

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS GRADUAÇÃO EM
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO

Ferramenta Simplificada Para Testes de Algoritmos de Seleção
de Características e Classificação em Sinais Cerebrais Captados
com EEG para BCIs baseados em Imagética Motora

Giovanna Bonafé Bernardi

Itajubá, Janeiro de 2018

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS GRADUAÇÃO EM
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO

Giovanna Bonafé Bernardi

Ferramenta Simplificada Para Testes de Algoritmos de Seleção
de Características e Classificação em Sinais Cerebrais Captados
com EEG para BCIs baseados em Imagética Motora

Dissertação submetida ao Programa de Pós-Graduação em
Ciência e Tecnologia da Computação como parte dos requisitos
para obtenção do Título de Mestre em Ciência e Tecnologia
da Computação

Área de Concentração: Sistemas de Computação

Orientador: Prof. Dr. Robson Luiz Moreno

Janeiro de 2018
Itajubá - MG

Agradecimentos

Agradeço aos meus pais, Marcelo e Cecília, por me ensinarem todos os valores que possuo, pela confiança depositada em mim, e por todo o apoio nos momentos que mais precisei.

A Deus, por me dar forças para nunca desistir apesar dos obstáculos e dificuldades e por ser sempre um refúgio nos momentos de desespero.

Aos meus amigos e familiares, que me apoiaram, me deram forças e me ajudaram na conclusão deste trabalho.

Ao professor Robson Luiz Moreno, pela orientação, incentivo e paciência durante o desenvolvimento deste trabalho. Ele com toda sua calma, experiência e conhecimento dispôs de seu tempo para esclarecer dúvidas e fornecer sugestões imprescindíveis para a conclusão e desenvolvimento de todas as etapas do mestrado.

Ao professor Edmilson Marmo, por ter me incentivado a entrar no mestrado.

À CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelo suporte financeiro durante todo o período de realização deste mestrado.

Epígrafe

*“Por vezes sentimos que aquilo que fazemos não é
senão uma gota de água no mar. Mas o mar
seria menor se lhe faltasse uma gota.”
(Madre Teresa de Calcutá)*

Resumo

Uma interface cérebro-computador é um sistema que traduz sinais elétricos em comandos e permite que usuários possam controlar um dispositivo apenas com o uso de sinais cerebrais. No entanto, sinais cerebrais são distintos para pessoas distintas e até mesmo para uma mesma pessoa. Uma mudança no emocional ou apenas cansaço são fatores que costumam afetar o comportamento desses sinais. Desta forma, o sistema deve ser construído com algoritmos que possam se adaptar ao usuário. O intuito deste trabalho é desenvolver uma ferramenta cujo objetivo é simplificar o trabalho de um profissional de interface cérebro-computador que tenha interesse em sistemas que utilizam ritmos sensório-motores captados na região do córtex motor como sinais de controle e que estejam especialmente interessados em testes de algoritmos de classificação e/ou nas características escolhidas para a mesma. Gravações de movimentos de mãos direita e esquerda captadas por eletrodos são passadas como entrada para a ferramenta, esta irá processar os sinais eliminando ruídos e separando os sinais nos tipos de movimento encontrado em cada eletrodo. Depois, a ferramenta separa os sinais nas faixas de frequência que representam os ritmos sensório-motores. Para os projetistas que desejam escolher suas próprias características, uma das saídas da ferramenta são os sinais que representam os sinais de controle. Para aqueles que desejam usar características como: média, variância, amplitude máxima e energia, a outra saída possível da ferramenta é justamente essas informações retiradas dos sinais de controle e colocadas em um vetor. Esse vetor pode, então, ser usado como entrada para um algoritmo de classificação. A ferramenta é desenvolvida de forma fixa a fim de possibilitar melhores comparações entre algoritmos projetados pelo usuário. Desta forma, aumenta-se a velocidade de construção de sistemas desse tipo, além de facilitar a introdução de profissionais de áreas específicas, como de computação, uma vez que se torna menos necessário aprofundar-se em outros tópicos como o funcionamento do cérebro em si, por exemplo. Ao longo deste trabalho, é feita uma contextualização com algumas definições importantes sobre sistemas de interface cérebro-computador. É dado um destaque para o comportamento dos sinais de controle usados, bem como para o algoritmo de separação de frequências escolhido. As características escolhidas para compor o vetor de saída da ferramenta foram extraídas com fórmulas matemáticas simples e conceitos sobre energia. É feita também, uma análise gráfica do comportamento dos sinais de controle usados, comprovando a viabilidade da ferramenta para testes de algoritmos e fazendo com que seja possível que usuários a utilizem para procurar aqueles que forneçam melhores resultados para a interpretação de sinais cerebrais.

Palavras-chaves: Ferramenta. Interface cérebro-computador. BCI. EEG. Imagética motora. MI. DWT. Ritmos sensório-motores. ERD/ERS.

Abstract

A brain computer-interface is a system that translates electrical signals into commands allowing users to control a device using only brain signals. However, brain signals are different for different people or even for the same person. Emotional change or just fatigue are factors that usually affect the behaviour of these signals. Therefore, this systems must be built with algorithms that can adapt to its users. The intention of this work is to develop a tool that can help simplify the work of a brain computer-interface professional who is interested in systems that use sensory-motor rhythms acquired over the motor cortex as control signals and that are specially interested in testing classification algorithms and/or in features selected for this classification. Recordings of left and right hand movements acquired with the use of electrodes are used as input for the proposed tool. The tool will then process the signals avoiding noise and dividing the signals according to the type of movement found. Then, the tool divides the signals into frequency bands that represent the sensory-motor rhythms. For those who wish to choose their own features, one of the outputs of the tool are the signals that represent the rhythms of the control signal. For those who wish to use features such as: mean, variance, maximum amplitude and energy, the other output of the tool is a vector formed by these features selected from the control signal. This vector can be used as input to a classification algorithm. The tool is developed in a fixed form to enable better comparisons between algorithms developed by the user. Thus, increasing the speed in the development of such systems and facilitating the introduction of professionals from specific fields, such as computer programmers, since it becomes less necessary to go deeper into other topics such as the functioning of the brain, for example. Throughout this work a contextualization is made with some important definitions about brain-computer interfaces. An emphasis is given on the behaviour of the control signals used as well as on the algorithm chosen to separate the frequencies. The features used to form the output vector were extracted with simple mathematical formulas and a concept about energy. A graphical analysis on the behaviour of the control signals used is also performed, proving that the developed tool complies with the theory regarding the behaviour of the imagination of hand movements, showing the feasibility of the tool for the testing of algorithms and allowing the research of algorithms that result in the best outcomes for the analysis of brain signals.

Key-words: Tool. Brain-computer interface. BCI. EEG. Motor imagery. MI. DWT. Sensorimotor rhythms. ERD/ERS.

Lista de ilustrações

Figura 1 – Exemplo de um sistema de interface cérebro-máquina baseado em eletroencefalograma. (Fonte: McFarland e Wolpaw (2011))	14
Figura 2 – Operação e projeto básicos de um sistema BCI. (Fonte: adaptado de McFarland e Wolpaw (2011)).	19
Figura 3 – Etapas típicas de um sistema BCI.	20
Figura 4 – Exemplo de sinais no domínio do tempo e como eles são detalhados no eixo do tempo, mas não possuem informações distintas de frequência.	28
Figura 5 – Exemplo de como, ao contrário do sinal no domínio do tempo, os sinais disponíveis pela FFT são detalhados no eixo da frequência, mas perdem as informações de tempo.	29
Figura 6 – Exemplo de como os sinais são detalhados conforme a janela escolhida para a STFT. (a) mostra uma STFT com janela larga. (b) mostra uma STFT com janela estreita.	30
Figura 7 – Exemplo das resoluções da WT de acordo com sua janela.	31
Figura 8 – Exemplo de uma touca com eletrodos para aquisição de sinais por EEG. Fonte: (VARGHESE, 2009)	33
Figura 9 – Posição dos eletrodos no padrão ISO 10-20. (Fonte: Nicolas-Alonso e Gomez-Gil (2012))	35
Figura 10 – Os dois hemisférios do cérebro. (Fonte: adaptado de Cisotto (2014))	36
Figura 11 – Os lobos do córtex cerebral. (Fonte: adaptado de Cisotto (2014))	36
Figura 12 – Exemplo de ritmos observados por um EEG de um adulto saudável. Onde <i>beta 1</i> é o chamado <i>baixo beta</i> e <i>beta 2</i> , <i>alto beta</i> . (Fonte: Cisotto (2014))	39
Figura 13 – Comportamento temporal de ERD/ERS de mu e beta gravado de C3 durante um experimento de movimento voluntário que envolve o levantamento rápido do dedo indicador direito. (Fonte: adaptado de Nicolas-Alonso e Gomez-Gil (2012))	41
Figura 14 – Exemplo da função <i>wavelet</i> base (família <i>Daubechies</i>) no plano espectro-temporal. (Fonte: adaptado de Graps (1995)).	42
Figura 15 – Exemplo de funções <i>wavelet</i> base de diferentes famílias. O número ao lado do nome de cada <i>wavelet</i> representa a quantidade de <i>vanishing moments</i> da subclasse da família <i>wavelet</i> (Fonte: adaptado de Graps (1995)).	44
Figura 16 – Algoritmo do funcionamento da DWT para um nível de decomposição. (Fonte: adaptado de Misiti et al. (1996)).	47

Figura 17 – Algoritmo da DWT para diversos níveis de decomposição. (Fonte: adaptado de Misiti et al. (1996)).	47
Figura 18 – Visão abstrata da ferramenta proposta.	53
Figura 19 – Estágios da construção do BCI presente neste trabalho e o vetor de características resultante.	54
Figura 20 – Etapas do código da ferramenta proposta.	55
Figura 21 – Posição dos eletrodos no padrão ISO 10-20.	56
Figura 22 – Gravação dos movimentos ao longo de um segmento de tempo. (Fonte: adaptado de Brunner et al. (2008))	58
Figura 23 – Algoritmo simples para exemplo de extração de valor máximo em um vetor.	62
Figura 24 – Exemplo das frequências presentes no sinal original e após o uso de um filtro passa-faixa <i>Chebyshev tipo II</i> de 5 a 30Hz.	64
Figura 25 – Exemplo das frequências presentes no sinal após o uso de um filtro passa-faixa <i>Chebyshev tipo II</i> de 5 a 30Hz.	64
Figura 26 – Coeficientes reconstruídos da DWT para movimento de mão direita no canal C3 (ensaio 48 do indivíduo 1).	65
Figura 27 – Exemplo de um sinal comum de EEG de uma pessoa saudável gravado sobre o canal C3 referente a um movimento de mão direita.	65
Figura 28 – Gráfico de cores dos coeficientes da CWT para a observação da intensidade de cada frequência em cada momento no tempo.	67
Figura 29 – Gráfico de cores dos coeficientes da CWT representando todos os ensaios do canal C3 com relação à movimento de mão direita, apenas para as frequências de mu e beta.	68
Figura 30 – Gráfico de cores dos coeficientes da CWT representando todos os ensaios do canal C3 com relação à movimento de mão direita.	69
Figura 31 – Gráfico de cores dos coeficientes da CWT representando todos os ensaios do canal C3 com relação à movimento de mão direita.	69
Figura 32 – Um gráfico ERP para um único ensaio. (Fonte: Varghese (2009)).	70
Figura 33 – Um gráfico ERP para todos os ensaios empilhados dos canais C3 e C4 relativos à movimento de mão direita.(Fonte: Varghese (2009)).	71
Figura 34 – Um gráfico ERP para todos os ensaios empilhados dos canais C3 e C4 relativos à movimento de mão esquerda.(Fonte: Varghese (2009)).	71
Figura 35 – Energia para os canais C3 e C4 quando movimento de mão esquerda é imaginado.	72

Lista de tabelas

Tabela 1 – Exemplo dos coeficientes e suas faixas de frequências (do inglês, <i>bandwidth</i> - <i>BW</i>) para uma DWT de ordem 5. Onde f_s é a frequência de amostragem.	48
Tabela 2 – Faixas de frequências (BW) aproximadas de cada coeficiente de aproximação e detalhe para uma frequência de amostragem de 250Hz. . . .	59

Lista de Algoritmos

3.1	Exemplo de uso da função <i>sload</i>	57
3.2	Exemplo de uso da função para criar um filtro <i>Chebyshev</i> tipo II	58
3.3	Exemplo de uso do filtro especificado	59
3.4	Exemplo do uso das funções do MATLAB para obtenção dos coeficientes desejados	60

Lista de abreviaturas e siglas

ALS	<i>Amyotrophic Lateral Sclerosis</i>
BCI	<i>Brain-Computer Interface</i>
CNA	<i>Cortical Neuronal Activity</i>
CWT	<i>Continuous Wavelet Transform</i>
DWT	<i>Discrete Wavelet Transform</i>
EEG	<i>Electroencephalography</i>
ECG	<i>Electrocardiography</i>
ECoG	<i>Electrocorticographic</i>
EMG	<i>Electromiography</i>
EOG	<i>Electrooculography</i>
ERD	<i>Event-Related Desynchronization</i>
ERP	<i>Event-Related Potential</i>
ERS	<i>Event-Related Synchronization</i>
ELA	Esclerose Lateral Amiotrófica
FES	<i>Functional Electrical Stimulation</i>
FFT	<i>Fast Fourier Transform</i>
fMRI	<i>Functional Magnetic Resonance Imaging</i>
fNIR	<i>Near-infrared Spectroscopy</i>
GDF	<i>General Data Format for Biosignals</i>
ICA	<i>Independent Component Analysis</i>
ICM	Interface Cérebro-Máquina
ISO 10-20	Sistema de padrão internacional concebido pela <i>International Federation of Societies for Electroencephalography</i>
MEG	<i>Magnetoencephalography</i>
MI	<i>Motor Imagery</i>
P300	Sinal de controle em que é possível observar um pico positivo em torno de 300ms
PSD	<i>Power Spectral Density</i>
SCP	<i>Slow Cortical Potentials</i>
SMR	<i>Sensory-Motor Rhythms</i>
SNR	<i>Signal-to-Noise Ratio</i>
STFT	<i>Short-Time Fourier Transform</i>
SVM	<i>Support Vector Machine</i>
VEP	<i>Visual Evoked Potential</i>
WT	<i>Wavelet Transform</i>

Sumário

Lista de Algoritmos	10
1 Introdução	13
1.1 Objetivos	16
1.2 Organização do Trabalho	17
2 Fundamentação Teórica	18
2.1 Interface Cérebro Máquina	18
2.2 Visão Geral	20
2.3 Eletroencefalograma	33
2.4 ERD/ERS de Ritmos Sensório-Motores (Mu e Beta)	37
2.5 Transformada <i>Wavelet</i> (CWT/DWT)	41
2.6 Estudos Desenvolvidos na Área	49
3 Desenvolvimento	53
3.1 Aquisição de Dados	54
3.2 Separação de Ensaios e Extração de Épocas (ERD/ERS)	57
3.3 Filtragem	58
3.4 Separação de Ritmos Mu e Beta com DWT	59
3.5 Extração de Características	60
3.6 Formação do Vetor de Características	62
4 Resultados	63
5 Conclusão	74
5.1 Trabalhos futuros	75
Referências	76
ANEXO A Artigo Enviado para Congresso	80

1 Introdução

Uma Interface Cérebro-Computador, ou Interface Cérebro-Máquina (do inglês, *Brain-Computer Interface - BCI*), é um sistema que faz uso de processamento de sinais e de inteligência artificial com o objetivo de possibilitar que um usuário controle um dispositivo utilizando apenas sinais cerebrais (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Um BCI pode ser construído para diversas aplicações, no entanto, devido ao fato de diferentes tipos de algoritmos serem mais adequados para determinados tipos de análise, BCIs possuem melhores resultados quando feitos para um propósito específico.

Uma das aplicações que mais atrai a atenção na área de BCIs é a que envolve o controle motor (WOLPAW et al., 2002; KUMAR; INBARANI, 2016; CISOTTO, 2014; ALOMARI et al., 2014). Porque não dependem do controle neuromuscular, BCIs são particularmente interessantes para pessoas que sofrem de doenças neuromusculares severas que dificultam ou até mesmo impossibilitam a comunicação das mesmas com o mundo exterior (MCFARLAND; WOLPAW, 2011). Pesquisadores são motivados a trabalhar na construção desses sistemas na esperança de que essa tecnologia seja útil para pessoas gravemente debilitadas, ajudando-as a expressar seus desejos e necessidades a seus cuidadores e melhorando sua qualidade de vida (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Além disso, esses sistemas podem potencialmente se tornar uma ferramenta poderosa para revelar informações escondidas no cérebro do usuário e que não podem ser expressadas.

Devido à sua simplicidade e baixo custo comparado a outros métodos de análise de funções cerebrais, a técnica de aquisição de sinais mais usada nos estudos desses sistemas é o eletroencefalograma (EEG) (MCFARLAND; WOLPAW, 2011; KUMAR; INBARANI, 2016). O eletroencefalograma utiliza eletrodos na superfície do couro cabeludo em localizações específicas para monitorar e gravar sinais de atividade elétrica gerados por neurônios, fornecendo informações úteis sobre o estado do cérebro (SUBHA et al., 2010). Um exemplo desse sistema pode ser observado na [Figura 1](#).

Como mencionado, dependendo do objetivo final do sistema, pode-se analisar os sinais obtidos de maneiras distintas. Uma maneira muito utilizada para traduzir comandos motores imaginados de forma voluntária, é o uso de um tipo de sinal de controle conhecido como ritmos sensório-motores. Este sinal de controle pode ser usado com este tipo de sistema porque a amplitude desses ritmos varia quando a atividade cerebral está relacionada com qualquer atividade motora, embora movimento, propriamente dito, não seja necessário para modular suas amplitudes (JEANNEROD, 1995; PFURTSCHELLER et al., 1997). De fato, descobriu-se que esses ritmos, em uma certa faixa de frequência, comportam-se de forma semelhante tanto na realização de um movimento quanto na ima-




Figura 1 – Exemplo de um sistema de interface cérebro-máquina baseado em eletroencefalograma. (Fonte: [McFarland e Wolpaw \(2011\)](#))

ginação da realização do mesmo ([MCFARLAND et al., 2000](#); [MCFARLAND](#); [WOLPAW, 2011](#); [CISOTTO, 2014](#)).

O EEG pode monitorar sinais sobre o córtex sensório-motor para observar o comportamento de ritmos sensório-motores, como os ritmos μ (8-13Hz) e β (13-30Hz). Outro motivo pelo qual esses ritmos costumam ser usados para controlar BCIs com foco em atividade motora é o fato das pessoas conseguirem aprender a modular suas amplitudes, voluntariamente ([PFURTSCHELLER](#); [NEUPER, 2001](#); [BLANKERTZ et al., 2010](#)).

Apesar dos avanços significativos mais recentes na tecnologia de BCIs, ainda é preciso superar alguns desafios para permitir o uso desses sistemas fora de laboratórios ([MOORE, 2003](#)). Em uma revisão do uso de tecnologia de BCI para dispositivos robóticos e protéticos, [McFarland e Wolpaw \(2008\)](#) concluíram que o maior problema encontrado por aplicações de BCI é o de fornecer controle de sinais de forma rápida, precisa e confiável.

No entanto, a construção de sistemas de interface cérebro-máquina não é uma atividade trivial. Para que essas características de controle sejam alcançadas, é preciso lidar com algumas limitações e dificuldades ([KUMAR](#); [INBARANI, 2016](#)). Nesse contexto, alguns dos principais desafios encontrados por projetistas são: (i) o processamento de sinais do tipo cerebral, cujo comportamento apresenta complexidades que dificultam sua análise; (ii) o fato da área envolver pesquisadores de diferentes especialidades; e (iii) a dificuldade na comparação de projetos.

(i) O grande objetivo do processamento de sinais biológicos é observar o sinal e classificá-lo com precisão, no entanto, esta é uma tarefa desafiadora ([KUMAR](#); [INBA-](#)

RANI, 2016). Os sinais cerebrais são sinais complexos que apresentam um comportamento não-linear e não-estacionário. Além disso, a atividade cerebral não possui as mesmas características de indivíduo para indivíduo e nem sequer para um mesmo indivíduo, uma vez que essas características dependem fortemente da idade e do estado mental do usuário. Para mais, a gravação de sinais cerebrais com um EEG está predisposta a captação, tanto de sinais misturados com outros vindos de um conjunto finito de atividades cerebrais e que se sobrepõem no tempo e espaço, quanto de ruídos (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Por esses motivos, faz-se necessário o uso de técnicas de processamento de sinais avançadas com algoritmos que são capazes de se adaptar aos usuários (SUBHA et al., 2010).

(ii) Pesquisas em interfaces cérebro-máquina fazem parte de uma área relativamente nova e multidisciplinar, que envolve profissionais de diversas especialidades, como neurocientistas, engenheiros, matemáticos, especialistas em reabilitação clínica, entre outras disciplinas técnicas e de cuidados com a saúde (WOLPAW et al., 2002). Esse fato contribui para um avanço menos veloz no desenvolvimento desses sistemas, pois necessita-se de um grupo formado por especialistas de áreas distintas trabalhando em conjunto ou que os poucos profissionais que trabalham neles, além de realizarem pesquisas em suas próprias áreas, tenham que estudar partes de outras áreas envolvidas.

(iii) Segundo Nicolas-Alonso e Gomez-Gil (2012), a escolha de informações interessantes é de extrema importância para os algoritmos de classificação e, ainda hoje, é um dos maiores desafios encontrados na área de BCI. Para melhorar o desempenho de sistemas BCI de múltiplas classes de imagética motora, vários estudos vêm sendo feitos nas fases de extração e/ou seleção de características, e de classificação (KUMAR; INBARANI, 2016). Normalmente, em trabalhos na área, encontram-se comparações de desempenho entre os sistemas com o uso de métricas, como o valor de precisão ou o coeficiente *kappa*, calculadas após os algoritmos de classificação. No entanto, no trabalho de Lotte et al. (2007), foi observada uma falta de comparação entre classificadores dentro de um mesmo estudo usando parâmetros idênticos. Idealmente, classificadores deveriam ser testados dentro de um mesmo contexto, isto é, com os mesmos usuários, usando os mesmos métodos de extração de características, protocolo e parâmetros (MCFARLAND; WOLPAW, 2011). Desta forma, a comparação de desempenho entre os sistemas levaria a conclusões mais adequadas.

Como resultado, apesar dos avanços notáveis, ainda não foi criada uma linguagem comum para o desenvolvimento desses sistemas, além disso, as tecnologias usadas em BCIs variam, o que dificulta muito a comparação entre os sistemas, reduzindo a velocidade das pesquisas (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Para auxiliar os projetistas na construção de uma interface cérebro-máquina, existem algumas ferramentas disponíveis como o *BCI2000*, o *EEGLAB*, o *bcilab*, e o *biosig*

(SCHALK et al., 2004; KOTHE; MAKEIG, 2013; SCHLÖGL; BRUNNER, 2008; DELORME; MAKEIG, 2004). No entanto, apesar dessas ferramentas normalmente fornecerem funções prontas de diversos algoritmos, ainda se faz necessário o entendimento sobre o que essas funções retornam e como utilizar esses resultados nas próximas fases do desenvolvimento. Algumas vezes, é necessário uma compreensão não só da teoria do algoritmo como também de sua implementação. Isso faz com que essas ferramentas apresentem um certo grau de dificuldade no aprendizado e utilização por pessoas cuja especialização não esteja exatamente relacionada com algumas terminologias e conceitos usados. Além disso, essas ferramentas permitem uma certa liberdade na escolha de conjuntos de dados, algoritmos e tipo de análises para a construção de seus sistemas. Essa liberdade é boa só até certo ponto, pois ela acaba criando uma grande variabilidade, o que não auxilia na comparação eficiente dos algoritmos usados.

1.1 Objetivos

O objetivo principal deste trabalho é o desenvolvimento de uma ferramenta de pré-processamento e caracterização para testes de algoritmos de análise de sinais de EEG baseados em imagética motora de mãos direita e esquerda, utilizando ritmos sensório-motores, dentro de um ambiente limitado. O propósito desta limitação é permitir a comparação dos algoritmos que serão implementados, com o máximo de similaridade e menor variabilidade, mantendo fixos o protocolo, método de separação de frequências e pré-processamento, para deixá-los sob um mesmo contexto. Isto é feito, no intuito de ajudar projetistas com a criação de sistemas que consigam atingir os melhores valores para os principais desafios da área, como a precisão e a confiabilidade.

Além do objetivo principal citado, alguns outros, com suas motivações e vantagens merecem ser citados:

- A ferramenta em questão é desenvolvida para simplificar o trabalho de projetistas de sistemas de interface cérebro-computador. Pelo fato de fornecer processamento de sinal e análises, ela pode facilitar o entendimento por parte de usuários que estão iniciando os estudos nessa área, além de tirar a necessidade de ter que lidar com as etapas iniciais da construção desse sistema. Isso permite, por exemplo, que usuários que desejam testar apenas algoritmos de classificação para tipos de dados cerebrais relacionados à atividade motora, possam simplesmente se preocupar apenas com esses algoritmos.

Assim sendo, a diminuição na complexidade pode ajudar na adesão de profissionais de outras áreas que podem usar seus conhecimentos mais aprofundados e específicos, proporcionando maior velocidade no desenvolvimento de sistemas mais adequados. Da mesma forma, sem a necessidade de passar por todas as etapas iniciais do sis-

tema, acelera-se o processo de desenvolvimento, permitindo foco em algoritmos de extração e seleção de características e de classificação. Encontrar características e algoritmos melhores diminui a taxa de erro do sistema, aumentando sua precisão e confiabilidade.

- A ferramenta pode ser usada por aqueles que desejam trabalhar com o algoritmo da *transformada wavelet discreta* e/ou com *ritmos sensório-motores*, permitindo que o usuário escolha suas próprias características ou algoritmo de extração de características para formar o vetor de características.
- A ferramenta fornece um ambiente que possibilita a análise de resultados parciais da construção de um BCI. Esses resultados podem ser usados para a análise da separação dos sinais em frequências e para a observação de suas características e comportamento. Esta análise pode ser útil para um melhor entendimento do sistema, já que, normalmente, não se dá muita atenção aos resultados das etapas intermediárias da construção desses sistemas. Em geral, os sistemas são classificados como um todo em termos da precisão atingida pelos métodos de classificação e outras métricas relacionadas a esses algoritmos.

