

**FELIPE CZUBIENIAK RUBELLO  
THOMAS YUKIO OSHIMA**

**DETECÇÃO DA INTENÇÃO E REALIZAÇÃO DO  
MOVIMENTO A PARTIR DOS SINAIS DE EMG E  
EEG PARA MEMBROS SUPERIORES**

São Paulo  
2021

**FELIPE CZUBIENIAK RUBELLO  
THOMAS YUKIO OSHIMA**

**DETECÇÃO DA INTENÇÃO E REALIZAÇÃO DO  
MOVIMENTO A PARTIR DOS SINAIS DE EMG E  
EEG PARA MEMBROS SUPERIORES**

Trabalho apresentado à Escola Politécnica  
da Universidade de São Paulo para obtenção  
do Título de Engenheiro Mecatrônico.

São Paulo  
2021

**FELIPE CZUBIENIAK RUBELLO  
THOMAS YUKIO OSHIMA**

**DETECÇÃO DA INTENÇÃO E REALIZAÇÃO DO  
MOVIMENTO A PARTIR DOS SINAIS DE EMG E  
EEG PARA MEMBROS SUPERIORES**

Trabalho apresentado à Escola Politécnica  
da Universidade de São Paulo para obtenção  
do Título de Engenheiro Mecatrônico.

Área de Concentração:

Bioengenharia

Orientador:

Arturo Forner Cordero

São Paulo  
2021

# AGRADECIMENTOS

Agradecemos o professor Arturo Forner Cordero pelo apoio durante todo o projeto e o seu direcionamento de críticas e sugestões.

Agradecemos aos doutorandos Eric Cito Becman, Gabriel Chaves de Melo e Lucas de Oliveira Suplino por suas orientações sobre os assuntos de EEG e EMG.

Agradecemos a todos os professores da graduação, nossas famílias e amigos.

# RESUMO

Deficiência física motora é um problema que afeta milhares de pessoas no Brasil e no mundo e a tendência é só aumentar conforme a expectativa de vida aumenta. Uma das possíveis soluções para um portador de deficiência é reabilitação, com o objetivo de recuperar a movimentação do membro. Com isso em mente exoesqueletos podem ser utilizados para oferecer uma melhor experiência de reabilitação, auxiliando o paciente nas atividades e diminuindo os esforços do fisioterapeuta. Para o melhor uso de um exoesqueleto deve-se ter uma sensação de controle sobre o mesmo, tanto em questão do movimento realizado quanto do tempo de realização do movimento. Desse modo, o princípio deste trabalho é utilizar dados de eletroencefalografia (EEG) e eletromiografia (EMG) a partir de um experimento do movimento de alcance da mão, disponíveis em um banco de dados público, para encontrar a relação temporal entre a intenção de movimento e o movimento em si. Duas técnicas de detecção de movimento são utilizadas, uma para cada sinal: o Event-Related Desynchronization (ERD) a partir do sinal de EEG, para detectar a intenção do movimento; e a detecção do ONSET e OFFSET no sinal de EMG, representando o início e final do movimento, respectivamente. Para complementar o trabalho, é realizada uma análise de coerência entre os sinais. Deste trabalho conclui-se que os métodos de detecção de movimento dos dois sinais são suficientes para encontrar o tempo entre a intenção e o próprio movimento, mesmo apesar da complexidade do sinal de EEG. São também definidas as bandas de frequência onde os sinais apresentam melhor coerência.

**Palavras-Chave** – EEG, EMG, Coerência, ERD, Onset/Offset, Engenharia.

# ABSTRACT

Physical disability is a problem that affects thousands of people in Brazil and worldwide and the trend is only to increase as life expectancy increases. One of the possible solutions for a person with a physical disability is rehabilitation, with the aim of regaining the limb movement. With this in mind, exoskeletons can be used to offer a better rehabilitation experience, helping the patient with activities and reducing the physiotherapist's efforts. For the best use of an exoskeleton, one must have a sense of control over it, both in terms of the movement performed and the time the movement is performed. Thus, the principle of this work is to use electroencephalography (EEG) and electromyography (EMG) data from a hand-reaching movement experiment, available in a public database, to find the temporal relationship between the intention of movement and the movement itself. Two motion detection techniques are used, one for each signal: Event-Related Desynchronization (ERD) from the EEG signal, to detect motion intention; and the detection of ONSET and OFFSET in the EMG signal, representing the beginning and end of the movement, respectively. To complement the work, an analysis of coherence between the signals is carried out. From this work, it is concluded that the motion detection methods of the two signals are sufficient to find the time between the intention and the movement itself, despite the complexity of the EEG signal. The frequency bands where the signals have better coherence are also defined.

**Keywords** – EEG, EMG, Coherence, ERD, Onset/Offset, Engineering.

# LISTA DE FIGURAS

1	Montagem do experimento do pé extraído de [1]. . . . .	14
2	Sistema para controle de órtese de cotovelo extraído de [2]. . . . .	15
3	Classes dos movimentos analisados para a formação do banco de dados extraído de [3]. . . . .	16
4	Parâmetros de movimentação do membro superior para a coleta dos dados de EMG e EEG extraído de [3]. . . . .	16
5	Posição dos eletrodos nos voluntários extraído de [3]. . . . .	16
6	Comparação entre o algoritmo proposto com demais métodos [4]. . . . .	17
7	Exemplo de um burst curto e um burst não típico, extraído de [5] . . . . .	18
8	Passo a passo do método utilizado para calcular a coerência [6] . . . . .	22
9	Etapas de pré-processamento do sinal de EMG. . . . .	30
10	Detalhamento do pré-processamento do sinal de EMG . . . . .	30
11	Etapas de pré-processamento do sinal de EEG. . . . .	31
12	Detalhamento do pré-processamento do sinal de EEG . . . . .	32
13	Etapas de obtenção de ONSET . . . . .	33
14	Etapas de obtenção de ONSET (focado) . . . . .	34
15	Processo de identificação do intervalo de tempo entre a intenção e inicia- lização do movimento . . . . .	35
16	Resultado do algoritmo de ONSET e OFFSET no dado de EMG . . . . .	39
17	Resultado do algoritmo de ONSET e OFFSET no dado de EMG (focado) .	39
18	Caso mais frequente: sobreposição dos sinais de EMG dos 6 diferentes canais praticamente idênticos . . . . .	40
19	Casos menos frequentes: movimento que indica atuação diferente entre os 6 canais . . . . .	41
20	ERD de todos os sinais . . . . .	42

21	ERD dos sinais que apresentam uma alta diferença do previsto . . . . .	42
22	Média dos sinais de ERD . . . . .	43
23	Resultado da análise de coerência dos sinais de EEG e EMG em uma região de movimento, a partir dos dados coletados do voluntário 4 sessão 1 . . .	44
24	Resultado inesperados da análise de coerência dos sinais de EEG e EMG em uma região de movimento, a partir dos dados coletados do voluntário 4 sessão 1 . . . . .	45
25	Resultado da análise de coerência da média dos sinais de EEG e EMG pré-processados, na região onde o movimento é realizado, a partir dos dados coletados do voluntário 4 sessão 1 . . . . .	45
26	Resultado da análise de coerência da média dos sinais de EEG e EMG pré-processados, na região onde o movimento é realizado, a partir de todos os dados coletados . . . . .	46



## LISTA DE TABELAS

1	Requisitos do projeto . . . . .	24
2	Parâmetros utilizados no algoritmo eDTA para detecção de ONSET e OFF-SET . . . . .	37
3	Taxa de detecção entre todos os sinais de EMG do experimento, em movimentos detectados e porcentagem de detecção . . . . .	38

# SUMÁRIO

<b>1</b>	<b>Introdução</b>	<b>10</b>
1.1	Motivação . . . . .	10
1.1.1	Reabilitação . . . . .	11
1.1.2	Exoesqueleto . . . . .	11
1.1.3	Sistema integrado EEG e sEMG . . . . .	12
<b>2</b>	<b>Estado da arte</b>	<b>13</b>
2.1	EMG e EEG em sistemas de exoesqueletos . . . . .	13
2.2	Dataset . . . . .	15
2.3	Análise de sinais EMG . . . . .	17
2.3.1	Detecção de Onset . . . . .	17
2.3.2	Classificação de movimento . . . . .	19
2.4	Análise de sinais EEG . . . . .	19
2.4.1	Identificação do ERD/ERS . . . . .	20
2.5	Coerência de sinais . . . . .	21
<b>3</b>	<b>Objetivo</b>	<b>23</b>
<b>4</b>	<b>Requisitos</b>	<b>24</b>
<b>5</b>	<b>Embasamento Teórico</b>	<b>25</b>
5.1	Eletromiografia e Eletroencefalografia . . . . .	25
5.2	Pré-processamento . . . . .	25
5.3	ONSET/OFFSET . . . . .	26
5.4	ERD . . . . .	27

5.5	Coerência entre os sinais . . . . .	28
<b>6</b>	<b>Metodologia</b>	<b>29</b>
6.1	Coleta de dados e pré-processamento - sinais EMG e EEG . . . . .	29
6.2	Deteccção de ONSET e Offset do sinal de EMG e classificação do movimento	32
6.3	Identificação do ERD do sinal de EEG . . . . .	34
6.4	Coerência dos sinais . . . . .	35
<b>7</b>	<b>Resultados e Discussões</b>	<b>37</b>
7.1	Algoritmo de detecção de ONSET e OFFSET . . . . .	37
7.2	Identificação da intenção de movimento a partir do sinal de EEG . . . . .	41
7.3	Coerência . . . . .	43
<b>8</b>	<b>Conclusão</b>	<b>47</b>
	<b>Referências</b>	<b>49</b>
	<b>Apêndice A – Códigos</b>	<b>52</b>

# 1 INTRODUÇÃO

## 1.1 Motivação

Pode-se definir deficiência como toda condição que traga impedimentos físicos, mentais, sensoriais ou intelectuais ao ser humano ao tentar realizar alguma atividade ou interagir com seu ambiente (Lei Federal nº 13.146/2015, artigo nº2). Assim, todos estão sujeitos a adquirir uma deficiência ao longo da vida. De acordo com a Cartilha do Censo de 2010 [7], cerca de 23,9% da população brasileira têm algum tipo de deficiência.

Inserido nesse dado, temos que a segunda maior deficiência presente entre os brasileiros é a deficiência motora ou física (7%) [7], cuja definição é dada pela limitação de qualquer função motora do corpo. Esse tipo de deficiência pode ser relacionado tanto à doenças genéticas (como a síndrome de Down) e neurológicas (como a doença de Parkinson ou o AVC), quanto à lesões (medulares ou cranianos) [8].

Além da existente população com deficiência física, deve-se atentar também à população que tende a adquirir tal deficiência. Com o avanço da medicina, acompanha-se o aumento da expectativa de vida. Consequentemente, pode-se enxergar um aumento da população idosa: de acordo com a Organização Mundial da Saúde, a população com mais de 60 anos de idade chegará a 2 bilhões até 2050 [9]. Devido a maior idade, a pessoa possui menos capacidade física e mental, e maior risco de doenças [9], causando maior chance de adquirir uma deficiência física.

O cenário de deficiência física pode ser visto então, como um vasto e crescente problema. Além da dificuldade dos portadores superarem barreiras socioeconômicas e físicas da sociedade, ainda necessitam lidar com a dependência de outros, afetando ambos os lados [10]. Recorre-se, então, à engenharia para poder solucionar esse problema. Dentro das existentes áreas de trabalho para a solução desse problema (promoção, prevenção, tratamento e reabilitação) [8] pode-se utilizar da tecnologia da engenharia mecatrônica para auxiliar na melhoria dos processos de assistência dos movimentos dos portadores de deficiência motora e a seu processo de reabilitação.

