



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE  
CENTRO DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA



Trabalho de Conclusão de Curso

**CLASSIFICAÇÃO DE SINAIS DE EEG EM ATIVIDADES DE  
IMAGÉTICA MOTORA COM A TRANSFORMADA WAVELET**

Rodrigo Henrique Oliveira do Amaral

Natal/RN

2019

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

**CLASSIFICAÇÃO DE SINAIS DE EEG EM ATIVIDADES DE  
IMAGÉTICA MOTORA COM A TRANSFORMADA WAVELET**

Trabalho de conclusão de curso apresentado ao  
Departamento de Engenharia Biomédica da  
Universidade Federal do Rio Grande do Norte  
para obtenção do título de Graduado em  
Engenharia Biomédica.

Graduando: Rodrigo Henrique Oliveira do Amaral

Orientador: Professor Dr. Danilo Alves Pinto Nagem

Natal/RN

2019

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

**CLASSIFICAÇÃO DE SINAIS DE EEG EM ATIVIDADES DE  
IMAGÉTICA MOTORA COM A TRANSFORMADA WAVELET**

Banca Examinadora do Trabalho de Conclusão de Curso:

Prof. Dr. Danilo Alves Pinto Nagem

\_\_\_\_\_

UFRN - Orientador

Profª. Dra. Heliana Bezerra Soares

\_\_\_\_\_

UFRN – Avaliadora Interna

Prof. Dr. Luiz Gonzaga de Queiroz  
Silveira Júnior

\_\_\_\_\_

UFRN – Avaliador Interno

Natal/RN

2019

## **AGRADECIMENTOS**

Agradeço a todos os professores que fizeram parte da minha trajetória acadêmica nos cursos de Ciências e Tecnologia e Engenharia Biomédica, que aperfeiçoaram os meus conhecimentos e me permitiram aprender o que sei hoje.

Ao meu orientador, Prof. Dr. Danilo Alves Pinto Nagem, por me orientar, me tranquilizar nos momentos que as coisas deram errado e por toda a sua paciência.

À minha família, por despertar em mim o interesse pela leitura e a busca pelo conhecimento, e por proporcionar todo o suporte necessário para esta jornada.

A todos os meus amigos, os Blackthorn, os Oompa-Loompas da Ciência, os Biolindos e os Anatomonitores, por estarem presentes nesta trajetória, desde os momentos de estudo até os momentos de descontração.

## SUMÁRIO

LISTA DE FIGURAS	VI
LISTA DE TABELAS	VII
LISTA DE ABREVIACÕES, SIGLAS E SÍMBOLOS	VIII
RESUMO	IX
ABSTRACT	X
1. INTRODUÇÃO	1
2. OBJETIVOS	3
2.1. GERAL	3
2.2. ESPECÍFICOS	3
3. REVISÃO BIBLIOGRÁFICA	4
3.1. ELETROENCEFALOGRAFIA	4
3.1.1. FISIOLOGIA DO POTENCIAL DO NEURÔNIO	4
3.1.2. DESCRIÇÃO DO SINAL	5
3.2. IMAGÉTICA MOTORA	6
3.3. HOMÚNCULO DE PENFIELD	6
3.4. AQUISIÇÃO DO SINAL	7
3.4.1. ARTEFATOS	9
3.5. PROCESSAMENTO DO SINAL	9
3.5.1. TRANSFORMADA DE FOURIER	9
3.5.2. TRANSFORMADA <i>WAVELET</i>	10
3.5.3. CLASSIFICAÇÃO DO SINAL	12
4. METODOLOGIA	13
4.1. BANCO DE DADOS	13
4.2. FERRAMENTA DE DESENVOLVIMENTO	13
4.3. SEPARAÇÃO DO SINAL	13

4.4. FILTRAGEM	14
4.5. TRANSFORMADA WAVELET	16
4.6. CLASSIFICAÇÃO	18
5. RESULTADOS E DISCUSSÕES	19
5.1. RESULTADOS	19
5.2. DIFERENÇAS ENTRE BANDAS	20
5.3. COMPARAÇÃO COM OUTROS TRABALHOS	20
5.4. APLICAÇÕES	21
6. CONCLUSÕES	23
7. REFERÊNCIAS	24

## LISTA DE FIGURAS

Figura 1 - A Sinapse Química	5
Figura 2 - Bandas de Frequência do Sinal Cerebral	6
Figura 3 - Mapeamento do Córtex Motor e Córtex Somatossensorial	7
Figura 4 - Sistema 10-20	8
Figura 5 - A Transformada de Fourier	10
Figura 6 - As <i>Wavelets</i> Daubechies	11
Figura 7 - Sinal Após Três Segundos	14
Figura 8 - Resposta do Filtro <i>Butterworth</i> Passa-Banda	15
Figura 9 - FT do Sinal	16
Figura 10 - DWT do Sinal	17

## **LISTA DE TABELAS**

Tabela 1 - Resultados	19
Tabela 2 - Comparação com Outros Classificadores	21



## LISTA DE ABREVIACOES, SIGLAS E SMBOLOS

Db4 - Daubechies 4

DWT - Transformada Discreta de *Wavelet*

EEG - Eletroencefalografia

FT - Transformada de Fourier

ICM - Interfaces crebro-mquina

KNN - k vizinhos prximos

RMS - Raiz Quadrtica Mdia

WT - Transformada de *Wavelet*

AMARAL, Rodrigo Henrique Oliveira do. **Classificação de sinais de EEG em atividades de imagética motora com a transformada *wavelet***. Trabalho de Conclusão de Curso, Graduação em Engenharia Biomédica, Universidade Federal do Rio Grande do Norte, 38p., 2019.

## RESUMO

As interfaces cérebro-máquina são ferramentas para controle de aparelhos e comunicação que recebem informações diretamente do cérebro, e para isso essas informações devem ser processadas e classificadas. O propósito deste trabalho é criar um classificador capaz de diferenciar a imagética motora dos movimentos das mãos direita e esquerda com apenas dois eletrodos utilizados como fonte de informações, C3 e C4. Foram utilizados a base de dados Graz2003 e o software MATLAB para o processamento. As características dos sinais escolhidas para a classificação foram os coeficientes *wavelet*, uma vez que eles representam o sinal de forma eficaz. Após a extração dos coeficientes com a Transformada Discreta de *Wavelet* e remoção de características, foram criados dois tipos de classificadores, um envolvendo as bandas de frequência alfa e beta e uma apenas a beta. Ambos os classificadores do tipo k vizinhos próximos. Como resultados, o classificador com informações da banda beta apresentou acurácia mais significativa, 85% de acertos para sinais não vistos. Pôde-se observar que é possível criar um classificador acurado utilizando apenas dois eletrodos como fonte de informação, e que a banda beta foi levemente superior para a classificação de imagética motora com *feedback* visual.

**Palavras-chave:** Eletroencefalografia, Imagética Motora, Transformada *Wavelet*, Classificação por k Vizinhos Próximos.

AMARAL, Rodrigo Henrique Oliveira do. **EEG signal classification in motor imagery activities with wavelet transform.** Conclusion Work Project, Biomedical Engineering Bachelor Degree, Federal University of Rio Grande do Norte, 38p., 2019.

