

## Continuous Wavelet Transform study for normal and ictal eeg signals analysis

### Estudo da Transformada Wavelet Contínua para análise de sinais EEG normais e ictais

Article Info:

Article history: Received 2023-01-02 / Accepted 2023-02-20 / Available online 2023-02-20

doi: 10.18540/jcecv19iss1pp15427-01e



**Thiago Bastos da Silva**

ORCID: <https://orcid.org/0000000199313872>

Universidade do Estado do Rio de Janeiro, Instituto Politécnico, Brasil

E-mail: [thiagobastos71@gmail.com](mailto:thiagobastos71@gmail.com)

**Sílvia Mara da Costa Campos**

ORCID: <https://orcid.org/0000000235717023>

Universidade do Estado do Rio de Janeiro, Instituto Politécnico, Brasil

E-mail: [silviacampos@iprj.uerj.br](mailto:silviacampos@iprj.uerj.br)

#### Resumo

Neste artigo propomos o uso da transformada wavelet contínua para analisar alguns sinais específicos obtidos via eletroencefalograma (EEG). O EEG é um exame muito utilizado para análise da atividade elétrica cerebral e, através dele, é possível detectar, em determinadas bandas de frequência, se essa atividade elétrica está de acordo com as normas estabelecidas. Para atingir este objetivo, primeiramente explicaremos um pouco sobre o funcionamento do EEG e depois utilizaremos a transformada wavelet contínua, por meio de um programa escrito na linguagem python, para analisar o comportamento de sinais de EEG nos domínios do tempo e da frequência. São dois tipos específicos de sinais estudados: de pessoas saudáveis e de pessoas em crise epilética, conhecidos como sinais ictais. Foram utilizados sinais de uma base de dados consolidada da Universidade de Bonn. Os principais resultados foram a obtenção dos dados estatísticos obtidos dos sinais e de seus respectivos escalogramas, em que foram comparados a diferença entre os valores máximos, média de valores e outros parâmetros de cada sinal e escalograma.

**Palavras-chave:** EEG. Transformadas Wavelet contínuas. sinal. escalograma.

#### Abstract

In this article we propose the use of the continuous wavelet transform to analyze some specific signals acquired via electroencefalogram (EEG). The EEG is a widely used test to analyze the brain electrical activity and, through it, it is possible to detect, in certain frequency bands, if this electrical activity is in accordance with the established norms. To achieve this goal, we will first explain a little about how the EEG works and then use the continuous wavelet transform, through a program written in python language, to analyze the behavior of EEG signals in the time and frequency domains. There are two specific types of signals studied: from healthy people and from people in epileptic seizures, known as ictal signals. Signals from a consolidated database of the University of Bonn were used. The main results were statistical data obtained from the signals and their respective scalograms, in which the difference between the maximum values, mean values, and other parameters of each signal and scalogram were compared.

**Keywords:** EEG, Continuous Wavelet Transform, signal, scalogram.

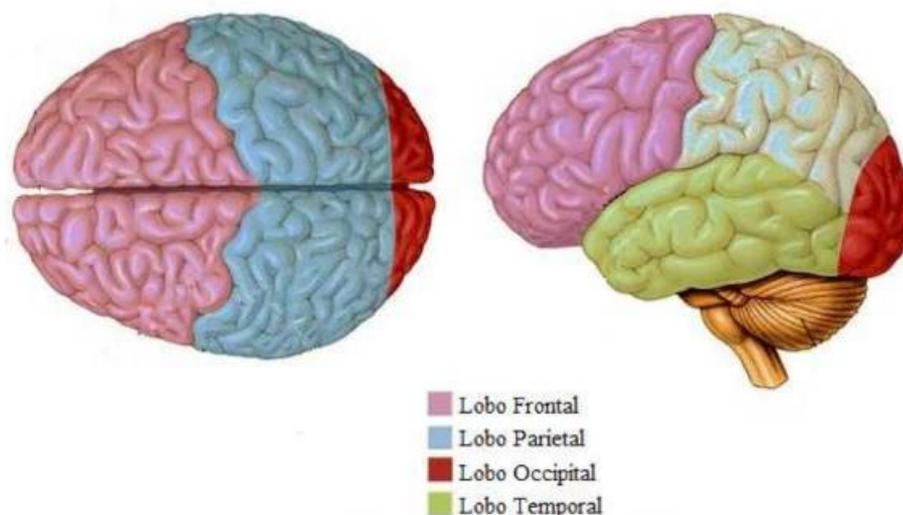
## 1. Introdução

O eletroencefalograma é realizado com a finalidade de captar sinais elétricos resultantes da atividade do cérebro. A frequência registrada normalmente se encontra entre 0 e 100 Hz e a amplitude na faixa de 0,5 a 100  $\mu\text{V}$ .