### 1.1.1 Reabilitação

A reabilitação tem grande importância para os portadores de deficiência física. Tem como objetivo a recuperação gradual dos movimentos perdidos a partir da fisioterapia e terapia ocupacional. Mesmos nos casos em que a deficiência apresenta danos permanentes no paciente, a reabilitação possibilita o portador a aprender a conviver com a incapacidade motora, encontrando diferentes maneiras de se reajustar ao ambiente. Dentro dessas terapias, o portador conta com exercícios físicos e sociais para reaprender as tarefas motoras perdidas, ganhando assim sua independência de volta.

O que realmente ocorre nessas terapias tem correlação com a neuroplasticidade e reorganização cortical. A neuroplasticidade é uma propriedade neuroquímica de variação da conexão dos neurônios. Assim como um elemento plástico, essa conexão pode se fortalecer ou enfraquecer com o tempo. A neuroplasticidade tem grande responsabilidade da aprendizagem motora e promove a reorganização cortical no córtex do cérebro. Esse princípio permite criar novos caminhos neurais aos danificados, podendo assim reaprender funções motoras. Ambos são resultados do exercício ativos, ativo-assistidos e passivos que ocorrem nas terapias. [8]

Todavia, no Brasil, o processo de fisioterapia é mais delicado. Pode-se então aplicar os conhecimentos de engenharia em tecnologias para assistir os profissionais fisioterapêuticos [11].

Equipamentos assistivos vêm ganhando espaço nas clínicas de reabilitação motora. Além de minimizar o trabalho dos terapeutas, devido a automação de tarefas pesadas e repetitivas, os equipamentos trazem mais consistência nas atividades. Assim, os resultados são mais controlados e quantificados [8].

### 1.1.2 Exoesqueleto

Entre os equipamentos tecnológicos assistivos para reabilitação, podemos destacar o exoesqueleto. Trata-se de uma tecnologia que mimetiza o exoesqueleto retratado na natureza, como em insetos. O LOKOMAT [12] é um exemplo de exoesqueleto. A origem de seu trabalho parte dos treinos em esteiras de locomoção, adotados em vários centros de reabilitação. Geralmente nesses trabalhos, fisioterapeutas assistem o movimento das pernas do paciente, parcialmente colocados na esteira por meio de um sistema de suspensão. A aplicação de um método autônomo por meio do LOKOMAT melhora a qualidade dos resultados e permite uma maior duração, uma vez que não depende dos esforços dos pro-

fissionais. Ao identificar esforços de movimentos, o LOKOMAT auxilia adicionando uma força e um movimento da esteira, para a realização da marcha.

Entretanto, o trabalho a ser realizado terá o foco nos membros superiores, visto que já existe ótimos trabalhos para os membros inferiores. Deficiência dos membros superiores não se limitam apenas aos casos de imobilidade, mas também de doenças como o Parkinson ou o AVC. São os membros superiores, em específico os braços e mãos, os responsáveis de tarefas mais diversas, como as de ambiente de trabalho. A reabilitação desses membros permite a reinserção dos portadores de deficiência em ambientes de trabalhos, e com isso menos barreiras para o paciente [13]. Os produtos Armeo são exemplos sofisticados de exoesqueletos para membros superiores: possuem exoesqueletos ativos e passivos. A partir de sinais EMG, o exoesqueleto auxilia no torque de flexão e extensão do braço. Por uma malha de controle da posição, pode-se definir a força e posição do exoesqueleto [14].

### **1.1.3 Sistema integrado EEG e sEMG**

Dentre os exoesqueletos mencionados anteriormente, todos trabalham com um mesmo sistema de captação de esforço dos músculos. O sensor utilizado é um eletromiograma, que permite captar a reação do músculo ao ser contraído ou relaxado, devido ao potencial elétrico gerada pelas fibras musculares. O eletromiograma mais comumente utilizado é o superficial (sEMG), pois é não invasivo ao paciente. [15]

O sinal EMG (eletromiografia) extraído, no entanto, apresentam ruídos que podem afetar a análise, diminuindo sua precisão. Filtros de controle são então utilizados nesses casos. Todavia, a integração dos sinais EMG já usados com os sinais EEG (eletroencefalografia) é apontado por trazer resultados mais satisfatórios [6]. Os sinais EEG são captados do cérebro, onde eletrodos monitoram as atividades elétricas. Quando uma pessoa realiza uma atividade, essa é comandada pelo cérebro. Como os eletrodos não estão presentes diretamente no músculo, os sinais EEG são considerados mais fracos. Assim, podemos relacionar os dois sinais EEG e EMG, resultando numa dupla compensação dos dois.

## 2 ESTADO DA ARTE

Com a finalidade de alcançar os conhecimentos atuais para a realização do projeto, alguns artigos científicos foram selecionados para o estado da arte. Além de artigos sobre o uso dos sinais EMG e EEG em um exoesqueleto, também escolheu-se estudar artigos de assuntos mais específicos, sobre os dados do dataset escolhido, métodos de análise de sinal EMG, métodos de análise de sinal EEG e a coerência entre as duas.

### 2.1 EMG e EEG em sistemas de exoesqueletos

Os trabalhos seguintes já abordam a fusão das duas técnicas. No artigo [1] é utilizado EEG e sEMG para identificar movimentos dos membros inferiores unilaterais, uma vez que os métodos exploram as vantagens de cada um e aliviam as limitações uma da outra. Durante o experimento, o sujeito deveria, partindo do relaxamento (movimentação nula), contrariar o pé (dorsiflexão ou flexão plantar), como indicado na Figura 1.

Após a filtragem e amplificação dos sinais capturados, tanto pelo EMG quanto pelo EEG, os métodos foram avaliados pelas suas performances de captura e os sinais EMG foram melhores que os sinais EEG, devido a aquisição direta da fonte (músculo). Porém está mais sujeito a distúrbios e ruídos. Ao cascatear os dois sinais, obteve-se o melhor resultado, anulando o problema de precisão do EEG e de ruído do EMG.




Figura 1: Montagem do experimento do pé extraído de [1].

Foi apresentado em [2] um sistema de controle do cotovelo direito utilizando sinais de EEG e EMG gravados com o auxílio de uma Raspberry Pi 3 B+ e o conversor analógico digital ADS1299EEG-FE. O experimento consiste em utilizar o DAS1299 para captar os sinais EEG e EMG por uso de eletrodos passivos não invasivos e transmitir para o Raspberry Pi. O Raspberry Pi comanda um motor DC brushless por intermédio de um conversor de nível lógico para controlar uma órtese de cotovelo. O sistema de montagem pode ser visto da Figura 2, retirada do próprio artigo.

O primeiro passo foi utilizar o sistema para gravar o movimento do cotovelo da mão direita repetidas vezes. Os dados obtidos foram movidos para um computador onde são feitos o pré-processamento para remover possíveis sinais de ruído. Os sinais de EEG e EMG são processados em um computador para obter uma relação entre os sinais e os movimentos que serão feitos. O segundo passo é extrair as frequências desejadas para estudo, e isso é feito usando a transformada discreta de wavelet em ambos os sinais, EEG e EMG. Para o sinal de EEG é usado Delta-Alpha Ratio e o EMG é usado o Quadrado Médio da Raiz para poder classificar os sinais medidos. A acurácia das medições finais foram de 90.3% para o treinamento e de 85.2% para os testes. Grande parte da acurácia veio do sinal de EMG, enquanto o sinal de EEG apresentou uma acurácia bem reduzida.

Um projeto que utiliza os sinais de EEG e EMG de maneira diferente de todos os trabalhos citados anteriormente é o apresentado em [16]. Esse trabalho propõe um modelo matemático para a performance psicomotora dos dedos das mãos de músicos. Foi proposto um modelo híbrido de análise chamado "*the-upper-alpha-power-EEG-simultaneous-with-foreheadEMG-response-to-finger-movement* ( $\Delta\alpha\text{-EEG}/\Delta\text{EMG}$ )". Esse modelo compara



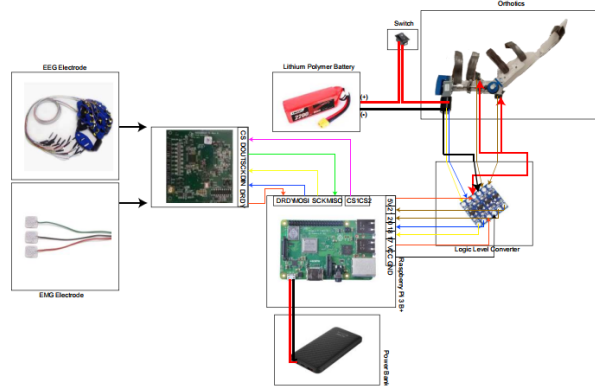


Figura 2: Sistema para controle de órtese de cotovelo extraído de [2].

os sinais de EEG e EMG de diversas pessoas com níveis de proficiência musicais diferentes para encontrar uma caracterização na performance psicomotora.

## 2.2 Dataset

Para progredir com nosso projeto, escolheu-se usar os dados já coletados para poder trabalhar com os sinais EMG e EEG [3]. Os dados referem-se a um experimento cujo o objetivo foi fornecer dados para a melhoria da comunicação entre usuários e interface cérebro computador (BCI).

O experimento, que envolveu 25 participantes realizando 11 diferentes pares de movimentos e movimentos imaginários de membros superior durante 3 dias, resultou em um enorme banco de dados - tanto não processados quanto processados - de sinais sEMG e EEG. Os movimentos são separados em 3 classes: arm-reaching, hand-grasping e wrist-twisting, representados na Figura 3. Cada movimentação segue um protocolo de descanso, aviso visual do próximo movimento e realização do movimento ou movimento imaginário - seguindo o padrão temporal de 4 segundos, 3 segundos e 4 segundos, respectivamente, como visto na Figura 4.

Para a coleta de dados, foram utilizados 7 canais de sinais sEMG - envolvendo 6 diferentes músculos do braço (extensor ulnar do carpo, extensor dos dedos, flexor do carpo radial, flexor ulnar do carpo, bíceps braquial e tríceps braquial) e o cotovelo como sinal de referência, e 60 canais de sinais EEG, além de mais 4 canais de sinais de eletro-oculografia (EOG) para eliminar sinais falsos de EEG. A montagem dos eletrodos pode ser observada na Figura 5. Todos sinais foram capturados em uma frequência de 2500Hz, com um filtro de 60Hz. A qualidade dos dados dos sinais obtidos foram validados comparando a acurácia dos dados obtidos com a classificação de performance de BCI.




Figura 3: Classes dos movimentos analisados para a formação do banco de dados extraído de [3].

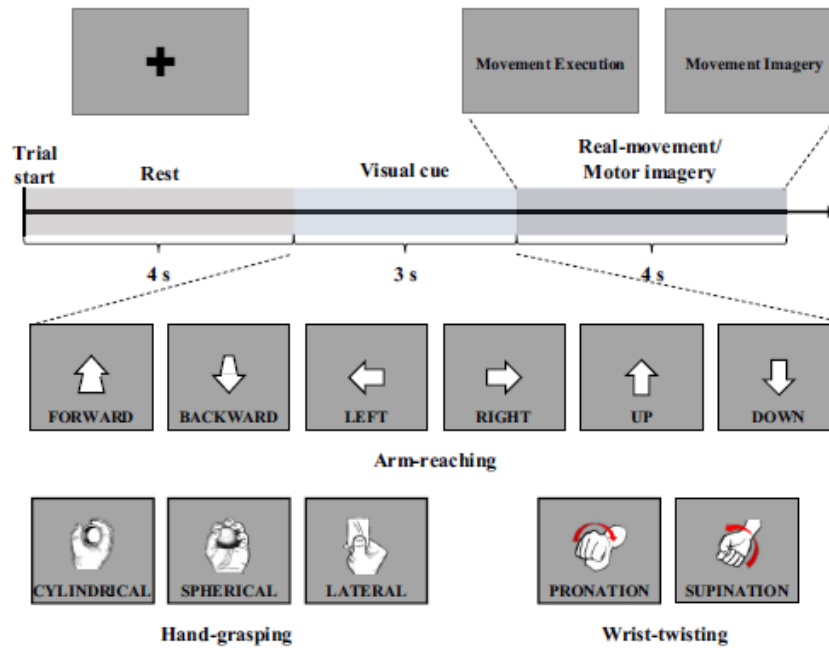


Figura 4: Parâmetros de movimentação do membro superior para a coleta dos dados de EMG e EEG extraído de [3].