1.2 Organização do Trabalho

Este trabalho está estruturado em cinco capítulos, como a seguir:

- **Capítulo 2:** apresenta uma visão geral com os principais tipos de BCIs, neuroimagens, sinais de controle e ruídos, existentes, além de discutir sobre as etapas típicas da construção desses sistemas e tratar das técnicas utilizadas na metodologia proposta.
- **Capítulo 3:** apresenta a proposta implementada com sua metodologia e os dados utilizados. A metodologia inclui: utilização de sinais de base de dados pública, separação dos sinais de acordo com os eventos analisados, filtragem, utilização de algoritmo para separação de frequências e observação dos sinais tanto no domínio do tempo quanto no da frequência, além de extração de características simples.
- **Capítulo 4:** apresenta formas de análise dos sinais obtidos pela ferramenta e as utiliza para demonstrar a viabilidade do sistema. Neste capítulo, também é feita uma análise de desempenho do sistema e apresentação de seus resultados.
- **Capítulo 5:** conclui o trabalho, resumindo o que foi realizado e comentando sobre os resultados obtidos. Também são apresentadas sugestões de melhorias e ideias para continuidade do projeto.

2 Fundamentação Teórica

2.1 Interface Cérebro Máquina

De acordo com a definição de [McFarland e Wolpaw \(2011\)](#), uma Interface Cérebro-Máquina é um sistema que traduz atividades elétricas produzidas por sinais cerebrais em comandos, permitindo que usuários possam se comunicar controlando um dispositivo externo sem fazer uso de músculos ou nervos periféricos.

Devido ao fato de gerarem uma grande quantidade de dados (também conhecido, atualmente, pelo termo *big data*); apresentarem comportamento não-estacionário, não-linear e predisposição a ruídos; serem afetados por propriedades como cansaço e estado de consciência; e serem diferentes de usuário para usuário nas suas variações de frequência e observações de tarefas; sinais elétricos produzidos pela atividade cerebral são considerados de difícil análise ([KUMAR; INBARANI, 2016](#)).

Essas características demonstram a necessidade de se construir modelos de sistemas BCI que possam se adaptar aos usuários, com o uso, por exemplo, de processamento de sinais e inteligência artificial para reconhecimento de padrões ([NICOLAS-ALONSO; GOMEZ-GIL, 2012](#)).

Um exemplo básico de um sistema BCI pode ser observado na [Figura 2](#). Os sinais de entrada do sistema são os sinais cerebrais, detectados no escalpo, na superfície cortical, ou dentro do cérebro. Esses sinais são processados para que sejam extraídas características específicas do sinal que reflitam a intenção do usuário. As características são traduzidas em comandos e usadas para controlar um dispositivo, que pode ser, por exemplo, um computador ou uma prótese ([MCFARLAND; WOLPAW, 2011](#)).

O termo BCI foi utilizado pela primeira vez na década de 70, quando Jacques Vidal criou um sistema BCI baseado em potenciais visuais evocados. [Vidal \(1977\)](#) usou técnicas de processamento de sinais para análise em tempo real de sinais EEG, além de remoção de artefatos oculares, para que o movimento ocular não fosse usado para o controle do sistema. De acordo com [McFarland e Wolpaw \(2011\)](#), a façanha de Vidal foi uma demonstração interessante de prova de princípio, pois no início de 1970, seu sistema não era nada prático, uma vez que dependia de um sistema de *hardware* com capacidade de processamento limitada.

Justamente pelo fato de não precisar fazer uso de músculos ou nervos periféricos, um sistema BCI é particularmente interessante para pessoas que sofrem de doenças neuromusculares severas que dificultam ou até mesmo impossibilitam a comunicação das mesmas com o mundo exterior ([MCFARLAND; WOLPAW, 2011](#)). Para essas pessoas,

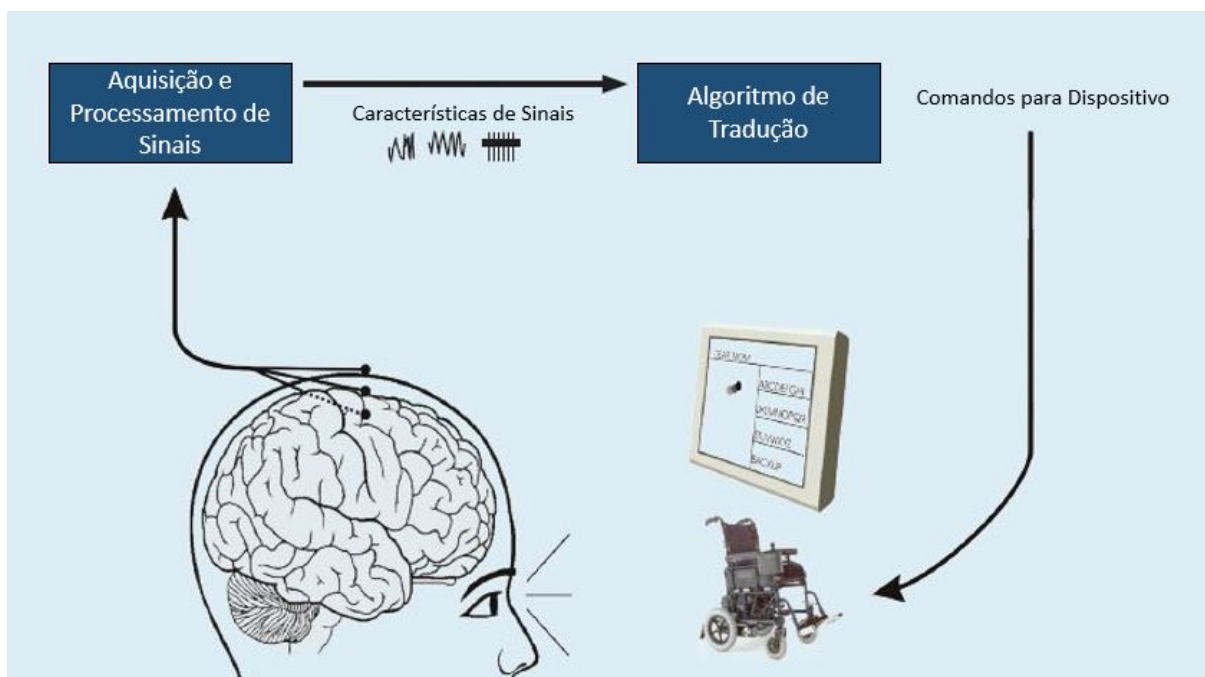


Figura 2 – Operação e projeto básicos de um sistema BCI. (Fonte: adaptado de [McFarland e Wolpaw \(2011\)](#)).

um sistema como esse pode melhorar a qualidade de vida e, ao mesmo tempo, reduzir o custo de cuidados intensivos ([NICOLAS-ALONSO; GOMEZ-GIL, 2012](#)).

Um dos principais objetivos de aplicações baseadas em BCI é alcançar o máximo de independência para o paciente, apesar de qualquer deficiência motora. Sistemas BCIs podem ter diversas aplicações. Na sua revisão sobre BCIs, [Nicolas-Alonso e Gomez-Gil \(2012\)](#) classificam essas aplicações em cinco áreas principais: comunicação, controle do ambiente, locomoção, restauração motora, e entretenimento. Como a **comunicação** é uma atividade essencial para humanos, essa talvez seja a aplicação de maior urgência em pesquisas no campo de BCI. Aplicações de BCI na área de **controle do ambiente** focam no controle de dispositivos domésticos, como luzes ou temperatura do ambiente. BCIs usados para **locomoção** permitem que pacientes debilitados possam controlar um meio de transporte. Graças a esses tipos de aplicações, pessoas que sofrem de paraplegia ou outras deficiências físicas podem dirigir de forma autônoma uma cadeira de rodas, por exemplo. Dentro da área de aplicações de BCI em **restauração motora**, existe a hipótese de que treinamento com BCI fornece *feedback* ao córtex sensório-motor e, com isso, movimento é restaurado a medida que as vias cerebrais se reorganizam para conectar comando motores a movimentos motores. Usuários podem adquirir controle seletivo sobre certas áreas do cérebro por meio de *neurofeedback*, com o objetivo de induzir mudanças no comportamento do cérebro. *Neurofeedback* fornecido por um sistema BCI pode melhorar o desempenho cognitivo, habilidades de fala, controle de dor, entre outros. De todas as aplicações citadas, pesquisas em BCIs para **entretenimento** normalmente possuem a

prioridade mais baixa. Além de proporcionar uma modalidade desafiadora de videogame, o BCI pode fornecer, também, uma forma de acessar conhecimento sobre a experiência do usuário. Com ele, é possível saber quando o jogador está entediado, ansioso ou frustrado com o objetivo de usar esse conhecimento para o projeto de jogos futuros. Esse tipo de aplicação expande o uso de BCIs para pessoas que não são deficientes.

Existem diversos caminhos para a construção de um BCI. Diferentes propósitos levam a diferentes escolhas de algoritmos e métodos, além de diferentes tipos de sinais de controle. A razão para esse fato é que para cada finalidade, um algoritmo (ou conjunto de algoritmos) pode ser mais adequado para apresentar um melhor resultado. Se o objetivo é criar um sistema para traduzir comandos motores imaginados de forma voluntária, então um tipo de sinal de controle que pode ser usado são os ritmos sensório-motores, que podem ser observados, por exemplo, sobre o córtex motor. Sendo assim, existem algoritmos que possuem melhores resultados com esses tipos de sinais do que com sinais de potenciais evocados, por exemplo, que podem ser observados sobre o córtex visual e precisam de estímulo externo para serem gerados.

2.2 Visão Geral

O funcionamento básico de um BCI segue as etapas vistas na [Figura 3](#):

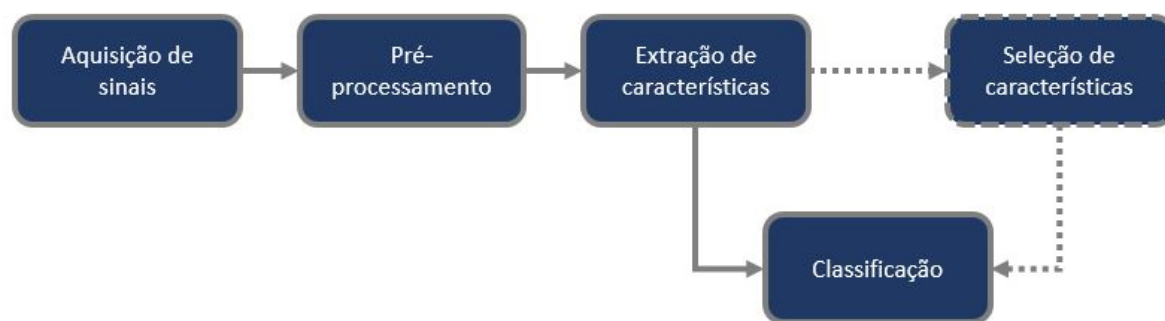


Figura 3 – Etapas típicas de um sistema BCI.

1. Aquisição de sinais

É nessa etapa que é feita a aquisição dos sinais cerebrais. A entrada escolhida é captada por eletrodos de gravação, amplificada, e digitalizada ([CABRERA, 2009](#)).

- **Tipos de BCI**

Com base na revisão feita por [Nicolas-Alonso e Gomez-Gil \(2012\)](#), dependendo da forma como é realizada a aquisição dos sinais, BCIs podem ser categorizados em: (i) exógenos ou endógenos; (ii) síncronos ou assíncronos; (iii) e invasivos ou não-invasivos.

BCIs também podem ser classificados em dependentes ou independentes, mas essa classificação é muito similar às categorias exógenas e endógenas.

(i) De acordo com a natureza dos sinais de entrada usados, sistemas BCIs podem ser classificados em exógenos ou endógenos. Sistemas **exógenos** necessitam de estímulo externo (como um estímulo visual ou auditivo, por exemplo). É necessário que o usuário tenha atenção permanente à esse estímulo, podendo, assim, levá-lo a fadiga. Porém, esses sistemas não necessitam de treinamento extenso, o controle de sinais pode ser realizado com apenas um canal EEG e eles podem atingir uma alta taxa de transferência de informação de até $60\text{bits}/\text{min}$ ([MCFARLAND; WOLPAW, 2011](#)).

Por outro lado, BCIs **endógenos** são baseados na autorregulação de ritmos e potenciais cerebrais, independentes de quaisquer estímulos.

[McFarland e Wolpaw \(2011\)](#) classificam sistemas exógenos como potenciais evocados e sistemas endógenos, como características oscilatórias. Potenciais evocados são apresentados como uma breve perturbação na atividade devido a um estímulo. Tais sinais são tipicamente analisados no domínio do tempo. Já as características oscilatórias, em EEG, podem ocorrer como resposta a um evento específico (como o movimento de um braço, por exemplo) e são tipicamente estudadas por análises espectrais.

A vantagem de um BCI endógeno é que o usuário pode operar o BCI livremente, por vontade própria, enquanto que um BCI exógeno pode restringir o usuário a escolhas apresentadas. Além disso, BCIs endógenos são especialmente úteis para usuários em estágio avançado de esclerose lateral amiotrófica (ELA) (do inglês, *amyotrophic lateral sclerosis - ALS*) ou cujos órgãos sensoriais foram afetados.

(ii) De acordo com a modalidade de processamento de dados de entrada, sistemas BCIs podem ser classificados em síncronos ou assíncronos. BCIs **síncronos** analisam sinais cerebrais em janelas de tempo pré-definidas. Qualquer sinal cerebral fora da janela pré-definida é ignorado. Portanto, o usuário só pode enviar comandos durante períodos específicos determinados pelo sistema. A vantagem desse tipo de sistema é que o início da atividade mental é previamente conhecido e associado com um tipo específico de sinalização (como um sinal indicando qual atividade deve ser realizada). Além disso, nesse tipo de sistema, pode-se evitar a geração de alguns tipos de artefatos, como o movimento dos olhos, pois o usuário pode fazê-lo fora da janela que será usada para a análise. Isso simplifica o projeto e a avaliação do BCI síncrono.

BCIs do tipo **assíncrono** analisam sinais cerebrais continuamente, não impor-

tando quando o usuário age. Eles oferecem uma forma mais natural de interação humano-máquina que BCIs síncronos. Porém, são mais computacionalmente complexos e custosos (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

(iii) Atividades elétricas do cérebro podem ser gravadas de forma invasiva ou não-invasiva.

Quando a captação de sinais é feita dentro do cérebro do usuário, ela é chamada de invasiva. Quando os sinais são coletados sobre o escalpo, sem a necessidade de implante ou cirurgia, o sistema é dito ser não-invasivo.

A modalidade **invasiva** envolve riscos significativos à saúde, uma vez que é necessária a implantação de um conjunto de microeletrodos dentro do crânio do usuário. No trabalho de Nicolas-Alonso e Gomez-Gil (2012) são citadas algumas questões que tiveram que ser abordadas antes que essa modalidade pudesse ser adequada para aplicações a longo prazo. Primeiro, existe a preocupação com a possibilidade de rejeição tecidual do microeletrodo. Segundo, a ligação entre o microeletrodo e um *hardware* externo deve ser feita com o uso de tecnologia *wireless* (sem fio) para reduzir o risco de infecção. E terceiro, o estresse contínuo causado pelo ato de conectar e desconectar o sistema de gravação pode levar a danos no tecido ou falha no sistema. Contudo, métodos de gravação invasivos como eletrocorticografia ou gravação de neurônio intracortical foram introduzidos em um esforço para aumentar a qualidade dos sinais cerebrais monitorados pelos BCIs. Esses sistemas podem captar sinais de neurônios individuais, possuindo melhor resolução temporal e espacial.

Em BCIs **não-invasivos**, eletrodos na superfície do escalpo estão a uma certa distância do tecido cerebral, separado desse pelos revestimentos do cérebro, crânio, tecido subcutâneo, e pelo próprio escalpo. Como resultado, o sinal é consideravelmente degradado e apenas atividade sincronizada de um grande número de elementos neurais podem ser detectados, limitando a resolução com a qual a atividade cerebral pode ser monitorada. Mais que isso, eletrodos no escalpo captam atividade de outras fontes que não o cérebro, incluindo ruídos do ambiente (como os $50Hz$ ou $60Hz$ da rede elétrica) e ruídos biológicos (como a atividade do coração, dos olhos e de músculos esqueléticos) (MCFARLAND; WOLPAW, 2011).

Um exemplo de BCI invasivo pode ser a atividade neuronal cortical, onde eletrodos implantados no córtex (diretamente, não sobre ele) conseguem detectar potenciais de ação de um único neurônio, oposto ao de um conjunto de neurônios, como acontece com EEG (WOLPAW et al., 2002).

A captação de sinais cerebrais de forma invasiva consegue ser mais detalhista, observando o comportamento de um único neurônio, por exemplo. Entretanto, por segurança e facilidade de uso, a forma não-invasiva ainda é a preferida em pesquisas da área.

- **Neuroimagens**

Neuroimagem é o termo empregado por [Nicolas-Alonso e Gomez-Gil \(2012\)](#) para os métodos de monitoramento de sinais de atividades cerebrais existentes em BCIs.

As modalidades de neuroimagem costumam ser separadas pelos tipos de atividade funcional cerebral os quais elas monitoram. Dentre as atividades cerebrais existentes para monitoramento, destacam-se duas: as eletrofisiológicas e as metabólicas ([NICOLAS-ALONSO; GOMEZ-GIL, 2012](#); [MCFARLAND; WOLPAW, 2011](#)).

Atividade eletrofisiológica é gerada pelo fluxo de corrente elétrica durante a troca de informações entre neurônios. Essas atividades podem ser medidas com o uso de eletroencefalograma (EEG), eletrocorticografia (ECoG) e gravação de neurônio intracortical. Sendo esses dois últimos, métodos invasivos ([MCFARLAND; WOLPAW, 2011](#); [WOLPAW et al., 2002](#); [NICOLAS-ALONSO; GOMEZ-GIL, 2012](#)).

A resposta hemodinâmica é um processo no qual o sangue libera glucose a neurônios ativos em uma taxa maior do que em áreas de neurônios inativos. Pode-se medir esse tipo de atividade com o uso de métodos metabólicos, como: ressonância magnética funcional (do inglês, *functional magnetic resonance imaging* - fMRI) e espectroscopia infravermelha próxima (do inglês, *near-infrared spectroscopy* - fNIR). Esses tipos de métodos são classificados como indiretos, pois medem a resposta hemodinâmica, a qual, em contraste com a atividade eletrofisiológica, não está diretamente relacionada com atividade neuronal ([NICOLAS-ALONSO; GOMEZ-GIL, 2012](#)).

Na categoria de medições não-invasivas, pesquisas demonstraram o uso viável da ressonância magnética funcional (fMRI) e de sistemas de infravermelho (fNIR). Porém, fMRI é custoso e de difícil utilização, fazendo com que tenha pouca probabilidade de ser usado para aplicações práticas. Apesar de fNIR ser menos custoso que fMRI, ainda é mais custoso que EEG, e, além disso, tanto fMRI quanto fNIR possuem tempo de resposta lento, já que são baseados em mudanças no fluxo sanguíneo cerebral.

Características eletrofisiológicas representam os sinais mais práticos para aplicações BCIs na atualidade segundo [McFarland e Wolpaw \(2011\)](#). Dentre as formas não-invasivas, o EEG é a modalidade de neuroimagem mais usada em pesquisas de BCI ([KUMAR; INBARANI, 2016](#)). Sua popularidade se dá devido à sua simplicidade e ao seu baixo custo comparado a outros métodos de análise de funcionamento cerebral ([MCFARLAND; WOLPAW, 2011](#)). O EEG precisa de equipamentos relativamente simples e de baixo custo; pode funcionar na maioria dos ambientes; possui boa resolução temporal, apesar de uma baixa resolução espacial; alta portabilidade; e fornece poucos riscos aos usuários. Desta forma, oferece a possibilidade de um novo canal para comunicação não-muscular de forma prática ([WOLPAW et al., 2002](#)).

Neuroimagens são usadas para análise de sinais de controle presentes em atividades cerebrais de interesse.

- **Tipos de sinais de controle**

Sinais cerebrais envolvem inúmeros fenômenos simultâneos relacionados a tarefas cognitivas. A maioria desses fenômenos ainda são incompreensíveis e suas origens desconhecidas. No entanto, fenômenos fisiológicos de alguns sinais cerebrais foram decodificados permitindo que usuários consigam aprender a modulá-los por vontade própria. Isso possibilita que sistemas BCIs interpretem suas intenções. Esses sinais são considerados como possíveis sinais de controle em BCIs (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Dentre os sinais de controle mais usados na área de BCI, pode-se citar: potenciais visuais evocados (do inglês, *visual evoked potentials* - *VEPs*); potenciais evocados P300; ritmos sensório-motores (do inglês, *sensorimotor rhythms* - *SMR*); e atividade neuronal cortical (do inglês, *cortical neuronal activity* - *CNA*). Sendo que neste último tipo, os sinais são captados de forma invasiva (MCFARLAND; WOLPAW, 2011).

Como é de interesse apenas os tipos de sinais de controle para BCIs não-invasivos, a seguir é feita uma breve apresentação sobre: VEPs, P300 e SMR.

Tanto VEPs quanto P300 são sinais do tipo potencial evocado. Sinais deste tipo dependem de algum tipo de estímulo para que a atividade cerebral analisada seja gerada. Após esse estímulo, pode-se observar formas de ondas transientes ou breves perturbações na atividade atual (MCFARLAND; WOLPAW, 2011).

VEPs: Segundo Nicolas-Alonso e Gomez-Gil (2012), VEPs são modulações da atividade cerebral que ocorrem no córtex visual depois de recebido um estímulo visual. Essas modulações são relativamente fáceis de se detectar já que a amplitude dos VEPs aumenta imensamente a medida que o estímulo é movido para mais perto do campo central visual. No entanto, VEPs dependem fortemente da direção do olhar da pessoa e, por dependerem de movimento ocular, não se enquadram na definição de sistema independente de músculos e nervos periféricos dada a BCIs (MCFARLAND; WOLPAW, 2011).

P300: Nesse tipo de sinal, pode-se observar um pico positivo em torno de 300ms após o estímulo, o qual pode ser visual, auditivo ou somatossensorial (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Um exemplo conhecido é o de um dispositivo de soletrar que utiliza uma matriz de letras 6x6. Nesse dispositivo, um número fixo e limitado de opções é exibido ao usuário que deve fixar o olhar na opção desejada. Uma luz irá piscar nas linhas e colunas da matriz, repetidamente, e, quando piscar na opção escolhida pelo usuário, o cérebro gerará um sinal involuntário em aproximadamente 300ms após a luz ter piscado sobre a opção desejada. O sistema, então, passa a pegar as letras presentes na linha ou coluna escolhida e, novamente, piscar uma luz entre elas até descobrir, por fim, qual a letra desejada. Considera-se que esse sistema necessita somente da atenção do usuário e, sendo assim, se enquadra dentro da definição de sistema independente (MCFARLAND; WOLPAW, 2011). Uma vanta-

gem é que sistemas desse tipo não necessitam de treinamento (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

SMR: Ritmos sensório-motores são ritmos que podem ser observados de forma não-invasiva e que mudam de acordo com movimento ou imaginação de movimento. Esses sinais são do tipo endógeno, ou seja, não precisam de estímulos específicos para serem gerados. Um dispositivo pode ser controlado por modulações nas amplitudes de alguns desses ritmos. A vantagem mais interessante com relação a SMR talvez seja a reportada por Wolpaw et al. (2002), McFarland e Wolpaw (2011) na qual usuários relataram que depois de um tempo de treinamento conseguiam controlar esses ritmos de uma forma natural, sem precisar se esforçar em como realizar o movimento. Como é comum com tarefas motoras simples, o desempenho se torna automatizado com a prática, o que torna menos provável a sua interferência em outras operações mentais que o usuário possa fazer enquanto esteja usando o BCI.

Dentre os tipos de sinais citados, P300 apresentam vantagens em aplicações de comunicação, enquanto SMR são os que apresentam características mais promissoras para aplicações que envolvem atividade motora, já que é possível aprender a controlar tais ritmos depois de um certo tempo de treinamento; podem ser captados de forma não-invasiva; e possuem comportamento semelhante tanto na realização de um movimento quanto na sua imaginação (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Na fase de aquisição de dados, pode-se também realizar redução de ruídos e processamento de artefatos.

- **Artefatos**

Artefatos são potenciais elétricos indesejados de origem não-cerebral que contaminam a atividade cerebral e podem reduzir a performance de sistemas baseados em BCI, pois afetam a forma de onda dos sinais cerebrais observados (SUBHA et al., 2010; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Em métodos de neuroimagem não-invasivos, como o EEG, eletrodos na superfície do escalpo acabam captando atividades de outras fontes além do cérebro, incluindo ruído ambiente e ruído biológico. Esses ruídos, também chamados de artefatos, reduzem a relação sinal-ruído (do inglês, *signal-to-noise ratio* - *SNR*) e portanto a habilidade de extrair informações significativas dos sinais gravados (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Artefatos podem ser classificados em duas categorias básicas:

- **Artefatos técnicos:** São artefatos considerados como externos, uma vez que são, principalmente, atribuídos a ruídos ambiente, como $50Hz$ ou $60Hz$ da rede elétrica ou mudanças nas impedâncias dos eletrodos.
- **Artefatos fisiológicos:** São artefatos gerados internamente ao usuário, também chamados de artefatos biológicos. Normalmente ocorrem devido a atividades ele-

tromiográficas (EMG), eletrooculográficas (EOG) e eletrocardíacas (ECG). Tais nomes referem-se aos métodos de monitoramento de sinais das atividades que geram artefatos musculares, oculares e cardíacos, respectivamente (NICOLAS-ALONSO; GOMEZ-GIL, 2012; WOLPAW et al., 2002).

Artefatos fisiológicos de atividades **EMG** são gerados por ações que envolvem contrações musculares, tais como: falar, mastigar, engolir, realizar expressões faciais. Esses artefatos normalmente implicam em grandes perturbações em sinais cerebrais. Artefatos de **EOG** são gerados por movimento ocular e piscar de olhos. Piscar produz, normalmente, padrões de alta amplitude sobre sinais cerebrais. Já o movimento ocular produz padrões de baixa frequência. Artefatos de **ECG** são gerados pelo movimento cardíaco. Esses artefatos introduzem um sinal rítmico na atividade cerebral.

Artefatos técnicos podem ser evitados com o uso de uma filtragem apropriada, como o uso de um filtro *notch* de $50Hz$ (ou $60Hz$, dependendo de onde é feita a gravação), o que normalmente é feito já na fase de aquisição de dados. Com isso, o desafio maior está em como lidar com os artefatos fisiológicos. O que pode ser feito na etapa de pré-processamento.