## **ABSTRACT**

Brain-machine interfaces are tools for controlling devices and communication that receive information directly from the brain, and for that information must be processed and classified. The aim of this work is to create a classifier capable of differentiating motor imagery from right and left hand movements with only two electrodes used as source of information, C3 and C4. The Graz2003 database and the software MATLAB for processing were used. The characteristics of the signals chosen for the classification were the wavelet coefficients, since they represent the signal effectively. After the extraction of coefficients with the Discrete Wavelet Transform and detection of the features, two types of classifiers were created, one involving the alpha and beta frequency bands and one with beta only. Both classifiers types were k nearest neighbors. As results, the classifier with beta band information presented the most significant accuracy, 85% for unseen signals. It could be observed that it is possible to create an accurate classifier using only two electrodes as source of information, and that the beta band was slightly superior for the classification of motor imagery with visual feedback.

**Key-words:** Electroencephalography, Motor Imagery, Wavelet Transform, K Nearest Neighbors Classification.

# 1. INTRODUÇÃO

As interfaces cérebro-máquina (ICM) são uma forma de comunicação entre eletrodos e aparelhos, geralmente computadores, as quais extraem e decodificam informações originadas do sistema nervoso e as transformam em uma resposta funcional (KRUCOFF *et al.*, 2016). Essa resposta pode ter diversos objetivos, mas as principais funções das ICM estão voltadas para controlar áreas motoras lesionadas na forma de tecnologias assistivas, facilitar a aprendizagem motora e plasticidade neural na forma de aparelhos para reabilitação, ou como forma de comunicação para pacientes que perderam sua capacidade de se movimentar (KRUCOFF *et al.*, 2016; CHAUDHARY; BIRBAUMER; CURADO, 2015). Um dos principais componentes das ICM é o método de captura de sinais neurais, que pode variar bastante: do menos invasivo eletrodo superficial no couro cabeludo até os eletrodos implantáveis.

Como esperado, um dos componentes de captura mais utilizado é o eletrodo superficial de eletroencefalografia (EEG). Além de possuir um grande destaque em aplicações clínicas no diagnóstico e acompanhamento dos distúrbios funcionais do cérebro (NAJARIAN; SPLINTER, 2012), os avanços da EEG tornaram possível o seu uso tanto na análise da atividade do sistema nervoso durante a utilização de ICM quanto para fornecer algum tipo de *feedback* para o paciente nesse tempo (BHAGAT *et al.*, 2016). Além disso, a EEG é um modo seguro e rápido de capturar as informações elétricas do córtex cerebral como um todo, sem que sejam necessárias cirurgias ou outros procedimentos invasivos.

Apesar disso, a técnica de EEG possui uma baixa resolução espacial. Isso ocorre porque a fonte que emite os sinais — a superfície do cérebro — está separado do eletrodo de captação por outros tecidos, como as meninges e o próprio crânio. Devido a isso, as atividades cerebrais captadas pelo EEG podem ser relativamente difíceis de se classificar. A utilização de mais canais de eletrodos pode ser uma forma de vencer essa dificuldade, e tradicionalmente são utilizados de 14 a 32 ou 64 eletrodos para este fim. Uma grande quantidade de canais, porém, pode introduzir informações redundantes ou desnecessárias para o classificador,

além de demandar um maior processamento e necessitar de mais tempo de preparação (ARVANEH *et al.*, 2011). A utilização de um número reduzido de eletrodos facilita tanto o processamento quanto a colocação dos eletrodos, e permite uma ICM mais amigável para o indivíduo (CAMACHO; MANIAN, 2016).

As informações dos eletrodos são enviadas aos classificadores, que são aqueles responsáveis por definir a resposta ao estímulo. Quanto mais acurados eles são, menor a chance de erros de classificação. Uma das formas de classificar sinais é utilizando informações de amplitude e frequência, o que geralmente é feito com a Transformada de Fourier (FT). Mas a passagem para o domínio da frequência com a FT faz com que as informações de tempo do sinal sejam perdidas, e essas informações aumentam a performance do classificador para os sinais de EEG. A Transformada Discreta de *Wavelet* (DWT) permite a decomposição do sinal na frequência ainda mantendo as informações no tempo, e por isso é uma ferramenta mais interessante para a extração de padrões (PATTNAIK; DASH; SABUT, 2016).

## 2. OBJETIVOS

### 2.1. GERAL

Este estudo tem como objetivo a criação de um classificador KNN para separar em duas classes os sinais de EEG de imagética motora das mãos direita e esquerda utilizando os coeficientes da DWT como fonte das características do sinal. Além disso, pretende-se realizar essa classificação utilizando como fonte de informação apenas os eletrodos C3 e C4 no sistema 10-20 de EEG.

### 2.2. ESPECÍFICOS

Os objetivos específicos deste estudo são:

- Compreender a classificação de sinais e a Transformada *Wavelet*;
- Fazer um referencial bibliográfico;
- Estudar técnicas de processamento de sinais;
- Encontrar uma base de dados adequada e entendê-la;
- Realizar a análise do sinal;
- Extrair informações relevantes dos coeficientes *wavelet*;
- Criar um classificador com apenas dois eletrodos de captação;
- Comparar diferentes formas de classificar o sinal a partir de diferentes faixas de frequência;
- Realizar testes com o classificador.

### **3. REVISÃO BIBLIOGRÁFICA**

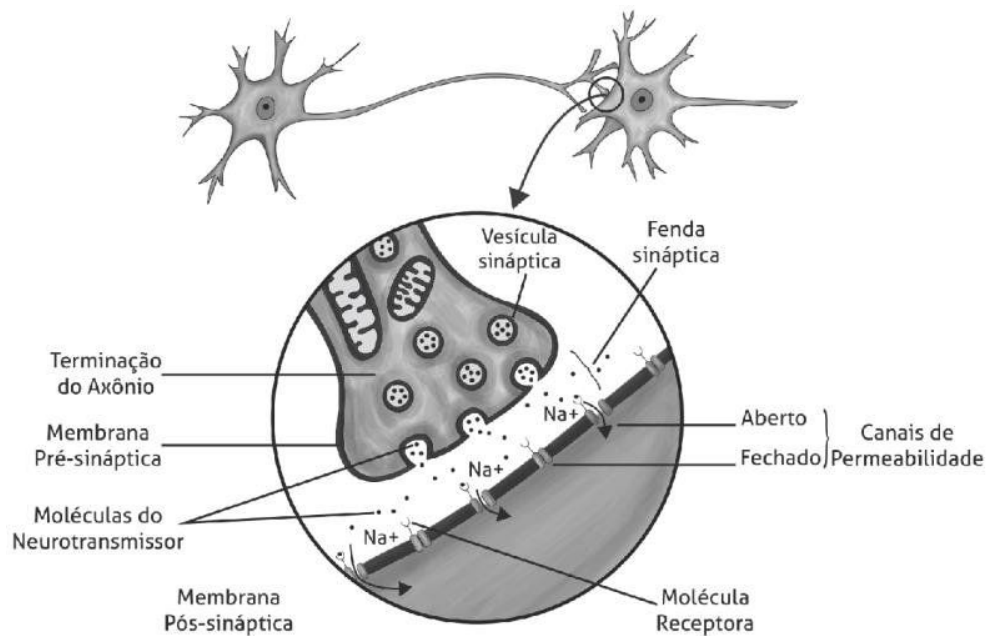
#### **3.1. ELETROENCEFALOGRAFIA**

O eletroencefalograma é uma representação gráfica das funções elétricas do cérebro, que reflete a diferença de potencial no tempo entre as duas regiões corticais que estão mais próximas do eletrodo. A EEG engloba também o estudo desses sinais, promovendo uma avaliação geral da atividade elétricas cerebrais. Os potenciais elétricos adquiridos indiretamente por meio do couro cabeludo permitem análises de frequência, forma de onda, voltagem, morfologia e topografia (TATUM *et al.*, 2008).