O eletroencefalograma expõe as variações de frequência da atividade elétrica cerebral, frequências essas que podem ser divididas em bandas (que podem ter uma pequena divergência, de acordo com a referência). A banda Delta está situada entre 0,5 a 3,5 Hz e são ondas de baixa frequência e de alta amplitude, e características de estado de sono profundo. As bandas Teta estão situadas entre 3,5 a 7,5 Hz, e estão diretamente associadas ao sono. A alta recorrência dessas ondas teta, em adultos, se caracteriza como anormalidades que podem estar relacionadas à ansiedade, à epilepsia e a outros distúrbios cerebrais. As bandas Alfa podem ser encontradas entre 7,5 e 12,5Hz; em adultos normais, elas se desenvolvem naturalmente em estado de relaxamento e inatividade mental e sua amplitude varia entre 10 a 50  $\mu\text{V}$ . As bandas Beta podem ser encontradas entre 12,5 a 30 Hz. Ao contrário das ondas Delta, as ondas Betas são ondas de alta frequência e baixa amplitude, e estão associadas a estados de resolução de problemas, concentração e alerta.

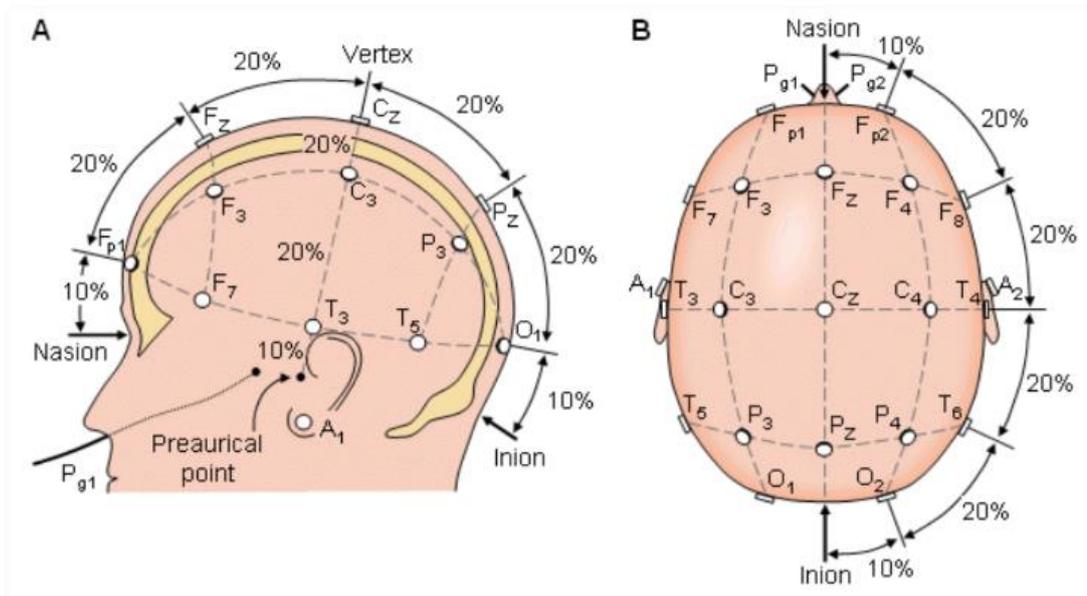
O sinal do EEG é captado através de eletrodos posicionados estrategicamente na cabeça do paciente. Esses eletrodos são compostos de Ag/AgCl. Alguns fatores, como gordura, suor, poeira e cabelos, podem interferir no resultado da coleta do sinal. O exame deve ser realizado, preferencialmente, em ambientes longe de possíveis fontes de interferência eletromagnética ou elétrica e o paciente deve evitar movimentos desnecessários durante o processo de coleta.