2. Pré-processamento

Esse estágio prepara os sinais para as próximas fases do BCI. Essa preparação inclui a separação dos sinais em janelas de acordo com os eventos pré-definidos (no caso de BCIs síncronos) e o tratamento de artefatos.

De acordo com Nicolas-Alonso e Gomez-Gil (2012), existem diversas formas de se lidar com artefatos fisiológicos. Artefatos podem ser, por exemplo, evitados, rejeitados ou removidos de gravações de sinais cerebrais.

Para evitar artefatos, é pedido aos usuários que evitem piscar ou mexer o corpo durante as gravações. Essa forma não é muito efetiva, uma vez que não se pode evitar produzir artefatos involuntários como os do batimento cardíaco. Sem contar que devido a algumas doenças, o usuário pode não ser capaz de controlar seu movimento muscular.

O método de rejeição de artefatos envolve descartar períodos de tempo, também chamados de épocas, contaminados por artefatos. Esse método pode ser feito manualmente ou automaticamente. A rejeição manual necessita de um especialista para identificar e eliminar épocas contaminadas por artefatos. A rejeição automática é uma forma efetiva de lidar com artefatos, porém, ela falha quando as amplitudes de EOG são muito pequenas. Mais ainda, essa abordagem não é adequada para sistemas BCI que funcionam em tempo real, uma vez que, em geral, rejeitar artefatos significa que o usuário perde o controle do dispositivo quando sinais contaminados por artefatos EMG e EOG são descartados.

Em vez de rejeitar amostras, a abordagem de remoção de artefatos tenta identificar e remover artefatos mantendo o fenômeno neurológico intacto.

Para a remoção de artefatos, pode-se fazer uso de algoritmos ou apenas de filtros passa-alta ou passa-faixa.

Um dos algoritmos mais tradicionalmente usados para remoção de artefatos é o de análise de componentes independentes (do inglês, *independent component analysis - ICA*). ICA é um método efetivo para a remoção de artefatos e é comumente usado para a remoção de artefatos EOG. Contudo, alguns estudos indicam que esse método pode corromper o espectro de frequências da atividade neural subjacente (SUBHA et al., 2010; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

3. Extração de Características

Nessa fase, o objetivo é extrair características específicas do sinal que reflitam a intenção do usuário. Para tal, pode-se fazer uso tanto de filtros quanto de algoritmos. No entanto, o uso deste último tende a dar melhores resultados (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Na revisão de BCIs feita por Nicolas-Alonso e Gomez-Gil (2012) é apresentada uma tabela com alguns dos métodos mais usados para extração de características. Dentre os métodos citados, vale ressaltar o uso dos Padrões Espaciais Comuns (do inglês, *Common Spatial Patterns - CSP*) e o das Transformadas *Wavelet* (do inglês, *Wavelet Transform - WT*).

O **CSP** (e algumas de suas variações) é um método popular e é usado para redução de dimensionalidade. Seu objetivo é maximizar a diferença entre duas classes de sinais, como por exemplo, sinais responsáveis pelo movimento da mão esquerda (classe 1) ou direita (classe 2) (NICOLAS-ALONSO; GOMEZ-GIL, 2012). Porém, esse método é afetado pela resolução espacial, uma vez que eletrodos em algumas posições específicas fornecem informações mais discriminativas para determinadas atividades cerebrais que em outras. Com isso, faz-se necessário o uso de muitos eletrodos, o que aumenta o tempo de processamento e não garante nem uma melhora nos resultados e nem alta precisão na classificação do sistema (MENG et al., 2009). A **WT** é um dos métodos preferidos para revelar variações de tempo não-estacionárias de sinais cerebrais (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Os métodos de extração de características podem extrair informações do sinal no domínio do tempo ou transformar os sinais cerebrais para serem analisados em diferentes domínios, como o domínio da frequência ou o domínio do tempo-frequência (CABRERA, 2009).

Existe uma série de características físicas, matemáticas e estatísticas que podem ser retiradas do sinal no domínio do tempo, com baixa complexidade computacional. Apenas com a extração de parâmetros simples, como: valor médio absoluto, valor máximo de pico

e integral quadrática simples, [Khorshidtalab, Salami e Hamedi \(2012\)](#) obtiveram ótimos resultados para a caracterização de um sinal de EEG.

Contudo, utilizando somente uma análise no domínio do tempo, não se tem informações sobre as frequências presentes no sinal e nem de como elas se comportam. O gráfico da [Figura 4](#) ajuda a exemplificar essa questão. É possível observar que no eixo do tempo o sinal é separado em períodos, enquanto que no eixo da frequência ele não possui nenhuma divisão, não trazendo, portanto, nenhuma informação sobre esta última.




Figura 4 – Exemplo de sinais no domínio do tempo e como eles são detalhados no eixo do tempo, mas não possuem informações distintas de frequência.

Como, neste trabalho, é de interesse observar os ritmos mu e beta, os quais podem ser observados em determinadas faixas de frequência, a análise no domínio da frequência se torna necessária.

Existem alguns algoritmos tipicamente usados em análises no domínio da frequência. Entre eles, estão: a transformada rápida de *Fourier* (do inglês, *Fourier transform - FFT*), a transformada de *Fourier* de tempo curto (do inglês, *Short time Fourier transform - STFT*) e a transformada *wavelet* (do inglês, *wavelet transform - WT*).

- **FFT:** A transformada rápida de *Fourier* considera que um sinal pode ser representado por uma função formada por uma combinação de senos e cossenos de diferentes amplitudes e frequências. Assim, a FFT analisa o sinal e separa suas senoides de acordo com suas frequências.

A transformada funciona, primeiro, traduzindo uma função no domínio do tempo em uma função no domínio da frequência. O sinal pode, então, ser analisado por seu conteúdo de frequência, porque os coeficientes de *Fourier* da função transformada representam a contribuição de cada função seno e cosseno em cada frequência ([GRAPS, 1995](#)).

Porém, quando a transformação para o domínio da frequência ocorre, a informação no domínio do tempo é perdida (CUSIDÓ et al., 2008). Ou seja, é possível observar as frequências presentes no sinal, mas não é possível distinguir em que momento no tempo elas ocorrem. Essa característica pode ser observada na Figura 5.




Figura 5 – Exemplo de como, ao contrário do sinal no domínio do tempo, os sinais disponíveis pela FFT são detalhados no eixo da frequência, mas perdem as informações de tempo.

A separação de frequências é tradicionalmente feita com o uso de uma FFT. Contudo, segundo Oh, Lee e Kim (2014), a FFT possui alta complexidade computacional e informação redundante em aplicações em tempo real. Mais que isso, o fato de não ser possível saber em que momento no tempo as frequências presentes no sinal ocorrem é uma grande desvantagem para a análise de sinais não-estacionários (como os sinais cerebrais), cujas frequências variam com o tempo (CUSIDÓ et al., 2008).

Desta forma, assim como acontece com a análise no domínio do tempo, a análise, somente no domínio da frequência, não traz todas as informações necessárias para a caracterização de um sinal cerebral.

Para suprimir essa necessidade de informação de tempo junto com a informação de frequência, pode-se utilizar uma transformada de *Fourier* de tempo curto.

- **STFT:** A transformada de *Fourier* de tempo curto. é uma transformada de *Fourier* dependente do tempo para uma sequência, e é calculada usando-se uma janela deslizante (CUSIDÓ et al., 2008).

Na FFT, um sinal de tamanho finito é expresso como a soma dos componentes de frequência de duração infinita. Na transformada STFT, o sinal é dividido em pequenos segmentos e o sinal dentro desse segmento é assumido como sendo estacionário. Para esse propósito, uma função janela, cuja largura é igual ao tamanho do segmento, é usada (SUBHA et al., 2010).

A desvantagem da STFT é justamente o fato da sua janela possuir tamanho finito. A todo momento as janelas possuem a mesma largura. Pela Figura 6, pode-se observar que quando a janela é larga (Figura 6(a)), a STFT resulta em uma boa resolução espectral e uma fraca resolução temporal, pois, quanto mais larga, mais específicas são as faixas de frequência (boa resolução espectral) e maiores são os intervalos de tempo em que essas faixas podem ter acontecido (baixa resolução temporal), e quando a janela é estreita (Figura 6(b)), ela fornece uma melhor resolução de tempo e uma pior resolução de frequência, já que, quanto mais estreitas forem as janelas, maiores são as faixas de frequência (fraca resolução espectral) e mais específicos são os intervalos de tempo em que essas faixas ocorreram (boa resolução temporal). Além disso, janelas largas podem violar a condição de estacionariedade.

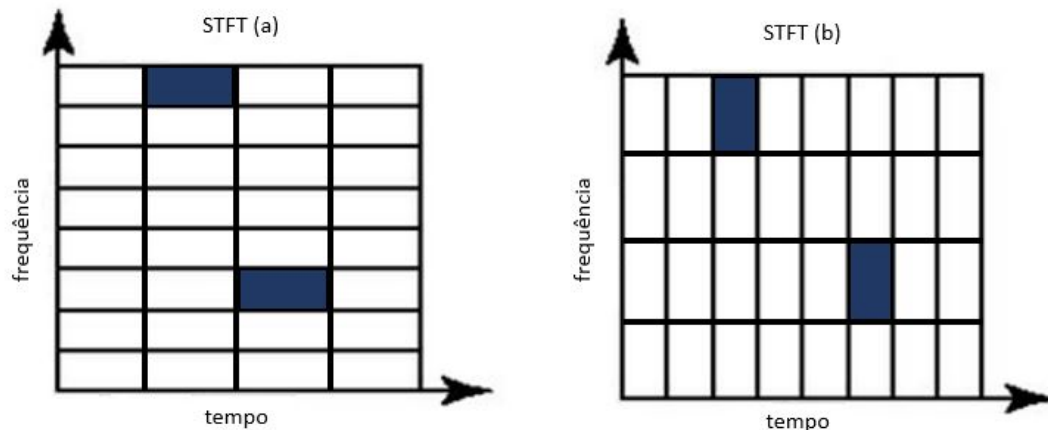


Figura 6 – Exemplo de como os sinais são detalhados conforme a janela escolhida para a STFT. (a) mostra uma STFT com janela larga. (b) mostra uma STFT com janela estreita.

Ademais, de acordo com Cusidó et al. (2008), o algoritmo da STFT precisa de alto poder de processamento para obter uma boa resolução, atribuindo seu elevado custo computacional às suas informações redundantes. Assim, a resolução é um grande problema da STFT, o qual pode ser resolvido com o uso de uma *transformada wavelet* (SUBHA et al., 2010).

- **WT:** A transformada *wavelet* substitui as ondas senoidais da transformada de *Fourier* por translações e dilatações de uma função janela base chamada de *wavelet* (que em algumas literaturas nacionais pode ser chamada de *ondelete* ou de *onda pequena*). A WT decompõe o sinal tanto no domínio do tempo quanto no domínio da frequência em múltiplas resoluções, usando uma janela modulada que é deslocada ao longo do sinal em escalas variadas (KUMAR; INBARANI, 2016). Em outras palavras, as translações podem ser entendidas como o deslocamento da janela ao longo do período de tempo e a dilatação, como a largura da janela em cada momento. Desta forma, altas frequências fornecem boa resolução temporal (porém, resolução espectral

ruim), enquanto que baixas frequências, fornecem boa resolução espectral (mas, baixa resolução temporal), como pode ser observado na Figura 7.

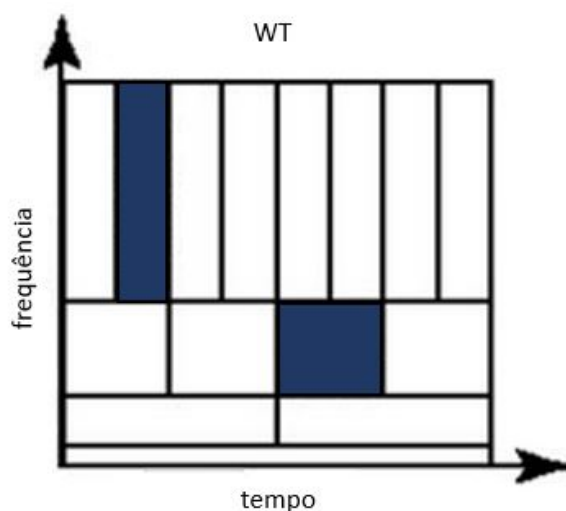


Figura 7 – Exemplo das resoluções da WT de acordo com sua janela.

A transformada *wavelet* é uma ferramenta particularmente adequada para a análise de sinais não-estacionários e é a escolhida para este trabalho.

Após a separação do sinal, deve-se extrair as informações desejadas. As características apropriadas são essenciais para se alcançar alta precisão na classificação de tarefas de imagética motora em EEG (KUMAR; INBARANI, 2016). Para a extração de características que permitam a separação entre movimentos de mãos, pode-se fazer uso de algoritmos ou operações matemáticas. Uma vez extraídas, essas informações são mapeadas em um vetor, chamado de vetor de características. Esse vetor é passado a um classificador, que decidirá à qual padrão o sinal observado pertence.

Algoritmos de classificação podem sofrer de um problema conhecido como *maldição da dimensionalidade* (do inglês, *curse of dimensionality*), onde o número de amostras de treinamento necessário (ou seja, a quantidade de dados necessária para descrever de forma adequada diferentes classes), cresce exponencialmente com a dimensionalidade do vetor de características (NICOLAS-ALONSO; GOMEZ-GIL, 2012; LOTTE et al., 2007). Desta forma, vetores de características de alta dimensão reduzem o desempenho de classificadores que sofrem de *curse of dimensionality*.

4. Seleção de Características

Esta é uma etapa optativa na construção de um BCI. Ela aparece após a fase de extração de características e seu principal objetivo é fazer uma seleção das características retiradas na fase de extração para reduzir a dimensionalidade do vetor de características.

Segundo Kumar e Inbarani (2016), as características de imagética motora em EEG extraídas são de grande dimensão, e normalmente possuem uma quantidade pequena de

amostras para o treinamento de classificadores. Além disso, sinais de EEG são obtidos de vários eletrodos e os sinais desses múltiplos canais são combinados para formar o resultado em um vetor de características de alta dimensionalidade.

Algoritmos de seleção de características tentam reduzir a dimensão do vetor de características eliminando características redundantes e não-relacionadas, procurando não perder informações relevantes (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Dentre as vantagens da redução da dimensionalidade está a melhoria na precisão da classificação, a generalização de aprendizagem do sistema e a redução do custo computacional (KUMAR; INBARANI, 2016).

5. Classificação

O objetivo da fase de classificação é reconhecer as intenções dos usuários com base no vetor de características vindo da etapa anterior.

Diversos métodos de classificação são usados com bom desempenho em BCIs. Lotte et al. (2007), na sua revisão sobre classificadores, concluíram que máquinas de vetores de suporte (do inglês, *support vector machine - SVM*) são particularmente eficientes para BCIs síncronos, atribuindo essa eficiência à sua propriedade de regularização e imunidade ao problema de *curse of dimensionality*. Mesmo assim, é sempre preferível ter um vetor de características pequeno, sendo altamente recomendável usar técnicas de redução de dimensionalidade e/ou seleção de características.

Outro método eficiente para BCIs síncronos é o uso de uma combinação de algoritmos de classificação. Mais que apenas uma combinação entre classificadores, uma combinação de métodos de extração de características e de classificação que funcionem bem juntos pode levar a um aumento no desempenho do sistema.

Dentre as medidas usuais de avaliação de desempenho de um BCI, pode-se citar: precisão (do inglês, *accuracy*), coeficiente *kappa*, informação mútua, sensibilidade (*sensitivity*), especificidade (do inglês, *specificity*), taxa de transferência de bits (do inglês, *transfer bit rate*), falso positivo (do inglês, *false positive - FP*), falso negativo (do inglês, *false negative - FN*), verdadeiro positivo (do inglês, *true positive - TP*) e verdadeiro negativo (do inglês, *true negative - TN*).

Após a classificação, os sinais classificados são traduzidos em comandos específicos para o controle de um dispositivo conectado, como um computador, por exemplo (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

O foco deste trabalho está em BCIs baseados em EEG com imagética motora, cujos sinais de controle são SMR, mais precisamente, ritmos mu e beta observados sobre o córtex motor. Assim, esses ritmos serão cobertos posteriormente e as revisões subsequentes levarão em conta o tipo de BCI de interesse para a ferramenta proposta.

2.3 Eletroencefalograma

O eletroencefalograma é um tipo de neuroimagem utilizado para monitorar atividade elétrica do cérebro gerada pelo fluxo de correntes elétricas durante excitações sinápticas de dendritos nos neurônios (MCFARLAND; WOLPAW, 2011). A comunicação entre as células do cérebro ocorrem por impulsos elétricos que podem ser medidos com o uso de eletrodos posicionados sobre o escalpo do indivíduo (SUBHA et al., 2010).

Uma das maiores vantagens do EEG é o fato de sua gravação ser um processo não-invasivo e de baixo custo comparado a outros processos. Além disso, Niedermeyer e Silva (2005) comprovaram conclusivamente que sinais de EEG são de fato produzidos pela atividade cerebral, em vez de serem apenas uma representação de algum tipo de artefato, como sugerido por alguns cientistas (MCFARLAND; WOLPAW, 2011). Mais ainda, os traços de EEG são diferentes para diferentes atividades cerebrais (SUBHA et al., 2010). Essas e outras vantagens tornam viáveis o uso desse tipo de gravação para monitoramento de sinais cerebrais em pesquisas na área de BCIs.

- **Funcionamento**

Um sistema de gravação de um EEG (Figuras 1 e 8) é composto por eletrodos, amplificadores, conversores A/D, e um dispositivo de gravação. Os eletrodos, normalmente feitos de cloreto de prata ($Ag/AgCl$), obtêm os sinais do couro cabeludo, os amplificadores processam o sinal analógico para aumentar a amplitude dos sinais de EEG para que o conversor A/D possa digitalizar o sinal de forma mais precisa. Finalmente, o dispositivo de gravação, o qual pode ser um computador pessoal ou algo similar, guarda, e exibe os dados (NICOLAS-ALONSO; GOMEZ-GIL, 2012).



Figura 8 – Exemplo de uma touca com eletrodos para aquisição de sinais por EEG. Fonte: (VARGHESE, 2009)

Os sinais captados por EEG são gravados em um arquivo com uma extensão específica que indica como tais arquivos devem ser lidos com suas particularidades e padronizações. Uma extensão muito usada é a *.gdf*. *GDF* é um formato de arquivo de dados médico e científico. Sua sigla significa, em inglês, *General Data Format for Biosignals*, ou em uma tradução literal, *Formato de Dados Comum Para Sinais Biológicos*. Arquivos *GDF* são divididos em duas partes: cabeçalho e sinal. No cabeçalho, são encontradas informações sobre a gravação, como tipos de eventos captados, número total de amostras, frequência de amostragem do sinal, onde ocorrem os inícios de eventos, se o paciente tem algum problema de saúde, entre outras. Já o sinal extraído é disposto como em uma matriz, onde as colunas correspondem aos eletrodos (também chamados de canais) e as linhas são as amostras em cada momento para cada eletrodo.

De acordo com [Nicolas-Alonso e Gomez-Gil \(2012\)](#), para uma medição de EEG, faz-se necessário o uso de, no mínimo, três eletrodos: um eletrodo ativo, um de referência e um eletrodo terra. O sinal de EEG é medido como a diferença de potencial ao longo do tempo entre o sinal ou eletrodo ativo e o eletrodo de referência. O eletrodo terra é usado para medir a tensão diferencial entre os pontos ativo e de referência.

Assim como acontece com o formato dos arquivos, é comum fazer uso de padronizações. O posicionamento dos eletrodos sobre o escalpo é normalmente baseado no sistema internacional *ISO 10-20* ([JASPER, 1958](#)).

ISO 10-20 é o sistema de padrão internacional concebido pela Federação Internacional das Sociedades para Eletroencefalografia (*International Federation of Societies for Electroencephalography*). Esse sistema é baseado na relação entre a localização de um eletrodo e a área do córtex cerebral subjacente ([SUBHA et al., 2010](#)). Usa-se dois pontos de referência na cabeça para definir a localização dos eletrodos. Um desses pontos de referência é o *násio* (*nasion*), localizado no topo do nariz ao nível dos olhos. O outro ponto de referência é o *ínion* (*inion*), que se encontra na protuberância óssea na base do crânio. Os planos transversal e mediano dividem o crânio a partir desses dois pontos. O posicionamento dos eletrodos são determinados fazendo-se marcações nesses planos em intervalos de 10% e 20%, como pode ser observado na [Figura 9](#). As letras em cada localização correspondem às regiões específicas do cérebro, onde *A* representa o lóbulo da orelha, *C* a região central, *P_g* a nasofaríngea, *P* a parietal, *F* a frontal, *F_P* a frontal polar, e *O* a área occipital ([NICOLAS-ALONSO; GOMEZ-GIL, 2012](#)). Os números ímpares subscritos em cada letra indicam eletrodos posicionados no lado esquerdo e os números pares, no lado direito. As letras que possuem um subscrito *Z* encontram-se na região central, no plano longitudinal que vai do násio ao ínion e divide o escalpo em lados direito e esquerdo.

O número de eletrodos usados para a captura dos sinais varia de acordo com o tipo de sinal de controle escolhido. De acordo com [Guger, Edlinger e Krausz \(2011\)](#), para abordagens como P300 ou ritmos oscilatórios de mu e beta, um total de 1 a 8 eletrodos é

o suficiente.




Figura 9 – Posição dos eletrodos no padrão ISO 10-20. (Fonte: [Nicolas-Alonso e Gomez-Gil \(2012\)](#))

• Características

O cérebro é dividido em dois hemisférios, o esquerdo e o direito ([Figura 10](#)). Cada hemisfério é dividido em quatro lobos: o lobo frontal, o parietal, o temporal, e o occipital ([CISOTTO, 2014](#)). A localização de cada um desses lobos pode ser observada na [Figura 11](#). Diferentes áreas do córtex controlam sinais sensoriais e de movimento de diferentes partes do corpo. Com isso, os traços de EEG são diferentes para diferentes atividades cerebrais ([SUBHA et al., 2010](#)).

Seguindo o padrão ISO 10-20, os eletrodos são separados entre si com distâncias de 10% e 20%, cobrindo as principais regiões do cérebro. No entanto, o eletroencefalograma é conhecido por ter uma resolução espacial baixa. Isto significa que devido ao fato dos seus eletrodos se encontrarem na superfície do escalpo, eles estão a alguma distância do tecido cerebral, separados deste pelos revestimentos do cérebro, crânio, tecidos subcutâneos, e o próprio escalpo. Com isso, o sinal é consideravelmente degradado e, portanto, ele não consegue detectar a atividade de um único neurônio, apenas, a atividade sincronizada de um grupo de neurônios ([MCFARLAND; WOLPAW, 2011](#)). Em outras palavras, ter uma resolução espacial baixa dificulta especificar o local exato do neurônio que deu origem à atividade elétrica. Ainda assim, o disparo de um conjunto de neurônios gera uma atividade elétrica intensa o suficiente para ser medida de forma não-invasiva pelo EEG ([KUMAR; INBARANI, 2016](#)). Apesar de sua resolução espacial ser limitada, o EEG possui uma boa




Figura 10 – Os dois hemisférios do cérebro. (Fonte: adaptado de [Cisotto \(2014\)](#))

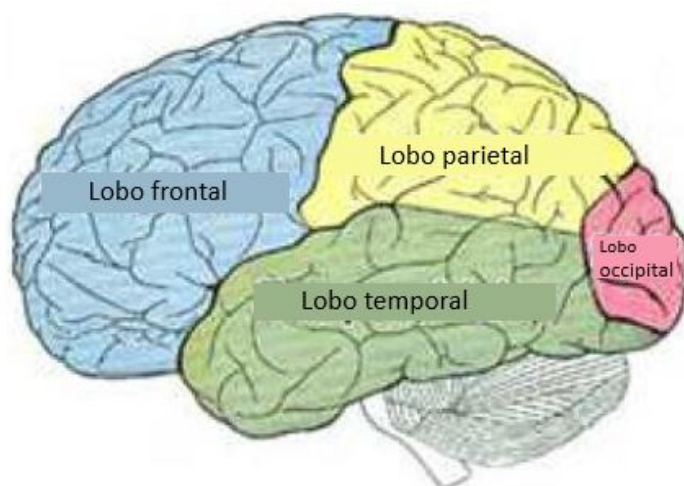


Figura 11 – Os lobos do córtex cerebral. (Fonte: adaptado de [Cisotto \(2014\)](#))

resolução temporal, isto é, possui boa capacidade de detectar mudanças dentro de um intervalo de tempo ([HOANG, 2014](#)). Seu tempo de resposta é baixo, apresentando cerca de 10 milissegundos de atraso, permitindo a análise em tempo real dos sinais do usuário ([NICOLAS-ALONSO; GOMEZ-GIL, 2012](#)).

A amplitude de um sinal típico de EEG é de aproximadamente $10\mu V$ a $100\mu V$ e a sua faixa de frequência, de $1Hz$ a $100Hz$ ([SUBHA et al., 2010](#)). Pequenas amplitudes em sinais de EEG são bastante sensíveis a artefatos. Durante a gravação do sinal, diferentes tipos de ondas de interferências são adicionados ao sinal de EEG, resultando em uma sobreposição de sinais, tanto de artefatos quanto do sinal que será analisado ([MCFARLAND; WOLPAW, 2011](#)). Esses artefatos devem ser detectados e removidos para melhorar a interpretação dos sinais de EEG. Isto pode ser feito com o uso de filtros,

já que, dependendo do tipo de artefato, sua contaminação se dá em uma certa faixa de frequência. Sendo assim, pode-se filtrar o sinal para que ele tenha apenas frequências não contaminadas.

Após uma filtragem para lidar com contaminações presentes nos sinais devido a artefatos, é possível detectar padrões comportamentais em sinais cerebrais ligados a certas atividades. O item 2.4 apresenta uma explicação sobre comportamentos de ritmos sensório-motores em consequência de atividades relacionadas ao controle motor.

2.4 ERD/ERS de Ritmos Sensório-Motores (Mu e Beta)

Pode ser observado na literatura que diversos tipos de tarefas mentais estão relacionadas com a ocorrência de sinais cerebrais específicos (KUMAR; INBARANI, 2016). Estes, podem ser reconhecidos em gravações de EEG e usados como sinais de controle para determinar intenções do usuário. Esses sinais encontrados no EEG, também chamados de ritmos, podem ser classificados de acordo com a faixa de frequência à qual pertencem. Faixas de frequências conhecidas têm sido definidas de acordo com a distribuição espacial sobre o escalpo (isto é, em quais regiões do córtex ocorrem) e/ou significado biológico (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Segundo Cisotto (2014), apesar de sociedades internacionais de EEG definirem padrões de faixas de frequências e ocorrências para reconhecimento de ritmos diferentes, a experiência mostra que nenhuma distinção estrita pode ser declarada. Tanto é que alguns autores apresentam as faixas de frequência desses ritmos conhecidos com pequenas variações, o que pode ser devido a existência tanto de diferenças intra-individuais quanto inter-individuais, além de que, estado de vigília, idade, gênero, temperatura corporal assim como diferentes estados emocionais são fatores comuns que podem modificar o comportamento desses ritmos.

