

Douglas Ruy Soprani da Silveira Araújo

**Interface Multimodal com Predição de  
Movimentos para Uso em Reabilitação de  
Membros Inferiores**

**Vitória – ES**

**2014**



Douglas Ruy Soprani da Silveira Araújo

## **Interface Multimodal com Predição de Movimentos para Uso em Reabilitação de Membros Inferiores**

Dissertação submetida ao programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do Grau de Mestre em Engenharia Elétrica.

Universidade Federal do Espírito Santo – UFES

Centro Tecnológico

Programa de Pós-Graduação em Engenharia Elétrica

Orientador: Dr. Anselmo Frizera Neto

Coorientador: Dr. André Ferreira

Vitória – ES

2014

Dados Internacionais de Catalogação-na-publicação (CIP)  
(Biblioteca Setorial Tecnológica,  
Universidade Federal do Espírito Santo, ES, Brasil)

---

A662i Araújo, Douglas Ruy Soprani da Silveira, 1988-  
Interface multimodal com predição de movimentos para uso  
em reabilitação de membros inferiores / Douglas Ruy Soprani da  
Silveira Araújo. – 2014.  
144 f. : il.

Orientador: Anselmo Frizera Neto.  
Coorientador: André Ferreira.  
Dissertação (Mestrado em Engenharia Elétrica) –  
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Eletroencefalografia. 2. Eletromiografia. 3. Robótica –  
Reabilitação. 4. Processamento de sinais. 5. Sensores inerciais.  
6. Interface Multimodal. I. Frizera Neto, Anselmo. II. Ferreira,  
André. III. Universidade Federal do Espírito Santo. Centro  
Tecnológico. IV. Título.

CDU: 621.3

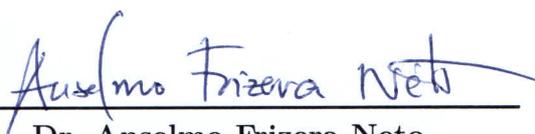
---

Douglas Ruy Soprani da Silveira Araújo

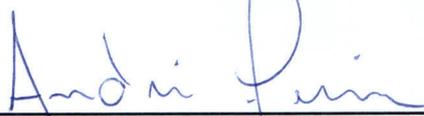
## **Interface Multimodal com Predição de Movimentos para Uso em Reabilitação de Membros Inferiores**

Dissertação submetida ao programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do Grau de Mestre em Engenharia Elétrica.

Trabalho aprovado. Vitória – ES, 10 de outubro de 2014:



**Dr. Anselmo Frizera Neto**  
Orientador



**Dr. André Ferreira**  
Coorientador



**Dr. Daniel Cruz Cavalieri**  
Instituto Federal de Educação, Ciência e  
Tecnologia do Espírito Santo



**Dr. Klaus Fabian Côco**  
Universidade Federal do Espírito Santo

Vitória – ES  
2014



*Para minha mãe, meu pai (in memoriam), minha tia, minha avó e para Aline.*



# Agradecimentos

Dedico meus agradecimentos à minha família e à minha namorada, Aline, que me serviram de *âncora* nos momentos mais difíceis dessa caminhada.

Aos meus colegas de trabalho do Laboratório de Automação Inteligente (LAI), onde este projeto foi desenvolvido, em especial aos amigos do grupo de pesquisa, pelo companheirismo.

Aos meus colegas de trabalho do IFES, pelo apoio.

Aos meus orientadores, pela oportunidade de aprendizado.



*"Quem, de três milênios, não é capaz de se dar conta,  
vive na escuridão, na sombra, à mercê dos dias, do tempo."*

*Johann Wolfgang von Goethe*



# Resumo

Esta dissertação apresenta o desenvolvimento de uma plataforma multimodal de aquisição e processamento de sinais. O projeto proposto insere-se no contexto do desenvolvimento de interfaces multimodais para aplicação em dispositivos robóticos cujo propósito é a reabilitação motora adaptando o controle destes dispositivos de acordo com a intenção do usuário. A interface desenvolvida adquire, sincroniza e processa sinais eletroencefalográficos (EEG), eletromiográficos (EMG) e sinais provenientes de sensores inerciais (IMUs). A aquisição dos dados é feita em experimentos realizados com sujeitos saudáveis que executam tarefas motoras de membros inferiores. O objetivo é analisar a intenção de movimento, a ativação muscular e o início efetivo dos movimentos realizados, respectivamente, através dos sinais de EEG, EMG e IMUs. Para este fim, uma análise *offline* foi realizada. Nessa análise, são utilizadas técnicas de processamento dos sinais biológicos e técnicas para processar sinais provenientes de sensores inerciais. A partir destes, os ângulos da articulação do joelho também são aferidos ao longo dos movimentos. Um protocolo experimental de testes foi proposto para as tarefas realizadas. Os resultados demonstraram que o sistema proposto foi capaz de adquirir, sincronizar, processar e classificar os sinais combinadamente. Análises acerca da acurácia dos classificadores utilizados mostraram que a interface foi capaz de identificar intenção de movimento em  $76,0 \pm 18,2\%$  dos movimentos. A maior média de tempo de antecipação ao movimento foi obtida através da análise do sinal de EEG e foi de  $716,0 \pm 546,1$  milissegundos. A partir da análise apenas do sinal de EMG, este valor foi de  $88,34 \pm 67,28$  milissegundos. Os resultados das etapas de processamento dos sinais biológicos, a medição dos ângulos da articulação, bem como os valores de acurácia e tempo de antecipação ao movimento se mostraram em conformidade com a literatura atual relacionada.

**Palavras-chaves:** eletroencefalografia. eletromiografia. sensores inerciais. interface multimodal. robótica de reabilitação



# Abstract

This master thesis presents a multimodal platform for acquisition and signal processing. The proposed interface acquires, synchronizes and processes electroencephalographic (EEG) signals, electromyographic signals (EMG) and inertial sensors (IMUs) signals. The data acquisition is done in experiments with healthy subjects performing motor tasks of lower limbs. The objective is to analyze the movement intention, the muscle activation and the movement onset. To do so, an offline analysis was performed. In the analysis are shown EEG signal processing techniques, whose aim is to identify movement intention, and EMG signal techniques aiming at identifying the initial muscle activation. Techniques for processing signals from inertial sensors whose aim is to identify movement onset and measure the knee joint angles are also shown. An experimental protocol is proposed. The platform can be used in the development of interfaces for rehabilitation robotics devices aiming at adapting their control with respect to the patient's intention. The results obtained showed that the system is capable to acquire, process and classify the signals synchronously. The movement intention was detected in  $76,0 \pm 18,2\%$  of the movements. The movement anticipation achieved  $716,0 \pm 546,1$  ms based on EEG signal and  $88,34 \pm 67,28$  ms based on EMG signals. The results of the biological signal processing, the movement anticipation times, the accuracy of classifiers and joint angles measurements were in accordance with the currently related studies.

**Key-words:** electroencephalography. electromyography. inertial sensors. multimodal platform. rehabilitation robotic.



# Lista de ilustrações

Figura 1 – Exosqueleto ativo utilizado em reabilitação no qual a interface multimodal proposta neste trabalho pode ser aplicada. . . . .	30
Figura 2 – A interface multimodal proposta no contexto de controle de dispositivos robóticos. . . . .	31
Figura 3 – Um neurônio e suas principais estruturas, mostrando o funcionamento da condução sináptica. Adaptado de Pons (2008a). . . . .	34
Figura 4 – Atenuação do campo elétrico gerado por correntes sinápticas extracelulares de células piramidais. Adaptado de Bear, M. F; Connors, B. W. e Paradiso (2008). . . . .	36
Figura 5 – Divisão do cérebro. Os principais lobos do cérebro são divididos de acordo com a localização de cada área. Cada lobo cerebral tem uma função especializada relacionada com a principal informação recebida a partir do corpo. O sulco central é a fronteira entre os lobos frontal e parietal. O lobo occipital é especializado no processamento de informação visual, o lobo temporal está relacionado principalmente com estímulos auditivos e o lobo parietal integra os diferentes estímulos. Na vizinhança do sulco central estão os córtex sensorial e motor. Adaptado de Pons (2008a). . . . .	37
Figura 6 – Esquerda: Localização cerebral das áreas funcionais relacionadas às ações motoras; Direita: Localização das áreas responsáveis pela coordenação dos principais membros do corpo. Adaptado de Guyton, A. C. e Hall (2006). . . . .	38
Figura 7 – Representação da porção das áreas motoras do cérebro relacionando com o membros do corpo. Adaptado de Guyton, A. C. e Hall (2006). . . . .	39
Figura 8 – Procedimento para visualização e as etapas do ERD (à esquerda) e do ERS (à direita). Adaptado de Pfurtscheller (1999). . . . .	42
Figura 9 – Gravação típica de EEG. Adaptado de Bear, M. F; Connors, B. W. e Paradiso (2008) . . . . .	43
Figura 10 – Posicionamento dos eletrodos segundo a padrão internacional 10-20. . . . .	44
Figura 11 – Modos distintos para a criação de canais para medição do sinal de EEG. (A) Eletrodos referência, R, terra, G, e ativo, A, para formar o canal O1; (B) Modo Bipolar; (C) Modo Unipolar (referência uni-auricular); (D) Modo Unipolar (referência biauricular); (E) Modo CAR usando referência uni-auricular. Adaptado de BENEVIDES (2013) . . . . .	45
Figura 12 – Representação da fibra muscular e suas partes. Adaptado de W (1996). . . . .	48

Figura 13 – Caminho do potencial de ação. A soma de MUAPs síncronas pode produzir contração contínua e força. Adaptado de Pons (2008a) . . . . .	49
Figura 14 – Filamentos grossos e finos em contração e relaxamento. Adaptado de Celani (2010) . . . . .	50
Figura 15 – Potencial de ação muscular: alterações nos canais iônicos durante o potencial de ação. . . . .	51
Figura 16 – Potencial de ação muscular: esquema simplificado de propagação do <i>AP</i> . Adaptado de MERLETTI (2004). . . . .	51
Figura 17 – Estruturas na contração do músculo esquelético produzindo sinal EMG. Adaptado de Rechy-Ramirez (2011) . . . . .	52
Figura 18 – ilustração do caminho do impulso elétrico desde o cérebro até o músculos, à esquerda, e a relação de membros com áreas do córtex motor mostrando o sistema piramidal, à direita. Adaptado de Bear, M. F; Connors, B. W. e Paradiso (2008). . . . .	52
Figura 19 – Localização dos eletrodos em relação às fibras musculares e amplitude gerada por cada posicionamento dos canais bipolares. Adaptado de Celani (2010) . . . . .	54
Figura 20 – A amplificação diferencial do sinal de EMG, os pontos por onde o potencial elétrico atravessa até chegar ao eletrodo para captação do sinal, à amplificação e à posterior filtragem e processamento. Adaptado de Criswell (2011). . . . .	54
Figura 21 – Detecção da contração muscular. Em (A) tem-se a detecção correta, em (B) se registram falsos positivos por ruídos e (C) a atividade secundária não é detectada. Adaptado de Staude (2001). . . . .	56
Figura 22 – Acelerômetro tri-axial piezoresistivo, à esquerda. À direita, a seção da figura da esquerda: um circuito de sensores piezoresistivos detectando diferença de tensão para mensurar a aceleração própria. Adaptado de Pons (2008b). . . . .	57
Figura 23 – Operação e eixos de referência do giroscópio. Adaptado de Pons (2008b). 58	58
Figura 24 – Ilustração do uso de sensores inerciais para a medição de ângulos do joelho, à esquerda. Diferença entre a medição baseada apenas no giroscópio (linha tracejada) e na IMU completa (linha contínua), à direita. Adaptado de Pons (2008b). . . . .	60
Figura 25 – Sistemas comerciais de sensores inerciais. Sistema <i>XSENSE</i> , à esquerda (A) (??) e sistema <i>SST-IBS</i> , à direita (B) (??). . . . .	60
Figura 26 – Esquema de um sujeito assistido por um exoesqueleto em um possível cenário de reabilitação proposto por Kirchner, Tabie e Seeland (2014) (Adaptado). . . . .	62

Figura 27 – Ilustração do protocolo experimental de testes do trabalho de Novak et al. (2013) (Adaptado). . . . .	63
Figura 28 – Etapas de processamento do sinal de EEG para a detecção de intenção de movimento do trabalho de Ibanez et al. (2013) (Adaptado). . . . .	64
Figura 29 – Esquema que ilustra o funcionamento da interface homem-robô proposta em Gallego et al. (2012) (Adaptado). . . . .	65
Figura 30 – Esquema que ilustra o funcionamento da interface homem-robô proposta para movimento de membro inferior (XU et al., 2014). (Adaptado). . . . .	66
Figura 31 – BrainNet <sup>®</sup> BNT-36. . . . .	68
Figura 32 – Painel de conectores do BrainNet <sup>®</sup> BNT-36. . . . .	68
Figura 33 – Gorro MedCap <sup>®</sup> utilizada para a aquisição de sinais de EEG. . . . .	69
Figura 34 – Eletrodo passivo para sEMG utilizado. . . . .	69
Figura 35 – Sistema de sensores inerciais Tech-MCS <sup>®</sup> . Concentrador de sinais e sensores inerciais (??). . . . .	70
Figura 36 – Sensores inerciais Technaid com a orientação de sua referência global. . . . .	71
Figura 37 – Colocação dos eletrodos para aferição de sEMG sobre o músculo Reto Femoral (CRISWELL, 2011). . . . .	72
Figura 38 – Colocação dos sensores inerciais na parte externa da perna direita do usuário. . . . .	73
Figura 39 – Fluxograma que ilustra a arquitetura de construção do <i>software</i> de aquisição de dados. . . . .	74
Figura 40 – Fluxograma que ilustra o funcionamento do <i>software</i> de aquisição de dados. . . . .	75
Figura 41 – Interface gráfica desenvolvida para o <i>software</i> de aquisição de dados de EEG, sEMG e de IMU. . . . .	76
Figura 42 – Diagrama de blocos que representa o sistema composto proposto, evidenciando a fonte, a forma de aquisição e o processamento dos dados. . . . .	77
Figura 43 – Ilustração da sincronia de dados entre dois sistemas . . . . .	78
Figura 44 – Ilustração das amostras de dados dos sistemas em uma linha de tempo. . . . .	79
Figura 45 – Ilustração do descarte de amostras e da sincronia de dados. . . . .	79
Figura 46 – Ilustração do posicionamento de amostras sincronizadas. . . . .	80
Figura 47 – Interpolação linear das amostras do sistema Tech-MCS <sup>®</sup> . . . . .	81
Figura 48 – Diagrama que representa a aquisição o pré-processamento dos dados. . . . .	81
Figura 49 – Usuário vestindo os sensores durante uma sessão de experimentos. . . . .	82
Figura 50 – Representação gráfica de uma repetição de movimento. . . . .	83
Figura 51 – Movimentos de rotação relativos ao joelho. Adaptado de WHITTLE (2008). . . . .	85
Figura 52 – Representação da perna através de segmentos e descrição dos ângulos relativos às rotações do joelho. . . . .	86

Figura 53 – Ilustração dos passos envolvidos no processamento para a obtenção dos ângulos do joelho. . . . .	86
Figura 54 – Ilustração do procedimento de alinhamento virtual. . . . .	87
Figura 55 – Ilustração dos passos envolvidos no processamento para a detecção do início do movimento. . . . .	90
Figura 56 – Ilustração do sincronismo do início do movimento entre as repetições de um experimento. . . . .	91
Figura 57 – Ilustração dos passos envolvidos no processamento do sinal eletromiográfico. . . . .	92
Figura 58 – Ilustração da forma como o classificador utiliza o janelamento para analisar as amostras do sinal. . . . .	93
Figura 59 – Ilustração do processo de validação cruzada usando o método de <i>Leave-one-out</i> . . . . .	94
Figura 60 – Ilustração dos passos envolvidos no processamento para a detecção da intenção de movimento observada em várias épocas do sinal. . . . .	96
Figura 61 – Ilustração dos passos envolvidos no pré-processamento do sinal de EEG para a detecção da intenção de movimento para uma época do sinal. . . . .	98
Figura 62 – Disposição das fontes cerebrais e dos eletrodos. Adaptado de Benevides (2009). . . . .	99
Figura 63 – Disposição das fontes cerebrais, eletrodos e atenuações. Adaptado de Benevides (2009). . . . .	100
Figura 64 – Dipolo Elétrico. (BENEVIDES, 2009). . . . .	101
Figura 65 – Esquerda: Disposição dos eletrodos sobre o escalpo; Direita: Mapeamento dos eletrodos referentes aos canais utilizados em um plano euclidiano. Adaptado de Benevides (2009). . . . .	103
Figura 66 – Ilustração dos passos envolvidos na classificação do sinal de EEG para a detecção da intenção de movimento para uma época do sinal. . . . .	105
Figura 67 – Distribuição normal univariada definida pela média $\mu$ e desvio padrão $\sigma$ , 95% da normal está no intervalo $ x - \mu  \leq 2\sigma$ (Duda, R. O.; Hart, P. E. e Stork, 2001). . . . .	108
Figura 68 – Um hiper-espaço de características com $d$ dimensões resulta em distribuições representadas em $d + 1$ dimensões. Para o espaço de características bidimensional da figura, a curva normal é representada em um espaço tridimensional e as elipses vermelhas representam planos de corte em diferentes alturas da normal. A figura representa amostras bidimensionais de uma normal bivariada que estão num conjunto centrado na média $\mu$ . As elipses vermelhas são as distâncias de <i>Mahalanobis</i> e mostram linhas de mesma densidade de probabilidade (Duda, R. O.; Hart, P. E. e Stork, 2001). . . . .	109

Figura 69 – Região de decisão não linear entre duas normais bivariadas. O hiperplano de separação são duas curvas. Adaptado de Duda, R. O.; Hart, P. E. e Stork (2001).	110
Figura 70 – Um sinal exemplar no tempo, à esquerda, e a densidade espectral de potência referente à uma janela do sinal obtido, à direita.	112
Figura 71 – Ilustração do processo de validação cruzada usando o método de <i>Leave-one-out</i> para treinamento e teste dos classificadores do sinal de EEG.	114
Figura 72 – Ângulos dos sensores com referência global.	116
Figura 73 – Ângulos relativos do joelho sem alinhamento virtual dos sensores inerciais.	117
Figura 74 – Ângulos relativos do joelho com alinhamento virtual dos sensores inerciais.	118
Figura 75 – Detecção do início efetivo de movimento.	118
Figura 76 – Sinal de sEMG cru.	119
Figura 77 – Sinal de sEMG filtrado em frequência a partir dos filtros <i>Notch</i> .	120
Figura 78 – Sinal da Figura 77 filtrado em frequência, com filtro passa-altas.	120
Figura 79 – Sinal da Figura 78 filtrado com o filtro de variância.	121
Figura 80 – Sinal de energia relativa nas bandas $\mu$ , em preto, e $\beta$ , em cinza.	122
Figura 81 – Sinal de EEG cru do canal Cz.	123
Figura 82 – Sinal de EEG filtrado na frequência com filtro <i>Notch</i> , espacialmente com filtro <i>CAR</i> e depois de ter passado pela SFL, do canal Cz.	124
Figura 83 – Sinal de EEG da Figura 82 filtrado em frequência na banda $\mu$ .	125
Figura 84 – Magnitude dos PSDs na frequência selecionada ao longo das janelas de tempo em uma época no canal Cz.	125
Figura 85 – Sinal relativo à diferença entre os discriminantes.	126
Figura 86 – Sinal relativo à variância da diferença entre os discriminantes.	127
Figura 87 – Detecções de EEG (triângulos) e EMG (pontos) realizadas pelos classificadores através dos procedimentos de validação cruzada.	128



# Lista de tabelas

Tabela 1 – Comparação entre pontos positivos e negativos dos sinais utilizados no trabalho de Gallego et al. (2012) (Adaptado). . . . .	65
Tabela 2 – Especificações técnicas do sistema Tech-MCS <sup>®</sup> . . . . .	70
Tabela 3 – Especificações técnicas dos sensores inerciais TechIMU <sup>®</sup> (Technaid). . . . .	72
Tabela 4 – Modas das frequências selecionadas em cada iteração da validação cruzada para os canais. . . . .	126
Tabela 5 – Acurácia dos classificadores por janelas de tempo obtidas pela interface proposta para os sinais de EEG. . . . .	130
Tabela 6 – Acurácia dos classificadores por janelas de tempo obtidas pela interface proposta para os sinais de EMG. . . . .	130
Tabela 7 – Acurácia na antecipação do movimento ( <i>Janela1</i> ) em sinais de EEG OU EMG. . . . .	131
Tabela 8 – Tempo médio e desvio padrão das classificações de antecipação do movimento. . . . .	131
Tabela 9 – Valores de Falsos-Positivos ( <b>FP</b> ) e Falsos-Negativos ( <b>FN</b> ) obtidos para os sinais de EMG e EEG por sujeito. . . . .	132



# Lista de abreviaturas e siglas

A/D	Analógico/Digital
ANVISA	Agência Nacional de Vigilância Sanitária
AP	<i>Action Potential</i>
AVC	Acidente Vascular Cerebral
AU	<i>Arbitrary Unit</i>
CAN	<i>Controller Area Network</i>
CAR	<i>Common Average Reference</i>
CI	Circuito Integrado
CPAP	<i>Continuous Positive Airway Pressure</i>
DCM	<i>Direction Cosine Matrix</i>
ECoG	Eletrocorticografia
EEG	Eletroencefalografia
EMG	Eletromiografia
ERD	<i>Event Related Dessynchronization</i>
ERP	<i>Event Related Potential</i>
ERS	<i>Event Related Synchronization</i>
ICC	Interface Cérebro-Computador
IHC	Interface Homem-Computador
IMU	<i>Inertial Measurement Unit</i>
INMETRO	Instituto Nacional de Metrologia, Qualidade e Tecnologia
LAN	<i>Local Area Network</i>
MEMs	<i>MicroElectroMechanical Systems</i>
MRP	<i>Movement Related Potential</i>

MU	<i>Motor Unit</i>
MUAP	<i>Motor Unit Action Potential</i>
MUAPT	<i>Motor Unit Action Potential Train</i>
PDF	<i>Probability Density Function</i>
PPSE	Potencial Pós-sináptico Excitatório
PPSI	Potencial Pós-sináptico Inibitório
PSD	<i>Power Spectral Density</i>
QDA	<i>Quadratic Discriminant Analysis</i>
SLF	Separação Linear de Fontes
sEMG	Eletromiografia de Superfície
SNC	Sistema Nervoso Central
SNP	Sistema Nervoso Periférico
UDP	<i>User Datagram Protocol</i>
USB	<i>Universal Serial Bus</i>

# Lista de símbolos

$\gamma$  Ângulo Pitch

$\alpha$  Ângulo Roll

$\beta$  Ângulo Yaw



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>29</b>
<b>1.1</b>	<b>Cenário e Motivação</b>	<b>29</b>
<b>1.2</b>	<b>Objetivos</b>	<b>30</b>
<b>1.3</b>	<b>Organização desta Dissertação</b>	<b>32</b>
<b>2</b>	<b>FUNDAMENTOS CONCEITUAIS</b>	<b>33</b>
<b>2.1</b>	<b>Sinais Eletroencefalográficos</b>	<b>34</b>
2.1.1	Origem do sinal de EEG	34
2.1.2	Aquisição do sinal de EEG	43
<b>2.2</b>	<b>Sinais Eletromiográficos</b>	<b>47</b>
2.2.1	Origem do sinal de EMG	47
2.2.2	Aquisição do sinal de sEMG	53
2.2.3	Detecção do começo da contração muscular	55
<b>2.3</b>	<b>Sensores Inerciais</b>	<b>57</b>
<b>2.4</b>	<b>Sistemas Multimodais Aplicados à Robótica de Reabilitação</b>	<b>61</b>
<b>3</b>	<b>ARQUITETURA DO SISTEMA DE MEDIÇÃO</b>	<b>67</b>
<b>3.1</b>	<b>Sistema de Amplificação e Condicionamento de Sinais Biológicos</b>	<b>67</b>
<b>3.2</b>	<b>Sistema de Análise de Movimento</b>	<b>69</b>
<b>3.3</b>	<b>Arquitetura da Interface Multimodal Proposta</b>	<b>72</b>
3.3.1	Aquisição dos dados	72
3.3.2	Sincronismo dos dados	77
<b>3.4</b>	<b>Protocolo Experimental de Testes</b>	<b>82</b>
<b>4</b>	<b>PROCESSAMENTO DOS SINAIS</b>	<b>85</b>
<b>4.1</b>	<b>Processamento dos Sinais dos Sensores Inerciais</b>	<b>85</b>
4.1.1	Medição de ângulos do joelho	85
4.1.2	Detecção do início do movimento	89
<b>4.2</b>	<b>Processamento do Sinal Eletromiográfico</b>	<b>91</b>
<b>4.3</b>	<b>Processamento do Sinal Eletroencefalográfico</b>	<b>95</b>
4.3.1	Detecção de intenção de movimento utilizando-se várias épocas do sinal	95
4.3.2	Detecção de intenção de movimento utilizando-se uma época do sinal	97
4.3.2.1	Pré-processamento do sinal de EEG	97
4.3.2.2	Classificação do sinal de EEG	104
<b>5</b>	<b>RESULTADOS OBTIDOS E DISCUSSÃO</b>	<b>115</b>

<b>5.1</b>	<b>Resultados das etapas de processamento dos sinais . . . . .</b>	<b>115</b>
5.1.1	Sinal das IMUs . . . . .	115
5.1.2	Sinal de sEMG . . . . .	119
5.1.3	Sinal de EEG . . . . .	121
<b>5.2</b>	<b>Acurácia dos classificadores e antecipações aos movimentos . . . . .</b>	<b>129</b>
<b>5.3</b>	<b>Considerações acerca dos resultados . . . . .</b>	<b>132</b>
<b>6</b>	<b>CONCLUSÕES . . . . .</b>	<b>135</b>
<b>6.1</b>	<b>Principais Contribuições . . . . .</b>	<b>136</b>
<b>6.2</b>	<b>Trabalhos Futuros . . . . .</b>	<b>137</b>
	<b>Referências . . . . .</b>	<b>139</b>

# 1 Introdução

## 1.1 Cenário e Motivação

Nos últimos anos, o número de pessoas que apresentam alguma deficiência em membros inferiores, devido a diversos motivos como AVC ou lesões na medula espinhal, vem crescendo muito (TSUKAHARA; HASEGAWA; SANKAI, 2009). Essas deficiências podem levar a problemas secundários como, por exemplo, a dependência de cadeira de rodas, osteoporose e escaras. Tais problemas levam à diminuição da qualidade de vida por interferirem diretamente na realização de tarefas cotidianas. Visando recuperar ou melhorar as funções dos membros inferiores, diferentes programas de reabilitação são realizados. Convencionalmente, a reabilitação depende muito da experiência e do apresto manual do terapeuta.

Robôs foram introduzidos na área de reabilitação como uma potencial ferramenta para terapias. Eles podem auxiliar terapeutas a realizarem movimentos repetitivos durante a reabilitação e auxiliar pacientes em tarefas cotidianas como andar ou pegar objetos.

Próteses ou órteses podem ser projetadas adaptando seu controle de acordo com a intenção do paciente. Essa interação pode reduzir o impacto que a adaptação à tecnologia assistiva pode causar ao usuário (IBANEZ et al., 2013). Tais dispositivos podem utilizar dados fisiológicos do paciente para detectar intenções de movimento. A intenção de movimento pode ser detectada antes do deslocamento físico efetivo de um membro, através da análise de EEG e EMG (MRACHACZ-KERSTING et al., 2012; LU et al., 2010; SHIBASAKI; HALLETT, 2006; KIRCHNER; TABIE; SEELAND, 2014).

Sinais eletromiográficos (EMG) podem ser utilizados para controlar atividade de próteses ou órteses. Sinais eletroencefalográficos (EEG), alternativamente, podem ser utilizados como suporte na ação de controle de tais dispositivos em casos em que a atividade muscular está largamente diminuída por lesões periféricas ou espinhais (PFURTSCHELLER et al., 2000). Em pessoas que não apresentem tais problemas, a detecção de intenção de movimento baseada na análise de EEG pode, por exemplo, ser confirmada pela detecção da atividade muscular no sinal de EMG e, então, a identificação do deslocamento efetivo do membro pode corroborar as detecções anteriores.

A predição de movimento pode melhorar a ação de controle dos dispositivos de reabilitação robótica, pois o tempo de resposta desses dispositivos em relação à intenção de seus usuários pode ser reduzido, tornando os movimentos realizados mais naturais e adaptados às tarefas cotidianas. A identificação da intenção de movimento pode ser aperfeiçoada quando há análise de dados combinados, como diferentes dados fisiológicos

ou até mesmo dados que mostrem preferências em atividades cotidianas do paciente em tratamento (NOVAK et al., 2013; HUANG et al., 2011; CORBETT; PERREAULT; KÖRDING, 2012).

A grande vantagem na integração de sinais, por exemplo de EEG e EMG, na estimação de intencionalidade de movimento é a antecedência da previsão do movimento, em função da análise do EEG, e o aumento da confiabilidade do sistema, pois dois sinais fisiológicos são analisados e não somente um (MURALIDHARAN; CHAE; TAYLOR, 2011). A análise combinada de dados forma um sistema multimodal. Sinais de EEG permitem a percepção da intenção voluntária da locomoção, sinais de EMG mostram a ativação muscular, e o deslocamento efetivo pode ser aferido através outros dados, por exemplo, provenientes de sistemas de visão computacional ou sensores inerciais.

Dessa forma, sistemas multimodais podem indicar não somente a intencionalidade do movimento, mas também mostrar sua execução efetiva. Com isso, é possível caracterizar um movimento intencional desde seu planejamento até sua realização (GALLEGO et al., 2012). Assim, há mais robustez e confiabilidade nas ações de controle desempenhadas por dispositivos utilizados em reabilitação robótica.

## 1.2 Objetivos

Este trabalho tem o objetivo geral de desenvolver uma interface multimodal que possa ser utilizada no desenvolvimento de próteses ou órteses cujo propósito é o estudo da reabilitação. A Figura 1 ilustra uma órtese, um exosqueleto ativo com a instrumentação necessária para que seja utilizado em reabilitação. Este é um exemplo de dispositivo em que a interface multimodal proposta neste trabalho pode ser aplicada.

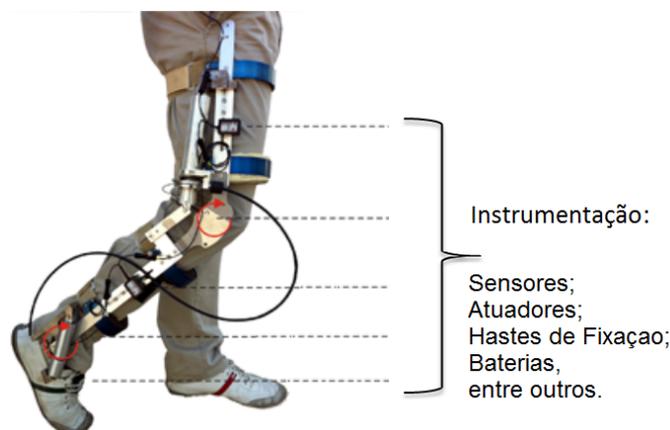


Figura 1 – Exosqueleto ativo utilizado em reabilitação no qual a interface multimodal proposta neste trabalho pode ser aplicada.

A interface proposta faz o sincronismo e a análise de sinais de EEG, EMG e

sinais provenientes de sensores inerciais (IMUs). O objetivo é fazer uma análise *offline* e identificar a intenção de movimento, a ativação muscular e o movimento efetivo de membros inferiores através dos sinais de EEG, EMG e IMU, respectivamente. A Figura 2 ilustra como a interface multimodal proposta atua no contexto do controle de dispositivos robóticos utilizados em reabilitação.

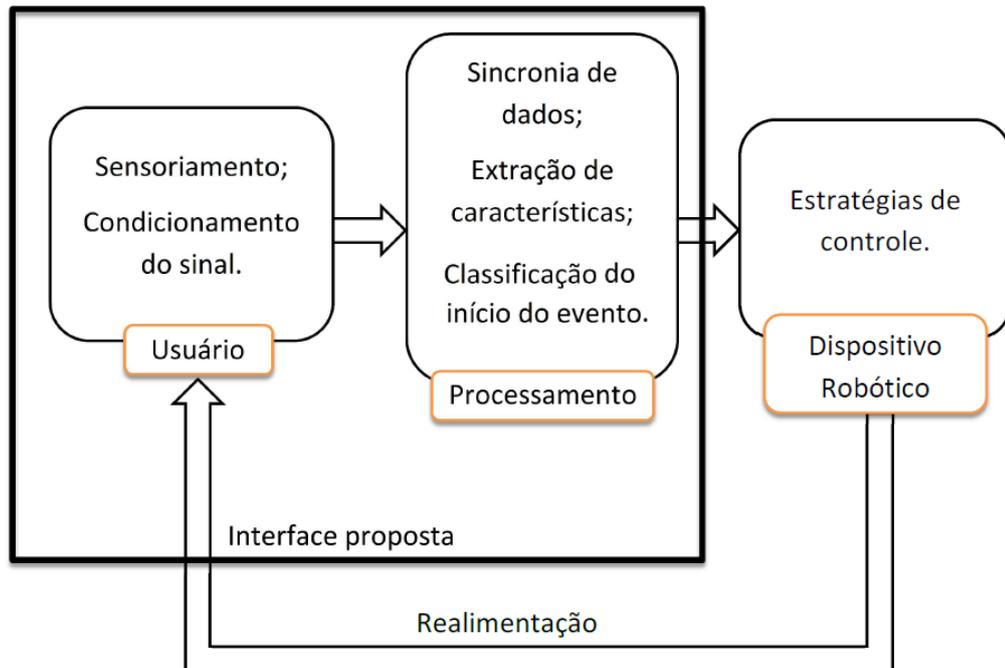


Figura 2 – A interface multimodal proposta no contexto de controle de dispositivos robóticos.

Na Figura 2, é possível observar que o sistema proposto trata da aquisição de dados do usuário e do processamento dos sinais. É possível observar também que a parte de aquisição envolve o sensoriamento e o condicionamento dos sinais, e o processamento envolve a sincronia dos dados, a extração de características para que possa ser realizada a detecção do início da intenção do movimento e assim, classificação dos sinais. Estes podem ser aplicados em estratégias de controle do dispositivo robótico, que não está no escopo deste trabalho. Este sistema como um todo deve ser realimentado em função das variáveis controladas, e.g., força, posição, entre outras.

Como observado na Figura 2, para o desenvolvimento dessa plataforma é preciso fazer a integração de sistemas que façam aquisição dos sinais, de forma que estes estejam sincronizados. Para o processamento dos sinais, pretende-se utilizar técnicas de detecção de intencionalidade de movimento através da análise de uma época de sinais de EEG, isto é, uma análise *single trial*, e técnicas para a detecção do início da atividade muscular durante o movimento de flexão e extensão do joelho. Ainda nessa etapa, propõe-se técnicas para processamento dos sinais das IMUs para que o início efetivo do movimento seja detectado

e para que os ângulos da articulação do joelho sejam medidos durante as tarefas realizadas. Um objetivo específico é fazer uma análise da correção dos métodos utilizados para o processamento e classificação dos sinais nos eventos citados, mostrando a acurácia dos classificadores utilizados e os tempos de antecipação do movimento obtidos.

Este Projeto de Pesquisa também tem como objetivo específico propor um protocolo experimental de testes, que envolve a colocação de sensores, a partir do qual um banco de dados com os sinais adquiridos será criado. Com isso, os resultados obtidos podem ser analisados e comparados com estudos atuais presentes na literatura.

### 1.3 Organização desta Dissertação

No Capítulo 2 desta dissertação, faz-se uma introdução na qual os conceitos gerais sobre os sinais de EEG e EMG são mostrados. Sensores inerciais também são abordados de forma introdutória. Neste capítulo também são mostradas a motivação e as aplicações de sistemas que utilizam combinações de sinais aplicados no controle de dispositivos usados em reabilitação robótica. Dessa forma, são mostrados conceitos sobre os sinais utilizados neste trabalho, bem como o contexto atual dos sistemas multimodais aplicados à robótica de reabilitação a partir de alguns dos principais trabalhos atuais relacionados à área.

Os materiais utilizados nesta pesquisa são apresentados no Capítulo 3. Os equipamentos utilizados para a aquisição dos sinais de EEG, EMG e IMU são descritos, bem como o funcionamento do *software* de aquisição de dados desenvolvido. A forma como foi realizada a sincronia dos dados é abordada. Por fim, o protocolo experimental de testes também é descrito por estar relacionado com a forma como os dados foram adquiridos.

No Capítulo 4, são mostradas as técnicas de processamento de sinais utilizadas. Neste capítulo apresentam-se as técnicas utilizadas para a detecção de intenção de movimento baseada nos sinais de EEG e técnicas utilizadas para a aferição do início da atividade muscular. O processamento dos dados das IMUs, para que o início efetivo do movimento seja detectado e os ângulos da articulação do joelho sejam medidos durante os experimentos, também são mostrados.

Os resultados obtidos pelo sistema proposto são apresentados no Capítulo 5. Uma discussão acerca desses resultados também é realizada.

Finalmente, o Capítulo 6 mostra as conclusões, as contribuições e os trabalhos futuros a serem desenvolvidos neste Projeto de Pesquisa.

## 2 Fundamentos Conceituais

A relação entre robôs e seres humanos pode ir além de uma simples interação física. Essa relação pode envolver sensores, atuadores, processamento de dados e estratégias de controle capazes de coletar e decodificar ações ou expressões humanas ou até fenômenos fisiológicos. Robôs podem usar tais informações para adaptar, aprender e otimizar suas funções, e até mesmo reconhecer um processo cognitivo humano e fornecer uma resposta a partir desta interação (PONS, 2008a).

Um processo cognitivo pode ser definido como uma sequência de tarefas que incluem o raciocínio, o planejamento e a execução de uma ação a partir de um objetivo previamente identificado. Originalmente, esse conceito era restrito a seres vivos, mas atualmente também pode ser aplicado a robôs inteligentes que podem realizar a sequência de tarefas citadas anteriormente (PONS, 2008a). As interfaces cognitivas homem-robô são a ligação entre seres humanos e robôs nas quais as informações relativas a essas etapas são adquiridas, processadas e transmitidas bidirecionalmente. Novas interfaces homem-máquina têm sido desenvolvidas, recentemente, para realizar o fluxo de informações que sistemas inteligentes necessitam para executar suas funções. Cientistas consideram o termo interação cognitiva fundamental, de forma que termos como interface homem-computador (IHC) e interface cérebro-computador (ICC) são encontrados na literatura relacionados a interfaces que envolvam processos cognitivos. A procura por um canal de comunicação entre seres humanos e máquinas, nesse contexto, mais natural e adaptado a tarefas cotidianas é um objetivo constante nas pesquisas, especialmente na área de robôs de serviços (Ratanaswasd, P., Dodd, W., Kawamura, K., Noelle, 2005).

A interação entre robôs e humanos pode se dar em três níveis: um relacionado com o raciocínio ou com a planificação da realização de uma tarefa, outro relacionado com a atividade muscular durante a tarefa e outro relacionado com o deslocamento efetivo, por exemplo, de um membro (PONS, 2008a). O nível de planificação das tarefas pode ser estimado a partir do monitoramento da atividade cerebral, como através da eletroencefalografia. O nível relacionado com a atividade muscular pode ser aferido através da eletromiografia, que pode ser identificada mesmo que não haja movimento efetivo. O nível relacionado com o movimento pode utilizar informações cinemáticas a partir, por exemplo, de sistemas de visão ou sensores inerciais para caracterizar a execução de uma tarefa. Abordagens multimodais, nesse contexto, propõem o uso de dados combinados para reunir informações mais robustas, que possam retratar um comportamento ou ação de forma mais completa e então, melhorar o entendimento desses fenômenos através de fusão de técnicas de processamento desses dados. O objetivo final é, como citado anteriormente, um canal de comunicação ou uma interação mais natural entre homens e robôs.

Este capítulo apresenta uma introdução, tratando conceitualmente, sobre o sinal eletroencefalográfico, abordando sua origem, as principais formas de aquisição desses sinais e os principais potenciais relacionados ao movimento. Neste capítulo também é feita uma introdução sobre eletromiografia em que é mostrada a origem do sinal e formas de aquisição relacionadas a aplicações em robótica de reabilitação. Também é feita uma introdução sobre sensores inerciais, mostrando os principais aspectos relacionados ao funcionamento e algumas de suas aplicações. Por fim, são citadas atuais pesquisas que envolvem plataformas multimodais aplicadas à robótica de reabilitação.

## 2.1 Sinais Eletroencefalográficos

### 2.1.1 Origem do sinal de EEG

O cérebro é a estrutura mais complexa do corpo humano. Consiste de sucessivas camadas de tecido neural que resulta numa estrutura com subestruturas especializadas. Essas subestruturas estão interconectadas com outras, formando um circuito altamente interligado (PONS, 2008a). Como já é sabido, as principais unidades funcionais do tecido neural são os neurônios, ilustrados na Figura 3.

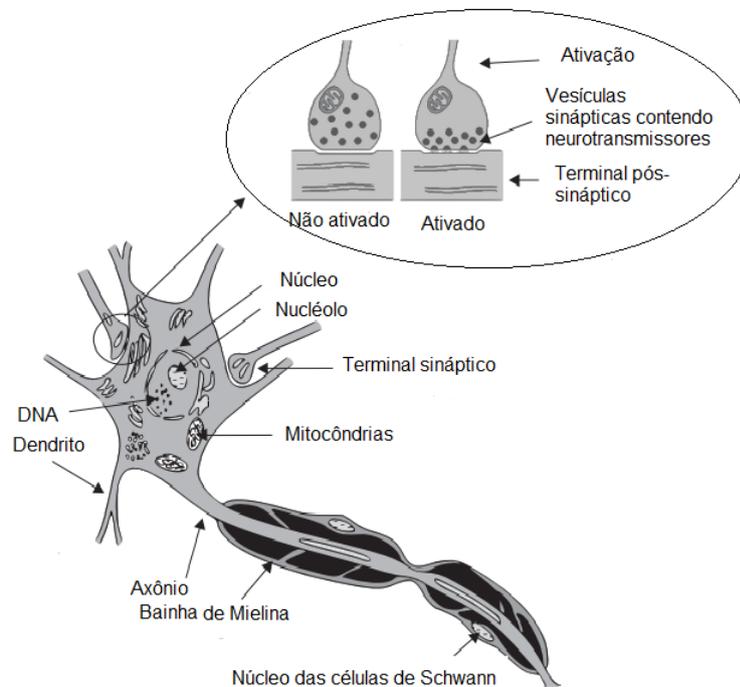


Figura 3 – Um neurônio e suas principais estruturas, mostrando o funcionamento da condução sináptica. Adaptado de Pons (2008a).

Na Figura 3, podem ser observadas as sinapses e outras estruturas, como axônios e dendritos. Em todas as células do corpo humano, o potencial elétrico varia através das

suas membranas. Essa variação deve-se à diferença nas concentrações de íons, causada por atividade interna da célula. Em células excitáveis, como neurônios e células musculares, essa diferença deve-se à excitabilidade da membrana celular. A membrana do neurônio pode receber estímulo excitatório através de estruturas especiais chamadas dendritos. A função do neurônio é integrar os estímulos nos diferentes dendritos e alterar a polarização do axônio de acordo com estes estímulos integrados. Estímulos entre os neurônios são excitados através de uma estrutura chamada sinapse. As sinapses são pequenos espaços entre axônios e dendritos. Quando um estímulo ocorre, uma substância chamada de neurotransmissor é segregada na sinapse pelo axônio que é percebida pelo dendrito como um estímulo. A intensidade do estímulo depende da quantidade de neurotransmissor presente na sinapse (Malmivuo, J., Plonsey, 1995).

A transmissão de informação entre neurônios envolvendo neurotransmissores perfaz um fenômeno químico que está acompanhado de um fenômeno elétrico: uma troca de íons, evento elétrico que propaga um sinal elétrico dentro de um neurônio, o potencial de ação. O potencial de ação é o impulso nervoso transmitido pelo neurônio através do axônio. Este potencial só consegue se propagar pelo axônio se a membrana celular, que está com o potencial de repouso, for excitada por um valor acima de um limiar específico.