Figura 5: Posição dos eletrodos nos voluntários extraído de [3].

## 2.3 Análise de sinais EMG

A partir do sinal de EMG obtido, é possível identificar o início do movimento (ONSET) realizado e o seu fim (OFFSET) no domínio do tempo. Existem, entretanto, algumas dificuldades de identificação, como por exemplo ruídos externos e distorções provocadas internamente, como o batimento cardíaco. Embora alguns especialistas consigam identificar visualmente apenas observando o sinal, existem também alguns métodos matemáticos que possam ajudar.

### 2.3.1 Detecção de Onset

Com o objetivo de trabalhar com os dados EMG coletados, deve-se compreender a detecção da ativação dos músculos - ONSET/OFFSET de cada sinal. É fato que o método mais acurado e preciso de detecção ONSET/OFFSET é o visual, porém é necessário uma pessoa especializada para tal método. Foi proposto em [4] um método mais simples e sem necessidade de um profissional ou um processo de treinamento anterior. Tal método foi aplicado em cima dos dados de sinais EMG coletados do movimento de abrir e fechar da mão. O método consiste em calcular o valor médio absoluto em janelas; utilizar um threshold baseado na taxa constante de alarme falso; e processar com o algoritmo de morphological hole filling. Comparou-se o resultado de tempos de ONSET/OFFSET com um sinal referência a partir de um giroscópio colocado no dedo médio, e com mais dois métodos regularmente usados: extended double threshold method (eDTM) e novel double threshold algorithm (nDTA). Os tempos de ONSET e OFFSET do método proposto ficou mais próximo da referência do que os métodos usuais de detecção, como visto na Figura 6, comprovando assim a eficácia do método proposto.

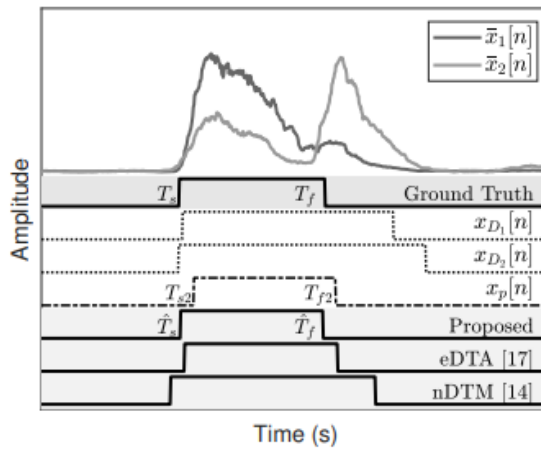


Figura 6: Comparação entre o algoritmo proposto com demais métodos [4].

O método de extended double threshold algorithm (eDTA) foi apresentado em [5]. Esse método apresenta uma maneira diferente de otimização de parâmetros para obter os thresholds. A principal diferença na seleção é a utilização de parâmetros não globais para a seleção do threshold, mas sim baseado em parâmetros obtidos por meio da realização de uma média móvel. O processo feito foi comparado com uma análise obtida de especialistas e apresentou uma boa concordância nos dados.

O método do eDTA é dividido em sete partes, com a sétima etapa sendo usada para o caso de movimentos que possuam duas componentes e seja desejado obter os ONSET e OFFSET do conjunto como um todo. As seis etapas obrigatórias são: Baseline Detection; First threshold using baseline parameters; Second threshold using on time; Third threshold using off time; Prune short events; Prune non-typical bursts. Para cada uma das etapas é necessário fornecer alguns valores de entrada, além dos dados de EMG, que servem para controlar as características dos threshold. Pode-se observar na Figura 7 exemplos da detecção e eficiência do algoritmo utilizado no sinal de EMG.




Figura 7: Exemplo de um burst curto e um burst não típico, extraído de [5]

No trabalho [17] foi apresentado o método novel double threshold algorithm (nDTA). O método nDTA é similar ao método tradicional de double threshold, mas tem como diferencial a seleção dos parâmetros de detecção antes e durante os testes. Os métodos tradicionais de double threshold utilizam dados médios de testes para obter os valores de threshold do sinal de EMG para detecção de ONSET e OFFSET, entretanto para sinais onde o signal to noise ratio, razão de sinal para ruído, (SNR) é variável, a detecção de ONSET e OFFSET pode ser prejudicada. Desse modo o nDTA propõe que a cada detecção de burst de sinal, seja feita uma reavaliação do SNR e dos valores de threshold. Ao final, foi comparado os resultados de detecção do método clássico com o nDTA, e foi observado uma melhora considerável para casos de SNR variáveis.

### 2.3.2 Classificação de movimento

Além da informação de início de movimento, pode-se também extrair do sinal de EMG informações capazes de construir um classificador de movimento, partindo do conceito de aprendizado de máquina. O processo de classificação do sinal pode ser resumido em 3 etapas (no aprendizado supervisionado) ou 4 etapas (no aprendizado não supervisionado) [18]. A primeira etapa é segmentar os sinais que representam o movimento realizado em janelas, adjacentes ou sobrepostas. Em seguida, são extraídas de cada janela características (features) que vão ser os indicadores do classificador. Essas características podem ser escolhidas dependendo do domínio trabalhado: tempo, frequência ou tempo e frequência. No domínio do tempo, as características mais comuns são as de valor médio absoluto e a raiz média quadrada. É recomendado antes de extrair as características que o sinal já esteja processado, uma vez que o sinal bruto pode ter baixa eficiência na classificação [19].

No caso em que o aprendizado de máquina seja não-supervisionado, deve-se aplicar uma clusterização nos dados obtidos, para poder identificar os grupos. A etapa final então é fazer o treino do classificador e o seu teste, com base de sinal diferente, para avaliar a eficiência do classificador. A entrada do classificador são as características extraídas do sinal e a saída a classe do movimento. Existem vários tipos sistemas de classificadores, sendo o mais comum e mais simples o Linear Discrimination Analysis (LDA). Para evitar sobrecarregar o classificador, pode-se optar por utilizar um método de redutor de dimensão, como o Principal Component Analysis (PCA) [19].

## 2.4 Análise de sinais EEG

Outro método de detecção de movimento é a observação de Event-Related Desynchronization (ERD) e Event-Related Synchronization (ERS) a partir dos sinais de EEG. Esses dois padrões do sinal são considerados a indicar a ativação da parte do cortex motor durante planejamento, execução e finalização do movimento. Ambos eventos podem ser interpretados no domínio do tempo [20]. Portanto, ERD e ERS são aspectos confiáveis para a identificação do movimento no tempo.

### 2.4.1 Identificação do ERD/ERS

Event-related desynchronization e event-related synchronization são fenômenos causados a partir de mudanças, decremento ou incremento, da sincronização de atividade neural. Esses dois fenômenos refletem mudanças no comportamento da frequência do sinal EEG, que indicam a inicialização (dessincronização) e finalização (sincronização) de algum movimento ou intenção de movimento do ser humano. Para medir tais fenômenos, é utilizado a relação entre potência do sinal EEG dentro das bandas de frequência e a potência base do mesmo na mesma banda de frequência, gravado antes do evento acontecer. Assim, ERD e ERS representam porcentagens de incremento ou decremento de potência do sinal.

O método segue as seguintes etapas: filtro passa-banda de todos os eventos (movimentos do voluntário); obter a potência da amplitude dos sinais e calcular a variância de ponto a ponto; obter uma média móvel entre essas potências [21].

É relevado no artigo que a atividade de movimento ativa o fenômeno de ERD na banda alpha de frequência, ativando dois padrões diferentes de dessincronização. Na faixa de 7 a 10Hz (Lower alpha desynchronization) é obtido a partir de qualquer tipo de atividade, já na faixa de 10 a 12Hz (Upper alpha desynchronization) é obtido a partir de processamento de informação semântica-sensorial. Movimentos voluntários resultam dessincronização na lower alpha band e upper alpha band, aproximadamente 2 segundos antes do ONSET do movimento.

O trabalho de [22] busca encontrar uma relação entre habilidades cognitivas e convulsões pouco frequentes em crianças com epilepsia focal não sintomáticas. Para o trabalho foram estudados 6 crianças com epilepsia e 11 crianças sem a doença, usadas como grupo de controle. O experimento obteve dados de EEG em 4 faixas de frequência de interesse (4-6 Hz, 6-8 Hz, 8-10 Hz e 10-12 Hz) durante tarefas de memória auditiva. Em cada um das faixas de frequências o sinal foi elevado ao quadrado e suavizado por uma media móvel. Para obter as taxas do sinal, tanto de ERD quanto ERS, foi utilizado uma janela de 1,5 segundos da posição de descanso como sinal de referência e a taxa foi calculada aplicando  $100\% \times (\text{energia durante referência} - \text{energia durante experimento}) / (\text{energia durante referência})$ . O estudo concluiu que as diferenças na faixa de baixa frequência (4-8 Hz) nas crianças com epilepsia, quando comparados com pessoas saudáveis da mesma faixa etária, podem indicar que as convulsões afetem a memória.

## 2.5 Coerência de sinais

A coerência dos sinais de EMG e EEG não só avaliam a relação entre os sinais, como podem também indicar diferenças entre pessoas saudáveis e pessoas com alguma doença neurológica. O sinal de EEG e EMG possuem magnitudes e comportamentos distintos, trazendo variações nos resultados dependendo das condições dos trabalhos.

No artigo [23] pode-se entender melhor os processos para o cálculo desse dado estatístico. Para investigar de melhor forma a atividade do sistema nervoso central de pacientes de com distonia focal na mão (FHD), é utilizado a métrica de CMC para comparar os resultados de uma pessoa saudável e uma portador da doença. O experimento realizado foi o descanso da mão tanto para o voluntário saudável quanto para o portador de FHD. Os dados foram coletados à 1kHz, e no pré-processamento foi usado um filtro de 4Hz 45Hz para o EEG e 50Hz 350Hz para o EMG.

Observou-se então nos resultados que os picos acima do nível de confiança que mais se destacaram foram ao redor das frequências de 5Hz 20Hz (banda de frequência  $\alpha$  e  $\beta$ ), enquanto nos pacientes com FHD houve picos também na região de maior frequência.

Os valores obtidos de CMC são afetados por múltiplos fatores, como a magnitude da força do sujeito e o tipo (estático ou dinâmico), a saúde, o design do experimento (movimento e músculos), a idade e as bandas de frequência [24]. Na maioria dos casos, entretanto, é melhor observado picos do valor de coerência acima do nível de confiança para frequências de banda  $\beta$ , especialmente entre 13Hz 21Hz e 21Hz 30Hz [25]. Um exemplo dado nos artigos é a doença de Parkinson, onde os valores de coerência podem ser observados na região de 4 6Hz e 8 12Hz.