As cinco faixas de frequências mais comuns são conhecidas como: delta (δ), teta (θ), alfa (α), beta (β), e gama (γ), da menor frequência para a maior, respectivamente.

Delta: A atividade delta pode ser encontrada, segundo Nicolas-Alonso e Gomez-Gil (2012), abaixo de $4Hz$. Esse ritmo é encontrado predominantemente em bebês e quanto mais velha a criança, menor sua amplitude. Normalmente são observados em adultos apenas em estado de sono profundo. Uma grande quantidade de atividade delta em adultos acordados é anormal e está relacionado a algumas doenças cerebrais orgânicas (como estado vegetativo persistente) em uma distribuição espacial difusa (CISOTTO, 2014). A atividade delta é encontrada em crianças na região posterior e em adultos na região frontal do cérebro. Devido à sua baixa frequência, é fácil confundir ondas delta com sinais de artefatos causados pelos grandes músculos do pescoço ou maxilar.

Teta: Subha et al. (2010) define a faixa de frequência de teta como sendo de $4Hz$ a $8Hz$. Esse ritmo existe em bebês e crianças normais e também durante estados de sonolência e sono em adultos. De forma similar ao ritmo delta, a presença de uma grande quantidade de atividade teta em adultos acordados está relacionada a doenças neurológicas. Porém, essa atividade pode ser encontrada em pequena quantidade em adultos normais sob estresse emocional principalmente frustração e desapontamento. Além disso, ela tem sido associada à concentração meditativa e à atividade mental (observada, sobretudo, na linha média frontal) (CISOTTO, 2014). As ondas teta costumam ter amplitudes maiores que $20\mu V$ e as regiões parietal e occipital do cérebro são suas principais geradoras.

Alfa: O ritmo alfa está na faixa de frequência de $8Hz$ a $13Hz$. Este é um ritmo encontrado em adultos normais quando relaxados (SUBHA et al., 2010). Sua amplitude é variável, mas em sua maioria, abaixo de $50\mu V$. As amplitudes aumentam quando os olhos fecham e o corpo relaxa e são atenuadas quando os olhos abrem e esforço mental é realizado. O aumento de esforço mental causa supressão de atividade alfa, especialmente das áreas frontais. Esses ritmos podem ser encontrados sobre a região occipital (área do cérebro responsável pelo processamento visual) e podem estar relacionados também à funções de memória do cérebro (NICOLAS-ALONSO; GOMEZ-GIL, 2012). A definição dessa localização é especialmente importante para esse ritmo, pois um ritmo ligado a atividade motora, conhecido como ritmo mu, se encontra praticamente na mesma faixa de frequência de alfa, porém é observado na região do córtex motor.

Beta: Os ritmos beta se encontram na faixa de $13Hz$ a $30Hz$. Esses ritmos estão associados a atividades motoras e aparecem também em situações de concentração e ansiedade. A amplitude dessas ondas normalmente não excede $30\mu V$. Elas podem ser encontradas em quase todo adulto saudável sobre as regiões frontal e central do cérebro (CISOTTO, 2014). Ondas beta são caracterizadas por suas distribuições simétricas quando nenhuma atividade motora está acontecendo. No entanto, em caso de movimento ativo, as ondas beta se atenuam, e sua distribuição simétrica muda (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Gama: Ritmos gama pertencem à faixa de frequência de $30Hz$ a $100Hz$. Ondas gama, em adultos saudáveis, estão relacionadas com certas funções motoras e com alta atividade mental incluindo percepção, resolução de problemas, medo e consciência. A amplitude dos ritmos é inversamente proporcional a suas frequências, isto é, quanto menor a frequência, maior a amplitude. Desta forma, ritmos gama possuem amplitude pequena, menor que as de alfa ou beta, o que dificulta sua detecção sobre o escalpo. Apesar de envolvidos com atividades motoras, ritmos gama são menos usados em BCIs baseados em EEG porque artefatos como EMG ou EOG tendem a afetá-los (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Uma comparação entre as amplitudes dos ritmos citados pode ser observada na

Figura 12.

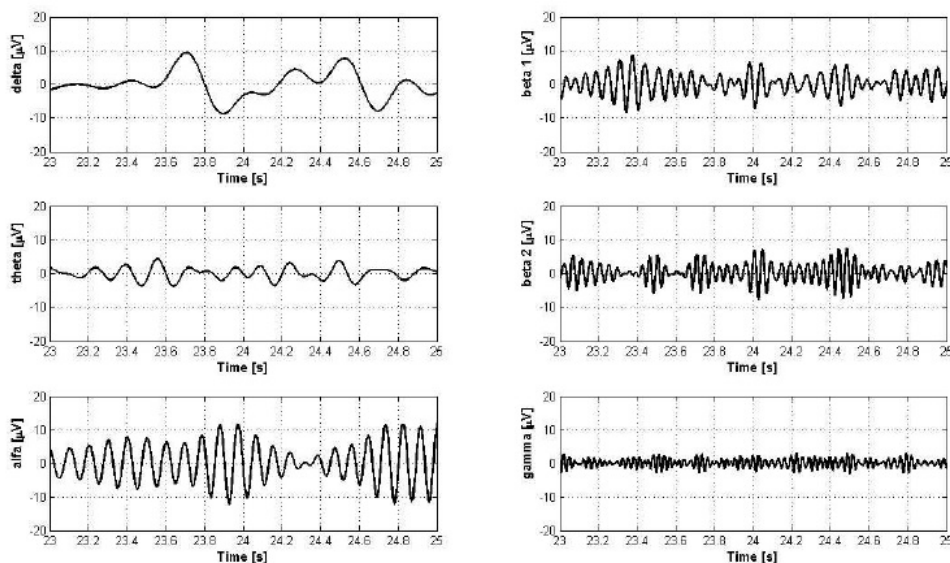


Figura 12 – Exemplo de ritmos observados por um EEG de um adulto saudável. Onde *beta 1* é o chamado *baixo beta* e *beta 2*, *alto beta*. (Fonte: [Cisotto \(2014\)](#))

Um tipo de sinal de controle bastante usado em sistemas de interface cérebro-máquina baseados em EEG com imagética motora são os *Ritmos Sensório-Motores (SMR)*. Ritmos sensório-motores são sinais eletrofisiológicos que podem ser monitorados por eletrodos de EEG localizados no córtex sensoriomotor, região que fica sob os canais *C3*, *Cz* e *C4* no padrão ISO 10-20, como pode ser visto na [Figura 9 \(CABRERA, 2009\)](#).

A amplitude dos ritmos sensório-motores apresenta alterações quando uma atividade cerebral está relacionada a uma tarefa motora. De acordo com [McFarland e Wolpaw \(2011\)](#), diversos estudos foram feitos em que usuários conseguiram mover um cursor para um alvo no topo da tela ou na parte inferior da tela (ou em alvos extras em locais intermediários) controlando a amplitude de SMR. Segundo [Nicolas-Alonso e Gomez-Gil \(2012\)](#), avanços na área mostram que é possível prever movimentos humanos voluntários antes deles ocorrerem com base nas modulações desses ritmos. Mais que isso, essa predição pode ser feita apenas com a imaginação da realização do movimento. Isso é possível pois, como [Pfurtscheller e Silva \(1999\)](#) observou em seu trabalho, os ritmos sensório-motores comportam-se de forma semelhante tanto na realização de um movimento quanto na imaginação da realização do mesmo. A imaginação da realização de um movimento é a ação conhecida como *imagética motora* (do inglês, *motor imagery - MI*) e pode ser definida como preparações mentais de uma atividade motora sem o uso de qualquer movimento muscular ([KUMAR; INBARANI, 2016](#)). De fato, foi comprovado que nem a atividade de EEG nem os movimentos do cursor foram contabilizados em atividade de EMG, significando que modulações SMR não necessitam de movimentos reais ou atividade muscular ([MCFARLAND; WOLPAW, 2011](#)).

Ritmos sensório-motores são formados por ritmos **mu** (μ) e **beta** (β), que são oscilações na atividade cerebral localizadas na faixa de frequência $8Hz$ a $13Hz$ e na faixa de frequência $13Hz$ a $30Hz$, respectivamente.

Os ritmos **mu** são encontrados na mesma faixa de frequência dos ritmos alfa, no entanto, a principal diferença entre esses ritmos está na localização onde são gerados. Enquanto os ritmos alfa são gerados principalmente na região occipital, os ritmos mu podem ser observados sobre a área sensoriomotora do cérebro. Além da localização, esses ritmos diferenciam-se também pelo tipo de atividade com a qual estão relacionados. Alguns autores, como Varghese (2009) e Huang e Wu (2010), consideram que os ritmos alfa são ritmos relacionados com relaxamento e inatividade das áreas visuais enquanto que os ritmos mu estão relacionados com relaxamento e inatividade das áreas sensoriomotoras, uma vez que mu é *bloqueado* com movimento. Seja como for, os ritmos mu são usados como indicativo de movimento, pois sua amplitude diminui quando o usuário realiza um movimento, preparação de movimento ou até mesmo quando ele realiza apenas a imaginação de um movimento (HUANG; WU, 2010; CISOTTO, 2014).

Assim como os ritmos mu, os ritmos beta - em especial o chamado beta central ($16Hz$ - $26Hz$) - também são usados como indicativos de movimento, já que também são *bloqueados* no momento do movimento ou de sua imaginação (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Dizer que os ritmos são *bloqueados* significa que suas amplitudes diminuem quando um certo evento ocorre. Essa diminuição na amplitude de um SMR é chamada de *Dessincronização Relacionada a Evento* (do inglês, *Event-Related Desynchronization - ERD*) e o aumento na amplitude, de *Sincronização Relacionada a Evento* (do inglês, *Event-Related Synchronization - ERS*).

O comportamento típico dos sinais mu e beta com relação a um evento de atividade motora apresenta uma sequência de ERS, ERD e ERS. A Figura 13 retrata esse comportamento. Durante descanso e relaxamento, quando nenhuma entrada sensorial ou saída motora está sendo processada ou produzida, os ritmos mu e beta se encontram sincronizados (ERS). No momento da preparação para um movimento ou da sua execução, os ritmos mu e beta se dessincronizam (ERD). Após o término do movimento, a força do ritmo das ondas do cérebro aumenta e os ritmos voltam a se sincronizar (ERS), com as ondas beta entrando em sincronia mais rapidamente que as ondas mu (PFURTSCHELLER; SILVA, 1999).

Algumas das atividades motoras usadas em experimentos de BCI que usam imagética motora são as de movimento da mão direita, da mão esquerda e dos pés. No entanto, como observado por Varghese (2009), a maioria dos sistemas nos dias de hoje utilizam apenas a detecção de ERD e ERS de ritmo mu de imagética motora das mãos como sinais de controle. Isso ocorre principalmente pelo fato de gravações de EEG possuírem baixa

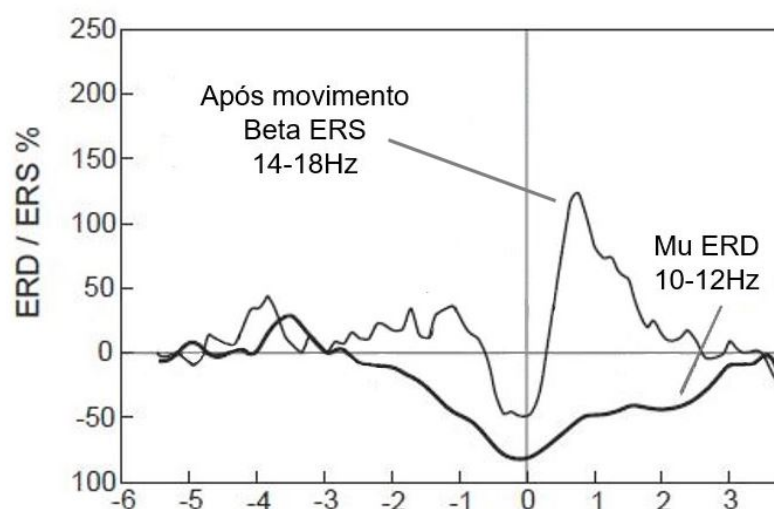


Figura 13 – Comportamento temporal de ERD/ERS de mu e beta gravado de C3 durante um experimento de movimento voluntário que envolve o levantamento rápido do dedo indicador direito. (Fonte: adaptado de [Nicolas-Alonso e Gomez-Gil \(2012\)](#))

resolução espacial, já que o ritmo mu da área dos pés é de difícil detecção por causa da sua localização anatômica dentro da parede mesial na fissura inter-hemisférica.

O cérebro assume o comando de lados opostos do corpo, sendo assim, a imaginação de um movimento da mão direita apresenta ERD dos ritmos mu e beta central na área sensoriomotora das mãos do lado esquerdo do cérebro e a imaginação de um movimento da mão esquerda apresenta ERD dos ritmos mu e beta central na área sensoriomotora das mãos do lado direito do cérebro. Assim, normalmente, monitora-se o canal *C4* para movimentos do lado esquerdo e o canal *C3*, para movimentos do lado direito ([CISOTTO, 2014](#)).

Para se observar os comportamentos de ERD/ERS de ritmos mu e beta, é necessário, primeiramente, separar o sinal em faixas de frequência que permitam a distinção de ritmos. Mais ainda, deve-se usar um método que permita extrair características do sinal que irão ajudar na decisão sobre qual movimento o usuário desejou realizar. No item 2.5 será feita uma discussão sobre a *transforma wavelet*, a qual proporciona tanto a separação de faixas de frequência, quanto a análise do sinal para extração de características, além da vantagem de poder observar o sinal nos domínios da frequência e do tempo, sendo ideal para sinais não-estacionários, cujas frequências variam com o tempo.

2.5 Transformada *Wavelet* (CWT/DWT)

Para sistemas de interface cérebro-máquina com foco em imagética motora, características encontradas nas faixas de frequência de mu e beta possuem maior probabilidade de fornecer melhor separabilidade de classes que características encontradas em outras

faixas de frequência (CABRERA, 2009). Desta forma, faz-se necessária uma separação do sinal em frequências para que se possa observar as informações nelas contidas. Principalmente, aquelas presentes nas faixas dos ritmos desejados.

É boa prática, conhecer, da melhor forma possível, quais as propriedades comportamentais existentes no tipo de sinal que será analisado, para que, então, seja possível escolher algoritmos que possam levar aos melhores resultados de análise. Uma das propriedades de sinais cerebrais que deve ser levada em consideração na construção de um BCI é a da **não-estacionariedade**. Esse termo é usado para indicar que as propriedades espectrais do sinal variam com o tempo (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Devido à essa propriedade, não é indicado utilizar a transformada rápida de *Fourier* na separação das frequências, uma vez que a FFT dá resposta apenas no domínio da frequência e, para sinais desse tipo, é preciso saber também em que momento essas frequências ocorreram e/ou tiveram modificações em suas amplitudes, por exemplo (ZHANG; WANG; HAN, 2010). Deste modo, faz-se necessária a utilização de uma técnica alternativa para o processamento de um sinal com tal comportamento.

A transformada *wavelet* tem sido utilizada para análise de sinais EEG com sucesso em diversos trabalhos (KUMAR; INBARANI, 2016; ZHANG; WANG; HAN, 2010), já que possui suas próprias vantagens em relação a outras transformadas clássicas. Em comparação com a FFT e a STFT, ela tem a vantagem de fornecer, respectivamente, uma localização espectro-temporal e uma análise com múltipla resolução, pois utiliza janelas de tamanhos variáveis (largas para frequências mais baixas e estreitas para as mais altas) (KUMAR; INBARANI, 2016), como pode ser observado na Figura 14.




Figura 14 – Exemplo da função *wavelet* base (família *Daubechies*) no plano espectro-temporal. (Fonte: adaptado de Graps (1995)).

A possibilidade da análise de sinais em diferentes resoluções de frequência (também conhecida como análise de multi-resolução), permite à transformada determinar variações escondidas em padrões, em diversas escalas diferentes (SAINI; DEWAN, 2016). Com isso, a transformada *wavelet* é capaz de revelar aspectos de um dado que outras técnicas de análise de sinais não conseguem, como tendências, e descontinuidades abruptas (CUSIDÓ et al., 2008; GRAPS, 1995). Além disso, sinais de faixas de frequência idênticas podem ser distinguidos por meio da posição temporal. Da mesma forma, é possível separar processos sobrepostos no tempo graças aos diferentes conteúdos de frequência (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

- **Funcionamento**

O ponto inicial, tanto para a transformada *wavelet* quanto para a de *Fourier*, é expressar o sinal como uma combinação linear de funções bases (ZHANG; WANG; HAN, 2010). A função base de uma FFT é formada por uma combinação de senos e cossenos com diferentes amplitudes e frequências. Enquanto que a transformada *wavelet* faz uso de funções *wavelet* para a análise do sinal (GRAPS, 1995). As *wavelets* são geradas a partir de uma única *wavelet* referência, chamada de *wavelet* mãe (do inglês, *mother wavelet*) e consistem em versões deslocadas e dilatadas dessa função base (POLIKAR, 2008; ZHANG; WANG; HAN, 2010).

O fator de **translação** (ou deslocamento) corresponde à informação de tempo do sinal e o fator de **escala** (ou dilatação) fornece informação de frequência. No entanto, vale ressaltar que os valores de escala são inversamente proporcionais à frequência.

Observando a Figura 14, é possível ver que altas frequências (representadas por baixas escalas) possuem boa resolução temporal, porém, uma resolução espectral ruim. A função *wavelet* é comprimida e uma visão mais detalhada do sinal é fornecida. Já as baixas frequências (representadas por altas escalas) possuem boa resolução espectral, mas uma resolução temporal ruim. Uma visão global do sinal é fornecida com o uso de uma função *wavelet* dilatada (KUMAR; INBARANI, 2016).

Existem diversas famílias de *wavelet* base que podem avaliar um sinal de EEG e extrair um vetor de características. Algumas das *wavelets* mais populares são: *Daubechies*, *Morlet*, chapéu México-Colombiano, entre outras. Uma vez que essas funções base possuem propriedades diferentes, elas devem ser escolhidas com base nos requerimentos específicos da aplicação (ZHANG; WANG; HAN, 2010). Na Figura 15, são apresentadas algumas famílias existentes e suas formas de onda.

A família *Daubechies*, assim como outras famílias, possui variações de *mother wavelets* que são classificadas, principalmente, com relação ao seu número de “momentos de desaparecimento” (do inglês, *vanishing moments*). Esses momentos são um conjunto extra

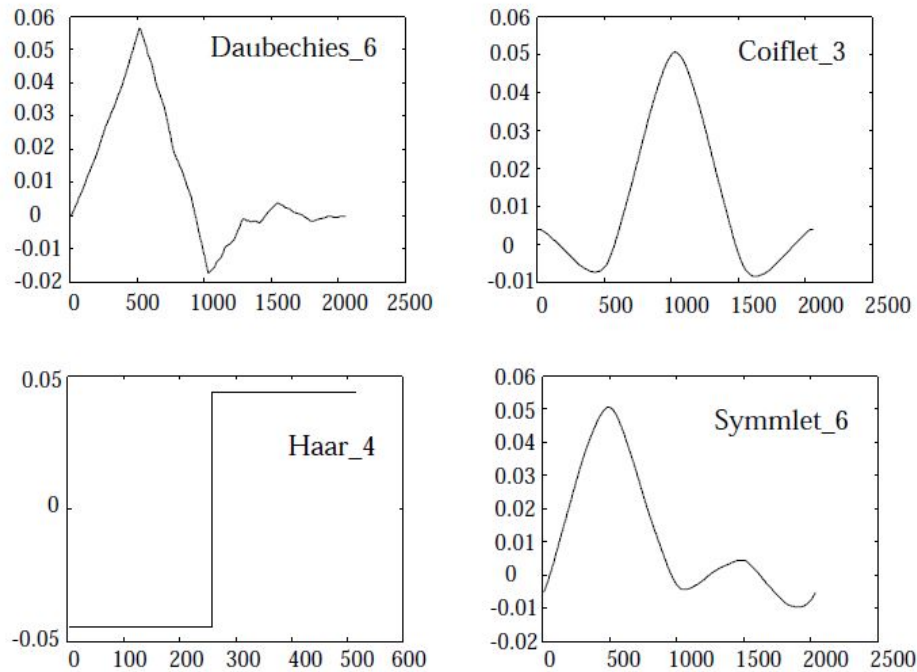


Figura 15 – Exemplo de funções *wavelet* base de diferentes famílias. O número ao lado do nome de cada *wavelet* representa a quantidade de *vanishing moments* da subclasse da família *wavelet* (Fonte: adaptado de Graps (1995)).

de relações matemáticas que devem ser satisfeitas e estão diretamente ligados ao número de coeficientes da *mother wavelet* (GRAPS, 1995).

Uma *mother wavelet* $\psi(t)$ pode ter diversas formas, contudo, ela deve sempre apresentar algumas características, como por exemplo:

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (2.1)$$

$$\int_{-\infty}^{\infty} \psi^2(t) dt = 1 \quad (2.2)$$

A escolha da *mother wavelet* é arbitrária e deve ser feita levando-se em consideração a natureza do sinal analisado. Isto é, a forma da *wavelet* deve refletir o tipo de características que estão presentes no dado (TORRENCE; COMPO, 1998).

Geralmente, para um tipo de aplicação em particular, são feitos testes com vários tipos de *wavelets* e aquela que apresentar melhor eficiência, é escolhida. Segundo Kumar e Inbarani (2016), pesquisas recentes apontam que a *wavelet Daubechies* de ordem 4 (db4) é uma base eficiente e apropriada para analisar e identificar mudanças em sinais de EEG.

- **Tipos de WT**

Existem duas variantes da transformada *wavelet* a ser mencionadas: a transformada *wavelet* discreta (do inglês, *discrete wavelet transform - DWT*) e a transformada *wavelet* contínua (do inglês, *continuous wavelet transform - CWT*).

A **CWT** é definida como a convolução do sinal $x(t)$ com a função *wavelet* $\psi_{s,\tau}(t)$ (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

$$w(s, \tau) = \int_{-\infty}^{\infty} x(t)\psi_{s,\tau}^*(t)dt \quad (2.3)$$

Onde: $w(s, \tau)$ é o coeficiente *wavelet* que corresponde à frequência associada com a escala (ou parâmetro de dilatação) s e o tempo (ou parâmetro de deslocamento) τ da função *wavelet* $\psi_{s,\tau}(t)$, e o símbolo ‘*’ expressa o conjugado complexo. A função *wavelet* $\psi_{s,\tau}(t)$ é uma versão dilatada e deslocada da *mother wavelet* $\psi(t)$:

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}}\psi\left(\frac{t - \tau}{s}\right) \quad (2.4)$$

Ou seja, a CWT é calculada mudando-se a escala da janela de análise, deslocando a janela no tempo, multiplicando-a pelo sinal, e integrando-a sobre todos os tempos. Esse processo produz coeficientes *wavelet* que são funções de escala e posição (SUBHA et al., 2010). Uma vez que seu cálculo envolve a análise do sinal em um alto número de frequências usando múltiplos deslocamentos e dilatações da *mother wavelet*, a CWT gera uma grande quantidade de dados e requer um alto tempo computacional (NICOLAS-ALONSO; GOMEZ-GIL, 2012; SAINI; DEWAN, 2016).

A **DWT** desloca e dilata a *mother wavelet* apenas em certos valores discretos. Mas, ainda assim, oferece informações suficientes tanto para análise quanto para a síntese do sinal original, com uma redução significativa no tempo computacional comparada à CWT (SUBHA et al., 2010). Outra vantagem em relação à CWT, é que a DWT possui menor complexidade, sendo consideravelmente mais fácil de se implementar e fornecendo informação menos redundante quanto à reconstrução do sinal (POLIKAR, 2008).

A DWT pode ser definida pela Equação 2.5.

$$\varphi(m, n) = \frac{1}{\sqrt{s^m}}\varphi\left(\frac{t - n\tau s^m}{s^m}\right) \quad (2.5)$$

Onde:

m é um inteiro para lidar com a dilatação (escala) s ;

n é um inteiro para lidar com a translação τ .

Em DWT, escalas e posições são escolhidas com base em potências de dois chamadas de escalas diádicas (SAINI; DEWAN, 2016). Isto é feito para diminuir os cálculos realizados pela CWT e, ao mesmo tempo, fornecer uma análise mais eficiente e tão precisa

quanto (MISITI et al., 1996). Assim, escolhendo $s = 2$ e $\tau = 1$ e substituindo na equação 2.5, temos:

$$\varphi(m, n) = 2^{-\frac{m}{2}} \varphi(2^{-\frac{m}{2}} t - n) \quad (2.6)$$

- **Funcionamento da DWT**

Devido ao fato do sinal original poder ser representado em termos de uma expansão *wavelet* (usando coeficientes em uma combinação linear das funções *wavelet*), operações de dados podem ser feitas usando apenas os coeficientes *wavelets* correspondentes (GRAPS, 1995). De fato, segundo Kumar e Inbarani (2016), esses coeficientes fornecem uma representação sólida do sinal EEG em ambos os domínios.

Na DWT, o sinal original é decomposto com o uso de filtros passa-alta e passa-baixa, fornecendo informações de detalhe e de aproximação (POLIKAR, 2008). No entanto, desse modo, tem-se o dobro da quantidade de dados do sinal de entrada, pois tanto a saída resultante do filtro passa-alta quanto a do passa-baixa, terão, aproximadamente, a mesma quantidade de amostras do sinal original. Assim, é introduzida a noção de *downsampling por 2*, que nada mais é do que a eliminação de informações redundantes, mantendo um ponto sim e outro não, ficando com, aproximadamente, metade dos pontos do sinal de entrada (MISITI et al., 1996).

Logo, supondo que o sinal original seja constituído de 1000 amostras (Figura 16), então, após ser passado por um filtro passa-alta e sofrer *downsampling* de 2, o resultado será um coeficiente de detalhe (cD) que representa altas frequências e que é constituído de aproximadamente 500 amostras. Do mesmo modo, após ser passado pelo filtro passa-baixa e sofrer *downsampling* de 2, a saída será um coeficiente de aproximação (cA) que representa baixas frequências e que também é constituído de aproximadamente 500 amostras (MISITI et al., 1996).