##### **3.1.1. FISILOGIA DO POTENCIAL DO NEURÔNIO**

Os sinais elétricos captados pelos eletrodos são criados quando cargas elétricas se movem no cérebro na forma de gradientes iônicos estabelecidos pelas membranas dos neurônios, como pode ser visto em uma sinapse química na Figura 1. Um potencial de repouso da membrana existe por meio da entrada de íons Potássio até um equilíbrio eletroquímico de -75 milivolts. Com a entrada de íons Sódio e uma despolarização acima do limiar do repouso, a condução para porções adjacentes resulta no potencial de ação. Apesar disso, é o potencial sináptico o de maior relevância na corrente extracelular que produz o sinal de EEG (TATUM *et al.*, 2008). Quando a despolarização chega ao botão sináptico, canais de íons Cálcio se abrem e ocorre a liberação de neurotransmissores na fenda sináptica, que resulta na passagem de íons para o neurônio e um potencial pós sináptico. As camadas de neurônios e suas sinapses são a principal fonte do EEG (TATUM *et al.*, 2008).

**Figura 1 - A Sinapse Química**



Fonte: FREITAS *et al.*, 2017

### 3.1.2. DESCRIÇÃO DO SINAL


Diversos aspectos devem ser levados em conta ao se descrever o sinal eletroencefalográfico. Um dos mais conhecidos é o aspecto da frequência. A EEG pode ser dividida em diferentes bandas de frequência, cada uma representando diferentes situações. Uma representação gráfica delas pode ser vista na Figura 2. São elas:

- Ondas delta ( $\delta$ ): 0,5 – 3,5 Hz
- Ondas teta ( $\theta$ ): 3,5 – 7,5 Hz
- Ondas alfa ( $\alpha$ ): 7,5 – 13 Hz
- Ondas beta ( $\beta$ ): 13 – 40 Hz

Algumas outras formas de descrever a EEG é de acordo com a sua amplitude, a forma dos potenciais, a sua expressão, a sua simetria, entre outros (NAJARIAN; SPLINTER, 2012).



**Figura 2 - Bandas de Frequência do Sinal Cerebral**



Fonte: NAJARIAN; SPLINTER, 2012

### **3.2. IMAGÉTICA MOTORA**

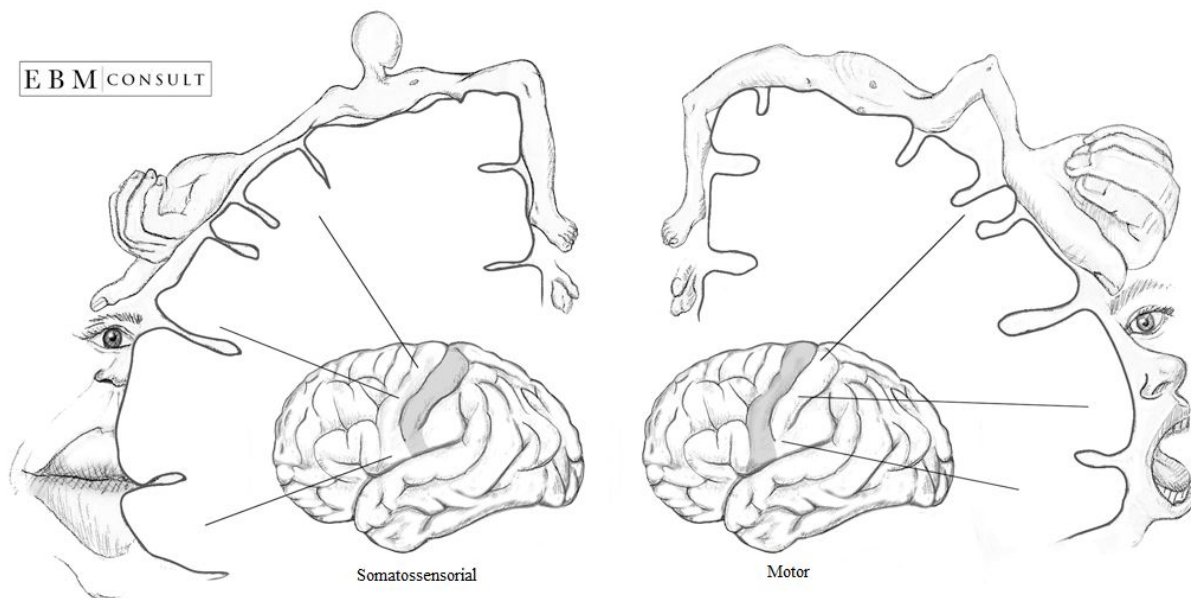
A imagética motora é um processo mental que envolve a imaginação da realização de uma ação, de forma que o indivíduo deve fazer uma simulação de si mesmo na prática imaginada. Durante as atividades envolvendo imagética motora, observa-se que a duração de tempo dos movimentos é alterada na mesma proporção dos movimentos físicos. Isso significa que movimentos mais complexos duram mais tempo, seja na prática física ou na imagética. Outra propriedade da imagética é que ela depende da integridade das estruturas motoras do cérebro, mas ainda assim é possível observá-la em pacientes com lesões cerebrais que afetam o sistema motor, mesmo que a performance seja afetada. Além disso, também é observado que as frequências cardíaca e respiratória podem aumentar como resposta a atividades de imagética motora (JACKSON *et al.*, 2001).

### **3.3. HOMÚNCULO DE PENFIELD**

O neurocirurgião Wilder Graves Penfield descobriu que os giros pré-central e pós-central, responsáveis pelo comportamento motor primário e somatossensorial primário respectivamente, possuem regiões bem mapeadas de atuação. Isso

significa que diferentes locais no córtex são responsáveis por diferentes regiões no corpo, e isso pode ser observado com eletroestimulação (PENFIELD; BOLDREY, 1937). A partir desta descoberta foi criado um mapa com um homúnculo cujo corpo está distribuído para cada região cortical responsável, que pode ser visto na Figura 3. A partir deste mapa é possível descobrir quais regiões estão sendo ativadas em um dado momento utilizando sistemas de captura de sinais cerebrais, como o EEG.