O córtex cerebral é subdividido em quatro áreas, chamados lobos (Figura 1). O lobo frontal está relacionado ao processamento de informações referentes ao planejamento de ações futuras e ao controle do movimento. O lobo parietal está relacionado com o processamento de informações sensoriais e de noção de espaço. O lobo occipital está relacionado com o processamento de informações da visão. Já o lobo temporal está associado ao processamento de informações da audição, aprendizado, memória e emoção (Andrés, 2009).



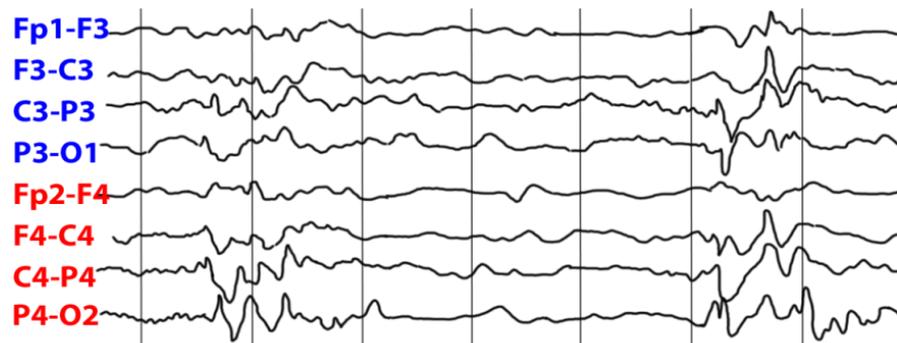
**Figura 1 - Áreas do córtex**  
**Fonte: Andrés, 2009**

Essa divisão representa os pontos de referências de localização cerebral para definição das posições dos eletrodos (Figura 2), dependendo da função que se deseja explorar.



**Figura 2 – Pontos de referência**  
**Fonte: Henrique, 2011**

Cada eletrodo é identificado através de uma letra e de um número: as letras referenciam as áreas as quais foram colocados os eletrodos e os números referenciam a qual hemisfério o eletrodo está inserido - números pares no hemisfério direito e ímpares no hemisfério esquerdo (Figura 3). Um exemplo de saída de um exame EEG é demonstrado abaixo (Andrés, 2009).



**Figura 3 – Identificação dos eletrodos**  
**Fonte: Henrique, 2011**

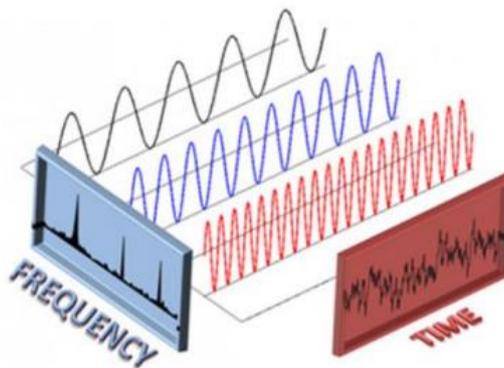
Pode-se notar, no exemplo acima, que cada eletrodo tem como saída os sinais elétricos provenientes de cada região cerebral citada anteriormente. Os eletrodos com a notação Fp e F captam informações essencialmente do lobo frontal, os com letra P do lobo parietal, os com letra T do lobo temporal, e os com a letra O correspondem ao lobo occipital. Existem também os eletrodos que são identificados pela letra C, localizados na região central que está definida entre os lobos frontal e parietal, e também os eletrodos identificados pela letra A, que são encontrados nas orelhas e, normalmente, são utilizados como referência (Andrés, 2009).

No exemplo acima foram analisadas as ondas de eletrodos específicos - os simbolizados pela cor azul são os Frontais parietais, Frontais, Centrais, Parietal e Occipital localizados no hemisfério esquerdo da cabeça (como comentado antes, os números ímpares se referem ao hemisfério esquerdo), já os simbolizados pela cor vermelha representam os Frontais parietais, Frontais, Centrais, Parietal e Occipital localizados no hemisfério direito devido aos números pares. O eletrodo Fp1-F3 está localizado entre as regiões do Frontal parietal e Frontal, já o F3-C3 está localizado entre a região Frontal e Central, o C3-P3 está localizado entre a região Central e Parietal e o P3-O1 que está localizado entre as regiões do lobo Parietal e Occipital. Para os eletrodos em vermelho as regiões são as mesmas, o que as diferem são os hemisférios.

