes dois padrões eletrográficos são considerados paroxismos epileptiformes pode-se considerar que sua banda de frequência é a faixa de 5 a 50 Hz (SCHOMER; DA SILVA, 2011). No entanto, a predominância de padrões na base de dados ocorre na faixa de 2,5 a 25 Hz.

No processamento por banco de filtros foi implementada a metodologia proposta por Scolaro (2014). Em seu trabalho o autor realiza um estudo a cerca da escolha dos níveis de decomposição que melhor compreendem o espectro de frequência dos padrões epileptiformes e cujo banco de filtros é o mais adequado para processar o sinal de EEG.

Figura 12 – Banco de filtros proposto por Scolaro (2014), utilizando apenas aproximações e realizando a diferença entre os níveis A3 e A6.

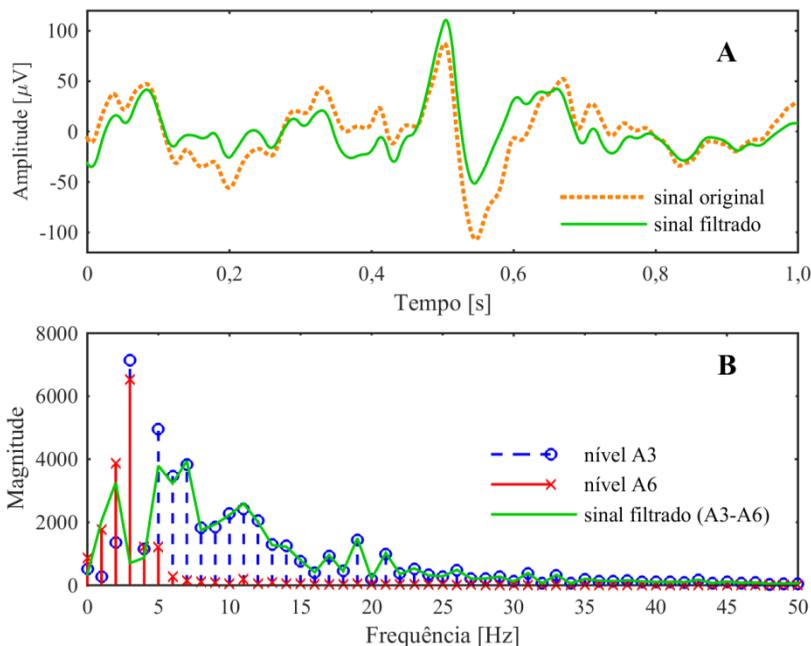


Fonte: Scolaro (2014).

Conforme o estudo de Scolaro (2014), o banco de filtros mais apropriado para o processamento dos sinais é aquele que decompõe o sinal em seis níveis, obtendo os níveis de aproximação de A1 a A6 e de detalhes de D1 a D6, e realiza a diferença entre os níveis A3 e A6 ($\text{sinal filtrado} = A3 - A6$). O sinal resultante da aplicação deste banco de filtros possui apenas frequências entre 4 Hz e 32 Hz, conforme ilustrado na Figura 12. Um exemplo da aplicação do banco de filtros é apresentado na Figura 13.

Na parte superior (A) da Figura 13 é possível observar um padrão epileptiforme sem processamento e filtrado pelo banco de filtros com a função Bior 3.1. Em (B) são apresentadas as respostas em frequência dos níveis A3 e A6, e do sinal filtrado. É possível observar que algumas frequências do sinal original foram atenuadas, permanecendo inalteradas apenas as frequências compreendidas entre 4 Hz e 32 Hz.

Figura 13 – Processamento por banco de filtros. Em (A) apresenta-se um exemplo de padrão epileptiforme com e sem processamento (filtragem). Em (B) apresenta-se a resposta em frequência da filtragem para o sinal de (A).



Fonte: próprio autor.

3.4 ESCALOGRAMA *WAVELET*

Inicialmente os sinais da base de dados foram processados utilizando oito escalas diádicas. No entanto, notou-se que, ao utilizar estes escalogramas como estímulo de entrada da rede neural o tempo necessário para aprendizado de cada rede era alto (aproximadamente três horas) e o custo computacional inviabilizava a realização de todas as simulações necessárias.

Desta forma, para diminuir o tempo de processamento da rede, foram selecionadas apenas algumas escalas diádicas. A escolha das escalas baseou-se no estudo de Malaver (2014), que considerou o intervalo de frequências dos padrões epileptiformes e das escalas diádicas, conforme apresentado Tabela 3, para utilizar as escalas 2^5 , 2^6 , 2^7 e 2^8 .

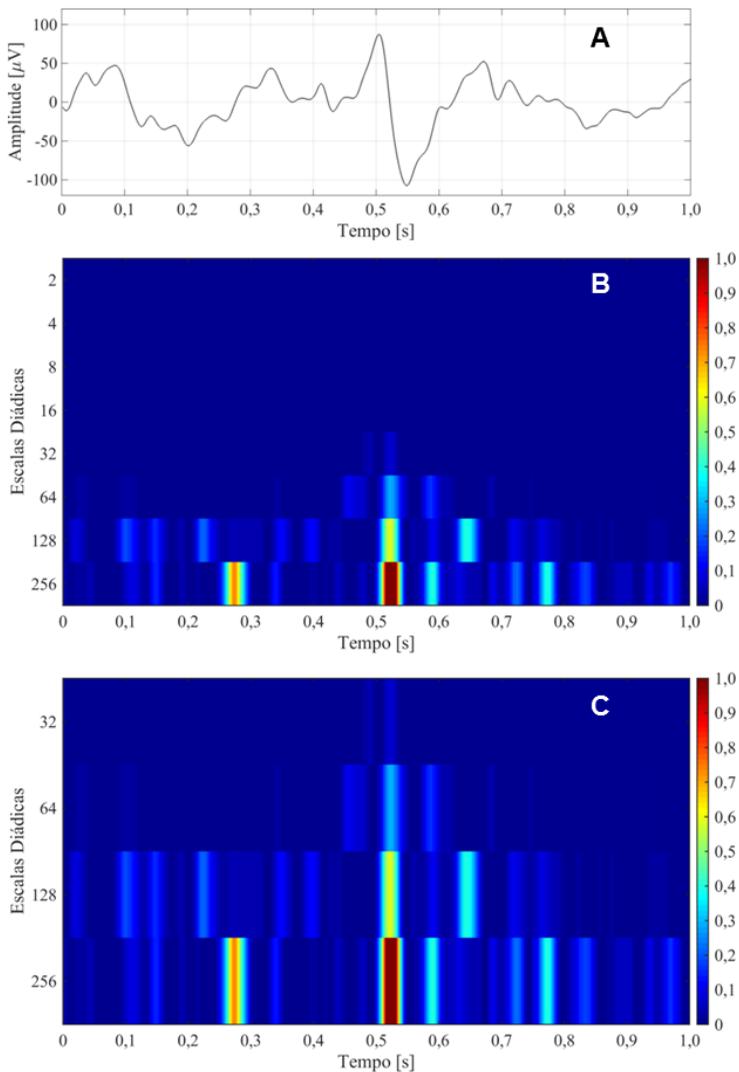
Tabela 3 – Escalas contínuas e diádicas e suas faixas de frequência.

Escalas Contínuas	Faixa de Frequências (Hz)	Escalas Diádicas	Faixa de Frequências (Hz)
2	170,60 – 256,00	2^1	128 – 256
3	128,00 – 170,60	2^2	64 – 128
4	102,40 – 128,00	2^3	32 – 64
5	85,30 – 102,40	2^4	16 – 32
...	...	2^5	8 – 16
254	2,01 – 2,02	2^6	4 – 8
255	2,00 – 2,01	2^7	2 – 4
256	0,00 – 2,00	2^8	0 – 2

Desta forma, todos os sinais contidos na base de dados utilizada passaram pelo processo de filtragem, sendo obtidos os gráficos da densidade espectral de energia, que podem ser vistos nas Figura 14 e Figura 15, nas quais podem ser observados os sinais sem processamento e os sinais processados utilizando escalogramas da Transformada *Wavelet* com as escalas 2^1 a 2^8 (2 a 256) e 2^5 a 2^8 (32 a 256).

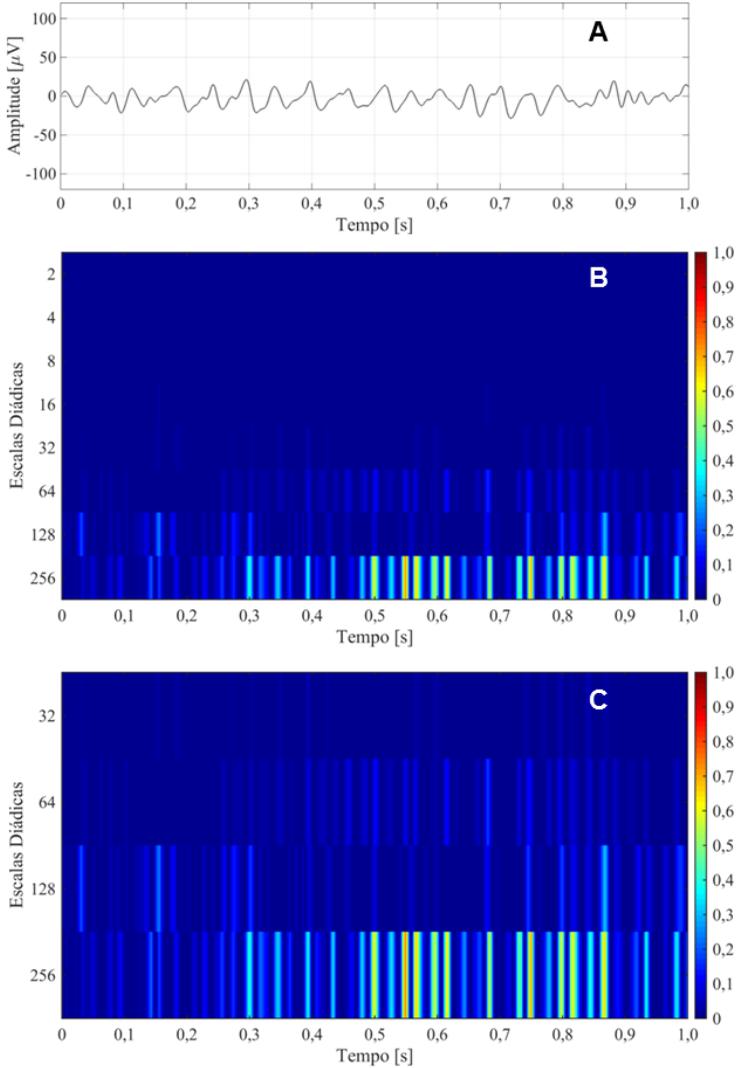
Realizando uma análise comparativa entre os escalogramas obtidos a partir das duas classes de sinal (padrão epileptiformes e ruído) exemplificadas nas figuras, é possível afirmar que padrões epileptiformes possuem energia maior que os sinais correspondentes a ruído.

Figura 14 – Sinal representativo de padrão epileptiforme em sua forma original e processado utilizando escalogramas da Transformada *Wavelet*. Sinal original (A), sinal filtrado utilizando 8 escalas diádicas (B), sinal filtrado utilizando 4 escalas diádicas (C).



Fonte: próprio autor.

