

Identificação de Crises Epilépticas Baseada em Sinais de Eletroencefalograma Utilizando a Transformada Wavelet

Ana Paula Rosa Negri¹, Diego da Silva de Medeiros²

¹Universidade Federal de Santa Catarina
Pós-graduação em Engenharia Elétrica
ana.negri@hotmail.com

²Instituto Federal de Santa Catarina
Telecomunicações
diegomedeiros@ifsc.edu.br

Resumo – A identificação visual das crises epilépticas é bastante complexa e, algumas vezes, o resultado é diferente na análise de cada médico especialista. Com base nesse contexto, este artigo tem como objetivo apresentar a transformada *wavelet* como técnica para a identificação de crises epilépticas em sinais de eletroencefalograma (EEG). Como método, foram testadas duas famílias *wavelet* e três níveis de decomposição. Para a análise do sinal de saída da transformada *wavelet*, foi utilizada a limiarização.

Palavras-chave: epilepsia, eletroencefalograma, transformada *wavelet*, identificação de crises.

1. Introdução

O cérebro possui bilhões de neurônios que comandam todas as ações do corpo através das sinapses, trocas elétricas entre neurônios. A epilepsia afeta o comportamento dos neurônios que passam a interagir de forma anômala durante a ocorrência de uma crise. Descargas elétricas são emitidas de forma exagerada em parte do cérebro causando perda do controle do corpo. É ainda tratada com preconceito por muitos pela falta de conhecimento sobre o assunto. Pode ser hereditária ou adquirida por algum fator que possa causar instabilidade nos neurônios, como a meningite, hipoglicemia e traumatismos cranianos [1].

Para diagnosticar a epilepsia em um paciente, o exame mais indicado é o eletroencefalograma (EEG). No EEG, eletrodos captam a atividade elétrica cerebral durante situações simuladas que podem causar instabilidade nos neurônios, como a hiperpneia e o fotoestímulo. O exame é analisado de forma manual por um médico especialista. A detecção manual é complexa por se tratar de um sinal com diversas particularidades. Outro fator que aumenta a complexidade de análise é o número de sinais elétricos captados por cada um dos eletrodos.

Muitos métodos foram desenvolvidos com o intuito de auxiliar a identificação de crises. Neste cenário, destaca-se a transformada *wavelet*, uma ferramenta de análise de sinais não estacionários, cujos valores de potencial elétrico têm variação relativamente aleatória com a existência de alguns padrões típicos. Uma de suas características é a adequação da análise à

frequência do sinal, característica esta importante na análise de sinais de EEG [2].

Este trabalho apresenta um sistema preliminar de detecção de crises epilépticas, baseado na transformada *wavelet*. O restante deste trabalho está organizado da seguinte forma: a Seção 2 descreve a epilepsia e o processo de identificação de crise a partir do EEG; a Seção 3 mostra sucintamente a transformada *wavelet*; a Seção 4 apresenta a estrutura dos testes realizados e as métricas de avaliação empregadas; na Seção 5 faz-se a avaliação e discussão dos resultados obtidos; e a Seção 6 conclui o trabalho.

2. Epilepsia

Não há uma definição específica para a epilepsia por não se tratar de apenas uma doença ou síndrome, mas a combinação de vários sintomas decorrentes da atividade cerebral excessiva [4]. Esses sintomas podem ter duração de até 5 minutos e fim natural, caso a crise ultrapasse esse limite, é aconselhável a consulta a um médico. Normalmente, as crises são acompanhadas pela perda da consciência.

O exame de EEG utiliza eletrodos para captar a atividade elétrica cerebral em suas diferentes regiões, o que torna possível a obtenção de informações úteis para detecção de diferentes patologias neurológicas, entre elas a epilepsia.

2.1. Epilepsia no EEG

O sinal de EEG é não estacionário, mas possui alguns padrões que têm formatos de onda conhecidos e aparecem no decorrer do sinal de acordo com as características de cada crise. Ele é

dividido em três partes, atividade de base, período ictal e período interictal (pré-ictal e pós-ictal).