Pode-se observar na Figura 17, um algoritmo genérico para j níveis de decomposição. Para a análise de mais níveis de decomposição, esse processo de filtragem e *downsampling* é repetido com o coeficiente de aproximação resultante até que o número de níveis de decomposição desejado seja atingido. Assim, a primeira saída do sinal original cA_j é disponível na aproximação cA_1 e detalhe cD_1 . A primeira aproximação cA_1 é decomposta em cA_2 e cD_2 e assim por diante (KUMAR; INBARANI, 2016).

Os j coeficientes de detalhe (cD_j a cD_1) e uma aproximação final (cA_j), podem ser apresentados em um vetor como na Equação 2.7:

$$coef = [cA_j, cD_j, \dots, cD_1] \quad (2.7)$$

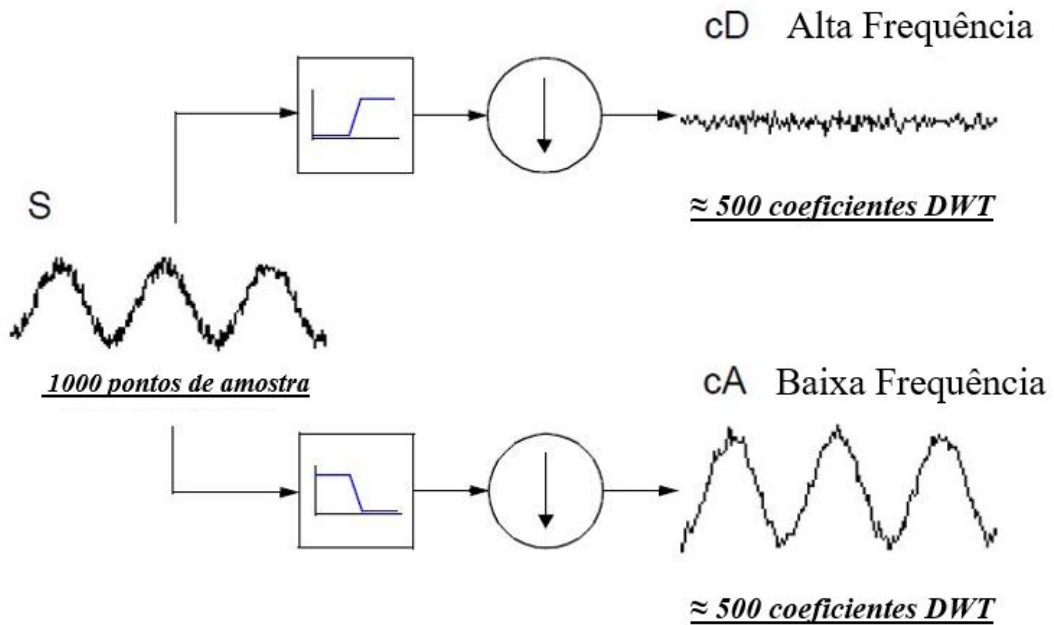


Figura 16 – Algoritmo do funcionamento da DWT para um nível de decomposição. (Fonte: adaptado de Misiti et al. (1996)).

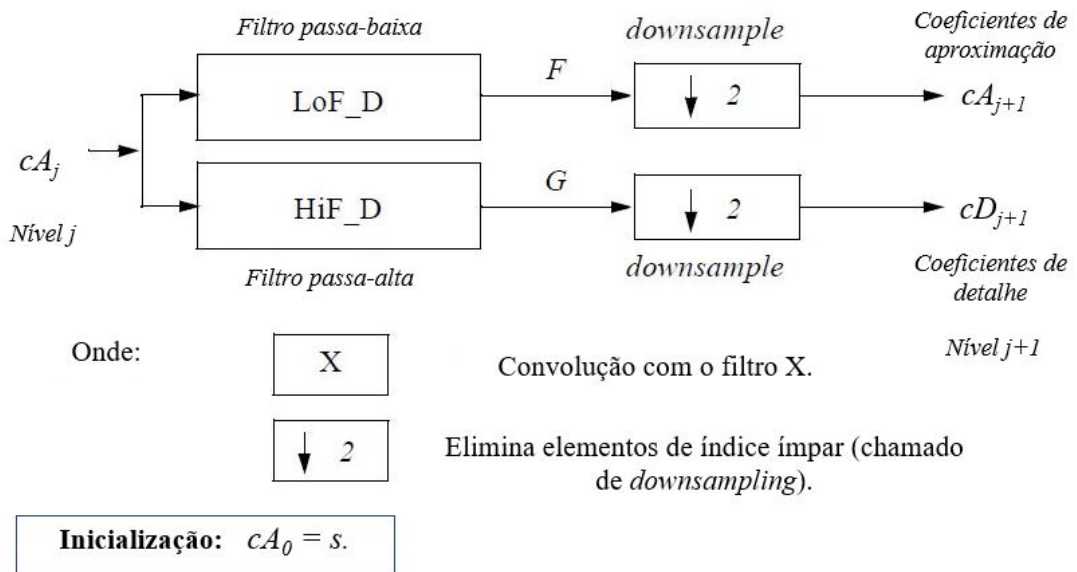


Figura 17 – Algoritmo da DWT para diversos níveis de decomposição. (Fonte: adaptado de Misiti et al. (1996)).

Esses coeficientes cobrem todo o espectro de frequência com diferentes larguras de banda e a cada nível de decomposição, tanto a frequência central quanto a largura de banda são divididas pela metade. Sendo assim, a faixa de frequência de menor valor se encontra no coeficiente de aproximação cA_j e, a medida que o coeficiente de detalhe vai diminuindo, os valores de frequência vão aumentando. Ou seja, cD_1 possui a faixa de frequência mais alta (CUSIDÓ et al., 2008).

Além da escolha de qual *mother wavelet* utilizar, é preciso selecionar, também, o número de níveis de decomposição na análise dos sinais de EEG. O nível de decomposição depende da frequência de amostragem e das faixas de frequência desejadas.

Se o sinal for decomposto em 5 níveis, por exemplo, o vetor de coeficientes resultantes é dado pela Equação 2.8 e a Tabela 1 mostra, de forma simplificada, como as faixas de frequência são separadas.

$$coef = [cA_5, cD_5, cD_4, cD_3, cD_2, cD_1] \quad (2.8)$$

Tabela 1 – Exemplo dos coeficientes e suas faixas de frequências (do inglês, *bandwidth - BW*) para uma DWT de ordem 5. Onde f_s é a frequência de amostragem.

Coeficientes de aproximação	BW	Coeficientes de detalhe	BW
A_1	$0 - f_s/4$	D_1	$f_s/4 - f_s/2$
A_2	$0 - f_s/8$	D_2	$f_s/8 - f_s/4$
A_3	$0 - f_s/16$	D_3	$f_s/16 - f_s/8$
A_4	$0 - f_s/32$	D_4	$f_s/32 - f_s/16$
A_5	$0 - f_s/64$	D_5	$f_s/64 - f_s/32$

Pelo teorema de *Nyquist*, a maior frequência que pode estar contida no sinal é de $f_s/2$. Então, a banda mais alta, que corresponde ao nível 1 da decomposição, cobre de $f_s/2$ a $f_s/4$, onde f_s é a frequência de amostragem do sinal original.

Consequentemente, a DWT pode ser usada para a separação das faixas de frequência de ritmos sensório-motores de um sinal de EEG. Basta calcular as faixas de acordo com a frequência de amostragem e, então, escolher os respectivos coeficientes.

- **Propriedade ortogonal e a preservação de energia**

Outra propriedade interessante da DWT é que quando se utiliza uma *mother wavelet* com propriedade ortogonal, a DWT também possui essa propriedade. Por consequência, pela *lei de Parseval*, a transformada apresenta, então, preservação de energia. Isto é, a energia do sinal é preservada e particionada entre seus coeficientes. (THE MATHWORKS, INC., 2017). Com isso, além da amplitude dos ritmos, a energia também pode ser uma característica interessante para a formação do vetor de características, já que, de acordo

com (TING et al., 2007), as energias nas faixas de frequência de EEG são diferentes durante a imaginação de diferentes tarefas.

Na seção 2.6 será feita uma revisão de alguns estudos recentes na área, comparando seus resultados e metodologias.

2.6 Estudos Desenvolvidos na Área

Nicolas-Alonso e Gomez-Gil (2012) fazem uma revisão sobre o estado da arte de interface-cérebro máquina até recentemente (2012), incluindo os principais algoritmos usados em todas as fases do processo de construção de um BCI e as diferentes aplicações existentes para esses sistemas. De acordo com os autores, devido ao desenvolvimento de *hardware* e *software* mais baratos, o número de artigos publicados com relação a tecnologia de interface neural tem crescido exponencialmente na última década. Eles apontam ainda, que a grande maioria dos estudos de BCI tratam das dimensões de tempo, frequência e espaço dos sinais cerebrais de forma independente e que considerar essas dimensões em conjunto (ou seja, utilizar informações de diferentes domínios) pode levar a um aumento significativo no desempenho de BCIs.

Huang e Wu (2010) propõem um método de extração de características de imagética motora de sinais de EEG, baseado nas propriedades ERD/ERS de ritmos mu e beta dos canais C3 e C4, utilizando apenas a média da energia de cada canal para a composição do vetor de características. Os ritmos são obtidos após uma filtragem feita com o uso de um filtro elíptico passa-faixa de 8 a 30Hz. A separação das faixas de frequência é feita com uma *wavelet packet transform* - WPT (uma variação da WT) com função *wavelet* db4. A informação de energia é formada pelo quadrado da amplitude no domínio do tempo e a classificação é feita com a função *classify* do MATLAB. Para a análise dos resultados, utilizam o banco de dados da Competição de BCI de 2003 de sinal de mesmas características. A classificação é feita para duas classes, sendo elas, sinais imaginados de mão esquerda e de mão direita. Os resultados obtidos mostraram que o método proposto é bem simples e que a taxa de precisão máxima atingida na classificação do conjunto de teste (88,571%), está no mesmo nível dos valores máximos atingidos pelos participantes da competição. Sendo que o primeiro colocado atingiu 89,29% e o segundo, 84,29%.

Já Alomari, Samaha e AlKamha (2013) apresentam novas abordagens para extração e classificação do mesmo tipo de sinal e classes dos autores citados anteriormente, porém, para conjunto de dados, características e canais diferentes. A base de dados utilizada pelos autores é uma base criada e contribuída para *Physionet* pelos desenvolvedores do sistema de instrumentação BCI2000. O pré-processamento dos dados foi feito com uma *toolbox* do EEGLAB no MATLAB e a remoção de artefatos foi feita usando remoção automática de artefatos (do inglês, *automatic artifact removal* - AAR). Os dados foram

divididos em épocas com base nas características de ERD/ERS e movimento relacionado a potenciais corticais (do inglês, *movement-related cortical potentials - MRCP*). Os ritmos mu e beta dos canais C3, Cz e C4 foram isolados para a análise de ERD/ERS e os ritmos delta de oito canais (FC3, FCz, FC4, C3, C1, Cz, C2, C4) foram isolados para análise de MRCP. Um filtro passa-faixa de 0,5 *Hz* a 90 *Hz* foi usado para remover os deslocamentos DC e minimizar a presença de artefatos de filtragem em fronteiras de épocas. Além disso, um filtro *notch* também foi usado para remover os 50 *Hz* de ruído de rede elétrica. Para a remoção de artefatos de EOG e EMG, foi implementada uma *toolbox* de AAR como um *plug-in* de EEGLAB no MATLAB. Para isolar os ritmos desejados, fizeram uso de filtros IIR curto. Um passa-faixa de 8 a 30*Hz* foi aplicado nos conjuntos de dados com épocas de ERD/ERS para isolar os ritmos mu e beta, e um passa-baixa com frequência de corte de 3 *Hz* foi usado nas épocas com MRCP para isolar os ritmos delta. Depois do processo de AAR, um algoritmo de análise de componentes independentes (do inglês, *independent component analysis - ICA*) foi usado. Assim, as características usadas para a montagem do vetor de características foram ERD, ERS, MRCP e média, potência e energia de ativação dos componentes independentes resultantes. Para a classificação, foram empregados dois algoritmos de aprendizado de máquina: redes neurais (do inglês, *Neural Networks - NNs*) e SVMs. Por fim, os autores fazem uma comparação entre combinações de características e precisão para cada um dos classificadores testados. Onde, os melhores resultados vieram da SVM, sendo que o maior valor de precisão foi de 97,1% para potência, energia e tipo de evento (ERD/ERS/MRCP) como características e o segundo melhor valor foi de 94,1% quando foram usadas apenas as características de energia e tipo de evento. O melhor resultado para NN foi de 89,8%, também para as características de potência, energia e tipo de evento. Segundo os próprios autores, sua metodologia pode não ser a melhor, mas é simplificada e eficiente.

Alvarez-Meza, Velasquez-Martinez e Castellanos-Dominguez (2013) propõem uma abordagem de análise de relevância de características baseada em um método de decomposição de autovalores e autovetores (*principal component analysis - PCA*) para discriminação automática entre duas classes de MI em sinais de EEG. Apenas os canais C3, Cz e C4 são usados e os artefatos oculares não foram eliminados, segundo os autores, para obter resultados mais realistas e para afirmar a robustez do método proposto a esses tipos de artefatos. O conjunto de características foi escolhido de forma a representar, da melhor maneira possível, o processo estudado. Esse conjunto consiste em informações comumente usadas em pesquisas da área, sendo que três estratégias de caracterização são baseadas em frequência (PSD, DWT, e CWT) e uma é baseada no tempo (parâmetros *Hjorth*). O classificador utilizado foi a SVM e para validar o sistema, o conjunto de dados vindo da Competição de BCI de 2008 - conjunto B e o método de *10-fold cross-validation* são usados. Para a CWT, DWT e parâmetros *Hjorth*, o primeiro e segundo momentos estatísticos (média e variância, respectivamente), além do valor máximo, são usados como caracterís-

ticas. Já a magnitude de PSD é parametrizada com base no primeiro e segundo momentos estatísticos, apenas. Como resultado, concluíram que PSD fornece melhores valores de relevância que as outras estratégias analisadas. Além disso, para PSD, os canais C3 e C4 fornecem melhor variabilidade que Cz. A DWT também fornece informações relevantes, com os canais C3 e C4 apresentando maior relevância. Por fim, os resultados obtidos são aceitáveis e permitem discriminações estáveis de MI em comparação com abordagens de estado da arte.

Devi e Inbarani (2016) propõem um novo classificador para imagética motora de sinais de EEG usando os conjuntos de dados das competições de BCI III - conjunto de dados 3a (quatro classes: mão esquerda, mão direita, pés e língua) e IV - conjunto de dados 1 (duas classes: mão direita e pé). O pré-processamento é feito com um filtro *Chebyshev* tipo II. A extração (principalmente de ritmos sensório-motores) é feita usando uma DWT com uma *wavelet* da família *Daubechies* (db4) e a classificação é feita com um conjunto aproximado de multigranulação de precisão variável (do inglês, *Variable Precision Multigranulation Rough Set*). A precisão do classificador proposto depende dos valores de alfa e beta (parâmetros do classificador). No conjunto de dados de treinamento, foram feitos testes do algoritmo com diferentes valores de parâmetros (alfa e beta) usando validação cruzada (*cross-validation*) e os quatro melhores valores foram verificados no conjunto de teste final. Para certos valores de alfa e beta, a precisão atingida foi alta e os resultados mostram que é possível usar o algoritmo proposto para classificação de dados EEG e obter bons resultados comparado à técnicas existentes. Sendo que, para ambos os conjuntos de dados, a variação nos valores de alfa e beta resultaram em precisão maior que 90%.

Mais recentemente, Kumar e Inbarani (2016) propuseram um novo método para a seleção de características que combina as forças das técnicas de conjuntos aproximados e otimização de enxame de partículas (do inglês, *particle swarm optimization - PSO*), a fim de encontrar o menor conjunto de características relevantes entre aquelas extraídas com uma DWT de ordem 5 e função *wavelet* db4. Os autores propuseram também, uma nova técnica de classificação de MI para múltiplas classes (mão esquerda, mão direita, pés e língua), chamada de *neighborhood rough set (NRSC)*. O conjunto de dados usado é o da competição de BCI de 2008 - conjunto de dados IIa. O pré-processamento é feito com um filtro passa-faixa *Chebyshev* tipo II de 5 a 30 Hz. São calculadas 16 características a partir dos coeficientes da DWT. Dessas, nem todas são relevantes, então, usando o algoritmo de seleção proposto, é selecionada para cada indivíduo, uma quantidade mínima de características discriminativas. Para a análise dos resultados, é feita uma comparação entre os resultados de precisão do sistema proposto e os dos vencedores da competição do banco de dados usado. A média dos valores do método proposto atinge melhores valores de *kappa* que os outros 9 métodos comparados. Sendo que a classificação geral de desempenho foi alcançada com 80,9848% de precisão. Os autores concluem, assim, que a combinação

do filtro usado no pré-processamento e dos métodos de extração e classificação, é efetiva.

Observando os trabalhos mencionados, pode-se notar que vários estudos são feitos tanto nas fases de extração de características quanto na de classificação com o objetivo de melhorar o desempenho de sistemas BCI baseados em imagética motora. É possível perceber também, o quanto as tecnologias propostas e os tipos de informações usadas variam. Em alguns trabalhos, como o de [Kumar e Inbarani \(2016\)](#), por exemplo, os autores propõem novos métodos e explicam que são calculadas uma certa quantidade de características, mas não especificam quais são elas. Essa variedade de métodos e omissão de especificações, dificulta a comparação entre algoritmos, uma vez que uma combinação de características e algoritmos pode ser mais adequada que outra e fornecer maior precisão. Por esta razão, é proposta uma ferramenta de parâmetros não-variáveis e dados abertos, em que os artefatos são tratados sempre da mesma maneira e a separação de ritmos é feita sempre com o mesmo algoritmo.

No [Capítulo 3](#), será explicada a construção da ferramenta proposta, tomando como base os trabalhos mais atuais e seus resultados, a fim de permitir o teste de algoritmos que levam aos melhores valores de precisão para o sistema montado.

3 Desenvolvimento

De acordo com a classificação de tipos de BCIs, o sistema desenvolvido é **não-invasivo**, já que a forma de monitoramento de sinais utilizada é o EEG. Os dados utilizados foram gravados de maneira que houvesse sinalizações de entrada e os sinais cerebrais foram analisados durante uma janela de tempo pré-definida. Portanto, o BCI desenvolvido é também classificado como **síncrono**. As sinalizações foram usadas apenas como indicações para que o usuário fizesse a imaginação de um movimento de forma voluntária, desta forma, o sistema é do tipo **endógeno**.

A ferramenta é implementada na linguagem MATLAB[®] e utiliza, como sinal de entrada, uma base de dados pública e bastante conhecida, vinda da competição de BCIs de Graz do ano de 2008. Esta base contém dados de gravações de EEG de imagética motora que incluem movimento de mãos direita e esquerda. Os sinais gravados são tratados e separados em ensaios e épocas com limites definidos para observação de ERD/ERS de ritmos sensório-motores mu e beta. Os sinais são filtrados e separados nas bandas de frequências dos ritmos escolhidos com o uso de uma DWT e os coeficientes correspondentes às bandas de frequência de mu e beta são selecionados. A ferramenta pode entregar como resultado um vetor de características simples formado pelas características de energia, média, variância e amplitude máxima dos coeficientes da DWT, o qual poderá ser usado como entrada para um algoritmo de classificação; ou apenas esses mesmos coeficientes, os quais podem ser usados tanto para a escolha de características arbitrárias diferentes das fornecidas, quanto como entrada de algoritmos de extração, que procuram, para cada usuário, as melhores características possíveis. Uma visão geral da ferramenta proposta é apresentada na [Figura 18](#).

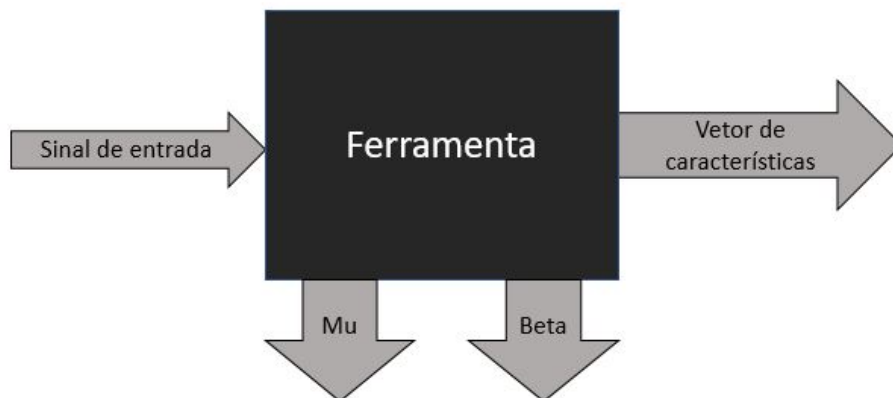


Figura 18 – Visão abstrata da ferramenta proposta.

De forma geral, o trabalho foi feito seguindo os três primeiros estágios presentes em um BCI típico, como pode ser visto na [Figura 19](#).




Figura 19 – Estágios da construção do BCI presente neste trabalho e o vetor de características resultante.

Tanto a leitura do arquivo quanto o código para o processamento do sinal e para o algoritmo de extração de características foram realizados na linguagem MATLAB[®] com ajuda de *toolboxes* como o *biosig* (SCHLÖGL; BRUNNER, 2008) e o *eeglab* (DELORME; MAKEIG, 2004). A ferramenta MATLAB[®] (THE MATHWORKS, INC., 2011) foi escolhida para o trabalho por possuir facilidades para a análise deste tipo de sistema. Ela disponibiliza, de forma simplificada, visualização gráfica; funções para leitura de arquivos de diferentes extensões; facilidade de integração de outras ferramentas, como o *biosig*; além de funções já existentes de análises estatísticas e de algoritmos como o da DWT.

A [Figura 20](#) exemplifica com mais detalhes as etapas seguidas para a realização do código da ferramenta. A seguir, será explicada cada uma delas.

3.1 Aquisição de Dados

A forma de captação e a formação do conjunto de dados limita algumas escolhas de algoritmos e análises. Para simplificar o projeto, é utilizado um conjunto de dados previamente gravado.

Como citado anteriormente, os dados utilizados na ferramenta proposta são advindos do banco de dados feito para a *competição IV de BCI de 2008* em Graz na Áustria. Diversos tipos de gravações estão disponíveis nesse banco e o conjunto de dados usado para o teste da ferramenta desenvolvida é o de nome *BCI IV Dataset IIIa*. Esse conjunto foi escolhido por já ter sido gravado da forma necessária para o tipo de análise desejado, isto é, ele possui sinais de EEG, os quais foram gravados com a imaginação de movimentos, permitindo a análise de ritmos mu e beta em atividades motoras. Outra vantagem do uso desse conjunto é o fato dele ser público e fazer parte de uma base de dados relativamente conhecida na área. Existem diversos outros trabalhos que a utilizam e isto possibilita comparações mais sensatas entre sistemas e algoritmos.

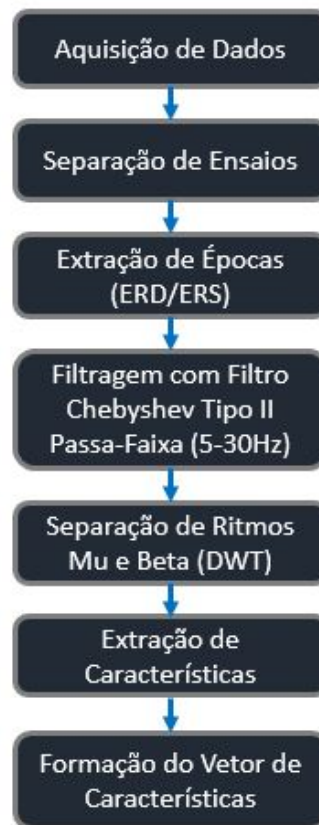


Figura 20 – Etapas do código da ferramenta proposta.

- **Descrição do conjunto de dados**

O conjunto de dados é formado por gravações de sinais de EEG com atividade de imagética motora de nove indivíduos. Esses deveriam realizar a imaginação de quatro movimentos, sendo eles: da mão esquerda, da mão direita, dos pés, e da língua. Para cada indivíduo, foram gravadas duas seções em dias diferentes. Cada seção possuindo seis rodadas separadas por intervalos de curtos períodos. Uma rodada continha 48 ensaios (*trials*), sendo 12 ensaios para cada um dos 4 movimentos, resultando em um total de 288 ensaios por seção.

As gravações dos ensaios foram feitas em aproximadamente 9 segundos. No início ($t = 0s$), uma cruz aparecia em uma tela preta e um som de aviso podia ser escutado. Depois de dois segundos ($t = 2s$), um sinal de indicação na forma de uma seta apontando para esquerda, para a direita, para baixo ou para cima (correspondendo a um dos movimentos que o indivíduo deveria imaginar: mão esquerda, mão direita, ambos os pés ou língua, respectivamente) se apresentava na tela por 1.25s. Os indivíduos foram pedidos para imaginar o movimento correspondente até que a sinalização desaparecesse da tela, em $t = 6s$. A partir de então a tela ficava preta novamente indicando um curto período de pausa até o início do próximo ensaio.

Vinte e dois eletrodos foram dispostos sobre o escalpo dos indivíduos conforme

o sistema internacional 10-20. Os sinais foram amostrados com $250Hz$ e filtrados com um filtro passa-faixa entre $0.5Hz$ e $100Hz$, além de um filtro *notch* de $50Hz$ para eliminar o ruído da rede elétrica.

Para maiores detalhes sobre o conjunto de dados, pode-se consultar o arquivo de descrição da competição [Brunner et al. \(2008\)](#), onde pode-se encontrar especificações de como foram realizadas as gravações e de como o conjunto de dados pode ser usado.

Neste trabalho foram utilizados apenas os ensaios de uma seção relacionados à mão esquerda e à mão direita. Assim, o total de ensaios usados por seção é de 144, isto é, 72 gravações para cada mão.

Atividades diferentes geram ativação de neurônios em regiões diferentes. A atividade motora gera atividade neural na área do córtex motor. Assim, apenas os eletrodos *C3*, *Cz* e *C4* foram considerados. Além disso, segundo [Alomari, Samaha e AlKamha \(2013\)](#), muitos dos canais de EEG parecem apresentar informações redundantes, o que significa que não é necessário analisar todos os canais disponíveis. Essa forma com menos eletrodos é usada para realizar o objetivo com boa precisão e menos trabalho computacional.