**Figura 3 - Mapeamento do Córtex Motor e Córtex Somatossensorial**



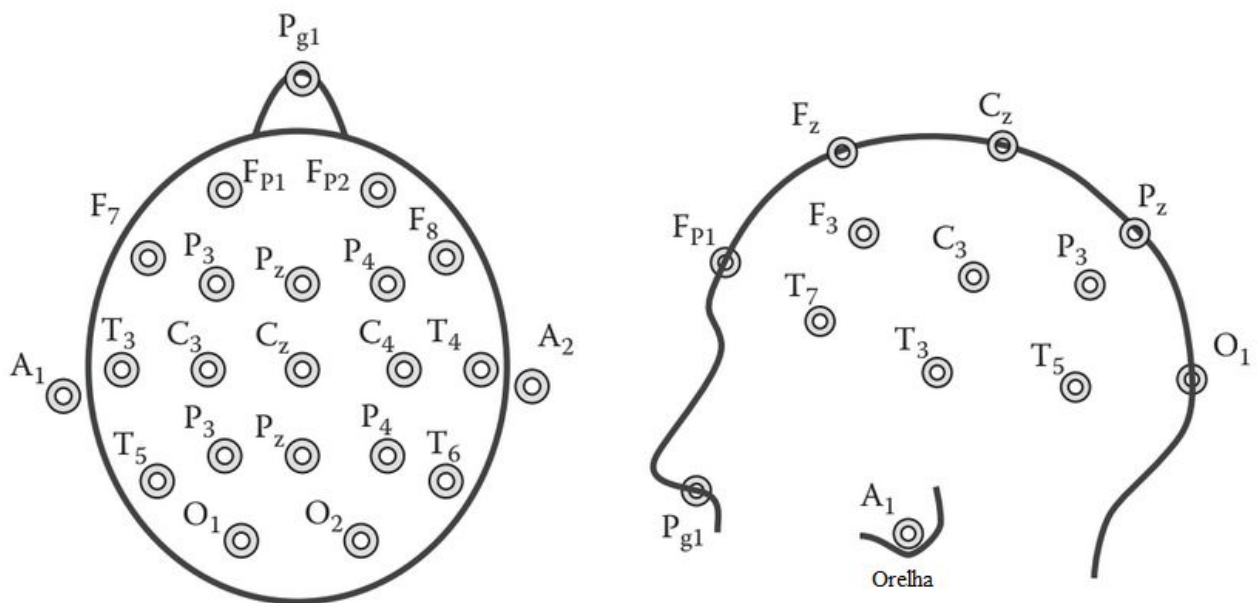
Fonte: Adaptado de EBM CONSULT, 2019

### 3.4. AQUISIÇÃO DO SINAL

O sinal de EEG é adquirido através de eletrodos de superfície colocados no couro cabeludo. Diferentes posições dos eletrodos entre si e em relação ao crânio irão provocar resultados diferentes. Diferenças com relação a voltagem, por exemplo, aumentam quanto maior for as distâncias entre eletrodos. Para isso existem padrões, e o padrão mais conhecido de EEG é o 10-20, que pode ser visto na Figura 4. Nele, os eletrodos são posicionados em dois passos (NAJARIAN; SPLINTER, 2012):

1. As medidas longitudinais são feitas do náseo ao ínio, e as transversais da orelha esquerda à orelha direita. Mede-se também as circunferências cranianas ao nível Fz e Oz e dos eletrodos temporais;
2. As distâncias são determinadas entre os eletrodos a partir da divisão em etapas de 10 e 20%.

Figura 4 - Sistema 10-20



Fonte: NAJARIAN; SPLINTER, 2012

Existe também um padrão de nomenclatura dos locais de aplicação dos eletrodos, sendo eles (NAJARIAN; SPLINTER, 2012):

- F — Frontal;
- C — Central
- T — Temporal;
- P — Parietal;
- O — Occipital.

### 3.4.1. ARTEFATOS

Os artefatos são interferências no sinal eletroencefalográfico causadas por qualquer outra fonte senão o sinal cerebral (NAJARIAN; SPLINTER, 2012). Eles podem ser adquiridos pelo sinal de EEG de diversas maneiras, e são divididos em dois grupos principais: os exógenos e os biogênicos. Os artefatos exógenos são aqueles de natureza técnica, como uma falha ligação térrea, eletrodos mal posicionados ou defeituosos, por indução eletrostática ou até mesmo a presença de um marcapasso cardíaco. Já os artefatos biogênicos são originados no próprio corpo do paciente, podendo ser musculares, bulbo-palpebrais ou cardíacas, além das interferências causadas por sudorese, tremores e movimentos (NAJARIAN; SPLINTER, 2012).

Os diferentes tipos de artefatos podem ser eliminados de diferentes maneiras. As práticas de boa colocação de eletrodos e instruir o indivíduo a não se mover já eliminam alguns possíveis artefatos. Outros não são evitados de forma tão simples, e necessitam de filtros para serem removidos. Um sinal com altas frequências, por exemplo, muitas vezes pode ter ruídos de alta frequência, e para resolver isso é necessário que seja passado um filtro passa-baixa no sinal (NAJARIAN; SPLINTER, 2012). Os filtros passa-baixa atenuam parte do sinal cuja frequência encontra-se superior a determinado valor, enquanto os passa-alta fazem o contrário. Já os filtros passa-banda são o conjunto entre os passa-baixa e passa-alta. A filtragem geralmente é feita em conjunto com a Transformada de Fourier.

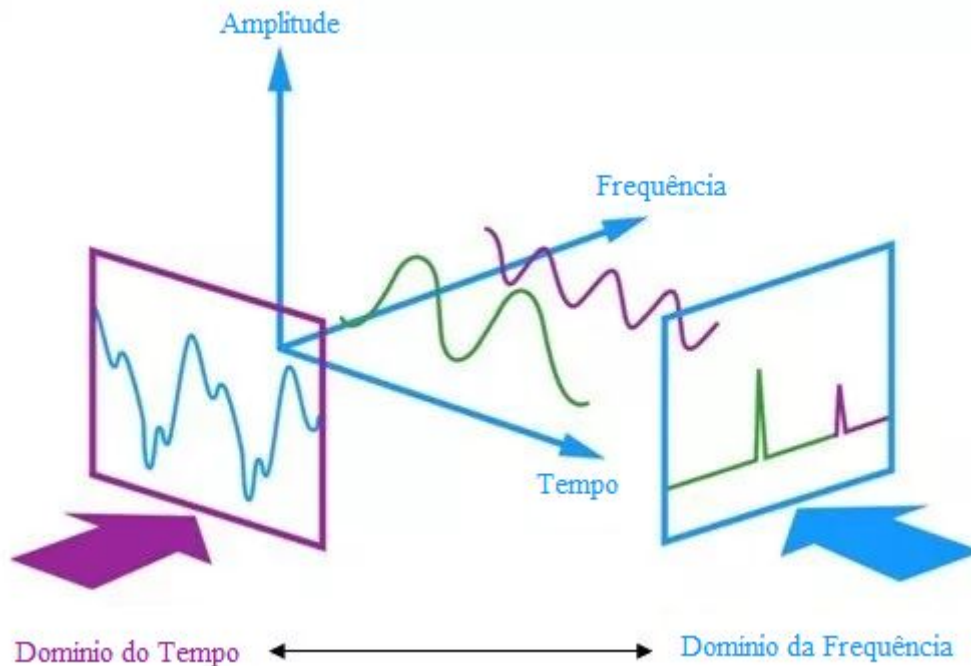
## 3.5. PROCESSAMENTO DO SINAL

### 3.5.1. TRANSFORMADA DE FOURIER

Um sinal pode ser representado de diversas formas em diferentes domínios. Os sinais representados no tempo, como são vistos normalmente, respondem a “quando” os eventos ocorrem. Já os sinais representados no domínio da frequência respondem a “com que frequência” eles ocorrem. A Transformada de Fourier (FT) é responsável por transformar sinais no domínio do tempo para o domínio da

frequência, enquanto sua inversa faz o oposto (NAJARIAN; SPLINTER, 2012). Uma representação gráfica da transformada pode ser vista na Figura 5.

Figura 5 - A Transformada de Fourier



Fonte: Adaptado de MAKING IT UP, 2017


Uma vez que toda a informação no tempo é perdida na FT, seu uso em sinais de EEG pode ser limitado. Se a FT for aplicada a segmentos sucessivos de um sinal eletroencefalográfico, é possível observar que os espectros de frequência obtidos variam com o tempo, o que indica que o sinal de EEG é um sinal não estacionário, e análises com a FT, em geral, assumem que o sinal é estacionário. Com isso, é possível perceber que as características de tempo e de frequência são ambas bastante importantes no sinal de EEG (AKIN, 2002).

