

Estudo comparativo de sistemas de detecção automática de epilepsia utilizando duas famílias wavelet, Coiflets e Daubechies, e redes neurais artificiais

Fábio J. Parreira¹, Keiji Yamanaka¹, J. B. Destro-Filho¹, Ângela A. de Sá¹, Agnaldo Bertucci², Eduardo Lázaro Martins Naves¹, Guilherme Bernadino¹, Kety Rosa de Barros¹

¹Laboratório de Engenharia Biomédica - Universidade Federal de Uberlândia, Campus Santa Mônica – 38408-100Uberlândia, MG

²Faculdade de Medicina -- Universidade Federal de Uberlândia, Campus Umuarama -- 38400-902 Uberlândia, MG

fabiojparreira@yahoo.com.br, keiji@ufu.br, jbdestrof@yahoo.com

Resumo

Esse trabalho apresenta um estudo comparativo de sistemas de detecção de crises epiléticas baseados na aplicação das Wavelet mães, Coiflet e Daubechies, mais populares em EEG, juntamente com as redes neurais artificiais para a detecção de padrões epiléticos. Esse sistema é composto de quatro etapas: construção da base de dados; janelamento e extração de características, detecção dos eventos epiléticos, e tomada de decisão, onde os eventos são classificados como crise, não crise ou indefinido. No janelamento foi utilizada a janela retangular; para a extração das características utilizou-se a wavelet (considerando apenas duas faixas de frequências), e na etapa de detecção foram empregadas as redes neurais artificiais e, o sistema especialista foi composto por um conjunto de regras heurísticas. Mostra-se que o sistema baseado em Daubechies gerou os melhores resultados.

Abstract

This research work presents a comparative study on epileptic crises detection systems, using two Wavelet mothers (Coiflet and Daubechies), more popular in EEG, together with the application of different neural networks. The proposed system is composed of four stages: Formation of the database, windowing and extraction of characteristics, detection of the epileptics events, and decision making, where the events are classified as crisis, no crisis or indefinite. In the

windowing the rectangular window was used to extract the characteristics it was just used the wavelet (which considers only two bands of frequencies), and in the detection stage a neural network was used, and the specialist system was composed by heuristic rules. It is shown that the proposed epileptic crises detection system based on Daubechies can generate satisfactory results.

1. Introdução

O eletroencefalograma (EEG) é definido como sendo a principal medida da atividade elétrica do cérebro em diferentes regiões da cabeça [1]. Geralmente a classificação dos padrões em EEG correlacionados com funções normais ou patológicas do sistema nervoso central é baseada na experiência médica, assumindo um caráter empírico.

Os sistemas para detecção de ataques epiléticos automáticos fornecem informações para os profissionais responsáveis (Médicos, enfermeiros, etc) e para o próprio paciente sobre o início da crise [2], auxiliando no reconhecimento desse padrão patológico.

Diversas ferramentas computacionais foram utilizadas para detecção durante os últimos 10 anos. Os métodos mais tradicionais utilizam a análise espectral do sinal [12], que consiste na aplicação direta da transformada de Fourier (FFT), obtendo resoluções no domínio da frequência, mas todas as descrições temporais do sinal são perdidas. Devido à necessidade de obtenção de informações no tempo, pesquisadores começaram a

trabalhar com a Transformada de Fourier de curto termo (SFFT) [7]. Essa transformada trabalha com pequenas janelas de tamanho fixo, obtendo boas resoluções no tempo, mas em contra partida, ocasiona uma perda na resolução da frequência. Atualmente, a grande maioria dos pesquisadores estão empregando a transformada Wavelet (WT) [8], que oferece resoluções tanto na frequência quanto no tempo.