Pela convenção da ISO 10-20, números ímpares indicam hemisfério esquerdo, enquanto os números pares, o direito. Desta forma, o canal *C3* se encontra no hemisfério esquerdo e *C4* no direito ([Figura 21](#)). É sabido, também, que os sinais observados são contralaterais ao movimento. Portanto, podem-se observar alterações no sinal do eletrodo do lado esquerdo quando houver um movimento de mão direita e vice-versa.




Figura 21 – Posição dos eletrodos no padrão ISO 10-20.

A leitura do arquivo de gravação de extensão GDF é feita com a função *sload* do *biosig*. Essa função fornece duas variáveis como resultado: uma com as informações contidas no cabeçalho e outra com todos os sinais. Ela recebe como argumento o nome do

arquivo de gravação e pode receber, também, um conjunto de canais, para que já na leitura do arquivo seja possível utilizar sinais apenas dos eletrodos desejados. O [Algoritmo 3.1](#) mostra um exemplo de uso da função *sload*. Onde *filename* representa o arquivo a ser lido; os números 8, 10 e 12 representam, respectivamente, os canais *C3*, *Cz* e *C4*; *s* é a variável que contém os sinais gravados e *HDR* é a variável que contém as informações sobre os sinais.

Algoritmo 3.1 – Exemplo de uso da função *sload*

```
[s,HDR] = sload(filename, [8 10 12]); % sinais dos eletrodos C3, Cz e C4
```

3.2 Separação de Ensaios e Extração de Épocas (ERD/ERS)

Para cada indivíduo é disponibilizado um arquivo com os ensaios de uma seção. Os dados nesse arquivo foram gravados como uma gravação única. Sendo assim, faz-se necessário separar os ensaios correspondentes a cada tipo de movimento. Com as informações fornecidas na descrição dos dados e no cabeçalho do arquivo GDF é possível separar cada ensaio feito e, em cada ensaio, extrair épocas. Com as épocas pode-se observar o momento anterior à imaginação do movimento, o momento em que a imaginação está acontecendo e o momento em que ele termina e a pessoa volta ao estado de relaxamento.

Para a separação dos ensaios, foi criada uma função que utiliza as informações de inícios de gravações presentes no cabeçalho. O tamanho dos ensaios foi calculado subtraindo-se o valor de amostra do início do ensaio seguinte com o início do ensaio atual. Os ensaios foram separados por movimento (ou classe) e por canal. Sendo assim, cada canal possui 72 ensaios de cada movimento (mão esquerda e mão direita). E para cada ensaio, extraiu-se épocas.

Neste trabalho, as épocas foram selecionadas de forma a possibilitar a observação, principalmente, de comportamentos ERD e ERS dos ritmos mu e beta. ERD pode ser extraído de 1 a 2 segundos antes do movimento de fato. E ERS pode ser observado dentro de 1 a 2 segundos depois do movimento ([ALOMARI; SAMAHA; ALKAMHA, 2013](#)).

A [Figura 22](#) representa como foi feita a gravação dos sinais. Como os ensaios separados possuem em torno de 9 segundos, foi feita uma extração de épocas com duração de apenas 5 segundos para a análise dos ritmos mu e beta. Uma vez que o movimento é imaginado de $t = 3s$ a $t = 6s$, as épocas foram extraídas com início em $t = 2s$ e fim em $t = 7s$. Como o MATLAB utiliza a ideia de matriz, cada ensaio é um vetor na matriz de ensaios. Assim, para a extração das épocas foi retirado apenas um subconjunto do vetor de ensaios com os valores de início e fim multiplicados pela frequência de amostragem, já que os dados são tratados como amostras.

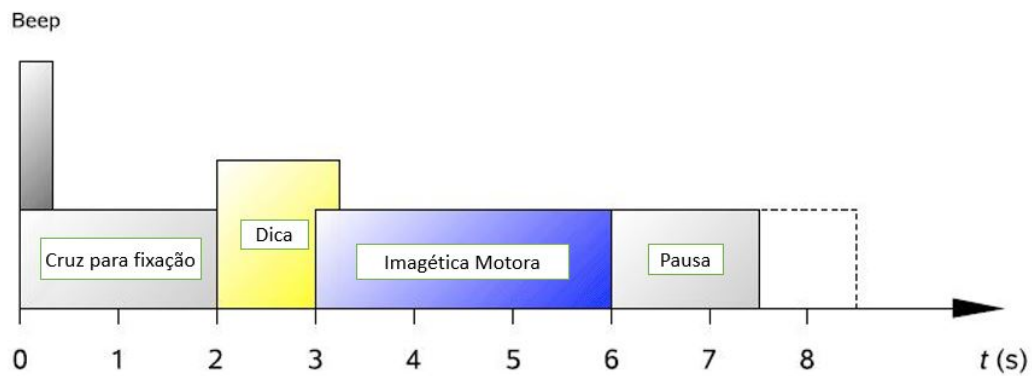


Figura 22 – Gravação dos movimentos ao longo de um segmento de tempo. (Fonte: adaptado de Brunner et al. (2008))

3.3 Filtragem

De acordo com a descrição do banco de dados usado, os artefatos técnicos já foram limitados e removidos durante a gravação dos dados (BRUNNER et al., 2008). Assim, não é necessário lidar com esse tipo de artefato. Além disso, uma inspeção visual de todos os conjuntos de dados foi feita por um especialista e os ensaios contaminados por artefatos foram marcados. No entanto, é necessário remover artefatos de EOG antes do processamento de dados subsequente. Para tal, o próprio artigo de descrição indica a utilização de um filtro passa-alta ou técnicas de regressão linear. Neste trabalho, faz-se uso apenas de um filtro passa-faixa.

As épocas foram filtradas com um filtro *Chebyshev tipo II* com frequências de corte de 5 a $30Hz$, ordem 9 e atenuação de $50dB$. Esse filtro foi escolhido porque, segundo Kumar e Inbarani (2016), é um filtro de ordem realista e habilidade seletiva na faixa de $5-30Hz$ para sinais cerebrais monitorados por EEG.

As frequências de borda foram escolhidas justamente para evitar artefatos como piscar e outros tipos de componentes fisiológicos e não-fisiológicos que ocorrem em baixas frequências, e contrações musculares, que ocorrem normalmente acima de $30Hz$. Essa faixa de frequência também é suficiente para englobar os ritmos mu ($8-13Hz$) e beta ($18-30Hz$).

Para criar o filtro com as especificações desejadas, foi utilizada a função *cheby2* que tem como argumentos a ordem, a atenuação e as frequências de corte. Para filtrar o sinal, foi usada a função *filter*, que usa as variáveis resultantes da função *cheby2* e a época a ser filtrada. Ambas as funções estão disponíveis no MATLAB. Os algoritmos 3.2 e 3.3 ajudam a exemplificar o uso das funções usadas para a filtragem. Onde, *ordem* é a ordem do filtro, *Rs* é a atenuação do filtro, *Ws* são as frequências de corte e *Fs* é a frequência de amostragem.

Algoritmo 3.2 – Exemplo de uso da função para criar um filtro *Chebyshev* tipo II

```
Rs = 50; % [dB]
Ws = [5 30]/(Fs/2);
ordem = 9;
[b,a] = cheby2(ordem,Rs,Ws);
```

Algoritmo 3.3 – Exemplo de uso do filtro especificado

```
epocaFiltrada = filter(b,a,epoca);
```

3.4 Separação de Ritmos Mu e Beta com DWT

Para a separação dos ritmos mu e beta, foi empregada a *transformada wavelet discreta* (DWT). Devido ao fato da DWT disponibilizar informações tanto no domínio do tempo quanto no da frequência, é possível saber o momento em que os comportamentos de ERD/ERS dos ritmos mu e beta ocorrem.

O formato da *mother wavelet* deve refletir os tipos de características que estão presentes no sinal (TORRENCE; COMPO, 1998). A *mother wavelet* utilizada foi escolhida com base na natureza do sinal, que é um sinal biológico cerebral. Segundo Kumar e Inbarani (2016), a *mother wavelet* mais indicada para detectar mudanças em sinais de EEG e a usada neste trabalho, é a *Daubechies 4* (db4) de nível 5. O nível para essa *wavelet* foi escolhido com base nas faixas de frequência de desejo (8 - 30Hz) e na frequência de amostragem do sinal ($fs = 250Hz$).

As faixas de frequência contidas nos coeficientes da DWT podem ser representadas como na Tabela 1. A Tabela 2 traz os valores preenchidos de acordo com a frequência de amostragem dada. Observando-a, pode-se notar que os coeficientes de detalhe *D3* e *D4* representam as faixas de frequências que compreendem os ritmos beta e mu, respectivamente, indicando que a escolha do valor do nível como 5 é o suficiente para incluir as faixas desejadas.

Tabela 2 – Faixas de frequências (BW) aproximadas de cada coeficiente de aproximação e detalhe para uma frequência de amostragem de 250Hz.

Coefficientes de aproximação	BW	Coefficientes de detalhe	BW
A1	0 – 62.50	D1	62.50 – 125.00
A2	0 – 31.25	D2	31.25 – 62.50
A3	0 – 15.62	D3	15.62 – 31.25
A4	0 – 7.81	D4	7.81 – 15.62
A5	0 – 3.90	D5	3.90 – 7.81

A função *wavedec* da *Wavelet toolbox*TM do MATLAB foi usada para a extração dos coeficientes desejados. Apenas os coeficientes de detalhe 3 e 4 foram reconstruídos e, então, selecionados. O Algoritmo 3.4 mostra um exemplo de algoritmo para fazer essa extração dos coeficientes. Onde *wName* é a *mother wavelet* escolhida, *nivel* é o nível de decomposição da análise, *detcoef* é a função para extrair os coeficientes de detalhe e *wrcoef* é a função usada para extrair os coeficientes reconstruídos.

Algoritmo 3.4 – Exemplo do uso das funções do MATLAB para obtenção dos coeficientes desejados

```
wNome = 'db4';
nivel = 5;
[c,l] = wavedec(epocaFiltrada,nivel,wNome);
detalheBeta = detcoef(c,l,3);      % [15.625 – 31.25] – Beta
detalheMu = detcoef(c,l,4);       % [7.812 – 15.62] – Mu
reconstruidoBeta = wrcoef('d',c,l,wNome,3); % Beta
reconstruidoMu = wrcoef('d',c,l,wNome,4);  % Mu
```

3.5 Extração de Características

Após a obtenção das faixas de frequências, pode-se retirar as informações desejadas dos ritmos mu e beta. Desta forma, a escolha das características é feita com os coeficientes de detalhe *D3* e *D4*.

Como o objetivo do trabalho é apresentar uma ferramenta simplificada para ajudar na utilização posterior de algoritmos mais complexos, as características escolhidas são simples, porém conhecidas e utilizadas com resultados satisfatórios por outros autores (ALOMARI; SAMAHA; ALKAMHA, 2013; HU; LI; CHEN, 2011; ALVAREZ-MEZA; VELASQUEZ-MARTINEZ; CASTELLANOS-DOMINGUEZ, 2013). Os termos "*não-estacionário*" ou "*variante no tempo*" significam que o sinal possui características estatísticas, como média, variância, e características espectrais, que variam com o tempo (BLANCO et al., 1995; KLONOWSKI, 2009). Assim, as características foram selecionadas a fim de se obter uma combinação de características estatísticas que possa descrever a distribuição do sinal no tempo e na frequência. Sendo elas: (i) a *média*; (ii) a *variância*; (iii) a *energia*; e (iv) o *valor máximo de amplitude*.

(i) A média (\bar{x}) é a soma de todas as amostras dividida pelo número total de amostras e representa a distribuição da frequência do sinal no domínio do tempo.

A equação utilizada para o cálculo da média é dada pela Equação 3.1.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.1)$$

Onde:

N é o número total de amostras.

x_i são as amostras.

(ii) O desvio padrão (σ) é a medida do quanto o sinal flutua em relação à média e é calculado como na [Equação 3.2](#).

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |x_i - \bar{x}|^2} \quad (3.2)$$

A variância (σ^2) é o quadrado do desvio padrão e representa a potência dessa flutuação, como pode ser visto na [Equação 3.3](#).

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N |x_i - \bar{x}|^2 \quad (3.3)$$

(iii) Além de ser uma base eficiente para análise de dados EEG, a *mother wavelet* escolhida possui a propriedade da ortogonalidade e, portanto, pela *lei de Parseval*, apresenta preservação de energia ([THE MATHWORKS, INC., 2017](#)).

Após o movimento, as energias de C3 e C4 são diferentes, então, a média da energia de C3 e C4 pode ser considerada como uma característica para o vetor de características ([HUANG; WU, 2010](#)).

Para o seu cálculo, a energia (E) pode ser entendida como a amplitude ao quadrado e descreve a variabilidade do sinal no domínio da frequência.

$$E = \sum_{i=-\infty}^{\infty} |x_i|^2 \quad (3.4)$$

(iv) O valor máximo de amplitude pode ser encontrado utilizando uma função simples que procura, dentre todas as amostras, aquela de maior valor. Como exemplificação, pode-se observar o algoritmo em pseudocódigo da [Figura 23](#).

Com exceção da energia, todas as outras informações foram extraídas com o uso de funções do MATLAB, como: *mean*, *var*, e *max*, para a média, variância e amplitude máxima, respectivamente. Já a energia foi calculada como o quadrado da amplitude no domínio do tempo.

Variáveis:

dados: conjunto de dados.

i: número de estágios.

max: valor máximo.

Inicialização:

$max = dados[1]$

Início:

Para *i* de 2 até $tamanho(dados)$ faça:

Início:

Se $dados[i] > max$ então:

$max = dados[i]$

Fim**Fim**

Figura 23 – Algoritmo simples para exemplo de extração de valor máximo em um vetor.

3.6 Formação do Vetor de Características

Os resultados das operações da etapa anterior são concatenados em um único vetor. Este vetor é, então, passado ao classificador. Alguns ensaios, cujas respostas são previamente conhecidas, são utilizados para treinar o classificador. Depois de treinado, o restante dos ensaios com respostas conhecidas é usado para se fazer uma análise sobre a precisão do classificador. Neste trabalho, não é feita a parte de classificação.

4 Resultados

Para comprovar a viabilidade da ferramenta desenvolvida, será feita uma análise passo a passo do esperado para cada etapa de acordo com a teoria descrita. Será apresentado, dependendo da análise, apenas o sinal de um indivíduo para uma época específica. Algumas análises são feitas com todas as 72 épocas de um movimento de um dado canal. Para essas, apenas o gráfico de um indivíduo é apresentado. Isso será feito apenas a título de exemplificação. Para a validação do sistema desenvolvido, foi levado em consideração uma média dos sinais de todas as épocas de todos os 9 indivíduos.

Recapitulando

Após a aquisição dos dados, o primeiro passo é separar os ensaios. Estes, são separados por canais e por tipo de evento. Eventos referem-se ao intervalo de tempo em que algo aconteceu durante a seção de captura dos dados. Nesse caso, os eventos são a imaginação de movimentos. Por exemplo, tem-se um ensaio de movimento de mão direita para o canal C3 e outro de movimento de mão esquerda para o mesmo canal. Da mesma forma, essa separação ocorre para os outros canais escolhidos.

Para cada ensaio, um período de duração de 5s foi escolhido como época para a análise do comportamento dos ritmos mu e beta. Iniciando em $t = 2s$ e terminando em $t = 7s$, já que o movimento é imaginado de $t = 3s$ a $t = 6s$. Então, o sinal original é filtrado para eliminar artefatos.

Usando uma FFT, é possível observar as frequências presentes tanto no sinal original quanto no sinal filtrado. Na [Figura 24](#), tem-se um exemplo de um sinal de movimento de mão direita observado no canal C3 e sua filtragem feita como descrito no [Capítulo 3](#). A [Figura 25](#) mostra o mesmo sinal filtrado, porém, mais de perto, demonstrando que o sinal foi filtrado com sucesso na faixa de 5 - 30Hz.

Após a filtragem, é feita a separação dos ritmos mu e beta com o uso da *transformada wavelet discreta*. Na [Figura 26](#), é apresentada a decomposição dos coeficientes da DWT com o uso do comando *wavemenu* do MATLAB. Nela, é possível observar o sinal original, suas aproximações e seus coeficientes de detalhe, para os 5 níveis escolhidos. Sendo que, os coeficientes de detalhe d_3 e d_4 são os que contêm as faixas de frequência dos ritmos desejados. Na [Figura 27](#), é mostrado um exemplo do comportamento do sinal em cada etapa feita até o momento. Primeiro, é apresentado o sinal original bruto. Logo após, tem-se o mesmo sinal, porém filtrado com o filtro da ferramenta proposta. Então, os sinais equivalentes aos ritmos mu e beta dos coeficientes da DWT são calculados e mostrados.

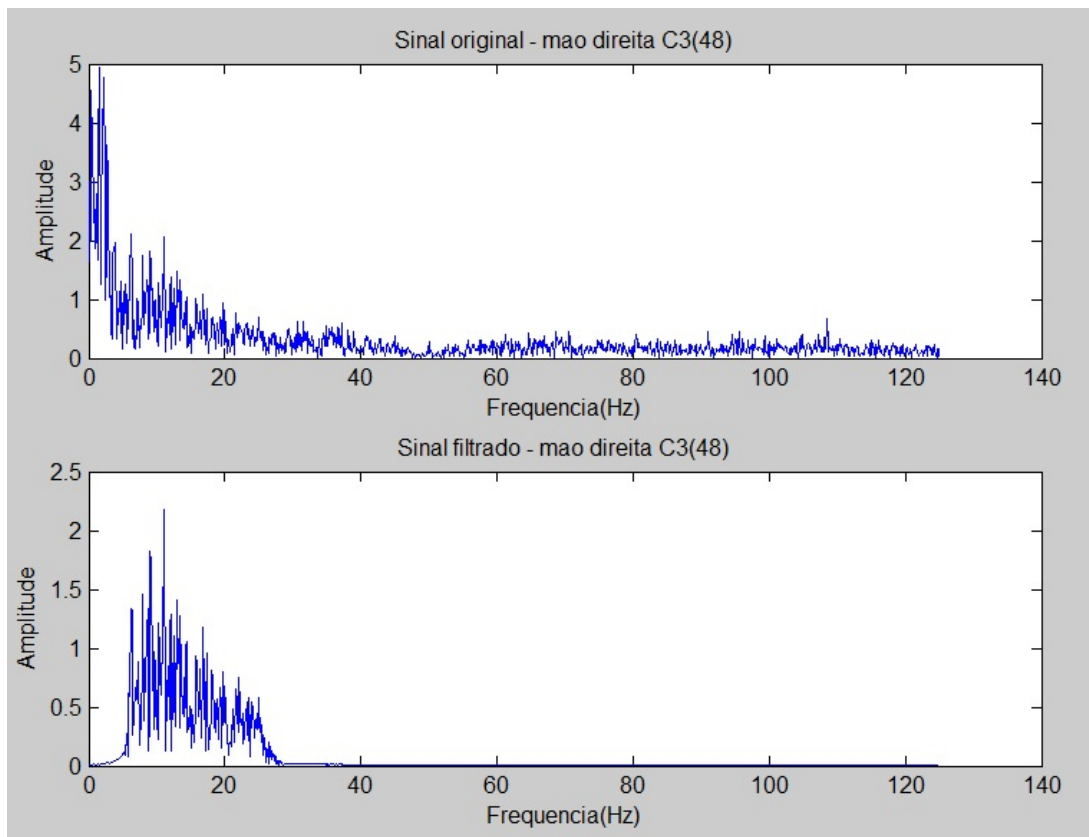


Figura 24 – Exemplo das frequências presentes no sinal original e após o uso de um filtro passa-faixa *Chebyshev tipo II* de 5 a 30Hz.

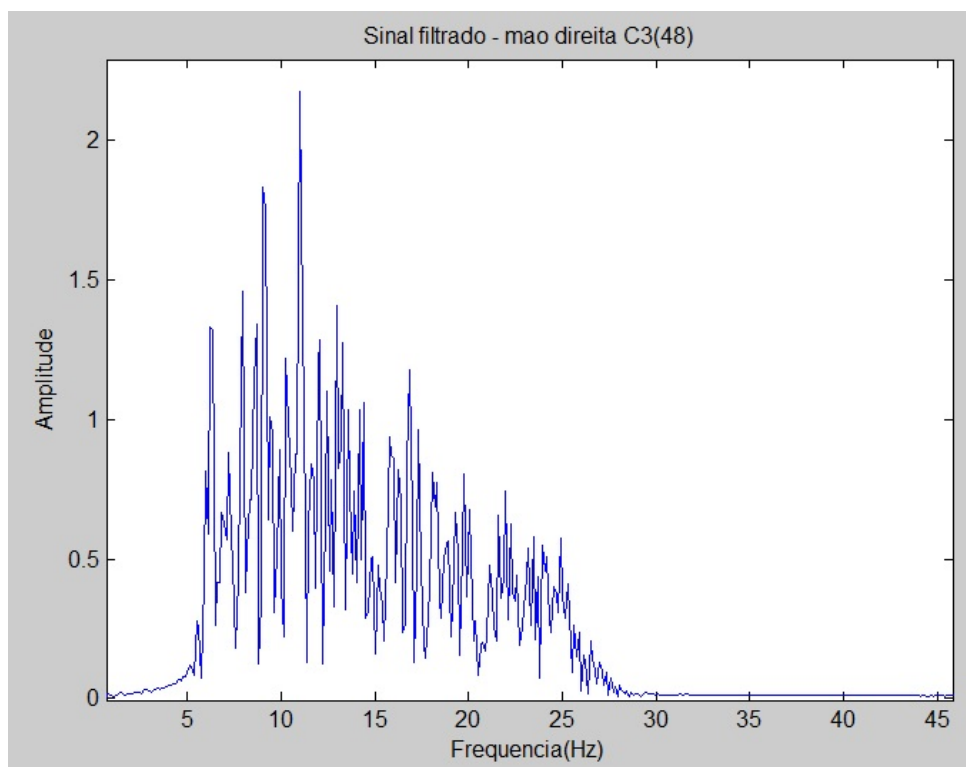


Figura 25 – Exemplo das frequências presentes no sinal após o uso de um filtro passa-faixa *Chebyshev tipo II* de 5 a 30Hz.

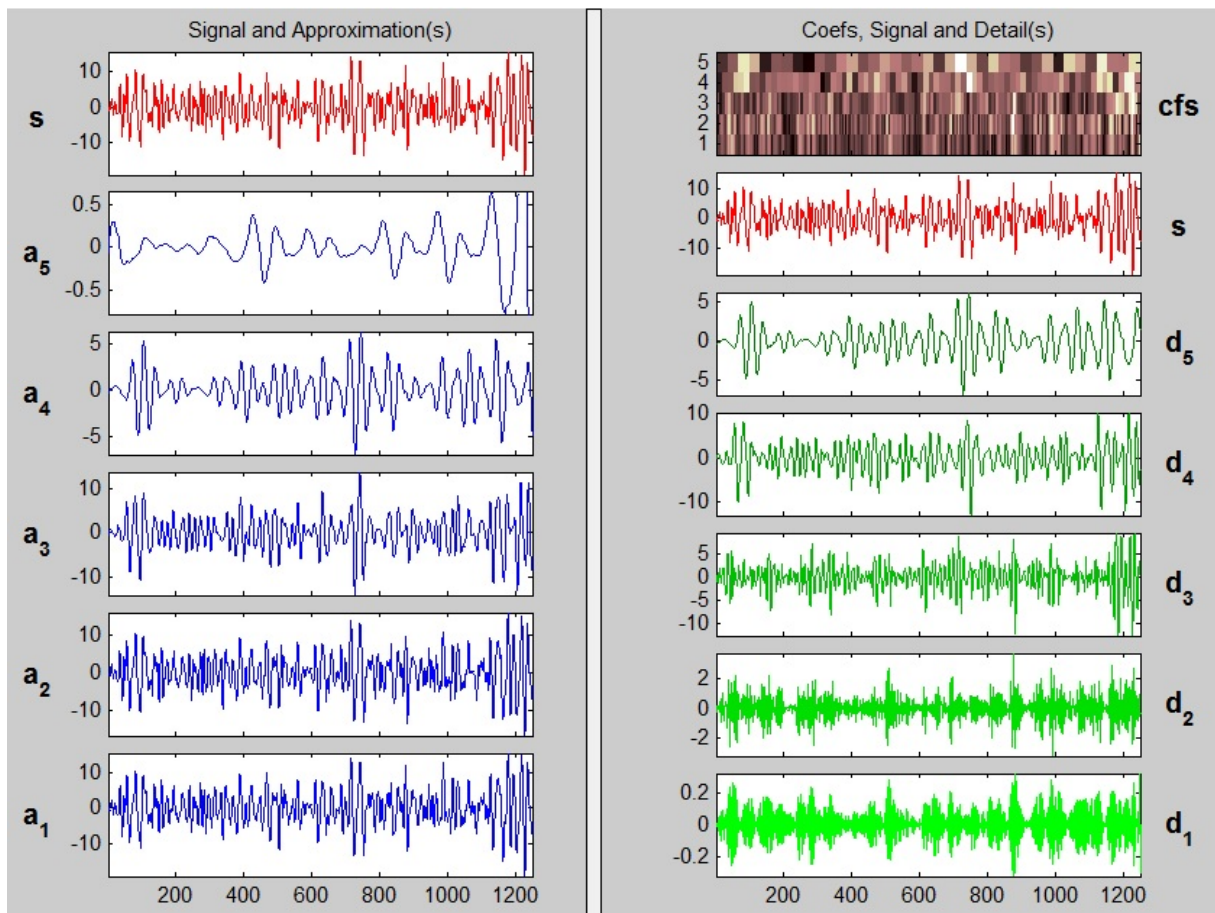


Figura 26 – Coeficientes reconstruídos da DWT para movimento de mão direita no canal C3 (ensaio 48 do indivíduo 1).