### 3.5.2. TRANSFORMADA *WAVELET*

As *wavelets* são funções que oscilam por um curto período de tempo. Elas possuem um valor médio de zero e geralmente são irregulares e assimétricas. Diferentemente da FT, que transforma o sinal em uma combinação ponderada de senoides de diferentes frequências, a Transformada de *Wavelet* (WT) transforma o

signal em uma combinação ponderada de versões de diferentes escalas e posições da *wavelet* original, a *wavelet-mãe*. Dessa forma, a análise com *wavelets* significa que o sinal será comparado com uma *wavelet-mãe* que será esticada ou comprimida e atrasada ou adiantada diversas vezes (MISITI *et al.*, 2009). Existem vários tipos de *wavelet-mãe*, um exemplo a seguir são as *wavelets* de Daubechies:

Figura 6 - As *Wavelets* Daubechies



Fonte: MISITI *et al.*, 2009

A Transformada Discreta de *Wavelet* (DWT) possui como entrada um sinal contínuo e realiza as alterações em escala e posição apenas de forma discreta. Para que isso seja feito, definindo

$$a_{jk} = a_0^j, b_{jk} = ka_0^j T$$

como o tempo de amostragem e uma constante positiva não nula respectivamente, e

$$\Psi_{jk}(t) = a_0^{-j/2} \Psi(a_0^{-j} t - kT),$$

em que  $\Psi(t)$  é a *wavelet-mãe*,  $0 \leq j \leq N-1$  e  $0 \leq k \leq M-1$ , os coeficientes são calculados da seguinte maneira (NAJARIAN; SPLINTER, 2012):

$$W_{jk} = \int_{-\infty}^{\infty} x(t) \Psi_{jk}^*(t) dt$$

Computacionalmente, o primeiro passo da WT produz dois conjuntos de coeficientes, os de aproximação e os de detalhe. Eles são obtidos ao se passar um filtro passa-baixa e passa alta, respectivamente (MISITI et al., 2009). Esse processo é a primeira decomposição do sinal. Múltiplas decomposições realizam as mesmas etapas, subamostrando o sinal a um nível de dois cada vez, mas sem perder as informações anteriores.

Entre as aplicações da WT, uma das principais é a realização de análises locais, pois as *wavelets* são capazes de revelar aspectos do sinal que outras técnicas podem deixar passar, como tendências, pontos de ruptura e descontinuidades. A WT também permite a compressão de sinais e imagens e a remoção de ruídos (MISITI et al., 2009). Além disso, com os coeficientes *wavelet* é possível transformar o sinal em um conjunto de características. Mesmo o sinal de EEG, com todas as suas informações, pode ser descrito através dessas características. Com isso, é possível utilizar a WT para reconhecimento de padrões e classificação de sinais (GÜLER; ÜBEYLI, 2005).

### 3.5.3. CLASSIFICAÇÃO DO SINAL

Para realizar a classificação devem existir exemplos de dois ou mais grupos de objetos. Um classificador é então treinado com os exemplos cujos grupos já estão determinados. Dessa forma, será criado um conjunto de regras ou um modelo matemático que podem ser usados em exemplos cujos grupos não são conhecidos. O classificador irá, então, rotular os exemplos em seus respectivos grupos. Os primeiros exemplos usados no classificador são considerados o seu treinamento, e aqueles usados para determinar a acurácia do classificador são os exemplos de teste. Quando os exemplos de teste já são conhecidos, a aprendizagem do classificador é considerada como supervisionada (NAJARIAN; SPLINTER, 2012).

## 4. METODOLOGIA

### 4.1. BANCO DE DADOS

Os sinais de EEG utilizados foram adquiridos do banco de dados Graz2003, do BCI Competition II (BBCI, 2003). O sinal foi gravado de um sujeito normal (25F) em uma sessão com uso de *feedback*. Ela estava sentada em uma cadeira confortável com apoio para os braços enquanto o sistema informava se a imagética seria direita ou esquerda de forma aleatória. O teste foi realizado sete vezes com 40 tentativas em cada, com vários minutos entre eles, para um total de 280 tentativas de 9 segundos cada. Em  $t = 2s$  uma cruz era mostrada por 1s, e em  $t=3s$  uma seta era mostrada na tela indicando o lado que ela deveria mover a barra com a imagética motora. Todos os sinais foram captados com uma frequência de amostragem de 128 Hz.

Uma frequência de amostragem de 128 Hz, segundo o teorema de Nyquist, permite uma análise do sinal envolvendo frequências de até 64 Hz, pois é a metade da frequência de captação. Uma vez que a análise é feita para até 32 Hz, a frequência de amostragem não foi um problema.

### 4.2. FERRAMENTA DE DESENVOLVIMENTO

O processamento do sinal foi feito utilizando o MATLAB R2017a, assim como as funções presentes na *Signal Processing Toolbox* e na *Wavelet Toolbox*. Esse *software* foi escolhido devido ao seu poder de processamento e suas aplicações voltadas à análise de sinais e funções envolvendo a WT (MATHWORKS, 2019).


### 4.3. SEPARAÇÃO DO SINAL

Inicialmente, os três primeiros segundos, que não continham as informações de imagética motora, foram removidos de todos os sinais de C3 e C4. A Figura 7 mostra uma imagem do primeiro sinal não filtrado. As informações de Cz não foram



utilizadas, pois C3 e C4 já representam a imagética motora das mãos direita e esquerda do córtex sensorimotor. Foram utilizados os 100 primeiros sinais de treino para a criação do classificador para facilitar o processamento computacional. Uma vez com os 100 sinais de 6 segundos cada de ambos os eletrodos C3 e C4, o próximo passo é a filtragem deles.