A atividade de base é caracterizada como a captação da atividade elétrica cerebral pelos eletrodos e se apresenta em todo o sinal. Em períodos onde não há ocorrência de crise, todo o sinal captado é considerado atividade de base. Caso contrário, pode aparecer entre as ondas e/ou somada a elas.

O período ictal é o momento no qual o sinal de saída do EEG sofre maior alteração e está associado ao momento da crise. Este período apresenta sintomas clínicos relacionados aos paroxismos epileptiformes, formatos de onda característicos de crises epiléticas, e duração acima de 10 segundos. Possui ondas rítmicas em diferentes faixas de frequência além de mudanças de amplitude e morfologia.

Os registros interictais são caracterizados pela ausência de sintomas. Podem aparecer nesse período do sinal, paroxismos epileptiformes de pequena duração e isolados.

Os padrões de onda do EEG podem ocorrer nos períodos ictal e interictal, mas de maneiras diferentes. A atividade de base não apresenta esses padrões.

3. Transformada *Wavelet*

Para a obtenção da transformada *wavelet*, o sinal é janelado de acordo com sua frequência, assim frequências maiores têm janelas de tempo menores e frequências menores o contrário. A transformada pode ser caracterizada como um par de filtros, um passa-altas e um passa-baixas, seguido de uma subamostragem. A frequência de corte é calculada como a metade da frequência máxima. Cada vez que o sinal passa por esse processo, têm-se novos níveis de decomposição e cada novo nível utiliza as baixas frequências (coeficiente de aproximação) para refazer o processo. Dessa forma, o sinal possui diversas faixas de frequência que não se sobrepõem e apresentam diferentes informações [5].

A transformada *wavelet* costuma ser a mais utilizada para a identificação de sinais por possuir uma vantagem sobre a transformada de Fourier, se adequar à frequência do sinal. A transformada de Fourier analisa todo o sinal, dessa forma algumas características são perdidas. Uma alternativa seria a transformada de Fourier janelada que divide o sinal em janelas de mesmo tamanho e aplica a transformada a cada uma delas. O problema dessa técnica é o tamanho fixo para as janelas, assim, janelas pequenas

perderiam dados importantes enquanto janelas maiores utilizariam mais sinal que o necessário para a obtenção dos dados.

Como mostrado na Figura 1, a transformada de Fourier apresenta janelas de mesmo tamanho independente da frequência do sinal enquanto a transformada *wavelet* tem janelas maiores para baixas frequências e menores para altas frequências.

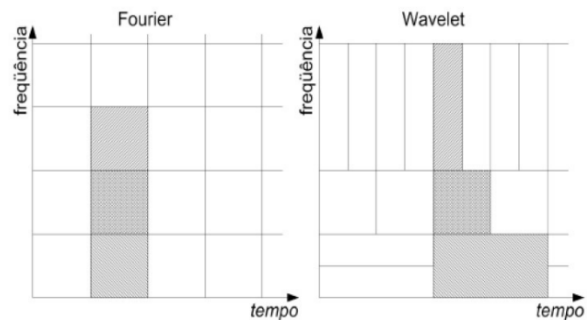


Figura 1: Diferença entre o janelamento da transformada de Fourier e da transformada *wavelet* [6].

4. Estrutura dos Testes

Foram usados sinais de EEG disponibilizados pela Physionet [7], com pacientes pediátricos com crises intratáveis [8]. Foram escolhidos de forma aleatória 45 arquivos, cada um contendo sinais captados pelos eletrodos, com no mínimo uma crise. No total foram analisadas 49 crises. Todas elas especificadas por faixa de tempo.

Cada sinal passou pela transformada *wavelet* seguida da limiarização, como mostrado na Figura 2. A limiarização é parte essencial para a verificação do resultado. O limiar é calculado com base no valor máximo de pico do sinal analisado. Assim, todo valor que ultrapassar o limiar estipulado é considerado crise, as medidas de desempenho analisam os resultados.




Figura 2: Estrutura dos testes realizados.