A natureza do neurotransmissor liberado determinará o efeito que causa no elemento pós-sináptico, podendo ser excitatório ou inibidor. A sinapse excitatória ocasiona uma diminuição na negatividade da membrana e um potencial pós-sináptico excitatório (PPSE). Isso acontece quando o efeito líquido da liberação do transmissor é para despolarizar a membrana, levando-a a um valor mais próximo do limiar elétrico para disparar um potencial de ação. Esse efeito ocorre porque o neurotransmissor controla a abertura dos canais da membrana, alterando sua permeabilidade a íons de sódio. A entrada dos íons  $Na^+$  despolariza a membrana pós-sináptica (BENEVIDES, 2009).

A sinapse inibitória ocasiona um aumento na negatividade da membrana e um potencial pós-sináptico inibitório (PPSI). Isso ocorre porque o efeito líquido da liberação do transmissor é para hiperpolarizar a membrana, tornando mais difícil alcançar o potencial de limiar elétrico. Esse efeito ocorre quando o neurotransmissor abre os canais de cloreto,  $Cl^-$ , ou potássio,  $K^+$ , tornando a célula mais negativa (Guyton, A. C. e Hall, 2006).

Uma célula nervosa normalmente tem centenas ou milhares de sinapses químicas excitatórias e inibitórias que chegam a seus dendritos ou corpo celular. Se o resultante de todos os estímulos for um impulso que seja capaz de despolarizar a membrana até o potencial limiar, o potencial de ação resultante será transmitido pelo axônio do neurônio. A propagação desses impulsos no tecido gera um potencial elétrico que pode ser medido utilizando eletrodos.

Os neurônios do córtex estão distribuídos em seis camadas paralelas à superfície e podem ser de dois tipos: piramidais e não piramidais. As células não piramidais possuem

simetria esférica, não tendo um sentido definido de propagação do sinal elétrico. Por consequência dessa simetria, o campo eletromagnético produzido tem resultante nula. Já no caso das células piramidais, devido à distribuição linear de seus axônios, é possível identificar um campo eletromagnético resultante segundo uma distribuição bipolar (LOPES, 2005; Araújo D. B., 2006). Dessa forma, os sinais eletroencefalográficos registram principalmente as correntes extracelulares que surgem como consequência da atividade sináptica nos dendritos de neurônios piramidais do córtex cerebral.

Os campos elétricos extracelulares gerados pelos neurônios são atenuados e espalhados ao atravessarem o crânio em direção ao escalpo, devido a baixa condutividade elétrica do crânio. A distribuição superficial dos campos elétricos é ainda distorcida pela variação de condutividade e espessura do crânio de local para local. Dessa forma, o campo elétrico medido no eletrodo depende dos valores de condutividade dos tecidos de revestimento do cérebro, e.g., meninges, crânio e pele (M., 2003), como ilustrado na Figura 4.

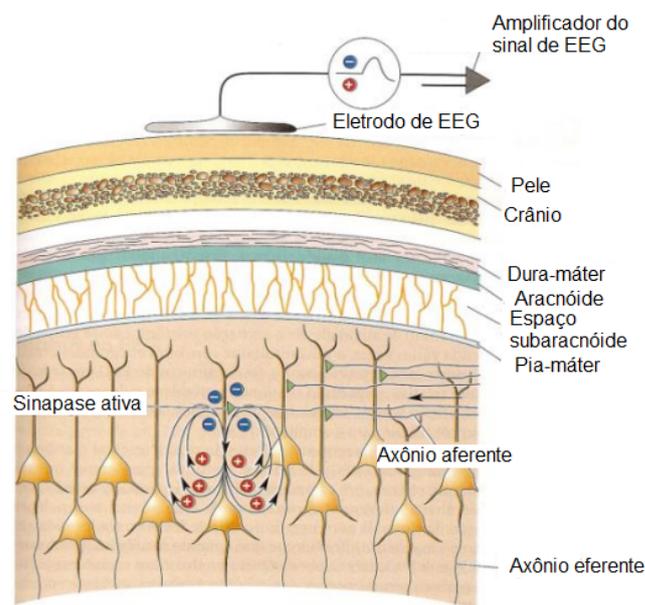


Figura 4 – Atenuação do campo elétrico gerado por correntes sinápticas extracelulares de células piramidais. Adaptado de Bear, M. F; Connors, B. W. e Paradiso (2008).

Assim, para que essa atividade seja detectável através de eletrodos no escalpo são necessários milhões de neurônios trabalhando em sincronia. Essa população de neurônios recebe o nome de massa neural e consiste de  $10^4$  a  $10^7$  neurônios (P., 2005). O sincronismo consiste na ativação em conjunto de uma massa neural, assim, o somatório resultante dos milhares de sinais sincronizados, são interferências construtivas e alcançam em média  $50\mu\text{V}$  (GRAIMANN, 2002).

O córtex cerebral pode ser dividido de acordo com a função ou localização. Em termos da localização, os lobos frontal, temporal, parietal e occipital podem ser identificados.

Em termos da função, os córtex visual, auditivo e sensorimotor podem ser apontados (PONS, 2008a). A Figura 5 ilustra tais divisões.

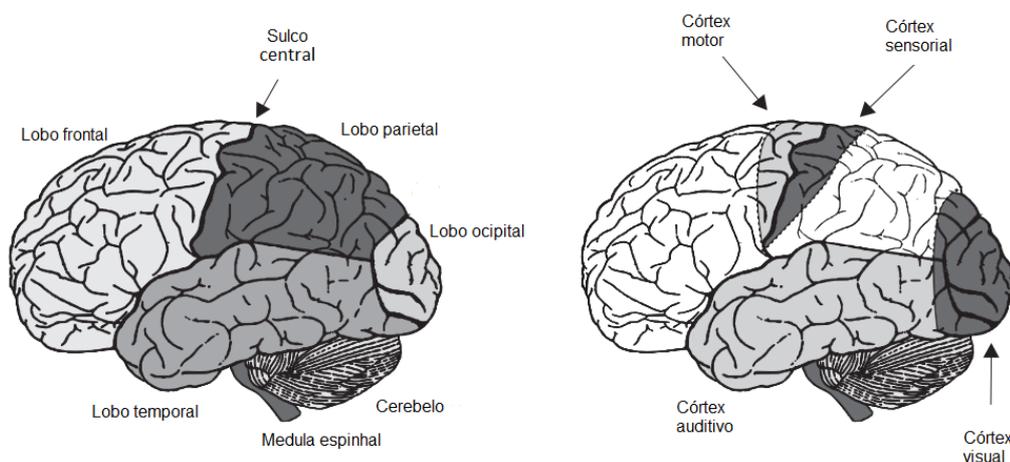


Figura 5 – Divisão do cérebro. Os principais lobos do cérebro são divididos de acordo com a localização de cada área. Cada lobo cerebral tem uma função especializada relacionada com a principal informação recebida a partir do corpo. O sulco central é a fronteira entre os lobos frontal e parietal. O lobo occipital é especializado no processamento de informação visual, o lobo temporal está relacionado principalmente com estímulos auditivos e o lobo parietal integra os diferentes estímulos. Na vizinhança do sulco central estão os córtex sensorial e motor. Adaptado de Pons (2008a).

Mudanças na atividade dessas áreas estão estreitamente relacionadas com as suas funções específicas, mas devido ao volume de condução, a atividade de uma área pode ser transmitida através de outras áreas. A atividade do cérebro, definida pela polarização ou despolarização de grupos de neurônios da massa cerebral, pode se cancelar ou se somar, formando potenciais elétricos que podem ser observados no escalpo.

Neste trabalho são analisados sinais eletroencefalográficos envolvidos em tarefas motoras, portanto, esta área será abordada com maiores detalhes.

Como pode ser observado na Figura 5, à direita, o córtex motor está localizado anteriormente ao sulco central (ou sulco cortical central), ocupando aproximadamente um terço do lobo frontal. Este alimenta o córtex motor com muitos dos sinais que iniciam as atividades motoras e está localizado posteriormente ao sulco central. A tarefa mental de intenção motora é realizada no córtex motor que é subdividido em três áreas: córtex motor primário, área pré-motora e área motora suplementar (Guyton, A. C. e Hall, 2006), como ilustrado na Figura 6.

O córtex motor primário é diretamente responsável pela coordenação dos movimentos voluntários. A Figura 6 à direita, mostra um mapeamento cerebral, relacionando as

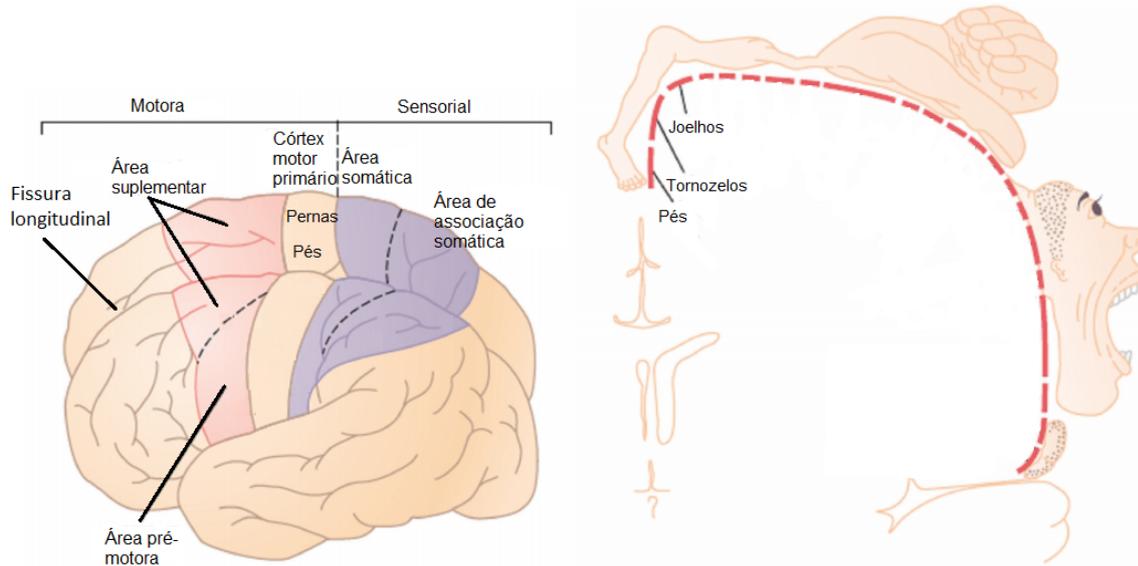


Figura 6 – Esquerda: Localização cerebral das áreas funcionais relacionadas às ações motoras; Direita: Localização das áreas responsáveis pela coordenação dos principais membros do corpo. Adaptado de [Guyton, A. C. e Hall \(2006\)](#).

áreas do córtex motor com o movimento de vários membros. Nesta figura estão destacadas as pernas pois, os movimentos realizados descritos na Seção 3.4 envolvem tarefas motoras de membros inferiores.

A área pré-motora, localizada no hemisfério esquerdo, tem por função dar suporte aos movimentos gerados no córtex motor primário de ambos os hemisférios. Significa que para realizar um movimento desejado para a mão também é necessário mover braço e ombro. Para conseguir tal resultado a área pré-motora, ou córtex pré-motor, realiza uma “imagem motora” do movimento muscular a ser realizado. Os sinais associados a esse movimento são enviados diretamente ao córtex motor primário para excitar múltiplos grupos de músculos relacionados à realização da tarefa ou frequentemente via o gânglio basal<sup>1</sup> e o tálamo<sup>2</sup> para o córtex motor primário ([Guyton, A. C. e Hall, 2006](#)).

A área motora suplementar, em geral, funciona em conjunto com a área pré-motora para prover movimentos de postura de diferentes segmentos do corpo, movimentos de posição da cabeça e dos olhos, como pano de fundo para o melhor controle motor dos

<sup>1</sup> Os gânglios basais constituem um acessório do sistema motor, que não funciona por si mesmo, mas em associação com o córtex cerebral e o sistema motor corticoespinal, interligado através do tálamo. O gânglio basal recebe a maior parte de seus sinais de entrada do córtex cerebral e retorna quase todos seus sinais de saída para o córtex cerebral. Para maiores informações acerca deste assunto, consulte [Guyton, A. C. e Hall \(2006\)](#)

<sup>2</sup> O tálamo interliga diferentes áreas e camadas corticais, formando circuitos realimentados ou redes neuronais, que apresentam diferentes estados de sincronia, com oscilações em diferentes frequências. As diferentes faixas de frequências do padrão oscilatório do sinal de EEG estão relacionadas à ativação ou desativação de diferentes circuitos neuronais tálamo-corticais. Para maiores informações acerca deste assunto, consulte [Guyton, A. C. e Hall \(2006\)](#)

braços e mãos pela área pré-motora e pelo córtex motor primário (Guyton, A. C. e Hall, 2006).

Analisando-se a Figura 6, percebe-se que a porção de massa neuronal diretamente relacionada com atividades motoras das pernas ou pés é muito menor que a relacionada com a atividade das mãos, por exemplo. A Figura 7 ilustra de forma mais intuitiva essa comparação. Nela, o tamanho dos membros é proporcional ao tamanho da área cerebral relacionada. Neste ponto, observa-se então, uma maior dificuldade de obtenção de sinais eletroencefalográficos relacionados com membros inferiores que os relacionados com membros superiores.



Figura 7 – Representação da porção das áreas motoras do cérebro relacionando com o membros do corpo. Adaptado de Guyton, A. C. e Hall (2006).

A atividade oscilatória medida no sinal de EEG é uma propriedade emergente do sistema tálamo-cortical<sup>3</sup>. Durante a realização de uma tarefa mental de imaginação motora ou ainda durante a intenção de movimento ou mesmo durante o movimento, o córtex motor primário e as áreas adjacentes como a área motora suplementar e a área pré-motora são ativadas utilizando circuitos neuronais para se intercomunicar. Esses circuitos fazem

<sup>3</sup> Os neurônios que interligam o sistema nervoso e as diferentes camadas do cérebro formam circuitos ou sistemas neuronais. Os circuitos neuronais oscilatórios são os mais importantes circuitos neuronais do sistema nervoso. Os circuitos são formados por realimentação positiva dentro do mesmo circuito neuronal. Consequentemente, uma vez estimulado, o circuito pode produzir estímulos periódicos por longos períodos. Sistema tálamo-cortical refere-se ao circuito entre o tálamo e o córtex. Para maiores informações acerca deste assunto, consulte Benevides (2009).

parte do sistema tálamo-cortical. A atividade oscilatória resultante dos circuitos neuronais pode ser medida sobre o escalpo através de uma análise de frequência, uma vez que a realização de uma tarefa mental aciona circuitos neuronais do córtex com frequências de oscilação numa determinada banda (Guyton, A. C. e Hall, 2006).

As diferentes frequências das bandas que compõem as componentes espectrais do espectro de amplitude do sinal de EEG podem ser agrupadas em bandas que apresentam as mesmas características e são geradas na mesma área cerebral. Cada banda é observada em um local e circunstância específica. São estas principais descritas por  $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$  e  $\mu$ . Cada tipo de oscilação é gerada por um determinado conjunto de correntes neuronais. As características mais importantes do EEG estão compreendidas nas de frequências que se estendem até 30 Hz, e essa faixa de frequências é subdividida em grupos ou ritmos, como descrito. Os dois últimos são relacionados à atividades motoras e, portanto, de interesse neste trabalho (PFURTSCHELLER, 1999).

O ritmo  $\beta$ , atividade de maior frequência (14 - 30 Hz) com menor amplitude, está relacionado geralmente pela abertura dos olhos, estando em estado de vigília e é bloqueado por atividade motora e estimulação tátil.

O ritmo  $\mu$  (8 - 12 Hz) é um ritmo associado às atividades motoras e melhor adquirido sobre o córtex motor. O ritmo  $\mu$  diminui com o movimento ou a intenção de se mover. Apesar da frequência e a amplitude do ritmo  $\mu$  serem similar as do ritmo  $\alpha$ , o ritmo  $\mu$  é topograficamente e fisiologicamente diferente daquele, que é gravado sobre a área occipital do córtex (P., 2005; CHEEÍN, 2005; M., 2003)

O Potencial Relacionado ao Evento (do inglês, *Event-Related Potential - ERP*) é a mudança do potencial eletroencefalográfico em resposta a um evento em particular. O ERP possui amplitude muito menor do que a atividade espontânea do EEG, de forma que não pode ser reconhecido no sinal de EEG cru, mas a relação sinal-ruído do EEG pode ser melhorada utilizando-se a média de várias gravações de EEG repetidas com as mesmas circunstâncias (RUGG, M.D. e COLES, 1996). O ERP também pode ser detectado como resposta a uma intenção. Nesse conjunto estão os Potenciais Relacionados aos Movimentos (do inglês, *Movement-Related Potential - MRP*), que são potenciais da ordem de  $1\mu\text{V}$ , gerados como resposta a uma intenção mental de realizar o movimento de um membro, sendo medido na área do cérebro relacionada a essa função, o córtex motor (P., 2005). Alguns ERPs específicos, como o MRP, somente são detectados por análise de frequência. Esses ERPs representam, em termos gerais, o decremento ou incremento de energia de determinadas bandas de frequência. O decremento de energia de uma determinada banda de frequência é chamado Dessincronização Relacionada ao Evento (do inglês *event-related desynchronization - ERD*) enquanto o caso oposto é chamado Sincronização Relacionada ao Evento (do inglês *event-related synchronization - ERS*) (PFURTSCHELLER, 1999).

Essas características foram utilizadas neste trabalho para a detecção de intenção

de movimento, como descrito na Seção 4.3, e serão abordadas com mais detalhes a seguir.

Normalmente, quando uma população neuronal está inativa, os circuitos neuronais oscilatórios dessa população produzem sinais sincronizados, assim, a resultante da soma desses sinais possui grande amplitude. Quando uma massa neural é ativada por um estímulo ou uma intenção, os circuitos neuronais oscilatórios dessa massa neural perdem a sincronia e a resultante da soma desses sinais possui amplitude menor gerando um ERD. De forma contrária, um aumento da sincronia e uma resultante com amplitude maior gera um ERS, este observado geralmente após a realização do movimento mais acentuadamente na banda  $\beta$  (P., 2005; CHEEÍN, 2005).

A realização de tarefas mentais motoras, como imaginação de movimento, intenção de movimento ou movimento ocasionam uma atenuação no ritmo  $\mu$ , que ocorre na área do córtex motor. Dessa forma, os eletrodos posicionados sobre essa área podem medir um decremento de energia (ERD) no sinal de EEG. Esse decremento pode começar até 2 segundos antes do movimento efetivo começar e durar até o final do movimento (PFURTSCHELLER, 1999). Mesmo pessoas com amputações de membros apresentam ERD durante a imaginação de movimento do membro fantasma (BENEVIDES, 2009). O ERD é contralateral, isto é, ocorre no hemisfério cerebral oposto ao movimento, da mesma forma, o MRP também é contralateral. Isso ocorre pois, as fibras do trato corticoespinal<sup>4</sup> se cruzam e a motricidade voluntária é 100% cruzada.

O método clássico para a observação do ERS/ERD foi descrito por Pfurtscheller (1999) em que, dado um conjunto com várias gravações (épocas) de EEG contendo o ERD/ERS, os sinais são filtrados na faixa de frequência desejada. Então, as amostras dos sinais são elevados ao quadrado obtendo as amostras de potência. Calcula-se a média de todas as épocas e a curva resultante é suavizada através do cálculo da média dos pontos num pequeno intervalo de tempo. Para obter os valores percentuais do ERD/ERS, calcula-se energia da banda de frequência de interesse do período depois do evento  $A$  e a energia média de um período de referência anterior ao evento  $R$ . O ERD e ERS são definidos como os valores percentuais de decremento ou incremento, respectivamente, de acordo com a Equação 2.1 (PFURTSCHELLER, 1999).

$$ERD(\%) = \frac{A - R}{R} \cdot 100 \quad (2.1)$$

A Figura 8 ilustra o procedimento descrito. É possível observar um decréscimo da amplitude do sinal na banda (ERD) antes do movimento acontecer (*on trigger*). Essa

<sup>4</sup> O trato corticoespinal é composto principalmente de axônios motores, constituindo o componente voluntário da motricidade. As vias piramidais consistem em um único trato, originado no encéfalo. O comportamento das vias piramidais leva à conclusão de que a motricidade voluntária é 100% cruzada, seja a nível bulbar, seja a nível medular. Para maiores informações acerca deste assunto, consulte Guyton, A. C. e Hall (2006)

característica será a principal avaliada neste trabalho para a detecção de intencionalidade de movimento.

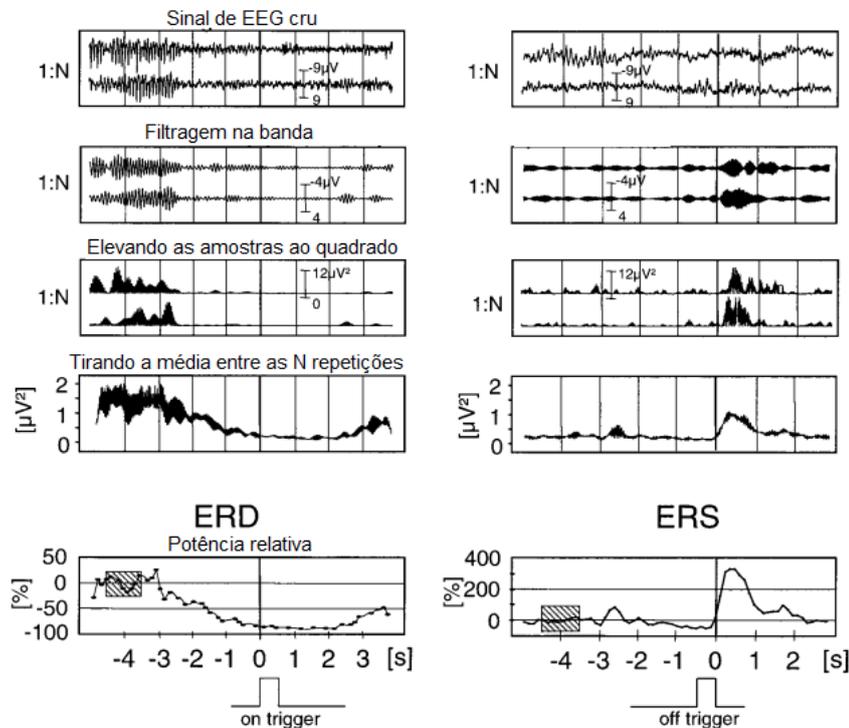


Figura 8 – Procedimento para visualização e as etapas do ERD (à esquerda) e do ERS (à direita). Adaptado de [Pfurtscheller \(1999\)](#).

Esse procedimento foi utilizado neste projeto, como descrito na Seção 4.3.1 para a detecção de intenção de movimento com uma abordagem que utiliza várias épocas do sinal de EEG.

A utilização de várias épocas do sinal de EEG para a visualização dessas características se dá pois, o córtex motor no lobo parietal está cercado pelos lobos frontal, temporal e occipital. Assim, os sinais gerados pelas áreas vizinhas se misturam aos sinais do córtex motor e o sinal medido pelos eletrodos sobre este córtex contém uma mistura de sinais provenientes de diferentes áreas cerebrais. Dessa forma, o padrão ERD/ERS gerado no córtex motor durante uma intenção de movimento não pode ser observado por uma única medição por isso é necessário o cálculo da média de várias épocas para se visualizar o ERD/ERS ([PFURTSCHELLER, 1999](#)).

O procedimento descrito acima não pode ser implementado num classificador em tempo real, pois neste caso seria necessário encontrar o ERD/ERS em apenas uma *trial*, repetição ou também chamada de época do sinal de EEG. Na Seção 4.3.2 é descrita uma técnica para a visualização do ERD em uma época do sinal. Dessa forma, essa característica pode ser utilizada em interfaces cérebro computador e integradas ao controle de dispositivos

robóticos que tenham por objetivo a antecipação de um movimento, identificando a intenção de fazê-lo.

### 2.1.2 Aquisição do sinal de EEG

Como já definido, a eletroencefalografia é o registro da atividade elétrica do cérebro medida sobre a superfície do escalpo através de eletrodos. O método mais usual é o não invasivo, porém a atividade neuronal pode ser obtida através introdução de eletrodos no interior do tecido cerebral (registro de profundidade) ou colocando eletrodos na superfície exposta do cérebro, esta chamada de eletrocorticografia (ECoG) (GEISINGER, 2005). Este trabalho realizou a aquisição de sinais cerebrais apenas pelo método não invasivo, registrando a eletroencefalografia, atividade medida sobre a superfície do escalpo.

A aquisição do sinal de EEG é relativamente simples: uma quantidade específica de eletrodos, dependente da aplicação, são fixados em posições padrão no escalpo e conectados aos canais amplificadores dos sistemas de gravação de EEG. Pequenas flutuações na tensão elétrica, da ordem de  $\mu$ Volts, são medidas entre pares de eletrodos selecionados e então são amplificadas, geralmente entre 5 e 30 mil vezes (Davidson, R. J; Jackson, D. C and Larson, 2000). A Figura 9 ilustra uma aquisição típica de EEG: sinais irregulares no tempo, indicando mudanças de tensão entre pares de eletrodos devidamente aterrados. Cada sinal de saída do amplificador é mostrado e/ou processado ou salvo numa memória para processamento posterior.

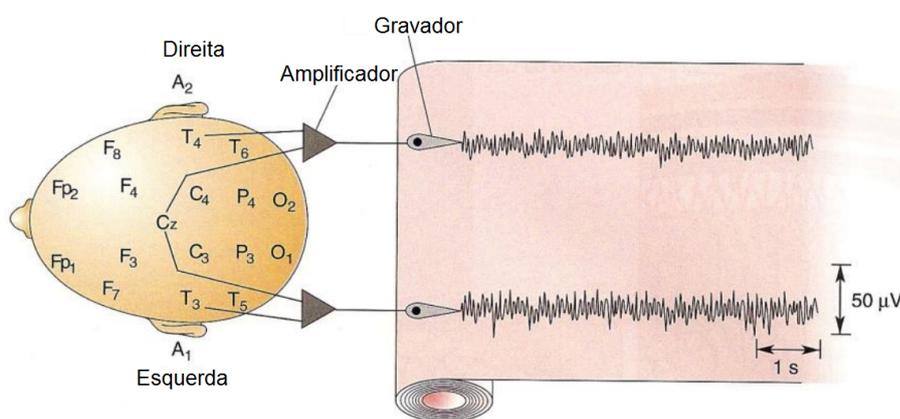


Figura 9 – Gravação típica de EEG. Adaptado de Bear, M. F; Connors, B. W. e Paradiso (2008)

Eletrodos de prata, envoltos em cloreto de prata (Ag/AgCl) eram utilizados desde a década de 1980, já que a prata é um dos metais que melhor conduz corrente elétrica. Recentemente, gorros comerciais com eletrodos de estanho, um bom condutor e inerte ao oxigênio e à corrosão, têm sido amplamente utilizados. Neste trabalho, este último foi utilizado, como descrito no Capítulo 3.



Se o potencial elétrico no escalpo for medido com apenas um eletrodo relativo ao terra de aquisição do circuito, o sinal obtido seria apenas devido à diferença de eletricidade estática entre o escalpo e o terra do circuito. Isso ocorre pois a atividade neural é de muito menor amplitude. Usando dois eletrodos no escalpo e tomando-se a diferença entre eles para criar um canal de EEG,  $C$ , qualquer ruído que afete o terra ou a fonte do sistema de aquisição iria mascarar o sinal de atividade neural. Para resolver tal problema, os sistemas de amplificação utilizam amplificadores diferenciais com três eletrodos para um canal: um eletrodo chamado de "ativo"<sup>5</sup>, eletrodo  $A$ , um eletrodo de referência  $R$  e um eletrodo terra  $G$ . A Figura 11 (A) ilustra esse procedimento. O amplificador diferencial amplifica a diferença entre  $V_{AG}$  e  $V_{RG}$ ,  $C = V_{AG} - V_{RG}$  e assim o ruído comum que afeta o terra de ambas medidas é eliminado (LUCK, 2005).

O eletrodo de terra é normalmente posicionado no osso da fronte para minimizar o ruído com origem muscular, e seu potencial é cancelado durante a amplificação diferencial. Sua localização não é tão importante como a localização do eletrodo de referência. Não há lugar idealmente neutro para posicionar o eletrodo de referência, de modo que deve ser levado em consideração que o sinal de EEG de um canal reflete sempre a contribuição de ambos os eletrodos ativos e de referência. O eletrodo de referência é normalmente colocado num lóbulo da orelha ou de ambas.

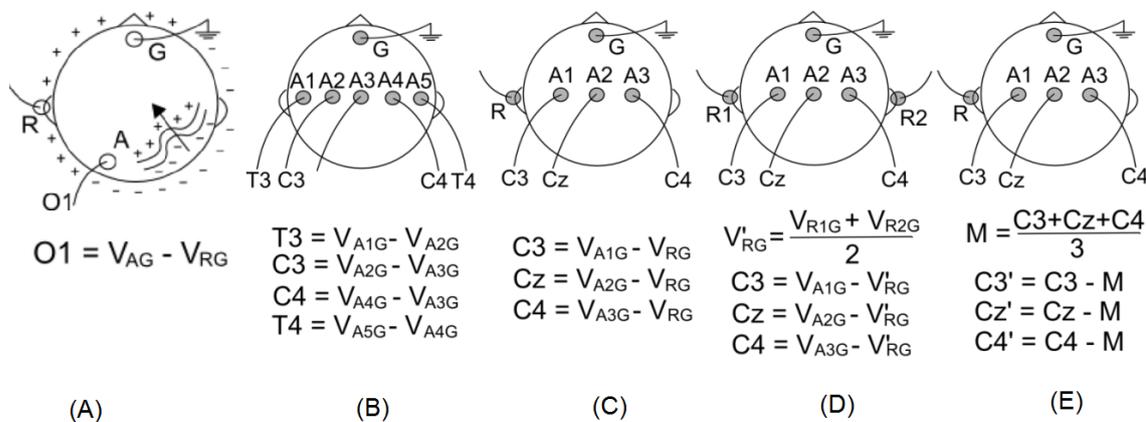


Figura 11 – Modos distintos para a criação de canais para medição do sinal de EEG. (A) Eletrodos referência, R, terra, G, e ativo, A, para formar o canal O1; (B) Modo Bipolar; (C) Modo Unipolar (referência uni-auricular); (D) Modo Unipolar (referência biauricular); (E) Modo CAR usando referência uni-auricular. Adaptado de BENEVIDES (2013)

Na Figura 11 (A), podem ser observados o eletrodo terra  $G$ , o eletrodo de referência  $R$  e o eletrodo ativo  $A$ , posicionado na área de interesse para medição do EEG, o canal  $O1$

<sup>5</sup> Este eletrodo é chamado de "ativo" para distinguir-se do terra e do eletrodos de referência, mesmo medindo passivamente o potencial do couro cabeludo. Não deve ser confundido com eletrodos ativos que realizam a amplificação de sinal dentro de si.

é criado a partir de tais eletrodos. A mesma figura também mostra o dipolo resultante de uma área ativa do córtex e sua distribuição de potencial elétrica sobre o escalpo. Neste exemplo  $V_{AG}$  é inferior a  $V_{RG}$  e o potencial calculado para  $O1$  será negativo.

Há três modos distintos para a criação de canais para medição do sinal de EEG: modo ou método bipolar, unipolar ou de referência comum e método de referência média comum, *CAR*, do inglês *Common Average Reference*. A Figura 11 (B) ilustra o método bipolar, em que cada canal (T3, C3, C4 e T4) é a diferença de potencial entre os dois eletrodos vizinhos (A1, A2, A3, A4 ou A5). Pode-se notar que neste método não há eletrodo de referência fixo e o número de canais é sempre menor do que o número de eletrodos. A Figura 11 (C) mostra o método unipolar, que tem um eletrodo de referência (R) comum a todos os canais. A tensão medida é a diferença entre um eletrodo e a referência. A Figura 11 (D) mostra o método unipolar com referência biauricular, os eletrodos (R1 e R2), em que a tensão medida é a diferença entre qualquer eletrodo e os valores médios dos eletrodos de referência. O método *CAR* é mostrado na Figura 11 (E), nele o sinal é inicialmente adquirido através do método unipolar ( Figura 11 (C), canais C3, Cz C4) e, em seguida, os canais C3', Cz' e C4' são formadas subtraindo os potenciais unipolares pelo potencial médio de referência (M). Este último processo será tratado com mais detalhes na Seção 4.3.2, pois foi utilizado neste projeto como um processamento após a aquisição dos dados. Deve-se lembrar que o eletrodo de aterramento (terra) está presente em todos os três tipos de derivação.

As características dos sinais de EEG variam aleatoriamente com o tempo e formam um vetor de variáveis aleatórias,  $\bar{x}(t)$ , cuja natureza da aleatoriedade é dependente do tempo. Portanto, o sinal de EEG é um processo estocástico (BLANCO, 1995).

Para se utilizar os métodos de classificação Bayesianos, como realizado neste trabalho e descrito na Seção 4.3.2, é necessário assumir que o sinal de EEG seja estacionário. O sinal de EEG pode ser considerado um processo estocástico estacionário em curtos períodos de tempo. São encontrados trabalhos que demonstram que o EEG pode ser considerado estacionário no sentido amplo desde alguns segundos até minutos (BLANCO, 1995). Portanto, realizando a medição do EEG em janelas de alguns segundos, de acordo com os estudos realizados por Popivanov, D. e Mineva (1999), Pardy, J., Roberts, S. e Tarassenko (1996), pode-se aproximar o EEG como um processo estocástico estacionário no sentido amplo<sup>6</sup>.

Sinais de EEG têm sido estudados no contexto do uso como sinais de controle

<sup>6</sup> Um sinal é considerado estacionário no sentido estrito se sua distribuição estatística independe do instante de tempo em que é observada. Para que um sinal seja considerado estacionário no sentido amplo a função média deve ser constante para todo o tempo e a função de autocorrelação, ou equivalentemente, a autocovariância deve ser independente de deslocamentos no tempo. Se um processo estocástico gaussiano é estacionário no sentido amplo também será estacionário no sentido estrito (GARCIA, 1994). Para maiores informações acerca deste assunto, consulte Garcia (1994), BLANCO (1995), Pardy, J., Roberts, S. e Tarassenko (1996), Popivanov, D. e Mineva (1999)

em técnicas de ajuda para pessoas com deficiência. A razão é que, em alguns casos de acidente vascular cerebral, lesões da medula espinhal ou doenças degenerativas tais como a Esclerose Lateral Amiotrófica, o paciente não tem qualquer controle de seu sistema muscular ou só pode controlar um pequeno grupo muscular. Em tais casos, o paciente não pode comunicar-se, mesmo com o cérebro intacto e totalmente funcional. Com o auxílio de uma interface que possa reconhecer sinais cerebrais, o paciente pode se expressar através de um computador ou até mesmo recuperar alguma independência, se a interface é utilizada para controlar um ambiente inteligente, uma prótese ou órtese. Esta última é o objetivo de aplicação da interface multimodal proposta neste trabalho.

A próxima seção tratará da origem e da aquisição dos sinais eletromiográficos de superfície, também utilizados no sistema multimodal apresentado neste trabalho. A partir desta seção e da próxima, será possível entender como um sinal fisiológico gerado no cérebro chega até o músculo para resultar em movimentos.

## 2.2 Sinais Eletromiográficos

### 2.2.1 Origem do sinal de EMG

O entendimento da origem do sinal de EMG requer a compreensão da morfologia e do funcionamento dos músculos esqueléticos e a maneira como eles geram o potencial elétrico, que é observado em gravações de eletromiografia. Os músculos esqueléticos se inserem sobre os ossos e sobre as cartilagens e contribuem, com a pele e o esqueleto, para formar o invólucro exterior do corpo. Esses músculos aplicam força às articulações e aos ossos através da contração muscular. A contração muscular pode ser voluntária, produzindo movimentos propositalis, ou involuntária, criando movimentos como os observados em tremores patológicos.

Um músculo esquelético é composto por centenas de fibras com diâmetros variando entre 10 e 80  $\mu\text{m}$  em que cada fibra constitui uma célula única, multinucleada, longa e cilíndrica, composta por sua vez, por unidades menores que são responsáveis pelos mecanismos moleculares de contração e propagação dos potenciais elétricos (W, 1996), como ilustrado na Figura 12. É possível observar uma estrutura entre as linhas  $Z$  adjacentes chamada sarcômero, que constitui uma unidade de contração por deslizamento dos filamentos. Estes se encurtam e se sobrepõem na banda  $A$ , constituindo uma contração.

Sob condições normais, a contração muscular é ativada pelo córtex motor cerebral. Os sinais de controle passam do sistema nervoso central (SNC) para o sistema nervoso periférico (SNP), finalmente atingindo o tecido muscular. Esses sinais são chamados Potenciais de Ação ( $AP$  - do inglês *Action Potential*) e quando atingem as fibras musculares causam a contração do músculo.

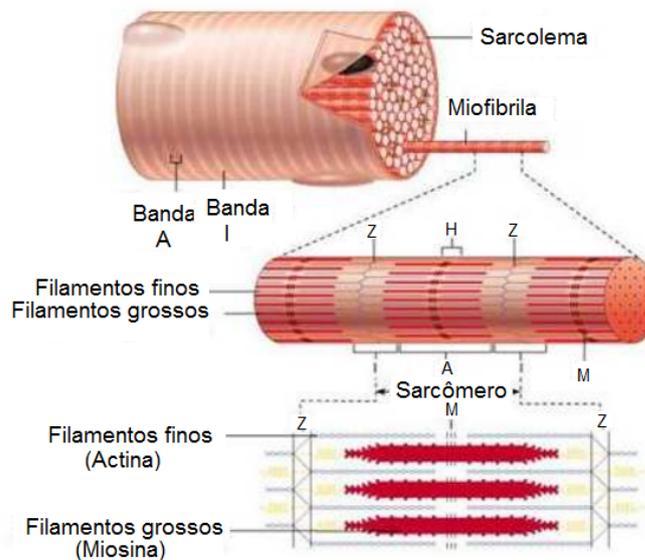


Figura 12 – Representação da fibra muscular e suas partes. Adaptado de W (1996).

Um neurônio motor, ou o  $\alpha$ -motoneurônio<sup>7</sup>, é a estrutura responsável por transmitir os APs da medula espinhal ao músculo. O neurônio motor, através de seu axônio, pode inervar várias fibras musculares que são ativadas em sincronia quando ele é excitado (PONS, 2008a). As fibras correspondentes aos neurônios motores são localizadas próximas umas às outras, como ilustrado na Figura 13.

O número de fibras inervadas por um único neurônio motor pode variar e é um fator ligado à precisão do movimento. Uma Unidade Motora (*MU* - do inglês *Motor Unit*) é a combinação de um neurônio motor e todas as fibras musculares que ele inerva. Pequenas unidades motoras são responsáveis por movimentos mais precisos, como o movimento dos olhos, por exemplo, enquanto grandes unidades motoras, com centenas de fibras inervadas, são encontradas nas extremidades de músculos maiores, como os localizado nos membros. A combinação dos APs de todas as fibras musculares inervadas por um neurônio motor é chamado potencial de ação da unidade motora (*MUAP* - do inglês *Motor Unit Action Potential*).

Basicamente, a execução de um movimento consiste em uma sequência de ativação de várias MUs que inervam diferentes músculos. A execução final do movimento depende de

<sup>7</sup> O  $\alpha$ -motoneurônio é um tipo de neurônio Motor Anterior. Estes estão localizados em cada segmento na porção anterior da substância cinzenta, estes dão origem às fibras nervosas que abandonam a medula por meio das raízes anteriores e inervam as fibras musculares esqueléticas. Dele originam grandes fibras nervosas do tipo A alfa, a estimulação de uma só fibra nervosa excita de três até várias centenas de fibras musculares esqueléticas, que são coletivamente chamadas de unidade motora. Ramo Alfa 1 – entrará em contato com as fibras intrafusais do músculo agonista contraindo-o, sinapse excitatória. Ramo Alfa 2 - recebe uma sinapse inibitória da célula de Renshaw, inibe o antagonista. Realiza força. Para maiores informações acerca deste assunto, consulte Guyton, A. C. e Hall (2006)

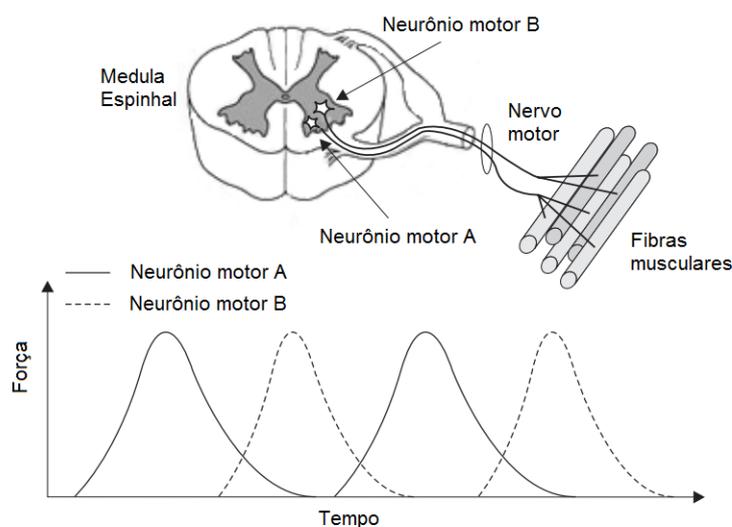


Figura 13 – Caminho do potencial de ação. A soma de MUAPs síncronas pode produzir contração contínua e força. Adaptado de Pons (2008a)

muitos parâmetros relacionados às MUs, como por exemplo, força, velocidade de contração, velocidade de condução axonal, resistência à fadiga, padrões de disparo, entre outros (PONS, 2008a).

Durante uma contração muscular, grupos de MUs são ativados. Diferentes padrões de ativação são usados para excitar cada MU. O mecanismo para ativação das MUs é chamado estratégia de recrutamento. Há dois tipos dessas estratégias motoras de controle que são sabidas aumentarem a força produzida pela contração muscular. Uma delas é a estratégia de recrutamento espacial. Nesta, quanto mais força muscular é requerida mais MUs são ativadas. A segunda é conhecida como recrutamento temporal, em que as taxas de disparo<sup>8</sup> dos neurônios motores ativos são aumentadas com o aumento da força demandada (Fuglevand, A., Winter, D., Patla, 1993).

O neurônio motor, ou motoneurônio, é um neurônio mielínico, o que faz com que a condução do pulso elétrico seja rápida. O axônio do neurônio motor entra em contato com o músculo e se divide em múltiplos botões terminais que se introduzem no músculo esquelético. Através destes botões, neurotransmissores são liberados. A placa motora terminal recebe esses neurotransmissores. Essa placa é uma estrutura especializada pós-sináptica para a realização da sinapse mioneural. A placa motora é importante no acoplamento eletro-mecânico responsável pela contração muscular (CELANI, 2010).

A contração muscular, então, consiste basicamente no encurtamento das fibras musculares devido ao deslizamento dos filamentos finos sobre os filamentos grossos. O

<sup>8</sup> A taxa de disparo está relacionada com a frequência das sinapses excitatórias repetidamente estimuladas. O esgotamento dos neurotransmissores, importante para conter processos de superexcitação, como as convulsões eplépticas, está relacionado com a fadiga muscular e a diminuição dessas taxas.

tamanho das bandas *A* é constante embora as linhas *Z* se movam, aproximando-se no momento da contração e afastando-se no momento de relaxamento muscular, como ilustrado na Figura 14.