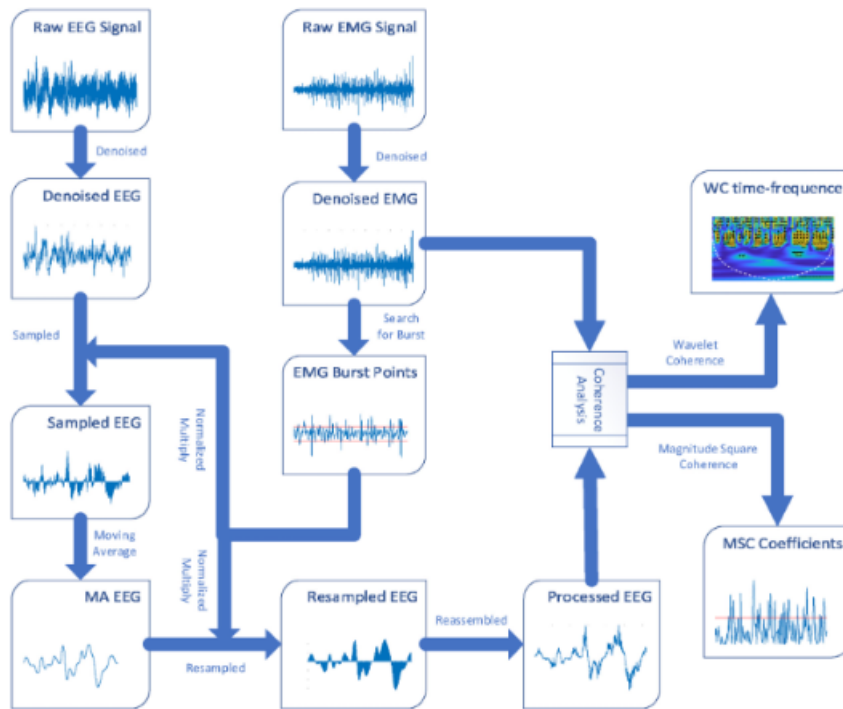


Figura 8: Passo a passo do método utilizado para calcular a coerência [6]

O trabalho [6] teve como meta melhorar a coerência entre os sinais de EEG e sEMG, antes baseada na transformada de Fourier (considerando o sinal como estacionário). Como o sinal do EEG é muito mais fraco que o EMG, a coerência entre eles é baixa. Para isso é proposto um algoritmo para o pré-processamento do sinal EEG a partir de parte do EMG mais significativo e, assim, a coerência do sinal EEG pré-processado e o sinal EMG são analisados pela wavelet coherence (Figura 8). O experimento foi aplicado aos movimentos gerados pela mão, porém analisando os movimentos de abrir e fechar da mão e o torcer do pulso. Os dados foram obtidos com uma frequência de amostragem de 512Hz, os eletrodos posicionados nos músculos do pulso direito e o canal de EEG utilizado para a coerência foi o C3, eletrodo central principal do lado esquerdo. Os resultados indicam que esse algoritmo consegue melhorar a coerência entre os sinais EEG-EMG, comparados com os resultados obtidos de Magnitude Squared Coherence (MSC) ou CMC. Além disso, dos resultados pode-se extrair diferentes valores de coerência para diferentes músculos e movimentos, podendo levar a uma futura classificação de movimentos a partir das coerências. Deve-se notar que experimento está limitado para parâmetros específicos, sinais EEG e EMG de mesma frequência e pessoas saudáveis.



### 3 OBJETIVO

O principal objetivo do projeto é a criação de um sistema de software responsável por detectar a intenção e inicialização do movimento, a partir dos sinais de EEG e EMG, e identificar a relação temporal entre as duas. Espera-se que a adequação temporal entre a intenção do usuário e a ação do exoesqueleto contribua para melhorar a sensação de controle do usuário sobre o dispositivo.

O objetivo principal pode-se então ser dividido em 3 partes: detecção de movimento dos sinais EMG; detecção de intenção de movimento dos sinais EEG; correlação dos inícios de movimento de cada resultado obtido e análise da coerência entre os dois sinais diferentes. Para a detecção do movimento do sinal EMG, o foco é sobre a identificação do ONSET e do OFFSET no sinal, ou seja, a identificação do começo e fim do movimento a partir do sinal. Já no sinal de EEG, o propósito é analisar os event-related desynchronization (ERD), evento relacionado à inicialização da intenção do movimento. Após obter as duas primeiras partes do objetivos, será então feita a correlação temporal e aplicar conceitos de coerência entre os sinais para encontrar as bandas de frequência nas quais os sinais possuem maior coerência.

## 4 REQUISITOS

Para que os objetivos do projeto sejam alcançados, é necessário garantir que os métodos de detecção sejam eficientes, tanto para os sinais de EMG quanto para os sinais de EEG. Somente a partir das detecções é que o programa será capaz de identificar o tempo entre a intenção de movimento e a coerência dos sinais. O programa deve ser responsável pela detecção e análise dos resultados, dentro da linguagem de programação *Python*.

O algoritmo utilizado para detectar os ONSETs e OFFSETs de movimentos no sinal de EMG deve ser capaz de detectar a maioria dos movimentos realizados em todo experimento: quanto mais movimento forem detectados, melhor será a confiabilidade da relação temporal e da coerência dos sinais. Além disso, o programa deve ser capaz de identificar o ERD no sinal de EEG a partir dos movimentos encontrados, o tempo médio entre o ERD e o ONSET e as bandas de frequência nas quais a coerência é relevante durante o movimento. Assim, os requisitos do projeto podem ser resumidos na tabela 1.

<b>Requisitos do projeto</b>
1. Detecção da maioria dos movimentos dentro dos sinais de EMG da base de dados
2. Capacidade de identificar o ERD no sinal de EEG
3. Identificação do tempo médio entre o ERD e ONSET
4. Identificação das bandas de frequência de maior coerência entre os sinais de EMG e EEG durante o movimento

Tabela 1: Requisitos do projeto

## 5 EMBASAMENTO TEÓRICO

### 5.1 Eletromiografia e Eletroencefalografia

O EMG é um método de detecção e medição de sinais elétricos gerados pelos músculos durante sua contração, representando atividade neuromuscular [26]. É possível obter os sinais de EMG de duas maneiras diferentes, eletrodos invasivos e não-invasivos. Os eletrodos invasivos consistem de agulhas que são inseridas diretamente no músculo, enquanto eletrodos não-invasivos são colocados na superfície da pele.

EEG é um dos métodos de medição de atividade cerebral [27]. Os sinais medidos por meio de EEG são sinais elétricos causados pela superposição e sincronização de atividades neuronais do cérebro que são captadas por meio de eletrodos posicionados no couro cabeludo. A medição de sinais de EEG ocorre com a utilização de eletrodos especificamente colocados em pontos cruciais pelo couro cabeludo, capazes de identificar atividade cerebral consequentes da ativação muscular.

### 5.2 Pré-processamento

Ao captar os sinais de EEG e EMG geralmente é captado diversos artefatos indesejados. Dentre os artefatos os mais comuns e conhecidos são a interferência da rede elétrica, o movimento dos olhos e de piscar. Por isso é necessário realizar um pré-processamento no sinal obtido. É utilizado um filtro do tipo notch para remover a interferência da rede elétrica. Outro motivo para o pré-processamento é uma filtragem do tipo passa-banda, com o intuito de obter apenas as faixas de frequência de interesse para o estudo em questão. Os limites do filtro variam para sinais de EEG e EMG.

O método mais utilizado para realizar o pré-processamento de dados é utilizando filtro de Butterworth. Uma das características desse filtro é que ele apresenta um ganho mais uniforme, sem ondulações, para as regiões da banda passante. É muito comum utilizar filtros de ordem bastante elevadas, quarta à oitava ordem, pois o filtro de Butterworth

mantém o mesmo formato para ordens elevadas, apenas reduzindo a variação do ganho na região da banda rejeitada.

### 5.3 ONSET/OFFSET

ONSET e OFFSET são os instantes de tempo em que ocorrem, respectivamente, o início da ativação muscular e o término da ativação muscular. Entretanto como os sinais do corpo humano não são do tipo binário, ativado ou desativado, esses instantes são obtidos com base em threshold de valores. Portanto, a análise de identificação dos ONSETs e OFFSETs não são sempre de exata precisão, e deve-se utilizar um algoritmo para detectá-los no sinal de EMG, evitando ruídos externos como picos de movimentos indesejados ou falhas na hora de captação.

Entre os algoritmos de detecção de ONSET e OFFSET, o extended double threshold algorithm (eDTA) apresenta resultados próximos aos identificados por profissionais [5]. O eDTA é composto por 7 etapas, nas quais são necessárias fornecer alguns valores de entrada com intuito de controlar as características dos thresholds. Esses valores são : Tamanho do segmento de baseline ( $L_b$ ); O rank da média móvel para seleção do segmento de baseline ( $K^{th}_b$ ); Número de desvios padrões do segmento de baseline ( $N_{sd}$ ); Tempo, em segundos, para detecção de um ONSET ( $T_{on}$ ); Tempo, em segundos, para detecção de um OFFSET ( $T_{off}$ ); Tempo, em segundos, para o menor tamanho de um burst de sEMG ( $T_s$ ); Número de desvios padrões do valor quadrático médio dos burst de sEMG ( $N_{nt}$ ); Tempo, em segundos, para o tempo máximo em que dois burst de sEMG estão separados para serem considerados apenas um burst de sEMG ( $T_j$ ).

A primeira etapa é a baseline detection, um procedimento para se obter parâmetros iniciais que serão utilizados durante o primeiro threshold. Nessa etapa o sinal de sEMG já pré-processado é retificado e então é passado uma média móvel de tamanho  $L_b$  segundos. Com os dados da média móvel é selecionado o  $K^{th}_b$  menor valor obtido como sendo o segmento de baseline. Com o segmento selecionado é calculado sua média e seu desvio padrão.

O primeiro threshold é obtido utilizando o dados original de sEMG, sem ser retificado, e os valores da média e desvio padrão obtidos anteriormente. Essa etapa consiste em selecionar todos os dados que possuem um valor superior à média somada a  $N_{sd}$  números de desvio padrões e criar uma nova lista de dados substituindo por 1 onde os valores de sEMG ultrapassam o baseline e 0 onde não ultrapassam. Com isso obtemos diversos pontos de

possível ativação muscular durante o sEMG. O segundo threshold utiliza os dados obtidos do primeiro threshold para obter uma primeira versão dos pontos de ONSET e OFFSET. Esse processo consiste em verificar todos os valores que ultrapassaram o valor do primeiro threshold e considerar a existência de um par ONSET e OFFSET quando se existe uma sequência de 1's com duração superior a  $T_{on}$  segundos. Esse segundo threshold é capaz de remover vários falsos positivos gerados pelo primeiro threshold.

O terceiro threshold utiliza os valores dos ONSET e OFFSET obtidos anteriormente para unificar ONSET's que estejam separados por menos de  $T_{off}$  segundos. Desse modo unimos pontos que fazem parte de um burst de sEMG mas cujo valor medido era menor que o primeiro threshold. O quarto threshold remove pares de ONSET e OFFSET que possuem duração menor que  $T_s$  segundos. Essa operação é realizada para permitir uma maior sensibilidade do  $T_{on}$  do algoritmo. Por fim removemos burst que possuem um tempo de duração relativamente elevado, mas cuja amplitude é baixa. A maneira para se efetuar essa remoção é obtendo os valores médios quadráticos para cada conjunto de ONSET e OFFSET, obter a média e desvio padrão dos valores médios quadráticos e considerar apenas os sinais que possuem uma média quadrática superior à media somada a  $N_{nt}$  desvios padrões. Podemos observar na Figura 7 dois tipos de situação que são removidas durante os dois últimos thresholds. Na esquerda vemos um burst de curta duração que havia sido considerado nas etapas anteriores, mas que foi removido durante o quarto threshold, e na direita vemos um burst de duração considerada pelo algoritmo, mas cuja amplitude não condizia com os outros bursts.

## 5.4 ERD

O ERD (Event-Related desynchronization) é uma queda na energia no sinal de EEG em determinada frequência. Este fenômeno junto ao ERS (Event-Related Synchronization) fazem parte dos ERPs (Event-Related Potentials), que são mudanças na atividade cerebral através de algum tipo de evento [20]. Em um sinal de EEG a partir de uma pessoa saudável, o ERD indica a ativação do córtex motor durante o planejamento de algum movimento, enquanto o ERS indica a recuperação das atividades neurais consequentes, ambos relacionados no domínio do tempo com o evento. O ERD e ERS, além de trazer essa informação, podem ser utilizados para identificar anomalias das atividades neurais causadas por doenças como Parkinson, com comportamentos diferentes em certas regiões de frequência.