Kalayci et al.[15], utilizou a wavelet mãe Daubechies(daub4) para extrair as características dos sinais EEG utilizando uma rede neural do tipo perceptron feed forward para detecção dos padrões epiléticos. A rede neural foi treinada para detectar espículas e EEG normal. Neste trabalho foi utilizada uma base de dados formada por EEG não invasivo que possui 16 canais, sendo captada de quatro pacientes com janelamento 512 pontos, a taxa de acerto corresponde a 84.3% e a taxa de erro 15.7%. Szilágyi et al.[16], utilizou a wavelet mãe Daubechies(daub4) para decompor o sinal em níveis dos respectivos padrões predominantes (delta, teta, alfa e beta), esses níveis de sinais são inseridos na entrada de uma rede neural do tipo back propagation feed forward, com três saídas. A base de dados é formada por EEG invasivo, sendo utilizado um janelamento de 100 pontos e a taxa de acerto neste trabalho corresponde a 95.0% e a taxa de erro 5.0%. Hulata et al.[17] utiliza um método para detecção de espículas embasando na transformada wavelet e na teoria da informação de Shannon para extração de características. Como estratégia de detecção utiliza a distância euclidiana dos K centros. A base de dados possui 400 amostras contendo espículas e 400 contendo ruídos, com janelamento 128 pontos, a taxa das amostras que foram classificadas como sendo verdadeiros positivos corresponde a 66.0% e a taxa dos verdadeiros negativos corresponde a 87.0%. Subasia et al.[18] utiliza a wavelet para extrair as características em bandas de frequência (delta, teta, alfa e beta) utilizando como estratégia de detecção apenas uma única rede neural(MLP) com 4 entradas e uma saída, que foi treinada para detectar eventos epiléticos. A base de dados é composta de EEG não invasivo, possuindo 4 canais. Para o treinamento foram utilizados 300 conjuntos epiléticos e não epiléticos, para a etapa de teste foram utilizados 200 conjuntos epiléticos e não epiléticos, a taxa de acerto corresponde a 91.3% e a taxa de erro em 8.7%. Pereira [11] utiliza wavelet mãe coiflet (coif1) para extrair as características do sinal decomposto em 4 sub-bandas, empregando quatro redes neurais e um sistema especialista para detecção. A base de dados utilizada é composta de EEG não invasivo, a taxa de acerto corresponde a 87.9% e a taxa de erro em 12.1%.

A maioria dos trabalhos citados utiliza basicamente um dos dois tipos de wavelet mãe (Coiflet ou Daubechies), além de subdividir o sinal EEG em quatro faixas de frequências. Embora esta divisão seja coerente com a realidade neurológica, ela acarreta um elevado custo computacional do sistema de detecção, além de tornar o desempenho do sistema muito elevado para certo conjunto de dados.

O objetivo deste trabalho é apresentar um método para detecção de crises epiléticas utilizando as transformadas Wavelet mãe daubechies (daub4) e coiflet (coif1) para extrair as características do sinal EEG, onde o sinal é decomposto em apenas duas sub-bandas. Para cada sub-banda tem-se uma rede neural com apenas uma saída que é responsável em realizar o reconhecimento automático dos estados epiléticos. As saídas das redes são utilizadas para alimentar um sistema especialista composto de regras heurísticas que dará a resposta final sobre o segmento analisado, como mostra a figura 2. Além de oferecer resultados comparativos entre as duas Wavelet mãe, que serão testadas com tipos diferentes de algoritmos de treinamento.

2. Embasamento teórico

2.1. O EEG

O psiquiatra alemão Hans Berger é considerado o pai da eletroencefalografia humana, tendo iniciado os seus estudos experimentais em animais em 1902. Realizou em 1924 o primeiro registro de oscilações rítmicas em cérebro humano, utilizando um galvanômetro de corda. Berger identificou dois tipos de ondas cerebrais e as nomeou Alfa (cerca de 10 Hz) e Beta (20 a 30 Hz) [3]. Em 1934, Berger demonstra, publicamente, a existência das ondas Alfa, ele também desenvolveu métodos de registros e estudos sobre as alterações do traçado EEG.

O EEG foi desde então usado como ferramenta para diagnóstico clínico e pesquisa, servindo para avaliar e quantificar as ondas provenientes do cérebro [3]. No método clínico convencional a observação das formas de onda é bastante subjetiva e difícil, porque os resultados dependem da experiência e da habilidade dos responsáveis [4]. O desenvolvimento do EEG quantitativo (qEEG) resultou na obtenção de medidas objetivas, automatizando parte do processo. O qEEG também auxilia no entendimento das atividades elétricas do cérebro e suas funções [7].