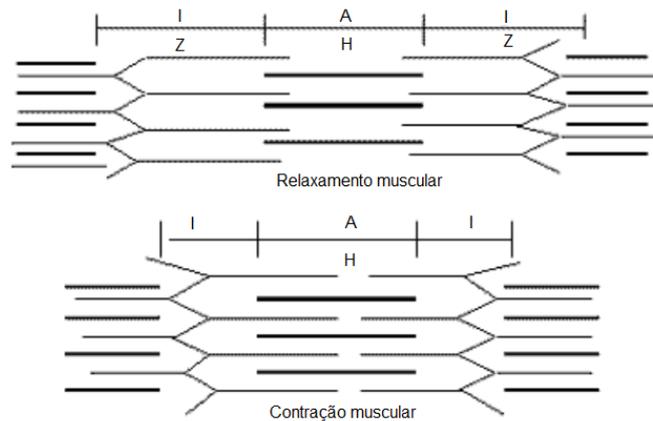


Figura 14 – Filamentos grossos e finos em contração e relaxamento. Adaptado de [Celani \(2010\)](#)

A nível molecular, a contração muscular está relacionada com a despolarização da fibra muscular. O neurônio motor conduz o potencial de ação, AP, e em sua terminação (neurônio pós-sináptico) o neurotransmissor é liberado (acetilcolina<sup>9</sup>), que vai para as placas motoras e interage produzindo um potencial elétrico. Se a despolarização da membrana da fibra muscular alcançar um limiar específico de disparo, outro potencial de ação é gerado. Este viaja pelas fibras musculares esqueléticas e íons de cálcio ( $Ca^{+}$ ) são liberados que interagem com as proteínas contráteis dos músculos (actina e miosina). Essa interação produz o encurtamento dos extremos realizando a contração. Esse processo ocorre repetidamente para que a contração muscular seja realizada ([CELANI, 2010](#)).

A membrana celular é a base dos fenômenos elétricos que resultam na contração muscular e na geração do sinal de EMG. Em [MERLETTI \(2004\)](#) está descrito um modelo celular muscular para representar o comportamento dos três principais canais de íons dessas células, os íons de cálcio, potássio e sódio.

O ponto-chave deste modelo é o comportamento dinâmico e a permeabilidade da membrana dependente do potencial elétrico causado por esses íons, já que quando mudanças de condutância atingem um valor de limiar do potencial de membrana em repouso (-80 mV para a membrana muscular), um potencial de despolarização transitório ocorre. Este é propagado em ambas as direções ao longo da fibra muscular e, somado ao

<sup>9</sup> A acetilcolina (ACh) foi o primeiro neurotransmissor descoberto. Tem um papel importante no sistema nervoso central (SNC). No sistema nervoso somático, a contração muscular ocorre devido à liberação desta substância pelas ramificações do axônio.

movimento de íons, gera um campo magnético na vizinhança, como ilustrado nas Figuras 15 e 16.

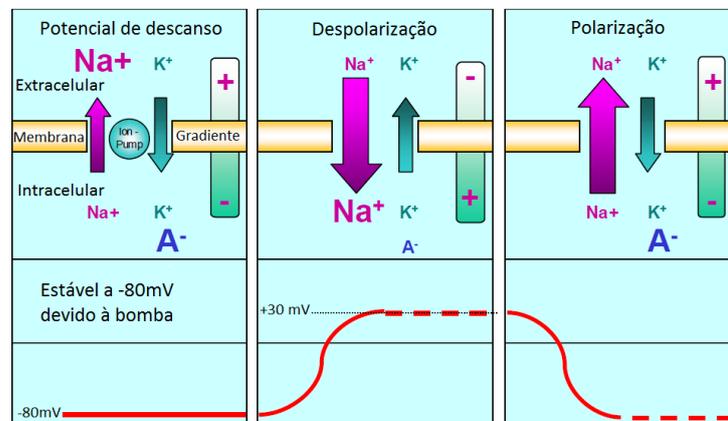


Figura 15 – Potencial de ação muscular: alterações nos canais iônicos durante o potencial de ação.

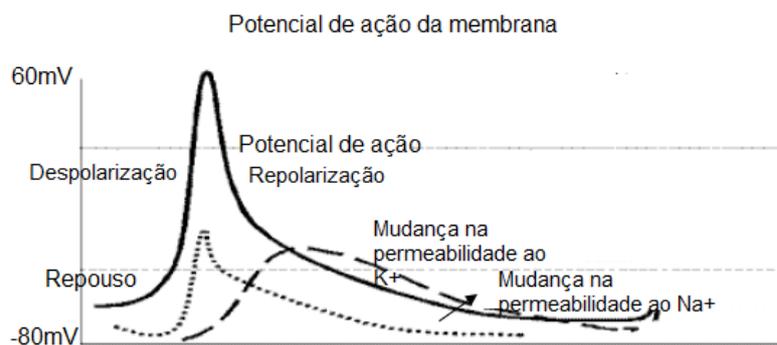


Figura 16 – Potencial de ação muscular: esquema simplificado de propagação do AP. Adaptado de MERLETTI (2004).

A forma e amplitude do potencial de ação dependem do comportamento iônico. Para detectar esse potencial externamente, coloca-se um eletrodo referenciado a um terra e os picos da atividade elétrica são observados. Ocorrem simultaneamente pulsos e contrações musculares em outras unidades motoras resultando em um potencial de ação complexo da unidade motora, o MUAP (MERLETTI, 2004).

A sustentação da contração muscular requer que a unidade motora seja ser ativada repetidamente. O resultado da sequência repetida de MUAPs para que isso ocorra é chamada Trem de Potenciais de Ação da Unidade Motora, *MUAPT* (do inglês *Motor Unit Action Potential Train*).

O Sinal de EMG pode ser tomado como uma soma linear das MUAPTs, como ilustrado na Figura 17.

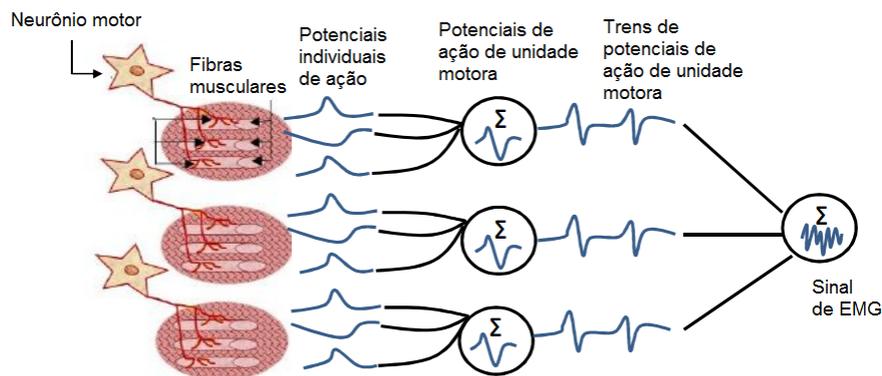


Figura 17 – Estruturas na contração do músculo esquelético produzindo sinal EMG. Adaptado de [Rechy-Ramirez \(2011\)](#)

O sinal de eletromiografia, então, é a representação do campo elétrico gerado pela despolarização da membrana das fibras musculares. Sua detecção envolve o uso de eletrodos intramusculares ou superficiais à pele, este último chamado de sEMG, eletromiografia de superfície. Este método foi utilizado neste trabalho e será abordado na seção seguinte.

A Figura 18 ilustra o caminho do sinal elétrico desde o cérebro até os músculos, passando por algumas estruturas citadas neste capítulo, bem como os mecanismos envolvidos na propagação deste impulso até a realização de um movimento.

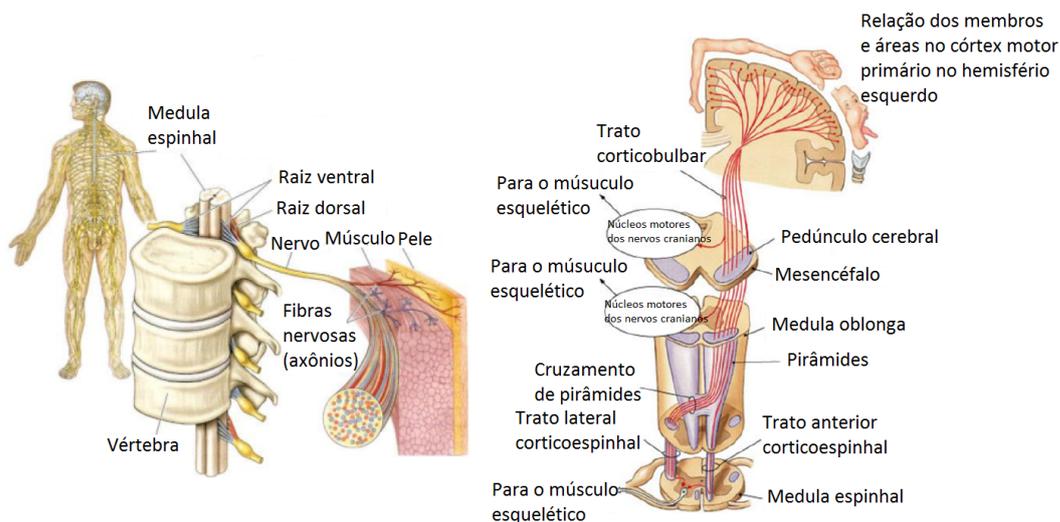


Figura 18 – ilustração do caminho do impulso elétrico desde o cérebro até o músculos, à esquerda, e a relação de membros com áreas do córtex motor mostrando o sistema piramidal, à direita. Adaptado de [Bear, M. F; Connors, B. W. e Paradiso \(2008\)](#).

### 2.2.2 Aquisição do sinal de sEMG

A aquisição do sinal de EMG pode ser feita de forma invasiva ou não invasiva. A primeira é feita através da inserção de um eletrodo de agulha através da pele diretamente ao músculo. Esta técnica é uma ferramenta clínica padrão utilizada principalmente para fins de diagnóstico, dedicada a analisar regiões específicas, uma vez que proporciona uma alta resolução espacial, e uma descrição localizada da atividade elétrica dos músculos. No entanto, é incômoda para o paciente, pode restringi-lo de realizar movimentos e pode não ser aplicável em razão da necessidade da inserção do eletrodo. A técnica não invasiva usa eletrodos superficiais à pele, sendo chamada de eletromiografia de superfície (sEMG). Nesta técnica, os eletrodos são colocados sobre a pele que recobre o músculo em estudo. A resolução espacial desta técnica é mais limitada do que a invasiva, e o conteúdo do sinal sofre atenuações devido principalmente ao acoplamento entre a pele e os eletrodos. No entanto, dada a característica não invasiva, mais cômoda ao paciente, que permite movimentos mais naturais e à possibilidade de medição de um sinal para aplicações em que não é necessária uma alta resolução espacial, i.e., sinal de fibras musculares específicas, este método foi utilizado neste trabalho e será abordado a seguir.

Para a aquisição do sEMG, recomenda-se o uso de eletrodos de prata e cloreto de prata,  $Ag/AgCl$ , e gel eletrolítico para diminuição da impedância e, conseqüentemente, melhor condução. Os eletrodos podem ser passivos, como os usados neste trabalho, ou ativos. A estabilização e o acoplamento entre o eletrodo e a pele também são importantes, de forma que deve-se limpar a pele até uma certa abrasão e evitar a colocação dos eletrodos sobre pelos. A impedância no local de aquisição do sinal de sEMG, entre a pele e o eletrodo, sugere-se ser inferior a aproximadamente  $10K\Omega$ .

Quando eletrodos de superfície são utilizados, a distância entre a fonte do sinal e ponto de detecção é significativa. O efeito do volume condutor do sinal, que é de um filtro passa-baixas, é relevante. Para minimizar este efeito e de componentes do modo comuns causados por interferências externas (outros sinais biológicos, interferência de rede elétrica, etc.) faz-se uma aquisição com canais de configuração bipolar e amplificação diferencial dos sinais.

A localização, em relação à direção das fibras do músculo, deve ser em paralelo à direção longitudinal, de modo a intersectar a maior quantidade de fibras, e, se possível, distante da área do tendão e zonas de inervação. A distância entre os eletrodos do canal bipolar recomenda-se estipular em 2 centímetros. Nessa distância, captura-se a maior amplitude possível do sinal muscular com uma menor interferência de sinais externos. O eletrodo de terra é normalmente posicionado em algum osso para minimizar sinais de outros músculos, e seu potencial é cancelado durante a amplificação diferencial. A Figura 19 ilustra o posicionamento dos eletrodos em relação à fibra muscular.

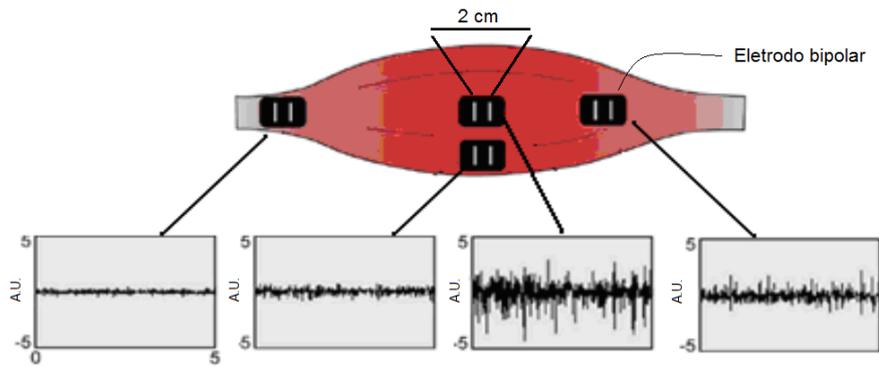


Figura 19 – Localização dos eletrodos em relação às fibras musculares e amplitude gerada por cada posicionamento dos canais bipolares. Adaptado de [Celani \(2010\)](#)

Todas essas sugestões foram avaliadas em um contexto de protocolo internacional para aquisição de sinais de sEMG, o *SENIAM*, Eletromiografia de Superfície para a Avaliação não Invasiva de Músculos ([HERMENS et al., 1999](#)) (do inglês *Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles*).

Uma vez que o potencial de ação do músculo chega ao eletrodo, passa através do processo de amplificação diferencial e rejeição de modo comum. A Figura 20 ilustra a amplificação diferencial, os pontos por onde o potencial elétrico atravessa até chegar ao eletrodo para captação do sinal, à amplificação e à posterior filtragem e processamento.

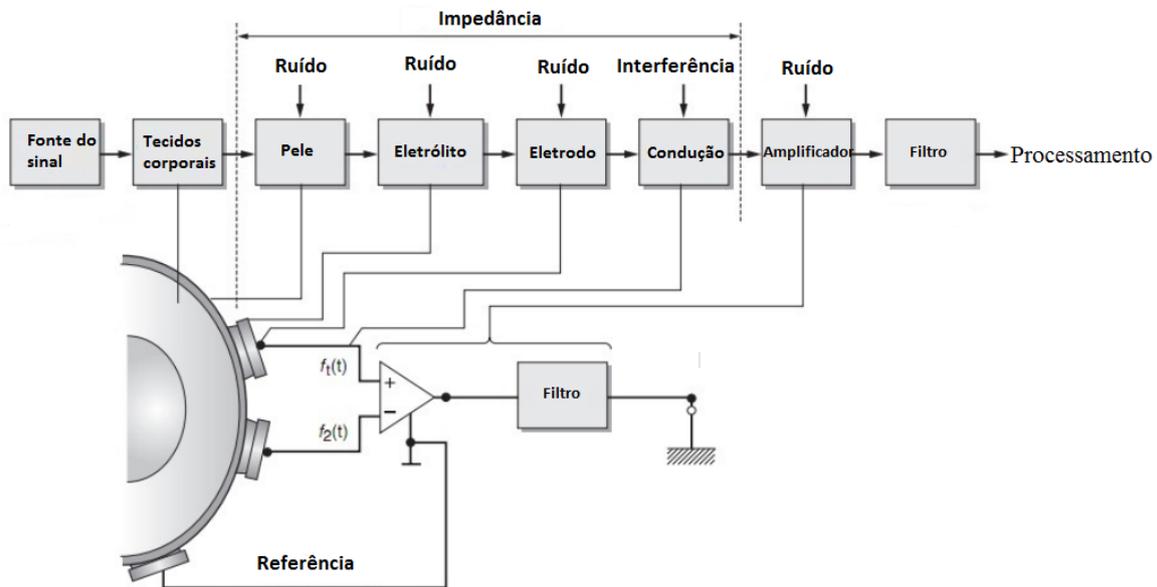


Figura 20 – A amplificação diferencial do sinal de EMG, os pontos por onde o potencial elétrico atravessa até chegar ao eletrodo para captação do sinal, à amplificação e à posterior filtragem e processamento. Adaptado de [Criswell \(2011\)](#).

Durante uma contração muscular voluntária um grande número de MUs se contraem,

geralmente, assincronamente e se observa na superfície da pele um padrão aleatório de sinal elétrico. A magnitude total da atividade elétrica superficial, sem a decomposição de APs individuais é um indicador da atividade muscular e da força exercida. O sinal de EMG na superfície da pele pode ser considerado um sinal estocástico, de média zero, representado por uma função de distribuição gaussiana, estacionário em sentido amplo e contaminado com ruído branco aditivo também gaussiano (??). A amplitude deste sinal pode variar até  $10\mu\text{V}$ , pico-a-pico, e o espectro útil de frequências de 10 a 500 Hz, com uma banda dominante entre 30 e 150 Hz, dependendo do músculo (CELANI, 2010).

Como visto, os músculos esqueléticos são os atuadores naturais responsáveis pelo movimento humano. No entanto, também desempenham um grande papel na locomoção humana a partir de interações com robôs, o que perfaz uma situação não natural mas possível de ser implementada no contexto de reabilitação robótica. Por exemplo, no âmbito de exoesqueletos, as funções de controle da órtese funcionam como amplificadores da força dos músculos e podem ser ativadas por sinais fisiológicos, como EEG e mesmo EMG. O entendimento de estratégias de controle de robôs a partir de sinais neuromotores para aplicações em reabilitação é um tópico atual de muito estudo.

No processamento de sinais de EMG há uma etapa de muito interesse no contexto de controle de dispositivos de reabilitação robótica: a detecção do início da contração muscular. Este assunto será abordado brevemente a seguir.

### 2.2.3 Detecção do começo da contração muscular

A correta detecção do começo da contração muscular no sinal de EMG é de grande importância. A classificação de padrões e o diagnóstico de patologias neuromusculares podem ser realizados a partir deste evento. Em aplicações no controle de dispositivos, como próteses ou órteses, utilizados em reabilitação robótica, sinais falsos positivos gerados por ruídos ou um atraso na detecção da contração muscular podem gerar comandos errôneos. Em geral, o método de inspeção visual é elegido para a detecção, no entanto, a partir deste método não há um critério objetivo, tampouco pode ser utilizado em sistemas automáticos. Para um sistema de controle em tempo real é necessária uma técnica de processamento de dados para a detecção do início da contração muscular. A Figura 21 ilustra detecções do início e fim da contração muscular mostrando o sinal de EMG cru, processado e classificado. Em (A) é possível observar que o sinal processado não apresenta ruídos significativos à aplicação e a classificação para início do movimento está correta. Em (B) os ruídos não são eliminados e fazem com que falsos positivos sejam gerados na detecção do início do movimento. Em (C) percebe-se que o limiar utilizado não está ajustado para a detecção da atividade secundária, de menor amplitude.

Não existe um consenso, tampouco um método padrão para a detecção do começo da ativação muscular durante um movimento. No entanto, um grande número de trabalhos

na área usa o conceito proposto por Fabio (1987). Este conceito propõe que quando o sinal atingir um limiar, calculado em repouso muscular, e se mantiver acima deste limiar por uma quantidade de tempo pré-determinada, o começo da ativação muscular ocorreu a partir do momento em que o sinal ultrapassou o limiar (CELANI, 2010).

Geralmente, o sinal é processado antes da aplicação deste método para a atenuação de ruídos. Deve-se levar em conta que algumas filtragens podem distorcer o sinal e modificar o tempo de ativação, uma vez que décimos de segundos podem ser relevantes dependendo da aplicação.

Alguns autores que propuseram técnicas para a detecção do início da contração muscular são Fabio (1987); Hodges (1996); Bonato, D'Alessio e Knafitz (1998); Staude (2001); Severini et al. (2012) e Kirchner, Tabie e Seeland (2014). Alguns desses autores usam características do sinal relacionadas à teoria da informação, relação sinal-ruído, espectro de frequências, amplitude, entre outros para proporem um método de detecção de início de contração. Este Projeto de Pesquisa utilizou o método proposto por Kirchner, Tabie e Seeland (2014), por ser utilizado em uma aplicação semelhante a deste estudo e ser de baixo custo computacional. Este método é baseado no método proposto por Fabio (1987) e será descrito com maiores detalhes na Seção 4.2. Para maiores detalhes acerca deste assunto, consulte Celani (2010), Staude (2001).

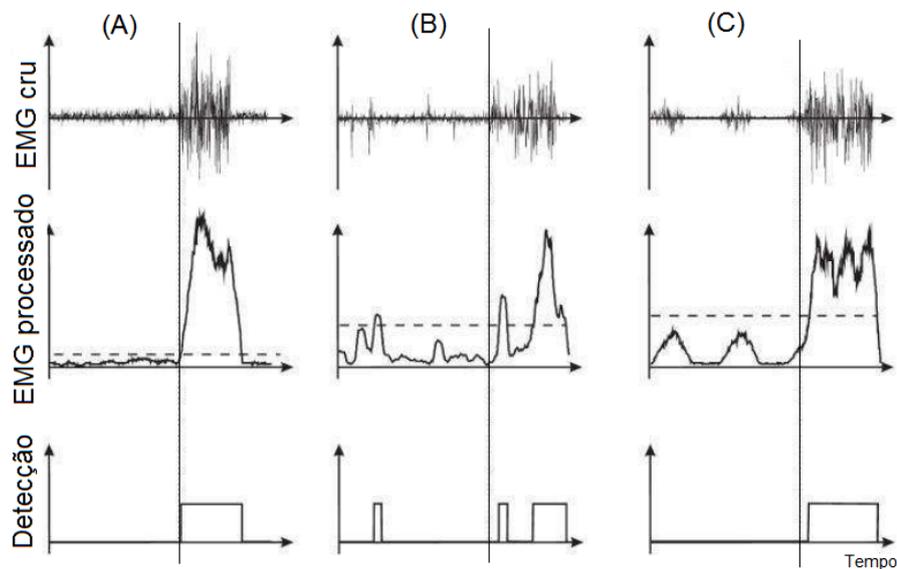


Figura 21 – Detecção da contração muscular. Em (A) tem-se a detecção correta, em (B) se registram falsos positivos por ruídos e (C) a atividade secundária não é detectada. Adaptado de Staude (2001).

## 2.3 Sensores Inerciais

As unidades de medição inercial ou *IMU* (do inglês *Inertial Measurement Unit*) são normalmente compostas por dispositivos eletromecânicos, multi-axiais, como acelerômetros, giroscópios e magnetômetros.

No passado, acelerômetros, giroscópios e magnetômetros eram construídos com estruturas mecânicas maiores se comparados aos atuais, como massas, molas, entre outros. Avanços recentes na tecnologia fizeram possível o desenvolvimento dos *MEMs*, (do inglês *MicroElectroMechanical Systems*), que refere-se a tais tipos de sensores miniaturizados em circuitos integrados. Estes são amplamente utilizados hoje em dia,

O acelerômetro é um dispositivo usado para medir a aceleração própria. A aceleração própria difere da aceleração, no sentido convencional de taxa de mudança de velocidade, pois está atrelada a sensação de peso medida em um dado referencial. Há vários tipos de acelerômetros que usam diferentes tipos de efeitos para medir a aceleração. Os principais podem ser classificados através do princípio físico de medida utilizado pelo circuito integrado usado como sensor. O piezoelétrico faz uso do efeito piezoelétrico em que normalmente, há uma massa presa a um cristal piezoelétrico, quando há uma aceleração no sistema a massa presa ao cristal acaba gerando uma deformação no cristal e este deslocamento gera um sinal elétrico; o piezoresistivo faz uso da variação de resistência de um cristal quando esticado; o capacitivo que funciona de modo que a aceleração no dispositivo desloca uma placa móvel de um capacitor em relação a placas fixas no dispositivo. Desta forma, altera-se a capacitância de cada capacitor, entre outros (Buffa, C., Langfelder, G., Longoni, A., Frangi, A., e Lasalandra, 2012). A Figura 22 ilustra um acelerômetro piezoresistivo tri-axial.

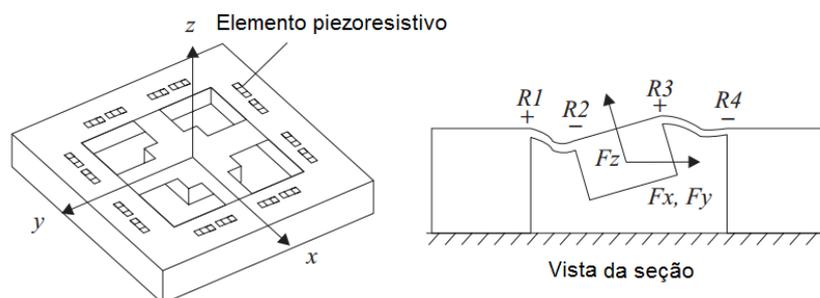


Figura 22 – Acelerômetro tri-axial piezoresistivo, à esquerda. À direita, a seção da figura da esquerda: um circuito de sensores piezoresistivos detectando diferença de tensão para mensurar a aceleração própria. Adaptado de Pons (2008b).

Os giroscópios são dispositivos que se baseiam no princípio da inércia para detectar o giro de um corpo em um determinado eixo. Estes sensores usam normalmente um elemento mecânico vibrante (massa de prova) para medir a rotação. A operação é geralmente

baseada na transferência de energia entre estruturas que vibram, causada pela aceleração de Coriolis<sup>10</sup>, que é proporcional à velocidade de rotação que o objeto experimenta. Em giroscópios do tipo MEMs, estruturas de substrato de silício detectam os efeitos de aceleração de Coriolis. A força tangencial de Coriolis é proporcional à rotação sentida pelo elemento (PONS, 2008b). A Figura 23 ilustra esse princípio.

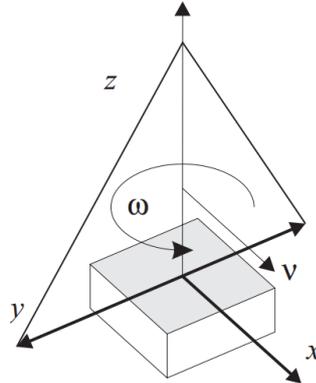


Figura 23 – Operação e eixos de referência do giroscópio. Adaptado de Pons (2008b).

Os magnetômetros funcionam como uma bússola magnética, medindo a intensidade do campo magnético na direção de seu eixo (Buffa, C., Langfelder, G., Longoni, A., Frangi, A., e Lasalandra, 2012). Combinando os sinais destes três sensores é possível estimar a orientação em 3 dimensões de um objeto.

O estudo do movimento humano na atualidade tem sido o foco de interesse das áreas da indústria de entretenimento, robótica, medicina, esporte, entre outras. Atualmente, sensores inerciais têm sido desenvolvidos em circuitos integrados (CIs) contendo circuitos para processamento e calibração dos sinais. A medida do movimento, mediante a utilização de sensores inerciais MEMs é atualmente utilizada em uma ampla faixa de produtos de consumo como computadores portáteis, telefones celulares, sistemas de entretenimento como consoles de *video game*, automóveis, entre outros (Buffa, C., Langfelder, G., Longoni, A., Frangi, A., e Lasalandra, 2012).

A área médica, principalmente no campo da biomecânica, tem sido bastante favorecida pelo uso dos sensores inerciais. Devido à necessidade de desenvolvimento de sistemas ambulatoriais para a obtenção de variáveis cinemáticas do corpo humano, dispositivos MEMs são utilizados na pesquisa e na caracterização do movimento humano.

<sup>10</sup> A força inercial ou pseudoforça de Coriolis é uma pseudoforça ou força inercial - não sendo portanto uma força na definição do termo - percebida apenas por observadores solidários a referenciais não-inerciais animados de movimento de rotação em relação a um referencial inercial que se afastam ou aproximam do centro deste movimento de rotação. A pseudoforça de Coriolis faz-se presente apenas quando o objeto encontrar-se em movimento em relação ao referencial não-inercial em consideração, mostrando-se sempre perpendicular à velocidade e também ao eixo de rotação do sistema não inercial em relação ao inercial.

Tal fato possibilita melhorias na caracterização dos movimentos. Sistemas MEMs vêm sendo utilizados em aplicações de controle de dispositivos, sejam virtuais como *mouses*, *avatares* em jogos de computador ou até mesmo reais como no controle de robôs (Moreno, J., Rocon, E., Ruiz, A. F., Brunetti, F., e Pons, 2006; Luinge, H. J. e Veltink, 2005; ROCON et al., 2007).

Exemplos deste tipo de aplicação são citados por RAYA (2010), através do uso de sensores inerciais para capturar movimentos da cabeça em aplicações de controle que fornecem aos usuários vantagens como deixar livres as mãos para outras atividades ou realizar tarefas que antes não eram possíveis como controlar um *mouse* de computador, quando os usuários têm deficiências físicas ou cognitivas; por Gallego et al. (2012), através de uma compensação ativa de tremor de membros superiores por meio de exoesqueletos; e por Moreno, J., Rocon, E., Ruiz, A. F., Brunetti, F., e Pons (2006), através do controle de monitoramento de órteses de membros inferiores por meio de sensores inerciais, entre outros.

Os últimos desenvolvimentos em sistemas MEMs, atrelados com o desenvolvimento das IMUs vestíveis, permitiram a implementação de sensores inerciais pequenos e de baixo peso, que podem ser colocados sobre segmentos do corpo humano sem interferir de forma significativa nos movimentos naturais do usuário. O baixo consumo destes sensores permite que possam ser alimentados por baterias e, geralmente, transmitem os dados através de uma conexão sem fio, possibilitando a medida ambulatória e contínua. Dessa forma, é possível a obtenção de parâmetros biomecânicos, como a medição de ângulos entre articulações, em tempo real. Por estes motivos, são amplamente utilizados nas mais recentes pesquisas sobre análises biomecânicas, como por exemplo de marcha humana (VAN DEN NOORT, 2013). O uso destes dispositivos ainda pode oferecer informações específicas aos profissionais de saúde, facilitando o monitoramento e diagnósticos a partir das análises, uma vez que decisões sobre o estado do paciente serão baseadas objetivamente conforme a avaliação dos sensores.

Ressalta-se a importância da fusão de sensores no desenvolvimento de sistemas MEMs, para valores mais corretos, na construção de um sensor inercial robusto. Os giroscópios são dispositivos sensíveis e que apresentam uma grande influência da temperatura, de modo que seu funcionamento por longos períodos se mostra comprometido devido ao acúmulo de erros. Por esse motivo, sensores inerciais mais recentes são compostos pelos três tipos de sensores citados anteriormente (acelerômetros, giroscópios e magnetômetros), ditas IMUs completas. A fusão dos dados de cada sensor propicia sistemas mais robustos, precisos e menos suscetíveis a erros (Kawano, K., Kobashi, S., e Yagi, 2007). A Figura 24 ilustra o uso de sensores inerciais para a medição de ângulos do joelho durante a marcha e mostra a diferença entre a medição baseada apenas no giroscópio e na IMU completa.

Na Figura 24, a linha tracejada é a medida do ângulo a partir do giroscópio e a

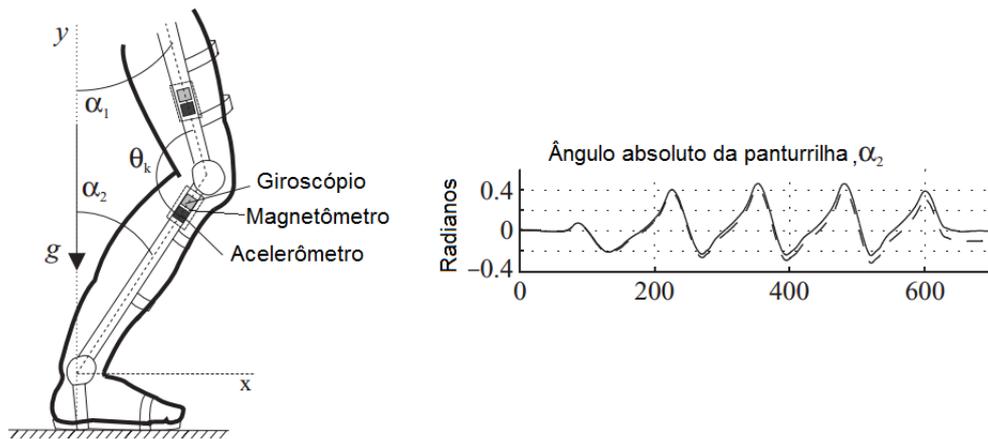


Figura 24 – Ilustração do uso de sensores inerciais para a medição de ângulos do joelho, à esquerda. Diferença entre a medição baseada apenas no giroscópio (linha tracejada) e na IMU completa (linha contínua), à direita. Adaptado de Pons (2008b).

linha contínua a partir da fusão dos sensores, formando o sinal de saída da IMU completa, cujo resultado é correto e não acumula erros com o tempo como o anterior.

Alguns dos principais sistemas comerciais para análise de movimento usando sensores inerciais são a *XSENSE* (Holanda), que tem vários produtos, com IMUs completas, para análise de movimento de alta precisão, criando uma solução de orientação tridimensional e permitindo formar redes sem fio para projetos de medição de segmentos do corpo durante atividades cotidianas; os sensores *STT-IBS* da *STT Systems* (Espanha) são IMUs com 9 graus de liberdade e também completas. Este sistema pode se comunicar sem fio com telefones celulares ou *tablets* para integração de interfaces gráficas; e o sistema *TechIMU* da *Technaid* (Espanha). Este último foi utilizado neste trabalho e será descrito com mais detalhes na Seção 3.2. A Figura 25 ilustra os dois primeiros sistemas comerciais citados.



Figura 25 – Sistemas comerciais de sensores inerciais. Sistema *XSENSE*, à esquerda (A) (??) e sistema *SST-IBS*, à direita (B) (??). .

Uma forma de calcular a orientação dos objetos a partir de sensores inerciais é mediante o uso do algoritmo de matriz de cossenos diretores, *DCM*, (do inglês *Direction Cosine Matrix*), usado para estimar a inclinação e orientação relativa de um objeto em relação a um sistema de referência. O algoritmo DCM usa a informação do giroscópio como fonte principal de orientação entre os dois sistemas de referência, um sistema de referência próprio do objeto e outro que pode ser um sistema de referência global. Os dados do magnetômetro e do acelerômetro são usados para compensar o deslocamento pela integração do sinal do giroscópio (LOU, 2011). Este método é utilizado pelo sistema de medida inercial usado neste trabalho e, a partir dele, a aferição dos ângulos da articulação do joelho, bem como a detecção do início do deslocamento da perna são realizados, como descrito na Seção 4.1.

Garantir uma apropriada fusão e calibração de acelerômetros, giroscópios e magnetômetros vai determinar a grau de precisão e acurácia do sistema de medição inercial, dando confiabilidade aos dados e também a possibilidade de integração com outros sistemas de aquisição de movimento em tempo real. A descrição de algoritmos para cálculo de orientação, fusão e calibração de sensores inerciais não está no escopo deste trabalho. Maiores informações acerca deste assunto podem ser encontradas em Sanchez (2014).

## 2.4 Sistemas Multimodais Aplicados à Robótica de Reabilitação

Nesta seção serão apresentados, brevemente, alguns trabalhos recentes que propõem interfaces multimodais no contexto da robótica de reabilitação. Naturalmente, este tema não está restrito a tais trabalho pois, é amplo em razão, principalmente, da interdisciplinaridade entre as áreas médica e de engenharia. No entanto, são trabalhos abrangentes e foram referências diretas nesta pesquisa.

### Kirchner et al.

Neste trabalho, Kirchner, Tabie e Seeland (2014) mostram através de uma análise *offline* de propósito generalista, a partir de um protocolo de testes em pessoas saudáveis, que a combinação de eletroencefalografia e eletromiografia pode ser usada na predição do movimento e no melhoramento da adaptabilidade de dispositivos assistivos. A adaptabilidade neste trabalho refere-se ao estágio de reabilitação em que o paciente se encontra. Em estágios em que a atividade muscular está diminuída a aferição dos sinais de EEG pode ser mais relevante na intenção de movimento e em situações em que a atividade muscular está normal a análise de outros sinais corrobora a detecção do EMG. A pesquisa faz comparações em detecções de intenção de movimento baseadas em EEG e EMG separadamente e também, de outras formas, por exemplo, analisando a lógica *OU* entre as detecções para verificar a antecipação do movimento a partir de qualquer dos sinais.

A detecção de início de movimento é realizada através de dispositivos mecânicos, como botões em que os sujeitos acionam (por soltura) ao realizarem movimentos dos membros superiores. A Figura 26 ilustra um dispositivo completo de reabilitação em que os estudos realizados pela interface proposta podem ser aplicados.

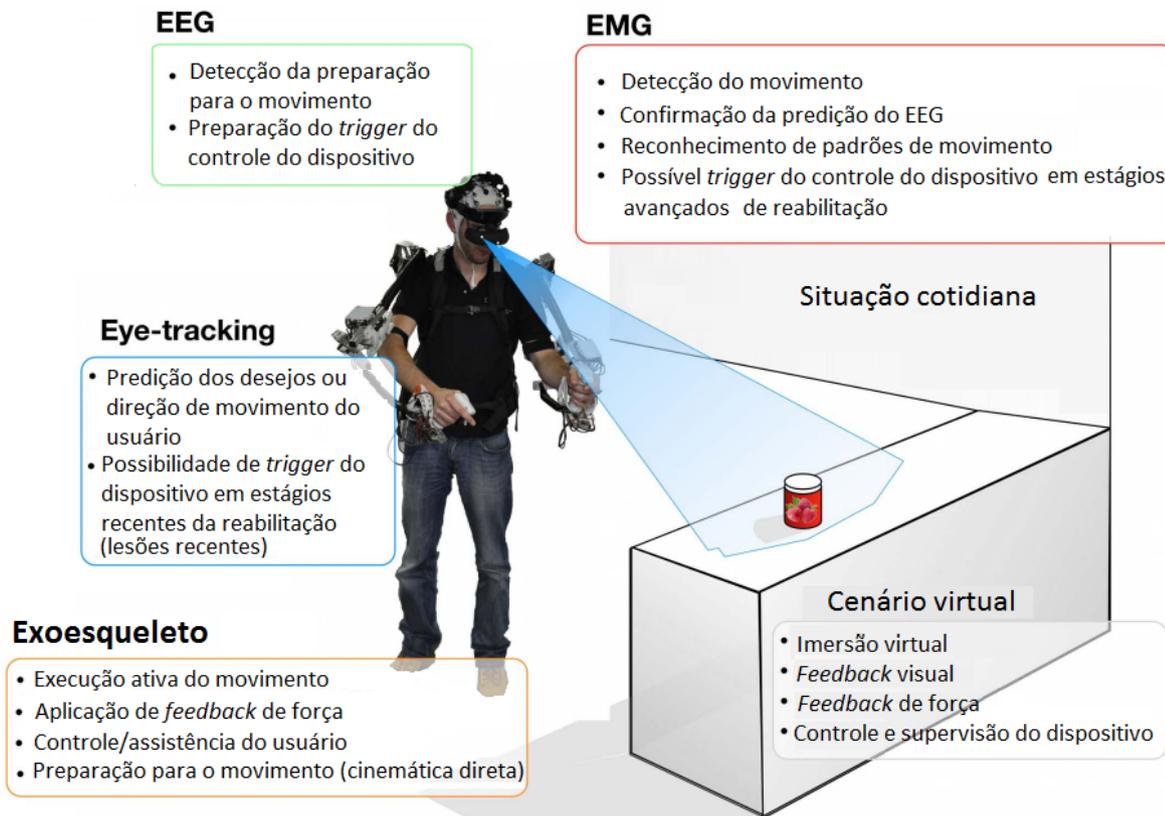


Figura 26 – Esquema de um sujeito assistido por um exoesqueleto em um possível cenário de reabilitação proposto por [Kirchner, Tabie e Seeland \(2014\)](#) (Adaptado).

Na Figura 26, é possível observar que os autores propõem uma futura combinação da interface proposta com sistemas de visão para mensuração da direção em que o sujeito olha, em um ambiente virtual de reabilitação, e com outros sensores, como de força, já aplicados em um sistema *online* de controle do dispositivo robótico ilustrado.

## Novak et al.

Neste trabalho, [Novak et al. \(2013\)](#) mostram que diferentes sensores devem ser combinados para diferentes situações, por exemplo, para planejamento de movimento, início de movimento ou ao longo de sua execução. Pode-se usar EMG, EEG, EOG, análise de movimento e até preferências pessoais do sujeito. Este trabalho compara performances de diferentes tecnologias ao prever movimentos para pegar objetos-alvo pré-determinados. As informações acerca da antecipação do movimento reconhecido pela

interface multimodal pode ser utilizada em controles de dispositivo para reabilitação robótica. Os testes deste trabalho foram realizados em sujeitos saudáveis. A Figura 27 ilustra o protocolo experimental proposto pelos autores.

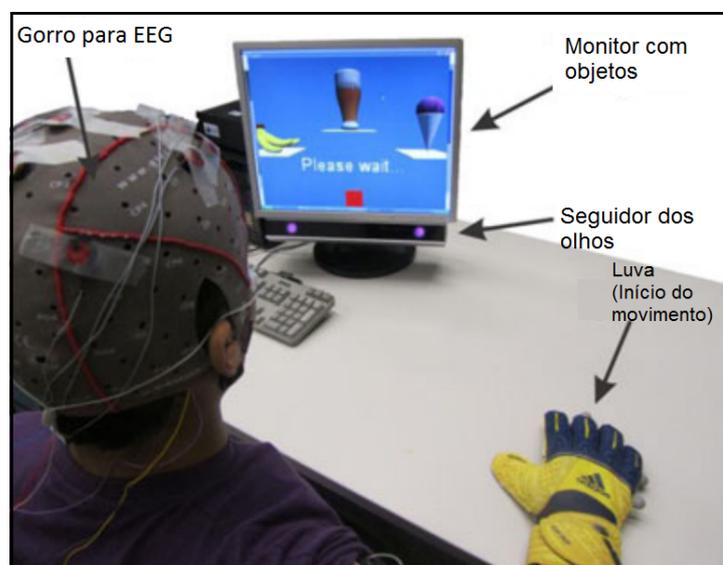


Figura 27 – Ilustração do protocolo experimental de testes do trabalho de [Novak et al. \(2013\)](#) (Adaptado).

Na Figura 27 é possível observar que há objetos em um ambiente virtual que o sujeito deve escolher através do movimento das mãos. Há aquisição de dados de EEG, EMG, seguimento de olhos, identificação do início do movimento da mão, através da luva de marcadores em conjunto com sistemas de visão e ainda um conhecimento prévio de preferências do sujeito relacionadas aos objetos mostrados.

### Ibanez et al.

Neste trabalho, [Ibanez et al. \(2013\)](#) não propõem especificamente uma interface multimodal e sim técnicas para detecção de intenção de movimento baseadas em EEG. No entanto, os autores propõem que este trabalho seja combinado com processamento de sinais de EMG para a análise de intenção de movimento. Por isso, tem relevância na referência desta dissertação. Os autores propuseram um protocolo de testes em que pessoas saudáveis e com tremor realizam movimento de membros superiores e fizeram uma comparação entre os resultados. A Figura 28 mostra um diagrama que ilustra as etapas de processamento do sinal de EEG para a detecção de intenção de movimento.

Na Figura 28, é possível observar que o trabalho utiliza limiares na saída de classificadores *Bayesianos* que são alimentados por valores de densidade espectral de potência do sinal de EEG em canais e frequências específicos. Ainda é possível observar que

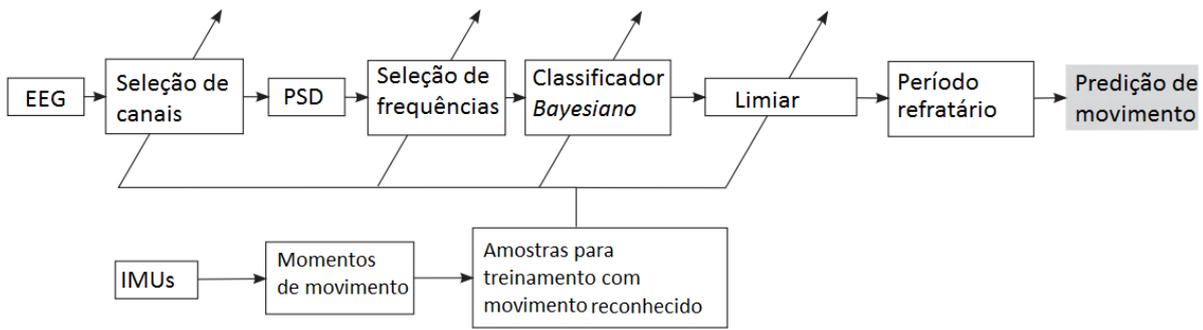


Figura 28 – Etapas de processamento do sinal de EEG para a detecção de intenção de movimento do trabalho de [Ibanez et al. \(2013\)](#) (Adaptado).

o sistema é treinado com dados de movimento identificados a partir de sensores inerciais. Os sensores inerciais utilizados neste trabalho são da fabricante Technaid.