Para identificar o ERD no sinal de EEG, é necessário realizar 3 etapas: filtrar o sinal

EEG para as bandas de frequências relacionadas ao evento, sendo a banda alpha a mais significativa; elevar ao quadrado as amplitudes do sinal para obter a potência; obter a média das potências entre todos os segmentos de movimento.

## 5.5 Coerência entre os sinais

A coerência é uma análise para relacionar dois sinais no domínio da frequência. O cálculo desse dado estatístico parte da densidade de potência espectral (PSD), e o seu valor varia entre 0 e 1.

No contexto dos sinais de EEG e EMG, existe a Coerência Corticomuscular (CMC), com objetivo de estudar as conexões funcionais e interações das atividades do córtex cerebral e a atividade do músculo. [24] Além disso, o CMC pode contribuir no ambiente médico, como indicador de doenças neurológicas ou sinais de recuperação de derrames, e no ramo de pesquisa de robôs biomédicos, próteses e reabilitação [25]. A fórmula do CMC é dada na fórmula 5.1, onde  $P_x(f)$  e  $P_y(f)$  são as densidades de potência espectrais de cada sinal, e  $P_{xy}$  5.2 o valor da densidade de potência espectrais cruzados (CPSD). Para avaliar a confiabilidade dos resultados obtidos, é calculado um nível de confiança (CL), dada a fórmula 5.3, onde  $\alpha$  é a porcentagem de confiança e  $N$  o número de segmentos usados para estimar a coerência.

$$Coh_{xy}(f) = \frac{P_{xy}(f)}{\sqrt{|P_x(f)|} \cdot \sqrt{|P_y(f)|}} \quad (5.1)$$

$$P_{xy}(f) = \frac{1}{n} \sum_{i=1}^n X_i(f) Y_i^*(f) \quad (5.2)$$

$$CL = 1 - (1 - \alpha)^{\left(\frac{1}{N-1}\right)} \quad (5.3)$$

Mesmo sendo um método comum e comprovado para as análises relacionais de córtex e músculo, os resultados obtidos de coerência e banda de frequência dentro CMC podem variar bastante, uma vez que o sistema neural é extremamente complexo e pode depender das condições da pesquisa em si: movimento realizado, idade dos voluntários e suas saúdes.

## 6 METODOLOGIA

### 6.1 Coleta de dados e pré-processamento - sinais EMG e EEG

Os dados dos sinais de EMG e EEG serão coletados de uma base de dados originada a partir de um experimento de movimento do membro superior. Os voluntários obedeceram a uma ordem de três classes movimentos distintos, com 50 repetições de cada movimento dentro da classe, durante três sessões. Os eletrodos foram posicionados na cabeça, para os sinais EEG, e nos músculos do membro superior, para os sinais EMG. A captura dos dados foi feita dentro de uma frequência  $f = 2500Hz$  [3]. Pode-se encontrar mais informações dos dados coletados na sessão 2.2 .

Para ser possível utilizar os dados de EMG posteriormente, será realizada uma série de processamento nos dados. As etapas do pré-processamento podem ser vistas nas Figura 9 e Figura 10, onde a segunda imagem apresenta uma visão mais aproximada do sinal. O primeiro gráfico é o sinal original como obtido da base de dados. Nesse sinal é aplicado um filtro Butterworth passa-banda de quarta ordem de fase zero, dentro da faixa de frequência de  $10Hz$  a  $490Hz$ , a faixa de frequência relativa à parte motora. O sinal após o filtro pode ser observado no segundo gráfico. O próximo passo é realizar uma retificação de dados, uma vez que para a detecção de ativação muscular é mais importante o valor absoluto do sinal.




Figura 9: Etapas de pré-processamento do sinal de EMG.

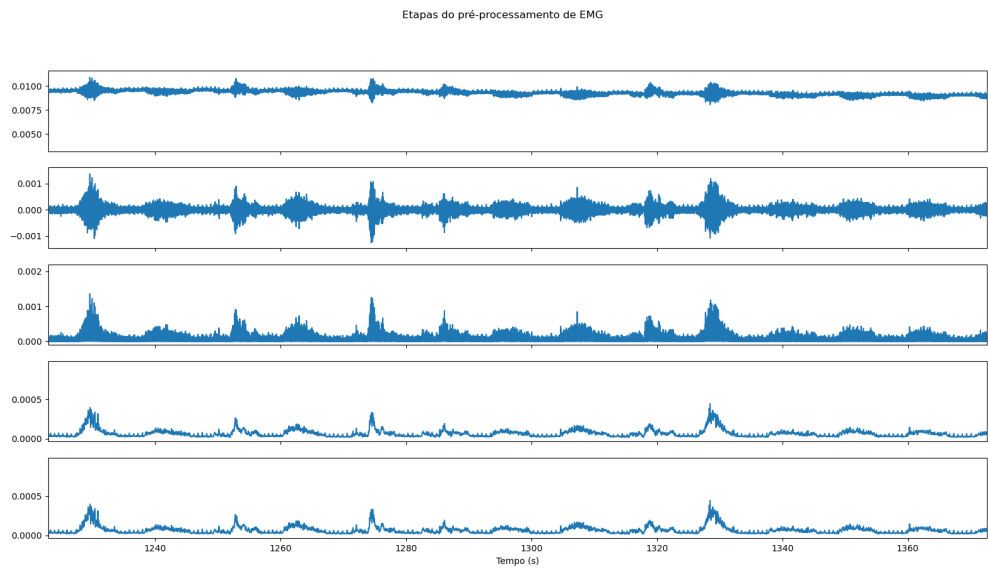


Figura 10: Detalhamento do pré-processamento do sinal de EMG

Como os dados obtidos da base de dados são extensos, aproximadamente 1 hora de duração gravadas em uma frequência de amostragem de  $2500Hz$  em 6 canais diferentes, realizar a detecção de ONSET e OFFSET em todos os dados seria uma tarefa que necessitaria de um grande poder computacional e demoraria muito tempo. Para reduzir o tamanho dos dados decidiu-se realizar uma redução de frequência nos dados. Para isso foi aplicado um novo filtro Butterworth passa baixa de quarta ordem de fase zero com frequência de corte de  $30Hz$ . Esse filtro é suficiente para obter as ativações musculares,



que são repetidas a cada 11 segundos e tem duração de 4 segundos. Por fim foi feita uma redução de amostragem para reduzir a frequência do sinal de  $2500Hz$  para  $100Hz$ .

De maneira similar os dados de EEG também deverão ser pré-processados para poderem ser usados posteriormente. Entretanto como são necessários uma quantidade bem menor de dados de EEG para a análise do ERD, uma vez que são utilizados apenas trechos do sinal ao redor do início do movimento, não é necessário realizar nenhuma mudança de frequência e nem retificação. Desse modo o único pré-processamento efetuado é um filtro no sinal de EEG extraído do banco de dados. O filtro utilizado é um Butterworth passa banda de quarta ordem de fase zero nas frequências entre  $8Hz$  e  $12Hz$ , como mostrado nas Figura 11 e Figura 12.




Figura 11: Etapas de pré-processamento do sinal de EEG.

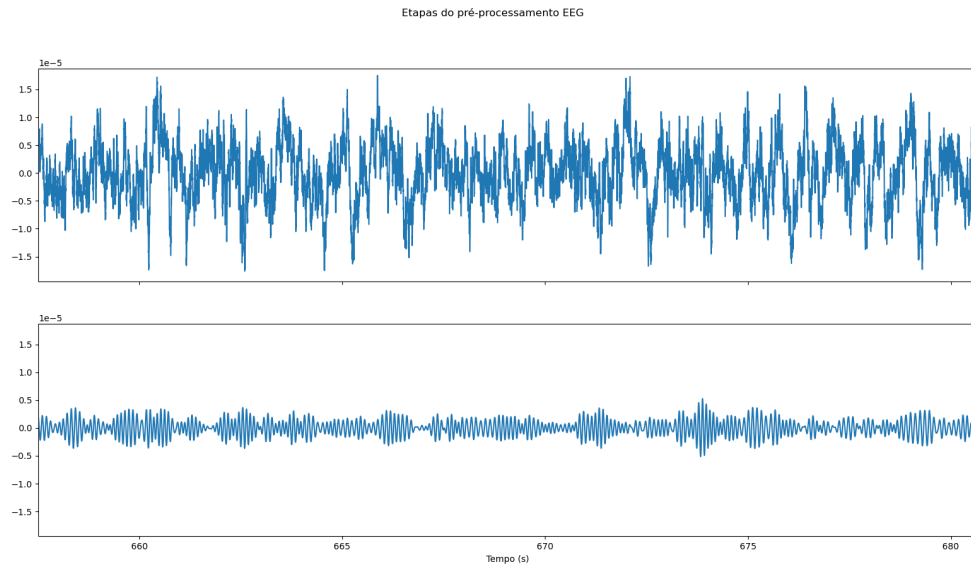


Figura 12: Detalhamento do pré-processamento do sinal de EEG

## 6.2 Detecção de ONSET e Offset do sinal de EMG e classificação do movimento

A partir dos dados de EMG pré-processados, será utilizado o algoritmo de extended Double Threshold Algorithm (eDTA) [5] para encontrar os pontos de ONSET e OFFSET do movimento. Com base nos códigos em matlab apresentados no artigo, o algoritmo, junto com suas respectivas funções e leituras de dados, será replicado no ambiente de programação Python. Assim, a partir dos dados pré-processados anteriormente, será possível encontrar o momento em que houve um início na atividade motora, representando um começo de movimento. O funcionamento do algoritmo pode ser observado nas Figura 13 e Figura 14, sendo a última uma versão focada da primeira.

O algoritmo tem como primeira etapa o cálculo da média e desvio e padrão de um segmento de dado considerado inativo. A duração do segmento de dado é fornecido ao código e pode ser modificado dependendo do experimento. O segundo passo é identificar quais sequencias de ativação muscular, obtidos anteriormente, possuem duração superior a um determinado threshold, definido pelo usuário. Desse modo obtém-se pares de ONSET e OFFSET, onde se inicia e termina uma ativação muscular. O próximo passo é unir pares que estejam distanciados por uma duração inferior a um threshold, também definido pelo usuário. Essa etapa serve para unir ativações musculares de um mesmo movimento, mas que o algoritmo considerou como dois movimentos. O quarto passo é remover pares

com duração inferior a um threshold de duração, controlado pelo usuário. Desse modo se retira qualquer possível espasmo muscular detectado que não pode ser considerado um movimento. Com os pares obtidos até o momento é calculado a média e o desvio padrão a partir da raiz do quadrado médio (RMS) do sinal entre os momentos de ativação muscular, e assim são removidos os conjuntos de dados que possuam sua RMS fora da faixa de mais ou menos a soma da média com o desvio padrão multiplicado por um threshold selecionado. Por fim, aplica-se uma lógica similar à terceira etapa, mas agora com um tempo relativamente maior, e junta-se qualquer conjunto de ativação de um mesmo movimento que estavam separadas.