A fim de converter os sinais advindos dos eletrodos em bandas de frequências, será necessário utilizar alguma transformada que nos possibilite avaliar as frequências presentes no sinal do exame de EEG.

Uma das formas de transformar o sinal do EEG em um sinal baseado em frequências é utilizando a Transformada de Fourier, que consiste em transformar um sinal Amplitude x Tempo em um sinal Frequência x Amplitude (Henrique, 2011).

Na Figura 4, a “parede” vermelha simboliza o sinal no domínio do tempo x amplitude; ele pode ser analisado como a soma dos três sinais do fundo (curva vermelha, azul e preta). Já a “parede” azul, simboliza o sinal no domínio da frequência x amplitude; pode-se analisar o mesmo a partir da análise de cada sinal em separado. Logo, pode-se analisar uma função senoidal de frequência por amplitude e tempo por amplitude.



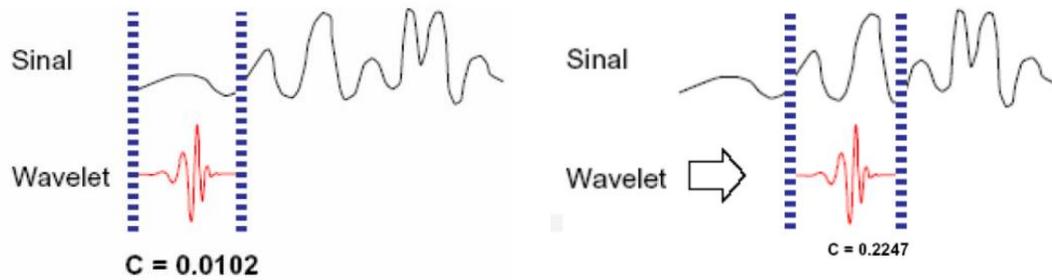
**Figura 4 – Relação entre o domínio do tempo e frequência**

Fonte: ENSUS, 2016

Para o estudo do EEG em diagnóstico precoce de epilepsia, a Transformada de Fourier não é a ferramenta mais indicada, pois a mesma não permite a análise de um sinal em frequência x tempo, dessa forma, a distribuição de frequência não pode ser analisada como aparece no exame, e sim como um padrão, pois os valores máximos e mínimos dependerão da amplitude em determinadas frequências; sendo assim, as mudanças bruscas em determinado intervalo não serão avaliadas.

Com a finalidade de contornar esse problema relativo à Transformada de Fourier para estes sinais, estudaremos outra forma de converter o sinal do eletroencefalograma em um sinal de frequência x tempo (Hagar *et al.*, 2022).

Uma transformada que satisfaz às necessidades apresentadas acima, é a Transformada Wavelet. A Transformada Wavelet consiste em transformar um sinal Amplitude x Tempo em um sinal Frequência x Tempo, permitindo a análise de cada frequência de maneira que ela aparece no exame, podendo nos mostrar anormalidades e distúrbios nas atividades elétricas cerebrais. A aplicação da Transformada Wavelet funciona de forma que, escolhida uma escala (que não tem dimensão, diferentemente da frequência, expressa em Hertz ou Hz) da “janela”, relacionada à largura da mesma, a janela passa pelo sinal todo através da translação e sempre começa onde a anterior terminou, como mostrado na Figura 5 (Najarian e Splinter, 2012).



**Figura 5 – Transformação para a wavelet**  
**Fonte: Conci *et al.*, 2008**

Após realizar a passagem da Wavelet pela escala em um intervalo, a próxima passagem vai vir no final da passagem anterior até realizar essa passagem por todo o sinal.