### Gallego et al.

Neste trabalho, [Gallego et al. \(2012\)](#) propõem uma compensação funcional para tremores em membros superiores com um robô vestível que utiliza dados de EEG, EMG e IMU para realizar estimulação elétrica funcional dos músculos. Esta pesquisa já apresenta resultados com pacientes que sofrem de tremores patológicos de membros superiores. O sinal de EEG é utilizado para detectar a intenção de movimento do usuário e proporcionar uma interface mais natural. O sinal das IMUs caracteriza o início efetivo do movimento e junto com o sinal de EMG diferencia o movimento voluntário, dos involuntários referentes aos tremores. Assim, o dispositivo robótico pode atuar estabilizando os movimentos dos membros em que há tremor. Isso proporciona um controle melhor do movimento por parte do paciente. A Figura 26 ilustra o funcionamento do sistema.

A abordagem multimodal deste trabalho realiza a implementação de um método redundante (caracterização do tremor através de EMG e IMUs) para aumentar a confiabilidade do sistema e adaptá-lo às necessidades dos pacientes. Na Figura 29, as caixas com bordas finas referem-se ao mecanismo redundante e compensatório do tremor, bem como as linhas tracejadas. As caixas com bordas grossas referem-se ao funcionamento comum do sistema, sem redundância. A Tabela 1 foi apresentada neste trabalho.

Na Tabela 1, [Gallego et al. \(2012\)](#) mostram uma comparação entre sinais de sensores inerciais, sEMG e EEG com seus pontos positivos e negativos para corroborar a integração desses dados num sistema robusto.

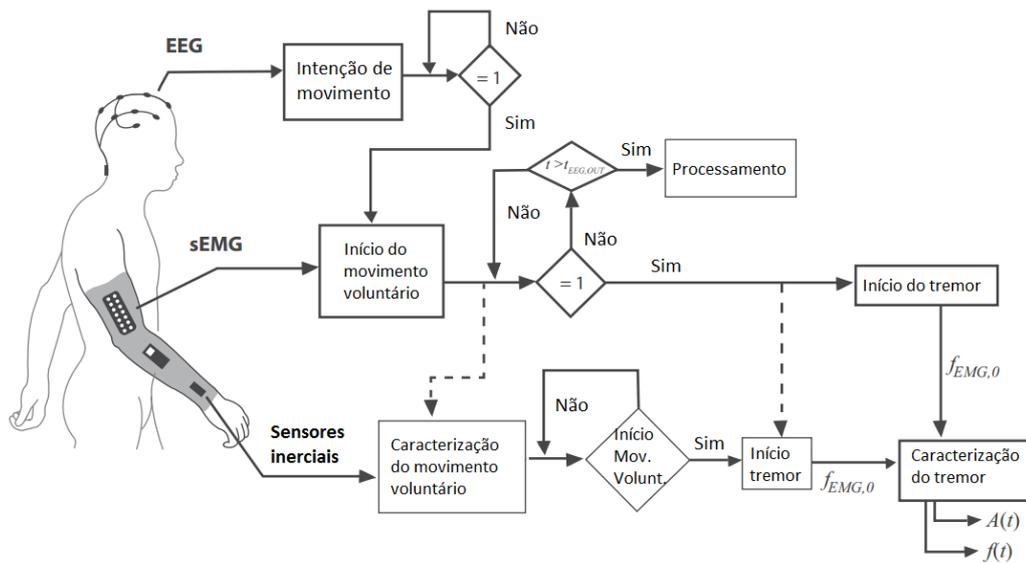


Figura 29 – Esquema que ilustra o funcionamento da interface homem-robô proposta em Gallego et al. (2012) (Adaptado).

Informações dos sinais		
EEG	<p>Maior antecipação do movimento efetivo;</p> <p>Distinção entre movimentos voluntários e não voluntários;</p>	<p>Índices de falsos positivos ou negativos consideráveis (Menor confiabilidade);</p> <p>Alguns indivíduos não apresentam padrões classificáveis;</p>
sEMG	<p>Rápida distinção entre tremor e movimento voluntário;</p> <p>Identificação específica do músculo com tremor;</p>	<p>Relações complexas com a cinemática das articulações para modelo biomecânico;</p> <p>Menor antecipação do movimento voluntário;</p>
IMU	<p>Parametrização eficaz e rápida de tremores;</p>	<p>Impossível de identificar músculo relacionado ao tremor;</p>

Tabela 1 – Comparação entre pontos positivos e negativos dos sinais utilizados no trabalho de Gallego et al. (2012) (Adaptado).

Xu et al.

Neste trabalho, Xu et al. (2014) propõem uma interface multimodal baseada em sinais de EEG e EMG para controle de uma órtese de membro inferior. O objetivo deste estudo é mostrar a neuroplasticidade<sup>11</sup>, que não está no escopo desta dissertação. No

<sup>11</sup> Neuroplasticidade, também conhecida como plasticidade neuronal, refere-se à capacidade do sistema nervoso de mudar, adaptar-se e moldar-se a nível estrutural e funcional ao longo do desenvolvimento

entanto, a interface multimodal proposta no estudo está relacionada com a desenvolvida neste trabalho de mestrado e o estudo destes autores pode trazer a possibilidade de aplicações para esta interface. A Figura 30 ilustra o funcionamento do sistema.

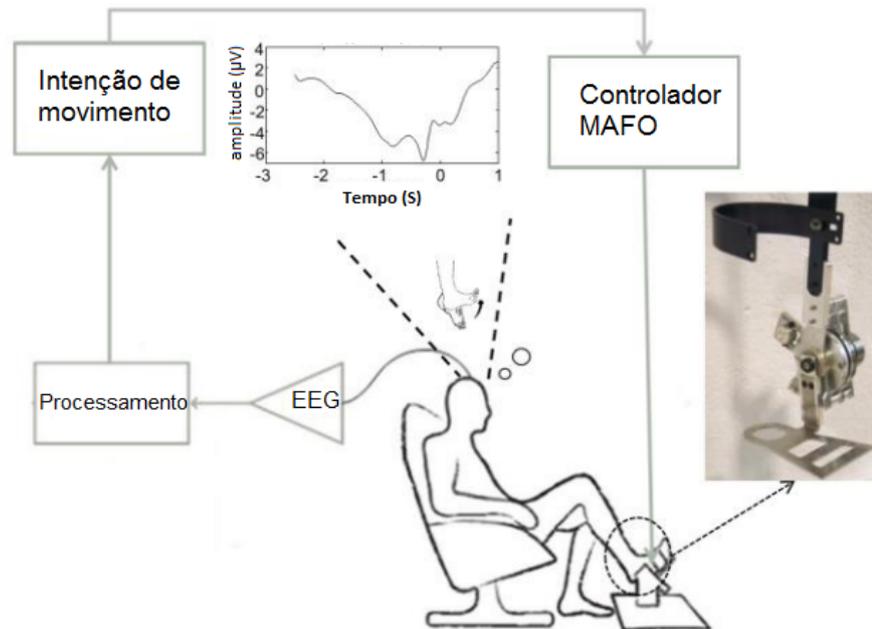


Figura 30 – Esquema que ilustra o funcionamento da interface homem-robô proposta para movimento de membro inferior (XU et al., 2014). (Adaptado).

Na Figura 30, é possível observar uma órtese ativa de um grau de liberdade para movimento do tornozelo. O termo *MAFO* refere-se a *Motorized Ankle-Foot Orthosis* ou Órtese de Tornozelo-Pés Motorizada.

Algumas etapas específicas do processamento de dados, bem como os resultados obtidos a partir dos trabalhos citados nesta seção, serão oportunamente mencionados e comparados com os obtidos por este trabalho nos Capítulos 4 e 5.

Trabalhos que apliquem interfaces multimodais no controle de dispositivos de reabilitação de membros inferiores, a partir de pesquisas consolidadas, também são desenvolvidos como soluções comerciais, por exemplo, pelas empresas *Technaid* (Espanha) e *OttoBock* (Alemanha).

O próximo capítulo tratará da arquitetura do sistema implementado neste trabalho. Abordará características do sistema de condicionamento de sinais biológicos utilizado para aquisição de EEG e de sEMG, bem como as características do sistema inercial utilizado. No próximo capítulo também será descrita a forma como os dados foram adquiridos a partir do protocolo experimental de testes.

---

neuronal e quando sujeito a novas experiências. Esta característica única faz com que os circuitos neuronais sejam maleáveis e está na base da formação de memórias e da aprendizagem bem como na adaptação a lesões e eventos traumáticos ao longo da vida adulta.

## 3 Arquitetura do Sistema de Medição

### 3.1 Sistema de Amplificação e Condicionamento de Sinais Biológicos

O equipamento utilizado para a aquisição de sinais de EEG e sEMG foi o BrainNet<sup>®</sup> BNT-36. Esse equipamento é um produto comercial fabricado pela companhia brasileira *Lynx Eletrônica Ltda.* O BrainNet<sup>®</sup> BNT-36 é produzido baseado nos requisitos gerais de segurança para equipamentos médicos e possui a aprovação das entidades responsáveis pela regulação de produtos médicos no Brasil, o INMETRO e o ANVISA.

BrainNet<sup>®</sup> BNT-36 é um amplificador e condicionador de sinais projetado para aplicações de aquisição digital de sinais biológicos, eletroencefalográficos e poligráficos. É comumente utilizado no monitoramento de polisonografia, eletrocardiografia, eletroencefalografia e eletromiografia. Os condicionadores são de instrumentação integrada e possuem entradas diferenciais, tecnologia integrada bipolar e rejeição de modo comum acima de 90 dB. Utiliza também filtros passa-altas de primeira ordem ajustados em 0.1 Hz e filtros passa-baixas de segunda ordem em 1000 Hz. Além disso, um filtro *Notch* em 60 Hz com atenuação de 40 dB pode ser ativado a fim de eliminar artefatos da rede elétrica. A frequência de amostragem da aquisição pode ser ajustada em 200; 300; 400; 500; e 600 Hz. Os conversores analógico-digital possuem resolução de 16 bits, com tempo de conversão de 10 microssegundos por conversão de aproximação sucessiva e fluxo de dados gerenciados por microcontrolador, para aquisição e comunicação de dados .

Com o BrainNet<sup>®</sup> BNT-36 podem ser adquiridos até 36 canais simultaneamente. No entanto, há apenas 10 canais configuráveis como bipolares, que podem ser utilizados para eletromiografia. A comunicação com um computador pessoal é através de uma conexão LAN, que utiliza protocolo UDP para transmissão de dados, a partir de um conector NET RJ45.

A Figura 31 ilustra o amplificador e condicionador de sinais biológicos utilizado neste trabalho. Nela é possível observar um painel na parte superior onde estão os conectores para a ligação dos cabos até os eletrodos de captação dos sinais.

A Figura 32 ilustra esse painel. Nela é possível ver 22 canais monopolares na parte cinza superior, Fp1, Fp2...O1. Esses canais amplificadores têm uma referência comum, configurável entre T3, C3, Cz, C4, T4, Terra (conector do meio da primeira linha) e *REF*. Na parte central, azul, é possível ver os 10 canais configuráveis entre monopolares ou bipolares, de 23 ao 32. Os canais 32 ao 35 são para registro de sinais cujo potencial varie



Figura 31 – BrainNet<sup>®</sup> BNT-36.

lentamente, como oximetria e pressão de CPAP. O canal 36 também é um canal bipolar. Os conectores de *Trig In* e *Trig Out* são canais de entrada e saída, respectivamente, de pulsos de sincronismo, úteis para comandar outros dispositivos como um fotoestimulador. Os *LEDs* indicam a energização do equipamento (verde) e a saturação de algum canal (amarelo). Informações complementares acerca deste produto e o manual técnico completo pode ser acessado em <http://www.lynxtec.com.br/medica.htm>

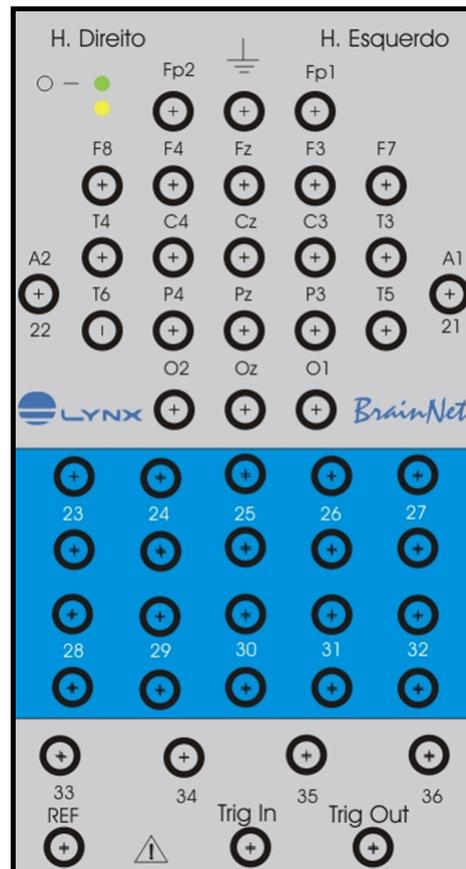


Figura 32 – Pannel de conectores do BrainNet<sup>®</sup> BNT-36.

Os sinais de EEG foram gravados utilizando-se um gorro com eletrodos passivos integrados seguindo o padrão internacional 10-20. O gorro MedCap<sup>®</sup> utilizado é apropriado

para medições de EEG e foi fabricado pela empresa italiana *SpesMedica*. A Figura 33 mostra o gorro utilizado. É possível observar os eletrodos de medição integrados, os eletrodos utilizados como referência, um chicote de cabos, que são conectados ao amplificador e condicionador de sinais utilizado e uma cinta para fixação.

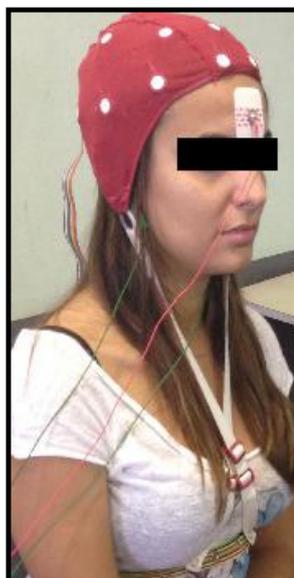


Figura 33 – Gorro MedCap<sup>®</sup> utilizada para a aquisição de sinais de EEG.

Eletrodos passivos Ag/AgCl-Gel Sólido MedTrace<sup>®</sup>, fornecidos pela empresa brasileira *Miotec*, foram utilizados para aquisição dos sinais de eletromiografia de superfície (sEMG). A Figura 34 mostra o eletrodo passivo utilizado neste projeto para aferição de sEMG.



Figura 34 – Eletrodo passivo para sEMG utilizado.

## 3.2 Sistema de Análise de Movimento

A captura de dados relacionados ao movimento foi realizada com o sistema de sensores inerciais comercial Tech-MCS<sup>®</sup> (Technaid, Espanha). O elemento principal deste sistema é um *hub*, um concentrador que pode se comunicar, via barramento CAN, com

até 16 IMUs simultaneamente. Este sistema é capaz de capturar e transmitir em tempo real a orientação espacial de cada sensor em relação à uma referência pré-determinada.

A utilização desse sistema inercial traz viabilidade à análise cinemática do movimento, uma vez que não há necessidade de ambientes estruturados, ao contrário dos sistemas baseados em visão computacional. Também é um sistema móvel e pequeno, portanto, flexível; é preciso e não interfere com os movimentos naturais do corpo humano.

Os dados das IMUs, a partir de conversores A/D de 12 bits, podem ser transmitidos a um computador através de uma porta USB ou ainda via *Bluetooth*. Este sistema pode ser alimentado por baterias ou conectado à rede elétrica. A Figura 35 mostra o concentrador de sinais ao centro conectado aos sensores em seu redor.



Figura 35 – Sistema de sensores inerciais Tech-MCS<sup>®</sup>. Concentrador de sinais e sensores inerciais (??).

A Tabela 2 mostra algumas especificações técnicas do sistema Tech-MCS<sup>®</sup>, como a tensão de operação do concentrador, a corrente consumida, suas dimensões físicas, entre outras.

Característica	Valores	Unidades
Tensão de Operação	3,5 - 5,0	V
Corrente Consumida	80 - 110	mA
Dimensões Físicas	10x15x6	cm (LxCxA)
Frequência de amostragem interna	10 - 200	Hz
Alimentação	4 baterias	AA

Tabela 2 – Especificações técnicas do sistema Tech-MCS<sup>®</sup>.

Cada sensor inercial consiste de acelerômetro, giroscópio e magnetômetro, todos triaxiais e ainda um sensor de temperatura cujo sinal é utilizado para compensar alterações

internas no circuito. A frequência de amostragem da captura pode variar entre 10 a 200 Hz, dependendo dos tipos de dados de saída. Os dados fornecidos pelos sensores podem ser de orientação ou dados físicos dos valores de aceleração, velocidade angular e campo magnético.

A Figura 36 mostra dois sensores inerciais com a orientação de sua referência global. A orientação dos sensores está alinhada com sua referência global quando

- a) Os eixos X e Y estão na horizontal, ou seja, perpendiculares a aceleração da gravidade;
- b) O eixo Z está na vertical, positivo para cima, ou seja, no sentido oposto à aceleração da gravidade.
- c) O eixo X está na direção do norte magnético terrestre em sentido positivo.

Nessa posição, os ângulos de rotação do sensor em torno dos eixos X, Y e Z, ou seja, os ângulos de *Euler*<sup>1</sup> são iguais a zero.

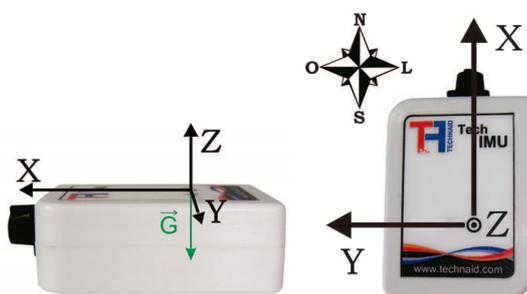


Figura 36 – Sensores inerciais Technaid com a orientação de sua referência global.

A Tabela 3 mostra especificações técnicas dos sensores inerciais utilizados. É possível observar características dos acelerômetros, giroscópios e magnetômetros utilizados, tipos de dados fornecidos pelos sensores e especificações técnicas gerais, como tensão de operação, dimensões físicas, entre outras.

Informações complementares acerca do sistema de medição inercial utilizados neste trabalho podem ser acessadas em <http://www.technaid.com/>.

<sup>1</sup> Os Ângulos de Euler foram formulados por Leonard Euler para descrever a orientação de um corpo rígido girante em um espaço euclidiano tridimensional. Neste caso, é útil fazer-se uso de dois sistemas de coordenadas: um sistema inercial fixo e outro que gira junto ao corpo em rotação. Para especificar a orientação do corpo girante em relação ao sistema inercial (fixo) faz-se uso de três ângulos independentes.

Característica	Valores	Unidades
Tensão de Operação	3,5 - 5,0	V
Corrente Consumida	80 - 110	mA
Dimensões Físicas	26x36x11	mm (LxCxA)
Frequência de amostragem interna	10 - 200	Hz
Peso	9	g
Alcance do Giroscópio	$\pm 2000$	$^{\circ}/s$
Alcance do Magnetômetro	$\pm 35,32$	$m/s^2$
Alcance do Acelerômetro	$\pm 200$	$\mu T$
Tipos de Dados de Saída		
Dados Físicos	Valores correspondentes à medição física	
Orientação	Cossenos diretores ou Quatérnions	

Tabela 3 – Especificações técnicas dos sensores inerciais TechIMU<sup>®</sup> (Technaid).

### 3.3 Arquitetura da Interface Multimodal Proposta

#### 3.3.1 Aquisição dos dados

Foram utilizados 11 canais para as gravações de EEG: Fp1, Fp2, F7, F3, Fz, F4, F8, C3, Cz, C4 e Pz. Foi utilizada a referência biauricular e como terra um eletrodo na frente do usuário. O posicionamento desses eletrodos sobre o escalpo e esse tipo de referência foram discutidos na Seção 2.1

Um canal, do tipo bipolar, para aferição de sEMG foi utilizado neste projeto. Os eletrodos foram posicionados na coxa direita do sujeito, de acordo o protocolo SENIAM (HERMENS et al., 1999), sobre o músculo Reto Femoral, que está diretamente relacionado com o movimento de flexão e extensão do joelho (CRISWELL, 2011). A Figura 37 mostra a recomendação, de acordo com Hermens et al. (1999) para posicionamento dos eletrodos em função do localização dos músculos.

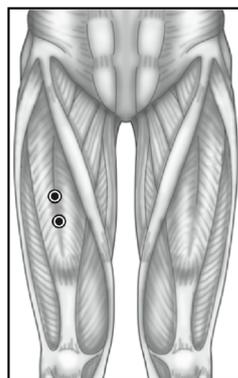


Figura 37 – Colocação dos eletrodos para aferição de sEMG sobre o músculo Reto Femoral (CRISWELL, 2011).

A análise cinemática do joelho foi realizada através de dois sensores inerciais. Estes foram posicionados na parte externa da coxa e da panturrilha direitas dos sujeitos, com o eixo  $Z$  dos sensores saindo da plano paralelo às pernas. A Figura 38 ilustra tal colocação. O protocolo de colocação dos sensores e detalhes acerca da análise cinemática realizada serão melhores discutidos nas Seções 3.4 e 4.1.

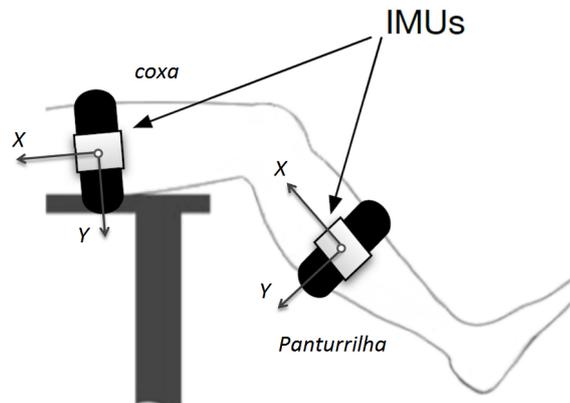


Figura 38 – Colocação dos sensores inerciais na parte externa da perna direita do usuário.

A frequência de amostragem do BrainNet<sup>®</sup> BNT-36 foi ajustada em 600 Hz e não foi utilizado filtro *Notch* na aquisição. Portanto, os sinais de EEG e sEMG foram adquiridos a 600 Hz.

Movimentos naturais de membros inferiores, como movimentos de marcha, são compostos por movimentos de frequência inferiores a 5 Hz (Yang, S. e Kong, 2009). A frequência de amostragem do sistema de sensores inerciais foi ajustada em 50 Hz, inerente à forma dos dados transmitidos: orientação na forma de matriz de cossenos diretores. Detalhes acerca desse tipo de dado serão abordados na próxima seção. Dessa forma, a frequência de amostragem é plausível para os movimentos dos membros inferiores executados nos experimentos realizados neste projeto, estes, abordados com detalhes na Seção 3.4.

Um *software* foi desenvolvido, na linguagem de programação C#, para integrar os dados dos sistema inercial com os dados do amplificador e condicionador de sinais biológicos. Esse programa foi desenvolvido a partir do ambiente de programação *Visual Studio*<sup>®</sup>. A partir desse programa é possível aferir as impedâncias relativas às conexões do canais, configurar as frequências de aquisição do BrainNet<sup>®</sup> BNT-36, ajustar as frequências de seus filtros, ligar ou desligar o filtro para eliminação de artefatos da rede elétrica e configurar o tipo de referência utilizada nos canais. Também é possível ajustar a frequência de aquisição do sistema Tech-MCS<sup>®</sup> e o tipo de dados que são transmitidos, entre vetor de quatérnions ou matriz de cossenos diretores, este último, utilizado neste trabalho. A parte de transmissão, recepção e estruturação dos dados é realizada por duas bibliotecas<sup>2</sup>

<sup>2</sup> Biblioteca é uma coleção de subprogramas utilizados no desenvolvimento de um programa maior.

desenvolvidas que se comunicam diretamente com o BrainNet<sup>®</sup> BNT-36 e o Tech-MCS<sup>®</sup>, respectivamente, *LibBN* e *LibTN*. Toda interface gráfica, i.e., controle de mensagens, botões, salvamento de dados, início e fim de captura de dados são realizados pelo programa principal *Multimodal*. A Figura 39 ilustra sua arquitetura de construção do *software*.

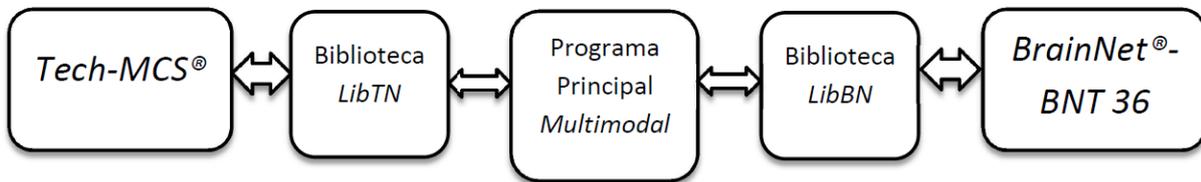


Figura 39 – Fluxograma que ilustra a arquitetura de construção do *software* de aquisição de dados.

A Figura 40 ilustra os passos desempenhados no seu funcionamento.

O programa desenvolvido manda e recebe os pacotes de dados do BrainNet<sup>®</sup> BNT-36 através de *sockets*<sup>3</sup> ao mesmo tempo em que se comunica com o sistema Tech-MCS<sup>®</sup>, a partir de uma biblioteca para desenvolvimento fornecida pelo fabricante deste sistema. A codificação dos pacotes de dados de transmissão e recepção do BrainNet<sup>®</sup> BNT-36 foi obtida a partir da documentação do projeto deste dispositivo junto ao seu fabricante e analisada através de programas do tipo *Sniffers*<sup>4</sup>. Os dados de ambos os sistemas são transmitidos *online* e o fluxo é controlado através de *Threads*.<sup>5</sup>

A Figura 41 mostra a interface gráfica desse *software*, em que é possível observar a conexão do sistema de medida inercial através de uma porta comunicação USB, parte superior à esquerda, e a conexão de rede para o sistema de aferição dos sinais de EEG e sEMG, parte inferior à esquerda. À direita, na parte superior, é possível observar uma interface para verificação de que os sistemas estão conectados e estão transmitindo dados. Ainda na Figura 41, na parte inferior à direita, é possível observar a escala de impedâncias relativa às conexões dos eletrodos fornecida pelo programa durante a captura dos dados. Nessa parte, são mostradas todas as possíveis conexões aos eletrodos fornecidas pelo BrainNet<sup>®</sup> BNT-36.

---

Bibliotecas contêm código e dados auxiliares, que provêm serviços a programas independentes, o que permite o compartilhamento e a alteração de código e dados de forma modular.

<sup>3</sup> *Sockets* são interfaces locais, criadas e mantidas pelas aplicações, controladas pelos sistemas operacionais, através das quais os processos de aplicação podem tanto enviar como receber mensagens de outro processo de aplicação local ou remoto. São usadas para aplicações cliente/servidor.

<sup>4</sup> *Sniffers* são ferramentas constituídas de um software ou hardware e são capazes de interceptar e registrar o tráfego de dados em uma rede de computadores. Conforme o fluxo de dados que trafega na rede, podem capturar cada pacote e eventualmente decodificar e analisar o seu conteúdo de acordo com o protocolo definido

<sup>5</sup> *Thread* é uma forma de um processo dividir a si mesmo em duas ou mais tarefas que podem ser executadas concorrentemente. Uma *Thread* permite, por exemplo, que o usuário de um programa utilize uma funcionalidade do ambiente enquanto outras linhas de execução realizam outros cálculos e operações.

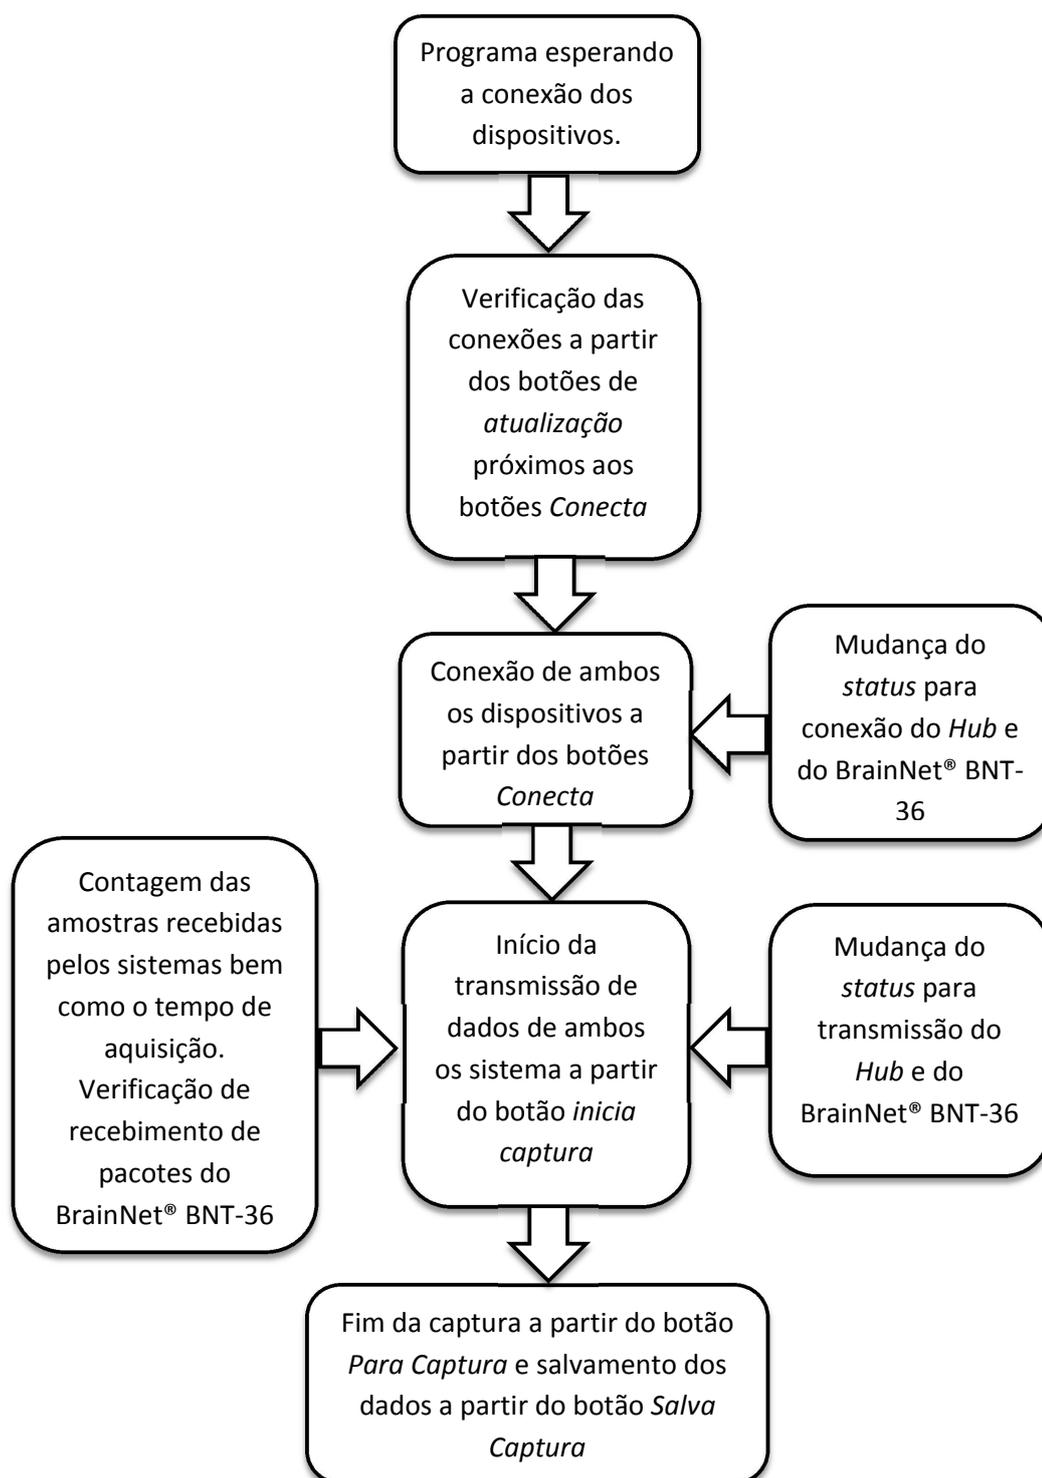


Figura 40 – Fluxograma que ilustra o funcionamento do *software* de aquisição de dados.

Na interface mostrada na Figura 41 também é possível observar que o programa conta as amostras de dados recebidas do BrainNet® BNT-36 e do Tech-MCS®, bem como o tempo de aquisição de dados de cada sistema separadamente. A partir desses tempos

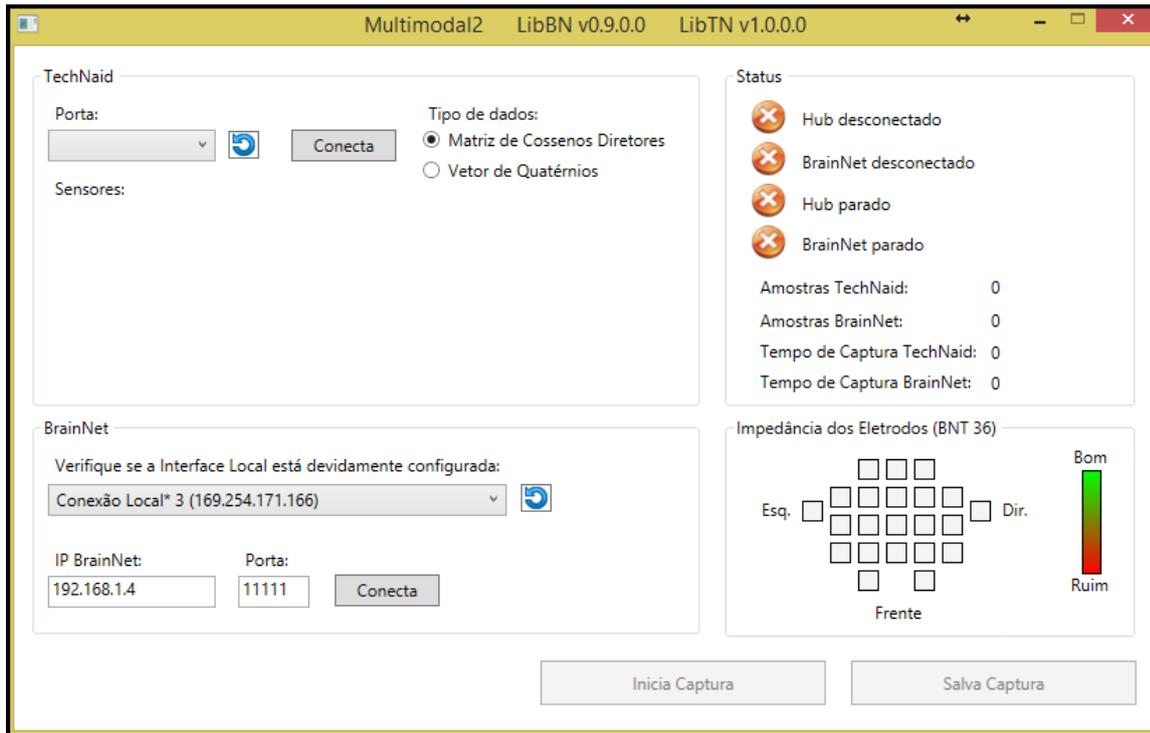


Figura 41 – Interface gráfica desenvolvida para o *software* de aquisição de dados de EEG, SEMG e de IMU.

é possível fazer a sincronia entre as amostras dos sistemas. Nessa etapa, como pode ser observado na Figura 40, o programa faz a verificação do sequenciamento dos pacotes recebidos para que não haja perda de pacotes, uma vez que o protocolo de transmissão de dados é o UDP<sup>6</sup>. Se houver perda de pacotes, o programa informa uma mensagem de erro e aborta a captura atual. Essa aplicação foi executada num computador com processador *Intel*<sup>®</sup> *Core i7*, com 8 GB de memória RAM e validada experimentalmente a partir de sinais de testes conhecidos fornecidos pelos sistemas BrainNet<sup>®</sup> BNT-36 e capturas de dados controladas através das quais sabe-se de antemão, através de goniômetros,<sup>7</sup> os valores inerentes ao sistema Tech-MCS<sup>®</sup>. A forma como os dados são sincronizados e salvos para serem processados será discutida na seção seguinte.

A partir desse ponto, começa uma outra etapa de processamento dos dados da interface multimodal proposta neste trabalho.

<sup>6</sup> O *User Datagram Protocol* (UDP) é um protocolo simples da camada de transporte, permite que a aplicação escreva um datagrama encapsulado num pacote IPv4 ou IPv6, e então enviado ao destino. Mas não há qualquer tipo de garantia que o pacote irá chegar ou não. Caso garantias sejam necessárias, é preciso implementar uma série de estruturas de controle, tais como timeouts, retransmissões, acknowledgments, controle de fluxo, etc. Também pode-se dizer que o UDP é um serviço sem conexão, pois não há necessidade de manter um relacionamento longo entre cliente e o servidor. Assim, um cliente UDP pode criar um socket, enviar um datagrama para um servidor e imediatamente enviar outro datagrama com o mesmo socket para um servidor diferente.

<sup>7</sup> Goniômetro é um instrumento de medida em forma semicircular ou circular graduado utilizado para medir ou construir ângulos.

Como o escopo deste trabalho se insere numa análise de viabilidade geral, a partir de dados de pessoas saudáveis, programas desenvolvidos a partir da plataforma MATLAB<sup>®</sup> fazem uma análise *offline* dos dados adquiridos a partir dos meios descritos até este ponto. Dessa forma, todo o processamento dos dados após a aquisição é feito de forma *offline*.

A Figura 42 representa a plataforma proposta. Nela é possível observar a integração dos sinais de EEG e sEMG adquiridos pelo BrainNet<sup>®</sup> BNT-36 e os sinais das IMUs adquiridos pelo sistema Tech-MCS<sup>®</sup>. Todos esses dados são salvos em um computador, sincronizados e processados. A sincronia dos dados é necessária pois, o programa integra dois sistemas que operam independentemente, então é preciso identificar instantes de tempo inerentes às amostras tanto do BrainNet<sup>®</sup> BNT-36 quanto às amostras do Tech-MCS<sup>®</sup>, isto é, fazer a sincronia dos dados de EEG e sEMG, que já estão sincronizados pois vêm de um sistema único, com os dados das IMUs. Este assunto será abordado na próxima seção.

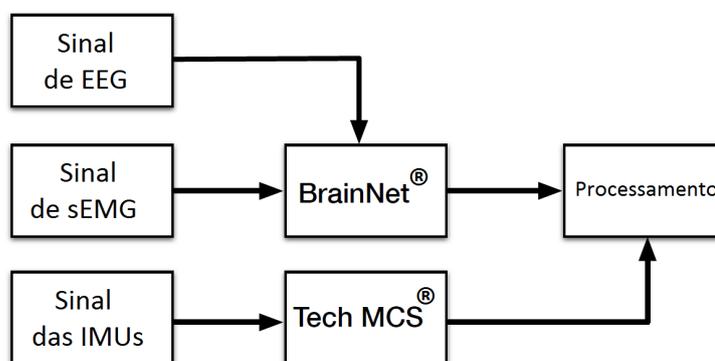


Figura 42 – Diagrama de blocos que representa o sistema composto proposto, evidenciando a fonte, a forma de aquisição e o processamento dos dados.

### 3.3.2 Sincronismo dos dados

Após a aquisição dos dados, o programa salva arquivos de texto com os dados relativos aos sinais do BrainNet<sup>®</sup> BNT-36, i. e., potenciais inerentes ao EEG e sEMG, e os dados relativos ao Tech-MCS<sup>®</sup>, i. e., orientação espacial de cada sensor inercial utilizado em suas referências globais. A forma para que os sensores forneçam a orientação espacial foi configurada em *DCM* (Matrizes de Cossenos Diretores do inglês *Direction Cosine Matrix*)<sup>8</sup>. O programa também salva um outro arquivo de texto com informações acerca da aquisição de dados realizada, e.g., data da aquisição, hora do salvamento do arquivo, frequência de amostragem de cada sistema e o tempo em que a primeira amostra da dados de cada sistema foi recebida a partir do momento em que se iniciou a captura de dados.

<sup>8</sup> Matrizes de Cossenos Diretores são matrizes formadas por vetores que representam os cossenos dos ângulos de um vetor em relação aos eixos coordenados  $X$ ,  $Y$  e  $Z$

O sincronismo de dados entre sistemas que operam separadamente pode ser feito de forma a se identificar um tempo que seja relativo à uma amostra específica em cada sistema e, então, descartar amostras até este tempo e alinhar as amostras para que sejam processadas. Este processo é ilustrado na Figura 43. Nela, o referido tempo é ilustrado por  $Tr$ . Esse processo é utilizado na sincronia dos dados dos sistemas utilizados neste trabalho e será explicado a seguir.

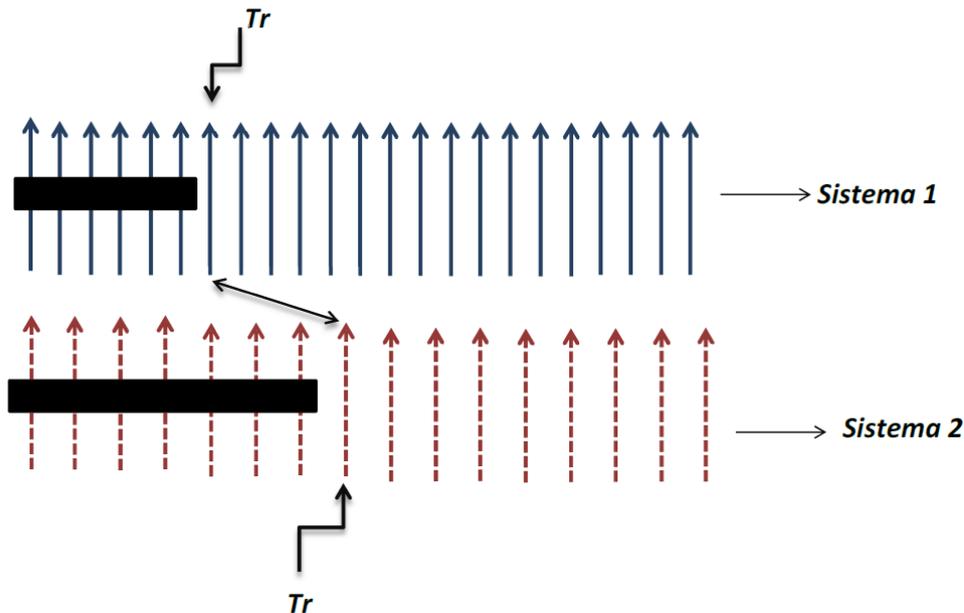


Figura 43 – Ilustração da sincronia de dados entre dois sistemas

A Figura 44 ilustra as amostras de dados de cada sistema sob uma linha de tempo. O tempo referente a  $0\text{ ms}$  para a interface desenvolvida acontece quando o botão *Iniciar Captura* é acionado. As amostras de dados do BrainNet<sup>®</sup> BNT-36 começam a chegar antes das amostras do Tech-MCS<sup>®</sup>, pois este passa primeiro pelo processo de calibração dos sensores e então, começa a transmitir suas amostras.