Figura 15 – Sinal representativo de ruído em sua forma original e processado utilizando escalogramas da Transformada *Wavelet*. Sinal original (A), sinal filtrado utilizando 8 escalas diádicas (B), sinal filtrado utilizando 4 escalas diádicas (C).



Fonte: próprio autor.

3.5 REDE NEURAL ARTIFICIAL

A classificação dos padrões foi realizada utilizando redes neurais artificiais do tipo Perceptron Multicamadas com algoritmo de aprendizagem *Error Backpropagation*. Os parâmetros ótimos de configuração das redes foram determinados após sucessivas simulações.

Na implementação das redes neurais foi utilizado o processo de validação cruzada e a parada antecipada com o objetivo de evitar a especialização da rede. O algoritmo de treinamento da rede foi implementado de acordo com o fluxograma apresentado no Apêndice A.

Como ferramenta de auxílio para as simulações (treinamento e teste das redes) foi desenvolvida uma interface gráfica utilizando o software MATLAB[®]. Esta interface, ilustrada no Apêndice B, permite:

- definição dos parâmetros de configuração da rede como, por exemplo, tipo de função de ativação, matriz de pesos sinápticos iniciais, taxa de aprendizagem, coeficiente de momento, critério de parada do treinamento, coeficiente de inclinação da função de ativação, quantidade de neurônios da camada intermediária da rede;
- realização do treinamento da rede;
- visualização das curvas de treinamento e validação da rede;
- realização de testes de desempenho da rede;
- visualização do resultado dos testes (desempenho) da rede;
- arquivamento (salvar) a rede neural treinada;
- utilização de redes neurais treinadas anteriormente.

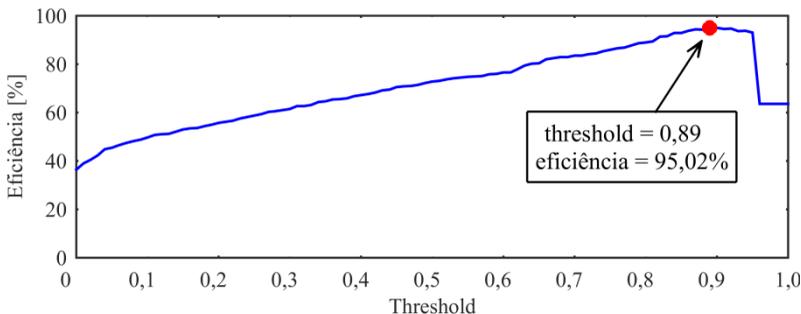
3.6 AVALIAÇÃO DE DESEMPENHO

Neste trabalho, o indicador de desempenho adotado é a máxima eficiência. No entanto, como critério de desempate caso duas ou mais funções apresentem a mesma eficiência máxima, são utilizados como critérios os valores de sensibilidade e especificidade.

Para o cálculo da eficiência são necessários os valores de verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN), conforme a Equação 8. Assim, como para cada limiar de decisão tem-se uma quantidade diferente de VP, VN, FP e FN, implica que o valor de eficiência muda de acordo com o limiar (*threshold*) definido. Logo, o limiar ideal é aquele que maximizar a

eficiência para a rede neural. Neste caso é adotado um intervalo de 0 a 1 com passo de 0.01 para o limiar. Assim, são analisados 100 diferentes valores de limiares para cada uma das redes neurais implementadas, conforme ilustra a curva característica da eficiência da Figura 16.

Figura 16 – Exemplo de gráfico representativo da curva da eficiência.



Fonte: próprio autor

Neste exemplo de simulação, a eficiência máxima encontrada foi de 95,02% quando utilizado um limiar (*threshold*) de 0,89.

3.7 SIMULAÇÕES

Nesta subseção será apresentado o protocolo de simulações utilizados no desenvolvimento deste trabalho.

Inicialmente, todos os dados dos conjuntos de treinamento, validação e teste foram processados utilizando banco de filtros e escalogramas e o conjunto de nove funções *Wavelet* definidas.

Posteriormente, utilizando a interface gráfica desenvolvida, conforme Apêndice B, os sinais de EEG do conjunto de treinamento processados por um dos métodos da TW são carregados e os parâmetros de configuração da rede (taxa de aprendizagem, coeficiente de momento, coeficiente de inclinação e tipo de função de ativação, critérios de parada e quantidade de neurônios da camada intermediária) são definidos pelo usuário.

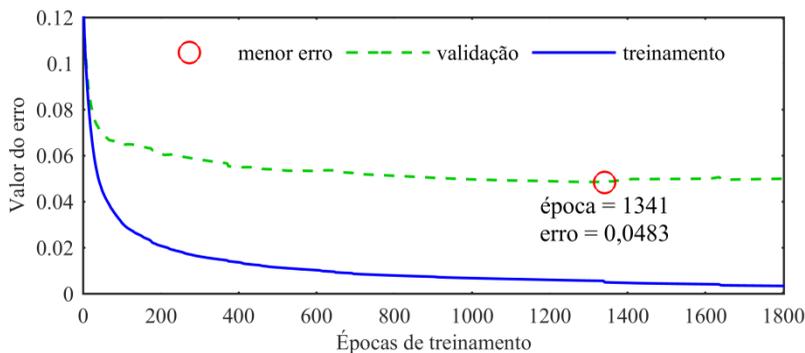
Ao iniciar o processo de treinamento, ocorre a definição automática da dimensão ideal para a matriz de pesos iniciais, a qual depende do tipo de entrada escolhida. Após cada época de treinamento,

inicia-se o processo de validação cruzada o qual consiste em aplicar um conjunto de sinais de EEG de validação (processados com o mesmo método da TW e função do conjunto de treinamento) à rede resultante da época.

Assim, no momento em que o erro de validação começa a aumentar, diz-se que a rede passou a especializar-se, conforme ilustrado na Figura 17, na qual pode-se observar que para a rede treinada o erro de validação a partir da época 1341 começa a aumentar, indicando que o treinamento deve ser interrompido. Assim, são considerados ideais os valores contidos na matriz de pesos que antecede a especialização da rede.

Para as simulações descritas neste estudo, diversas configurações de parâmetros foram utilizadas com objetivo de determinar qual delas resulta em um melhor desempenho para a rede. Desta forma, foram obtidas 15 diferentes redes neurais para cada uma das nove funções, para cada um dos dois métodos de aplicação da TW. Logo, foi obtido um total de 270 redes neurais distintas, conforme Apêndice C e Apêndice D.

Figura 17 – Exemplo de gráfico representativo das curvas de erro de treinamento e de validação cruzada. Curva de erro de treinamento (sólido), curva de erro de validação (tracejado).



Fonte: próprio autor.

4 RESULTADOS E DISCUSSÃO

Nos testes realizados com as redes neurais implementadas e treinadas, foram calculados os seguintes indicadores de desempenho: sensibilidade (Sens.), especificidade (Espec.), eficiência (Efic.) além das quantidades de verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN) para o limiar que maximiza a eficiência de cada rede neural.

Como critério para determinar qual função e qual método de processamento seria mais apropriado para a base de dados utilizada, utilizou-se a máxima eficiência. No entanto, como critério de desempate caso duas ou mais funções apresentassem a mesma eficiência foram analisados os valores calculados para sensibilidade e especificidade.

A partir do conjunto de 270 redes neurais testadas, contidas no Apêndice C e Apêndice D, foram analisadas se as distribuições de dados para eficiência de banco de filtros e escalogramas aderem a uma distribuição normal de probabilidades para então se dar início a comparação de resultados. Para isto foi utilizado o teste de *Kolmogorov-Smirnov* (teste K-S) utilizando a ferramenta computacional MATLAB[®]. O teste K-S fornece o parâmetro valor de prova (valor-p) que corresponde ao grau de concordância entre os dados e a hipótese nula H_0 , que corresponde por sua vez a uma distribuição normal. Logo, caso a hipótese nula seja rejeitada a um nível de significância p , não se pode admitir que a distribuição de dados aproxima-se de uma distribuição normal. Caso contrário, não se rejeitando H_0 , a distribuição normal é uma distribuição possível para o conjunto de dados em questão.

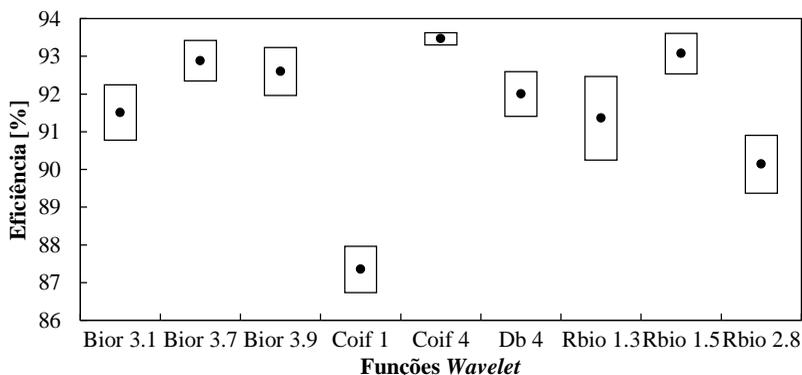
Tabela 4 – Resultados do teste de normalidade Kolmogorov-Smirnov para as eficiências do banco de filtros e dos escalogramas.

Banco de Filtros			Escalograma		
Função	Valor-p	H_0	Função	Valor-p	H_0
Bior 3.1	0,6325	0	<i>Bior 3.1</i>	<i>0,0386</i>	<i>1</i>
Bior 3.7	0,5653	0	Bior 3.7	0,1861	0
Bior 3.9	0,4026	0	Bior 3.9	0,1873	0
Coif 1	0,7170	0	Coif 1	0,0530	0
Coif 4	0,6614	0	Coif 4	0,4904	0
Db 4	0,1864	0	Db 4	0,3219	0
Rbio 1.3	0,0537	0	Rbio 1.3	0,2096	0
Rbio 1.5	0,1508	0	Rbio 1.5	0,3286	0
<i>Rbio 2.8</i>	<i>0,0152</i>	<i>1</i>	Rbio 2.8	0,14936	0

Analisando os resultados da Tabela 4 pode-se observar que as distribuições de dados para as funções Rbio 2.8 utilizando Banco de Filtros e Bior 3.1 utilizando Escalogramas rejeitaram a hipótese nula, ou seja, não aderem a uma distribuição normal de dados. Desta forma, é necessário fazer uso de métodos não paramétricos para análise dos resultados. Dentre os testes não paramétricos existentes na ferramenta STATISTICA[®] tem-se o teste de Friedman ANOVA, no qual análise de variância (ANOVA) testa a hipótese de que as médias de duas ou mais populações são iguais. Para as simulações de Friedman ANOVA foram utilizadas 15 redes neurais ($N = 15$) e oito graus de liberdade ($df = 8$). A partir dos testes realizados foram obtidos *chi square* de 42,38175 para o Banco de Filtros e *chi square* de 77,15854 para os escalogramas e valores de significância (p) de 0,00001 para ambos os métodos de filtragem.