**Figura 7 - Sinal Após Três Segundos**

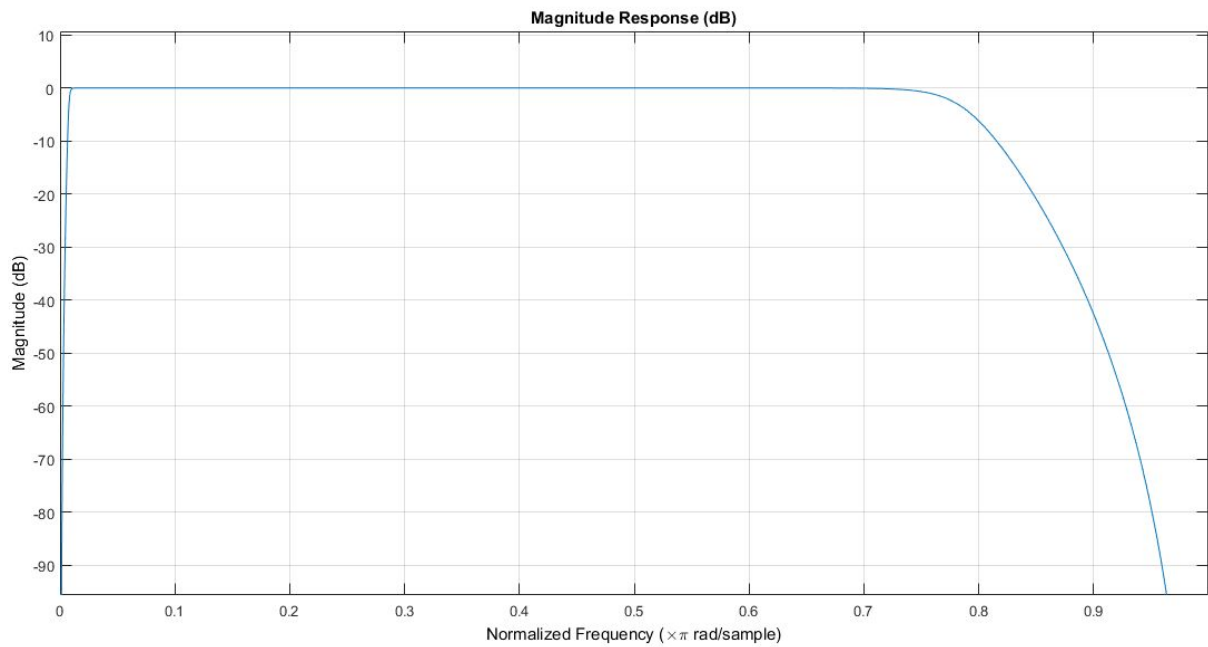


Fonte: Produzido pelo autor

#### **4.4. FILTRAGEM**

Foi criado um filtro *Butterworth* passa-banda entre 0,5 e 50 Hz para ser utilizado em todos os 100 sinais de treino, de forma que o filtro removeu todas as frequências abaixo de 0,5 e acima de 50 Hz. Essas frequências foram escolhidas porque a região de interesse do EEG encontra-se dentro dessa banda. Uma imagem da resposta de magnitude do filtro pode ser vista a seguir.

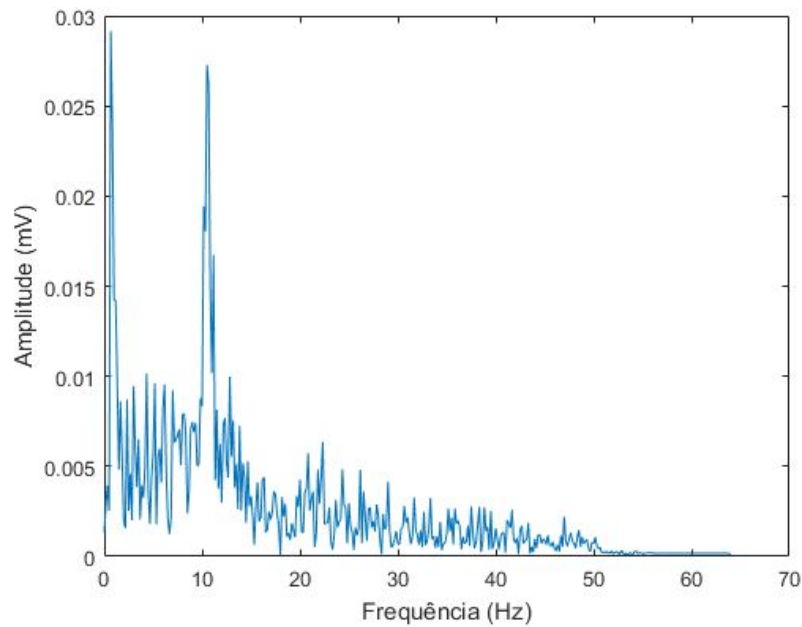
**Figura 8 - Resposta do Filtro *Butterworth* Passa-Banda**



Fonte: Produzido pelo autor

Para verificar o efeito do filtro passado no sinal, realizou-se a FT no primeiro sinal do treinamento. A transformação do sinal para o domínio da frequência mostra quais delas foram atenuadas pelo filtro. Pode-se observar no gráfico abaixo que todas as frequências muito próximas ao valor de zero ou acima de 50 Hz foram atenuadas, o que comprova a efetividade do filtro.

**Figura 9 - FT do Sinal**



Fonte: Produzido pelo autor


#### **4.5. TRANSFORMADA *WAVELET***

Após a filtragem dos dados, o próximo passo foi realizar a transformada. A DWT é feita passando um sinal por um conjunto de filtros passa-alta e passa-baixa para que os coeficientes *wavelet* possam ser calculados. Foram realizadas quatro decomposições com as *wavelets* Daubechies 4 (db4), cada uma captando os coeficientes de detalhe de metade das frequências do sinal até que o último extraiu o coeficiente de detalhe da metade com maior frequência e o coeficiente de aproximação da de menor frequência. Dessa forma, as bandas de frequência de cada nível ficaram da seguinte forma:

- 64–128;
- 32–64;
- 16–32;
- 8–16 e
- 0-8.

Sendo a última delas a banda representando os coeficientes de aproximação. Uma vez realizada a DWT, os gráficos para cada banda de frequência no tempo e amplitude poderiam ser visualizados. A seguir, na Figura 10, pode-se observar as diferentes bandas para o primeiro sinal do treinamento.

Figura 10 - DWT do sinal



Fonte: Produzido pelo autor

Pode-se observar que a banda de frequência que não foi englobada pelo filtro passa-banda,  $d_1$ , possui uma amplitude bastante reduzida.

Após o cálculo dos coeficientes wavelet, foi possível extrair as características para treinar o classificador. A partir deste ponto, o trabalho foi dividido em dois: foram realizados os procedimentos para a banda  $d_3$ , com os coeficientes das regiões dos sinais entre 16–32 Hz, e para as bandas  $d_3$  e  $d_4$  em conjunto, totalizando as regiões entre 8–32 Hz. Dessa forma, foi possível captar as ondas

beta e alfa e beta respectivamente. Isso foi feito para analisar qual das duas opções resulta em um classificador mais acurado. Ambas as opções utilizam as informações dos eletrodos C3 e C4.

Os coeficientes foram então separados e, para cada um, realizou-se um cálculo de média e um cálculo de potência do sinal. O cálculo de potência é feito através da raiz quadrática média (RMS) do sinal:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$$

Foram escolhidas essas duas características devido a sua simplicidade em relação ao poder computacional necessário para o cálculo e devido a sua eficácia na representação de sinais para classificação.

#### 4.6. CLASSIFICAÇÃO

Por fim, os classificadores foram treinados com o método de k vizinhos próximos (KNN) com os dois conjuntos de características. Esse método de classificação utiliza vetores de n dimensões para treinar. No caso da banda d3, esse vetor possui quatro dimensões, média e potência para ambos os eletrodos. Já para as bandas d3 e d4, o vetor possui oito dimensões, duas para cada banda por eletrodo. A partir desses vetores é possível calcular distâncias para cada uma das sessões e atribuir uma classe para cada uma delas. Para o propósito deste trabalho, as classes foram “direita” e “esquerda”, numeradas “1” e “2”, para o lado da imagética motora sendo realizado no momento.

As distâncias calculadas no classificador KNN foram distâncias euclidianas, e foram contabilizados 7 vizinhos próximos de cada sinal para a classificação. Esse valor de KNN foi escolhido a partir de testes com outros números, sendo 7 aquele que obteve melhor resultado.

## 5. RESULTADOS E DISCUSSÕES

### 5.1. RESULTADOS

Uma vez treinado, o classificador KNN foi capaz de calcular, para cada característica do sinal de entrada, sete vizinhos próximos e, a partir do número de vizinhos mais próximos de cada classe, definir a qual classe pertence o sinal. Como o número de classes é par, o resultado não poderia ser um empate, e a classe para a qual cada sinal é definido deve possuir pelo menos três vizinhos próximos das características do sinal de entrada.