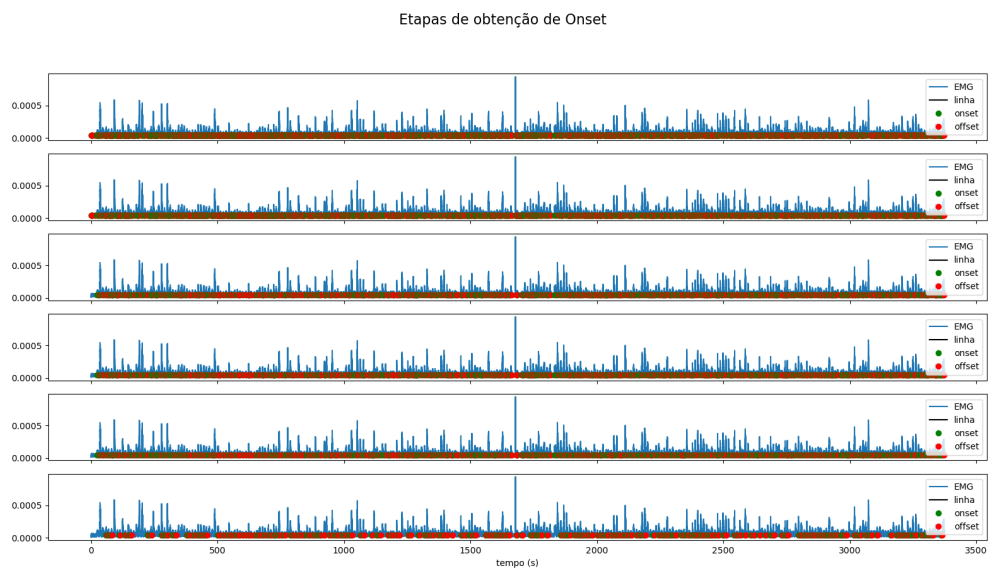


Figura 13: Etapas de obtenção de ONSET

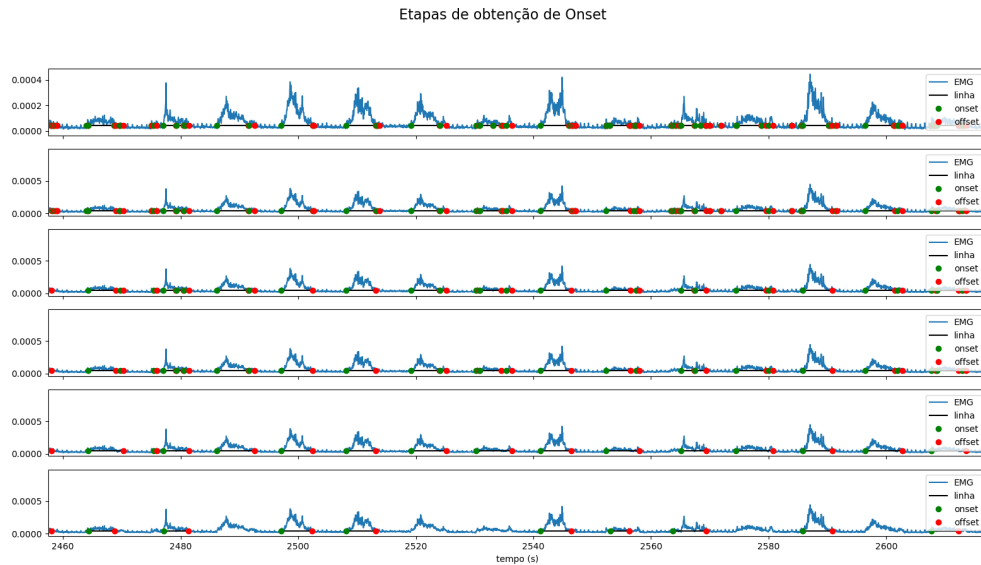


Figura 14: Etapas de obtenção de ONSET (focado)

Pela aplicação do eDTA obtém-se 6 conjuntos de ONSETs e OFFSETs, um para cada canal de EMG. Para reunir esses conjuntos em apenas um, realiza-se mais duas etapas de processamento. A primeira consiste em considerar uma ativação muscular apenas os instantes de tempo onde houve ativação em mais de N canais simultâneos, onde N é definido na utilização do código. Por fim, considera-se para os dados do experimento utilizado que qualquer ativação muscular com duração superior a 6 segundos ou inferior a 2 segundos poderia ser descartada para análise, uma vez que o movimento do experimento tem duração de 4 segundos e ativações muito maiores ou menores podem ser consideradas de detecção ruim para análise.

### 6.3 Identificação do ERD do sinal de EEG

O próximo passo é aproveitar dos sinais EEG. Baseado nas pesquisas de colegas de doutorando e iniciações científicas, adotou-se o método de identificar o Event Related Desynchronization (ERD) para avaliar as detecções de movimento. Esse também será adaptado para o ambiente de programação escolhido.

Para visualizar o ERD será utilizado os dados de ONSET obtidos anteriormente para obter os momentos de início de movimento. O primeiro passo é passar os dados de EEG por um filtro Butterworth passa-banda de quarta ordem de fase zero, dentro da faixa de frequência de  $8Hz$  a  $12Hz$ , que é a principal faixa de frequência para se obter o ERD (banda  $\alpha$  de frequência). A partir dos instantes de início de movimento, utiliza-se os

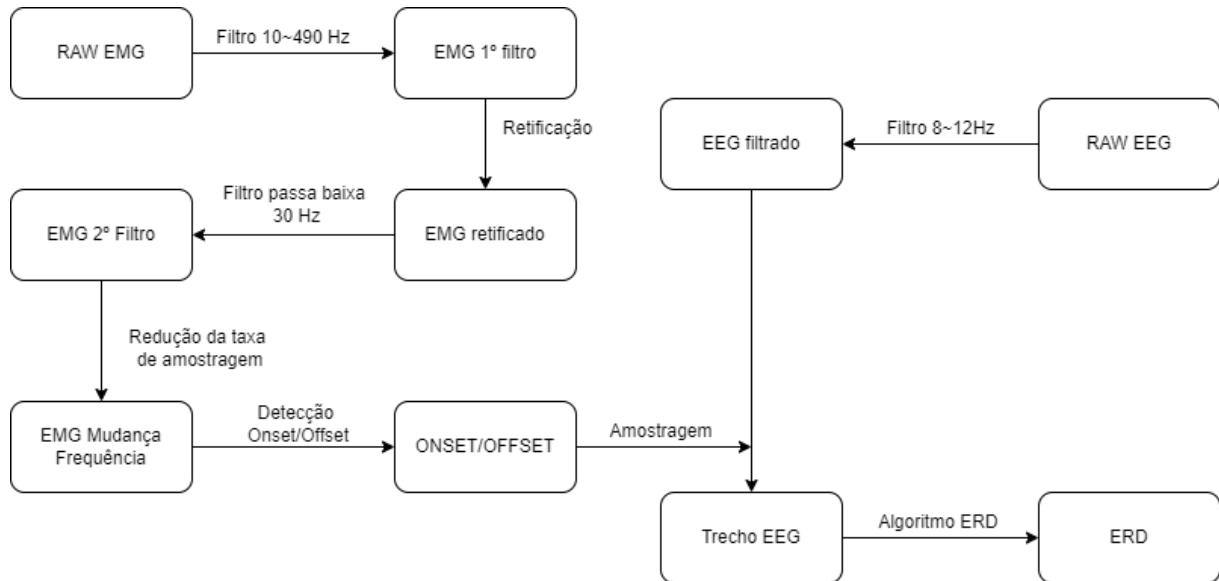


Figura 15: Processo de identificação do intervalo de tempo entre a intenção e inicialização do movimento

dados de EEG em um intervalo de -3s a 4s do ONSET. Desse modo é obtido a completa duração do movimento efetuado e uma duração anterior ao mesmo, onde pode se detectar o ERD. O próximo passo é obter a relação de energia do sinal nos instantes de interesse, e para isso eleva-se o sinal ao quadrado. Por fim aplica-se uma média móvel no sinal resultante para suavizar o sinal.

Como o sinal de EEG apresenta muito ruído, tanto de outras ativações cerebrais não relacionadas ao movimento, quanto de dificuldades em obter o sinal do cérebro através do crânio, a média de várias amostras de movimento é calculada com intuito de remover esse ruído. Finalmente, obtém-se a relação temporal do ERD e o ONSET, como mostrado na Figura ??.

## 6.4 Coerência dos sinais

Para finalizar o trabalho apresentado, será realizado o cálculo da coerência dos sinais EMG e EEG. Existe uma vasta literatura que aborda estudos da relação entre o EMG e o EEG, sendo a coerência um dos métodos mais comuns. A partir dos resultados observados no estado da arte, sabe-se que, no geral, valores de coerência corticomuscular resultam em picos na região de frequências entre a região  $\alpha$  e o início da  $\gamma$  (7-50Hz). O intuito da análise do CMC (5.1) neste trabalho é não só certificar que os sinais estão coerentes entre si, apresentando valores altos relativos na região esperada, como também observar comportamentos diferentes relacionados ao design deste experimento.

O estudo da coerência dos sinais será realizado em três etapas: pré-processamento, amostragem dos sinais e cálculo e plotagem da coerência para as regiões de frequência. Na primeira parte, com base nos estudos já realizados, os sinais de EEG e EMG são filtrados em um filtro de passa-banda semelhante ao utilizado na detecção de ONSET do EMG e na detecção de ERD no EEG, porém com frequências que abrangem a região de interesse. Para o sinal de EMG, a banda de frequência escolhida foi de 13-100Hz e para o EEG 8-30hz. É também realizado uma re-amostragem do sinal, de 2500Hz para 500Hz, devido ao enorme quantidade de informação do sinal.

A coerência do sinal inteiro é ineficaz, pois pode apresentar excesso de informação e picos de coerência em frequências fora do interesse. Assim, será analisado apenas nas regiões de movimento. Para isso, utilizaremos novamente a informação coletada de tempos de inicialização de movimento, a partir da detecção do ONSET, assim cortando em sinais menores com informação essencial. Os 7 segundos utilizados como base para a identificação do ERD também será considerado nesta parte de coerência.

Finalmente, como auxílio da biblioteca de análise de sinais do python utiliza-se as funções de coerência ( *scipy.signal.coherence* ) e a função que plota o gráfico ( *matplotlib.pyplot.cohere* ), que seguem o mesmo princípio do cálculo de CMC. A função de janela utilizada para o cálculo de coerência é a Hann, a mais comum. As configurações para a função são as padrões, havendo sobreposição e tamanho da janela igual a 256. A função logo retorna as magnitudes quadráticas de coerência dos finais, junto com as frequências nas quais elas se estabelecem, em forma de array.

Como visto na literatura, o processo de cálculo de coerência pode variar em relação aos filtros e parâmetros utilizados, portanto é importante notar que não há certeza na melhor forma de se calcular a coerência, dado o design do experimento.

## 7 RESULTADOS E DISCUSSÕES

Nessa seção será abordado os resultados obtidos. Será avaliado o método de detecção de cada sinal individualmente e como eles se complementam.

### 7.1 Algoritmo de detecção de ONSET e OFFSET

Com base no programa de MATLAB apresentado em [5], replicou-se a lógica do programa no ambiente de programação Python. Com a utilização do algoritmo de detecção de ONSET e OFFSET, e os parâmetros apresentados na tabela 2 baseados em [5], foi possível obter duas listas com os instantes de tempo onde ocorrem, respectivamente, os ONSETs e os OFFSETs do sinal.

Pode-se observar o resultado na Figura 16 e Figura 17. Cada gráfico representa um dos seis sinais gravados de EMG, os pontos verdes são os instantes de ONSET, início da ativação muscular, e os vermelhos são os OFFSETs, fim da ativação muscular, e a linha que os une é a ativação muscular em si. Visualmente, pode-se observar que na Figura 16 existe um movimento que não foi detectado. Isso acontece em alguns casos no qual a amplitude é muito menor em relação aos outros movimentos.