O baixo valor de p indica que há diferenças entre duas ou mais amostras nas análises. No entanto, para observar quais distribuições de dados são iguais e quais são distintas utilizou-se o teste de Wilcoxon *Matched pairs*, também utilizando a ferramenta STATISTICA[®]. Neste teste, as amostras são comparadas aos pares e é retornado o valor- p que indica se há ou não diferença entre suas médias. Um valor- p abaixo de 0,05 indica que existe diferença entre as médias das amostras. Em contrapartida, um valor- p acima de 0,05 indica que as médias das amostras são estatisticamente iguais.

Figura 18 – Valores da média e erro padrão, calculados com o teste de Friedman ANOVA, para a eficiência das redes neurais utilizando banco de filtros.



Fonte: próprio autor.

Os resultados dos testes (Friedman ANOVA e Wilcoxon *Matched pairs*) para o Banco de Filtros podem ser observados na Figura 18 e Tabela 5. As células sombreadas na Tabela 5 indicam pares de funções com médias estatisticamente iguais (valores-p acima de 0,05).

Tabela 5 – Resultado do teste Wilcoxon *Matched pairs* para a eficiência das redes neurais utilizando Bancos de Filtros com todas as funções *Wavelet*.

valor p	Bior 3.1	Bior 3.7	Bior 3.9	Coif 1	Coif 4	Db 4	Rbio 1.3	Rbio 1.5	Rbio 2.8
Bior 3.1	-	0,125	0,363	0,002	0,041	0,268	0,865	0,064	0,281
Bior 3.7	0,125	-	0,910	0,001	0,211	0,379	0,427	0,950	0,008
Bior 3.9	0,363	0,910	-	0,001	0,281	0,363	0,394	0,798	0,011
Coif 1	0,002	0,001	0,001	-	0,001	0,001	0,008	0,001	0,015
Coif 4	0,041	0,211	0,281	0,001	-	0,035	0,033	0,733	0,001
Db 4	0,268	0,379	0,363	0,001	0,035	-	0,955	0,156	0,100
Rbio 1.3	0,865	0,427	0,394	0,008	0,033	0,955	-	0,293	0,078
Rbio 1.5	0,064	0,950	0,798	0,001	0,733	0,156	0,293	-	0,006
Rbio 2.8	0,281	0,008	0,011	0,015	0,001	0,100	0,078	0,006	-

Analisando os resultados encontrados utilizando Banco de Filtros não é possível afirmar que a função Coif 4 é melhor que as demais funções pois o teste de Wilcoxon acusa que as médias das funções Coif 4, Bior 3.7, Bior 3.9 e Rbio 1.5 são estatisticamente iguais. No entanto, é possível afirmar que a pior função é a Coif 1 pois sua eficiência média é estatisticamente menor e diferente de todas as outras.

Para verificar se a função Coif 1 está influenciando os resultados da análise utilizando Banco de Filtros, foi feito um novo teste removendo a Coif 1 e mantendo as outras nove funções *Wavelet*, que pode ser visto na Tabela 6.

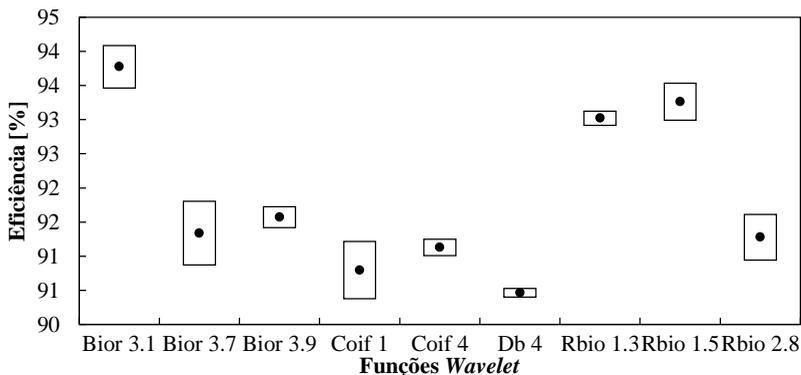
A retirada da função Coif 1 do teste não provocou alterações significativas nos valores-p de forma que se pudesse determinar qual função possui maior média estatística para eficiência. Desta forma, mantém-se o resultado de que as funções Coif 4, Bior 3.7, Bior 3.9 e Rbio 1.5 são estatisticamente iguais.

Tabela 6 – Resultado do teste de Wilcoxon *Matched pairs* para os valores de eficiência das redes neurais utilizando Bancos de Filtros sem a função Coif 1..

valor p	Bior 3.1	Bior 3.7	Bior 3.9	Coif 4	Db 4	Rbio 1.3	Rbio 1.5	Rbio 2.8
Bior 3.1	-	0,125	0,363	0,041	0,281	0,910	0,064	0,281
Bior 3.7	0,125	-	0,910	0,233	0,394	0,414	0,972	0,008
Bior 3.9	0,363	0,910	-	0,349	0,334	0,349	0,798	0,011
Coif 4	0,041	0,233	0,349	-	0,043	0,033	0,755	0,001
Db 4	0,281	0,394	0,334	0,043	-	0,851	0,140	0,088
Rbio 1.3	0,910	0,414	0,349	0,033	0,851	-	0,286	0,074
Rbio 1.5	0,064	0,972	0,798	0,755	0,140	0,286	-	0,006
Rbio 2.8	0,281	0,008	0,011	0,001	0,088	0,074	0,006	-

Os testes realizados para os Escalogramas foram os mesmos utilizados na análise dos Bancos de Filtros: Friedman ANOVA e Wilcoxon *Matched pairs*. Os resultados para os Escalogramas podem ser observados na Figura 19 e Tabela 7. As células sombreadas na Tabela 7 indicam pares de funções com médias estatisticamente iguais (valores-p acima de 0,05).

Figura 19 – Valores da média e erro padrão, calculados com o teste de Friedman ANOVA, para a eficiência das redes neurais utilizando Escalogramas.



Fonte: próprio autor.

Tabela 7 – Resultado do teste de Wilcoxon *Matched pairs* para os valores de eficiência das redes neurais utilizando Escalogramas com todas as funções *Wavelet*.

valor p	Bior 3.1	Bior 3.7	Bior 3.9	Coif 1	Coif 4	Db 4	Rbio 1.3	Rbio 1.5	Rbio 2.8
Bior 3.1	–	0,005	0,001	0,001	0,001	0,001	0,035	0,029	0,001
Bior 3.7	0,005	–	0,733	0,307	0,156	0,053	0,001	0,004	0,691
Bior 3.9	0,001	0,733	–	0,064	0,016	0,001	0,001	0,001	0,972
Coif 1	0,001	0,307	0,064	–	0,790	0,109	0,001	0,001	0,443
Coif 4	0,001	0,156	0,016	0,790	–	0,003	0,001	0,001	0,132
Db 4	0,001	0,053	0,001	0,109	0,003	–	0,001	0,001	0,012
Rbio 1.3	0,035	0,001	0,001	0,001	0,001	0,001	–	0,158	0,001
Rbio 1.5	0,029	0,004	0,001	0,001	0,001	0,001	0,158	–	0,001
Rbio 2.8	0,001	0,691	0,972	0,443	0,132	0,012	0,001	0,001	–

Analisando os resultados obtidos utilizando Escalogramas (Tabela 7 e Figura 19) é possível afirmar que a função Bior 3.1 é a melhor, pois sua média é superior e estatisticamente diferente das médias das outras funções. No entanto, neste caso, não é possível afirmar que a função Db 4 é a pior, pois sua média é estatisticamente igual as das funções Bior 3.7 e Coif 1.

Para os Escalogramas foi realizado um teste adicional utilizando apenas a funções que se destacaram no teste pareado para corroborar a definição da melhor função, visto que Rbio 1.3 e Rbio 1.5 apresentaram médias próximas das obtidas pela função Bior 3.1. O resultado deste teste pode ser observado na Tabela 8.

Tabela 8 – Resultado do teste de Wilcoxon *Matched pairs* para a eficiência das redes neurais com Escalogramas das funções Bior 3.1, Rbio 1.3 e Rbio 1.5.

valor p	Bior 3.1	Rbio 1.3	Rbio 1.5
Bior 3.1	–	0,035	0,033
Rbio 1.3	0,035	–	0,133
Rbio 1.5	0,033	0,133	–

Analisando o resultado do teste adicional com os Escalogramas, pode-se perceber que a função Bior 3.1 continua se destacando como a melhor função e as funções Rbio 1.3 e Rbio 1.5 continuam apresentando médias estatisticamente iguais.

Após analisar todas as funções para Banco de Filtros e Escalogramas, foi feita uma análise pareada entre o Banco de Filtros e Escalogramas de uma mesma função *Wavelet*. Esta análise teve como objetivo a definição de qual método de processamento (Banco de Filtros e Escalogramas) é o mais adequado para cada função. Para esta análise foram utilizados novamente os testes de Friedman ANOVA e Wilcoxon *Matched pairs*, cujos resultados podem ser observados na Tabela 9.

Tabela 9 – Resultado (valor p) dos testes de Friedman ANOVA e Wilcoxon para os pares de eficiência média das funções *Wavelet* analisadas.

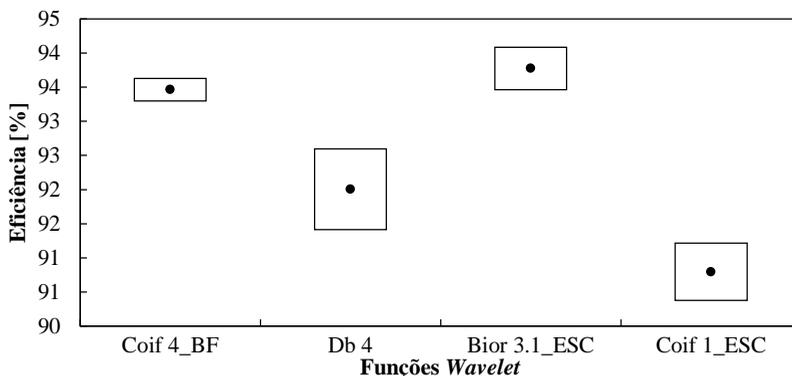
Função Wavelet	Valor médio da eficiência		Friedman ANOVA	Teste Wilcoxon
	Banco Filtros	Escalograma		
Bior 3.1	91,5106	93,7764	0,071	0,023
<i>Bior 3.7</i>	92,8802	91,3381	<i>0,197</i>	<i>0,069</i>
<i>Bior 3.9</i>	92,5982	91,5710	<i>0,071</i>	<i>0,140</i>
Coif 1	87,3515	90,7956	0,005	0,002
Coif 4	93,4643	91,1279	0,001	0,001
Db 4	92,0040	90,4632	0,033	0,030
<i>Rbio 1.3</i>	91,3595	93,0212	<i>0,439</i>	<i>0,233</i>
<i>Rbio 1.5</i>	93,0715	93,2628	<i>0,439</i>	<i>0,650</i>
<i>Rbio 2.8</i>	90,1410	91,2790	<i>0,071</i>	<i>0,078</i>

Analisando a Tabela 9 que apresenta os resultados obtidos nos testes para cada uma das funções processadas por Banco de Filtros com seu par correspondente em Escalogramas, pode-se afirmar que as funções Bior 3.7, Bior 3.9, Rbio 1.3, Rbio 1.5 e Rbio 2.8 possuem médias estatisticamente iguais para ambos os métodos de processamento. As demais funções analisadas, por sua vez, possuem médias estatisticamente diferentes. Desta forma, é possível afirmar que as funções Coif 4 e Db 4 apresentam melhor desempenho quando utilizado Banco de Filtros. E as funções Bior 3.1 e Coif 1 apresentam melhor desempenho quando utilizado Escalogramas.