## 2. Experimentos

O escalograma é um gráfico que apresenta a representação tempo x escala. O escalograma é gerado através da transformada wavelet contínua. Tem-se a seguinte relação: quanto maior a escala, maior a energia nas baixas frequências. Conforme diminuiu-se a escala, aumenta-se a energia nas frequências mais altas. O escalograma representa o espectro de energia dos coeficientes Wavelets em uma dada escala, e é obtido como (Magrini, 2020):

$$E(a, b) = |W(a, b)|^2 \quad (1)$$

Neste trabalho, foi utilizado um código *open source* adaptado (<https://github.com/brunobro/escalograma-series-temporais>), e também utilizaremos 2 sinais de um conjunto de dados disponibilizado pelo Dr. Ralph Andrzejak do Centro de Epilepsia da Bonn University (Base disponível em: <https://www.ukbonn.de/en/epileptology/workgroups/lehnertz-workgroup-neurophysics/downloads>), no qual foram analisados dois conjuntos de dados distintos, indivíduos saudáveis (dados normais) e indivíduos durante uma crise de epilepsia (dados ictais). Os conjuntos foram gravados com um sistema amplificador de 128 canais, contendo 100 seguimentos de EEG de apenas um desses canais, amostrado a uma taxa de 173,61 Hz.

Foram captados dados estatísticos do sinal e do escalograma como a média e o desvio padrão e entre outros (Vargas *et al.*, 2021).

Para facilitar o estudo dos sinais, foram separados os sinais em 2 considerando de 0 a 512 pontos e de 512 a 1024 pontos, os sinais apresentam 4096 pontos, mas para esse estudo foram utilizados apenas 1024 pontos.

Para esse estudo, foram utilizados os seguintes trechos de código, conforme as Figuras 5 e 6.

```

1  Fs = 173.61
2  ecg = pd.read_csv('z-normal-1')[1:512]
3  parametro1 = 1
4  parametro2 = 512
5  maior = ecg['-18'].max()
6  soma = ecg['-18'].sum()
7  desvio = statistics.stdev(ecg['-18'])
8  media = soma/513
9  mediana = ecg['-18'].median()
10 ruido = signaltonoise(ecg['-18'], 0, 0)
11
12 # Seleciona a escala ks para frequências em torno de alpha Hz
13  $\alpha$  = 100
14 ks = int(Fs /  $\alpha$ )
15 c = 5
16 s_start = 23
17 s_end = 50
18 if s_start <= 0:
19     s_start = ks

```

**Figura 5 – Código para o sinal**  
**Fonte: os Autores (2023)**

```

1  # Parâmetros para a CWT
2  # Escolhe as escalas. 5 acima e 5 abaixo da escala específica ks
3  s = np.arange(s_start, s_end + 1)
4  wav = 'cmor5.0-1.0' # Wavelet de Complexa de Morlet com B = 5.0 e C = 1.0
5
6  # Mostra as frequências cobertas para a wavelet e escalas selecionadas
7  # Converte escala para as frequências relativas
8  fre = pywt.scale2frequency(wav, s) * Fs
9  print('Escala - Frequência')
10 for i, item in enumerate(s):
11     print(['%.2f, %.2f' % (item, fre[i])])
12
13 # Computa a CWT
14 W, _ = pywt.cwt(ecg, s, wav, method='fft') # coeficientes wavelets
15 W = np.abs(W)**2 # obtêm o Escalograma
16
17 maiorescalograma = W.max()
18 menorescalograma = W.min()
19 escalogramatamanho = len(W)
20 mediaescalograma = W.sum()/escalogramatamanho

```

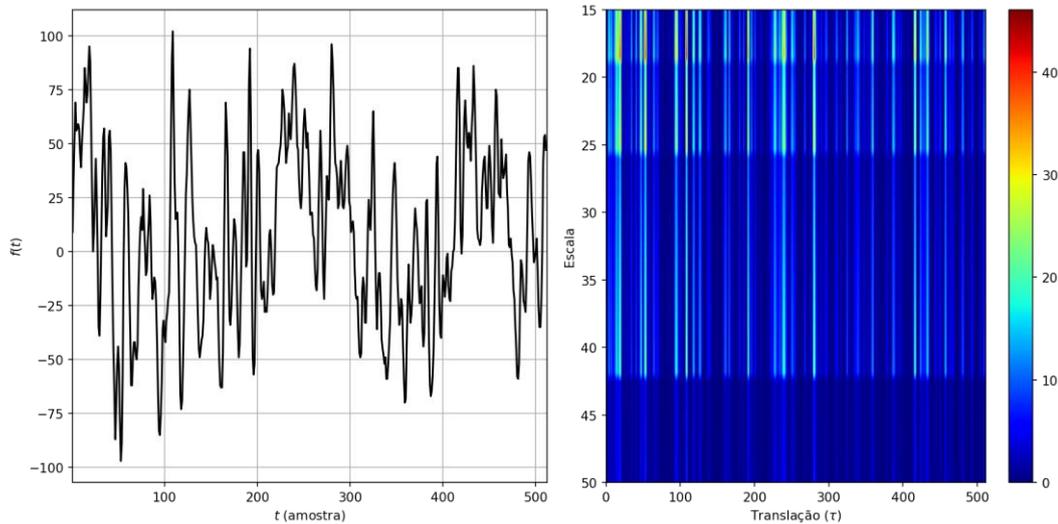
**Figura 6 – Código para o escalograma**  
**Fonte: os Autores (2023)**