Parâmetros	Valores utilizados
$L_b$	100
$K^{th}b$	5
$Nsd$	3
$T_{on}$	0.1
$T_{off}$	0.05
$T_s$	0.5
$N_{nt}$	1
$T_j$	100

Tabela 2: Parâmetros utilizados no algoritmo eDTA para detecção de ONSET e OFFSET

	<b>sessão 1</b>	<b>sessão 2</b>	<b>sessão 3</b>
<b>Voluntário 1</b>	218(73%)	55(18%)	150(50%)
<b>Voluntário 2</b>	245(82%)	248(83%)	249(83%)
<b>Voluntário 3</b>	112(37%)	91(30%)	154(51%)
<b>Voluntário 4</b>	238(79%)	260(87%)	258(86%)
<b>Voluntário 5</b>	168(56%)	217(72%)	235(78%)
<b>Voluntário 6</b>	277(92%)	0(0%)	274(91%)
<b>Voluntário 7</b>	205(68%)	210(70%)	73(24%)
<b>Voluntário 8</b>	68(23%)	56(19%)	235(78%)
<b>Voluntário 9</b>	0(0%)	0(0%)	69(23%)
<b>Voluntário 10</b>	256(85%)	25(8%)	25(8%)
<b>Voluntário 11</b>	231(77%)	245(82%)	214(71%)
<b>Voluntário 12</b>	191(64%)	284(95%)	241(80%)
<b>Voluntário 13</b>	253(84%)	249(83%)	0(0%)
<b>Voluntário 14</b>	0(0%)	116(39%)	84(28%)
<b>Voluntário 15</b>	204(68%)	26(9%)	7(2%)
<b>Voluntário 16</b>	96(32%)	77(26%)	0(0%)
<b>Voluntário 17</b>	190(63%)	90(30%)	0(0%)
<b>Voluntário 18</b>	233(78%)	0(0%)	258(86%)
<b>Voluntário 19</b>	286(95%)	275(92%)	256(85%)
<b>Voluntário 20</b>	252(84%)	234(78%)	180(60%)
<b>Voluntário 21</b>	6(2%)	0(0%)	271(90%)
<b>Voluntário 22</b>	275(92%)	212(71%)	0(0%)
<b>Voluntário 23</b>	235(78%)	244(81%)	217(72%)
<b>Voluntário 24</b>	285(95%)	283(94%)	26(9%)
<b>Voluntário 25</b>	193(64%)	230(77%)	263(88%)

Tabela 3: Taxa de detecção entre todos os sinais de EMG do experimento, em movimentos detectados e porcentagem de detecção






Figura 16: Resultado do algoritmo de ONSET e OFFSET no dado de EMG

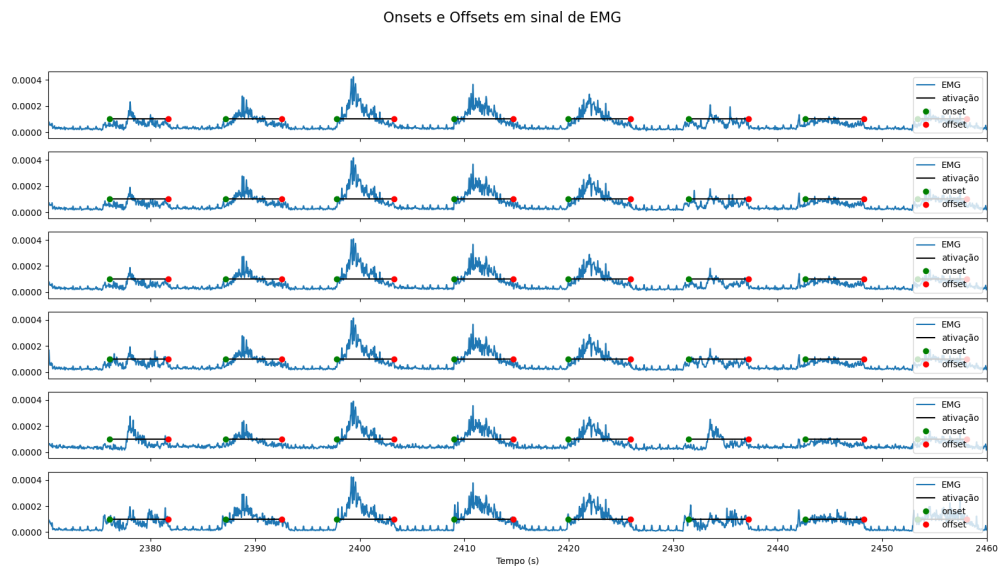


Figura 17: Resultado do algoritmo de ONSET e OFFSET no dado de EMG (focado)

Com o uso do algoritmo de detecção de ONSET e OFFSET foi possível obter quase que a totalidade dos movimentos realizados durante o experimento, com algumas exceções, como visto na Tabela 3. O principal fator para não detectar algum movimento é o sinal gravado ser muito fraco. Durante a execução dos códigos foi notado a grande sensibilidade dos parâmetros de detecção, pequenas alterações nos mesmos levam o algoritmo de detectar quase a totalidade dos movimentos para não detectar nenhum ou as vezes considerar grandes partes de sinal, incluindo momentos de repouso, como ativação muscular

de movimento.

A partir dos dados obtidos de ONSET e OFFSET, obteve-se os momentos teóricos em que cada movimento foi realizado, tanto o seu início quanto o seu término. A partir desses dados temporais, juntamente com o sinal de EMG, seria possível tentar separar os seis tipos diferente de movimentos em grupos, dado que o banco de dados escolhido não possui essa distinção em seus dados. Para esse agrupamento seriam utilizados os 6 canais de EMG, uma vez que movimentos diferentes possuem ativação de músculos diferentes. Entretanto ao analisar o sinal de EMG para cada um dos canais, que representam cada um dos músculos, foi verificado que não era possível distinguir os mesmos, como pode ser observado nas Figura 18 e Figura 19. Na maior parte dos movimentos todos os sinais apresentaram características idênticas, sendo raramente distinguíveis cada um dos canais. Com isso foi decidido por não realizar o agrupamento dos movimentos.




Figura 18: Caso mais frequente: sobreposição dos sinais de EMG dos 6 diferentes canais praticamente idênticos




Figura 19: Casos menos frequentes: movimento que indica atuação diferente entre os 6 canais

## 7.2 Identificação da intenção de movimento a partir do sinal de EEG

Utilizando os instantes de início de movimento obtidos pelo algoritmo de ONSET e OFFSET foi obtido os sinais de ERD de todos os sinais. As Figura 20 e Figura 21 apresentam os sinais obtidos. A primeira imagem mostra os sinais de ERD que apresentaram um comportamento condizente com o observado na literatura, enquanto a segunda mostra os sinais de ERD com um comportamento bem diferente.




Figura 20: ERD de todos os sinais




Figura 21: ERD dos sinais que apresentam uma alta diferença do previsto

Os sinais da Figura 20 apresentam características condizentes com o ERD, mas apresentam uma considerável variação. A variação do sinal de ERD pode ser considerado, em geral, como ruído, e por isso foi feita uma média de todos os sinais, que pode ser visto na Figura 22. Feita a média, os ruídos tendem a se anular, sobrando apenas o sinal de ERD desejado.

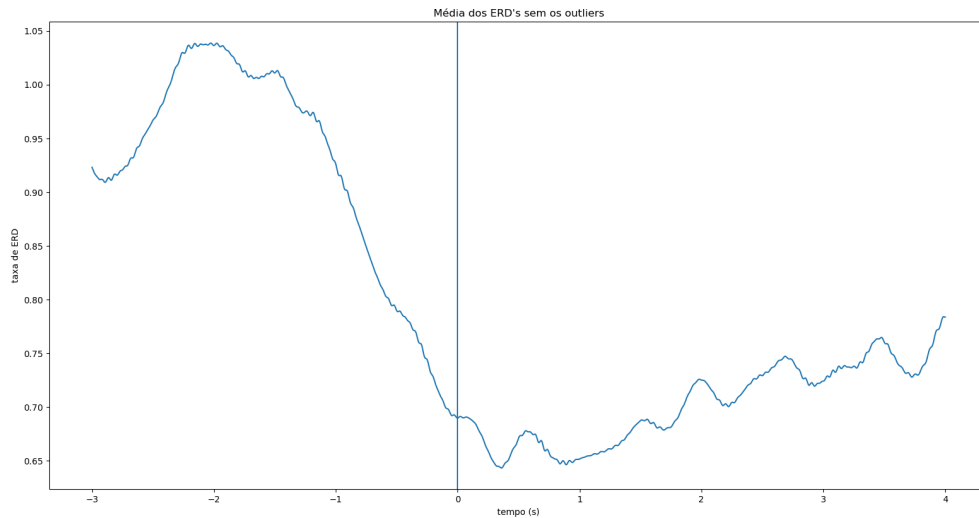


Figura 22: Média dos sinais de ERD

A partir da Fig 22 é possível verificar que existe uma grande relação com a intenção de movimento, com uma queda na energia do sinal de EMG, o que caracteriza o ERD. Essa queda pode ser percebida fortemente por volta de 1 segundo antes da realização do movimento. É possível observar que após o início do movimento a energia do sinal apresenta uma tendência de subida. Mesmo com esse resultado positivo, o uso do EEG para obter um possível início de movimento ainda é extremamente difícil. Como visto nas Figura 20 e Figura 21 o sinal apresenta muita variabilidade. É possível atribuir essa grande variabilidade com a complexidade do sinal de EEG, uma vez que eles são obtidos a partir de eletrodos posicionados cabeça. Por conta disso o sinal obtido é de baixa intensidade e sujeito a interferência de outros sinais indesejados de outras regiões do cérebro.

### 7.3 Coerência

Os resultados da coerência entre os sinais e EEG e EMG obtidos pela fórmula de CMC 5.1, não foram consistentes entre os movimentos. Dentre a vasta coleção de dados de movimentos, escolheu-se a os sinais de EEG e EMG do sujeito 4, sessão 1 para mostrar os resultados singulares. O canal escolhido de EMG foi o ligado ao músculo do bíceps.

As Figuras 23 e 24 são exemplos de resultados dos movimentos. Pode-se observar que ao mesmo tempo em que alguns movimentos apresentam os valores de pico de coerência na região esperada (13-30Hz), outros possuem comportamento inesperado. A grande variância do valor de coerência entre os movimentos pode ser explicado pela sensibilidade

do sinal de EEG e seu comportamento complexo.

Para obter um resultado mais sólido ao longo de todos os movimentos da sessão de dados, realizou o cálculo de CMC a partir da média dos dados de EEG e EMG na região dos movimentos, após eles serem tratados. A Figura 25 demonstra o comportamento obtido.




Figura 23: Resultado da análise de coerência dos sinais de EEG e EMG em uma região de movimento, a partir dos dados coletados do voluntário 4 sessão 1

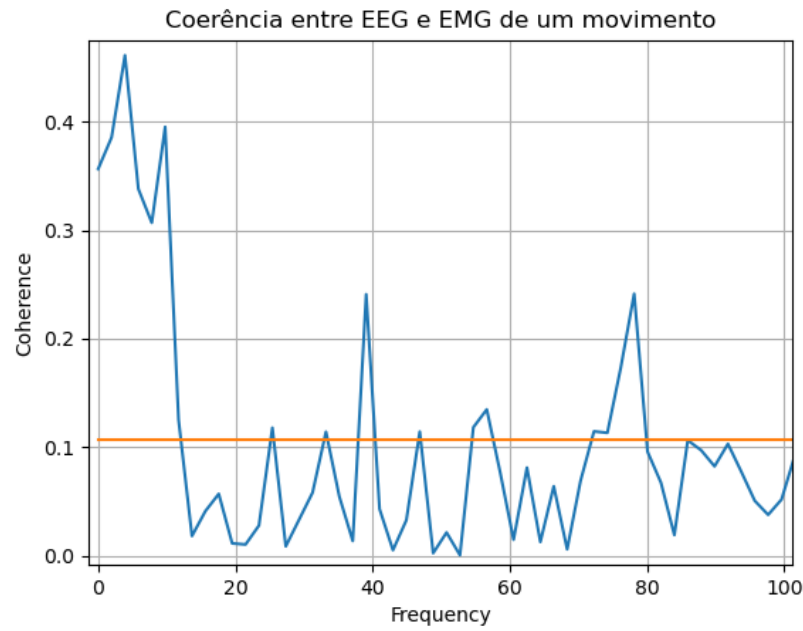


Figura 24: Resultado inesperados da análise de coerência dos sinais de EEG e EMG em uma região de movimento, a partir dos dados coletados do voluntário 4 sessão 1




Figura 25: Resultado da análise de coerência da média dos sinais de EEG e EMG pré-processados, na região onde o movimento é realizado, a partir dos dados coletados do voluntário 4 sessão 1

Pode-se observar que os picos na região de banda de frequência  $\beta$  são visíveis, porém

junto com outras peculiaridades. A Figura 26 representa um aprofundamento nas médias entre os demais sessões de coletas de dados, além de uma comparação entre os diferentes canais de EMG.