Como a frequência de amostragem do sistema inercial foi configurada em 50 Hz, o tempo entre duas amostras consecutivas deste sistema é de  $20\text{ ms}$ . O período das amostras do amplificador e condicionador de sinais é de  $1,667\text{ ms}$ , uma vez que a frequência de amostragem deste sistema foi configurada para 600 Hz. No entanto, estes dados são transmitidos através da rede sob o protocolo UDP, então, eles vêm em pacotes, cada um contendo 20 amostras de dados, aproximadamente, a cada  $33,33\text{ ms}$ , como pode ser observado na Figura 44. Nesta, o tempo  $T1$  representa o instante em que a primeira amostra do BrainNet<sup>®</sup> BNT-36 foi recebida e  $T2$  o instante em que a primeira amostra do Tech-MCS<sup>®</sup> foi recebida.

O sincronismo dos dados é feito retirando-se todas as amostras do BrainNet<sup>®</sup> BNT-36 até o instante em que a primeira amostra do sistema inercial é recebida. A partir

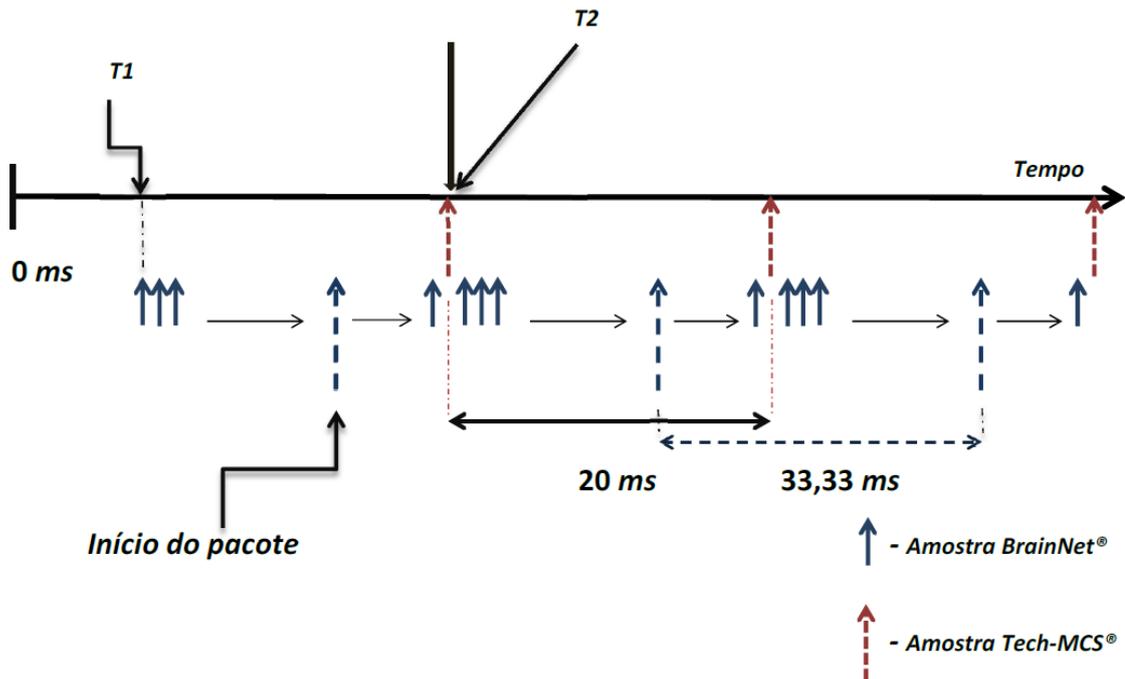


Figura 44 – Ilustração das amostras de dados dos sistemas em uma linha de tempo.

dos tempos e das frequências de amostragens salvas no arquivo de texto é possível fazer o cálculo da quantidade para o descarte dessas amostras. Então, o sistema assume um novo instante de início para processamento dos dados, o instante  $T3$ , que refere-se ao tempo de recebimento da primeira amostra do sistema inercial, como ilustrado na Figura 45.

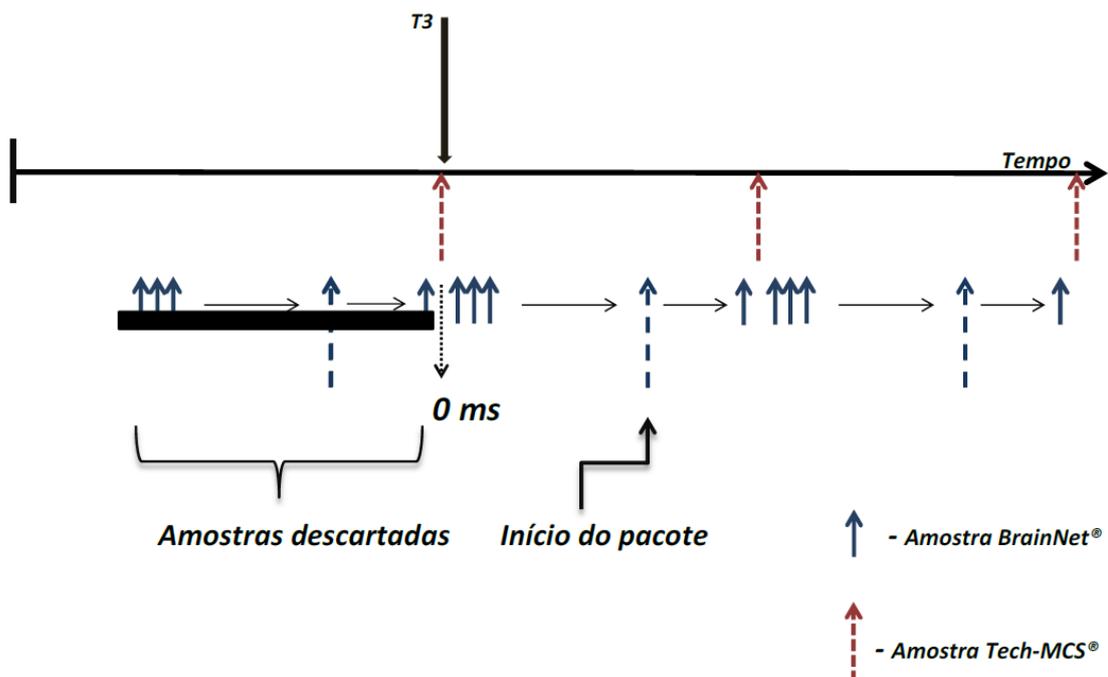


Figura 45 – Ilustração do descarte de amostras e da sincronia de dados.

Tempos inerente à transmissão e conversão de dados, bem como do processamento das rotinas de contagem de tempo pelo programa não foram levados em consideração, pois são da ordem de microsegundos. Considerou-se ainda que a porta USB funcionou com a mínima latência na comunicação de dados.

Ainda há que se observar que na retirada de amostras não há absoluta precisão para que as amostras de sistemas diferentes estejam exatamente no mesmo instante de tempo. Assume-se uma diferença máxima de, aproximadamente,  $1,667\text{ ms}$  no posicionamento relativo de duas amostras de sistemas distintos que estejam sincronizadas. Este valor é representado por  $T_s$  na Figura 46, valor do período de amostragem do BrainNet<sup>®</sup> BNT-36, considerado desprezível para as aplicações propostas. Assim, o método de sincronia proposto provê resolução temporal adequada às análises do escopo deste trabalho.

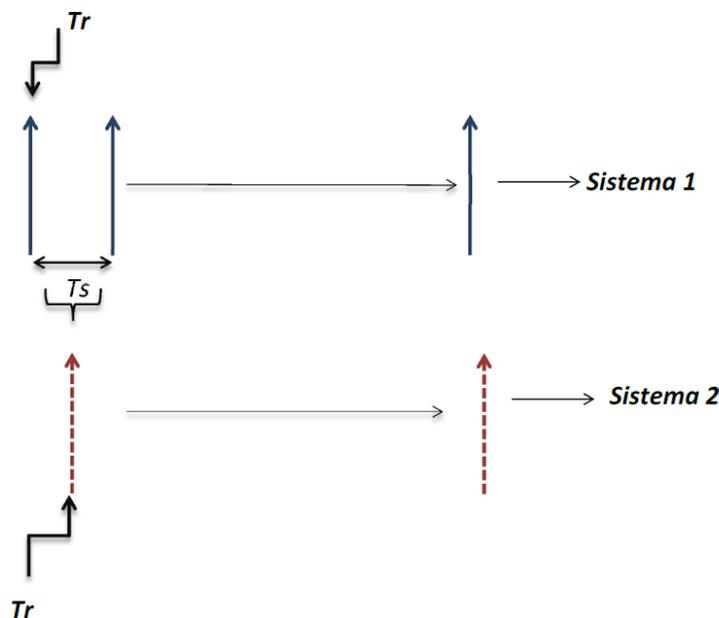


Figura 46 – Ilustração do posicionamento de amostras sincronizadas.

Uma vez que as amostras dos sistemas estão sincronizadas realizou-se a interpolação dos dados do sistema inercial. A aquisição de dados deste sistema foi realizada a  $50\text{ Hz}$ , valor inerente ao tipo de dado transmitido, as matrizes de cossenos diretores. Esse tipo de dado é de fácil manipulação para operações de mudança de referencial espacial, translações e rotações, por isso foi escolhido. Com o intuito de termos a mesma quantidade de amostras para os dois sistemas para melhor manipulação, processamento dos dados e para termos uma melhor resolução espacial a partir do sistema inercial optou-se pela interpolação destes dados.

Uma interpolação linear entre as amostras foi realizada. A diferença entre duas amostras consecutivas é obtida e igualmente distribuída entre amostras criadas, que terão o valor da amostra anterior mais a porção da diferença, até que os dados do sistema inercial

tenham a mesma quantidade de amostras do amplificador de sinais biológicos. A Figura 47 ilustra o processo. Nela, as amostras  $A1$  e  $A2$  representam amostras adquiridas e as amostras entre estas são as amostras linearmente interpoladas.

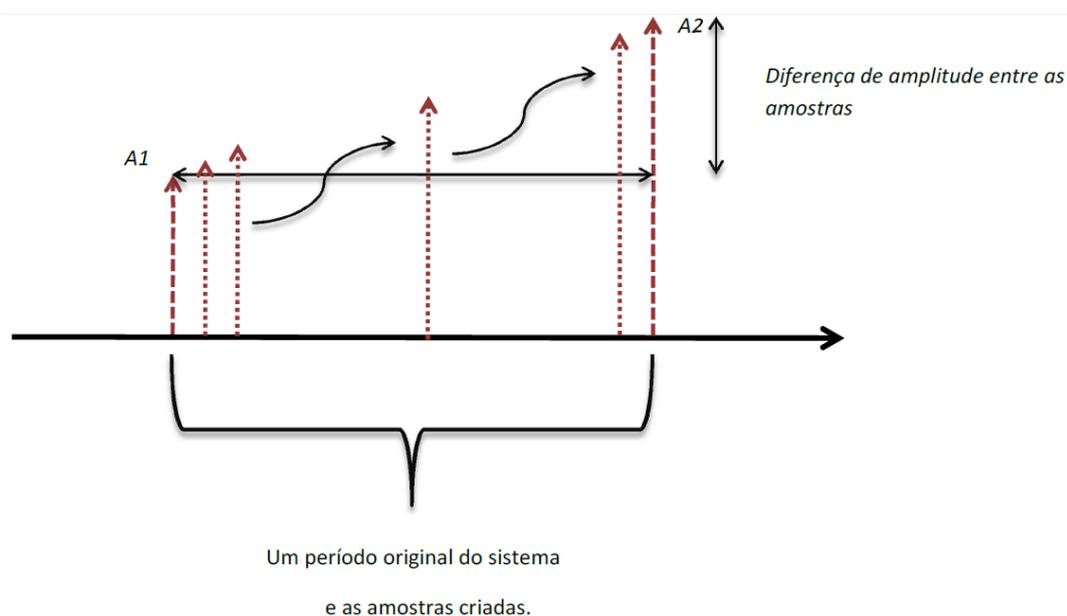


Figura 47 – Interpolação linear das amostras do sistema Tech-MCS®.

A Figura 48 mostra um diagrama que representa a aquisição e o processamento dos dados. Após a interpolação dos dados do sistema inercial, os dados de EEG, sEMG e IMU são separados e processados. As técnicas utilizadas para o processamento desses sinais a partir deste ponto serão abordadas no Capítulo 4.

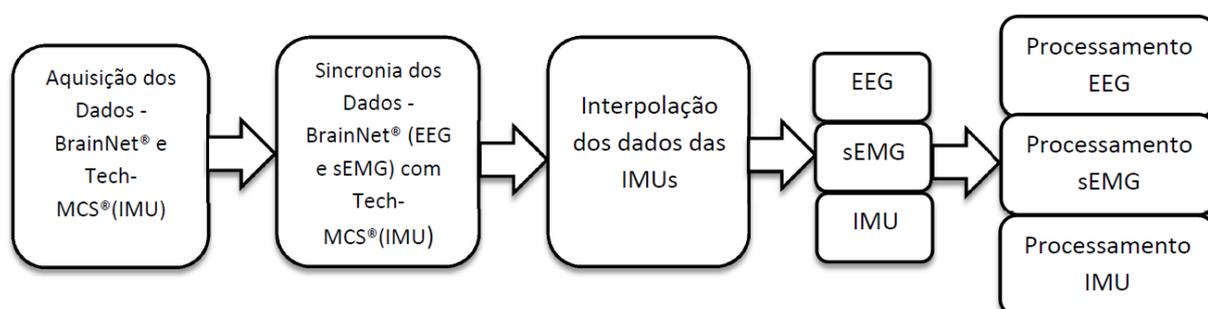


Figura 48 – Diagrama que representa a aquisição o pré-processamento dos dados.

A próxima seção descreverá o protocolo experimental de testes proposto.

### 3.4 Protocolo Experimental de Testes

Quatro indivíduos do sexo feminino e um do sexo masculino, destros e com idades entre 18 e 25 anos realizaram os experimentos. Durante a sessão experimental os sujeitos estavam confortavelmente sentados com as mãos relaxadas sobre as pernas e com os pés suspensos, sem tocar o chão. O ângulo suposto no início do experimento entre a coxa e a panturrilha foi de 90°. A calibração do sistema inercial ocorre nessa posição. Um sinal sonoro indica o final da calibração e o início do experimento. Após, aproximadamente, 10 segundos outro sinal sonoro indica que o sujeito pode realizar, no momento em que desejar, o movimento de extensão e flexão do joelho, utilizando ambas as pernas, desde a posição inicial até a máxima extensão. Esse movimento dura aproximadamente 3 segundos. A Figura 49 ilustra uma pessoa em posição inicial com eletrodos fixados em fase de calibração dos sensores.

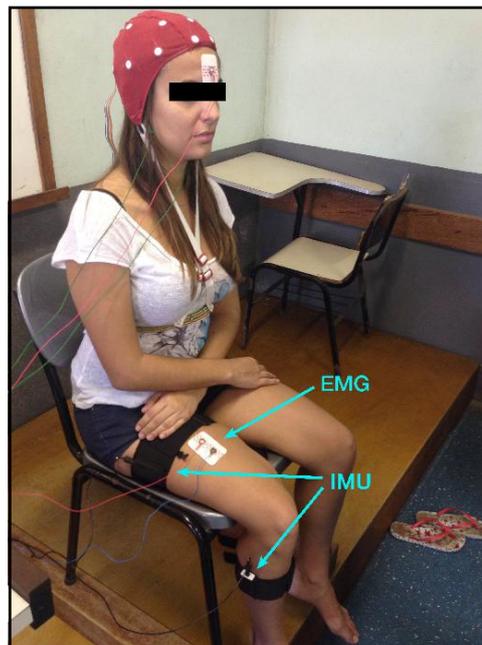


Figura 49 – Usuário vestindo os sensores durante uma sessão de experimentos.

Na Figura 49, é possível observar a pessoa com os sensores inerciais posicionados na parte externa da coxa e da panturrilha direitas, os eletrodos para aferição do sinal de sEMG sobre o músculo Reto Femoral e o gorro para aquisição dos sinais de EEG.

O protocolo de posicionamento não requer uma localização específica ou qualquer alinhamento na colocação dos sensores inerciais. O alinhamento entre esses sensores é realizado virtualmente no processamento dos dados e será tratado na Seção 4.1.

Assumi-se que a coxa permaneceu imóvel, pois estava em cima de uma superfície plana e rígida, e houve somente o movimento da panturrilha durante a tarefa. O examinador do experimento solicita que a pessoa realize o movimento normalmente e que mantenha os

olhos abertos, evitando piscar e engolir. Cada experimento foi composto por 30 repetições ou *trials* de extensão e flexão dos joelhos e cada repetição dura, aproximadamente, 30 segundos, incluindo esperar o segundo sinal sonoro, realizar o movimento e o descanso. Uma representação gráfica de uma repetição do movimento pode ser vista na Figura 50.



Figura 50 – Representação gráfica de uma repetição de movimento.

A Figura 50 ilustra graficamente os passos de uma repetição de movimento realizada nos experimentos. Como pode ser visto, existe um período de tempo dependente do sujeito antes do movimento voluntário e depois do segundo sinal sonoro. Também pode ser observado entre os segundos 5 e 8 um período denominado como linha-base ou *baseline*. A linha-base é um período durante a repetição do movimento no experimento em que o sujeito não se move, tampouco tem a intenção de fazê-lo. Os dados dos sinais na linha-base são utilizados para serem comparados com dados enquanto o sujeito se movimenta, ou tem a intenção de se movimentar, pelos classificadores em razão da intrínseca diferença entre tais momentos que propiciam a diferenciação dos padrões nos sinais. A classificação dos sinais de EEG, EMG e IMU será tratada no Capítulo 4.

O protocolo experimental de testes proposto neste Projeto de Pesquisa foi embasado nas tarefas propostas nos protocolos utilizados por [Kirchner, Tabie e Seeland \(2014\)](#), [Ibanez et al. \(2013\)](#), [Gallego et al. \(2012\)](#) e adaptado para os sistemas de aquisição de dados utilizados neste trabalho. Ressalta que a aquisição dos sinais biológicos foi realizada com os sujeitos descansados e que a influência do esforço muscular ao longo das repetições de um experimento foi considerado desprezível nos sinais de sEMG.

Ressalta-se ainda que este trabalho tem aprovação do Comitê de Ética em Pesquisa do Centro de Ciências da Saúde da Universidade Federal do Espírito Santo através do projeto de pesquisa 214/10.

O próximo capítulo tratará das técnicas de processamento dos sinais de EEG, EMG e das IMUs utilizadas.



## 4 Processamento dos Sinais

### 4.1 Processamento dos Sinais dos Sensores Inerciais

O sinais provenientes dos sensores inerciais (IMUs) foram utilizados para detectar o início do movimento, i.e., o começo do deslocamento efetivo do membro inferior para cada repetição de movimento realizada nos experimentos e para medir os ângulos do joelho durante a tarefa proposta no protocolo experimental. Ambos os procedimentos serão explicados a seguir, primeiro o procedimento para medição dos ângulos e então, o procedimento para a detecção de início do movimento.

#### 4.1.1 Medição de ângulos do joelho

As três rotações que ocorrem em movimentos naturais no joelho são flexão/extensão, abdução/adução e rotação interna/externa (FAVRE et al., 2009). A Figura 51 ilustra tais movimentos.

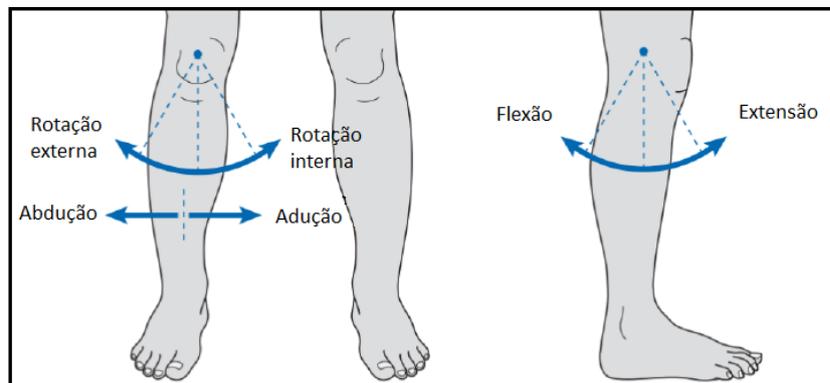


Figura 51 – Movimentos de rotação relativos ao joelho. Adaptado de WHITTLE (2008).

Pode-se usar um modelo baseado em segmentos para representar a perna (??). A Figura 52 ilustra tal representação, na qual a coxa e a panturrilha podem ser representadas pelos seguimentos (1) e (2), respectivamente. Os movimentos de flexão/extensão, abdução/adução e rotação interna/externa podem ser representados pelos ângulos  $\beta$ ,  $\gamma$  e  $\alpha$ , respectivamente. O ângulo  $\beta$  é medido no sentido horário e tem seu valor em  $0^\circ$  quando os segmentos estão alinhados paralelamente, como mostrado na mesma figura. Este ângulo está relacionado com o principal movimento realizado, de flexão/extensão, e é de principal interesse neste trabalho. Esse modelo será utilizado daqui em diante e a análise cinemática do joelho será realizada a partir da obtenção desses ângulos ao longo dos movimentos realizados. A forma como os ângulos foram obtidos será explicada a seguir.

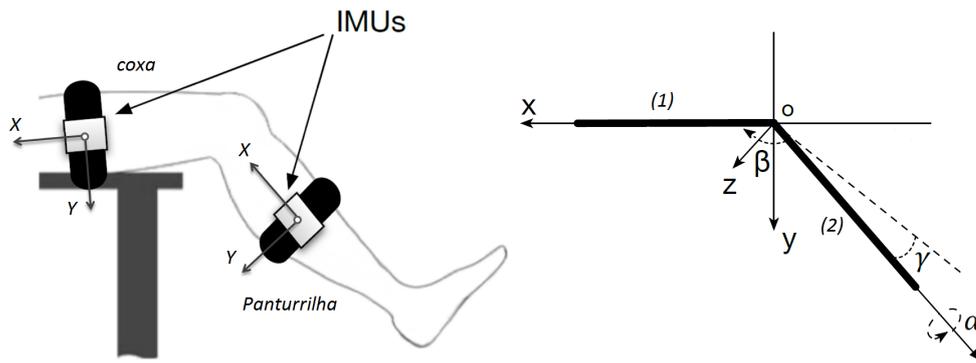


Figura 52 – Representação da perna através de segmentos e descrição dos ângulos relativos às rotações do joelho.

Como descrito na Seção 3.4, dois sensores inerciais foram posicionados na parte externa da perna direita do sujeito, um na coxa e outro na panturrilha, como ilustrado na Figura 52. O processamento dos dados realizado para a obtenção dos ângulos descritos anteriormente pode ser ilustrada através da Figura 53.

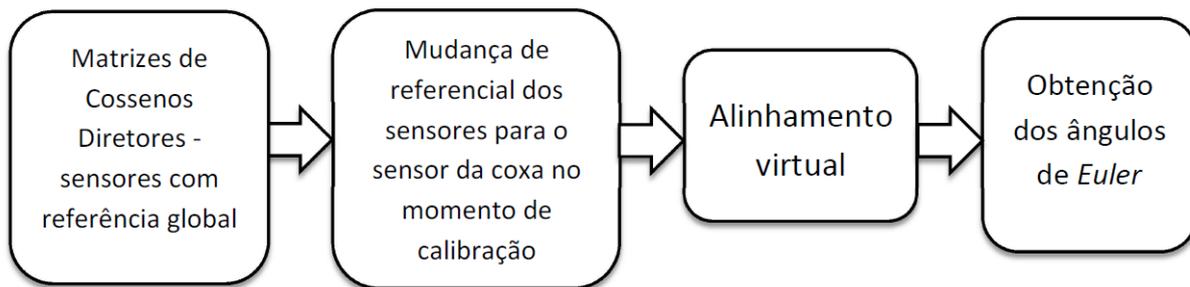


Figura 53 – Ilustração dos passos envolvidos no processamento para a obtenção dos ângulos do joelho.

Os sensores inerciais foram configurados para fornecerem a representação espacial através de matrizes de cossenos diretores (DCM). Os dados de representação espacial chegam à interface multimodal em relação à referência global dos sensores, como mostrado no primeiro bloco da Figura 53. Como os ângulos do joelho são os ângulos relativos entre os segmentos (1) e (2) da Figura 52, precisa-se medir os ângulos relativos entre os sensores da coxa e da panturrilha. Para tanto, a referência do sensor da panturrilha foi transformada de sua referência global para a orientação do sensor da coxa, como ilustrado no segundo bloco da Figura 53. Essa operação é representada pela Equação 4.1.

$$M_{pc} = M_c^{-1} M_p \quad (4.1)$$

$M_{pc}$  representa a DCM do sensor da panturrilha referenciada ao sensor da coxa,

$M_c$  e  $M_p$  representam as DCMs dos sensores da coxa e da panturrilha, respectivamente, com suas referências globais originais. A partir dos valores de  $M_{pc}$  é possível obter os ângulos relativos entre os sensores e, conseqüentemente, os ângulos do joelho. No entanto, os valores obtidos em  $M_{pc}$  são totalmente dependentes da posição em que os sensores são colocados na perna do usuário.

Com o objetivo de propor um protocolo de colocação dos sensores inerciais que forneça valores corretos e que seja independente da posição de colocação, um alinhamento virtual dos sensores é proposto, como ilustrado na Figura 53 e explicado a seguir.

Tal procedimento foi desenvolvido baseado nos estudos de Melim (2013) que abordam medições de ângulos das articulações com respeito aos planos que dividem o corpo humano<sup>1</sup>. Como descrito na Seção 3.4, a calibração dos sensores inerciais é realizada com o usuário sentado e com o pé suspenso, sem tocar o chão. Nesse momento, foi considerado que o ângulo de flexão/extensão do joelho é de  $90^\circ$ , i.e., a coxa e a panturrilha estão a  $90^\circ$  uma da outra. Também foi considerado não haver rotação interna/externa, tampouco adução/abdução nesse momento. Conseqüentemente, os sensores da coxa e da panturrilha foram assumidos alinhados no eixo  $Z$  e possuem um ângulo igual a  $90^\circ$  entre seus eixos  $Y$  e  $X$ , quando a calibração do sistema inercial ocorre. Como a colocação manual dos sensores não garante essa configuração, um sensor virtual foi criado para que tal posicionamento seja alcançado. A Figura 54 ilustra o procedimento.

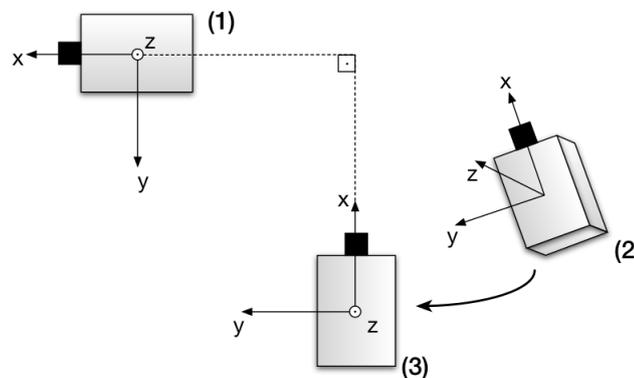


Figura 54 – Ilustração do procedimento de alinhamento virtual.

Na Figura 54, (2) ilustra o sensor real da panturrilha, colocado sem alinhamento, (3) representa um sensor virtual alinhado de acordo com as suposições feitas e (1) ilustra o sensor da coxa. O sensor virtual foi criado pela rotação do sensor da coxa em  $-90^\circ$  em

<sup>1</sup> Os planos que dividem o corpo humano no contexto dos movimentos anatômicos são Sagital, que corta o corpo humano verticalmente realizando uma divisão em duas partes iguais, direita e esquerda; Frontal ou coronal, que corta o corpo humano verticalmente realizando uma divisão em duas partes, anterior e posterior; Transversal ou horizontal, que corta o corpo humano horizontalmente realizando uma divisão em duas partes, superior e inferior. Para maiores informações acerca deste assunto, consulte Melim (2013)

torno do seu eixo  $Z$ . Para que a colocação dos sensores seja independente da posição, é preciso que a diferença entre a posição real do sensor da panturrilha e a posição do sensor virtual seja conhecida. Para tanto, fez-se a DCM do sensor real da panturrilha referenciada em relação ao sensor virtual. Essa operação é realizada através da Equação 4.2.

$$A = (RzMcC)^{-1}B \quad (4.2)$$

Na Equação 4.2,  $A$  representa a DCM do sensor real da panturrilha referenciada ao sensor virtual no momento de calibração do sistema,  $McC$  representa o sensor da coxa referenciado a ele próprio, ou seja, uma matriz identidade e  $Rz$  a matriz de rotação em torno do eixo  $Z$ , descrita pela Equação 4.3, com  $\psi = -90^\circ$ .  $B$  é a DCM do sensor real da panturrilha referenciado ao sensor da coxa no momento de calibração.

$$Rz(\psi) = \begin{bmatrix} \cos(\psi) & -\sin(\psi) & 0 \\ \sin(\psi) & \cos(\psi) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (4.3)$$

Para que o alinhamento seja realizado, a diferença entre o sensor virtual e o sensor real da panturrilha, que está contida em  $A$ , é aplicada ao sensor real da panturrilha ao longo do experimento. Dessa forma, é como se os sensores fossem posicionados de acordo com a suposição realizada. Esse passo é representado pela Equação 4.4.

$$C = Mpc(A)^{-1} \quad (4.4)$$

Na Equação 4.4,  $C$  representa a DCM do sensor da panturrilha alinhado com o sensor da coxa no momento da calibração, como suposto no protocolo e  $Mpc$  a DCM do sensor real da panturrilha referenciado ao sensor da coxa ao longo do experimento.

Ressalta-se que a referência utilizada em ambos os sensores neste ponto do processamento é a orientação do sensor da coxa no momento de calibração. Supõe-se que não há movimento na coxa durante a tarefa realizada, somente movimento da panturrilha. Tal consideração é feita pois, como já mencionado, a coxa está apoiada sobre uma superfície plana e rígida. Então, toda a referência foi baseada na orientação do sensor da coxa no momento de calibração.

Os dados da DCM  $C$  foram então convertidos em ângulos de *Euler*, como descrito no último bloco da Figura 53, para que o movimento do joelho pudesse ser representado em todos os eixos, ou seja, os ângulos  $\beta$ ,  $\gamma$  e  $\alpha$ , representados na Figura 52, pudessem ser obtidos. A obtenção dos ângulos de *Euler* é realizada através das Equações 4.5, 4.6, 4.7 e 4.8.

$$M = \begin{bmatrix} a & b & c \\ d & e & f \\ j & k & l \end{bmatrix} \quad (4.5)$$

$$\alpha = \arctan\left(\frac{M(2,3)}{M(3,3)}\right) \quad (4.6)$$

$$\gamma = \arcsin(-M(3,1)) \quad (4.7)$$

$$\beta = \arctan\left(\frac{M(2,1)}{M(1,1)}\right) \quad (4.8)$$

A Equação 4.5 mostra uma matriz de cossenos diretores genérica. Os ângulos de *Euler*, que representam rotações sucessivas em torno dos eixos  $X$ ,  $Y$  e  $Z$ , conhecidos como *Roll*, *Pitch* e *Yaw*, respectivamente, podem ser definidos pelas Equações 4.6, 4.7 e 4.8, também respectivamente.

Com isso, tem-se um protocolo de medição de ângulos do joelho apenas a partir de dois sensores inerciais que são independentes da colocação. Para a minimização dos erros decorrentes do procedimento proposto, um outro sistema de medida pode ser usado para que as suposições acerca do posicionamento das pernas no momento de calibração sejam de fato alcançadas. No entanto, isso envolveria a utilização de um outro sistema de análise cinemática, e.g., sistema de visão computacional, que tornaria o procedimento menos portátil e mais dependente de outros mecanismos, pela utilização de câmeras, *lasers* ou outros dispositivos.

A seguir, será explicado o procedimento realizado na detecção do início efetivo do movimento.

#### 4.1.2 Detecção do início do movimento

A Figura 55 ilustra o procedimento utilizado para a detecção de início efetivo do deslocamento do membro inferior.

Como representado no primeiro bloco da Figura 55, os dados dos sensores inerciais chegam ao sistema como matrizes de cossenos diretores. Para que o início efetivo do deslocamento seja detectado, são obtidos os ângulos de *Euler* relativos ao sensor colocado na panturrilha com sua referência global. Então, um classificador de limiar, baseado no valor da média e do desvio padrão do ângulo *Yaw*, obtidos na linha-base (*baseline*), enquanto não há movimento, avalia o deslocamento. O ângulo *Yaw* refere-se ao principal movimento realizado pelo joelho, a flexão/extensão, e foi observado que o deslocamento deste ângulo é, naturalmente, mais expressivo e ocorre antes que o dos outros ângulos, por

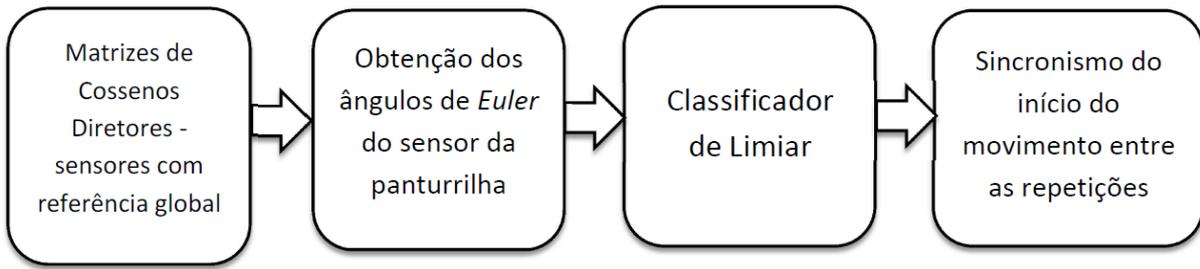


Figura 55 – Ilustração dos passos envolvidos no processamento para a detecção do início do movimento.

isso foi avaliado para detecção do início do movimento. Classificação de limiar análoga à descrita foi utilizada em (IBANEZ et al., 2013) para aplicação semelhante. A Equação 4.9 descreve o classificador de limiar.

$$T(t)_N = m(t)_N + pd(t)_N \quad (4.9)$$

Na Equação 4.9,  $T$  é o limiar,  $m$  é a média,  $d$  o desvio padrão e  $p$  um peso dado ao desvio padrão para o discernimento do classificador entre a região de ruído e o real aumento do sinal.  $N$  é o número de amostras que foram utilizadas em uma janela para o cálculo da média e do desvio padrão. Além dos parâmetros  $p$  e  $N$ , uma quantidade de amostras de sobreposição entre as janelas calculadas e uma quantidade de janelas acima do limiar também foram analisadas para que o classificador pudesse classificar o início do movimento. Naturalmente, a classificação de início de movimento é remetida à primeira amostra dessas janelas acima do limiar. Após uma procura por esses parâmetros para que sejam minimizadas as classificações por ruídos, que seriam falsos positivos, ou classificações atrasadas, para cada sujeito por experimento, toma-se o tempo da primeira amostra da janela que o classificador detecta e considera-se este como início efetivo do movimento. Os parâmetros encontrados variam por experimento e por sujeito.

O último bloco da Figura 55 refere-se ao sincronismo entre as repetições de cada experimento. Como dito na Seção 3.4, cada experimento é composto de 30 repetições do movimento de flexão e extensão do joelho. Como o sujeito realiza os movimentos quando deseja, dentro uma janela de tempo, é preciso sincronizar os momentos em que o movimento foi iniciado entre as repetições para que possam ser realizados processamentos que envolvam dados de várias repetições, e.g., a observação do ERD/ERS (PFURTSCHELLER, 1999) descrito na Seção 2.1.

A Figura 56 ilustra esse procedimento, em que as setas representam as amostras de duas repetições de um experimento. A amostra da **Repetição 1** classificada como início do movimento foi identificada no tempo  $T_{mov1}$ . A amostra da **Repetição 2** classificada

como início do movimento foi identificada no tempo  $T_{mov2}$ . Na sincronia das repetições, a repetição em que foi detectado o movimento posterior foi deslocada à frente a quantidade de amostras relativas à diferença de tempo entre as detecções, representada por  $Dist$ , e essa mesma quantidade de amostras foi descartada no final do experimento sem perda de dados relevantes, como ilustrado na Figura 56. Esse procedimento foi aplicado a todas as repetições dos experimentos. Dessa forma, a sincronia do início do movimento foi realizada no tempo da repetição em que foi detectado o primeiro movimento. Portanto, em análises que envolvam detecção do momento de início de intenção de movimento, o tempo zero será considerado como o primeiro movimento do experimento detectado pelas IMUs. Então, como dito, características que contenham informações sobre todo o experimento, e.g., média de dados entre as repetições, podem ser processados e identificados temporalmente durante o experimento.

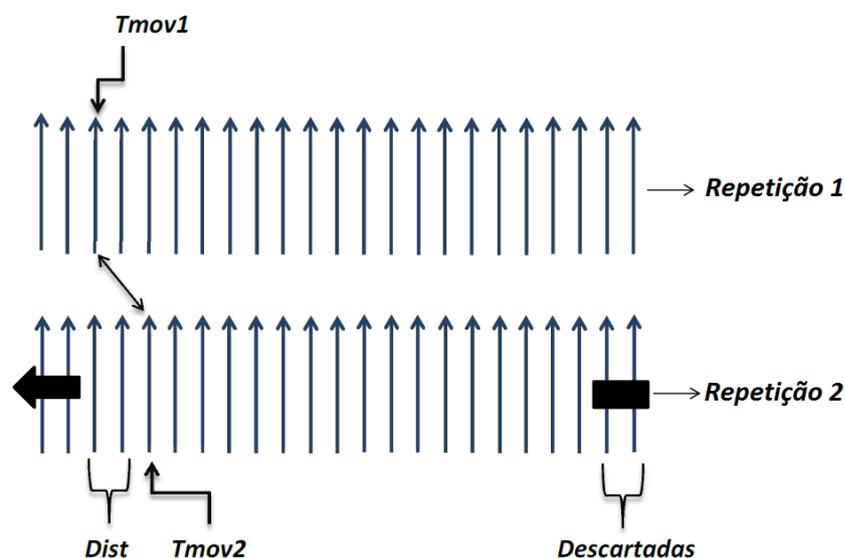


Figura 56 – Ilustração do sincronismo do início do movimento entre as repetições de um experimento.

## 4.2 Processamento do Sinal Eletromiográfico

O sinal de EMG foi utilizado para aferir a ativação muscular durante o experimento, com o objetivo específico de detectar o início da ativação muscular. A Figura 57 ilustra os passos realizados no processamento do sinal de eletromiografia de superfície (sEMG) para que pudesse ser obtido um valor de tempo com o qual o início da contração muscular fosse relacionado.

Como pode ser observado no primeiro bloco da Figura 57, o sinal de sEMG chega não processado (cru) ao sistema. O primeiro passo foi filtrá-lo com um filtro do tipo *Notch* para que artefatos devidos à rede elétrica pudessem ser eliminados. Nesta etapa, foram

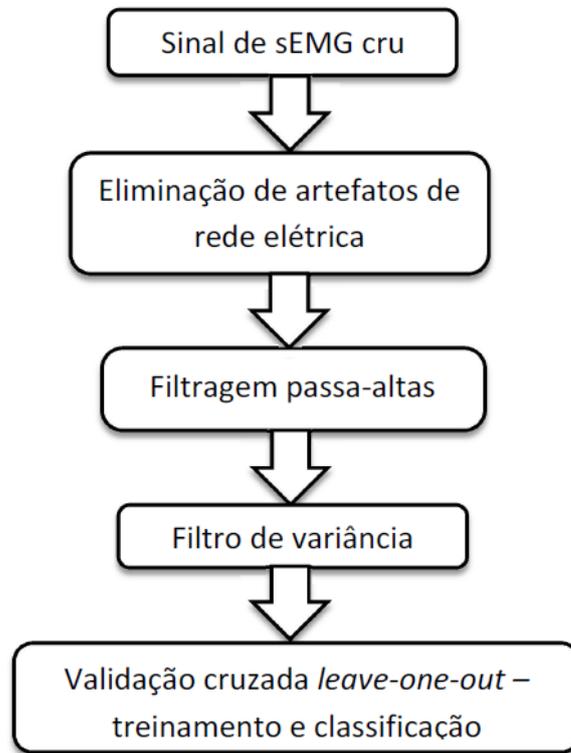


Figura 57 – Ilustração dos passos envolvidos no processamento do sinal eletromiográfico.

utilizados filtros *Notch* do tipo *Butterworth* de 4ª ordem com frequência de rejeição em 60 Hz e seus 3 primeiros harmônicos pois, após análise do espectro de frequências do sinal não processado, observou-se acentuada presença destas componentes.

O próximo bloco trata da filtragem em frequência em que se preservam as componentes inerentes ao sinal eletromiográfico do músculo Reto Femoral, a partir do qual foram feitas as aquisições do sinal, como descrito na Seção 3.4. Como recomendado por Hermens et al. (1999), foi realizada uma filtragem passa-altas com frequência de corte em 20 Hz e foi utilizado um filtro *Butterworth* de 4ª ordem, como em Novak et al. (2013). Lembra-se, neste ponto, que a frequência de aquisição do sinal de sEMG foi de 600 Hz.

O próximo passo no processamento foi a realização de uma filtragem no domínio do tempo através de um filtro de variância definido pela Equação 4.10.

$$v(t) = \frac{1}{N-1} \sum_{i=0}^N [x(t-i)]^2 - \left( \frac{1}{N-1} \sum_{i=0}^N x(t-i) \right)^2 \quad (4.10)$$

Na Equação 4.10,  $v$  refere-se ao sinal filtrado,  $N$  é o tamanho da janela de amostras usada na filtragem e  $x$  é o sinal de sEMG a ser filtrado. Essa filtragem foi proposta por Kirchner, Tabie e Seeland (2014) para finalidade semelhante à almejada neste projeto e tem como característica uma grande diferenciação entre os momentos de ativação muscular e não ativação, preservando o momento de ativação inicial, ao passo que elimina pequenas

variações, como ruídos. Tais características são desejadas neste projeto.

O sinal de sEMG filtrado foi, então, analisado por um classificador de limiar baseado nos valores de média e desvio padrão do sinal no momento em que não há ativação muscular, a linha-base descrita na Seção 3.4. Esse classificador é análogo ao classificador utilizado para detecção do início do movimento sobre os dados dos sensores inerciais e neste ponto é utilizado para a detecção do início da ativação muscular. A Equação 4.11 descreve novamente este classificador.

$$T(t) = m_N(t) + pd(t)_N \quad (4.11)$$

Assim como realizado para a Equação 4.9, na Equação 4.11  $T$  é o limiar,  $m$  é a média,  $d$  o desvio padrão e  $p$  um peso dado ao desvio padrão para o discernimento do classificador entre a região de ruído e o real aumento do sinal.  $N$  é o número de amostras que foram utilizadas em uma janela para o cálculo da média e do desvio padrão. Além dos parâmetros  $p$  e  $N$ , uma quantidade de amostras de sobreposição entre as janelas calculadas e uma quantidade de janelas acima do limiar também foram analisadas para que o classificador pudesse classificar o início da ativação muscular. Naturalmente, a classificação de início da ativação muscular é remetida à primeira amostra dessas janelas acima do limiar. Após uma procura por esses parâmetros para que sejam minimizadas as classificações por ruídos, que seriam falsos positivos, ou classificações atrasadas, para cada sujeito por experimento, toma-se o tempo da amostra que o classificador detecta e considera-se este como início da ativação muscular. Os parâmetros encontrados variam por experimento e por sujeito.

A Figura 58 ilustra a forma como o classificador de limiar utiliza o janelamento das amostras para realizar a análise dos sinais. Nela podem ser observadas as amostras do sinal

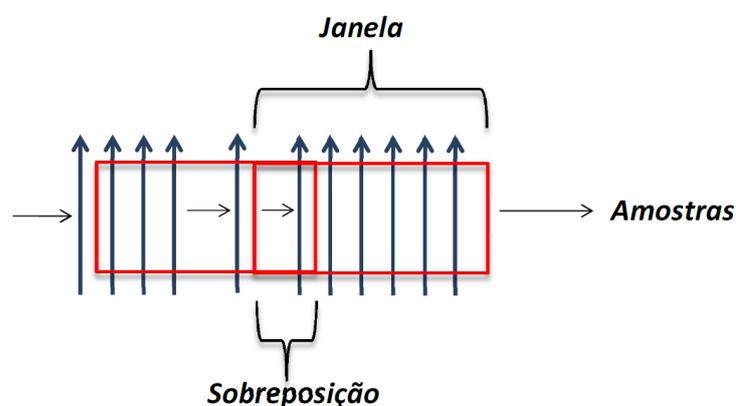


Figura 58 – Ilustração da forma como o classificador utiliza o janelamento para analisar as amostras do sinal.

e a janela utilizada para os cálculos. Pode ser observada também uma sobreposição entre

janelas consecutivas, de forma que uma certa quantidade de amostras possa pertencer a duas janelas consecutivas. Naturalmente, neste ponto há uma seleção adequada do tamanho da janela e da sobreposição, como mencionado anteriormente, que está relacionada ao custo de processamento demandado pelo sistema, inerente à quantidade de operações realizadas que são intrínsecas ao tamanho das janelas e à sobreposição utilizadas.