Para esse caso, tem-se a seguinte relação escala x frequência (Tabela 1), considerando a escala de 15 a 50, para captar-se as Frequências desejadas:

Tabela 1 – relação escala x frequência

<b>Escala</b>	<b>Frequência</b>
15,00	11,57
16,00	10,85
17,00	10,21
18,00	9,64
19,00	9,14
20,00	8,68
21,00	8,27
22,00	7,89
23,00	7,55
24,00	7,23
25,00	6,94
26,00	6,68
27,00	6,43
28,00	6,20
29,00	5,99
30,00	5,79
31,00	5,60
32,00	5,43
33,00	5,26
34,00	5,11
35,00	4,96
36,00	4,82
37,00	4,69
38,00	4,57
39,00	4,45
40,00	4,34
41,00	4,23
42,00	4,13
43,00	4,04
44,00	3,95
45,00	3,86
46,00	3,77
47,00	3,69
48,00	3,62
49,00	3,54
50,00	3,47

Trabalhando agora com o primeiro sinal normal entre 0 e 512, tem-se, conforme Figura 7.



**Figura 7 – Sinal normal de 0 a 512 e escalograma**  
**Fonte: os Autores (2023)**

Alguns valores estatísticos obtidos deste sinal:

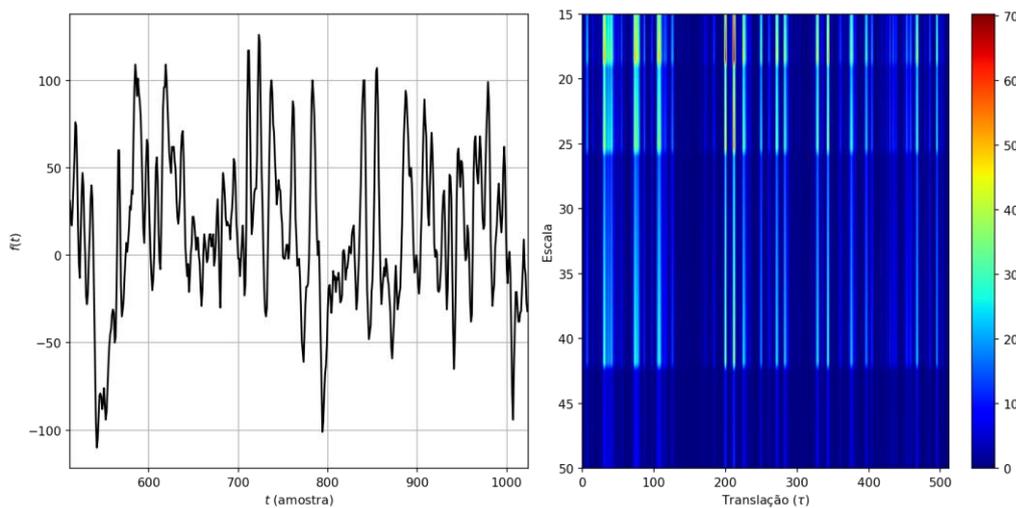
- Maior amplitude do sinal = 102
- Média do sinal = 6,88
- Mediana do sinal = 6
- Desvio padrão do sinal = 40,17
- Relação sinal-ruído = 0,172

E para o escalograma, obtêm-se:

- Maior valor do escalograma = 46,08
- Menor valor do escalograma = 0
- Média do escalograma = 1867,99