Atualmente, as relações do mecanismo funcional do cérebro, juntamente com as oscilações das atividades eletroencefalográficas (EEG) estão sendo muito

discutidas, objetivando investigar as oscilações de sincronização elétrica durante os estados patológicos ou fisiológicos do cérebro (por exemplo: ataques epilépticos, as fases do sono, etc.), ou até mesmo para verificar estímulos externo ou interno. Para estudar essa relação são aplicados métodos de análises em sinais EEG com o objetivo de localizar as mudanças das atividades que acontecem em uma relação temporal, de acordo com o surgimento dos eventos, que corresponde à transição dos estados no cérebro: ordem ou desordem [5].

O EEG pode ser considerado como uma reflexão da atividade dos conjuntos geradores que produzem oscilações em várias faixas de frequência, resultando em atividades muito complexas. Esta transição de um estado de desordem para um ordenado é acompanhado por um fenômeno de ressonância e estabilização de frequência, sincronização, e intensificação da atividade no EEG, produzindo potenciais no cérebro de acordo com cada evento relacionado [6]

2.2. Transformada Wavelet

Nos últimos anos, pesquisadores de matemática aplicada e processamento de sinais desenvolveram várias a transformadas wavelet (WT) bastantes poderosos que representam o sinal em várias bandas [8], [9]. Estas ferramentas diferem da técnica de Fourier tradicional no sentido da localização das informações no plano tempo-frequência. Na engenharia biomédica, essas propriedades da WT foram aplicadas com grande relevância, essa aplicabilidade é justificável devido a grande variedade de sinais juntamente com os problemas encontrados na medicina e na biologia.

As informações de interesse em um sinal biomédico é, frequentemente, uma combinação das características que estão localizadas no tempo (temporal) e no espaço (espacial). Para localizar essas informações é requerido o uso de métodos de análise suficientemente versátil, que controle eventos cuja sua representação exija uma resolução tempo-frequência, para essa exigência a WT se ajusta perfeitamente [10].

A WT representada na equação 1, consiste em um tipo de representação tempo-frequência de um sinal, que utiliza um conjunto de funções ortogonais de janelamento com larguras variadas. Deve-se definir uma função wavelet básica (wavelet mãe) a partir da qual, todas as outras serão derivadas através dos processos de dilatação ou escalonamento e translação [11], [10].

$$W T a \tau [f(t)] = \int_{-\infty}^{+\infty} f(t) \psi_{a\tau}^*(t) dt$$

Equação 1.

Onde:

$f(t)$: Sinal discreto no tempo a ser analisado;

$\psi^*(t)$: Complexo conjugado da wavelet mãe;

$\psi(t)$: Janela de tempo, a partir da qual as outras funções são obtidas, por meio de translações e rotações, como mostra a equação 2.

$$\psi_{a\tau}(t) = \frac{1}{\sqrt{a}} \psi \left[\frac{t - \tau}{a} \right]$$

Equação 2.

Onde:

$\frac{1}{\sqrt{a}}$: Constante de normalização da energia para as wavelets;

τ : Fator de translação;

a : Fator de dilatação.

Existem vários tipos de Wavelet mãe definidas, as mais utilizadas para processar sinais eletroencefalográficos, de acordo com os autores [1], [10],[11],[12],[13], é a Coiflet, como mostra na figura 1, e Daubechies, como mostra na figura 2, sendo assim, o estudo comparativo será realizado entre essas duas famílias.




Figura 1: Coiflet.




Figura 2: Daubechies.

3. Metodologia

A estratégia utilizada para extrair as características do sinal, processar e classificar estão representadas na figura 3, a metodologia empregada é dividida em

quatro etapas: Base de dados, processamento do sinal, detecção de crise ou artefatos e sistema especialista.




Figura 3: Metodologia.