Utilizando as funções do MATLAB feitas para a análise de classificadores, foi possível observar como cada um dos classificadores criados se comportaram. O primeiro deles, criado com os sinais encontrados entre a banda de frequência 16–32 Hz, em um primeiro teste para revelar sua performance em classificar os mesmos sinais usados no treinamento, mostrou uma taxa de acerto de 92%. Já a sua performance em classificar sinais ainda não vistos pelo classificador, sua acurácia foi de 85%.

Por sua vez, os segundo classificador, o qual utilizou os sinais presentes na banda de frequência 8–32 Hz, apresentou uma taxa de acerto de 89% para os sinais já treinados e 83% para os não utilizados no treinamento, como pode ser visto na tabela a seguir:

**Tabela 1 - Resultados**

	16–32 Hz	8–32 Hz
Sinais de treinamento	92%	89%
Sinais não vistos	85%	83%

## **5.2. DIFERENÇAS ENTRE BANDAS**

Pode-se observar nos resultados anteriores que o classificador envolvendo apenas a banda beta de ondas cerebrais obteve uma melhor performance do que aquele com as bandas beta e alfa, mesmo que a diferença tenha sido baixa. Foi possível observar que a banda alfa diminuiu a acurácia do classificador, mesmo sendo usada como informação extra. Processos que envolvem a simulação mental de ações estão associados com as oscilações na frequência em ambos os canais, alfa e beta. A diferença entre os dois é que a potência da oscilação na banda alfa aumenta na região do córtex sensorimotor ipsilateral da mão usada na imagética, enquanto a da banda beta diminui no hemisfério contralateral. Essas oscilações ocorrem nas diferentes bandas por diferentes motivos, e podem aparecer mais em simulações de ações com diferentes mecanismos (BRINKMAN *et al.*, 2014). Logo, a atividade maior na banda beta do trabalho em questão pode estar relacionada com o tipo de ação imaginada no momento dos testes. Pode-se dizer, no entanto, que a banda beta pode ser utilizada sozinha para a classificação de lados na atividade de imagética motora, do mesmo modo que a banda alfa, assim como as duas em conjunto. Além disso, o tipo de atividade imaginada deve ser levado em consideração nas práticas de imagética motora.

## **5.3. COMPARAÇÃO COM OUTROS TRABALHOS**

Esses resultados podem ser considerados satisfatórios, uma vez que o objetivo deste estudo foi fazer um classificador que utiliza baixo poder computacional para apenas dois eletrodos de captação. Ainda assim, o estado da arte na classificação de EEG de imagética motora já ultrapassa os valores dos resultados obtidos. Diversos trabalhos que englobam dois ou mais eletrodos feitos para a classificação de duas ou mais classes já supera a capacidade de classificação, apesar de a maioria dos outros ainda não atingir o valor de 85%, como pode ser visto na Tabela 2. A classificação de mais de duas classes é um

fator interessante que abre muitas possibilidades de aplicações para um classificador, mesmo que isso possa reduzir um pouco a sua acurácia.

Uma tabela comparando diferentes performances de classificadores que utilizam poucos eletrodos pode ser vista abaixo:

**Tabela 2 - Comparação com Outros Classificadores**

Autor	Nº de canais	Classificador	Acurácia
Método proposto	2	KNN	85%
Maswanganyi <i>et al.</i>	2	Análise Discriminante Linear	71,63%
		KNN	71,22%
		<i>Naive Bayes</i>	73,06%
		Árvore de decisão	72,84%
Siuly <i>et al.</i>	2	<i>Naive Bayes</i>	96,36%
Zhou <i>et al.</i>	3	Redes Neurais Artificiais	91,43%
Liu <i>et al.</i>	3	Limiarização por equilíbrio SPRT	85,9%
Kevric <i>et al.</i>	3	KNN	92,8
Taran e Bajaj	5	Máquina de vetores de suporte com mínimos quadrados	96,89

Pode-se observar na Tabela 2 que já existem métodos mais acurados do que o criado neste trabalho, ainda que eles utilizem um número maior de eletrodos ou uma forma de extração de características e classificação mais complexas. A utilização de cada um irá depender do objetivo final da aplicação.

#### 5.4. APLICAÇÕES

A utilização de classificadores para o uso em ICM tem diversas aplicações. Este trabalho foi idealizado com a ideia de criar um classificador que possa ser usado em um aparelho embarcado simples de captação e processamento de EEG



com poucos eletrodos, de forma a facilitar a captação e realizar o processamento e classificação ao mesmo tempo. A ideia é simplificar os aparelhos usados em pesquisas para transferir essa utilização para a vida cotidiana. A partir disso, o equipamento idealizado poderia, por exemplo, ser usado para o controle de um avatar em jogos envolvendo realidade virtual, o que já acontece de forma reduzida no campo da reabilitação e que ainda deve ser explorado no campo do entretenimento.

## 6. CONCLUSÕES

Uma vez que a tecnologia de ICM está cada vez maior, faz-se necessária a criação de classificadores cada vez mais simples e acurados para baratear os custos dessas máquinas e ampliar os usos dessas interfaces para englobar não apenas laboratórios de pesquisa, mas o dia a dia da população geral. O objetivo deste estudo era criar um classificador simples e acurado com apenas dois eletrodos usados como fonte de características do sinal, e pode-se afirmar que esse objetivo foi cumprido.

Foi possível criar um classificador KNN com 85% de acurácia utilizando características observadas dos coeficientes da DWT dos sinais dos eletrodos C3 e C4. Além disso, pode-se perceber que o nível computacional das análises realizadas é relativamente baixo, mas estudos futuros ainda devem ser realizados para quantificar esse fato. Com este trabalho foi possível perceber também que a atividade imaginada durante as práticas de imagética motora pode interferir na influência das bandas alfa e beta, mas também devem ser realizados estudos para comprovar esse fato.

Como trabalhos futuros, esse sistema de classificação deve ser atualizado para trabalhar em tempo real. Aplicações offline são utilizadas apenas para pesquisas, e uma ICM de uso cotidiano deve realizar suas tarefas em tempo real. Uma integração entre o classificador e um sistema atuador também deve ser realizada. A integração entre eletrodos, processamento e classificação e atuador irá compor uma ICM que, idealmente, poderá ser usada para controle de determinado dispositivo embarcado.

## 7. REFERÊNCIAS

AKIN, M. Comparison of Wavelet Transform and FFT Methods in the Analysis of EEG Signals. **Journal Of Medical Systems**, [s.l.], v. 26, n. 3, p.241-247, 2002. Springer Nature. <http://dx.doi.org/10.1023/a:1015075101937>.

ARVANEH, Mahnaz *et al.* Optimizing the Channel Selection and Classification Accuracy in EEG-Based BCI. **Ieee Transactions On Biomedical Engineering**, [s.l.], v. 58, n. 6, p.1865-1873, jun. 2011. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tbme.2011.2131142>.

BASHAR, Syed Khairul; BHUIYAN, Mohammed Imamul Hassan. Classification of motor imagery movements using multivariate empirical mode decomposition and short time Fourier transform based hybrid method. **Engineering Science And Technology, An International Journal**, [s.l.], v. 19, n. 3, p.1457-1464, set. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.jestch.2016.04.009>.