Para verificar se alguma função do conjunto selecionado se sobressai em relação às outras, foi realizada uma análise entre as funções que se destacaram em cada método de processamento utilizando

os testes não paramétricos de Friedman ANOVA e Wilcoxon *Matched pairs*, os quais podem ser observados na Tabela 10 e Figura 20.

Figura 20 – Valores da média e erro padrão da eficiência das redes neurais utilizando Banco de Filtros e Escalograma.



Fonte: próprio autor.

Tabela 10 – Resultado do teste de Wilcoxon *Matched pairs* para os valores de eficiência das redes neurais utilizando as funções Coif 1 e Db 4 para Banco de Filtros e Bior 3.1 e Coif 1 para Escalogramas.

valor p	Coif 4_BF	Db 4_BF	Bior 3.1_ESC	Coif 1_ESC
Coif 4_BF	–	0,035	0,084	0,001
Db 4_BF	0,035	–	0,020	0,112
Bior 3.1_ESC	0,084	0,020	–	0,001
Coif 1_ESC	0,001	0,112	0,001	–

Com base na Tabela 10, pode-se afirmar que nenhuma função analisada se destacou em relação às outras duas, de forma que, estatisticamente, as funções Coif 4_BF e Bior 3.1_ESC e, Db 4_BF e Coif 1_ES possuem a mesma média.

Em uma última análise, foi realizada uma comparação do desempenho entre Banco de Filtros e Escalogramas para as redes que obtiveram maior valor de eficiência para cada função.

Tabela 11 – Comparativo de desempenho entre Banco de Filtros e Escalogramas para as redes de cada função que obtiveram maior valor de eficiência entre as redes analisadas.

Banco de Filtros				Escalograma			
Função	Efi ^a (%)	Sen ^b (%)	Esp ^c (%)	Função	Efi ^a (%)	Sen ^b (%)	Esp ^c (%)
Bior 3.1	95,770	95,851	95,725	Rbio 1.5	94,864	97,095	93,587
Bior 3.7	95,770	96,266	95,487	Bior 3.1	94,411	94,191	94,537
Bior 3.9	95,468	94,606	95,962	Rbio 1.3	93,656	96,266	92,162
Coif 4	94,713	92,946	95,725	Bior 3.7	92,296	91,701	92,637
Rbio 1.3	94,713	92,946	95,725	Rbio 2.8	92,296	91,701	92,637
Rbio 1.5	94,713	90,871	96,912	Bior 3.9	92,145	86,307	95,487
Db 4	94,109	98,340	91,687	Coif 4	91,843	93,361	90,974
Rbio 2.8	93,050	93,360	92,870	Coif 1	91,692	90,456	92,399
Coif 1	91,239	90,042	91,924	Db 4	90,937	90,871	90,974

^a Eficiência.

^b Sensibilidade.

^c Especificidade.

Com base na Tabela 11 pode-se afirmar que utilizando Banco de Filtros e analisando como parâmetro a máxima eficiência, as funções que obtiveram melhor desempenho foram a Bior 3.1 e a Bior 3.7 e a que obteve pior desempenho foi a Coif 1. Utilizando-se Escalogramas, por sua vez, as funções que obtiveram melhor desempenho foram a Rbio 1.5 e a Bior 3.1 e a que obteve pior desempenho foi a Db 4.

Como critério para determinação de qual função (Bior 3.1 ou Bior 3.7) seria mais apropriada para a filtragem de sinais utilizando banco de filtros, foram utilizados os valores calculados de sensibilidade e de especificidade. Ambas as funções apresentaram 95,77% de eficiência, no entanto, a função Bior 3.1 apresentou 0,13% de diferença entre seus valores de sensibilidade e especificidade, enquanto que a Bior 3.7 apresentou 0,80% de diferença. Isto demonstra que a função Bior 3.1 apresenta os valores de sensibilidade e especificidade mais próximos entre si, não apresentando perda significativa de sensibilidade em detrimento de especificidade e vice-versa.

Considerando como critério a eficiência máxima, a função Bior 3.1 ficou em segundo lugar no “*ranking*” entre as melhores funções para processamento utilizando Escalogramas (94,41%), com 0,45 pontos

percentuais⁴ (0,47%) abaixo de Rbio 1.5. Enquanto a função Bior 3.1 apresenta 0,36% de diferença entre seus valores de sensibilidade e especificidade, a função Rbio 1.5 apresenta 3,61% de diferença. Logo, a função encontrada que demonstra ser mais apropriada para processamento por escalogramas também é a Bior 3.1.

Analisando comparativamente os métodos de filtragem propostos é possível afirmar que, dentre as nove funções testadas, em sete delas o método de filtragem que demonstrou ser mais apropriado foi por banco de filtros, exceto para as funções Coif 1 e Rbio 1.5, as quais obtiveram melhor desempenho quando utilizado o método de processamento por escalogramas (utilizando a eficiência máxima como critério de análise).

Por fim, considerando que a função Bior 3.1 demonstrou ser apropriada para ambos os métodos de filtragem de sinais de EEG, é necessário realizar uma comparação direta entre os resultados obtidos para cada método de processamento. Ao utilizando banco de filtros, a função Bior 3.1 obteve eficiência de 95,77% e diferença entre sensibilidade e especificidade de 0,13%, enquanto que utilizando escalogramas, esta função apresentou eficiência de 94,41% e diferença entre sensibilidade e especificidade de 0,36%. Logo, pode-se afirmar que tomando como base o resultado de uma única rede, a melhor função é a Bior 3.1 e o método de processamento mais apropriado é por Banco de Filtros.

Como forma adicional de análise, foram utilizadas as médias dos valores de eficiência encontrados para as funções mais utilizadas (Coif 1 e Db 4) dos trabalhos⁵ apresentados no Quadro 2. Nos trabalhos do quadro, o processamento dos sinais de EEG é por banco de filtro. A eficiência média para a Coif 1 na literatura é de 93,72% enquanto que para este trabalho é de 91,23%. Já a eficiência média da Db 4 para a literatura é de 95,51% enquanto que para este trabalho é de 94,10%. Desta forma, pode-se afirmar que os resultados obtidos neste estudo são próximos aos encontrados na literatura.

⁴ Ponto percentual é o nome da unidade que indica o valor absoluto da diferença entre percentagens

⁵ Apenas para os trabalhos que dispõem dos valores de eficiência encontrados.

5 CONCLUSÃO

O objetivo deste trabalho norteou-se no estudo comparativo entre as formas de aplicação da Transformada *Wavelet* (Banco de Filtros e Escalogramas) como método de processamento de sinais de EEG aplicados à entrada de classificadores neurais.

A metodologia proposta constituiu-se de duas etapas. Na primeira etapa foram processados os sinais de EEG para remoção de desvios de linha de base e eliminação de interferências (como as causadas pela rede elétrica) utilizando os dois métodos de aplicação da Transformada *Wavelet*: Banco de filtros e Escalogramas. Na segunda etapa, os sinais processados foram aplicados à entrada de um classificador neural do tipo Perceptron Multicamadas com algoritmo de aprendizagem *Error Backpropagation*.

No processamento por banco de filtros foram utilizados os níveis de aproximação A3 e A6 (na ordem A3-A6) para que o sinal permanecesse com espectro de frequência no intervalo de 4 a 32 Hz. Este intervalo corresponde a faixa de interesse para os padrões epileptiformes.

Por sua vez, no processamento por escalogramas foram utilizadas inicialmente as escalas diádicas de 2^1 a 2^8 . No entanto, após diversas simulações e análises, as escalas foram reduzidas para as bases 2^5 a 2^8 (0 a 16 Hz), o que diminuiu pela metade o tempo de aprendizado da rede neural sem perda de informação do sinal processado. Com um menor tempo gasto para aprendizado de cada rede neural, um maior número de redes puderam ser treinadas e testadas.

Na etapa de análise de resultados foi utilizado um conjunto de 270 redes neurais testadas. Para determinação de qual função e método de processamento de EEG é mais apropriado foram utilizados dois métodos de análise, sendo o primeiro considerando a média das eficiências de cada função *Wavelet* e fazendo uso de técnicas de análise não paramétrica e a segunda, utilizando o resultado obtido a partir de uma única rede testada (a que obteve maior eficiência) para cada função *Wavelet*.

Considerando os resultados da análise não paramétrica, as funções Coif 4_BF e Bior 3.1_ESC e, Db 4_BF e Coif 1_ES possuem a mesma média estatística, não sendo possível determinar qual delas possui melhor desempenho.

Por sua vez, considerando o resultado obtido para uma única rede, a função que demonstra ser mais apropriada para processamento

de sinais de EEG é a Bior 3.1 e o método de processamento mais indicado é utilizando Banco de Filtros.

Considerando que foi realizado um número reduzido de treinamentos em relação à quantidade de combinações possíveis para a configuração da rede (cerca de doía bilhões de configurações distintas), o método de análise de resultados mais apropriado é utilizando análise não paramétrica. Logo, as funções Coif 4 e Db 4 utilizando Banco de Filtros e Bior 3.1 e Coif 1 utilizando Escalogramas apresentam bom desempenho para processamento digital de sinais de EEG.

6 TRABALHOS FUTUROS

Apesar do trabalho aqui proposto ter alcançado o seu objetivo inicial que era a realização de uma comparação entre os dois métodos de aplicação da Transformada *Wavelet*, banco de filtros e escalogramas, algumas propostas de trabalhos futuros serão apresentadas com o objetivo de aperfeiçoar a análise e o processamento do sistema proposto, tais como:

- Aumentar a base de dados utilizada a fim de analisar se o resultado se mantém.
- Utilizar outros tipos de classificadores, tais como os utilizados nos trabalhos do Quadro 2. Com a implementação de novos classificadores é possível realizar um estudo comparativo entre o classificador utilizado neste trabalho, Perceptron Multicamadas com algoritmo de aprendizagem *Error Backpropagation*, e demais classificadores com o objetivo de verificar a influência destes sobre os resultados da classificação dos sinais contidos na base de dados.
- Utilizar outras funções *Wavelet* e aumentar o número de testes com cada função.
- Aprimoramento e aumento da interface gráfica com a inclusão de ferramentas adicionais de análise estatística, visualização de padrões apresentados à rede,
- Vincular a etapa de processamento dos sinais da base de dados à interface proposta. Assim, além de inicializar os parâmetros de treinamento da rede, será necessário definir os parâmetros desejados de processamento dos sinais, tais como método de processamento e função *Wavelet*.

Acredita-se que a implementação das propostas aqui apresentadas não demandaria muito esforço, visto que a rotina de processamento de sinais, bem como a interface gráfica proposta foram construídas em rotinas bem definidas para cada uma das etapas de processamento, treinamento, teste e análise de resultados, facilitando assim sua modificação e aprimoramento.

REFERÊNCIAS

ABIBULLAEV, B.; KIM, M. S.; SEO, H. D. Seizure detection in temporal lobe epileptic EEGs using the best basis wavelet functions. **Journal of Medical Systems**, v. 34, n. 4, p. 755–765, 2010.