A procura pelos parâmetros que melhor equalizem o classificador, para treinamento e as classificações são realizadas através do procedimento de validação cruzada utilizando o método *Leave-one-out*, como citado na Figura 57.

O procedimento de validação cruzada utilizando o método *Leave-one-out* é ilustrado na Figura 59.

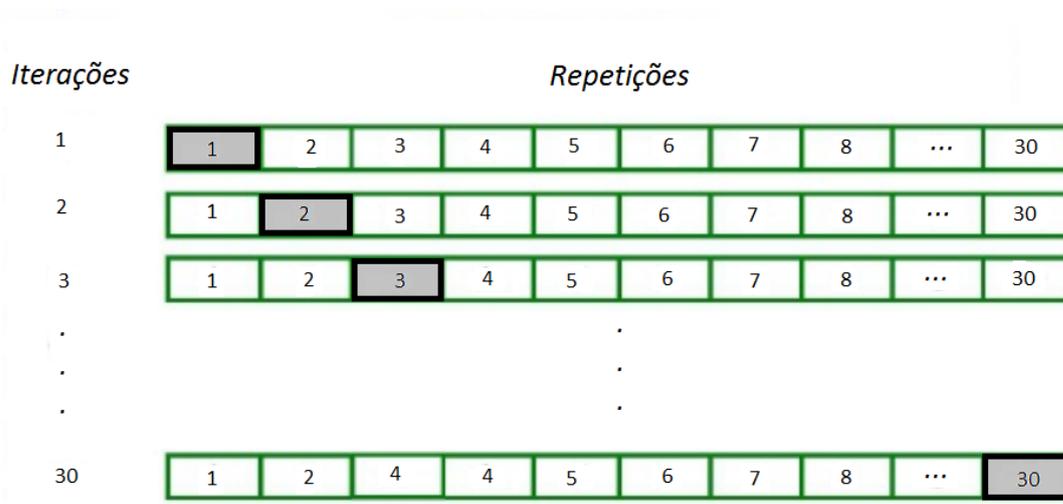


Figura 59 – Ilustração do processo de validação cruzada usando o método de *Leave-one-out*.

Na Figura 59, são ilustradas as 30 repetições de movimento realizadas em cada experimento e as iterações do processo de *Leave-one-out*. Esse procedimento tem por objetivo o treinamento e a validação dos parâmetros encontrados. Se há  $N$  amostras de dados disponíveis, treinam-se os parâmetros para que melhor classifiquem  $N - 1$  amostras e classifica-se a amostra de dados que ficou de fora. Esse procedimento é repetido  $N$  vezes, mudando a amostra de dados a ser classificada. No caso abordado neste trabalho, as amostras de dados são as 30 repetições disponíveis para cada experimento, como descrito na Seção 3.4. A correção do classificador está na detecção do início de ativação muscular em janelas de tempo, propostas pela bibliografia atual relacionada, ao longo das repetições do experimento. A atualização ou mudança dos parâmetros está relacionada à melhoria da correção do classificador a cada iteração. As janelas de tempo em que se espera que haja início de ativação muscular serão discutidas no Capítulo 5.

Ressalta-se que as filtragens em frequência foram realizadas utilizando a função *filtfilt* do MATLAB®. A função *filtfilt* realiza uma filtragem digital de fase zero, filtrando

em direção direta e inversa os dados. Isso só foi possível pois, o sistema realiza uma análise *offline* e os dados estão disponíveis a priori. Tal filtragem foi realizada para a certificação de que não haja distorções ao sinal filtrado que poderiam ser incorporadas relevantemente pela não linearidade de fase dos filtros *IIR*<sup>2</sup> utilizados. Assim, a análise temporal das características dos sinais torna-se mais precisa. Destaca-se que os filtros *Butterworth* apresentam uma resposta em fase mais linear na banda passante do que os filtros *Chebyshev* ou *elípticos* (Oppenheim, Alan V., Ronald W. Schafer; BUCK., 1999), de forma que também poderiam ser utilizados em aplicações *online*.

## 4.3 Processamento do Sinal Eletroencefalográfico

Os sinais de EEG foram utilizados para estimar a intenção de movimento do sujeito, i.e., detectar um tempo no qual o sujeito teve intencionalidade de se mover mesmo que o movimento ainda não tenha efetivamente começado. Duas abordagens foram utilizadas: a primeira, uma análise qualitativa, em que se leva em conta várias épocas do sinal de EEG, i.e., várias repetições de movimento, conhecida como abordagem *multi-trial*. Esta será explicada a seguir, e uma outra na qual apenas uma época do sinal, ou uma repetição do movimento, é necessária para se identificar a intencionalidade do movimento, com uma abordagem quantitativa acerca de acertos por parte dos classificadores, conhecida como abordagem *single-trial*. Esta será explicada na Seção 4.3.2.

### 4.3.1 Detecção de intenção de movimento utilizando-se várias épocas do sinal

A Figura 60 ilustra o procedimento realizado para a detecção de intenção de movimento baseado em várias repetições. Esse procedimento é conhecido como *método clássico* de observação das características de ERD/ERS, abordado na Seção 2.1, descrito por Pfurtscheller (1999).

Na Figura 60, é possível observar o primeiro bloco referente aos sinais de EEG, de todos os canais e repetições, que chegam não processados (*crus*) ao sistema para serem processados. Como esta abordagem requer dados de todos os movimentos realizados durante um experimento, perfaz uma abordagem totalmente *offline*.

Assim como no processamento do sinal de sEMG, o primeiro passo foi filtrar o sinal de EEG com um filtro do tipo *Notch* para que artefatos devidos à rede elétrica sejam eliminados. Nesta etapa foram utilizados filtros *Notch* do tipo *Butterworth* de 4ª ordem

<sup>2</sup> Filtros *IIR* são filtros de resposta ao impulso infinita do inglês *infinite impulse response*. Esse tipo de filtro é caracterizado, dentre outras peculiaridades, pela dificuldade de se alcançar um projeto de filtro com fase linear, ou atraso de grupo constante. Os principais filtros *IIR* são *Butterworth*, *Chebyshev*, *elíptico* e de *Bessel*. No entanto, há contrapontos positivos como a eficiência na implementação em termos de alcançar restrições acerca de bandas de rejeição, passagem, ondulações, etc... em comparação com os filtros de resposta finita ao impulso ou *FIR* (Oppenheim, Alan V., Ronald W. Schafer; BUCK., 1999).

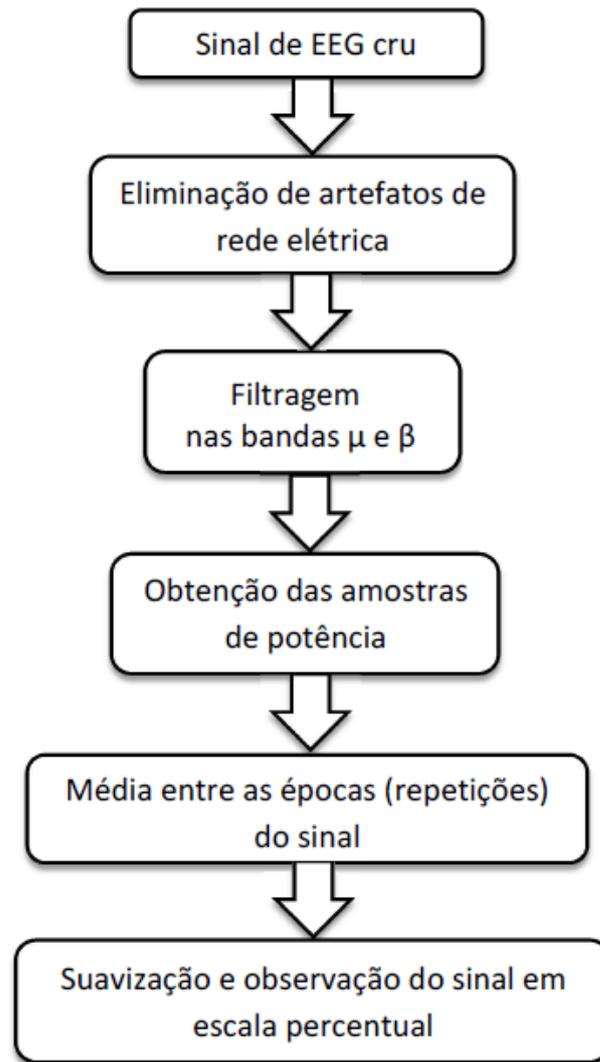


Figura 60 – Ilustração dos passos envolvidos no processamento para a detecção da intenção de movimento observada em várias épocas do sinal.

com frequência de rejeição em 60 Hz e seus 3 primeiros harmônicos pois, após análise do espectro de frequências do sinal não processado, observou-se acentuada presença destas componentes.

O próximo bloco trata da filtragem nas bandas em que ocorrem as características de ERD/ERS. Os sinais, nesta etapa, foram filtrados separadamente por filtros passa-banda *Butterworth* de 4ª ordem, como proposto por [Ibanez et al. \(2013\)](#) para uma aplicação semelhante à abordada neste trabalho, nas bandas  $\mu$  e  $\beta$ , respectivamente, dadas por 8-12 Hz e 14-30 Hz ([CHEEÍN, 2005](#)).

Após a filtragem, obtiveram-se as amostras de potência relativas aos sinais de cada canal e repetições analisados. Para tanto, elevam-se ao quadrado as amostras dos sinais.

A partir do sinal resultante dessa operação, fez-se a média, amostra-a-amostra, para

cada canal, entre as repetições dos sinais, de forma que haja apenas um sinal resultante para cada canal. Essa operação é realizada pois, o córtex motor, no lobo parietal, está cercado pelo lobos frontal, temporal e occipital e assim, os sinais gerados pelas áreas vizinhas se misturam aos sinais do córtex motor e os sinais de eletrodos localizados sobre este córtex contêm uma mistura de sinais provenientes de diferentes áreas cerebrais. Dessa forma, o padrão ERD/ERS gerado no córtex motor durante uma intenção de movimento não pode ser observado por uma única medição a partir do processo realizado, por isso é necessário o cálculo da média de várias repetições, ou épocas, para se evidenciar tal característica, como descrito por [Pfurtscheller \(1999\)](#).

O sinal resultante das operações anteriores é alisado, através de médias tiradas entre pequenas janelas de amostras consecutivas, para a redução de variabilidade do sinal e melhor visualização das características.

Por fim, comparou-se o sinal resultante ao longo do tempo em relação percentual ao sinal na linha-base, descrita na Seção 3.4, quando o sujeito não se movimenta, tampouco tem intenção fazê-lo. A dessincronização (ERD), relacionada à intenção de movimento pôde então, ser analisada como uma queda percentual do sinal, enquanto a sincronização (ERS) pôde ser vista como um aumento percentual do sinal, como descrito na Seção 2.1.

A seguir será explicado o método utilizado para a detecção da intencionalidade de movimento baseado em apenas uma época do sinal.

### 4.3.2 Detecção de intenção de movimento utilizando-se uma época do sinal

A Figura 61 ilustra os passos envolvidos no pré-processamento dos sinais de EEG para que seja possível a detecção da intenção de movimento em uma repetição. O processamento total desta abordagem envolve duas etapas: o pré-processamento do sinal e a classificação do sinal, que também envolve o treinamento dos classificadores. A parte de pré-processamento engloba a retirada de artefatos dos sinais, uma filtragem espacial, um processo de Separação Linear de Fontes e a filtragem em frequência na banda cujas características desejadas são observadas. O pré-processamento do sinal será abordado a seguir e a parte de classificação na Seção 4.3.2.2.

#### 4.3.2.1 Pré-processamento do sinal de EEG

Na Figura 61, é possível observar o primeiro bloco referente aos canais de EEG, cujos sinais chegam não processados ao sistema para serem processados, da mesma forma como no processamento descrito anteriormente. O próximo passo foi a eliminação de artefatos da rede elétrica através da mesma filtragem realizada no processamento de EEG descrito anteriormente.

Adiante, foi realizada uma filtragem espacial através de um filtro *CAR*, do inglês

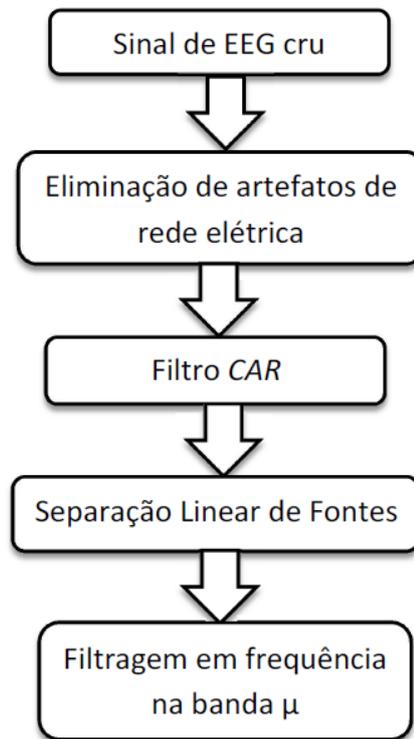


Figura 61 – Ilustração dos passos envolvidos no pré-processamento do sinal de EEG para a detecção da intenção de movimento para uma época do sinal.

*Common Average Reference* ou Referência de Média Comum. Esse tipo de filtragem espacial foi utilizada em [Ibanez et al. \(2013\)](#) para uma aplicação semelhante à abordada neste trabalho. Essa técnica de filtragem se baseia no fato de que os sinais biológicos externos ao cérebro afetam aproximadamente da mesma maneira todos os eletrodos de EEG, devido à grande distância da fonte de ruído aos eletrodos sobre o escalpo. Então, a técnica consiste na subtração, amostra-a-amostra, da média dos sinais dos eletrodos em cada um dos canais obtidos através de uma referência comum.

O filtro *CAR* pode ser definido pela Equação 4.12.

$$v_i^{CAR} = v_i^{RC} - \frac{1}{N} \sum_{j=0}^N v_j^{RC} \quad (4.12)$$

Na Equação 4.12,  $v_i^{RC}$  é o potencial entre o  $i$ -ésimo eletrodo e a referência,  $N$  é o número de canais utilizados e  $v_i^{CAR}$  é o potencial do  $i$ -ésimo eletrodo utilizando a referência pela média comum.

Como a média comum prioriza os sinais que estão presentes em uma grande quantidade de eletrodos, a subtração leva à eliminação destes sinais, funcionando como um filtro espacial passa-altas, ou seja, ele acentua componentes com distribuições altamente localizadas enquanto elimina as componentes que estão na maioria dos eletrodos, como de

fato os ruídos biológicos externos (M., 2003).

O sinal resultante passa por um processo de Separação Linear de Fontes (SLF). A Separação Linear de Fontes é uma abordagem relacionada ao conceito de Separação Cega de Fontes (*BSS* – do inglês *Blind Source Separation*). SLF é uma abordagem não estatística e relativamente simples, comparada com outras abordagens de Separação Cega de Fontes como Análise de Componentes Independentes (*ICA* – do inglês *Independent Component Analysis*) e Análise por Fração de Sinal (*SFA* – do inglês *Signal Fraction Analysis*). Para mais informações acerca destas últimas abordagens consulte P. (2005), Comon (2010).

A abordagem de Separação Linear de Fontes utilizada neste trabalho foi proposta por Benevides (2009), Benevides, A. B., Bastos Filho, T. F. e Sarcinelli Filho (2008) para uma aplicação semelhante à abordada neste trabalho.

O método SLF é baseado na suposição de um modelo para interação de fontes cerebrais e propõe a separação dos sinais elétricos corticais (ECoG) linearmente misturados no encéfalo (BENEVIDES, 2009).

Supõe-se que várias regiões do cérebro sejam fontes de sinal, de forma que o sinal medido por um eletrodo sobre o escalpo (EEG) seja uma combinação do sinal emitido por cada fonte no córtex (ECoG). O sinal emitido por cada fonte cerebral sofre atenuação até ser captado no eletrodo, portanto, a contribuição de cada fonte no sinal medido no eletrodo está relacionada à distância que a fonte está do eletrodo, como ilustrada na Figura 62.

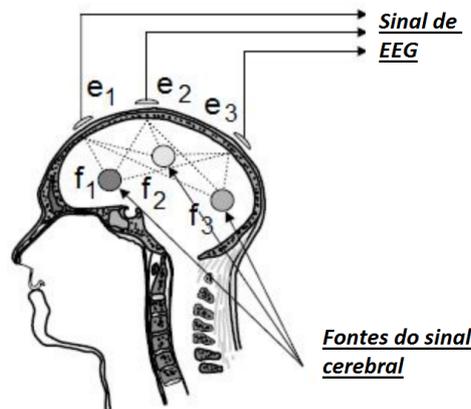


Figura 62 – Disposição das fontes cerebrais e dos eletrodos. Adaptado de Benevides (2009).

Na Figura 62,  $e_i$  exemplificam os eletrodos para medição de EEG e  $f_i$  as fontes dos sinais de EEG.

Como descrito na Seção 2.1, as fontes de sinal cerebral localizadas em diferentes áreas do córtex (fontes cerebrais) são massas neurais com milhões de neurônios piramidais perpendiculares a superfície do córtex. Portanto, a abordagem deste trabalho será de forma que as fontes cerebrais serão modeladas como dipolos elétricos perpendiculares à

superfície, devido à orientação dos neurônios piramidais e à distribuição bipolar de seu campo eletromagnético (BENEVIDES, 2009).

Um dipolo elétrico é formado por uma carga positiva e uma carga negativa, iguais em módulo, separadas por uma distância pequena. Assumiu-se que a superfície cerebral é plana e sem rugosidade, dessa forma, todos os dipolos estão posicionados perpendicularmente a um mesmo plano. Da mesma forma, os eletrodos, ou seja, os pontos onde serão calculadas as intensidades do campo elétrico estão posicionados no mesmo plano dos dipolos (Benevides, A. B., Bastos Filho, T. F. e Sarcinelli Filho, 2008).

Com esse modelo consideramos que não existe distância vertical entre as fontes cerebrais do córtex e os eletrodos sobre o escalpo. Como não há distância, não há atenuação vertical entre o sinal de uma fonte cerebral e o sinal medido pelo eletrodo correspondente, mas existem as distâncias horizontais entre as fontes de modo que o sinal medido por um eletrodo contém o sinal gerado na fonte cerebral que ele está localizado integralmente e também contém os sinais provenientes das fontes vizinhas, sofridas suas respectivas atenuações (Benevides, A. B., Bastos Filho, T. F. e Sarcinelli Filho, 2008).

A Figura 63 ilustra as fontes cerebrais  $f_1$ ,  $f_2$  e  $f_3$  representadas pelos círculos e os eletrodos  $e_1$ ,  $e_2$  e  $e_3$  no mesmo plano das fontes. As fontes estão separadas por uma distância  $d$ , que ocasiona uma atenuação. A atenuação é representada pelo termo  $a_{ij}$  em que  $i$  representa a fonte de origem do sinal e  $j$  representa o eletrodo de destino do sinal. As atenuações estão representadas sobre as setas que indicam a direção de propagação do sinal. Como não existe distância vertical entre o eletrodo  $e_i$  e a fonte  $f_i$ , os termos  $a_{11}$ ,  $a_{22}$  e  $a_{33}$ , que representam atenuações unitárias, estão representados dentro dos círculos das fontes cerebrais. A atenuação  $a_{ij}$  é uma constante com valor numérico real entre 0 e 1, calculada em função da distância  $d$ , que será multiplicada aos sinais das fontes. A atenuação  $a_{ii}$  é dita unitária, pois ao se multiplicar o sinal da fonte pela unidade, o sinal se mantém, e não ocorre atenuação (BENEVIDES, 2009).

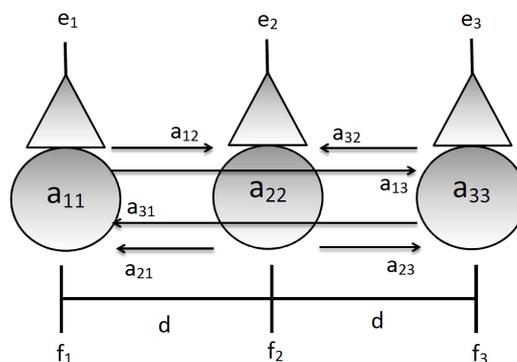


Figura 63 – Disposição das fontes cerebrais, eletrodos e atenuações. Adaptado de Benevides (2009).

A partir das simplificações do modelo, foi realizado o cálculo do campo elétrico dos dipolos, para que pudesse ser encontrada uma relação para a atenuação em função da distância. Em virtude das simplificações, o cálculo do campo elétrico pôde ser reduzido a um problema em duas dimensões, onde o dipolo (fonte cerebral) se encontra no eixo  $y$  e o ponto (eletrodo) se encontra no eixo  $x$ . Pôde-se calcular o campo dipolar utilizando o princípio da sobreposição, calculando o campo elétrico da carga positiva e negativa separadamente (BENEVIDES, 2009).

A Figura 64 ilustra um dipolo elétrico, mostrando as cargas  $q_1$  e  $q_2$  e o ponto  $p$ , sobre o qual foi calculada a intensidade do campo elétrico,  $|\vec{E}_i|$ .

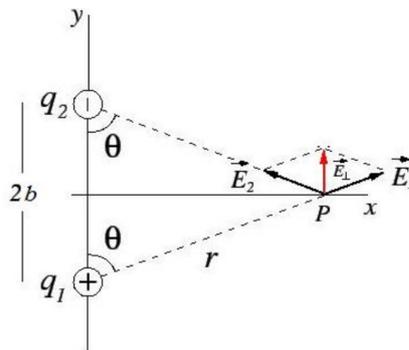


Figura 64 – Dipolo Elétrico. (BENEVIDES, 2009).

A partir da Figura 64, pode-se escrever

$$|\vec{E}_1| = |\vec{E}_2| = \frac{q}{4\pi\epsilon r^2}. \quad (4.13)$$

Na equação 4.13,  $|\vec{E}_1|$  e  $|\vec{E}_2|$  são as intensidades dos campos elétricos das cargas 1 e 2, respectivamente,  $q$  é o módulo das cargas elétricas  $q_1$  e  $q_2$ ,  $r$  é a distância do ponto  $P$  às cargas e  $\epsilon$  é a permissividade dielétrica do meio. Devido à geometria do problema e a condição acima, as componentes  $x$  de  $\vec{E}_1$  e  $\vec{E}_2$  são iguais em módulo, mas com sentidos opostos e, portanto, a componente  $x$  de  $\vec{E}_1 + \vec{E}_2$  é nula (Hayt, W. H. Jr., Buck, 2001). A componente  $y$  de  $\vec{E}_1 + \vec{E}_2$  é dada por

$$\vec{E}_{1y} + \vec{E}_{2y} = \frac{2qb}{4\pi\epsilon(x^2 + b^2)^{3/2}}. \quad (4.14)$$

Na equação 4.14,  $2b$  é a distância entre as cargas elétricas. Ainda podemos escrever:

$$\vec{E}_{1y} + \vec{E}_{2y} = \frac{kp}{x^3} = \frac{2qb}{4\pi\epsilon(x^2 + b^2)^{3/2}}. \quad (4.15)$$

Com isso, as atenuações podem ser calculadas, como feito a seguir. Para o campo elétrico,  $\vec{E}_{elet1}$ , na superfície do escalpo em um ponto  $P(0,0)$  centrado no dipolo e o campo

na superfície do córtex,  $\vec{E}_{elet2}$ , num ponto  $Q(x, 0)$  à uma distância  $x$  do dipolo, temos o seguinte cálculo de atenuação do potencial elétrico:

$$|\vec{E}_{elet1}| = \frac{kp}{b^3} \quad |\vec{E}_{elet2}| = \frac{kp}{(x^2 + b^2)^{3/2}}. \quad (4.16)$$

Assim,

$$|\vec{E}_{elet1}| = a|\vec{E}_{elet2}|. \quad (4.17)$$

Em que

$$a = \frac{b^3}{(x^2 + b^2)^{3/2}}. \quad (4.18)$$

A equação 4.18 pode representar a atenuação dos campos elétricos dadas as suposições realizadas e ainda tomando-se a permissividade dielétrica do meio  $\epsilon$  suposta constante para todo o encéfalo. As cargas  $q$  de todos os dipolos das fontes cerebrais foram consideradas iguais, as distâncias  $b$  entre as cargas dos dipolos também foram consideradas iguais para todas as fontes cerebrais. Assim, a Equação 4.18 é igualmente válida para todas as fontes cerebrais (Benevides, A. B., Bastos Filho, T. F. e Sarcinelli Filho, 2008).

A seguir, será explicado como o método SLF descrito foi aplicado para os canais de EEG adquiridos neste trabalho. Como dito na Seção 3.4, foram adquiridos 11 canais de EEG de acordo com o padrão internacional 10-20: Fp1, Fp2, F7, F3, Fz, F4, F8, C3, Cz, C4, Pz.

Foi suposto existir 11 fontes cerebrais na região cortical abaixo de cada eletrodo, constituindo um sistema com 11 equações lineares. Dessa forma, pôde-se formular um sistema linear com 11 equações. Todos os eletrodos e fontes cerebrais foram supostos estar posicionados em um mesmo plano euclidiano. O plano euclidiano foi discretizado em uma malha com distâncias horizontais e verticais iguais a  $d$ , os eletrodos e as fontes foram mapeados em nós dessa malha, como ilustra a Figura 65. É possível observar, à direita, o mapeamento dos eletrodos e fontes dos sinais cerebrais e, à esquerda, a disposição dos canais de EEG.

Os canais foram nomeados de 1 até 11 e descritos como  $e_1, e_2 \dots e_{11}$  como eletrodos, as fontes dos sinais como  $f_1, f_2 \dots f_{11}$ , as distâncias calculadas a partir da Figura 65 como euclidianas  $d_{ij}$ , em que  $i$  refere-se ao sinal de origem e  $j$  ao eletrodo de destino e as atenuação  $a_{ij}$  são calculadas como na Equação 4.18. Ainda foi assumido, como em Benevides, A. B., Bastos Filho, T. F. e Sarcinelli Filho (2008), Benevides (2009), que a distância  $d$  entre cada ponto da malha possui valor unitário, assim como a distância entre as cargas do dipolo e o ponto  $P(0, 0)$ ,  $b$ .

Temos assim, o seguinte sistema de equações:

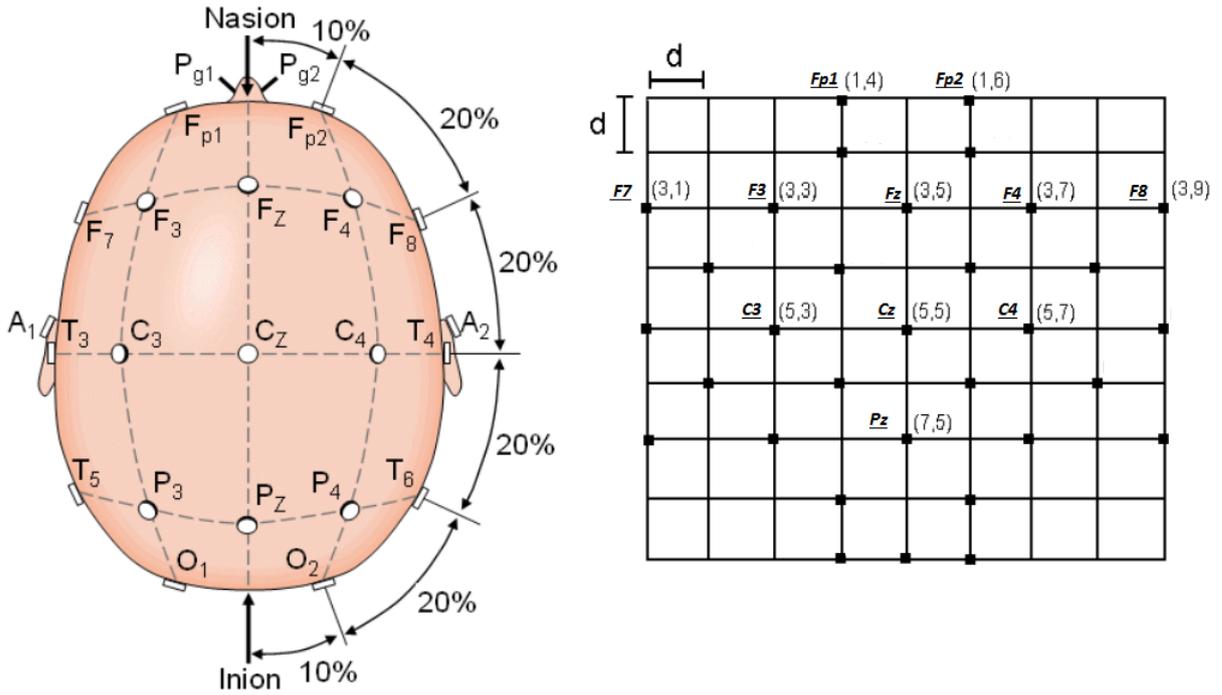


Figura 65 – Esquerda: Disposição dos eletrodos sobre o escalpo; Direita: Mapeamento dos eletrodos referentes aos canais utilizados em um plano euclidiano. Adaptado de Benevides (2009).

$$\begin{cases} e_1 = 1f_1 + a_{2,1}f_2 + \dots + a_{11,1}f_{11} \\ e_2 = a_{1,2}f_2 + 1f_2 + \dots + a_{11,2}f_{11} \\ \cdot \quad \cdot \quad \cdot \quad \cdot \quad \cdot \quad \cdot \\ \cdot \quad \cdot \quad \cdot \quad \cdot \quad \cdot \quad \cdot \\ \cdot \quad \cdot \quad \cdot \quad \cdot \quad \cdot \quad \cdot \\ e_{11} = a_{1,11}f_{11} + a_{2,11}f_2 + \dots + 1f_{11}. \end{cases}$$

Pode-se também considerar o sistema matricialmente com:

$$\mathbf{A} = \begin{pmatrix} 1 & a_{2,1} & \dots & a_{11,1} \\ a_{1,2} & 1 & \dots & a_{11,2} \\ \vdots & \vdots & \ddots & \vdots \\ a_{1,11} & a_{2,11} & \dots & 1 \end{pmatrix};$$

$$\mathbf{F} = \begin{pmatrix} f_1 \\ f_2 \\ \vdots \\ f_{11} \end{pmatrix};$$

$$\mathbf{E} = \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_{11} \end{pmatrix}.$$

E então, tem-se a equação que define o processo de Separação Linear de Fontes:

$$A.F = E \quad \Leftrightarrow \quad F = A^{-1}.E, \quad (4.19)$$

cujo procedimento permite a separação de fontes linearmente misturadas, de onde deriva a atribuição de seu nome, simulando a aquisição de um eletrocortigrama (ECoG), representado por  $F$  a partir de um eletroencefalograma (EEG), representado por  $E$ , na Equação 4.19. Os sinais medidos sob o córtex apresentam os padrões de ERD/ERS de forma mais nítida e proporcionam uma melhor taxa de acerto na classificação das tarefas mentais, por isso esse método foi implementado neste trabalho.

O próximo bloco na Figura 61 trata da filtragem no domínio da frequência na banda  $\mu$  em que ocorre predominantemente a característica de ERD, relacionada à intenção de movimento (PFURTSCHELLER, 1999), como descrito na Seção 2.1. Os sinais, nesta etapa, foram filtrados por filtros passa-banda *Butterworth* de 4ª ordem, como proposto por Ibanez et al. (2013) para uma aplicação semelhante à abordada neste trabalho.

O sinal resultante passa então, por classificadores para que estes possam detectar os momentos, durante os experimentos, em que houve intencionalidade de movimento por parte do sujeito. A classificação dos sinais, juntamente com o treinamento e as características utilizadas nos classificadores serão abordados a seguir.

#### 4.3.2.2 Classificação do sinal de EEG

A Figura 66 ilustra os passos envolvidos na classificação do sinal de EEG para a detecção da intenção de movimento em uma época do sinal. Como mostrado nesta figura, este trabalho utiliza um classificador *Bayesiano* alimentado por valores de Densidade Espectral de Potência dos sinais para classificar o sinal de EEG com o objetivo de detectar o início da intenção de movimento. Uma breve descrição acerca dos classificadores Bayesianos e discriminantes quadráticos, estes utilizados em conjunto com o classificador neste trabalho, será realizada a seguir.

#### Classificadores Bayesianos e discriminante quadrático

Os classificadores Bayesianos são derivados da regra de *Bayes*, mostrada na Equação 4.20. A regra de Bayes é uma probabilidade condicional relacionando a probabilidade a posteriori  $P(C_k|x)$ , de ocorrência do evento  $x$  em uma classe  $C_k$ , com a probabilidade a

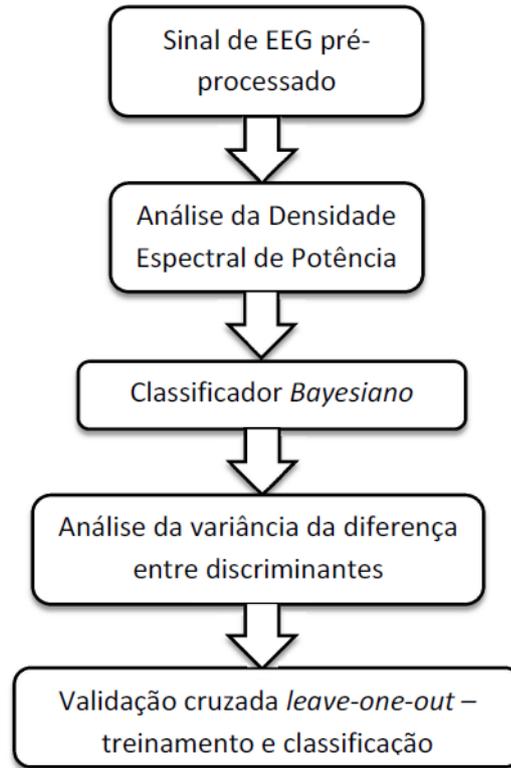


Figura 66 – Ilustração dos passos envolvidos na classificação do sinal de EEG para a detecção da intenção de movimento para uma época do sinal.

priori  $P(C_k)$ , de ocorrência da classe  $C_k$ , e a função densidade de probabilidade  $pdf^3$ , do inglês *Probability Density Function*,  $P(x|C_k)$  (GARCIA, 1994).

Na Equação 4.20,  $p(x)$  é somente um fator de escala, dado pelo teorema da probabilidade total<sup>4</sup>, que garante que a soma das probabilidades a posteriori seja igual a 1, como mostrado na Equação 4.21.

$$P(C_k|x) = \frac{P(x|C_k)P(C_k)}{p(x)} \quad (4.20)$$

$$p(x) = \sum_{i=1}^L P(x|C_i)P(C_i) \quad (4.21)$$

<sup>3</sup> A função densidade de probabilidade é definida pela derivada da *cdf*, Denomina-se função distribuição cumulativa (do inglês, *cumulative distribution function* - *cdf*) a probabilidade da variável aleatória contínua  $X$  assumir valores inferiores a um dado valor  $x$ . Para maiores informações acerca deste assunto, consulte Garcia (1994).

<sup>4</sup> A lei da probabilidade total é uma regra fundamental que relaciona probabilidades marginais e probabilidades condicionais. Ela expressa a probabilidade total de um resultado que pode ser realizado através de vários eventos distintos. A lei da probabilidade total é a proposição de que se  $[B_n : n = 1, 2, 3...]$  é uma partição finita ou infinita contável de um espaço amostral, i.e., um conjunto de eventos disjuntos pares cuja união é todo o espaço da amostra, e cada evento  $B_n$  é mensurável, então, para qualquer evento  $A$  do mesmo espaço de probabilidade:  $P_r(A) = \sum_n P_r(A \cap B_n)$ . Para mais informações acerca desse assunto, consulte Zwillinger, D., Kokoska (2000)

Seja um espaço amostral  $S$  particionado em  $L$  classes, como mostrado na Equação 4.22, em que a probabilidade de ocorrência de uma classe  $C_k$  em  $S$  é sua probabilidade a priori,  $P(C_k)$ . O hiper-espaço amostral possui  $N$  amostras e cada classe possui  $N_i$  amostras. Se as amostras das classes puderem ser consideradas como amostras aleatórias da distribuição de  $S$ , então a probabilidade a priori pode ser estimada pela fração de cada classe em  $S$  (FRIEDMAN, 1989; GARCIA, 1994).

Então, a probabilidade a priori de ocorrência de uma classe  $C_k$  é a fração do número de amostras  $N_k$  da classe  $C_k$  e o número total de amostras do hiper-espaço amostral,  $N$ , como mostrado na Equação 4.23.

$$S = [C_1, C_2, \dots, C_k \dots C_L] \quad (4.22)$$

$$P(C_k) = \frac{N_k}{N} \quad (4.23)$$

O espaço amostral possui  $d$  características que o definem, ou seja,  $d$  dimensões que o definem como um hiper-espaço. Cada classe possui, então,  $d$  características que foram observadas, ou amostradas,  $N_i$  vezes. Dessa forma, os elementos das classes são representados em matrizes, em que as linhas correspondem às características, ou dimensões de  $S$ , e as colunas correspondem às observações,  $y_i$ , como mostrado abaixo.

$$\begin{aligned} \mathbf{C}_1 &= \begin{pmatrix} y_{1,1} & \dots & y_{1,N_1} \\ \vdots & \ddots & \vdots \\ y_{d,1} & \dots & y_{d,N_1} \end{pmatrix}, \\ \mathbf{C}_2 &= \begin{pmatrix} y_{2,1} & \dots & y_{2,N_2} \\ \vdots & \ddots & \vdots \\ y_{d,1} & \dots & y_{d,N_2} \end{pmatrix} \dots \\ \mathbf{C}_L &= \begin{pmatrix} y_{L,1} & \dots & y_{L,N_L} \\ \vdots & \ddots & \vdots \\ y_{d,1} & \dots & y_{d,N_L} \end{pmatrix}. \end{aligned}$$

Neste caso, um evento  $x$  é um vetor de variáveis aleatórias,  $\bar{x}$  correspondendo a uma observação do hiper-espaço amostral em que não se sabe especificamente sua classe. A probabilidade a posteriori  $P(C_k|\bar{x})$  é a probabilidade de ocorrência da classe  $C_k$  dado que o evento  $x$  ocorreu, e deriva da probabilidade condicional de variáveis aleatórias múltiplas. A partir das matrizes das classes e do vetor do evento, pode-se estimar a distribuição estatística do evento em cada classe, ou seja, sua função densidade de probabilidade *pdf*. E para o caso geral em que o espaço  $S$  possui mais de uma dimensão, é estimada a *pdf*

conjunta,  $P(\bar{x}|C_k)$ , das características de cada classe. Na maioria dos casos,  $P(\bar{x}|C_k)$  é aproximado pela distribuição normal multivariada ou gaussiana (GARCIA, 1994).

O teorema do limite central<sup>5</sup> mostra que a soma de variáveis aleatórias independentes e identicamente distribuídas com quaisquer funções densidade de probabilidade, pode ser aproximada por uma *pdf* normal se o número de amostras for suficientemente grande (GARCIA, 1994). Isso quer dizer que podemos ter uma variável original com uma distribuição muito diferente da normal, mas se tomarmos várias amostras dessa distribuição, e então fizermos um histograma das médias amostrais, a forma se parecerá com uma curva normal (GARCIA, 1994). Portanto, a função densidade de probabilidade comumente utilizada é a distribuição normal multivariada, como mostrada na Equação 4.24.

$$P(\bar{x}|C_k) = N_k(\bar{\mu}_k, \Sigma_k) = \frac{1}{(2\pi)^{d/2} |\Sigma_k|^{1/2}} e^{0.5(\bar{x}-\bar{\mu}_k)(\bar{x}-\bar{\mu}_k)^T} \quad (4.24)$$

Na Equação 4.24,  $d$  é o número de dimensões do espaço de características, que corresponde ao tamanho do vetor de variáveis aleatórias  $\bar{x}$ .  $\bar{\mu}_k$  é o vetor que contém a média de cada característica da classe  $C_k$  e  $\Sigma_k$  é a matriz de covariância.

A *pdf* normal, ilustrada na Figura 67, é completamente definida por funções de seus momentos de primeira e segunda ordem, que são o vetor de média  $\bar{\mu}$ , representado abaixo juntamente com o vetor  $\bar{x}$ , e pela matriz de covariância  $\Sigma$ , representada pela Equação 4.25 (FUKUNAGA, 1990).

$$\bar{\mathbf{x}} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_d \end{pmatrix}, \bar{\mu}_{\mathbf{k}} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_d \end{pmatrix}$$

$$\Sigma_k = \frac{1}{N_k - 1} \sum_{i=1}^{N_k} (\bar{a}_i - \bar{\mu}_k)(\bar{a}_i - \bar{\mu}_k)^T \quad (4.25)$$

O vetor de média  $\bar{\mu}_k$  é dado pela Equação 4.26 sobre os elementos da classe  $C_k$ , mostrada abaixo, onde são definidos os termos  $a_i$  da Equação 4.25.

$$\mathbf{C}_k = \begin{pmatrix} yk_{1,1} & \dots & yk_{1,N_k} \\ \vdots & \ddots & \vdots \\ yk_{d,1} & \dots & yk_{d,N_k} \end{pmatrix} = [\bar{a}_1 \dots \bar{a}_{N_k}]$$

<sup>5</sup> O Teorema central do limite ou teorema do limite central, é um importante resultado da estatística. A demonstração de muitos outros teoremas estatísticos dependem dele. Em teoria das probabilidades, esse teorema afirma que quando o tamanho da amostra aumenta, a distribuição amostral da sua média aproxima-se cada vez mais de uma distribuição normal. Este resultado é fundamental na teoria da inferência estatística. Para mais informações acerca deste assunto consulte Fischer (2011)

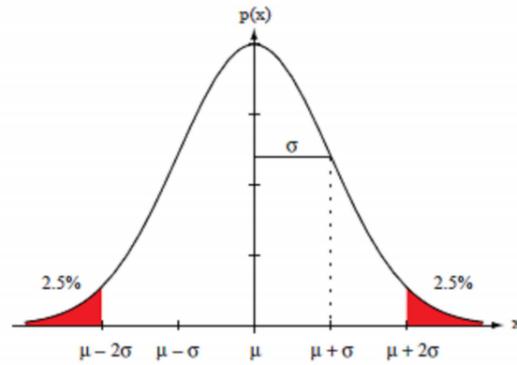


Figura 67 – Distribuição normal univariada definida pela média  $\mu$  e desvio padrão  $\sigma$ , 95% da normal está no intervalo  $|x - \mu| \leq 2\sigma$  (Duda, R. O.; Hart, P. E. e Stork, 2001).

$$\bar{\mu}_k = \frac{1}{N_k} \sum_{i=1}^{N_k} \bar{a}_i \quad (4.26)$$

As amostras extraídas de uma população normal tendem a cair em um único conjunto, o centro do conjunto é determinado pelo vetor média e o formato do conjunto é determinado pela matriz de covariância, como ilustrado na Figura 68. Os pontos de densidade constante são hiper-elipsóides onde a forma quadrática  $(x - \mu)^T \Sigma^{-1} (x - \mu)$  é constante. A quantidade  $r^2 = (x - \mu)^T \Sigma^{-1} (x - \mu)$  é chamada distância de *Mahalanobis* quadrática de  $x$  para  $\mu$ . Assim, os contornos de densidade constante são hiper-elipsóides de distância de *Mahalanobis* constante para  $\mu$  e o volume desses hiper-elipsóides mede a dispersão das amostras sobre a média corresponde à distância de *Mahalanobis* (Duda, R. O.; Hart, P. E. e Stork, 2001).