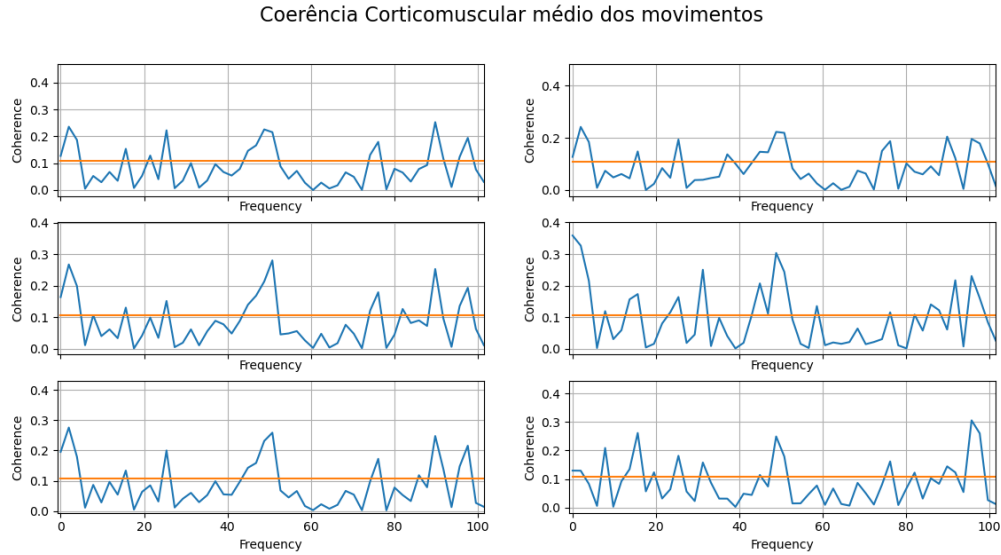


Figura 26: Resultado da análise de coerência da média dos sinais de EEG e EMG pré-processados, na região onde o movimento é realizado, a partir de todos os dados coletados

Como visto em pesquisas anteriores, o resultado de CMC pode ser afetado por diversos fatores, como saúde, idade, movimento, força, tratamento de dados e bandas de frequências. Os voluntários do experimento do dataset são apresentados como saudáveis e não possuem grandes diferenças de idade e todos eles são destros. Porém o design do experimento constitui em movimentos que não exercem força considerável. Além disso, um possível fator que possa ter influência nos resultados é a grande repetição dos movimentos durante a sessão de coleta de dados, podendo afetar os sinais obtidos de EEG. A escolha dos filtros para pré-processamento e bandas de frequência também são responsáveis pelo comportamento observado. Outros testes foram feitos com bandas de frequências diferentes, mas para a análise das regiões principais, as frequências escolhidas foram suficientes.

Mesmo assim, ainda foi possível identificar altos níveis relativos de coerência nas regiões desejadas, com algumas observações de picos na região de 50Hz e 5Hz. O resultado é suficiente para ter uma validação das coerências entre EEG e EMG no design do experimento.



## 8 CONCLUSÃO

Ao final deste trabalho pode-se concluir que o algoritmo utilizado para a detecção de intenção de movimento a partir do EEG e o início do movimento em si a partir do sinal de EMG é válido mesmo para um experimento de coleta de dados extenso e com grande resolução. O algoritmo para a detecção de onset e offset apresenta parâmetros sensíveis, que podem variar entre sinais de EMG e movimentos. Dos resultados da aplicação do algoritmo em todos sinais de EMG do experimento, utilizando os mesmos parâmetros de entrada, o algoritmo foi capaz de analisar 65 de 75 amostras de sinais, obtendo uma média de 62% de detecção entre todos os movimentos.

Individualmente, os dados podem apresentar variâncias por causa da complexidade do sinal de EEG, uma vez que sua captação envolve algumas sobreposições de sinais de outras regiões do cérebro. Pode-se, entretanto, assumir a média entre os movimentos a fim de identificar a variação de energia, separar os outliers e calcular o ERD do sinal de EEG, obtendo um valor adequado. A partir do ERD, representando a intenção do movimento, e do ONSET do início do movimento, obteve-se o intervalo de 1 segundo entre os dois.

É notável que este trabalho pode contribuir para futuros trabalhos dentro do assunto de sinais EEG e EMG. Com a informação temporal da intenção e a execução de movimento extraída de um banco de dados extenso, a criação de um sistema de controle para o uso em um exoesqueleto se torna mais aproximável. Existe a possibilidade de obter tempos diferentes de acordo com a saúde do paciente, idade e movimento específico, porém com o algoritmo proposto e utilizado no trabalho se torna mais confiável a detecção desse tempo. Além disso, a partir da coerência, sabe-se como se correlaciona os sinais dentro do design do experimento. Assim, se torna mais rápido a detecção de anomalias que podem ser relacionadas à doenças neurológicas. É possível assumir também que existe uma diferença entre as coerências de movimentos diferentes, mostrando a possibilidade de extrair uma classificação de movimentos a partir desses sinais EEG e EMG. Porém deve-se tomar cuidado com o posicionamento dos eletrodos responsáveis pelo sinal EMG e a complexidade de movimentação uma vez que no dataset trabalhado, os sinais de EMG

são muito semelhantes entre si e não possuem rótulos dos movimentos.

## REFERÊNCIAS

- [1] HOODA, N.; DAS, R.; KUMAR, N. Fusion of eeg and emg signals for classification of unilateral foot movements. *Biomedical Signal Processing and Control*, v. 60, 2020. Disponível em: <[www.scopus.com](http://www.scopus.com)>.
- [2] FERDIANSYAH, F. A.; PRAJITNO, P.; WIJAYA, S. K. Eeg-emg based bio-robotics elbow orthotics control. In: *Journal of Physics: Conference Series*. [s.n.], 2020. v. 1528. Disponível em: <[www.scopus.com](http://www.scopus.com)>.
- [3] JEONG, J.-H. et al. Multimodal signal dataset for 11 intuitive movement tasks from single upper extremity during multiple recording sessions. *GigaScience*, v. 9, n. 10, 10 2020. ISSN 2047-217X. Giaa098. Disponível em: <<https://doi.org/10.1093/gigascience/giaa098>>.
- [4] KANG, K.; RHEE, K.; SHIN, H. . Event detection of muscle activation using an electromyogram. *Applied Sciences (Switzerland)*, v. 10, n. 16, 2020. Disponível em: <[www.scopus.com](http://www.scopus.com)>.
- [5] RASHID, U. et al. Optimal automatic detection of muscle activation intervals. *Journal of Electromyography and Kinesiology*, v. 48, p. 103–111, 2019. ISSN 1050-6411. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1050641119302718>>.
- [6] XI, X. et al. Enhanced eeg–emg coherence analysis based on hand movements. *Biomedical Signal Processing and Control*, v. 56, p. 101727, 2020. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809419303088>>.
- [7] OLIVEIRA, L. M. B. Cartilha do censo 2010, pessoas com deficiência. 2012. Disponível em: <<http://www.unievangelica.edu.br/novo/img/nucleo/cartilha-censo-2010-pessoas-com-deficienciareduzido.pdf>>.
- [8] IBARRA, J. C. P. Controle de impedância adaptativo aplicado à reabilitação robótica do tornozelo. *PhD thesis, Universidade de São Paulo*, 2014.
- [9] AGEING. *World Health Organization*, Feb, 2018. Disponível em: <<https://www.who.int/news-room/facts-in-pictures/detail/ageing>>.
- [10] WORLD REPORT ON DISABILITY. *World Health Organization*, 2011.
- [11] COGLIATTI, P. A. S. P. Projeto de controle e comando de um robô paralelo para auxiliar na reabilitação do tornozelo. *PhD thesis, Universidade Federal de Santa Catarina*, 2019.
- [12] MORARI, S. J. G. C. T. K. H. F. M. Robotic orthosis lokomat: a rehabilitation and research tool. *National Library of Medicine*, Apr. 2003. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/22150969/>>.

- [13] TOKARSKI, D. R. L. T. Influence of disability type on upper-limb motor skills. *International Journal of Occupational Safety and Ergonomics*, Jul. 2016. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/22150969/>>.
- [14] LO, S. Q. X. H. S. Exoskeleton robots for upper-limb rehabilitation: State of the art and future prospects. *Medical Engineering & Physics*, Apr. 2011. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350453311002694>>.
- [15] YIN, G. et al. Processing surface emg signals for exoskeleton motion control. *Frontiers in Neurorobotics*, v. 14, 2020. Disponível em: <[www.scopus.com](http://www.scopus.com)>.
- [16] BAZANOVA, O.; PETRENKO, T. Alpha-eeg/emg-ratio as a viable predictor in modeling the psychomotor peak performance. In: *2019 International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON)*. [S.l.: s.n.], 2019. p. 0352–0353.
- [17] SEVERINI, G. et al. Novel formulation of a double threshold algorithm for the estimation of muscle activation intervals designed for variable snr environments. *Journal of Electromyography and Kinesiology*, v. 22, n. 6, p. 878–885, 2012. ISSN 1050-6411. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1050641112000855>>.
- [18] Asghari Oskoei, M.; HU, H. Myoelectric control systems—a survey. *Biomedical Signal Processing and Control*, v. 2, n. 4, p. 275–294, 2007. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809407000547>>.
- [19] CHOWDHURY, R. H. et al. Surface electromyography signal processing and classification techniques. *Sensors*, v. 13, n. 9, p. 12431–12466, 2013. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/13/9/12431>>.
- [20] AOH, Y. et al. Event-related desynchronization/synchronization in spinocerebellar ataxia type 3. *Frontiers in Neurology*, v. 10, p. 822, 2019. ISSN 1664-2295. Disponível em: <<https://www.frontiersin.org/article/10.3389/fneur.2019.00822>>.
- [21] PFURTSCHELLER, G.; Lopes da Silva, F. Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, v. 110, n. 11, p. 1842–1857, 1999. ISSN 1388-2457. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1388245799001418>>.
- [22] KRAUSE, C. M. et al. Brain oscillatory eeg event-related desynchronization (erd) and -synchronization (ers) responses during an auditory memory task are altered in children with epilepsy. *Seizure*, v. 17, n. 1, p. 1–10, 2008. ISSN 1059-1311. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1059131107001264>>.
- [23] CISOTTO, G.; MICHIELI, U.; BADIA, L. *A coherence study on EEG and EMG signals*. 2017.
- [24] LIU, J.; SHENG, Y.; LIU, H. Corticomuscular coherence and its applications: A review. *Frontiers in Human Neuroscience*, v. 13, p. 100, 2019. ISSN 1662-5161. Disponível em: <<https://www.frontiersin.org/article/10.3389/fnhum.2019.00100>>.

- [25] TUN, N. N.; SANUKI, F.; IRAMINA, K. Electroencephalogram-electromyogram functional coupling and delay time change based on motor task performance. *Sensors*, v. 21, n. 13, 2021. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/21/13/4380>>.
- [26] RAEZ, M. B. I.; HUSSAIN, M. S.; MOHD-YASIN, F. Techniques of emg signal analysis: detection, processing, classification and applications. *Biological Procedures Online*, v. 8, p. 11–35, Dec 2006.
- [27] R., M.-P. G. Chapter 18 - electroencephalography. In: RAMSEY, N. F.; MILLÁN, J. del R. (Ed.). *Brain-Computer Interfaces*. Elsevier, 2020, (Handbook of Clinical Neurology, v. 168). p. 249–262. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780444639349000184>>.

## APÊNDICE A – CÓDIGOS

Os códigos utilizados durante os experimentos se encontram no GitHub

<https://github.com/thomasoshima/TCC>