ACHARYA, U. R.; MOLINARI, F.; SREE, S. V.; CHATTOPADHYAY, S.; NG, K.-H.; SURI, J. S. Automated diagnosis of epileptic EEG using entropies. **Biomedical Signal Processing and Control**, v. 7, n. 4, p. 401–408, jul. 2012.

ADELI, H.; ZHOU, Z.; DADMEHR, N. Analysis of EEG records in an epileptic patient using wavelet transform. **Journal of Neuroscience Methods**, v. 123, n. 1, p. 69–87, 2003.

AIBINU, A. M.; SALAMI, M. J. E.; SHAFIE, A. A. Artificial neural network based autoregressive modeling technique with application in voice activity detection. **Engineering Applications of Artificial Intelligence**, v. 25, n. 6, p. 1265–1276, 2012.

ALOTAIBY, T.; EL-SAMIE, F. E. A.; ALSHEBEILI, S. A.; AHMAD, I. A review of channel selection algorithms for EEG signal processing. **EURASIP Journal on Advances in Signal Processing**, v. 2015, n. 1, p. 66, 2015.

ARAB, M. R.; SURATGAR, A. A.; ASHTIANI, A. R. Electroencephalogram signals processing for topographic brain mapping and epilepsies classification. **Computers in biology and medicine**, v. 40, n. 9, p. 733–9, set. 2010.

ARGOUD, F. I. M. **Contribuição à automatização da detecção e análise de eventos epileptiformes em eletroencefalograma**. Universidade Federal de Santa Catarina, 2001.

ARGOUD, F. I. M.; AZEVEDO, F. M.; NETO, J. M.; GRILLO, E. SADE3: An effective system for automated detection of epileptiform events in long-term EEG based on context information. **Medical and Biological Engineering and Computing**, v. 44, n. 6, p. 459–470, 2006.

ASKAMP, J.; VAN PUTTEN, M. J. A. M. Mobile EEG in epilepsy. **International journal of psychophysiology : official journal of the International Organization of Psychophysiology**, v. 91, n. 1, p. 30–5, jan. 2014.

CASSON, A. J.; LUNA, E.; RODRIGUEZ-VILLEGAS, E. Performance metrics for the accurate characterisation of interictal spike detection algorithms. **Journal of neuroscience methods**, v. 177, n. 2, p. 479–87, 15 mar. 2009.

CHAIBI, S.; LAJNEF, T.; GHROB, A.; SAMET, M.; KACHOURI, A. A Robustness Comparison of Two Algorithms Used for EEG Spike Detection. **The Open Biomedical Engineering Journal**, p. 151–156, 2015.

DAI, K.; ZHAO, J.; CAO, F. A novel decorrelated neural network ensemble algorithm for face recognition. **Knowledge-Based Systems**, v. 89, p. 541–552, 2015.

FAUSETT, L. V. **Fundamentals of Neural Networks: Architectures, Algorithms and Applications**. New Jersey: Prentice Hall, 1994.

GANDHI, T.; PANIGRAHI, B. K.; BHATIA, M.; ANAND, S. Expert model for detection of epileptic activity in EEG signature. **Expert Systems with Applications**, v. 37, n. 4, p. 3513–3520, 2010.

GHOSH-DASTIDAR, S.; ADELI, H.; DADMEHR, N. Principal component analysis-enhanced cosine radial basis function neural network for robust epilepsy and seizure detection. **IEEE transactions on bio-medical engineering**, v. 55, n. 2 Pt 1, p. 512–8, fev. 2008.

GUO, L.; RIVERO, D.; DORADO, J.; MUNTEANU, C. R.; PAZOS, A. Automatic feature extraction using genetic programming: An application to epileptic EEG classification. **Expert Systems with Applications**, v. 38, n. 8, p. 10425–10436, ago. 2011.

GUO, L.; RIVERO, D.; DORADO, J.; RABUÑAL, J. R.; PAZOS, A. Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks. **Journal of neuroscience methods**, v. 191, n. 1, p. 101–9, 15 ago. 2010.

HALFORD, J. J.; SCHALKOFF, R. J.; ZHOU, J.; BENBADIS, S. R.; TATUM, W. O.; TURNER, R. P.; SINHA, S. R.; FOUNTAIN, N. B.; ARAIN, A.; PRITCHARD, P. B.; KUTLUAY, E.; MARTZ, G.; EDWARDS, J. C.; WATERS, C.; DEAN, B. C. Standardized database development for EEG epileptiform transient detection: EEGnet scoring system and machine learning analysis. **Journal of neuroscience methods**, v. 212, n. 2, p. 308–16, 30 jan. 2013.

HARNER, R. Automatic EEG Spike Detection. **Clinical EEG and Neuroscience**, v. 40, n. 4, p. 262–270, 1 out. 2009.

HAYDARI, Z.; ZHANG, Y.; SOLTANIAN-ZADEH, H. Semi-automatic epilepsy spike detection from EEG signal using Genetic Algorithm and Wavelet transform. **Bioinformatics and Biomedicine Workshops (BIBMW), 2011 IEEE International Conference on**, p. 635–638, 2011.

HE, Y.; LIU, Y. Experimental research into time-frequency characteristics of cavitation noise using wavelet scalogram. **Applied Acoustics**, v. 72, n. 10, p. 721–731, 2011.

INDIRADEVI, K. P.; ELIAS, E.; SATHIDEVI, P. S.; DINESH NAYAK, S.; RADHAKRISHNAN, K. A multi-level wavelet approach for automatic detection of epileptic spikes in the electroencephalogram. **Computers in biology and medicine**, v. 38, n. 7, p. 805–16, jul. 2008.

JING ZHOU; SCHALKOFF, R. J.; DEAN, B. C.; HALFORD, J. J. A study of morphology-based wavelet features and multiple-wavelet strategy for EEG signal classification: Results and selected statistical analysis. In: 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2013, Osaka, Japão, **Anais...**, New Jersey, 2013, p. 5998–6002.

KUMAR, R.; KUMAR, A.; SINGH, G. K. Hybrid method based on singular value decomposition and embedded zero tree wavelet technique for ECG signal compression. **Computer Methods and Programs in Biomedicine**, v. 129, p. 135–148, 2015.

LIMA, C. A. M.; COELHO, A. L. V.; CHAGAS, S. Automatic EEG signal classification for epilepsy diagnosis with Relevance Vector

Machines. **Expert Systems with Applications**, v. 36, n. 6, p. 10054–10059, ago. 2009.

MAGOSSO, E.; URSINO, M.; ZANIBONI, A.; GARDELLA, E. A wavelet-based energetic approach for the analysis of biomedical signals: Application to the electroencephalogram and electro-oculogram. **Applied Mathematics and Computation**, v. 207, n. 1, p. 42–62, 2009.

MALAVAR, W. J. L. **Identificação de eventos epileptiformes em sinais de EEG com escalogramas como entrada de redes neurais artificiais**. Universidade Federal de Santa Catarina, 2014.

MALAVAR, W. L.; BOOS, C. F.; AZEVEDO, F. M. DE. Pattern recognition of epileptiform events in EEG signals using Wavelet Scalograms. (P. and S. (ICBAPS) I. C. BioSignal Analysis, Ed.)Kuala Lumpur, 2015, p. 123–128.

MALLAT, S. **A Wavelet Tour of Signal Processing**. 3. ed. Burlington: Academic Press, 2008.

MALMIVUO, J.; PLONSEY, R. **Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields**. New York: Oxford University Press, 1995.

MEIER, R.; DITTRICH, H.; SCHULZE-BONHAGE, A.; AERTSEN, A. Detecting epileptic seizures in long-term human EEG: a new approach to automatic online and real-time detection and classification of polymorphic seizure patterns. **Journal of clinical neurophysiology : official publication of the American Electroencephalographic Society**, v. 25, n. 3, p. 119–31, jun. 2008.

MONTENEGRO, M. A.; FERNANDO CENDES; MARILISA M. GUERREIRO; CARLOS A. M. GUERREIRO. **EEG na prática clínica**. 1. ed. São Paulo: Revinter, 2001.

MORAES, F. D. DE; CALLEGARI, D. A. **Automated Detection of Interictal Spikes in EEG: A literature review**. Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, 2014.

MYATT, G. J.; JOHNSON, W. P. **Making Sense of Data II: A practical Guide to Data Visualization, Advanced Data Mining Methods, and Applications**. New Jersey: John Wiley & Sons, 2009.

NUNES, T. M.; COELHO, A. L. V; LIMA, C. A. M.; PAPA, J. P.; DE ALBUQUERQUE, V. H. C. EEG signal classification for epilepsy diagnosis via optimum path forest - A systematic assessment. **Neurocomputing**, v. 136, p. 103–123, 2014.

OCAK, H. Optimal classification of epileptic seizures in EEG using wavelet analysis and genetic algorithm. **Signal Processing**, v. 88, n. 7, p. 1858–1867, 2008.

OLIVEIRA, H. M. DE. **Análise de sinais para engenheiros: uma abordagem via Wavelets**. Rio de Janeiro: Brasport, 2007.

PANAYIOTOPOULOS, C. P. (ED.). **Atlas of Epilepsies**. London: Springer London, 2010.

RAJENDRA ACHARYA, U.; VINITHA SREE, S.; ALVIN, A. P. C.; SURI, J. S. Use of principal component analysis for automatic classification of epileptic EEG activities in wavelet framework. **Expert Systems with Applications**, v. 39, n. 10, p. 9072–9078, ago. 2012.

SANDER, J. W.; KEEZER, M. R. Epilepsy: Trends in new-onset epilepsy - the importance of comorbidities. **Nature reviews. Neurology**, v. 12, n. 5, p. 254–256, 2016.

SANEI, S.; CHAMBERS, J. A. **EEG Signal Processing**. 1. ed. West Sussex: John Wiley & Sons Ltd, 2007.

SCHOMER, D. L.; DA SILVA, F. L. (EDS.). **Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields**. 6. ed. Philadelphia: Lippincott Williams & Wilkins, 2011.

SCOLARO, G. R. **Classificação de eventos epileptiformes em sinais de eletroencefalografia utilizando classificador neural**. Universidade Federal de Santa Catarina, 2009.

SCOLARO, G. R. **Sistema computacional automatizado para a identificação e contagem de eventos epileptiformes em sinais de eletroencefalografia de longa duração.** Universidade Federal de Santa Catarina, 2014.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas.** 1. ed. São Paulo: Artliber, 2010.

SILVERTHORN, D. U. **Fisiologia Humana - Uma Abordagem Integrada.** 5. ed. São Paulo: Artmed, 2010.

SONG, Y.; ZHANG, J. Automatic recognition of epileptic EEG patterns via Extreme Learning Machine and multiresolution feature extraction. **Expert Systems with Applications**, v. 40, n. 14, p. 5477–5489, out. 2013.

SOON, W.; VELASCO HERRERA, V. M.; SELVARAJ, K.; TRAVERSI, R.; USOSKIN, I.; CHEN, C. T. A.; LOU, J. Y.; KAO, S. J.; CARTER, R. M.; PIPIN, V.; SEVERI, M.; BECAGLI, S. A review of Holocene solar-linked climatic variation on centennial to millennial timescales: Physical processes, interpretative frameworks and a new multiple cross-wavelet transform algorithm. **Earth-Science Reviews**, v. 134, p. 1–15, 2014.