A *pdf* normal é calculada para cada classe e pode-se calcular a probabilidade a posteriori do vetor de variáveis aleatórias,  $\bar{x}$ , estar contido na respectiva classe, utilizando-se a Equação 4.27. Então, a regra da máxima semelhança é utilizada para atribuir o vetor de amostras  $\bar{x}$  a uma determinada classe. A regra determina que o vetor de amostras pertence à classe com maior função discriminante  $g_{c_k}(\bar{x})$  (Millán J. R., 2007).

$$\bar{x} \in C_k / C_k = \operatorname{argmax}(g_{c_i}), \quad i \in (1..k) \quad (4.27)$$

A função discriminante quadrática é dada pelo logaritmo da probabilidade a posteriori,  $P(C_k|\bar{x})$ , como mostrado na Equação 4.28.

$$g_{c_k}(\bar{x}) = \ln(P(C_k|\bar{x})) \quad (4.28)$$

O desenvolvimento deste logaritmo leva à Equação 4.29.

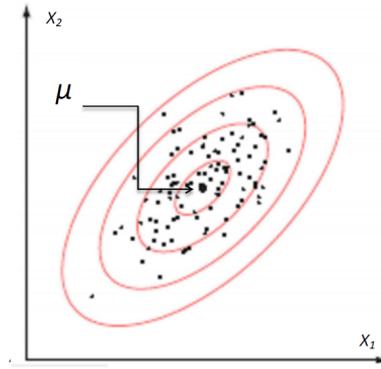


Figura 68 – Um hiper-espaço de características com  $d$  dimensões resulta em distribuições representadas em  $d + 1$  dimensões. Para o espaço de características bidimensional da figura, a curva normal é representada em um espaço tridimensional e as elipses vermelhas representam planos de corte em diferentes alturas da normal. A figura representa amostras bidimensionais de uma normal bivariada que estão num conjunto centrado na média  $\mu$ . As elipses vermelhas são as distâncias de *Mahalanobis* e mostram linhas de mesma densidade de probabilidade (Duda, R. O.; Hart, P. E. e Stork, 2001).

$$g_{c_k}(\bar{x}) = -\frac{1}{2}(\bar{x} - \bar{\mu}_k)^T \Sigma_k^{-1} (\bar{x} - \bar{\mu}_k) - \frac{1}{2} |\Sigma_k| + \ln(P(C_k)) \quad (4.29)$$

Portanto, são calculados a média e a matriz de covariâncias a partir dos elementos das classes e as respectivas funções discriminantes quadráticas, que estão em função de  $\bar{x}$ . Quando o evento  $\bar{x}$  ocorre, o vetor é aplicado nas funções discriminante, que retornam um número correspondendo à probabilidade de  $\bar{x}$  pertencer a uma determinada classe. A partir da regra da máxima semelhança, o vetor  $\bar{x}$  é atribuído à classe com maior função discriminante quadrática, ou seja, a função discriminante que apresente maior probabilidade de conter  $\bar{x}$ .

Esse método de classificação, utilizando funções discriminantes quadráticas é denominado análise por discriminante quadrático (*QDA*, do inglês, *Quadratic Discriminant Analysis*), pois geometricamente as regiões de decisão são hiper-planos quadráticos em torno das hiper-elipsóides que definem as classes, como ilustrado na Figura 69 (Duda, R. O.; Hart, P. E. e Stork, 2001).

A seguir será explicado como esse método de classificação foi aplicado neste trabalho.

#### Aplicação do classificador Bayesiano e discriminante quadrático na classificação

Foram utilizadas duas classes: a classe *movimento* e a classe *parado*. A primeira referente aos momentos de intenção de movimento e movimento efetivo, utilizada para

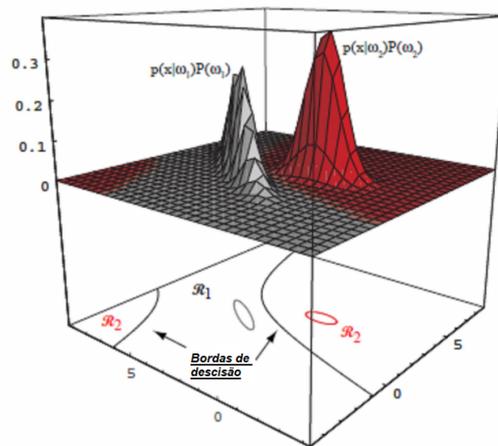


Figura 69 – Região de decisão não linear entre duas normais bivariadas. O hiper-plano de separação são duas curvas. Adaptado de Duda, R. O.; Hart, P. E. e Stork (2001).

classificar os momentos de intenção de movimento, e a segunda referente aos momentos em que o sujeito não se movimenta, tampouco tem intenção de fazê-lo.

Como sugerido por Ibanez et al. (2013), para uma aplicação semelhante à abordada neste trabalho, as características observadas que definem as classes citadas são valores de Densidade Espectral de Potência (*PSD*, do inglês, *Power Spectral Density*) nos canais C4, C3 e Cz em frequências específicas. Os canais C4, C3 e Cz foram selecionados em detrimento dos outros pois, estão diretamente relacionados às áreas motoras do córtex cerebral, como descrito na Seção 2.1 e foram os eletrodos nos quais melhor pôde ser observado o evento relacionado à intenção de movimento, a Dessincronização Relacionado ao Evento (ERD). A seleção das frequências foi feita baseada na maior características de ERD entre os momentos definidos como classe *parado* e classe *movimento* no treinamento do classificador. A maior característica de ERD foi definida como a maior diferença entre os valores médios dos PSDs para a classe *parado* e a classe *movimento* no treinamento, como descrito na Equação 4.30.

$$MaxDif(f_i) = argmax(Med_{j,f_k}(PSD(f_i)_{parado}) - Med_{j,f_k}(PSD(f_i)_{movimento})) \quad (4.30)$$

Na Equação 4.30,  $MaxDif(f_i)$  refere-se ao maior valor, representado pelo operador  $argmax$ , da diferença dos valores dos PSDs médios entre as janelas  $j$  (tomando-se os valores médios por frequências correspondentes  $f_k$ ) das classes *parado* e *movimento*, variando-se as frequências  $f_i$  do espectro.

As frequências no espectro que apresentarem as maiores diferenças de seus valores de densidade espectral de potência foram tomadas no treinamento, e o PSD do valor da

moda dessas frequência foi utilizado na classificação. O processo de escolha dessa frequência é realizado a cada iteração de treinamento para a realização da próxima classificação. As classes *parado* e *movimento* foram tomadas sobre a linha-base (*baseline*), descrita na Seção 3.4 e 2 segundos antes do movimento acontecer até o final do movimento, 3 segundos após o início, respectivamente. Na linha-base o sujeito não se movimenta e não tem intenção de fazê-lo e, aproximadamente, até 2 segundos antes do movimento acontecer até o final do movimento é onde espera-se observar o ERD (PFURTSCHELLER, 1999).

O procedimento de obtenção do PSD foi realizado utilizando-se a transformada discreta de *Fourier* (*DFT*, do inglês *Discrete Fourier Transform*), a partir do algoritmo de *FFT*<sup>6</sup> (do inglês *Fast Fourier Transform*) ou Transformada Rápida de *Fourier*, com 4096 pontos e janelas retangulares de 100 amostras com sobreposição de 50%, baseados nos estudos de BENEVIDES (2013) e Ibanez et al. (2013).

A Figura 70 ilustra um sinal exemplar no tempo, à esquerda, e a densidade espectral de potência referente à uma janela do sinal obtido, à direita. As janelas são sobrepostas em 50%, como realizado neste trabalho. Para cada janela processada do sinal, haverá um espectro como o mostrado na Figura 70.

Neste trabalho, as classes definidas podem ser representadas como:

$$\mathbf{C}_{\text{parado}} = \begin{pmatrix} C_{3,1} & \dots & C_{1, N_{\text{par}}} \\ C_{4,1} & \dots & C_{4, N_{\text{par}}} \\ C_{z,1} & \dots & C_{z, N_{\text{par}}} \end{pmatrix},$$

$$\mathbf{C}_{\text{movimento}} = \begin{pmatrix} C_{3,1} & \dots & C_{1, N_{\text{mov}}} \\ C_{4,1} & \dots & C_{4, N_{\text{mov}}} \\ C_{z,1} & \dots & C_{z, N_{\text{mov}}} \end{pmatrix}.$$

O número de observações para a classe  $C_{\text{parado}}$ ,  $N_{\text{par}}$  refere-se a quantidade de janelas utilizadas em que o PSD foi calculado sobre a linha-base, concatenando-se todas as repetições utilizadas no treinamento. O número de observações para a classe  $C_{\text{movimento}}$ ,  $N_{\text{mov}}$  refere-se a quantidade de janelas utilizadas em que o PSD foi calculado sobre os instantes de movimento, concatenando-se todas as repetições utilizadas no treinamento. Os instantes definidos para a classe  $C_{\text{movimento}}$  foram de 2 segundos antes do início do movimento até 3 segundos depois do início. Esse tempo foi escolhido pois o movimento dura, na média 3 segundos, como descrito na Seção 3.4, perfazendo um total de 5 segundos.

<sup>6</sup> A Transformada rápida de *Fourier* (em inglês *fast Fourier transform*, ou *FFT*) é um algoritmo eficiente para se calcular a Transformada discreta de *Fourier* (*DFT*) e a sua inversa. As Transformadas rápidas de *Fourier* são de grande importância em uma vasta gama de aplicações, de processamento digital de sinais para a resolução de equações diferenciais parciais a algoritmos para multiplicação de grandes inteiros. É um método largamente utilizado para o cálculo computacional cuja complexidade é  $O(n \log n)$  contra  $O(n^2)$  necessários para o mesmo cálculo. Para mais informações acerca deste assunto, consulte BRACEWELL (2000).

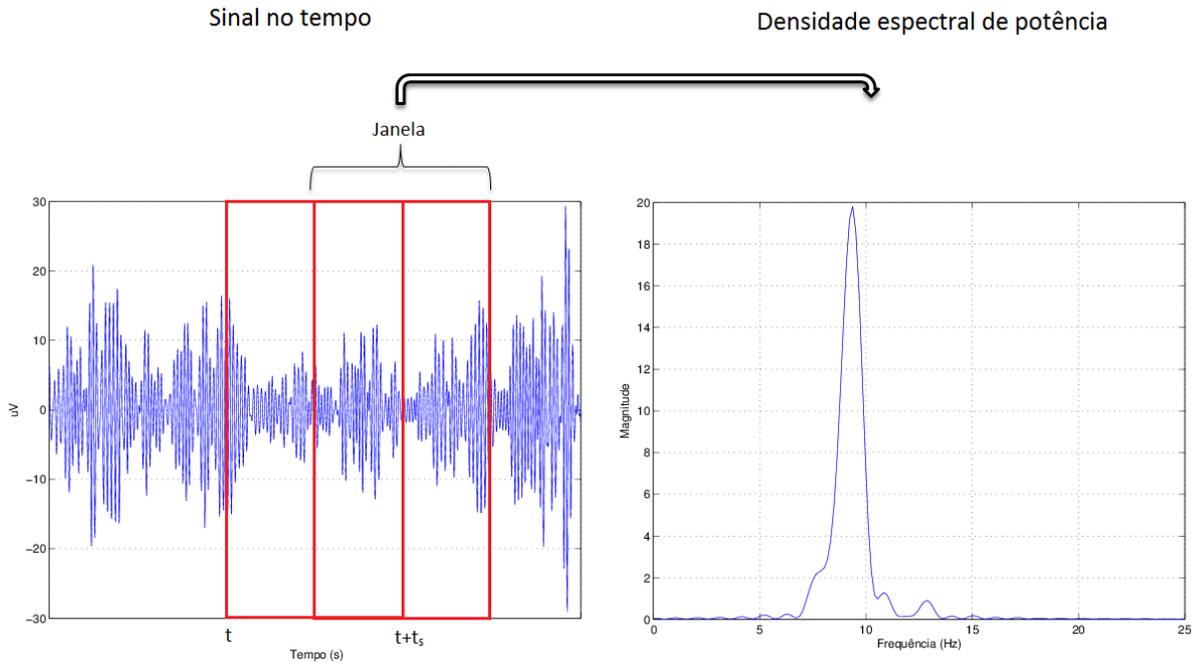


Figura 70 – Um sinal exemplar no tempo, à esquerda, e a densidade espectral de potência referente à uma janela do sinal obtido, à direita.

Cada observação  $C_{i,j,N_k}$  das matrizes para as duas classes é relativa ao valor de PSD, de cada janela, referente à frequência selecionada, como ilustrado na Equação 4.31.

$$C_{i,j,N_k} = PSD(C_i(moda(f_l))) \quad (4.31)$$

Na Equação 4.31,  $C_{i,j,N_k}$  é um elemento das matrizes que definem as classes,  $f_l$  são as frequências selecionadas nas quais ocorreram os maiores ERDs.  $PSD$  é o operador que define os valores de densidade espectral de potência do sinal do canal  $i$ , na moda das frequências  $f_l$ .

A classificação de um evento  $\bar{x}$ , i.e., uma janela com valores do PSD do sinal em C3, C4 e Cz, na frequência selecionada, pertencer à classe  $C_{parado}$  ou  $C_{movimento}$  é realizada utilizando-se as Equações 4.27 e 4.29. Para tanto, fez-se a diferença entre os discriminantes quadráticos  $g_{c_{parado}}(\bar{x})$  e  $g_{c_{movimento}}(\bar{x})$  relativos às classes, *parado* e *movimento*, respectivamente.

Para o cálculo das probabilidade à priori das classes,  $P(C_k)$ , foi realizado o seguinte método: a classe *movimento* é relativa à característica de ERD. A partir da visualização dessa característica em várias épocas de sinal de EEG, i.e., a abordagem *multi-trial* descrita na seção anterior, observou-se que essa característica ocorria em média por, aproximadamente, 5 segundos. O sinal de EEG foi analisado a partir do segundo 5 até o segundo 20 durante cada repetição do experimento. O segundos iniciais foram descartados

pois referem-se à estabilização dos sinais e não podem ser levados em conta e os segundos finais foram descartados na sincronia do início de movimento entre as repetições de um experimento, como exposto na Seção 3.2. Como em cada repetição do experimento há então 15 segundos para serem classificados, as probabilidades à priori das classes *movimento* e *parado* de acontecerem são dadas pela Equações 4.32 e 4.33, respectivamente.

$$P(C_{\text{movimento}}) = \frac{5}{15} \quad (4.32)$$

$$P(C_{\text{parado}}) = 1 - P(C_{\text{movimento}}) \quad (4.33)$$

Observou-se que a característica de variância da diferença entre os discriminantes  $g_{c_{\text{parado}}}(\bar{x})$  e  $g_{c_{\text{movimento}}}(\bar{x})$  é mais estável e proporciona uma classificação mais precisa que apenas a diferença entre os discriminantes, como descrito na Equação 4.34.

$$\text{VarDif}(j) = \text{argvar}(g_{c_{\text{movimento}}}(\bar{x}_j) - g_{c_{\text{parado}}}(\bar{x}_j)) \quad (4.34)$$

Na Equação 4.34, *VarDif* refere-se à variância da diferença entre os discriminantes  $g_{c_{\text{movimento/parado}}}(\bar{x}_j)$  em cada janela de dados  $j$ . O termo *argvar* refere-se a aplicação da variância do argumento entre parênteses, ou seja, da diferença entre os discriminantes. Naturalmente, a classificação envolve a análise da variância  $e$  do maior do discriminante da classe classificada. Ressalta-se que essa variância foi calculada janela-a-janela e tomando-se uma quantidade otimizada por sujeito de janelas para o cálculo.

Então, um classificador de limiar, baseado nos valores de média e desvio padrão do sinal resultante, obtidos na linha-base, é utilizado para determinar a pertinência das amostras entre as classes. O classificador de limiar utilizado nesta etapa é análogo aos utilizados nos sinais de EMG e de sensores inerciais.

Assim como utilizado nos sinais de EMG e sensores inerciais, uma quantidade de janelas acima do limiar também foi analisada para que o classificador pudesse identificar o evento. Naturalmente, a classificação da pertinência em uma classe é remetida à primeira amostra dessas janelas acima do limiar. Após uma procura pelos parâmetros do classificador de limiar, para que sejam minimizadas as classificações por ruídos, que seriam falsos positivos, ou classificações atrasadas, para cada sujeito por experimento, toma-se o tempo da amostra que o classificador detecta e considera-se este como início da intenção de movimento.

O treinamento e as classificações do sinal de EEG foram realizados através do procedimento de validação cruzada utilizando o método *Leave-one-out*, como ilustrado na Figura 71.

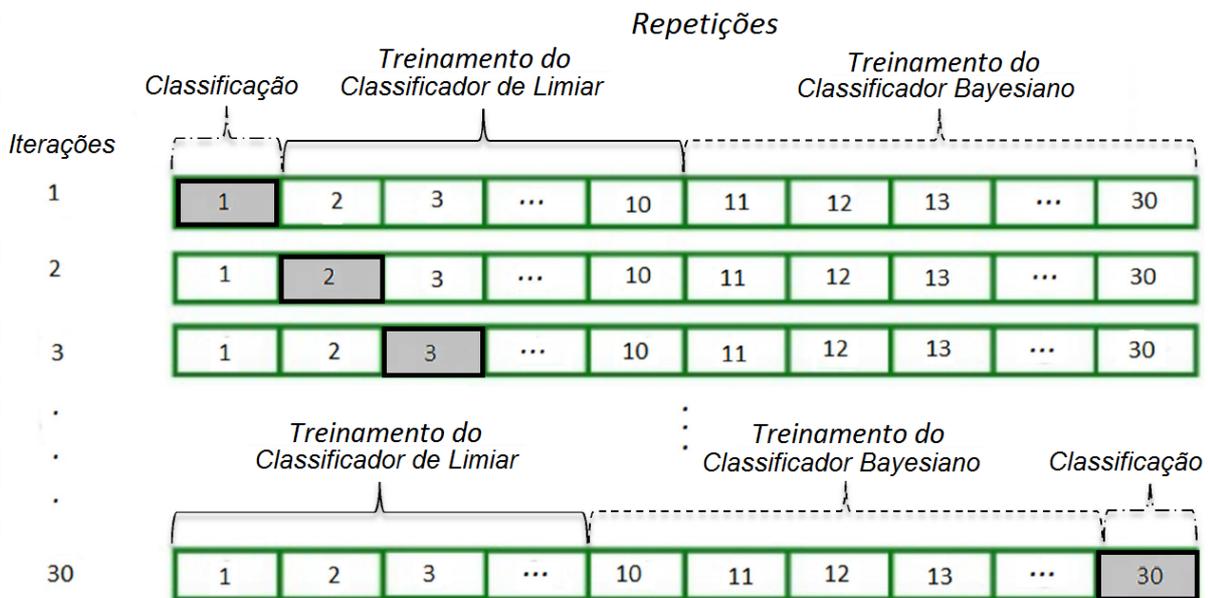


Figura 71 – Ilustração do processo de validação cruzada usando o método de *Leave-one-out* para treinamento e teste dos classificadores do sinal de EEG.

O procedimento de validação cruzada utilizando o método *Leave-one-out* nesta etapa é análogo ao utilizado no sinal de EMG. No entanto, para a classificação do sinal de EEG é preciso treinar o classificador Bayesiano utilizado e ajustar os parâmetros do classificador de limiar que é utilizado em conjunto com o anterior. Para isso, foi proposto o seguinte mecanismo: das 30 repetições disponíveis, treinou-se o classificador Bayesiano em 20, ajustou-se os parâmetros do classificador de limiar em 9 e classificou-se 1, mantendo o sistema de *Leave-one-out*, como é ilustrado na Figura 71.

Ressalta-se que, assim como no processamento dos sinais de EMG, as filtrações em frequência nos sinais de EEG foram realizadas utilizando-se a função *filtfilt* do MATLAB®.

O Capítulo 5 tratará dos resultados obtidos por este trabalho.

## 5 Resultados obtidos e discussão

Os resultados serão mostrados em duas abordagens: primeiramente, serão apresentados os resultados das etapas do processamento para cada tipo de sinal. Na Seção 5.2, uma comparação de resultados entre os sujeitos, para analisar de forma geral a interface multimodal proposta, abordando a antecipação do movimento e a acurácia dos classificadores será realizada. Discussões acerca dos resultados serão feitas a medida que estes forem expostos para melhor visualização dos gráficos e tabelas. Por fim, considerações finais acerca dos resultados obtidos serão feitas.

### 5.1 Resultados das etapas de processamento dos sinais

Nesta seção serão mostrados os resultados das etapas de processamento descritas no Capítulo 4. Tais etapas foram implementadas em todas as 30 repetições de movimento de cada experimento, para os cinco sujeitos. Exceto a Seção 4.3.1, que trata de uma técnica que leva em conta todas repetições para obter apenas um resultado. Os resultados entre as repetições são, em grande parte, muito semelhantes e serão ilustrados para alguns sujeitos. Diferenças relevantes entre as repetições e os sujeitos serão abordadas na Seção 5.2.

#### 5.1.1 Sinal das IMUs

Serão apresentados a seguir os resultados das etapas do processamento referentes à aferição dos ângulos do joelho a partir dos sinais dos sensores inerciais, como descrito na Seção 4.1.1.

Primeiramente, foram obtidos ângulos de cada sensor com referência global. Tais ângulos são mostrados na Figura 72, em que são apresentados os ângulos do sensor fixo, referente ao sensor da coxa, e do sensor móvel, referente ao sensor da panturrilha. Os gráficos mostram o deslocamento em ângulos ao longo do tempo de uma repetição do experimento. Como descrito na Seção 4.1, os ângulos *roll*, *pitch* e *yaw* referem-se aos movimentos de rotação interna/externa, adução/abdução e flexão/extensão, respectivamente. Pode ser observado que a suposição de que há deslocamento apenas da panturrilha é válida, pois os deslocamentos do sensor da coxa são muito pequenos em relação ao deslocamento principal do sensor da panturrilha. Também pode ser observado que o maior deslocamento ocorre no sensor móvel em *yaw*, pois este se refere ao movimento principal realizado. Os valores dos ângulos dependem da posição em que o sujeito se encontra em relação à referência global do sistema inercial no momento do experimento.

A Figura 73 mostra os ângulos relativos do joelho, isto é, os ângulos do sensor

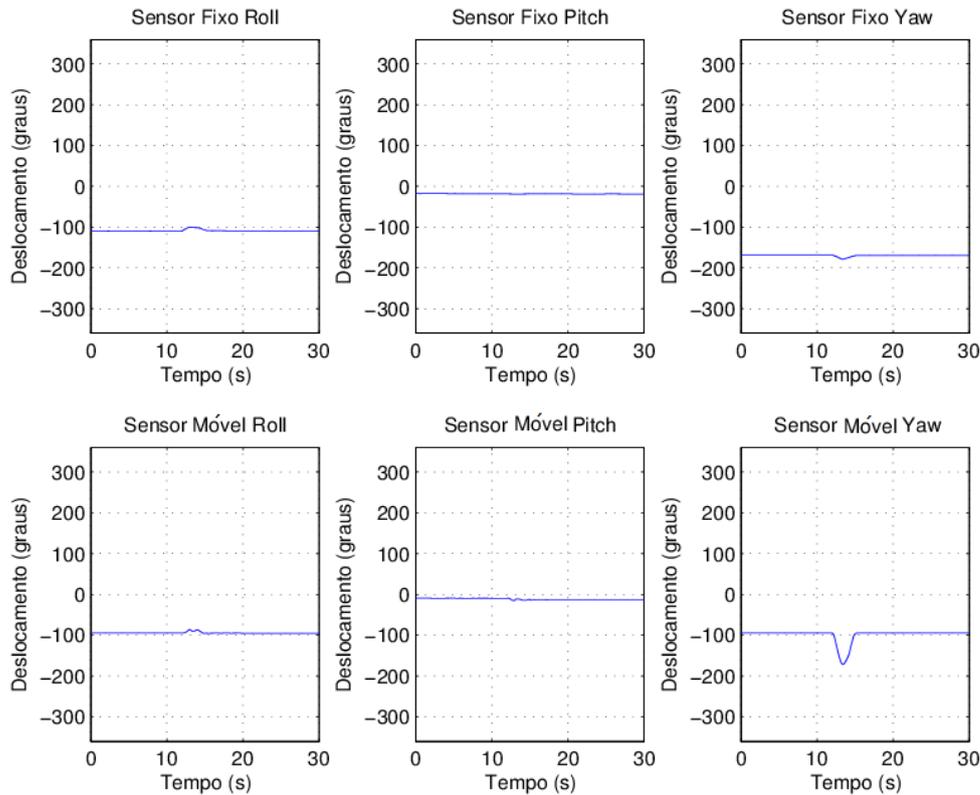


Figura 72 – Ângulos dos sensores com referência global.

móvel e fixo em relação ao sensor fixo no momento de calibração do sistema inercial, sem que o alinhamento virtual, descrito na Seção 4.1.1, seja aplicado. É possível observar que os sensores não estão alinhados como na suposição descrita na Seção 4.1.1, pois os ângulos relativos do sensor móvel em relação ao sensor fixo não começam exatamente em  $0^\circ$ ,  $0^\circ$  e  $90^\circ$ . Os ângulos do sensor da coxa variam ao longo do experimento pois, são referenciados a este sensor em seu momento de calibração.

A Figura 74 mostra os ângulos relativos do joelho, isto é, os ângulos do sensor móvel e fixo em relação ao sensor fixo no momento de calibração do sistema inercial com o alinhamento virtual proposto aplicado. É possível observar que os sensores começam o experimento alinhados de acordo com a suposição realizada:  $0^\circ$ ,  $0^\circ$  e  $90^\circ$  em *roll*, *pitch* e *yaw*, respectivamente. Os ângulos então, são aferidos corretamente ao longo do experimento. O principal deslocamento ocorre em *yaw*, coerente com o movimento proposto nos testes. Como dito, este ângulo parte de  $90^\circ$  e vai até a máxima extensão do sujeito. Neste caso, este valor foi de, aproximadamente,  $10^\circ$ .

Nas Figuras 72, 73 e 74, pode ser observado também que quando há uma extensão na articulação do joelho, ocorrem também movimentos secundários ao principal, como pequenas rotações e adução/abdução da panturrilha. Tais figuras são referentes ao mesmo movimento realizado pelo *Sujeito 1*. As outras repetições do experimento têm resultado

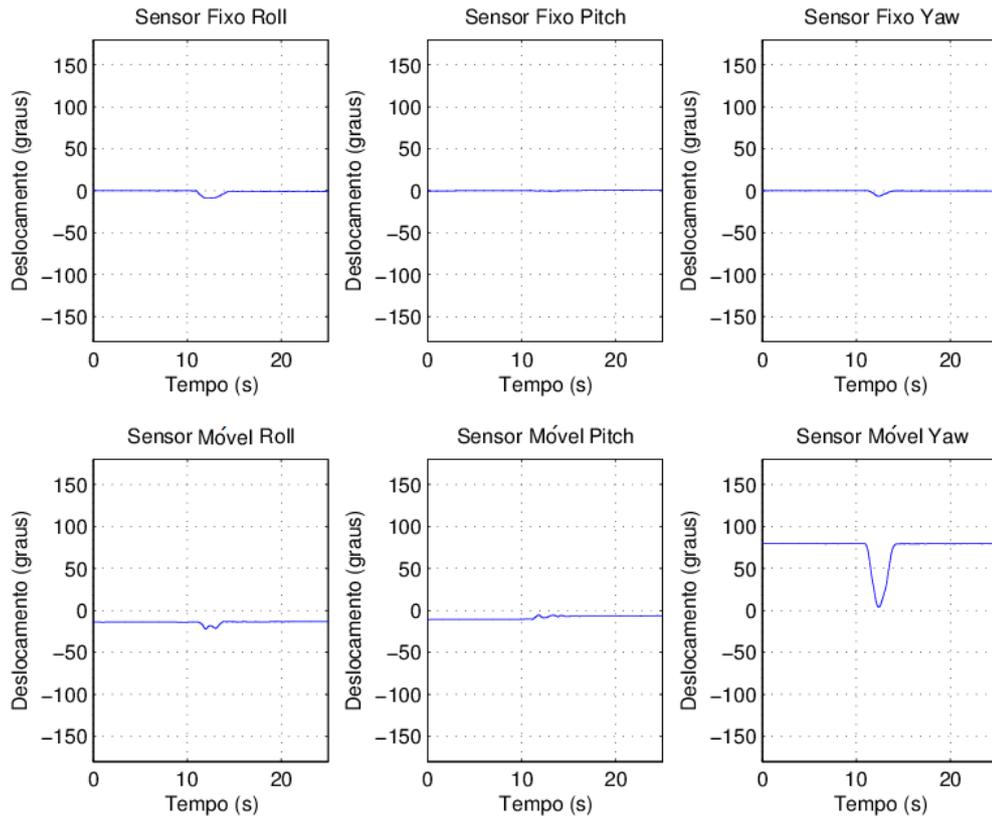


Figura 73 – Ângulos relativos do joelho sem alinhamento virtual dos sensores inerciais.

análogo aos mostrados. Os resultados obtidos são coerentes com os apresentados em ??Favre et al. (2009), Pons (2008a).

A detecção do início efetivo do movimento, descrita na Seção 4.1.2, é ilustrada pela Figura 75.

Na Figura 75, é possível observar na linha tracejada o momento em que o classificador, baseado na Equação 4.9, detecta o início efetivo do deslocamento do membro inferior a partir da análise do ângulo *yaw* do sensor da panturrilha com referência global. É possível observar também o tempo em que o sujeito começou o movimento: 11,997 segundos após o primeiro sinal sonoro, nesta repetição, coerente com o protocolo experimental. A partir do menor valor deste tempo, entre os movimentos, que foi realizada a sincronia entre as repetições descrita na Seção 4.1.2.

Para se chegar a uma classificação precisa acerca do tempo do início efetivo do movimento, descartam-se classificações antes dos 10 segundos, pois seriam falsos positivos (protocolo experimental). Faz-se o peso do desvio padrão,  $p$ , pequeno, a quantidade de janelas acima do limiar grande, bem como a sobreposição de janelas, proporcionados pela análise *offline*. Dessa forma, faz-se uma procura por parâmetros através da variação em faixas de valores e têm-se boa precisão do início do movimento. A Figura 75 é referente ao

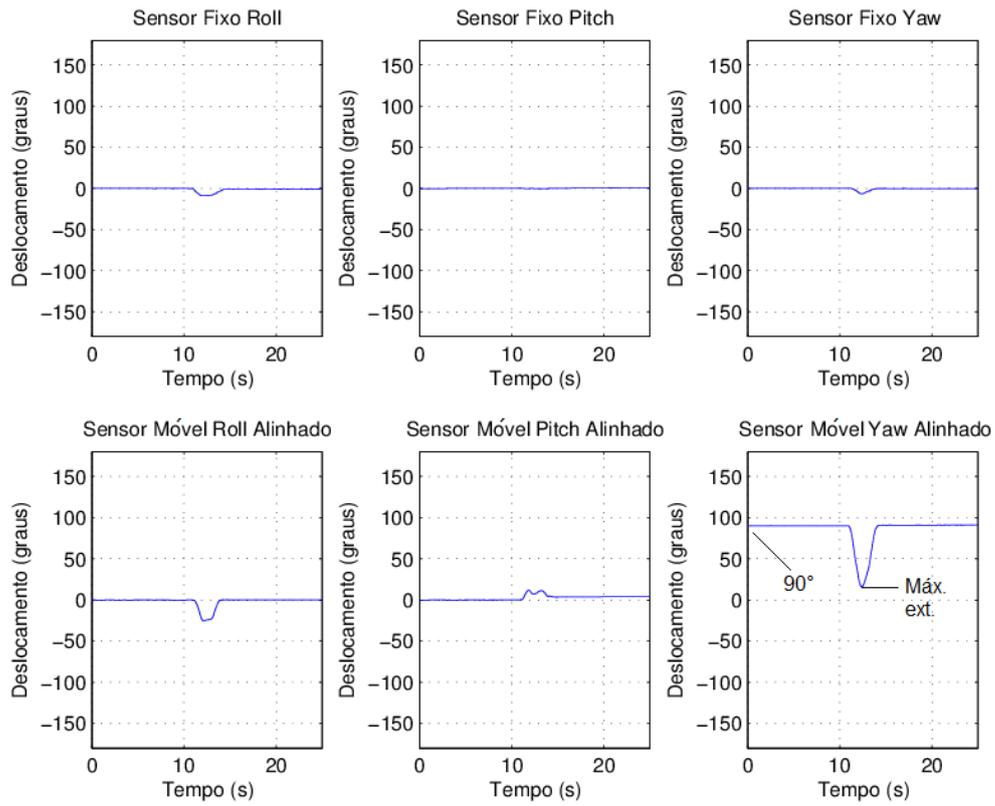


Figura 74 – Ângulos relativos do joelho com alinhamento virtual dos sensores inerciais.

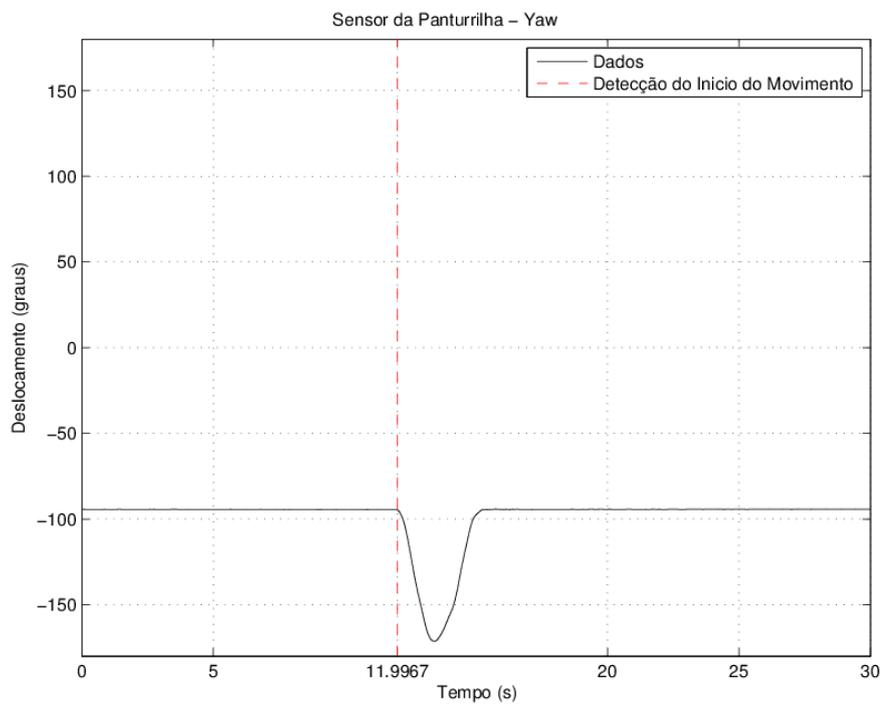


Figura 75 – Deteccção do início efetivo de movimento.

mesmo movimento mostrado nas Figuras 72, 73 e 74. As outras repetições têm resultados análogos, apenas com tempos diferentes.

### 5.1.2 Sinal de sEMG

Serão mostrados a seguir os resultados referentes às etapas de processamento do sinal de sEMG, descrito na Seção 4.2.

A Figura 76 mostra o sinal de sEMG não processado adquirido pelo sistema.

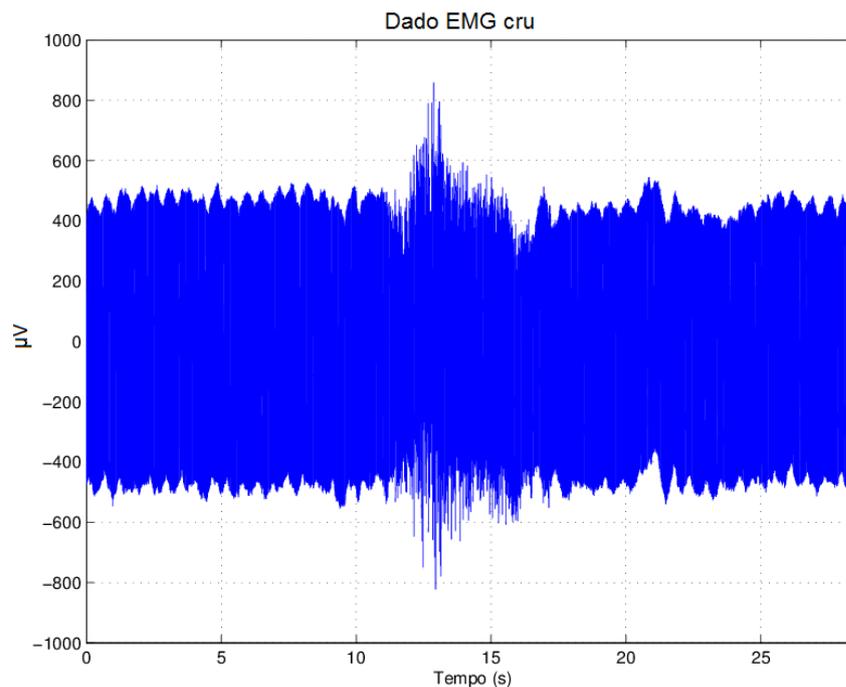


Figura 76 – Sinal de sEMG cru.

Na Figura 76, é possível observar uma diferenciação no sinal em torno dos 12 segundos, referente à ativação muscular. No entanto, o sinal é muito ruidoso e não há precisão para que métodos de processamento de dados classifiquem o início da ativação muscular.

A Figura 77 mostra o sinal de sEMG filtrado em frequência a partir dos filtros *Notch* para eliminação de artefatos da rede elétrica. É possível observar que houve uma grande retirada dos ruídos. No entanto, ainda há componentes de frequência, principalmente de baixo valor, que não estão na banda característica do músculo aferido segundo [Hermens et al. \(1999\)](#), como comentado na Seção 4.2. Neste sinal também não há fácil caracterização do início da ativação muscular.

A Figura 78 mostra o sinal da Figura 77 filtrado em frequência, com filtro passa-altas, com o corte em 20 Hz. É possível observar um sinal típico de sEMG para o músculo aferido descrito em [Criswell \(2011\)](#). No entanto, ainda não há precisão para detecção

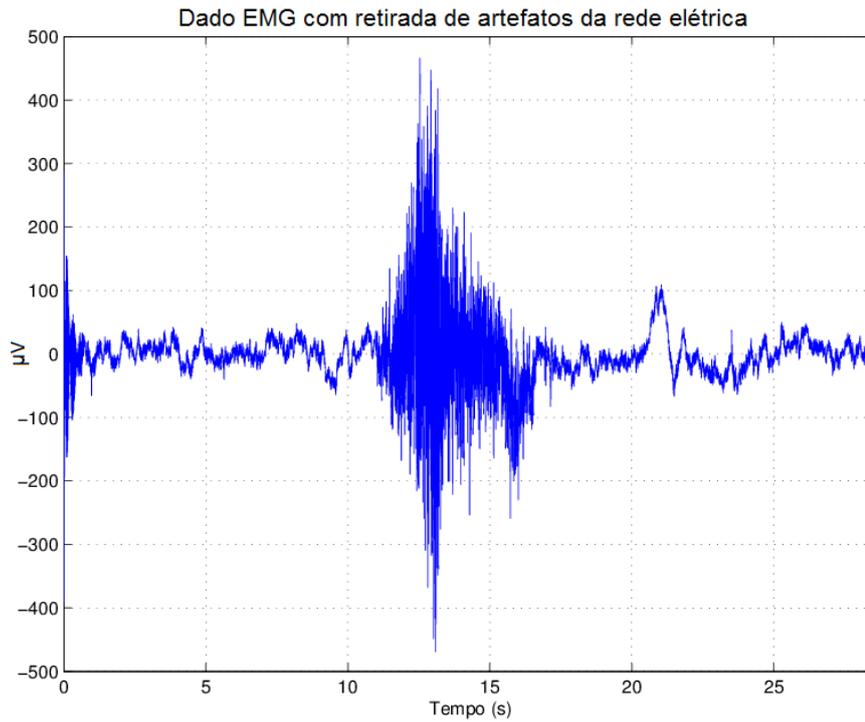


Figura 77 – Sinal de sEMG filtrado em frequência a partir dos filtros *Notch*.

do início da contração muscular através de um método computacional simples, como o utilizado neste trabalho.

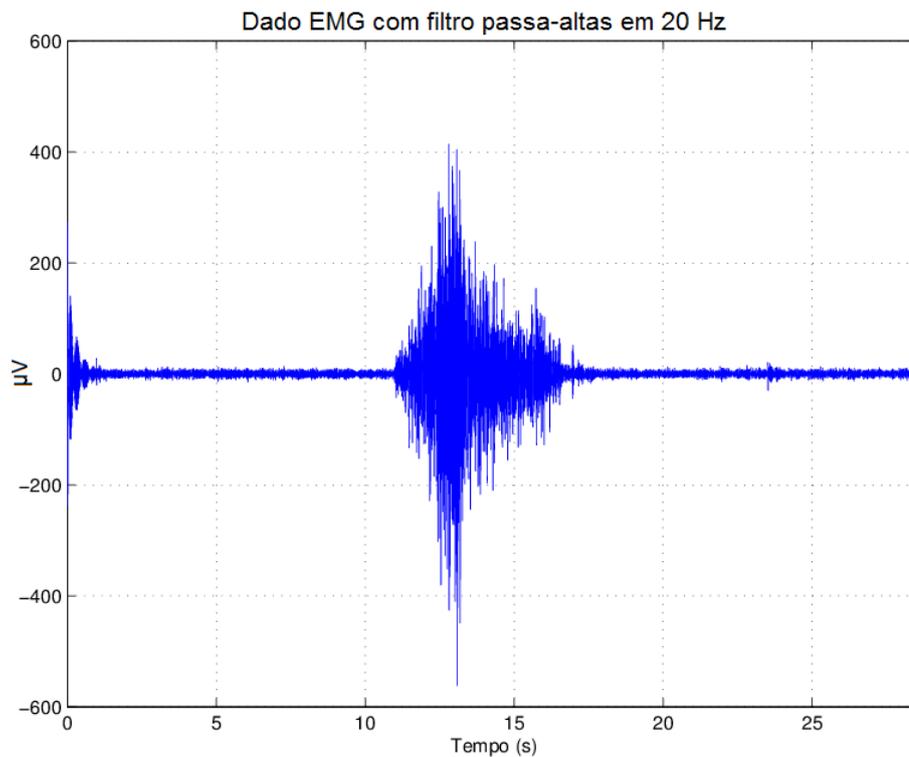


Figura 78 – Sinal da Figura 77 filtrado em frequência, com filtro passa-altas.

A Figura 79 mostra o sinal da Figura 78 filtrado com o filtro de variância descrito pela Equação 4.10.

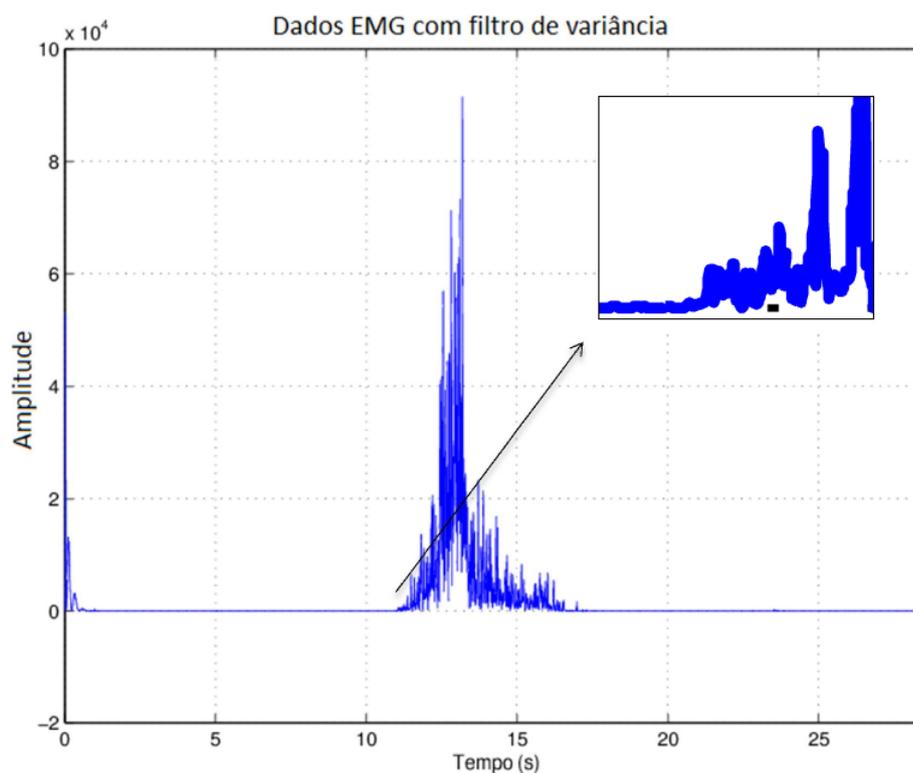


Figura 79 – Sinal da Figura 78 filtrado com o filtro de variância.