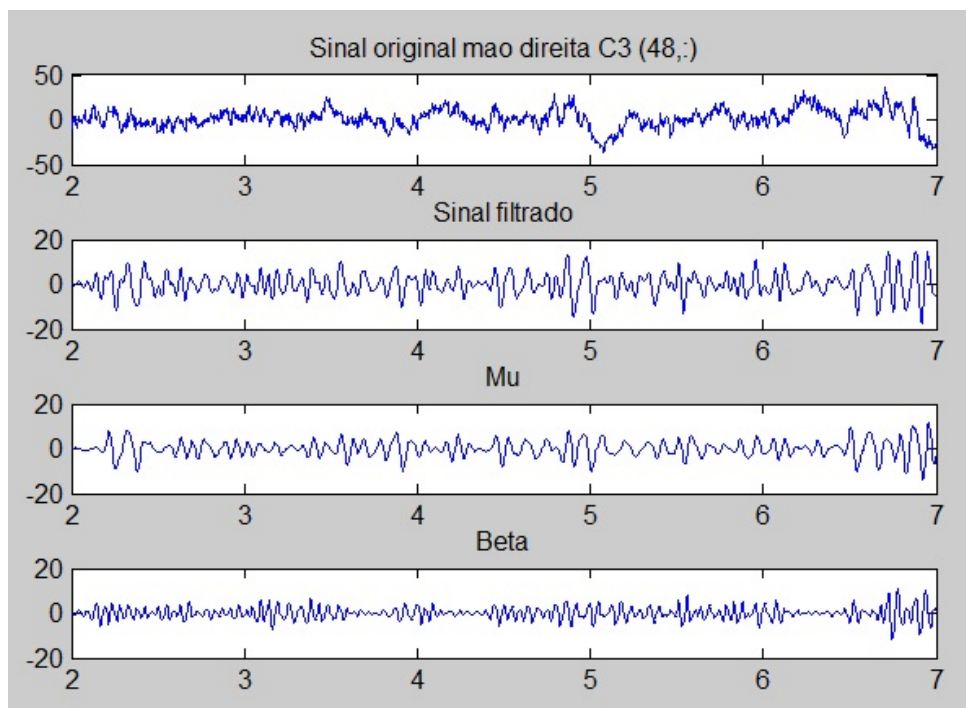


Figura 27 – Exemplo de um sinal comum de EEG de uma pessoa saudável gravado sobre o canal C3 referente a um movimento de mão direita.

Existem alguns tipos de representações gráficas que podem ser usadas para observar as informações obtidas a partir dos coeficientes da DWT, tais como: gráficos espectro-temporais, análise espectral de potência, escalogramas, entre outros.

A **análise espectral** de potência de um canal mostra a magnitude do sinal em pontos coloridos (VARGHESE, 2009). Já **escalogramas**, são gráficos que representam a porcentagem de energia para cada coeficiente. Um escalograma de uma série temporal pode ser definido como a média dos quadrados dos coeficientes da *wavelet* em uma dada escala (GRAPS, 1995). Um **espectrograma** é usado para estimar o conteúdo de frequência de um sinal. Esses tipos de imagens fornecem informações gráficas sobre a evolução do espectro de potência de um sinal, na medida que este é varrido através do tempo (CUSIDÓ et al., 2008). Espectrogramas mostram as frequências sob a perspectiva da variação do tempo e podem, assim, ser uma técnica útil para aplicar em sinais com frequência que variam com o tempo (CUSIDÓ et al., 2008).

Um gráfico de mapas de cores (*colormap*) mostra a intensidade das frequências em cada momento no tempo. Um *colormap* com todos os coeficientes da CWT, é plotado na Figura 28. A Figura 29 mostra um exemplo de escalograma com uma CWT. Os coeficientes *wavelet* da CWT são mostrados como pixels com certa intensidade (cor), em um plano bidimensional com o eixo y representando a dilatação (fator de escala) da *wavelet*, e o eixo x , sua translação (eixo de tempo). Assim, o gráfico da transformada *wavelet* (escalograma) é um padrão de cores 2D (SUBHA et al., 2010).

O escalograma pode ser usado para mostrar a porcentagem de energia em cada coeficiente da *wavelet*. A Figura 30 apresenta um escalograma obtido com o uso da ferramenta proposta. Para o objetivo da ferramenta, apenas a parte referente aos coeficientes de μ e β é apresentada. Além disso, os eixos x e y do gráfico são alterados para melhor entendimento.

Um exemplo de espectrograma pode ser observado na Figura 31. Neste gráfico, é possível ver que existem conteúdos de frequências nas faixas de μ e β (por volta de 8 e 30Hz).

Os gráficos de cores foram plotados com a CWT para uma melhor visualização, mas, para reduzir custo computacional e o uso de informações redundantes, os cálculos são feitos utilizando uma DWT.




Figura 28 – Gráfico de cores dos coeficientes da CWT para a observação da intensidade de cada frequência em cada momento no tempo.

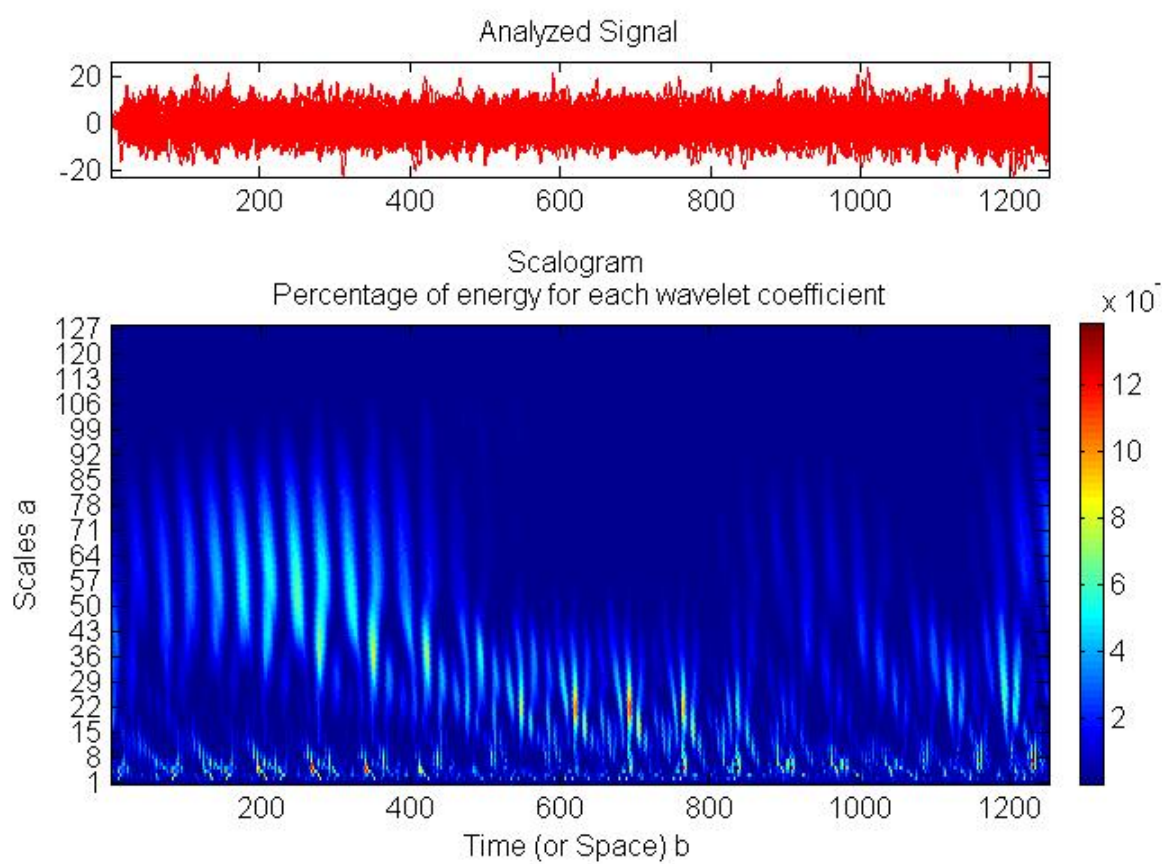


Figura 29 – Gráfico de cores dos coeficientes da CWT representando todos os ensaios do canal C3 com relação à movimento de mão direita, apenas para as frequências de mu e beta.

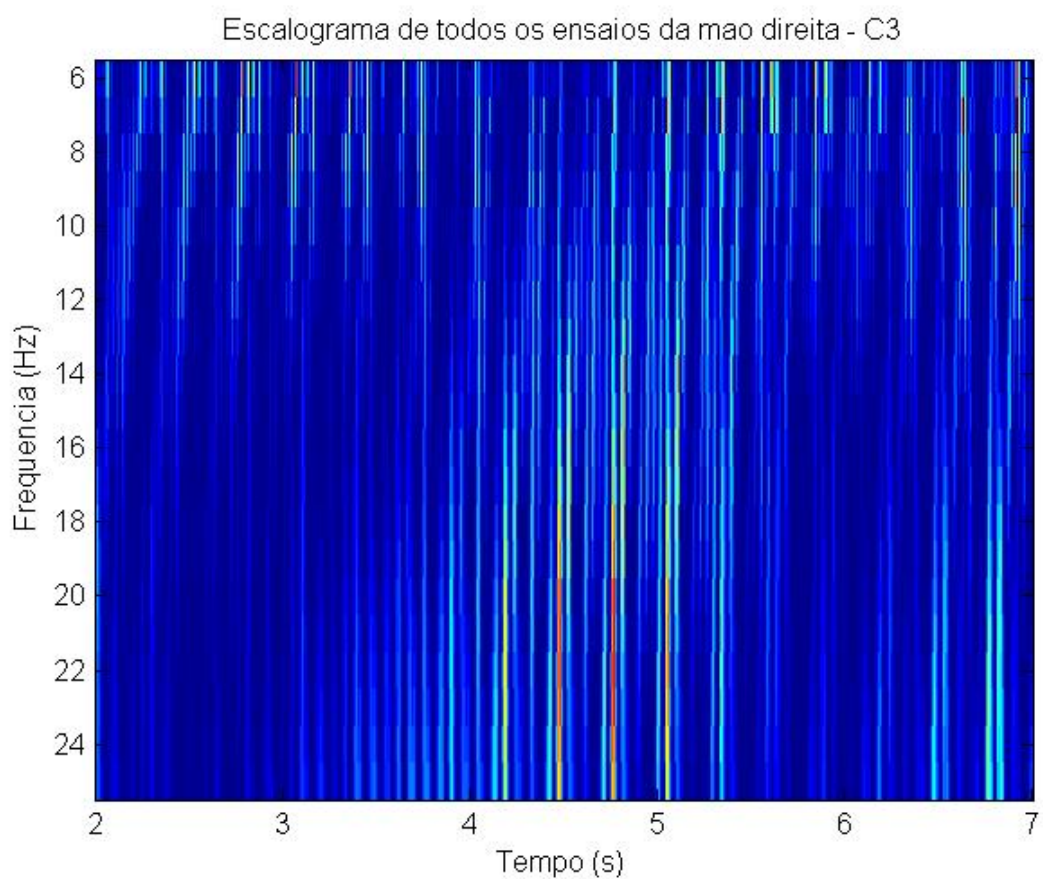


Figura 30 – Gráfico de cores dos coeficientes da CWT representando todos os ensaios do canal C3 com relação à movimento de mão direita.




Figura 31 – Gráfico de cores dos coeficientes da CWT representando todos os ensaios do canal C3 com relação à movimento de mão direita.

ERD ou **ERS** é definido como a porcentagem da diminuição ou aumento da potência, respectivamente, com relação a todos os ensaios. ERD pode ser calculado seguindo os passos presentes no trabalho de [Pfurtscheller e Silva \(1999\)](#). Para obter os valores percentuais de ERD/ERS, a potência na banda de frequência de interesse no período após o evento é dado por A enquanto aquele precedente ao *baseline*, ou período de referência, é dado por R , de acordo com a expressão:

$$ERD\% = (A - R)/R * 100 \quad (4.1)$$

Onde:

A é a densidade espectral de potência do MI.

R é a densidade espectral de potência da *baseline*.

Ainda para a [Equação 4.1](#), ERS pode ser visto apenas como ERD negativo.

Uma imagem de **potencial relacionado a evento** (do inglês, *event-related potential - ERP*) de um canal é uma imagem retangular colorida, na qual cada ensaio pode ser representado como linhas horizontais, cujas cores indicam o potencial em cada instante de tempo durante um único ensaio (amplitude (μV) x tempo (ms)), como visto no exemplo da [Figura 32](#).




Figura 32 – Um gráfico ERP para um único ensaio. (Fonte: [Varghese \(2009\)](#)).

Em vez de ensaios únicos, pode-se empilhar uma linha em cima da outra, formando uma imagem ERP de sequência de cores, como na [Figura 33](#) e na [Figura 34](#).

A **densidade espectral de potência** (do inglês, *Power Spectral Density - PSD*), representa a distribuição da potência em função da frequência ([SUBHA et al., 2010](#)). Onde, a potência do sinal pode ser calculada somando os quadrados de todos os coeficientes de detalhes e da aproximação final. A combinação de PSD e WT produz bons resultados ([CUSIDÓ et al., 2008](#)).

Com relação à energia, é possível observar na [Figura 35](#) que, assim como para a [Figura 34](#) do trabalho de [Varghese \(2009\)](#), para movimento de mão esquerda, tem-se um

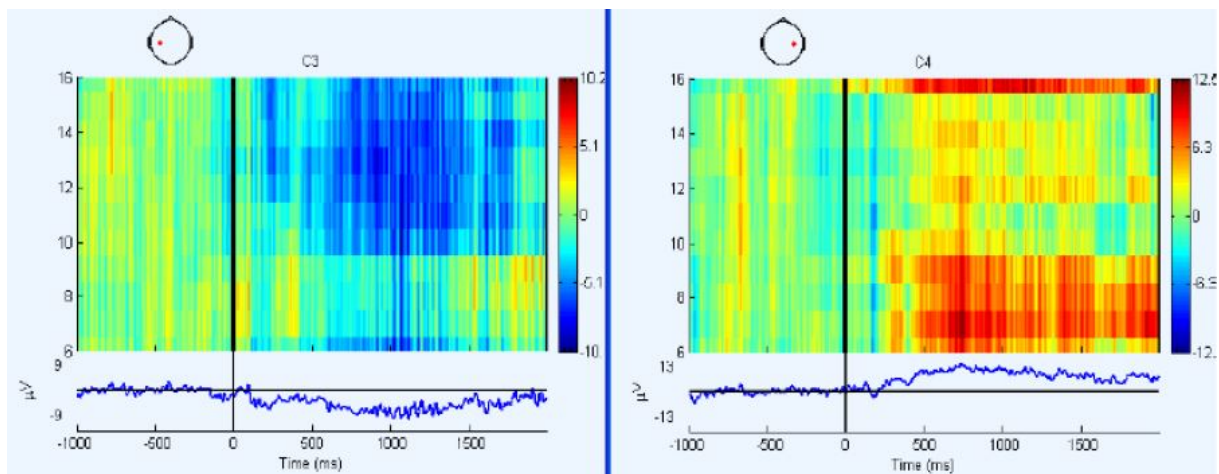


Figura 33 – Um gráfico ERP para todos os ensaios empilhados dos canais C3 e C4 relativos à movimento de mão direita.(Fonte: Varghese (2009)).

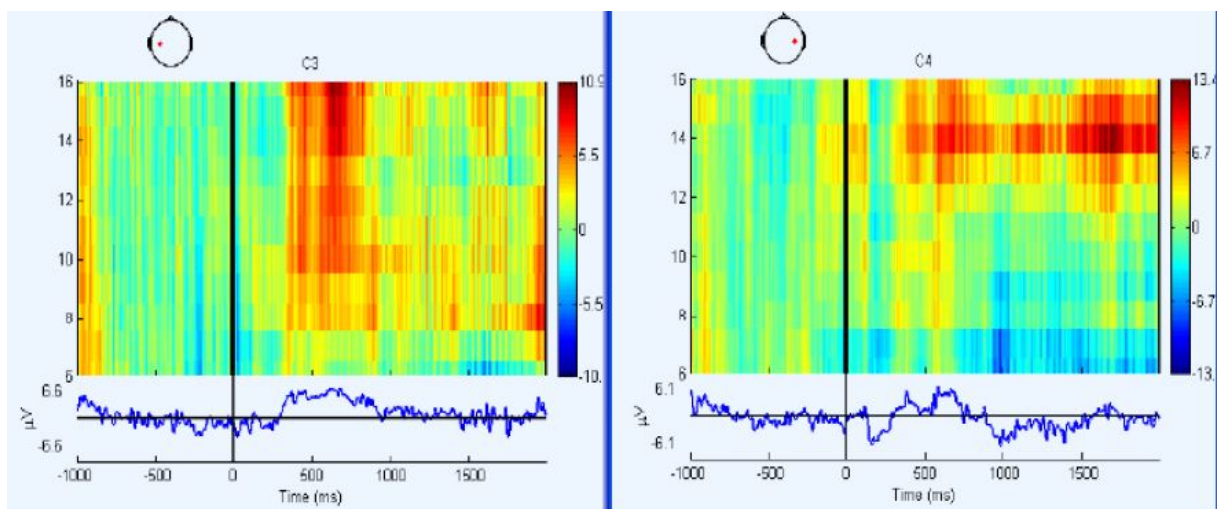


Figura 34 – Um gráfico ERP para todos os ensaios empilhados dos canais C3 e C4 relativos à movimento de mão esquerda.(Fonte: Varghese (2009)).

μERS e um βERS no canal C3 e um βERS e um μERD no canal C4. Uma região com ERS indica inatividade da área cortical. Assim, para o lado esquerdo, pode-se observar inatividade no canal C3 (lado esquerdo) e, para esse exemplo, uma pequena atividade no canal C4 (lado direito).

A seguir, será apresentado um pequeno guia para a utilização da ferramenta proposta.




Figura 35 – Energia para os canais $C3$ e $C4$ quando movimento de mão esquerda é imaginado.

- **Guia para a utilização da ferramenta proposta**

Primeiramente, deve-se escolher o arquivo de gravação com a extensão *.gdf* que contém os sinais a serem analisados. A ferramenta irá, assim, extrair as informações do cabeçalho e os sinais dos canais $C3$, Cz e $C4$ e fazer todo o pré-processamento e separação dos sinais em épocas.

Em seguida, a ela irá extrair os coeficientes da transformada *wavelet*, as quais serão disponibilizadas em variáveis para uso direto do usuário. Neste momento, as variáveis de saída são os coeficientes de detalhe após a reconstrução referente a cada canal nas faixas de frequência de mu e beta para cada movimento. Assim, são fornecidas 12 variáveis, 4 para cada canal. Por exemplo, para o canal $C3$, será fornecida uma variável na faixa de frequência de beta para movimento de mão esquerda, outra para mão direita e outras duas para as faixas de mu. O mesmo acontece para os outros canais.

Então, a ferramenta proposta continuará seu processamento e irá formar uma matriz de vetores de características formada pelas características extraídas dos coeficientes fornecidos.

Portanto, o uso da ferramenta é bem simples. Tudo o que o usuário deve fazer é passar o nome do arquivo que contém as gravações e utilizar as saídas fornecidas de acordo com sua necessidade. Se a intenção do usuário é escolher suas próprias características arbitrárias para formar seu vetor de características, ele pode usar as

variáveis fornecidas referentes aos coeficientes da transformada *wavelet*. Se o usuário deseja usar um vetor de características com informações previamente selecionadas, tudo o que ele precisa fazer é utilizar a variável que contém a matriz de vetores de características que é fornecida como saída.

Da mesma forma, para a observação gráfica do comportamento do sinal, são disponibilizadas duas funções: uma que fornece o gráfico de cores dos coeficientes da CWT com a intensidade de cada frequência em cada momento no tempo e outra que fornece um escalograma com a porcentagem de energia dos coeficientes da CWT que representam μ e β de todas as épocas de um movimento. Assim, é possível observar o comportamento dos ritmos com relação a cada movimento.

Sem a ferramenta proposta, faz-se necessário aprender como usar outras ferramentas existentes de acordo com o que se deseja fazer, além disso, é preciso dispender-se de tempo para se aprofundar nas razões e decisões sobre como realizar o processamento do sinal até que seja possível chegar na parte de testes de algoritmos de classificação em si.

5 Conclusão

Em processamento de sinais, alguns algoritmos ou uma combinação destes, se mostram mais adequados que outros dependendo do tipo do sinal analisado e de quais características e parâmetros são usados. Existem diversos algoritmos diferentes com métricas diferentes que são usados na construção de um sistema de interface cérebro-máquina. Isto torna difícil a comparação entre sistemas, uma vez que, desta forma, pode-se ter resultados variados para sistemas similares.

Neste trabalho, foi proposta uma ferramenta cujo processamento de dados de BCI baseado em EEG com imagética motora e ritmos sensório-motores, são feitos até a etapa de extração de características, deixando a implementação das fases seguintes para o usuário. Isso é feito para permitir comparações entre vários métodos, enquanto o protocolo, alguns parâmetros e o pré-processamento são mantidos fixos, na tentativa de deixá-los sob um mesmo contexto e de trazer maior clareza às conclusões tiradas sobre o desempenho dos sistemas. Deste modo, também é possível fazer uma comparação sobre os algoritmos mais apropriados para lidar com sinais cerebrais do tipo especificado. De maneira mais ampla, e de maior relevância, a possibilidade de encontrar algoritmos melhores para este tipo de sistema, melhoraria a qualidade de vida de milhões de pessoas com deficiências motoras graves.

Com os gráficos obtidos, foi possível observar a propriedade de preservação de energia de coeficientes da DWT quando uma base ortogonal é usada. Permitindo o uso da energia como característica para o vetor formado. Além disso, a análise das etapas intermediárias com o uso dos gráficos plotados comprovam que o sistema desenvolvido está de acordo com a teoria descrita quanto ao comportamento dos sinais de imaginação de movimento de mãos, indicando que eles podem ser usados para ajudar no entendimento do sistema e demonstrando a viabilidade da ferramenta para testes de algoritmos. Assim, é possível procurar algoritmos que levam aos melhores valores possíveis de precisão na predição de atividades de imagética motora para os sistemas projetados. Altas porcentagens de precisão são importantes para aumentar a usabilidade do sistema de forma prática.

Por ser simplificada e limitada, esta não é uma ferramenta otimizada. Apesar disso, os resultados são satisfatórios e adequados, ao menos, para pesquisadores que estão iniciando seus estudos na área ou para aqueles que não desejam lidar com a parte de processamento de sinal, desejam apenas testar seus algoritmos de extração, seleção, ou classificação de características.

Um artigo sobre a ferramenta foi escrito e submetido para o Congresso *2018 IEEE 30th Canadian Conference on Electrical and Computer Engineering (CCECE)*, no Canadá

e uma cópia dele pode ser vista no Anexo A.

5.1 Trabalhos futuros

O trabalho realizado atingiu os objetivos desejados para a criação de um meio para ajudar na busca de métodos que possam trazer melhoria nos valores de velocidade, precisão e confiabilidade de um sistema BCI baseado em EEG, os quais são as principais metas da área. No entanto, ainda existem maneiras de melhorar a ferramenta desenvolvida e de dar continuidade ao seu projeto. A seguir são listadas algumas atividades que podem ser realizadas:

- **Implementação da ferramenta em linguagem de *hardware*.** Os algoritmos usados na construção da ferramenta proposta podem ser implementados em linguagem de *hardware* (como visto, por exemplo, nos trabalhos de [Ahsan, Ibrahimy e Khalifa \(2011\)](#), [Borgio et al. \(2006\)](#) e [Elamary, Chester e Neasham \(2009\)](#)), a fim de melhorar a velocidade de resposta do sistema.
- **Melhorar o processo de tratamento de artefatos.** Apenas um filtro passa-faixa é usado para eliminar artefatos presentes no sinal gravado. No entanto, existem alguns algoritmos que podem ser usados para lidar com artefatos específicos, como por exemplo, aqueles de EOG.
- **Formação de uma base de resultados.** Para evitar trabalho repetitivo com comparações já realizadas anteriormente, pode-se montar um conjunto com métricas de precisão de combinações de algoritmos usados em outros trabalhos. Porém, para que o objetivo da ferramenta seja alcançado, esses valores devem ser calculados utilizando a ferramenta proposta.

Referências

- AHSAN, M. R.; IBRAHIMY, M. I.; KHALIFA, O. O. Vhdl modelling of fixed-point dwt for the purpose of emg signal denoising. In: IEEE. *Computational Intelligence, Communication Systems and Networks (CICSyN), 2011 Third International Conference on*. [S.l.], 2011. p. 236–241.
- ALOMARI, M. H. et al. Wavelet-based feature extraction for the analysis of eeg signals associated with imagined fists and feet movements. *Computer and Information Science*, v. 7, n. 2, p. 17, 2014.
- ALOMARI, M. H.; SAMAHA, A.; ALKAMHA, K. Automated classification of l/r hand movement eeg signals using advanced feature extraction and machine learning. *arXiv preprint arXiv:1312.2877*, 2013.
- ALVAREZ-MEZA, A. M.; VELASQUEZ-MARTINEZ, L.; CASTELLANOS-DOMINGUEZ, G. Feature relevance analysis supporting automatic motor imagery discrimination in eeg based bci systems. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE*. [S.l.], 2013. p. 7068–7071.
- BLANCO, S. et al. Stationarity of the eeg series. *IEEE Engineering in medicine and biology Magazine*, IEEE, v. 14, n. 4, p. 395–399, 1995.
- BLANKERTZ, B. et al. Neurophysiological predictor of smr-based bci performance. *Neuroimage*, Elsevier, v. 51, n. 4, p. 1303–1309, 2010.
- BORGIO, S. et al. Hardware dwt accelerator for multiprocessor system-on-chip on fpga. In: IEEE. *Embedded Computer Systems: Architectures, Modeling and Simulation, 2006. IC-SAMOS 2006. International Conference on*. [S.l.], 2006. p. 107–114.
- BRUNNER, C. et al. Bci competition 2008–graz data set a. *Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology*, p. 136–142, 2008.
- CABRERA, A. R. F. Feature extraction and classification for brain-computer interfaces. *Aalborg: Aalborg University, Denmark*, 2009.
- CISOTTO, G. Movement-related desynchronization in eeg-based brain-computer interface applications for stroke motor rehabilitation. 2014.
- CUSIDÓ, J. et al. Fault detection in induction machines using power spectral density in wavelet decomposition. *IEEE Transactions on Industrial Electronics*, IEEE, v. 55, n. 2, p. 633–643, 2008.
- DELORME, A.; MAKEIG, S. Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis. *Journal of neuroscience methods*, Elsevier, v. 134, n. 1, p. 9–21, 2004.