STEPHENSON, J. B. P. **A Clinical Guide to Epileptic Syndromes and their Treatment.** 2. ed. London: Springer-Verlag London, 2010. v. 14,

SUBASI, A. EEG signal classification using wavelet feature extraction and a mixture of expert model. **Expert Systems with Applications**, v. 32, n. 4, p. 1084–1093, 2007.

SUBASI, A.; ERÇELEBI, E. Classification of EEG signals using neural network and logistic regression. **Computer methods and programs in biomedicine**, v. 78, n. 2, p. 87–99, maio 2005.

SUBASI, A. Epileptic seizure detection using dynamic wavelet network. **Expert Systems with Applications**, v. 29, n. 2, p. 343–355, ago. 2005.

SURESH, H. N.; BALASUBRAMANYAM, V. Wavelet Transforms and Neural Network Approach for Epileptical EEG. [s.l.]: IEEE International Advance Computing Conference (IACC), 2012, p. 12–17.

TORRENCE, C.; COMPO, G. P. A Practical Guide to Wavelet Analysis. **Bulletin of the American Meteorological Society**, v. 79, n. 1, p. 61–78, 1998.

TZALLAS, A. T.; TSIPOURAS, M. G.; TSALIKAKIS, D. G.; KARVOUNIS, E. C.; ASTRAKAS, L.; KONITSIOTIS, S.; TZAPHLIDOU, M. Automated Epileptic Seizure Detection Methods: A Review Study. In: STEVANOVIC, D. (Ed.). **Epilepsy - Histological, Electroencephalographic and Psychological Aspects**. 1. ed. Rijeka: InTech, 2012. p. 75–98.

ÜBEYLI, E. D. Wavelet/mixture of experts network structure for EEG signals classification. **Expert Systems with Applications**, v. 34, n. 3, p. 1954–1962, 2008.

ÜBEYLI, E. D. Combined neural network model employing wavelet coefficients for EEG signals classification. **Digital Signal Processing: A Review Journal**, v. 19, n. 2, p. 297–308, 2009.

WEBSTER, J. **Medical Instrumentation: Application and Design**. 4. ed. Hoboken: NJ: John Wiley & Sons, 2010.

WILSON, S. B.; EMERSON, R. Spike detection: a review and comparison of algorithms. **Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology**, v. 113, n. 12, p. 1873–81, dez. 2002.

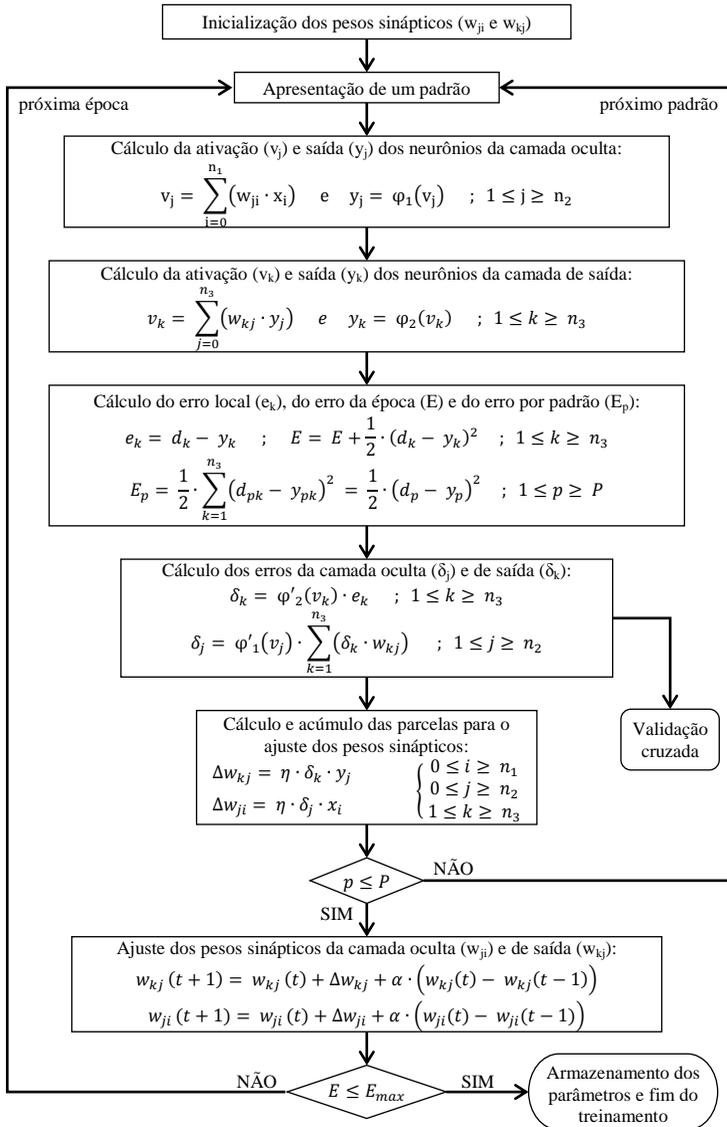
XIE, S.; KRISHNAN, S. Wavelet-based sparse functional linear model with applications to EEGs seizure detection and epilepsy diagnosis. **Medical and Biological Engineering and Computing**, v. 51, n. 1–2, p. 49–60, 2013.

YU, X.; YE, C.; XIANG, L. Application of Artificial Neural Network in the Diagnostic System of Osteoporosis. **Neurocomputing**, v. 3, p. 87–91, 2014.

ZANDI, A. S.; JAVIDAN, M.; DUMONT, G. A.; TAFRESHI, R. Automated Real-Time Epileptic Seizure Detection in Scalp EEG Recordings Using an Algorithm Based on Wavelet Packet Transform. **IEEE Transactions on Biomedical Engineering**, v. 57, n. 7, p. 1639–1651, 2010.

ZHANG, X.; ZHANG, S. Diffusion scheme using mean filter and wavelet coefficient magnitude for image denoising. **AEU - International Journal of Electronics and Communications**, v. 70, n. 7, p. 944–952, 2016.

Apêndice A – Fluxograma do processo de treinamento realizado nas redes neurais artificiais desenvolvidas



Apêndice B – Interface gráfica desenvolvida para os treinamentos e testes das redes neurais implementadas

Redes Neurais - treinamento e testes

Parâmetros de Configuração da Rede:

Número de Neurônios:

- » tipo de entrada: Banco de Filtrros
- » oculta: 10

Função de Ativação:

- » camada oculta: Tangente hiperbólica k = 0.1
- » camada de saída: Logística k = 0.1

Taxa de aprendizagem: 0.01

Constante de momento: 0.9

Critérios de parada:

- Erro mínimo (emq_epc): 0.001
- Nº máximo de épocas: 10000

Opções de ação:

Carregar Padrões Treino

Carregar Padrões Validação

Carregar Matriz Pesos

Parar Treinamento

TREINAR rede TESTAR rede

SALVAR rede SALVAR teste

Curva de Treinamento e Validação

Análise da rede (desempenho)

Threshold:

Qtd. padrões:

Resultado da análise do

VP	-	Sensibilidade	-
VN	-	Especificidade	-
FP	-	Eficiência	-
FN	-	VPP	-
FP/...	-	VPN	-

Analisar das... Eficiência ... PLOT

Analisar threshold

Apêndice C – Indicadores de desempenho do classificador neural utilizando banco de filtros

Família	Sens.^a	Espec.^b	Efic.^c	VP^d	VN^e	FP^f	FN^g	Limiar	Época
Bior 3.1	95,8506	95,7245	95,7704	231	403	18	10	0,99	4199
	96,2656	94,0618	94,8640	232	396	25	9	0,9	62
	92,9461	95,4869	94,5619	224	402	19	17	0,87	981
	94,1909	94,2993	94,2598	227	397	24	14	0,86	592
	91,7012	95,0119	93,8066	221	400	21	20	0,98	1637
	92,5311	92,1615	92,2961	223	388	33	18	0,95	50
	82,9876	96,9121	91,8429	200	408	13	41	0,94	79
	90,4564	92,3990	91,6918	218	389	32	23	0,98	612
	90,8714	91,9240	91,5408	219	387	34	22	0,98	418
	80,4979	96,4371	90,6344	194	406	15	47	0,98	68
	85,4772	92,6366	90,0302	206	390	31	35	0,98	1780
	99,5851	83,3729	89,2749	240	351	70	1	0,93	486
	91,2863	86,6983	88,3686	220	365	56	21	0,59	29
	84,2324	89,3112	87,4622	203	376	45	38	0,93	63
	83,4025	87,8860	86,2538	201	370	51	40	0,92	2533
	Bior 3.7	96,2656	95,4869	95,7704	232	402	19	9	0,98
95,8506		95,4869	95,6193	231	402	19	10	0,95	571
92,5311		96,9121	95,3172	223	408	13	18	0,93	331
95,0207		94,2993	94,5619	229	397	24	12	0,96	2000
90,8714		95,7245	93,9577	219	403	18	22	0,98	2478
95,8506		92,8741	93,9577	231	391	30	10	0,96	173
91,7012		95,0119	93,8066	221	400	21	20	0,95	5000
90,0415		95,0119	93,2024	217	400	21	24	0,95	1640
88,3817		95,7245	93,0514	213	403	18	28	0,96	5000
92,5311		90,7363	91,3897	223	382	39	18	0,92	3564
89,2116		92,6366	91,3897	215	390	31	26	0,92	235
92,5311		90,4988	91,2387	223	381	40	18	0,97	2905
97,0954		86,2233	90,1813	234	363	58	7	0,95	225
89,6266		90,2613	90,0302	216	380	41	25	0,93	879
90,4564		89,3112	89,7281	218	376	45	23	0,86	348
Bior 3.9		94,6058	95,9620	95,4683	228	404	17	13	0,96
	93,7759	95,9620	95,1662	226	404	17	15	0,95	1286
	95,0207	94,2993	94,5619	229	397	24	12	0,93	262
	91,2863	96,1995	94,4109	220	405	16	21	0,99	5000
	90,4564	95,9620	93,9577	218	404	17	23	0,96	1190
	89,2116	96,4371	93,8066	215	406	15	26	0,93	762
	90,4564	95,4869	93,6556	218	402	19	23	0,98	5000
	92,9461	93,8242	93,5045	224	395	26	17	0,96	5000
	92,9461	93,8242	93,5045	224	395	26	17	0,95	1567
	95,0207	90,9739	92,4471	229	383	38	12	0,95	722
	96,6805	88,1235	91,2387	233	371	50	8	0,98	4973
	90,4564	91,6865	91,2387	218	386	35	23	0,94	5000
	89,6266	90,7363	90,3323	216	382	39	25	0,89	749
	92,9461	86,6983	88,9728	224	365	56	17	0,98	2087
	97,0954	80,7601	86,7069	234	340	81	7	0,92	23