3.1. Base de dados

Neste trabalho os sinais de EEG utilizados para validar a pesquisa foram previamente classificados em suas respectivas patologias. A base de dados criada contém as seguintes características: descargas epiléticas provocada por tumores, descargas irregulares de epilepsia, crises com artefato EMG (Eletromiografia) e crises psicomotoras.

Os sinais de EEG foram adquiridos a 200Hz, contendo quatro canais: F7-C3, F8-C4, T5-O1 e T6-O2, com eletrodos posicionados no escalpo. Os canais foram separados em segmentos de 1 segundo, como mostra a figura 4.




Figura 4: Janelamento do sinal.

Essa segmentação foi feita de forma a manter em cada segmento as características necessárias para detecção de crises epiléticas, visto que os períodos de EEG patológicos geralmente possuem espículas com duração entre 20 a 70 milissegundos e ondas agudas que varia entre 70 a 200 milissegundos [3]. Portanto, 1 segundo de janelamento do sinal fornece sem problema as características para identificação dos padrões epileptogênicos. Os sinais foram divididos em dois grupos: Treinamento e teste.

O conjunto de treinamento é formado por trechos que contêm eventos epileptiformes, ruídos e sinais normais. O total de trechos de EEG utilizados foram 781 segmentos, para o treinamento utilizou 348 segmentos, correspondendo a 60% de todos os sinais utilizados. Para o conjunto de teste utilizou 233 segmentos, sendo estes segmentos de sinais diferentes do conjunto de treinamento, contendo eventos

epileptiformes, ruídos e sinais normais, correspondendo a 40% de todos os sinais utilizados.

3.2. Extração de características

Na etapa de processamento do sinal é aplicada uma janela de 200 pontos, nos segmentos obtidos na etapa da construção da base de dados, visando melhorar a classificação dos eventos através da rede neural, a janela utilizada é a retangular. Para extrair as características de forma significativa utilizou a transformada wavelet (WT), o sistema foi testado com dois tipos diferentes: Coiflets como mostra na figura 1, e Daubechies como mostra na figura 2.

A WT consegue detectar as alterações do sinal e fornece informações tanto no domínio da frequência quanto no tempo, resultando na detecção de transição entre os períodos: Preictal, ictal e posictal.

A transformada Wavelet decompõe o sinal S , em N níveis como mostra a figura 5.




Figura 5: Decomposição do sinal.

Neste trabalho foi utilizado os níveis de detalhe 1 (cD1) e detalhe 3 (cD3), tanto para a Coiflet, como para a Daubechies. O cD1 foi utilizado para treinar a rede neural que será especialista em reconhecimento de eventos de base (EEG normal) e o cD3 foi utilizado pra treinar a rede neural responsável em detectar os ruídos (artefatos de 60Hz, EMG, etc).

3.3. Detecção de crises

Vários pesquisadores estão utilizando redes neurais para, solucionar problemas relacionados à medicina, nessa extensa faixa de aplicações, a epilepsia também pode ser detectada empregado estas ferramentas.

Alguns tipos de redes estão sendo utilizados, mas a que melhor se adequou ao EEG, visando à detecção de crises, foi o backpropation [14]. Sendo assim, foram empregadas algumas de suas variações, tais como:

- FF-Feed Forwardbackpropagation;

- CF-CascadeForward backpropagation;
- EB- Elman backpropagation.

Foram realizados testes com essas redes, encontrando a que oferece o melhor desempenho nos resultados de classificação dos eventos relacionados ao EEG patológico.

Para todos os resultados realizados na tabela 1, as redes foram treinadas com 40000 ciclos, 60 neurônios na camada escondida e 1 neurônio na camada de saída.