Para a transformada *wavelet* foram testadas as famílias *Daubechies 4* e *Coiflet 1* com níveis de decomposição 1, 2 e 3. Para a avaliação da melhor família e nível, foram testados três limiares para identificação de crises, 30, 50 e 80% do valor máximo de pico do sinal avaliado.

4.1. Medidas de desempenho

Para a elaboração dos resultados, foram criadas duas medidas de desempenho. Esses dados permitiram a análise de importantes aspectos do sistema que serão posteriormente expostos. Sendo N_a o número de sinais em que crises foram identificadas e T o número total de sinais com crise, a taxa de acertos (η_a) indica o desempenho de cada combinação proposta (família *wavelet*, nível e limiar) quanto aos seus acertos e é definida como:

$$\eta_a = \frac{N_a}{T} \quad (1)$$

Esta medida não pode ser o único ou principal fator para a análise do desempenho por não considerar a quantidade de falsos positivos (picos que não representam crises). Para melhor analisar o sistema, outra medida foi utilizada, a taxa de identificação de crise. Este parâmetro é essencial para a análise por apresentar em porcentagem quanto dos picos encontrados foi referente à crise. A equação (2) define esta medida:

$$\eta_i = \frac{N_i}{N_T}, \quad (2)$$

onde η_i é a taxa de identificação de crise, N_i é o número de crises identificadas corretamente e N_T é o número total de crises identificadas.

As duas medidas utilizadas se contrapõem já que quanto maior o número de picos total, maior o número de falsos positivos, mas por outro lado, maior será a probabilidade de uma crise ser identificada no sinal.

5. Resultados

A Tabela 1 apresenta os resultados das medidas de desempenho utilizadas para cada família *wavelet*, limiar e nível.

Para a avaliação da família *wavelet* mais indicada na identificação de crises, foram feitos testes relacionados com cada combinação de limiar e nível. De acordo com a taxa de identificação de crise (medida de desempenho que apresenta a relação entre os picos encontrados dentro e fora do intervalo de crise), a família *Daubechies 4* apresentou menor número de falsos positivos (picos acima do limiar que indicam crise erroneamente). Em contrapartida, a *Coiflet 1* obteve uma taxa de acertos maior. Desta forma, não foi possível constatar qual das duas famílias *wavelet* é a mais indicada para o sistema desenvolvido.

Tabela 1: Taxa de acertos (η_a) e taxa de identificação de crises (η_i) para cada combinação das famílias *wavelet*, *Daubechies 4 (Db4)* e *Coiflet 1 (Coif1)*, nível de decomposição e limiar.

| <i>Wavelet</i> | Nível | Limiar (%) | η_a (%) | η_i (%) |
|---------------------|-------|------------|--------------|--------------|
| <i>Db4</i> | 1 | 30 | 61,70 | 10,76 |
| | | 50 | 48,94 | 11,10 |
| | | 80 | 19,15 | 21,05 |
| | 2 | 30 | 80,85 | 12,24 |
| | | 50 | 72,34 | 15,62 |
| | | 80 | 31,91 | 33,01 |
| | 3 | 30 | 80,85 | 18,81 |
| | | 50 | 65,96 | 33,80 |
| | | 80 | 38,30 | 56,00 |
| <i>Coif1</i> | 1 | 30 | 72,34 | 11,68 |
| | | 50 | 48,94 | 13,75 |
| | | 80 | 12,77 | 34,44 |
| | 2 | 30 | 85,11 | 9,77 |
| | | 50 | 65,96 | 21,64 |
| | | 80 | 29,79 | 39,29 |
| | 3 | 30 | 76,60 | 22,52 |
| | | 50 | 65,96 | 37,32 |
| | | 80 | 36,17 | 77,78 |

A escolha da quantidade de níveis de decomposição que melhor se adéqua à visualização de crises epilépticas, por sua faixa de frequência, foi baseada em testes relacionando a quantidade de níveis a serem testados (1, 2 e 3) com cada combinação de família *wavelet* e limiar. A taxa de acertos apresentou alta variação, assim a análise desta medida de desempenho impossibilita a obtenção de resultado comparativo. Quando verificada a taxa de identificação de crise, podem-se notar maiores resultados para o terceiro nível de decomposição, o que representa menor número de falsos positivos. O primeiro nível apresentou os piores resultados, com grande quantidade de falsos positivos.