Família	Sens.^a	Espec.^b	Efic.^c	VP^d	VN^e	FP^f	FN^g	Limiar	Época
	90,0415	91,9240	91,2387	217	387	34	24	0,94	255
	87,9668	92,3990	90,7855	212	389	32	29	0,98	5000
	78,4232	96,9121	90,1813	189	408	13	52	0,95	878
	90,8714	88,8361	89,5770	219	374	47	22	0,95	543
	83,4025	90,9739	88,2175	201	383	38	40	0,96	5000
	95,4357	83,8480	88,0665	230	353	68	11	0,92	88
	89,6266	86,4608	87,6133	216	364	57	25	0,89	5000
Coif 1	73,4440	95,0119	87,1601	177	400	21	64	0,97	2630
	81,7427	89,7862	86,8580	197	378	43	44	0,95	550
	84,6473	87,4109	86,4048	204	368	53	37	0,95	619
	89,2116	84,7981	86,4048	215	357	64	26	0,94	5000
	88,7967	83,6105	85,4985	214	352	69	27	0,93	146
	91,2863	80,7601	84,5921	220	340	81	21	0,95	5000
	98,7552	76,0095	84,2900	238	320	101	3	0,95	5000
	95,8506	76,2470	83,3837	231	321	100	10	0,87	678
	92,9461	95,7245	94,7130	224	403	18	17	0,96	2861
	89,6266	96,9121	94,2598	216	408	13	25	0,98	5000
	91,2863	95,4869	93,9577	220	402	19	21	0,97	3277
	90,0415	96,1995	93,9577	217	405	16	24	0,98	5000
	90,8714	95,4869	93,8066	219	402	19	22	0,98	5000
	89,2116	95,9620	93,5045	215	404	17	26	0,98	5000
	92,5311	94,0618	93,5045	223	396	25	18	0,95	3486
Coif 4	90,8714	95,0119	93,5045	219	400	21	22	0,96	2513
	92,5311	93,8242	93,3535	223	395	26	18	0,95	1396
	92,1162	93,8242	93,2024	222	395	26	19	0,97	5000
	90,0415	95,0119	93,2024	217	400	21	24	0,96	3054
	92,1162	93,8242	93,2024	222	395	26	19	0,97	5000
	89,2116	95,2494	93,0514	215	401	20	26	0,97	5000
	98,7552	89,0736	92,5982	238	375	46	3	0,98	2630
	91,2863	92,6366	92,1450	220	390	31	21	0,97	5000
	98,3402	91,6865	94,1088	231	386	35	4	0,94	220
	98,7552	90,9739	93,8066	238	383	38	3	0,98	3623
	98,3402	90,9739	93,6556	237	383	38	4	0,97	2828
	95,8506	92,1615	93,5045	231	388	33	10	0,94	169
	97,9253	90,9739	93,5045	236	383	38	5	0,94	482
	99,5851	89,5487	93,2024	240	377	44	1	0,96	294
	95,8506	91,6865	93,2024	231	386	35	10	0,98	1571
Db 4	89,2116	95,4869	93,2024	215	402	19	26	0,98	3968
	90,8714	94,0618	92,9003	219	396	25	22	0,96	1264
	97,5104	90,0238	92,7492	235	379	42	6	0,94	1137
	94,1909	89,3112	91,0876	227	376	45	14	0,97	903
	99,1701	85,0356	90,1813	239	358	63	2	0,97	3266
	94,1909	87,6485	90,0302	227	369	52	14	0,84	5000
	98,7552	83,1354	88,8218	238	350	71	3	0,9	32
	95,0207	80,9976	86,1027	229	341	80	12	0,97	1982

Família	Sens.^a	Espec.^b	Efic.^c	VP^d	VN^e	FP^f	FN^g	Limiar	Época
Rbio 1.3	92,9461	95,7245	94,7130	224	403	18	17	0,97	5000
	94,1909	94,7743	94,5619	227	399	22	14	0,96	5000
	92,1162	95,2494	94,1088	222	401	20	19	0,97	5000
	92,5311	94,5368	93,8066	223	398	23	18	0,97	5000
	93,3610	93,5867	93,5045	225	394	27	16	0,97	2883
	94,6058	92,3990	93,2024	228	389	32	13	0,97	5000
	92,5311	92,8741	92,7492	223	391	30	18	0,96	5000
	97,0954	90,0238	92,5982	234	379	42	7	0,93	5000
	92,1162	92,8741	92,5982	222	391	30	19	0,97	5000
	85,0622	95,9620	91,9940	205	404	17	36	0,95	1571
	85,0622	95,9620	91,9940	205	404	17	36	0,95	1571
	90,0415	91,9240	91,2387	217	387	34	24	0,95	2251
	95,4357	88,3610	90,9366	230	372	49	11	0,96	640
	97,5104	73,3967	82,1752	235	309	112	6	0,91	82
70,9544	85,5107	80,2115	171	360	61	70	0,94	851	
Rbio 1.5	90,8714	96,9121	94,7130	219	408	13	22	0,97	4568
	90,4564	97,1496	94,7130	218	409	12	23	0,99	5000
	93,3610	95,2494	94,5619	225	401	20	16	0,94	3044
	92,1162	95,9620	94,5619	222	404	17	19	0,95	755
	91,7012	95,9620	94,4109	221	404	17	20	0,97	4225
	90,4564	96,4371	94,2598	218	406	15	23	0,97	5000
	90,4564	96,4371	94,2598	218	406	15	23	0,97	5000
	91,7012	95,7245	94,2598	221	403	18	20	0,94	1539
	90,4564	94,5368	93,0514	218	398	23	23	0,91	4321
	87,5519	96,1995	93,0514	211	405	16	30	0,96	817
	95,4357	90,7363	92,4471	230	382	39	11	0,94	168
	89,6266	94,0618	92,4471	216	396	25	25	0,92	2508
	86,3071	95,0119	91,8429	208	400	21	33	0,98	5000
	94,6058	87,8860	90,3323	228	370	51	13	0,95	290
96,6805	81,7102	87,1601	233	344	77	8	0,97	489	
Rbio 2.8	93,36	92,87	93,05	225	391	30	16	0,99	5000
	90,04	93,35	92,15	217	393	28	24	0,98	5000
	95,44	89,31	91,54	230	376	45	11	0,94	938
	92,12	90,50	91,09	222	381	40	19	0,98	5000
	93,36	89,79	91,09	225	378	43	16	0,96	3458
	92,12	90,50	91,09	222	381	40	19	0,98	5000
	93,36	89,55	90,94	225	377	44	16	0,98	4640
	87,14	93,11	90,94	210	392	29	31	0,98	5000
	92,95	89,31	90,63	224	376	45	17	0,89	3978
	90,04	90,74	90,48	217	382	39	24	0,92	114
	85,06	92,64	89,88	205	390	31	36	0,91	127
	88,80	90,50	89,88	214	381	40	27	0,97	2710
	90,46	89,31	89,73	218	376	45	23	0,99	4145
	82,57	93,82	89,73	199	395	26	42	0,94	938

^a Sensibilidade.

^b Especificidade.

^c Eficiência.

^d Verdadeiros Positivos.

^e Verdadeiros Negativos.

^f Falsos Positivos.

^g Falsos Negativos.

Apêndice D – Indicadores de desempenho do classificador neural utilizando escalograma

Família	Limiar	Época	VP^d	VN^e	FP^f	FN^g	Sens.^a	Espec.^b	Efic.^c
Bior 3.1	0,92	1061	227	398	23	14	94,1909	94,5368	94,4109
	0,95	3396	225	400	21	16	93,3610	95,0119	94,4109
	0,89	971	228	397	24	13	94,6058	94,2993	94,4109
	0,91	105	227	398	23	14	94,1909	94,5368	94,4109
	0,92	270	227	398	23	14	94,1909	94,5368	94,4109
	0,95	301	225	399	22	16	93,3610	94,7743	94,2598
	0,91	2548	227	397	24	14	94,1909	94,2993	94,2598
	0,95	1010	225	399	22	16	93,3610	94,7743	94,2598
	0,95	347	225	399	22	16	93,3610	94,7743	94,2598
	0,95	2518	224	398	23	17	92,9461	94,5368	93,9577
	0,95	457	224	398	23	17	92,9461	94,5368	93,9577
	0,98	159	225	397	24	16	93,3610	94,2993	93,9577
	0,98	320	224	396	25	17	92,9461	94,0618	93,6556
	0,99	17	214	395	26	27	88,7967	93,8242	91,9940
0,91	13	234	362	59	7	97,0954	85,9857	90,0302	
Bior 3.7	0,82	594	222	389	32	19	92,1162	92,3990	92,2961
	0,81	547	223	388	33	18	92,5311	92,1615	92,2961
	0,82	55	221	390	31	20	91,7012	92,6366	92,2961
	0,82	70	221	390	31	20	91,7012	92,6366	92,2961
	0,83	305	221	389	32	20	91,7012	92,3990	92,1450
	0,83	510	221	389	32	20	91,7012	92,3990	92,1450
	0,83	51	221	389	32	20	91,7012	92,3990	92,1450
	0,85	986	219	390	31	22	90,8714	92,6366	91,9940
	0,95	96	218	391	30	23	90,4564	92,8741	91,9940
	0,87	58	228	381	40	13	94,6058	90,4988	91,9940
	0,95	6	224	383	38	17	92,9461	90,9739	91,6918
	0,89	57	223	380	41	18	92,5311	90,2613	91,0876
	0,87	643	224	378	43	17	92,9461	89,7862	90,9366
	0,86	531	224	378	43	17	92,9461	89,7862	90,9366
0,99	7	224	363	58	17	92,9461	86,2233	88,6707	
Bior 3.9	0,89	49	208	402	19	33	86,3071	95,4869	92,1450
	0,9	42	208	402	19	33	86,3071	95,4869	92,1450
	0,89	63	208	402	19	33	86,3071	95,4869	92,1450
	0,93	24	217	392	29	24	90,0415	93,1116	91,9940
	0,81	281	222	386	35	19	92,1162	91,6865	91,8429
	0,81	75	222	386	35	19	92,1162	91,6865	91,8429
	0,81	47	223	385	36	18	92,5311	91,4489	91,8429
	0,81	467	221	386	35	20	91,7012	91,6865	91,6918
	0,83	323	218	389	32	23	90,4564	92,3990	91,6918
	0,99	24	222	384	37	19	92,1162	91,2114	91,5408
	0,83	243	221	384	37	20	91,7012	91,2114	91,3897
	0,96	19	229	376	45	12	95,0207	89,3112	91,3897
	0,86	23	216	389	32	25	89,6266	92,3990	91,3897
	0,86	523	224	374	47	17	92,9461	88,8361	90,3323
0,98	77	232	365	56	9	96,2656	86,6983	90,1813	