Para o sinal entre 512 e 1024, por sua vez, têm-se os seguintes resultados (Figura 8):

:



**Figura 8 – Sinal normal de 512 a 1024 e escalograma**  
**Fonte: os Autores (2023)**

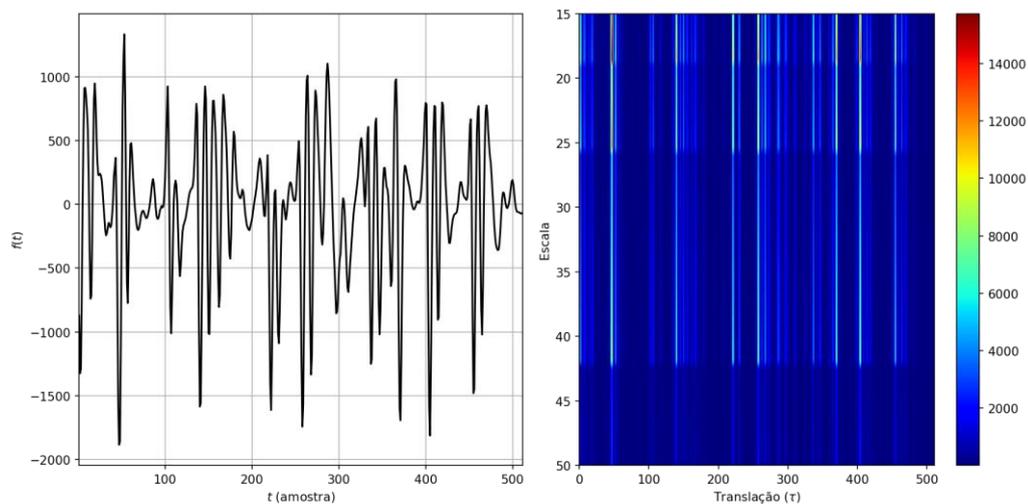
Para o sinal são obtidos os seguintes valores estatísticos:

- Maior valor do sinal = 126
- Média do sinal = 13,03
- Mediana do sinal = 9
- Desvio padrão do sinal = 44,02
- Relação sinal-ruído = 0,296

E para o escalograma, têm-se:

- Maior valor do escalograma = 70,31
- Menor valor do escalograma = 0
- Média do escalograma = 2375,12

Para o sinal ictal entre 0 e 512, a Figura 9 apresenta os seguintes resultados.:



**Figura 9 – Sinal ictal de 0 a 512 e escalograma**

**Fonte: os Autores (2023)**

Podemos perceber para todo esse intervalo do sinal uma maior variação nos valores de  $f(t)$  em relação ao sinal Normal, para esse sinal tem-se a mesma relação escala x frequência do sinal Normal.

Para o sinal têm-se os seguintes valores estatísticos:

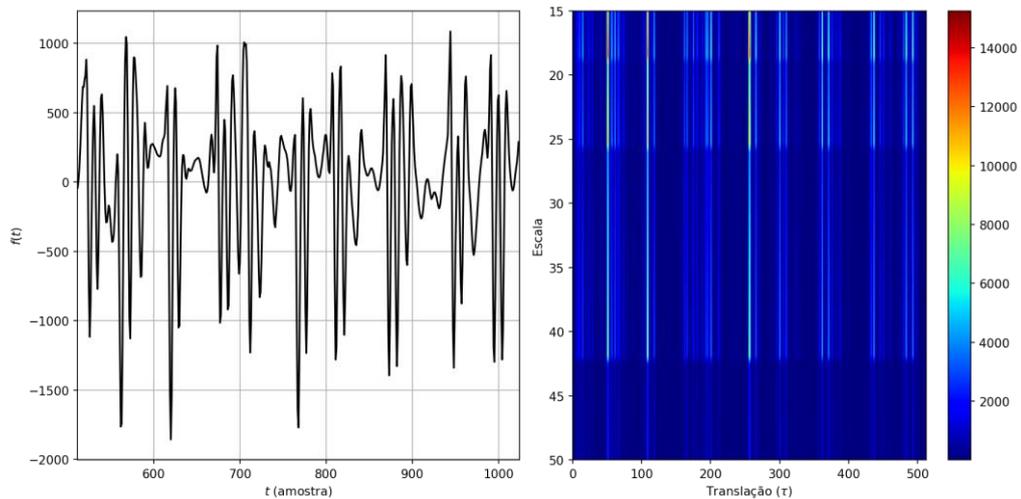
- Maior valor do sinal = 1333
- Média do sinal = -27,82
- Mediana do sinal = 20
- Desvio padrão do sinal = 545,46
- Relação sinal-ruído = -0,051