Para a decisão do limiar a ser utilizado, cada medida de desempenho apresentou resultado diferente. Os resultados com limiar de 30% apresentaram taxa de acerto significativamente maior que os dois outros limiares testados. Em contrapartida, a verificação da taxa de identificação de crises trouxe menor número de falsos positivos para o limiar de 80%, configurando um melhor resultado de acordo com a segunda medida de desempenho avaliada. Como o limiar de 30% apresentou uma taxa

muito alta de falsos-positivos e o limiar de 80% obteve taxa de acertos muito menor que os outros limiares testados, concluiu-se que o limiar de 50% apresenta resultados mais confiáveis.

Como pode ser visto, a taxa de acertos da combinação de limiar e nível de decomposição escolhida, obteve o mesmo resultado para ambas as famílias *wavelet*. Já na taxa de identificação de crise, a Coiflet 1 apresentou melhor resultado, com 37,32% contra 33,80% da Daubechies 4.

6. Conclusões

A epilepsia é uma doença muito comum e pouco conhecida que atinge o comportamento elétrico dos neurônios. O eletroencefalograma é o exame mais indicado para a detecção de crises epiléticas, mas trata-se de um exame com diversos sinais e de análise complexa.

Foram feitos testes com as duas famílias *wavelet* mais utilizadas pela literatura, *Coiflet 1* e *Daubechies 4*, os três primeiros níveis de decomposição e três limiares, 30, 50 e 80% do valor máximo do sinal com o objetivo de comparar as possíveis combinações e decidir qual delas apresenta melhor resultado.

O trabalho aqui exposto apresentou uma estrutura de detecção automática de crises que faz uso da transformada *wavelet*. Com os parâmetros escolhidos, verificaram-se taxas de acertos e de identificação de crises razoáveis tendo em vista a alta complexidade do tema.

Para aprimorar e dar continuidade a este trabalho, são propostos alguns temas:

Utilizar, conjuntamente, técnicas de aprendizado de máquina, como as Redes Neurais Artificiais, para automatizar a decisão na detecção de paroxismos epileptiformes.

Criar uma interface gráfica e interativa que tenha como sinal de entrada o arquivo de eletroencefalograma e o análise de forma automática.

Referências

- [1] Valença, M.M., Valença, L.P.A.A., 2000. Etiologia das crises epiléticas na cidade do Recife, Brasil: estudo de 249 pacientes. *Arq Neuropsiquiatr* 58, 1064–72.
- [2] Galvão, R.K.H., Araújo, M.C.U. de, Saldanha, T.C.B., Visani, V., Pimentel, M.F., 2001. Comparative study on instrumental signal denoising using Fourier and Wavelet transforms. *Quím. Nova* 24, 874–884.
- [3] Tavares, M.C., 2011. EEG e potenciais evocados - Uma introdução.
- [4] Guerreiro, C., Guerreiro, M., 2004. *Epilepsia: 50 Frequently Asked Questions*. Editora de Projetos Médicos, São Paulo.
- [5] Sanchez, F.L., 2008. Análise cepstral baseada em diferentes famílias de transformada wavelet (Tese de Doutorado). Universidade de São Paulo, São Paulo.
- [6] Cazes, T., Macedo, F., Costa, E., Rios, L., Mendonça, A., Ribeiro, L., 2013. Detecção de anomalias de consumo por meio de análise baseada em wavelet. Presented at the VII Congresso de Inovação Tecnológica em Energia Elétrica, Rio de Janeiro.
- [7] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 101(23):e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/cgi/content/full/101/23/e215>]; 2000 (June 13).
- [8] Ali Shoeb. Application of Machine Learning to Epileptic Seizure Onset Detection and Treatment. PhD Thesis, Massachusetts Institute of Technology, September 20.