Familia	Limiar	Época	VP ^d	VN ^e	FP ^f	FN ^g	Sens. ^a	Espec. ^b	Efic. ^c
Coif 1	0,87	309	218	389	32	23	90,4564	92,3990	91,6918
	0,87	154	221	385	36	20	91,7012	91,4489	91,5408
	0,84	477	220	386	35	21	91,2863	91,6865	91,5408
	0,86	1407	218	388	33	23	90,4564	92,1615	91,5408
	0,86	1965	218	388	33	23	90,4564	92,1615	91,5408
	0,86	2525	218	388	33	23	90,4564	92,1615	91,5408
	0,86	255	218	388	33	23	90,4564	92,1615	91,5408
	0,86	381	216	389	32	25	89,6266	92,3990	91,3897
	0,83	5000	211	394	27	30	87,5519	93,5867	91,3897
	0,97	68	217	388	33	24	90,0415	92,1615	91,3897
	0,9	142	216	387	34	25	89,6266	91,9240	91,0876
	0,87	1180	216	386	35	25	89,6266	91,6865	90,9366
	0,87	989	214	386	35	27	88,7967	91,6865	90,6344
	0,99	52	224	362	59	17	92,9461	85,9857	88,5196
	0,96	716	219	348	73	22	90,8714	82,6603	85,6495
Coif 4	0,99	24	225	383	38	16	93,3610	90,9739	91,8429
	0,85	95	214	392	29	27	88,7967	93,1116	91,5408
	0,79	117	222	384	37	19	92,1162	91,2114	91,5408
	0,77	200	223	383	38	18	92,5311	90,9739	91,5408
	0,93	23	217	388	33	24	90,0415	92,1615	91,3897
	0,79	945	219	385	36	22	90,8714	91,4489	91,2387
	0,83	89	217	387	34	24	90,0415	91,9240	91,2387
	0,84	852	214	390	31	27	88,7967	92,6366	91,2387
	0,79	171	219	385	36	22	90,8714	91,4489	91,2387
	0,98	36	229	374	47	12	95,0207	88,8361	91,0876
	0,85	84	214	389	32	27	88,7967	92,3990	91,0876
	0,86	76	214	388	33	27	88,7967	92,1615	90,9366
	0,86	56	215	383	38	26	89,2116	90,9739	90,3323
	0,87	732	212	386	35	29	87,9668	91,6865	90,3323
	0,87	2439	212	386	35	29	87,9668	91,6865	90,3323
Db 4	0,8	183	219	383	38	22	90,8714	90,9739	90,9366
	0,8	353	219	381	40	22	90,8714	90,4988	90,6344
	0,81	270	217	383	38	24	90,0415	90,9739	90,6344
	0,8	1745	219	381	40	22	90,8714	90,4988	90,6344
	0,8	140	219	381	40	22	90,8714	90,4988	90,6344
	0,8	1385	219	381	40	22	90,8714	90,4988	90,6344
	0,8	3466	219	381	40	22	90,8714	90,4988	90,6344
	0,8	274	217	382	39	24	90,0415	90,7363	90,4834
	0,82	79	211	387	34	30	87,5519	91,9240	90,3323
	0,82	482	211	387	34	30	87,5519	91,9240	90,3323
	0,81	159	209	389	32	32	86,7220	92,3990	90,3323
	0,8	525	220	378	43	21	91,2863	89,7862	90,3323
	0,98	27	215	383	38	26	89,2116	90,9739	90,3323
	0,82	341	206	390	31	35	85,4772	92,6366	90,0302
	0,82	611	206	390	31	35	85,4772	92,6366	90,0302

Família	Limiar	Época	VP ^d	VN ^e	FP ^f	FN ^g	Sens. ^a	Espec. ^b	Efic. ^c
Rbio 1.3	0,98	47	232	388	33	9	96,2656	92,1615	93,6556
	0,98	50	232	388	33	9	96,2656	92,1615	93,6556
	0,91	60	231	389	32	10	95,8506	92,3990	93,6556
	0,79	31	234	384	37	7	97,0954	91,2114	93,3535
	0,98	55	230	388	33	11	95,4357	92,1615	93,3535
	0,84	103	222	393	28	19	92,1162	93,3492	92,9003
	0,87	111	218	397	24	23	90,4564	94,2993	92,9003
	0,81	883	222	393	28	19	92,1162	93,3492	92,9003
	0,77	125	224	390	31	17	92,9461	92,6366	92,7492
	0,76	437	224	390	31	17	92,9461	92,6366	92,7492
	0,79	89	223	391	30	18	92,5311	92,8741	92,7492
	0,77	63	224	390	31	17	92,9461	92,6366	92,7492
	0,76	80	224	390	31	17	92,9461	92,6366	92,7492
	0,82	55	219	395	26	22	90,8714	93,8242	92,7492
0,87	4599	218	394	27	23	90,4564	93,5867	92,4471	
Rbio 1.5	0,98	34	234	394	27	7	97,0954	93,5867	94,8640
	0,98	39	233	392	29	8	96,6805	93,1116	94,4109
	0,97	44	233	390	31	8	96,6805	92,6366	94,1088
	0,94	61	227	393	28	14	94,1909	93,3492	93,6556
	0,82	105	226	393	28	15	93,7759	93,3492	93,5045
	0,84	126	222	397	24	19	92,1162	94,2993	93,5045
	0,82	1065	221	397	24	20	91,7012	94,2993	93,3535
	0,79	80	226	392	29	15	93,7759	93,1116	93,3535
	0,82	96	221	397	24	20	91,7012	94,2993	93,3535
	0,8	55	223	394	27	18	92,5311	93,5867	93,2024
	0,77	83	226	391	30	15	93,7759	92,8741	93,2024
	0,83	304	222	394	27	19	92,1162	93,5867	93,0514
	0,88	482	217	397	24	24	90,0415	94,2993	92,7492
	0,89	618	216	396	25	25	89,6266	94,0618	92,4471
0,99	9	213	384	37	28	88,3817	91,2114	90,1813	
Rbio 2.8	0,84	271	221	390	31	20	91,7012	92,6366	92,2961
	0,98	68	216	394	27	25	89,6266	93,5867	92,1450
	0,84	82	221	389	32	20	91,7012	92,3990	92,1450
	0,85	159	220	389	32	21	91,2863	92,3990	91,9940
	0,99	41	215	394	27	26	89,2116	93,5867	91,9940
	0,83	514	221	388	33	20	91,7012	92,1615	91,9940
	0,83	228	220	388	33	21	91,2863	92,1615	91,8429
	0,99	35	221	387	34	20	91,7012	91,9240	91,8429
	0,87	133	217	388	33	24	90,0415	92,1615	91,3897
	0,87	561	213	392	29	28	88,3817	93,1116	91,3897
	0,91	110	213	391	30	28	88,3817	92,8741	91,2387
	0,88	94	216	386	35	25	89,6266	91,6865	90,9366
	0,99	30	230	370	51	11	95,4357	87,8860	90,6344
	0,93	16	231	366	55	10	95,8506	86,9359	90,1813

^a Sensibilidade.

^b Especificidade.

^c Eficiência.

^d Verdadeiros Positivos.

^e Verdadeiros Negativos.

^f Falsos Positivos.

^g Falsos Negativos.

Anexo A – Parecer consubstanciado do Comitê de Ética em Pesquisa com Seres Humanos

UNIVERSIDADE FEDERAL DE
SANTA CATARINA - UFSC



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Sistema Inteligente para processar padrões epileptiformes em sinais de EEG de longa duração.

Pesquisador: Fernando Mendes de Azevedo

Área Temática:

Versão: 4

CAAE: 17045713.5.0000.0121

Instituição Proponente: UNIVERSIDADE FEDERAL DE SANTA CATARINA

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 1.183.201

Data da Relatoria: 10/08/2015

Apresentação do Projeto:

"Sistema Inteligente para processar padrões epileptiformes em sinais de EEG de longa duração". Pesquisa que visa desenvolver um Sistema Computacional para a automatização do processamento, detecção, marcação e contagem de eventos epileptiformes em sinais de EEG de longa duração. Para isso, os dados serão primeiramente tratados através de técnicas de Processamento Digital de Sinais, em seguida serão analisados para a identificação de possíveis padrões de interesse e por fim serão padrões presentes nos segmentos de sinais de EEG analisados serão classificados através de ferramentas de Inteligência Computacional.

Objetivo da Pesquisa:

Não se aplica.

Avaliação dos Riscos e Benefícios:

Não se aplica.

Comentários e Considerações sobre a Pesquisa:

Trata o presente da segunda Emenda do projeto de pesquisa "Sistema Inteligente para processar padrões epileptiformes em sinais de EEG de longa duração" na qual o Coordenador comunica a inclusão de mais pesquisadores na equipe: a neurologista Dra. Aline Vieira Scarlattelli Lima e mais três alunos do Programa de Pós-Graduação em Engenharia Elétrica, todos doutores em Engenharia

Endereço: Universidade Federal de Santa Catarina, Prédio Reitoria II (Edifício Santa Clara), R: Desembargador Vitor Lima,
Bairro: Trindade **CEP:** 88.040-400
UF: SC **Município:** FLORIANOPOLIS
Telefone: (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

UNIVERSIDADE FEDERAL DE
SANTA CATARINA - UFSC



Continuação do Parecer: 1.183.201

Biomédica. Diante do exposto, recomendamos a sua aprovação.

Considerações sobre os Termos de apresentação obrigatória:

Não se aplica.

Recomendações:

Não se aplica.

Conclusões ou Pendências e Lista de Inadequações:

Não se aplica.

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

Considerações Finais a critério do CEP:

FLORIANOPOLIS, 13 de Agosto de 2015

Assinado por:
Washington Portela de Souza
(Coordenador)

Endereço: Universidade Federal de Santa Catarina, Prédio Reitoria II (Edifício Santa Clara), R: Desembargador Vitor Lima,
Bairro: Trindade **CEP:** 88.040-400
UF: SC **Município:** FLORIANOPOLIS
Telefone: (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br



MINISTÉRIO DA SAÚDE - Conselho Nacional de Saúde - Comissão Nacional de Ética em Pesquisa – CONEP

PROJETO DE PESQUISA ENVOLVENDO SERES HUMANOS

Projeto de Pesquisa: Sistema Inteligente para processar padrões epileptiformes em sinais de EEG de longa duração.

Informações Preliminares

Responsável Principal

CPF: 06166695268	Nome: Fernando Mendes de Azevedo
Telefone: (48) 3721-8757	E-mail: fmazevedo2012@gmail.com

Instituição Proponente

CNPJ: 83.899.526/0004-25	Nome da Instituição: UNIVERSIDADE FEDERAL DE SANTA CATARINA
--------------------------	---

Essa submissão de emenda é exclusiva do seu Centro Coordenador?

A emenda é exclusiva de seu Centro Coordenador, então as alterações realizadas em seu projeto, em virtude da emenda, NÃO serão replicadas nos Centros Participantes vinculados e nos Comitês de Ética das Instituições Coparticipantes, quando da sua aprovação.

É um estudo internacional? Não

Assistentes

CPF	Nome
052.120.359-70	Christine Boos

Equipe de Pesquisa

CPF	Nome
05212035970	Christine Boos
00352204907	GEOVANI RODRIGO SCOLARO
01299375685	Aline Vieira Scarfatelli Lima
00412441926	Katia Lin
24618218878	lucia sukys claudino
06844486960	Mayara de Sousa
57570507991	Roger Walz
02785272056	Eduarda Rosado de Almeida
38121909821	Thais Carolina de Araújo

Área de Estudo
Grandes Áreas do Conhecimento (CNPq)

- Grande Área 3. Engenharias

Título Público da Pesquisa: Sistema Inteligente para processar padrões epileptiformes em sinais de EEG de longa duração.

Contato Público

CPF	Nome	Telefone	E-mail
06166695268	Fernando Mendes de Azevedo	(48) 3721-8757	fmazevedo2012@gmail.com

Contato Fernando Mendes de Azevedo

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica, Departamento de Engenharia Elétrica e Eletrônica, do Centro Tecnológico da Universidade Federal de Santa Catarina, como requisito para obtenção do Título de Mestre em Engenharia Elétrica

Orientador: Fernando Mendes de Azevedo, Dr.Sc.

Florianópolis, 2016