BBCI. BCI Competition II. Disponível em: <http://www.bbci.de/competition/ii/>. Acesso em 20 de março de 2019.

BHAGAT, Nikunj A. *et al.* Design and Optimization of an EEG-Based Brain Machine Interface (BMI) to an Upper-Limb Exoskeleton for Stroke Survivors. **Frontiers In Neuroscience**, [s.l.], v. 10, p.1-17, 31 mar. 2016. Frontiers Media SA. <http://dx.doi.org/10.3389/fnins.2016.00122>.

BHATTACHARYYA, Abhijit *et al.* A novel approach for automated detection of focal EEG signals using empirical wavelet transform. **Neural Computing And Applications**, [s.l.], v. 29, n. 8, p.47-57, 16 nov. 2016. Springer Nature. <http://dx.doi.org/10.1007/s00521-016-2646-4>.

BRINKMAN, L. *et al.* Distinct Roles for Alpha- and Beta-Band Oscillations during Mental Simulation of Goal-Directed Actions. **Journal Of Neuroscience**, [s.l.], v. 34, n. 44, p.14783-14792, 29 out. 2014. Society for Neuroscience. <http://dx.doi.org/10.1523/jneurosci.2039-14.2014>.

CAMACHO, Jaime; MANIAN, Vidya. Real-time single channel EEG motor imagery based Brain Computer Interface. **2016 World Automation Congress (wac)**, [s.l.], p.1-6, jul. 2016. IEEE. <http://dx.doi.org/10.1109/wac.2016.7582973>.

CHAUDHARY, U.; BIRBAUMER, N.; CURADO, M.r.. Brain-Machine Interface (BMI) in paralysis. **Annals Of Physical And Rehabilitation Medicine**, [s.l.], v. 58, n. 1, p.9-13, fev. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.rehab.2014.11.002>.

EBM CONSULT. Homunculus: Somatosensory and Somatomotor Cortex. Disponível em: <https://www.ebmconsult.com/articles/homunculus-sensory-motor-cortex>. Acesso em: 1 de julho de 2019.

FREITAS, Renato Hajenius Aché de *et al.* **Sporum**: dispersando curiosidades biológicas. Florianópolis: Universidade Federal de Santa Catarina, 2017.

GÜLER, İnan; ÜBEYLI, Elif Derya. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients. **Journal Of Neuroscience Methods**, [s.l.], v. 148, n. 2, p.113-121, out. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.jneumeth.2005.04.013>.

JACKSON, Philip L. *et al.* Potential role of mental practice using motor imagery in neurologic rehabilitation. **Archives Of Physical Medicine And Rehabilitation**, [s.l.], v. 82, n. 8, p.1133-1141, ago. 2001. Elsevier BV. <http://dx.doi.org/10.1053/apmr.2001.24286>.

KEVRIC, Jasmin; SUBASI, Abdulhamit. Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system. **Biomedical Signal Processing And Control**, [s.l.], v. 31, p.398-406, jan. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.bspc.2016.09.007>.

KRUCOFF, Max O. *et al.* Enhancing Nervous System Recovery through Neurobiologics, Neural Interface Training, and Neurorehabilitation. **Frontiers In Neuroscience**, [s.l.], v. 10, p.1-23, 27 dez. 2016. Frontiers Media SA. <http://dx.doi.org/10.3389/fnins.2016.00584>.

LIU, Rong *et al.* EEG Classification with a Sequential Decision-Making Method in Motor Imagery BCI. **International Journal Of Neural Systems**, [s.l.], v. 27, n. 08, p.1-16, dez. 2017. World Scientific Pub Co Pte Lt. <http://dx.doi.org/10.1142/s0129065717500460>.

MAKING IT UP. Signal Analysis for a Morse Decoder. Disponível em: <http://play.fallows.ca/wp/radio/ham-radio/signal-analysis-morse-decoder/>. Acesso em 1 de julho de 2019.

MASWANGANYI, Clifford *et al.* Discrimination of Motor Imagery Task using Wavelet Based EEG Signal Features. **2018 International Conference On Intelligent And Innovative Computing Applications (iconic)**, [s.l.], p.1-4, dez. 2018. IEEE. <http://dx.doi.org/10.1109/iconic.2018.8601238>.

MATHWORKS (Org.). MATLAB and Simulink. Mathworks. Disponível em: <https://www.mathworks.com/>. Acesso em: 18 de fevereiro de 2019.

MISITI, Michel *et al.* **Wavelet Toolbox™ 4**. Natick: The Mathworks, Inc, 2009.

NAJARIAN, Kayvan; SPLINTER, Robert. **Biomedical Signal and Image Processing**. 2. ed. Boca Raton: Crc Press, 2012.

PATTNAIK, Sasweta; DASH, M.; SABUT, S. K.. DWT-based feature extraction and classification for motor imaginary EEG signals. **2016 International Conference On Systems In Medicine And Biology (icsmb)**, [s.l.], p.186-201, 2016. IEEE. <http://dx.doi.org/10.1109/icsmb.2016.7915118>.

PENFIELD, Wilder; BOLDREY, Edwin. Somatic Motor and Sensory Representation in the Cerebral Cortex of Man as Studied by Electrical Stimulation. **Brain**, [s.l.], v. 60, n. 4, p.389-443, 1937. Oxford University Press (OUP). <http://dx.doi.org/10.1093/brain/60.4.389>.

SIULY; WANG, Hua; ZHANG, Yanchun. Detection of motor imagery EEG signals employing Naïve Bayes based learning process. **Measurement**, [s.l.], v. 86, p.148-158, maio 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.measurement.2016.02.059>.

TANG, Xianlun; YANG, Jiwei; WAN, Hui. A Hybrid SAE and CNN Classifier for Motor Imagery EEG Classification. **Advances In Intelligent Systems And Computing**, [s.l.], p.265-278, 27 maio 2018. Springer International Publishing. [http://dx.doi.org/10.1007/978-3-319-91189-2\\_26](http://dx.doi.org/10.1007/978-3-319-91189-2_26).

TARAN, Sachin; BAJAJ, Varun. Motor imagery tasks-based EEG signals classification using tunable-Q wavelet transform. **Neural Computing And Applications**, [s.l.], p.1-8, 11 maio 2018. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s00521-018-3531-0>.

TATUM, William O. *et al.* **The Handbook of EEG Interpretation**. New York: Demos Medical Publishing, 2008.

VUCKOVIC, Aleksandra; PANGARO, Sara; FINDA, Putri. Unimanual Versus Bimanual Motor Imagery Classifiers for Assistive and Rehabilitative Brain Computer Interfaces. **Ieee Transactions On Neural Systems And Rehabilitation Engineering**, [s.l.], v. 26, n. 12, p.2407-2415, dez. 2018. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tnsre.2018.2877620>.

ZHANG, Yu *et al.* Sparse Bayesian Learning for Obtaining Sparsity of EEG Frequency Bands Based Feature Vectors in Motor Imagery Classification. **International Journal Of Neural Systems**, [s.l.], v. 27, n. 02, p.1-13, mar. 2017. World Scientific Pub Co Pte Lt. <http://dx.doi.org/10.1142/s0129065716500325>.

ZHOU, Jie *et al.* Classification of motor imagery eeg using wavelet envelope analysis and LSTM networks. **2018 Chinese Control And Decision Conference (ccdc)**, [s.l.], p.5600-5605, jun. 2018. IEEE. <http://dx.doi.org/10.1109/ccdc.2018.8408108>.