- DEVI, K. R.; INBARANI, H. H. Motor imagery classification based on variable precision multigranulation rough set. In: *Computational Intelligence, Cyber Security and Computational Models*. [S.l.]: Springer, 2016. p. 145–154.
- ELAMARY, G.; CHESTER, G.; NEASHAM, J. A simple digital vhdl qpsk modulator designed using cpld/fpgas for biomedical devices applications. In: *Proceedings of the World Congress on Engineering*. [S.l.: s.n.], 2009. v. 1, p. 978–988.
- GRAPS, A. An introduction to wavelets. *IEEE computational science and engineering*, IEEE, v. 2, n. 2, p. 50–61, 1995.
- GUGER, C.; EDLINGER, G.; KRAUSZ, G. Hardware/software components and applications of bcis. In: *Recent Advances in Brain-Computer Interface Systems*. [S.l.]: InTech, 2011.
- HOANG, T. T. A. *Multivariate Features for Multi-class Brain Computer Interface Systems*. Tese (Doutorado) — University of Canberra, 2014.
- HU, D.; LI, W.; CHEN, X. Feature extraction of motor imagery eeg signals based on wavelet packet decomposition. In: IEEE. *Complex Medical Engineering (CME), 2011 IEEE/ICME International Conference on*. [S.l.], 2011. p. 694–697.
- HUANG, S.; WU, X. Feature extraction and classification of eeg for imagery movement based on mu/beta rhythms. In: IEEE. *2010 3rd International Conference on Biomedical Engineering and Informatics*. [S.l.], 2010. v. 2, p. 891–894.
- JASPER, H. H. The ten twenty electrode system of the international federation. *Electroencephalography and Clinical Neurophysiology*, v. 10, p. 371–375, 1958.
- JEANNEROD, M. Mental imagery in the motor context. *Neuropsychologia*, Elsevier, v. 33, n. 11, p. 1419–1432, 1995.
- KHORSHIDTALAB, A.; SALAMI, M.; HAMED, M. Evaluating the effectiveness of time-domain features for motor imagery movements using svm. In: IEEE. *Computer and Communication Engineering (ICCCCE), 2012 International Conference on*. [S.l.], 2012. p. 909–913.
- KLONOWSKI, W. Everything you wanted to ask about eeg but were afraid to get the right answer. *Nonlinear Biomedical Physics*, BioMed Central, v. 3, n. 1, p. 2, 2009.
- KOTHE, C. A.; MAKEIG, S. Bcilab: a platform for brain-computer interface development. *Journal of neural engineering*, IOP Publishing, v. 10, n. 5, p. 056014, 2013.
- KUMAR, S. U.; INBARANI, H. H. Pso-based feature selection and neighborhood rough set-based classification for bci multiclass motor imagery task. *Neural Computing and Applications*, Springer, p. 1–20, 2016.
- LOTTE, F. et al. A review of classification algorithms for eeg-based brain-computer interfaces. *Journal of neural engineering*, IOP Publishing, v. 4, n. 2, p. R1, 2007.
- MCFARLAND, D. J. et al. Mu and beta rhythm topographies during motor imagery and actual movements. *Brain topography*, Springer, v. 12, n. 3, p. 177–186, 2000.

- MCFARLAND, D. J.; WOLPAW, J. R. Brain-computer interface operation of robotic and prosthetic devices. *Computer, IEEE*, v. 41, n. 10, 2008.
- MCFARLAND, D. J.; WOLPAW, J. R. Brain-computer interfaces for communication and control. *Communications of the ACM, ACM*, v. 54, n. 5, p. 60–66, 2011.
- MENG, J. et al. Automated selecting subset of channels based on csp in motor imagery brain-computer interface system. In: IEEE. *Robotics and Biomimetics (ROBIO), 2009 IEEE International Conference on*. [S.l.], 2009. p. 2290–2294.
- MISITI, M. et al. Wavelet toolbox. *The MathWorks Inc., Natick, MA*, v. 15, p. 21, 1996.
- MOORE, M. M. Real-world applications for brain-computer interface technology. *IEEE Transactions on Neural Systems and Rehabilitation Engineering, IEEE*, v. 11, n. 2, p. 162–165, 2003.
- NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain computer interfaces, a review. *Sensors, Molecular Diversity Preservation International*, v. 12, n. 2, p. 1211–1279, 2012.
- NIEDERMEYER, E.; SILVA, F. L. da. *Electroencephalography: basic principles, clinical applications, and related fields*. [S.l.]: Lippincott Williams & Wilkins, 2005.
- OH, S.-H.; LEE, Y.-R.; KIM, H.-N. A novel eeg feature extraction method using hjorth parameter. *International Journal of Electronics and Electrical Engineering*, v. 2, n. 2, p. 106–110, 2014.
- PFURTSCHELLER, G.; NEUPER, C. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE, IEEE*, v. 89, n. 7, p. 1123–1134, 2001.
- PFURTSCHELLER, G. et al. Eeg-based discrimination between imagination of right and left hand movement. *Electroencephalography and clinical Neurophysiology, Elsevier*, v. 103, n. 6, p. 642–651, 1997.
- PFURTSCHELLER, G.; SILVA, F. L. D. Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical neurophysiology, Elsevier*, v. 110, n. 11, p. 1842–1857, 1999.
- POLIKAR, R. The wavelet tutorial. part iv. multiresolution analysis: the discrete wavelet transform. *Rowan University*, 2008.
- SAINI, S.; DEWAN, L. Application of discrete wavelet transform for analysis of genomic sequences of mycobacterium tuberculosis. *SpringerPlus, Springer International Publishing*, v. 5, n. 1, p. 64, 2016.
- SCHALK, G. et al. Bci2000: a general-purpose brain-computer interface (bci) system. *IEEE Transactions on biomedical engineering, IEEE*, v. 51, n. 6, p. 1034–1043, 2004.
- SCHLÖGL, A.; BRUNNER, C. Biosig: a free and open source software library for bci research. *Computer, IEEE*, v. 41, n. 10, 2008.
- SUBHA, D. P. et al. Eeg signal analysis: A survey. *Journal of medical systems, Springer*, v. 34, n. 2, p. 195–212, 2010.
- THE MATHWORKS, INC. *MATLAB versão 7.12.0.635(R2011a)*. Natick, Massachusetts, EUA, 2011.

- THE MATHWORKS, INC. *Wavelet Packets: Decomposing the Details*. Natick, Massachusetts, EUA, 2017. Acesso em: (10 mar. 2017). Disponível em: <<https://www.mathworks.com/help/wavelet/examples/wavelet-packets-decomposing-the-details.html>>.
- TING, W. et al. Eeg feature extraction based on wavelet packet decomposition for brain computer interface. *Measurement*, Elsevier, v. 41, n. 6, p. 618–625, 2007.
- TORRENCE, C.; COMPO, G. P. A practical guide to wavelet analysis. *Bulletin of the American Meteorological society*, v. 79, n. 1, p. 61–78, 1998.
- VARGHESE, J. P. Analysis of eeg signal for eeg-based brain computer interface. *School of Innovation, Design and Technology, Mälardalen University, Sweden*, 2009.
- VIDAL, J. J. Real-time detection of brain events in eeg. *Proceedings of the IEEE*, IEEE, v. 65, n. 5, p. 633–641, 1977.
- WOLPAW, J. R. et al. Brain–computer interfaces for communication and control. *Clinical neurophysiology*, Elsevier, v. 113, n. 6, p. 767–791, 2002.
- ZHANG, X.; WANG, Y.; HAN, R. P. Wavelet transform theory and its application in emg signal processing. In: IEEE. *Fuzzy Systems and Knowledge Discovery (FSKD), 2010 Seventh International Conference on*. [S.l.], 2010. v. 5, p. 2234–2238.

ANEXO A – Artigo Enviado para Congresso

A Simplified Tool for Testing of Feature Selection and Classification Algorithms in Motor Imagery of Right and Left Hands of EEG Signals

Giovanna Bonafé Bernardi
Computer Science and Technology Program
Federal University of Itajuba, UNIFEI
Itajuba, MG, Brazil 35903-087
Email: giovanna_bernardi@unifei.edu.br

Robson Luiz Moreno
Federal University of Itajuba, UNIFEI
Itajuba, MG, Brazil
Email: moreno@unifei.edu.br
Telephone: +55 (35) 3629-1922

Abstract—Some algorithms or a combination of them are more appropriated than others depending on the type of data that is being analyzed and what features and parameters are being used. In the analysis of motor imagery in an offline EEG-based BCI, different codes with different parameters are often used, making it harder to compare the effects of the algorithms applied. In this paper, we propose a simplified and limited tool that aims to aid in the testing of feature extraction, selection and classification algorithms separately or combined for the analysis of motor imagery (MI) in offline EEG-based brain signals while providing some information about the intermediate steps of a BCI construction. A known data set is used in order to ease the comparison between other researches. Only data from channels C3, Cz and C4 are used and the MI of left hand and right hand are analyzed. The data is filtered using a band-pass Chebyshev type II filter between 5 and 35 Hz. Then, The rhythms mu and beta are isolated using a DWT algorithm with a db4 mother wavelet of level 5. The proposed system can have two outputs: the coefficients of the DWT related to the rhythms mu and beta; and a feature vector with three chosen features that can be used as an input to a classifier. The features extracted are mean, variance and energy. These are simple but effective features. Fixing some of the parameters simplifies the tool, offers a better environment for comparison of algorithms and allows the user to focus on specific steps of a BCI construction such as the feature selection and the classification phases.

Keywords—BCI; EEG; DWT; Feature extraction; Feature Selection; Classification; Motor Imagery; SMR; ERD/ERS; Simple tool.

I. INTRODUCTION

The advances in hardware and software have enabled many studies in the field of brain-computer interface (BCI) in the last decades [1]–[8]. In a BCI system, a user with the aid of an interface can control an external device using only brain signals, without the help from any peripheral nerves or muscles [1].

Due to its simplicity and low cost compared to other methods of brain function analysis, the most used signal acquisition technique in BCI studies is the electroencephalogram (EEG) [2]. The EEG is a noninvasive method that uses electrodes on the surface of the scalp placed at specific locations to monitor and record electrical activity signals generated by the firing of a group of neurons in the brain [1]. EEG-based

BCIs have been used for communication and control to help people suffering from severe motor disabilities [1], [4]. Both the realization of a movement and the imagination of the realization of the movement, also known as motor imagery (MI), produce signals that behave in a similar manner [1]–[4]. This is relevant because it enables a person who is unable to execute the movement to simply imagine its realization. An EEG can monitor MI over the sensorimotor cortex to observe the behavior of sensorimotor rhythms (SMR), such as the mu and beta rhythms. One of the main reasons why SMR has been used in BCIs is that users are capable of learning how to control MI features voluntarily after a certain amount of training [4], [5].

According to McFarland and Wolpaw [1], the biggest challenge in a BCI system for robotic and prosthetic devices is how to provide control signals that are fast, accurate and reliable [9]. One of the reasons for that is because the processing of brain signals is hampered by its properties. Brain signals are known for being non-stationary, non-linear and prone to noise [10]. Furthermore, EEG signals are different from one user to another in their frequency variations and task observations [2]. Moreover, these signals can be altered by properties like tiredness and emotional changes. Hence the necessity to build models with algorithms that can adapt to each user. Finding better features and better algorithms for feature extraction, selection and classification, can help the achievement of more accurate results, making the system more reliable. However, Lotte *et al.* observed a lack of comparisons between classifiers within the same study using identical parameters [11]. Ideally, classifiers should be tested in the same context, that is, with the same users, using the same feature extraction methods, protocol and parameters [1]. Similarly, this concept can be spread to all of the algorithms present in the system so that more suitable conclusions about the best algorithms for this type of signal can be found.

There are some tools available to help with the construction of a BCI [12]–[15] Yet, BCI research and development is an interdisciplinary problem, involving professionals from neuroscientists to computer engineers [4]. And even though these tools usually offer functions and algorithms ready to be used, it is still necessary to find out what are the outputs of these functions and how they can be used as input to the next steps of the development. Sometimes, it is required to

understand not only the theory behind the algorithm but also its implementation. As a result, these tools present a certain degree of difficulty in their learning and use by people whose expertise are not exactly related to some of the terminologies and concepts used. Besides, they allow a certain freedom in the choice of data sets, algorithms and type of analysis. This freedom is only good to some extent, since it ends up bringing a lot of variability, making it harder to compare the algorithms efficiently.

This paper intends to provide a simplified tool for the testing of feature extraction, selection and classification algorithms separately or combined for the analysis of motor imagery of left and right hands using SMR in offline EEG-based brain signals within a limited environment. The purpose of this limitation is to enable the comparison of the implemented algorithms with maximum similarity and minimum variability, keeping the data set, method of frequency isolation and preprocessing fixed under the same context. All these while providing some detail about the intermediate steps of the construction of the system by analyzing its partial results. The goal of this work is to enable the discovery of systems that can achieve the best results in velocity, precision and reliability of control signals. The proposed tool uses a discrete wavelet transform (DWT) algorithm to separate the desired sensorimotor signals and build a simple feature vector that can be used as input to classification algorithms.

II. ERD/ERS OF SENSORIMOTOR RHYTHMS

Sensorimotor rhythms are a common type of control signal used in EEG-based BCI of motor imagery. SMR are electrophysiological signals that can be monitored non-invasively with electrodes located over the sensorimotor cortex. According to the ISO 10-20 distribution pattern, this area is under the channels $C3$, Cz and $C4$ [16].

SMR comprises the rhythms **mu** (μ) and **beta** (β), which are oscillations in the brain activity located in the frequency bands $8Hz$ to $13Hz$ and $13Hz$ to $30Hz$, respectively [5]. However, a small variation on these frequency ranges might be encountered in other studies.

The rhythms mu and beta can be used as an indication of movement because the amplitude of these rhythms presents changes when movement, preparation of movement or motor imagery occur [4], [5]. With movement, their amplitude decreases significantly. This event is called event-related desynchronization (ERD). After movement and with relaxation, these rhythms have their amplitude increased again. This event is known as event-related synchronization (ERS). Neither ERD nor ERS require actual movement, they also occur with MI [4].

For hand movement, μ ERD happens 1-2 seconds before movement onset, reaching the minimum value during movement. While β ERS reach its maximum value 1-2 seconds after the end of the movement [8], [17]. ERD/ERS are contralateral to the movement [4]. When MI of the right hand happens, the left side of the motor and sensory cortex of the brain displays ERD, while the right side displays ERS and the opposite happens when MI of the left hand occurs [6]. As a result, usually the channel $C4$ is monitored when observing movements from the left hand side and channel $C3$, for movements from the right hand side [18].

It is possible to isolate the frequency bands corresponding to the mu and beta rhythms with the use of simple filters or with the help of algorithms.

III. DISCRETE WAVELET TRANSFORM

Non-stationary signals, such as biological signals, are signals whose frequencies vary in time. For the analysis of EEG signals in terms of mu and beta rhythms, it is necessary to extract the frequency bands present in the signal as well as when in time they happen. For this reason, the Fast Fourier Transform (FFT) is not an appropriated method for analyzing such signals, since it gives information only in the frequency domain [2], [19]. The Wavelet Transform (WT) on the other hand, gives information in both time and frequency domain. A variant of the WT called Discrete Wavelet Transform (DWT) provides sufficient information both for analysis and synthesis of the original signal. Moreover, it is considerably easier to implement and provides less redundant information as far as the reconstruction of the signal goes compared to another type of WT, the Continuous Wavelet Transform (CWT) [19].

TABLE I: Example of coefficients and their bandwidths

Approximation coefficients	BW	Detail coefficients	BW
A1	0 - $fs/4$	D1	$fs/4$ - $fs/2$
A2	0 - $fs/8$	D2	$fs/8$ - $fs/4$
A3	0 - $fs/16$	D3	$fs/16$ - $fs/8$
A4	0 - $fs/32$	D4	$fs/32$ - $fs/16$
A5	0 - $fs/64$	D5	$fs/64$ - $fs/32$

The DWT decomposes the signal into approximation and detail information and analyses it at different frequency bands with different resolutions using scales and translations of a window function known as the *mother wavelet*. This window is shifted through the signal in varied scales [2]. In other words, the translations can be understood as the shifting of the window in a time period and the scale as the width of the window at each moment. The signal in time domain is passed through a number of high-pass and low-pass filters depending on the desired level of decomposition. The resultant signals have both higher and lower frequencies. Higher frequencies are best determined in time domain and lower frequencies are enhanced by frequency [2]. After the filtering, according to the Nyquist's rule, half of the samples can be eliminated since the highest frequency becomes half of the value that it was before. Therefore, the signal is downsampled by two [19]. The level of decomposition depends on the sampling frequency and the desired frequency bands.

The approximation and the detail coefficients with their respective bandwidths, can be roughly calculated as depicted in Table I, where fs is the sample frequency.

It is important to choose the correctly wavelet family and the number of decomposition levels of the DWT when analyzing EEG signals. The *Daubechies* wavelet family is known for its orthogonality property and efficient filter implementation [20]. Moreover, it has been pointed out that the Daubechies of order 4 (db4) is suitable for identifying changes in EEG signals [2], [20]. An orthogonal transform means that the energy in the signal is preserved and partitioned among the coefficients [21]. The energy of the frequency bands are different with the

imagination of distinctive tasks. After movement, the energy in $C3$ and $C4$ are different [20]. Thus, with the use of an orthogonal wavelet, the energy can be used as a feature to compose the feature vector.

IV. EXPERIMENT

A general overview of the proposed tool is presented in Fig. 1. It receives a file of recorded EEG signals as input and gives as output either just the coefficients that represent the mu and beta rhythms extracted with the use of a DWT or a feature vector formed by the features mean, variance and energy of these coefficients. This way, the user can choose arbitrary features to be extracted or use an algorithm to do so. And if the goal is to test just classification algorithms, then the user can simply use the given feature vector. The data set, preprocessing phase, rhythm isolation and feature extraction are always carried in the same manner so that the algorithms of feature selection and classification can be tested and compared. All of the algorithms are implemented using MATLAB and the biosig toolbox [14].




Fig. 1: Tool's overview

The data set used is from the Graz BCI Competition IV, 2008 - 2a. It is a public, well known and extensively used data set that consists of EEG data for motor imagery of four different tasks from nine subjects. A trial is a recording of one of the tasks and has the duration of approximately 9 seconds. A run consists of 48 trials, being 12 trials for each of the tasks. A file is recorded for each subject and it contains one session, which comprises 6 runs, yielding a total of 288 trials per session. 22 electrodes were used for the recording of the brain activity and their placement were carried based on the ISO 10-20 system. The signals were sampled with 250 Hz and were filtered with a band-pass filter between 0.5 Hz and 100 Hz and with a 50 Hz notch filter enabled to suppress line noise. For the recording, at $t = 2s$, that is, after 2 seconds, a cue in the form of an arrow pointing up, down, left or right (corresponding to each of the imagined movements) was displayed for 1.25s, indicating that the subject should begin the imagination and keep it going until $t = 6s$. More details about this data set can be found in the description file [22].

In this paper, only the activity of two tasks are analyzed, namely the motor imagery of left and right hands. As a result, each run is composed of 24 trials and the total of trial per session is 144. In order to simplify and reduce redundant information, only channels $C3$, Cz and $C4$ are used. Indeed, since the intention is to observe ERD/ERS from mu and beta rhythms, which are rhythms associated with motor imagery,




Fig. 2: Example of mu and beta rhythms observed over $C3$ related to motor imagery of right hand.

it is reasonable to use only the electrodes placed over the sensorimotor cortex. After acquiring the signals from the chosen channels, the trials were separated according to the instruction from the description of the competition [22]. The epoch extraction phase takes into consideration the events of ERD/ERS. Considering the reaction time of a health person as 500ms [18], the movement occurs around 4s and for this reason the epochs chosen are from 2-7s so that both events can be observed. Filtering is done using a band-pass Chebyshev type II filter from 5-35 Hz, which comprises the range of mu (8-12 Hz) and beta (18-30 Hz) rhythms and help avoid artifacts. The DWT algorithm is used to isolate the mu and beta rhythms from the filtered data. The mother wavelet used is the db4 of level 5. As seen in Table I, since the sample frequency is 250 Hz the estimated frequency bands for the detail coefficients of each level, from level 1 to level 5, are 62.50 - 125.00 Hz; 31.25 - 62.50 Hz; 15.62 - 31.25 Hz; 7.81 - 15.62 Hz; and 3.90 - 7.81 Hz. The detail coefficients $D3$ and $D4$ are the ones with the correspondent ranges of beta and mu rhythms, respectively. Hence, these two coefficients are one of the outputs of the tool and are the ones used for the extraction of information for the montage of the feature vector. Here, the extracted features are **mean**, **variance** and **energy**. These features were calculated according to equations (1), (2) and (3), respectively. Even though it is possible to extract other kinds of features, these features are commonly used with this type of signals and other works show that they have efficient results [7], [20]. Also, one of the advantages of using DWT is the capability of having information in both time and frequency domains. For this reason, the features were chosen so they could represent information in both domains. For example, the mean represents information in the time domain while the energy represents information in the frequency domain. Where N is the total number of samples and x_i are the samples.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (1)$$

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N |x_i - \bar{x}|^2 \quad (2)$$

$$E = \sum_{i=-\infty}^{\infty} |x_i|^2 \quad (3)$$

V. RESULTS

Fig. 2 shows an example of an original raw signal, the same signal, but filtered, and the related normalized mu and beta rhythms. All signals were extracted from channel C3 regarding the movement of right hand. As mentioned before, movement onset happens around $t = 4s$ and the epoch extracted is from 2-7s. Considering that $t = -1s$ in the figure corresponds to 2s, it is possible to observe that mu and beta have a decrease in their amplitude (ERD) around $t = 1s$ which corresponds to 4s of the original recording. In the same way, the rhythms start increasing their amplitudes again (ERS), about 2.5s after the movement.

The ability to notice the intended behavior, proves that the processing of the signal is carried out correctly.

VI. CONCLUSION

The main intention of the proposed tool is to ease the comparison and testing of selection and classification algorithms of motor imagery activities of hands in EEG-based BCIs using SMR, within a limited environment. The signal processing is done up to the step of frequency isolation, leaving the implementation of the subsequent phases of feature extraction, selection and classification to the users.

Because it is a simplified tool, it can facilitate its understanding by users that are initiating their studies in the field of BCI. In addition, users that want to focus just on the testing of classification algorithms don't have to deal with the previous steps of signal processing. This reduction on the complexity of BCI systems' design could help with the adhesion of specialists and their deeper and more specific research in their own fields, providing greater speed in the development of more suitable systems. Similarly, finding better features and algorithms decrease the error rate of the system, increasing its precision and reliability.

Regarding the intermediate steps' results, the graphic shows that they are in accordance with the theory described and, therefore, can also be used to help in the understanding of the system. Tests using this tool can be done to find the algorithms that lead to the best possible accuracy in the prediction of MI activities for the designed system. A high percentage of accuracy is important to increase the usability of the system in a practical way.

ACKNOWLEDGMENT

The authors would like to thank CAPES for its financial support.

REFERENCES

- [1] D. J. McFarland and J. R. Wolpaw, "Brain-computer interfaces for communication and control," *Communications of the ACM*, vol. 54, no. 5, pp. 60–66, 2011.
- [2] S. U. Kumar and H. H. Inbarani, "Pso-based feature selection and neighborhood rough set-based classification for bci multiclass motor imagery task," *Neural Computing and Applications*, pp. 1–20, 2016.
- [3] D. J. McFarland, L. A. Miner, T. M. Vaughan, and J. R. Wolpaw, "Mu and beta rhythm topographies during motor imagery and actual movements," *Brain topography*, vol. 12, no. 3, pp. 177–186, 2000.
- [4] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clinical neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
- [5] L. F. Nicolas-Alonso and J. Gomez-Gil, "Brain computer interfaces, a review," *Sensors*, vol. 12, no. 2, pp. 1211–1279, 2012.
- [6] S. Huang and X. Wu, "Feature extraction and classification of eeg for imagery movement based on mu/beta rhythms," in *2010 3rd International Conference on Biomedical Engineering and Informatics*, vol. 2. IEEE, 2010, pp. 891–894.
- [7] W. Ting, Y. Guo-zheng, Y. Bang-hua, and S. Hong, "Eeg feature extraction based on wavelet packet decomposition for brain computer interface," *Measurement*, vol. 41, no. 6, pp. 618–625, 2007.
- [8] M. H. Alomari, A. Samaha, and K. AlKamha, "Automated classification of l/r hand movement eeg signals using advanced feature extraction and machine learning," *arXiv preprint arXiv:1312.2877*, 2013.
- [9] D. J. McFarland and J. R. Wolpaw, "Brain-computer interface operation of robotic and prosthetic devices," *Computer*, vol. 41, no. 10, 2008.
- [10] W. Klonowski, "Everything you wanted to ask about eeg but were afraid to get the right answer," *Nonlinear Biomedical Physics*, vol. 3, no. 1, p. 2, 2009.
- [11] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, and B. Arnaldi, "A review of classification algorithms for eeg-based brain-computer interfaces," *Journal of neural engineering*, vol. 4, no. 2, p. R1, 2007.
- [12] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, and J. R. Wolpaw, "Bci2000: a general-purpose brain-computer interface (bci) system," *IEEE Transactions on biomedical engineering*, vol. 51, no. 6, pp. 1034–1043, 2004.
- [13] C. A. Kothe and S. Makeig, "Bcilib: a platform for brain-computer interface development," *Journal of neural engineering*, vol. 10, no. 5, p. 056014, 2013.
- [14] A. Schlögl and C. Brunner, "Biosig: a free and open source software library for bci research," *Computer*, vol. 41, no. 10, 2008.
- [15] A. Delorme and S. Makeig, "Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis," *Journal of neuroscience methods*, vol. 134, no. 1, pp. 9–21, 2004.
- [16] A. R. F. Cabrera, "Feature extraction and classification for brain-computer interfaces," *Aalborg: Aalborg University, Denmark*, 2009.
- [17] G. Pfurtscheller and F. L. Da Silva, "Event-related eeg/meg synchronization and desynchronization: basic principles," *Clinical neurophysiology*, vol. 110, no. 11, pp. 1842–1857, 1999.
- [18] G. Cisotto, "Movement-related desynchronization in eeg-based brain-computer interface applications for stroke motor rehabilitation," 2014.
- [19] R. Polikar, "The wavelet tutorial. part iv. multiresolution analysis: the discrete wavelet transform," *Rowan University*, 2008.
- [20] D. Hu, W. Li, and X. Chen, "Feature extraction of motor imagery eeg signals based on wavelet packet decomposition," in *Complex Medical Engineering (CME), 2011 IEEE/ICME International Conference on*. IEEE, 2011, pp. 694–697.
- [21] "Wavelet packets: Decomposing the details," The Mathworks, Inc., Natick, Massachusetts, EUA, 2017, acceso em: (10 mar. 2017). [Online]. Available: <https://www.mathworks.com/help/wavelet/examples/wavelet-packets-decomposing-the-details.html>
- [22] C. Brunner, R. Leeb, G. Müller-Putz, A. Schlögl, and G. Pfurtscheller, "Bci competition 2008–graz data set a," *Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology*, pp. 136–142, 2008.