3.5. Tomada de decisão

O sistema especialista é composto de regras heurísticas que desempenham um ótimo papel na tomadas de decisão, verificando simultaneamente a saída das duas redes neurais artificiais, sendo uma responsável em detectar crises epiléticas (RNA1) e a outra para detectar artefatos (RNA2). As regras utilizadas na saída da rede neural artificial 1 (RNA1) e rede neural artificial 2 (RNA2) estão descritas abaixo:

```

if (RNA1<=0.3) & (RNA2<=0.3)
  Não há crise;
elseif (0.3>RNA1<0.7) & (RNA2<=0.3)
  Não há crise;
elseif (RNA1<=0.3) & (RNA2>=0.7)
  Não há crise;
elseif (RNA1>=0.7) & (RNA2<=0.3)
  Há crise;
elseif (0.3<RNA1<0.7) &
  (0.3<RNA2<0.7)
  Indefinido;
elseif (RNA1>=0.7) & (RNA2>=0.7)
  if Saída RNA1 > Saída RNA2
    Há crise;
  else
    Não há crise;
  end
elseif (RNA1>=0.7) & (0.3<RNA2<0.7)
  Há crise;
elseif (RNA1<=0.3) & (0.3<RNA2<0.7)
  Não há crise;
elseif (0.3<RNA1<0.7)& (RNA2>=0.7)
  Não há crise;
End

```

Para tal, a análise é realiza simultaneamente nos resultados fornecidos pelas duas redes neurais, atuando como classificador do evento em crise, não crise e indefinido.

4. Resultados

Na tabela 1 estão representados os resultados obtidos com alguns algoritmos de treinamento de acordo com a metodologia apresentada na figura 3.

WT	AR	AT	AA	TA	FR	I
Coif	FF	GD	CL	81,8%	18,1%	0,1%
Coif	EB	SCG	GW	70,7%	29,2%	0,01%
Coif	CF	RP	WD	78,2%	28,7%	0,01%
Db4	FF	GD	CL	82,5%	17,1%	0,28%
Db4	EB	SCG	GW	69,3%	30,2%	0,5%
Db4	CF	RP	WD	70,3%	29,2%	0,5%

Tabela 1: Resultados obtidos.

Onde:

WT- Foram os dois tipos de wavelets mãe utilizados.

AR- Arquitetura da rede

- FF-Feed Forwardbackpropagation;
- CF-CascadeForward backpropagation;
- EB- Elman backpropagation.

AT - Algoritmos de treinamento

- GD-Batch gradiente descent;
- SCG-Scaled conjugate gradient;
- RP- Resilient.

AA - Algoritmos de aprendizado

- GW- Grad. descent w/momentum weight/bias;
- WD -Hebb with decay weight learning;
- CL- Conscience bias learning.

TA - Taxa de acerto:

FR - falsa detecção (Falso positivo e falso negativo);

I - Indefinido;

PC - Função de performance:

- MS- Mean squared;

FT1 - Função de ativação da camada 1

- FHT-Hyperbolic tangent sigmoid;

FT2 - Função de ativação da camada 2:

- FLT-Linear transfer;

As redes chegaram a apresentar valores de acerto em torno de 78% e erro em torno de 22%, variando com a alternância dos algoritmos de treinamentos, aprendizado e otimização.

5. Conclusão

A utilização das famílias wavelet Db4 ou Coif1, para decomposição do sinal em apenas duas sub-bandas, com a finalidade de detecção de crises epiléticas, onde o sistema terá como única ferramenta

de extração de características umas das wavelets, foi apresentado neste trabalho. Esse sistema é considerado uma estratégia satisfatória, de acordo com os resultados apresentados na tabela 4.

Coif1		Db4	
Acerto	Erro	Acerto	Erro
81,8%	18,1%	82,5%	17,1%

Tabela 4: Melhores resultados obtidos.

A taxa de acerto pode ser melhorada, pois, a rede neural artificial (RNA2) responsável em detectar todos os artefatos (60Hz, EMG, etc) obteve taxas de reconhecimentos relativamente baixas, se comparada com a rede neural responsável em detectar eventos epiléticos. Esse fato deve-se aos ruídos, que são muitos semelhantes aos eventos de crise e a rede não conseguiu distinguir, de forma satisfatória, a todos eles.

As melhores taxas de acerto, tanto para db4, como para coif1, mostraram-se bem próximas, sendo atribuída a db4 o melhor resultado, logo, essa família demonstrou uma melhor aptidão em trabalhar com sinais eletroencefalográficos patológicos.