E para o escalograma têm-se:

- Maior valor do escalograma = 15736,62
- Menor valor do escalograma = 0,0036
- Média do sinal = 335476,42

Pode-se perceber também que os maiores valores nessa faixa, comparando o sinal Ictal com o sinal Normal se encontram no sinal Ictal, principalmente ao olhar os maiores valores do escalograma.

Para o sinal ictal entre 512 e 1024 (Figura 10) observa-se que:



**Figura 10– Sinal ictal de 512 a 1024 e escalograma**  
**Fonte: os Autores (2023)**

Para o sinal têm-se os seguintes valores estatísticos:

- Maior valor do sinal = 1086
- Média do sinal = -7,893
- Mediana do sinal = 81
- Desvio padrão do sinal = 519,10
- Relação sinal-ruído = -0,015

E para o escalograma têm-se:

- Maior valor do escalograma = 15256,14
- Menor valor do escalograma = 0,0036
- Média do sinal = 303714,07

Pode-se perceber a notável diferença de energia entre os escalogramas do sinal normal e do sinal ictal dada a diferença na variação da frequência.

### 3. Conclusão

De acordo com o estudo dos dois diferentes sinais, conclui-se que a transformada wavelet contínua é uma importante ferramenta para a análise de sinais como EEG, e por meio dela pode-se estudar as diferenças em ambos os sinais, estudando os parâmetros estatísticos mais importantes e coletando-os para que possam ser usados em estudos posteriores, o que pode nos indicar uma maior chance de tratar uma crise epilética ou em prevenir crises epiléticas mais graves.

No estudo realizado percebe-se como pode-se fazer melhores comparações, usando os parâmetros coletados do escalograma, pois parte do estudo deve-se a uma pesquisa para saber quais os melhores dados para tais comparações entre os sinais normais e ictais. Com esse estudo em mãos pode-se criar, por exemplo, um serviço cognitivo capaz de definir precisamente o começo de uma crise epilética.

### **Agradecimentos**

Um agradecimento especial ao PIBIC, pelo auxílio financeiro, a qual permitiu a realização da pesquisa.

### **Referências**

- Ocaziones, S. A. C. (2009). Processamento no domínio da frequência de sinais de eletroencefalografia coletados durante protocolo de estresse moderado. Dissertação de mestrado, Universidade de Brasília, Brasília, Brasil.
- Henrique, J. (2011) Uso do eletroencefalograma e instrumentação virtual para análise do perfil do sono, Tese de graduação, UNESP, SP, Brasil.
- Conci, A, *et al.* (2018). Computação Gráfica Teoria e Prática Volume 2. Alta Books.
- Najarian, K. and Splinter, R. (2012). Biomedical Signal and Image. CRC press.
- ENSUS (2016). Análise de Vibração – Tipos de Sinais, Transformada de Fourier e PSD.
- Magrini, L. A. (2020). Funções wavelet e transformada wavelet contínua: representação simultânea nos domínios do tempo e da frequência. C.Q.D. – Revista Eletrônica Paulista de Matemática, Bauru, v. 19. DOI: 10.21167/cqdv19202023169664lam1732.
- Hagar, A. A, *et al.*, (2022). Wavelet Transform Processor Based Surface Acoustic Wave Devices, *Energies* 2022, DOI: <https://doi.org/10.3390/en15238986>
- Vargas, D. L.; Oliva, J. T.; Teixeira, Marcelo (2021). Uma abordagem baseada em redes neurais artificiais sobre o espectro de potência de eletroencefalogramas para o auxílio médico na classificação de crises epiléticas. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE (SBCAS), 21. Evento Online. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, p. 141-152. ISSN 2763-8952. DOI: <https://doi.org/10.5753/sbcas.2021.16060>.