Uma estratégia para melhorar a taxa de acerto seria adotar uma rede neural para cada ruído predominante, tornando a rede altamente especialista em detectar um tipo de artefato (60Hz, EMG, etc) ou utilizar outras técnicas de extração de características em conjunto com a Wavelet, que venham agregar informações juntamente com a wavelet, tais como: média, desvio padrão e energia.

6. Referências

- [1] Saab, M.E., Gotman J., "A system to detect the onset of epileptic seizures in scalp EEG", *International Federation of Clinical Neurophysiology*, 2005, pp. 427-442.
- [2] Unser M., Aldroubi A., "A review of wavelets in Biomedical applications", *IEEE*, VOL 84, NO.4, 1996, pp. 623-638.
- [3] Turner M., "Bases de electroencefalografia clinica", Editorial Paidós, 1971.
- [4] Parreira J.P., Yamanaka K., JB-Destro F, "Previsão de crise epilética baseada em análise de sinais eletroencefalográficos", *I Conferencia de Estudos em Engenharia Elétrica-UFU*, 2003.
- [5] GUYTON, A.C., "Tratado de Fisiologia Médica", Editora Guanabara Koogan S.A, 1992.
- [6] Rosso O. A., et al., "Wavelet entropy: a new tool for analysis of short duration brain electrical signals", *Journal of Neuroscience Methods*, 2001, pp. 65-75.
- [7] Thakor N.V., Tong S., "Advances in quantitative Electroencephalogram analysis methods", *Annual Reviews Biomed. Eng.*, 2004, pp. 453-495.
- [8] Krymik M.K., Guler K., Dizibuyuk A., Akin M., "Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for real-time application", *Computers in Biology and Medicine*, 2004, pp. 1-14;
- [9] Samar V. J., "Multiresolution analysis of event-related potentials by wavelet decomposition", *Brain and cognition-Elsevier*, 1995, pp. 398-438.
- [10] Hazarika N., Chen J. Z., Tsoi A. C., Segejew A., "Classification of EEG signals using the wavelet transform", *Signal Processing*, 1997, pp. 61-72.
- [11] Argoud F. I. M., "Contribuição à automatização da detecção e análise de eventos epileptiformes em eletroencefalograma", *Tese Universidade Federal de Santa Catarina*, 2001.
- [12] Pereira M. C., "Tratamento de sinais bioelétricos para processamento por redes neurais artificiais", *Tese Universidade Federal de Santa Catarina*, 2003.
- [13] Gutierrez J., Alcantara R., Medina V., "Analysis and localization of epileptic events using wavelet packets", *Medical Engineering & Physics*, Vol. 23, 2001, pp. 623-631.
- [14] Park H. S., Lee Y. H., Lee S. L., Kim S.I., "Detection Of Epileptiform Activity Using Wavelet And Neural Network", *International Conference-Ieee/Embs*, 1997, 1194-1197.
- [15] Salczak, S., Nowack W., "An artificial neural network approach to diagnosing epilepsy using lateralized bursts of theta EEGs", *Journal of medical systems*, Vol. 25, 2001, pp. 1-22.
- [16] Kalayci T., Ozdamar O., Erdol N, "The Use Of Wavelet Transform As A Preprocessor For The Neural Network Detection Of Eeg Spikes", 1994, pp. 94-97.
- [17] Szilágyi L., Benyó Z., Szilágyi S.M., "A new method for epileptic waveform recognition using wavelet decomposition and artificial neural networks", *Proceedings of the Joint EMBS/BMES-IEEE*, 2002, pp. 23-29.
- [18] Eyal Hulata, Ronen Segev, Eshel Ben-Jacob, "A method for spike sorting and detection based on wavelet packets and Shannon's mutual information", *Journal of Neuroscience Methods* 117, 2002, pp. 1-12
- [19] Subasia A., "Ercelebi E., Classification of EEG signals using neural network and logistic regression", *Computer Methods and Programs in Biomedicine*, 2005, pp. 1-13.