Na Figura 79 é possível observar a evidente retirada de ruídos que a filtragem proporciona e, conseqüentemente, a clara diferenciação entre os momentos de repouso e ativação muscular. Tal situação fica clara no canto direito superior, onde é mostrado o momento em que ocorre a contração muscular em escala aumentada em relação à mostrada no resto da figura. Dessa forma, o classificador, baseado na Equação 4.11, detecta o início da ativação muscular com boa precisão para a aplicação deste trabalho.

As Figuras 76 até 79 são referentes a um mesmo movimento realizado pelo *Sujeito 2*. As outras repetições têm resultados análogos.

### 5.1.3 Sinal de EEG

Serão mostrados a seguir os resultados obtidos para o processamento do sinal eletroencefalográfico com o objetivo de detectar a intenção de movimento utilizando-se várias épocas do sinal, como descrito na Seção 4.3.1.

A Figura 80 mostra a energia relativa percentual ao longo do tempo, em segundos, dos canais de EEG nas bandas  $\mu$ , em preto, e  $\beta$ , em cinza. Os sinais estão relativos à linha-base, descrita na Seção 3.4, do segundo 5 ao 8, calculados através da Equação 2.1

e foram obtidos pelo do método clássico descrito por [Pfurtscheller \(1999\)](#). É possível observar na banda  $\mu$ , principalmente nos canais sobre o córtex motor (C3, Cz e C4), uma diminuição do sinal. Essa diminuição é a dessincronização relacionada ao evento ou o ERD, discutido na Seção 2.1. Essa diminuição ocorre, aproximadamente, após 10 segundos e chega, a aproximadamente, 80% naqueles canais. O ERD dura, aproximadamente, em média, 5 segundos. Como o ERD tem relação com a intenção e realização do movimento, a partir de uma análise qualitativa, pode-se dizer que este resultado está coerente com os encontrados por [Pfurtscheller \(1999\)](#). É possível observar também um aumento do sinal na banda  $\beta$ , principalmente nos canais Cz e C4, aproximadamente, após 16 segundos. Esse aumento é a sincronização relacionada ao evento ou o ERS, discutido na Seção 2.1. Como o ERS é tipicamente observado após a realização do movimento, a partir de uma análise qualitativa, também pode-se dizer que este resultado está coerente com os encontrados por [Pfurtscheller \(1999\)](#).

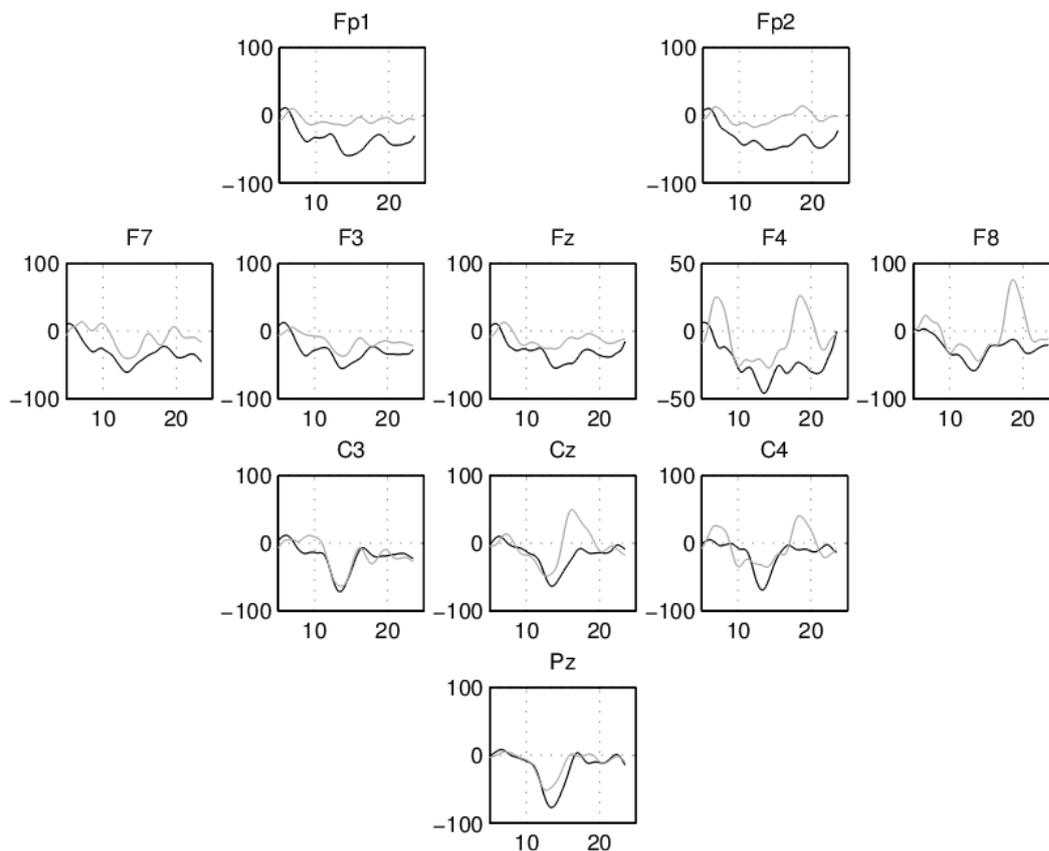


Figura 80 – Sinal de energia relativa nas bandas  $\mu$ , em preto, e  $\beta$ , em cinza.

Ressalta-se que essas características foram observadas levando-se em consideração todas as repetições do experimento realizado pelo *Sujeito 3*. Tais características foram avaliadas para todos os sujeitos e os resultados foram análogos aos mostrados, mesmo havendo variações dos padrões de ERD/ERS entre os sujeitos, o que é esperado como

discutido no Capítulo 2.

A seguir serão mostrados os resultados obtidos para as etapas do processamento do sinal eletroencefalográfico com o objetivo de detectar a intenção de movimento utilizando-se uma época do sinal, como descrito na Seção 4.3.2. Primeiramente, serão mostrados os resultados das etapas do pré-processamento do sinal, descrito na Seção 4.3.2.1.

A Figura 81 mostra uma época do sinal de EEG não processado do canal Cz.

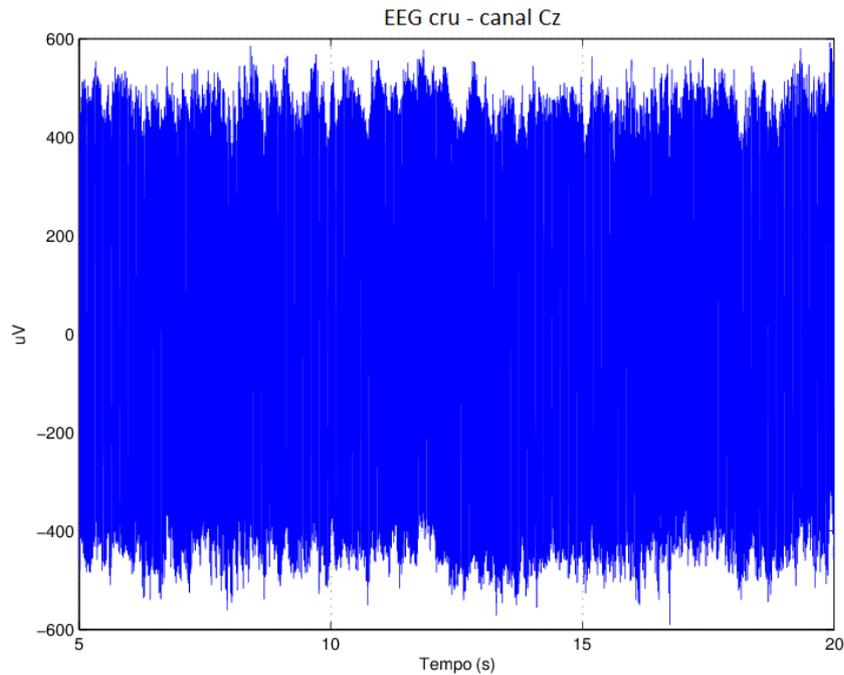


Figura 81 – Sinal de EEG cru do canal Cz.

Na Figura 81 não é possível observar nenhum padrão no sinal associado aos ritmos de EEG, apenas ruídos.

A Figura 82 mostra uma época do sinal de EEG filtrado na frequência com filtro *Notch*, especialmente com filtro *CAR* e depois de ter passado pela Separação Linear de Fontes, do canal Cz. É possível observar a evidente retirada de ruídos que os processamentos aplicados realizam. O sinal está coerente em amplitude e forma com um sinal de eletroencefalografia, no entanto, ainda não é possível observar um padrão claro associado aos ritmos típicos do sinal relacionados à intenção de movimento.

A Figura 83 mostra uma época do sinal de EEG da Figura 82 filtrado em frequência na banda  $\mu$ . É possível observar uma diminuição da energia do sinal, aproximadamente, após os 11 segundos. Essa diminuição refere-se ao ERD que está relacionado à intenção e realização do movimento, coerente com Pfurtscheller (1999). Então, a partir do processamento utilizado é possível visualizar o padrão no sinal em apenas uma época, repetição ou *trial*. As características que alimentam os classificadores Bayesiano e de limiar, que têm o

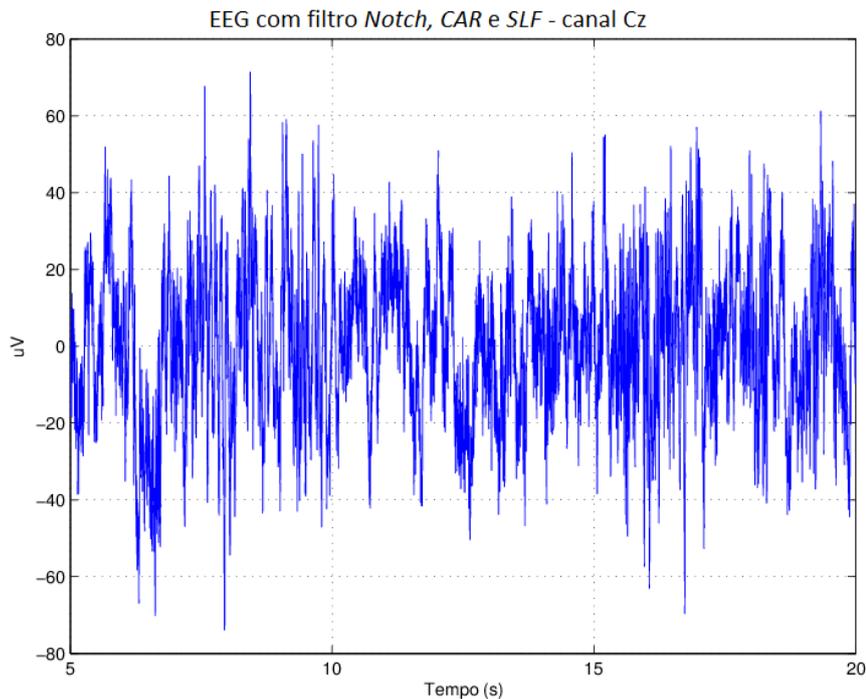


Figura 82 – Sinal de EEG filtrado na frequência com filtro *Notch*, espacialmente com filtro *CAR* e depois de ter passado pela SFL, do canal Cz.

objetivo de detectar o primeiro momento de intenção de movimento, são obtidas a partir dos sinais que passam pelo pré-processamento ilustrado, que tem como resultado o sinal mostrado na Figura 83.

Serão mostrados a seguir os resultados das etapas de classificação do sinal, descrito na Seção 4.3.2.2, que representam as características utilizadas para alimentar os classificadores utilizados.

A Figura 84 mostra a magnitude dos PSDs das janelas do sinal de EEG ao longo do tempo na frequência em que houve a maior diferença entre os momentos definidos como *parado* e *movimento* para uma época no canal Cz, em uma das iterações do processamento. Essa frequência foi obtida através da Equação 4.30 e o PSD referente à tal frequência, através da Equação 4.31.

Na Figura 84, é possível observar um decremento médio da magnitude dos PSDs em torno do segundo 11, indicando o padrão de intenção de movimento, perdurando-se até, aproximadamente, o segundo 15.

Ratifica-se que, como descrito na Seção 4.3.2.2, a cada iteração do treinamento do classificador Bayesiano, a moda das frequências do espectro em que há maior dessincronização (Equação 4.30) é utilizada na classificação. Tomando-se as frequências que mais aparecem neste procedimento, para cada sujeito, tem-se a Tabela 4.

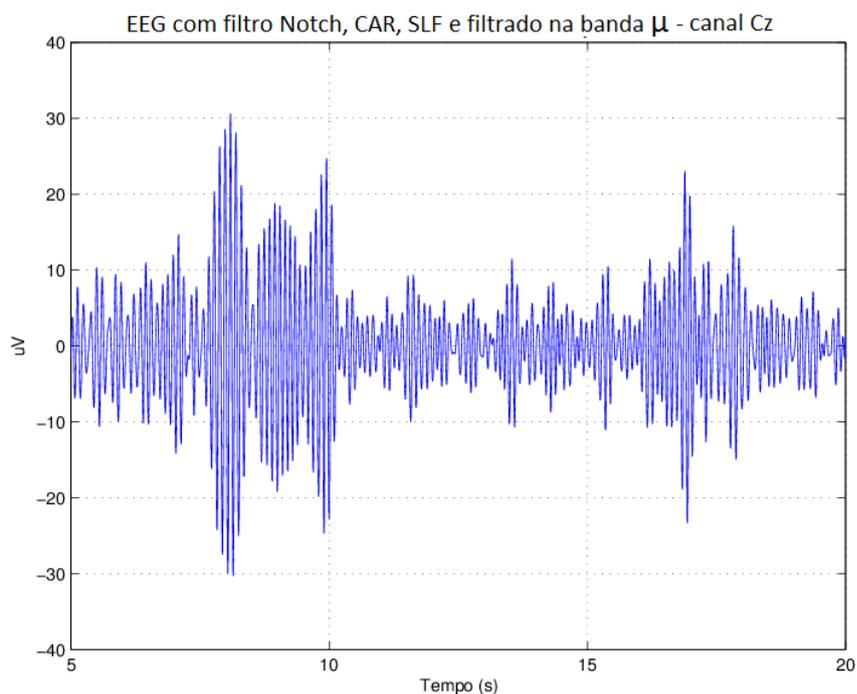
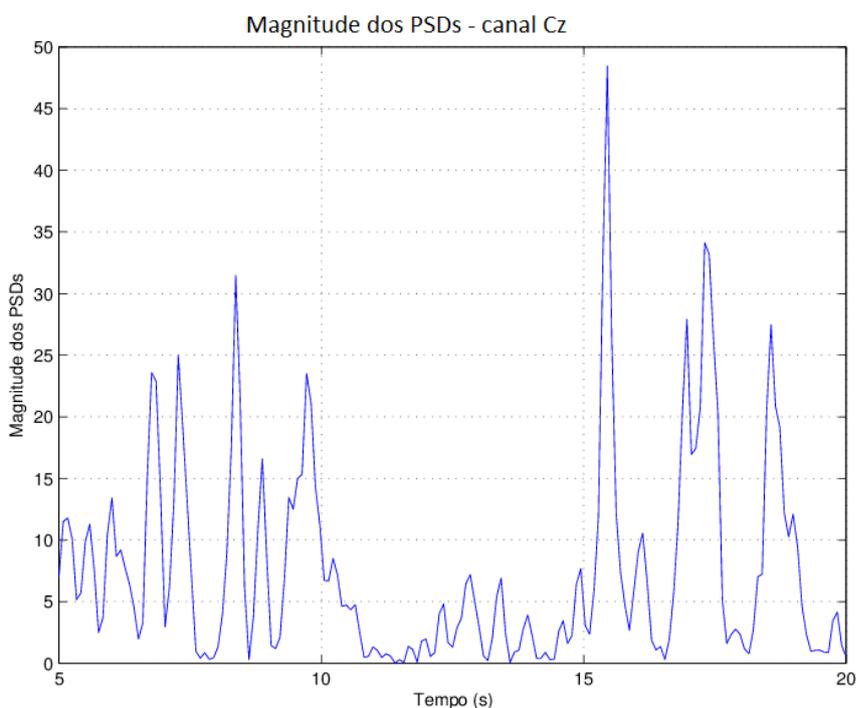
Figura 83 – Sinal de EEG da Figura 82 filtrado em frequência na banda  $\mu$  .

Figura 84 – Magnitude dos PSDs na frequência selecionada ao longo das janelas de tempo em uma época no canal Cz.

Como na Tabela 4 estão mostradas, para todos os sujeitos, as frequências que mais aparecem no procedimento descrito anteriormente, pode-se dizer que são mostradas as

Moda das frequências selecionadas em cada iteração por canais (Hz)					
Canal	Sujeito 1	Sujeito 2	Sujeito 3	Sujeito 4	Sujeito 5
$C3$	10,547	8,9355	9,2285	9,082	9,8145
$Cz$	9,9609	9,375	8,7891	10,254	9,9609
$C4$	9,8145	8,9355	9,375	10,107	9,9609

Tabela 4 – Modas das frequências selecionadas em cada iteração da validação cruzada para os canais.

modas das modas das frequências de cada iteração da validação cruzada, por canal. É possível observar que as frequências estão, coerentemente, dentro da banda filtrada do sinal, i.e., de 8 a 12 Hz.

A Figura 85 mostra a diferença entre os discriminantes (*classe parado* subtraído da *classe movimento*) dados pela Equação 4.29 para a decisão entre as classes.

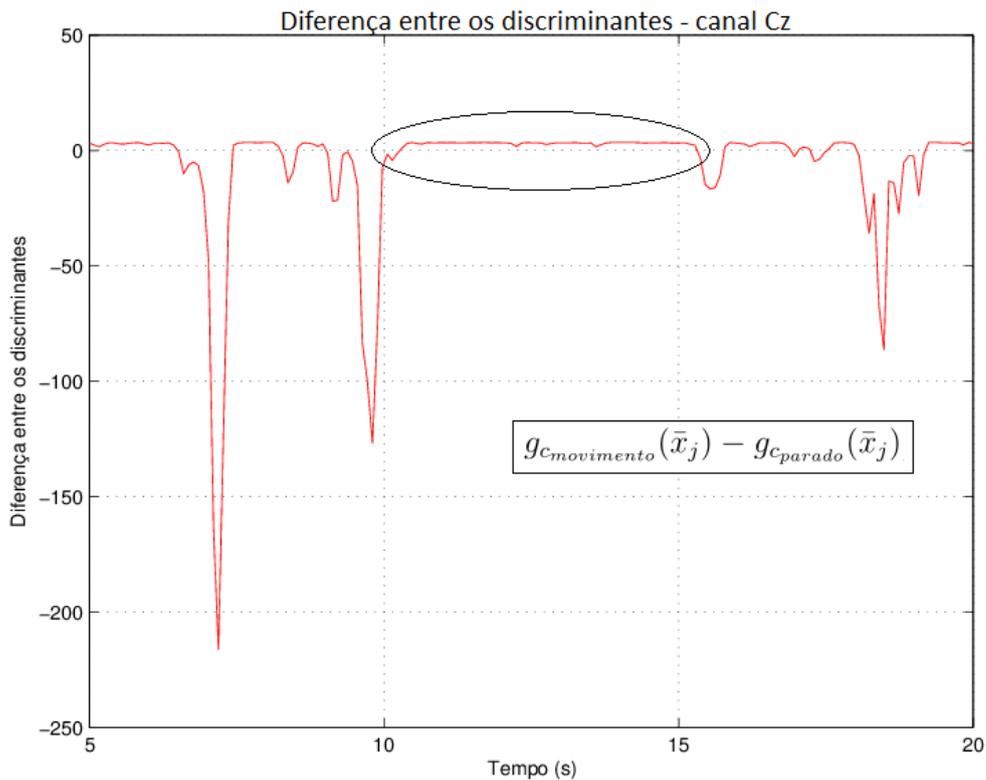


Figura 85 – Sinal relativo à diferença entre os discriminantes.

Na Figura 85, quando o valor do sinal se torna positivo e estável, como destacado, tem-se a classificação para a *classe movimento*. No entanto, o sinal nesta figura apresenta variações que dificultam essa classificação a partir do classificador de limiar adaptável, e seus parâmetros, discutido na Seção 4.3.2.2. Tais variações podem ser diminuídas através

do cálculo da variância do sinal mostrado na Figura 85, operação ilustrada na Figura 86, dada pela Equação 4.34.

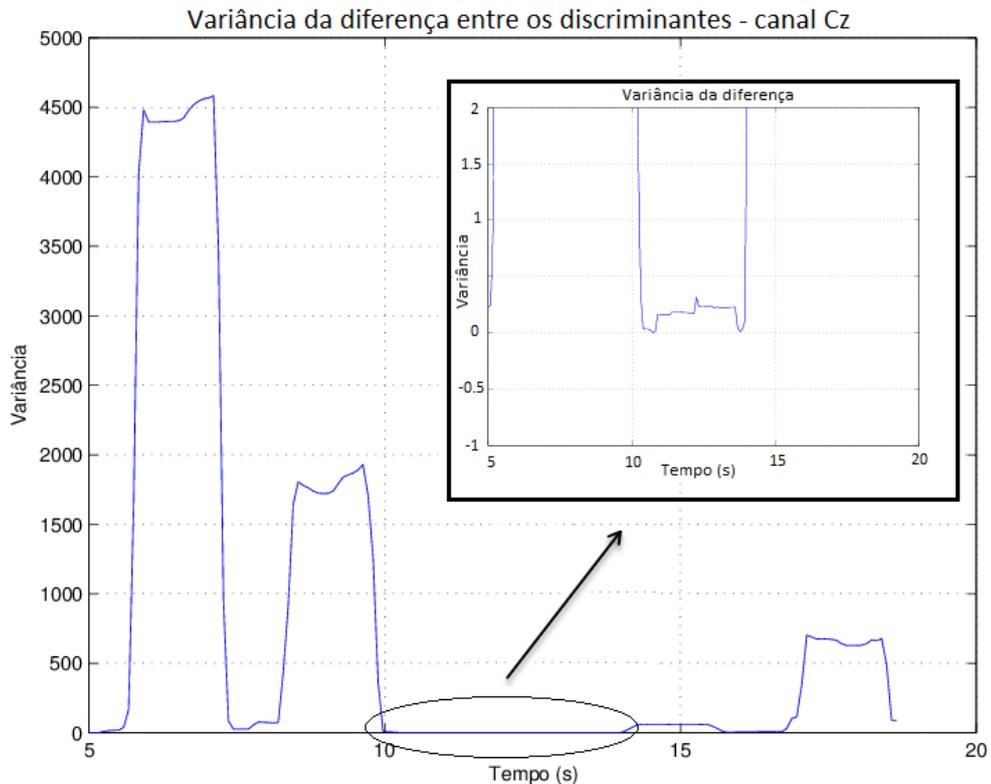


Figura 86 – Sinal relativo à variância da diferença entre os discriminantes.

Na Figura 86, é possível observar um sinal melhor discernível para um classificador de limiar inferior, com diferenciação nítida no sinal a partir de, aproximadamente, 11 segundos. Tal fato fica evidenciado no canto direito superior da figura, em que o sinal é mostrado com uma escala conveniente no eixo da amplitude. Assim, o classificador de limiar detecta o início da intenção de movimento com boa precisão para a aplicação deste trabalho. Além disso, a classificação é realizada a partir de mais parâmetros com a análise da variância, o que traz mais flexibilidade ao algoritmo e a possibilidade de melhor adaptabilidade para reconhecimento dos padrões apresentados pelos sujeitos.

As Figuras 81 até 86 são referentes a um mesmo movimento realizado pelo *Sujeito 4*. As outras repetições têm resultados análogos.

A seguir, serão mostradas, para o *Sujeito 2*, os resultados das classificações dos sinais de EEG e EMG combinadamente. A Figura 87 mostra as detecções para os sinais de EEG (triângulos) e EMG (pontos), realizadas pelos classificadores através dos procedimentos de validação cruzada com método de *leave-one-out*, descritos na Seções 4.3.2.2 e 4.2, respectivamente.

Na Figura 87, os pontos são referentes aos momentos em que o classificador

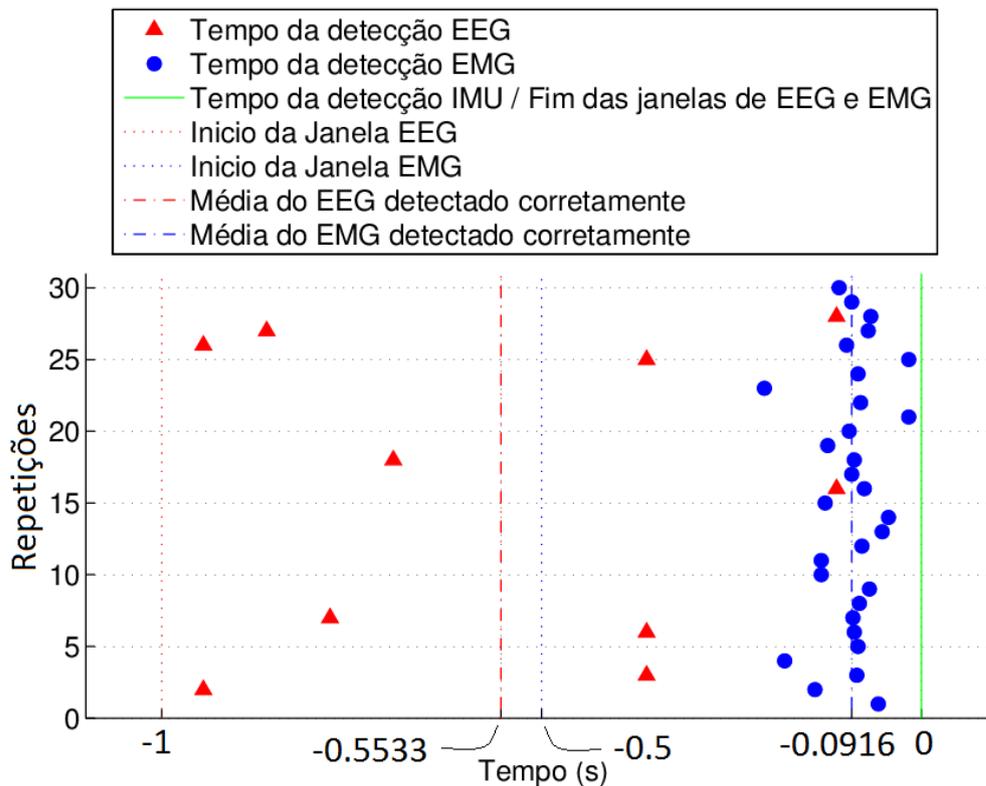


Figura 87 – Detecções de EEG (triângulos) e EMG (pontos) realizadas pelos classificadores através dos procedimentos de validação cruzada.

reconheceu início da ativação muscular e os triângulos são referentes aos momentos de início da intenção de movimento. O tempo 0 refere-se ao início de movimento efetivo detectado pelo sinal das IMUs, tempos negativos referem-se a momentos anteriores. Tal início de movimento é referente ao primeiro movimento entre as repetições que foram sincronizadas, como descrito na Seção 4.1.2.

As janelas de EMG e EEG são janelas de tempo nas quais convencionou-se aceitar detecções corretas do início da ativação muscular e intenção de movimento, respectivamente. Tais janelas são a restrição para uma classificação correta e a atualização ou não dos parâmetros dos classificadores no processo de validação cruzada. As janelas utilizadas neste caso foram de até 0,5 e 1 segundos antes do movimento efetivo até o início deste, respectivamente, para o sinal de EMG e EEG. Tais janelas foram propostas por [Kirchner, Tabie e Seeland \(2014\)](#). Para este sujeito, foi possível detectar todos os movimentos baseado em EMG dentro da respectiva janela, com uma média de 91,6 ms antes do movimento, valor de mesma ordem e portanto, coerente com o obtido por [Kirchner, Tabie e Seeland \(2014\)](#), de 61 ms. Baseado no EEG, foi possível detectar 33,33% (10 das 30 repetições) dos movimentos dentro da respectiva janela, com uma média de 532,2 ms antes do movimento, valor de mesma ordem e portanto, também coerente com o obtido por [Kirchner, Tabie e](#)

Seeland (2014), de 450 ms.

Na Figura 87 também é possível ser observado que as detecções de EMG têm menor variação temporal que as detecções de EEG. Este sinal tem detecções mais esparsas e apresenta maior erro.

Os momentos de detecção pelos classificadores, dentro ou fora das janelas de tempo permitidas, definem a acurácia do sistema multimodal. Tal discussão acerca das janelas de tempo permitidas, do tempo médio de detecção ou antecipação do movimento e acurácia dos classificadores para todos os sujeitos será abordada com maiores detalhes, a seguir, na Seção 5.2. Assim, uma comparação dos resultados entre sujeitos e uma mensuração de como foi o desempenho geral das classificações deste sistema poderão ser feitas.

## 5.2 Acurácia dos classificadores e antecipações aos movimentos

Pode-se definir a acurácia do sistema, por experimento ou por sujeito, como a relação entre a quantidade de repetições que foram classificadas corretamente e a quantidade total de repetições. A classificação correta significa a classificação dentro da janela de tempo permitida, como citado para o *Sujeito 2* e *Sujeito 4*. Definiremos duas janelas de tempo para os sinais de EEG e EMG: *Janela1* para o EEG refere-se ao início efetivo do movimento, tempo 0, até o tempo -2 segundos, i.e., até 2 segundos antes; *Janela2* para o EEG refere-se ao início efetivo do movimento, tempo 0, até o tempo 1 segundo, i.e., até 1 segundo depois; *Janela1* para o EMG refere-se ao início efetivo do movimento, tempo 0, até o tempo -0,5 segundos, i.e., até 0,5 segundos antes; e *Janela2* para o EMG refere-se ao início efetivo do movimento, tempo 0, até o tempo 0,1 segundos, i.e., até 100 ms segundos depois. A *Janela1* do EEG é coerente com os trabalhos de Gallego et al. (2012), Ibanez et al. (2013), Pfurtscheller (1999); A *Janela1* do EMG é coerente com o trabalho de Kirchner, Tabie e Seeland (2014). As *Janelas 2* do EEG e EMG são analisadas pelo presente autor para uma discussão acerca do desempenho do sistema proposto.

A Tabela 5 mostra a acurácia dos classificadores, a partir das definições anteriores, obtidas pela interface proposta para os sinais de EEG para cada sujeito. É possível observar que a acurácia na antecipação do movimento, i.e., referente à *Janela1* chega a 60%. Valor, mesmo que inferior, coerente com os obtidos em Ibanez et al. (2013), que chegam em torno de 75% em seu grupo de controle (6 pessoas saudáveis). É possível observar também que a média de antecipação do movimento baseada somente no EEG foi de  $40,6 \pm 19,3\%$ . Ibanez et al. (2013) obtiveram  $60,0 \pm 11,0\%$ , no grupo de controle, e  $42,0 \pm 27,0\%$ , em um grupo de 4 pacientes com tremores patológicos, de antecipação de movimento. A partir dos trabalhos de Pfurtscheller (1999), Ibanez et al. (2013), Gallego et al. (2012) é sabido que a característica do sinal cerebral avaliada pode não ocorrer antes do movimento, mas sim durante ou até mesmo não ocorrer, pois está relacionada a aspectos fisiológicos individuais

de cada sujeito. Por isso, foi avaliada a *Janela2* para se considerar um aparecimento do padrão procurado durante a realização do movimento. Considerando-se ambas a janelas de tempo, a acurácia média do sistema foi de  $63,3 \pm 12,4\%$ .

<b>Sinal de EEG</b>					
<b>Janela</b>	Sujeito 1	Sujeito 2	Sujeito 3	Sujeito 4	Sujeito 5
<i>Janela1 (-2 s a 0)</i>	43,3%	53,3%	10,0%	60,0%	36,7%
<b>Média de antecipação EEG</b>					
40,6 ± 19,3%					
<i>Janela2 (0 a 1 s)</i>	26,7%	23,3%	53,3%	3,3%	6,7%
<b>Total EEG (-2 a 1 s)</b>	70,0%	76,6%	63,3%	63,3%	43,4%
<b>Média Total EEG</b>					
63,3 ± 12,4%					

Tabela 5 – Acurácia dos classificadores por janelas de tempo obtidas pela interface proposta para os sinais de EEG.

A Tabela 6 mostra a acurácia dos classificadores, a partir das definições anteriores, obtidas pela interface proposta para os sinais de EMG para cada sujeito.

<b>Sinal de EMG</b>					
<b>Janela</b>	Sujeito 1	Sujeito 2	Sujeito 3	Sujeito 4	Sujeito 5
<i>Janela1 (-0,5 s a 0)</i>	46,7%	100,0%	43,3%	76,7%	46,7%
<b>Média de antecipação EMG</b>					
62,7 ± 24,9%					
<i>Janela2 (0 a 0,1 s)</i>	3,3%	0,0%	16,7%	10,0%	53,3%
<b>Total EMG (-0,5 a 0,1 s)</b>	50,0%	100,0%	60,0%	86,7%	100,0%

Tabela 6 – Acurácia dos classificadores por janelas de tempo obtidas pela interface proposta para os sinais de EMG.

Na Tabela 6 é possível observar que a acurácia na antecipação do movimento, i.e., referente à *Janela1* chega a 100%. É possível observar também que a média de antecipação do movimento baseada somente no EMG foi de  $62,7 \pm 24,9\%$ . Naturalmente, a ativação muscular deve ocorrer antes do movimento efetivo. No entanto, considerando um pequeno atraso na detecção do sistema, de 100 ms, mesmo não tornando a classificação correta, analisou-se a *Janela2*. Essa análise mostra que grande parte das detecções de EMG que não ocorrem na antecipação ocorrem muito próximas, ou seja, com um pequeno erro, i.e., atraso de 0,1 segundos. Tal fato pode ser observado acentuadamente no *Sujeito 3* e no *Sujeito 5*.

A Tabela 7 mostra a acurácia na antecipação do movimento (*Janela1*) tomando-se sinais de EEG OU de EMG para cada sujeito.

<b>Antecipação do movimento - EEG OU EMG</b>				
Sujeito 1	Sujeito 2	Sujeito 3	Sujeito 4	Sujeito 5
80,0%	100,0%	53,3%	83,3%	63,3%
<b>Média de antecipação</b>				
75,98 ± 18,18%				

Tabela 7 – Acurácia na antecipação do movimento (*Janela1*) em sinais de EEG OU EMG.

Na Tabela 7 é possível observar que a antecipação média do movimento a partir do sinal de EEG ou de EMG foi de 75,98 ± 18,18%, consideravelmente maior que a partir de apenas um dos sinais. Tal fato evidencia o ganho proporcionado por uma abordagem multimodal em detrimento da análise de apenas um sinal.

A Tabela 8 mostra os tempos de antecipação do movimento (*Janela1*) para os sinais de EEG e EMG para cada sujeito.

<b>Antecipação do movimento (<i>Janela1</i>)</b>					
Sujeitos	1	2	3	4	5
<b>Tempo EEG</b> (ms)	492,6	814,8	770,0	677,6	825,0
	±	±	±	±	±
	451,5	578,9	740,7	436,4	523,1
<b>Tempo EMG</b> (ms)	91,5	91,6	87,7	109,7	61,2
	±	±	±	±	±
	94,8	40,7	77,4	93,2	30,3
<b>Média do Tempo EEG (ms)</b>					716,0 ± 546,1
<b>Média do Tempo EMG (ms)</b>					88,34 ± 67,28

Tabela 8 – Tempo médio e desvio padrão das classificações de antecipação do movimento.

Na Tabela 8, é possível observar que a média de tempo de antecipação baseada em EEG foi de 716,0 ± 546,1 ms, enquanto a baseada em EMG foi de 88,34 ± 67,28 ms. Estes valores são coerentes com os obtidos por [Kirchner, Tabie e Seeland \(2014\)](#), como citado na Seção 5.1, e por [Ibanez et al. \(2013\)](#), que obtiveram 970,0 ± 990,0 ms para antecipação de movimento baseada no EEG de pessoas saudáveis.

A partir dos resultados mostrados também é possível observar que a antecipação ao movimento é maior analisando-se o sinal de EEG. No entanto, como já mencionado e explanado na Tabela 9, este apresenta uma menor acurácia, i.e., detecções fora da janela, como falsos positivos, i.e., detecções anteriores aos momentos permitidos segundo à literatura atual ou falsos negativos, i.e., não detecção ou atraso na detecção, sendo estas posteriores aos momentos permitidos segundo à literatura atual. Essa verificação é coerente com os resultados e discussões de [Gallego et al. \(2012\)](#), [Kirchner, Tabie e Seeland \(2014\)](#). Os falsos negativos neste trabalho sugeririam que não há movimento, no entanto, em todas as repetições houve o movimento dos membros inferiores. Já antecipação a partir

do sinal de EMG é menor, mas apresenta melhor acurácia. Dessa forma, a junção desses sinais corrobora a abordagem multimodal no contexto do reconhecimento da intenção de movimento para controle de dispositivos robóticos de reabilitação. Os valores expostos na Tabela 9 foram tomados utilizando-se a *Janela1* e a *Janela2* para os sinais de EEG, i.e., de 2 segundos antes do movimento até 1 segundo depois e a *Janela1* e a *Janela2* para os sinais EMG, i.e., de 0,5 segundos antes do movimento até 0,1 segundos depois, para cada sujeito.

Sinal de EEG					
<i>Erros</i>	Sujeito 1	Sujeito 2	Sujeito 3	Sujeito 4	Sujeito 5
<b><i>FP/FN</i></b>	13,3%/17%	13%/10%	23,3%/13,3%	33,3%/3,3%	27,3%/30,3%
Sinal de EMG					
<i>Erros</i>	Sujeito 1	Sujeito 2	Sujeito 3	Sujeito 4	Sujeito 5
<b><i>FP/FN</i></b>	47%/3%	0%/0%	30%/10%	10%/3,3%	0%/0%

Tabela 9 – Valores de Falsos-Positivos (***FP***) e Falsos-Negativos (***FN***) obtidos para os sinais de EMG e EEG por sujeito.

### 5.3 Considerações acerca dos resultados

Algumas considerações acerca da plataforma multimodal proposta e seus resultados são importantes.

A partir dos sinais de sensores inerciais foi possível, em todos os movimentos de todos os experimentos, ter boa precisão na identificação do início efetivo do movimento. A partir de apenas dois desses sensores, feitas as suposições descritas na Seção 4.1, foi proposta uma técnica para a medição dos ângulos do joelho durante o movimento de extensão e flexão das pernas. Essa técnica pode ser facilmente aplicada a quaisquer outras articulações do corpo para a realização de uma análise biomecânica completa de movimentos, o que não se insere no escopo deste Projeto de Pesquisa. O projeto desta dissertação tem por objetivo específico aplicações no controle de dispositivos que possam atuar no contexto da reabilitação de membros inferiores através, por exemplo, de estratégias de controle de impedância, como a passiva, resistida ou assistida. No entanto, como abordado com mais detalhes na Seção 6.2, a medição dos ângulos da articulação apresentada pode ser estendida para aplicações em análises de marcha, tema atual de estudo de pesquisas na área de biomecânica.

Como observado, os sinais de EMG tem boa acurácia e, se considerarmos classificações em qualquer momento, em todas repetições de todos os experimentos, o sistema conseguiu detectar a contração muscular. O uso do mesmo amplificador e condicionador de sinais comercial para a aquisição de EMG e EEG torna o sistema mais compacto e menos susceptível a problemas de sincronia de amostras entre dispositivos, uma vez que três

sinais são analisados (EEG, EMG e IMU) a partir de apenas dois sistemas (BrainNet<sup>®</sup> BNT-36 e Tech-MCS<sup>®</sup>).

A aquisição, o processamento e a classificação de padrões de sinais de EEG em tarefas motoras de membros inferiores traz complexidade ao sistema, quando comparado com tarefas de membros superiores. Tal fato é decorrente do local de origem do sinal de EEG e da menor quantidade de massa neural relacionada, como discutido na Seção 2.1. Dessa forma, a partir da aplicação de algoritmos de classificação de padrões em sinais EEG em tarefas motoras de membros superiores e inferiores, espera-se que nas tarefas de membros superiores tenha-se melhores taxas de acerto.

Como será abordado com mais detalhes adiante, na Seção 6.2, uma das futuras aplicações desta plataforma é o teste em pacientes com problemas neuromusculares. Nestes casos, espera-se haver percentuais inferiores de acertos por parte dos classificadores, principalmente em sinais de EMG pois, os pacientes podem ter sua atividade muscular diminuída. O uso de um sistema multimodal, nestas situações, é ainda mais relevante por levar em conta outras informações para reconhecer uma ação do paciente.

As variações de tempo nas detecções dos sinais de EEG e EMG e consequentes variações dos valores de acurácia, entre os sujeitos e mesmo entre repetições de um mesmo experimento, são esperadas e coerentes com trabalhos relacionados. Tais variações estão relacionadas, principalmente, com características fisiológicas, inerentes aos sinais aferidos, individuais dos sujeitos, como descrito nas Seções 2.1 e 2.2.

A comparação de taxas de acerto, tempos de antecipação ao movimento, precisão do momento de movimento efetivo, entre outros, nem sempre refletem totalmente a diferença entre os trabalhos de pesquisa atuais relacionados com interfaces multimodais aplicadas à robótica de reabilitação. Em muitos casos, mesmo em trabalhos análogos, há diferenças, como, por exemplo, no protocolo experimental proposto, que geralmente está relacionado com os equipamentos disponíveis à pesquisa, como amplificadores, condicionadores de sinal, processadores digitais, eletrodos, *software*, entre outros. A qualidade destes também pode ser determinante na robustez do sistema proposto. Assim, cada sistema tem suas especificidades e limitações em função dessas diferenças.



## 6 Conclusões

Neste Projeto de Mestrado foi proposta uma interface multimodal que pode ser utilizada no desenvolvimento de próteses ou órteses, cujo propósito é o estudo da reabilitação motora. A interface desenvolvida realiza a aquisição e o processamento dos sinais de EEG, EMG e sinais provenientes de sensores inerciais (IMU). O processamento dos sinais foi realizado através uma análise *offline*, de propósito geral a partir de dados adquiridos de sujeitos saudáveis, com o objetivo de identificar a intenção de movimento, a ativação muscular e o movimento efetivo de membros inferiores através dos sinais de EEG, EMG e IMU, respectivamente.

Para o desenvolvimento dessa plataforma foi preciso fazer a integração de sistemas que façam a aquisição dos sinais, de forma que estes estejam sincronizados. Para tanto, foi desenvolvido um *software* que adquire, em tempo real, sinais de um amplificador e condicionador de sinais biológicos e de um sistema de sensores inerciais. Após a aquisição, a sincronia de dados entre os sistemas e o processamento foi realizado.

A partir dos sinais obtidos através de sensores inerciais foi possível detectar o início efetivo do movimento dos membros inferiores. Ainda através destes sensores, foi proposto um método para medição dos ângulos da articulação do joelho. A detecção do início de movimento e a medição dos ângulos foram realizados em tarefas motoras executadas no protocolo experimental de testes proposto. Este envolve a colocação de eletrodos, para aferição de EEG e sEMG, e a colocação de sensores inerciais. A colocação destes sensores não requer um posicionamento específico ou alinhamento. Assim, foi possível detectar o início efetivo do movimento e medir os ângulos do joelho durante os movimentos de flexão e extensão, com boa precisão para a aplicação proposta, a partir de um sistema com baixo custo computacional e de fácil montagem, portátil e que não requer ambientes estruturados.

A partir dos sinais biológicos, a intencionalidade do movimento foi avaliada. Através dos sinais de sEMG foi possível aferir a ativação muscular dos sujeitos, realizando o processamento desde o sinal não processado até a identificação do início da ativação muscular. O processamento utilizado nesta etapa, mesmo sendo aplicado em uma análise *offline*, não apresenta alto custo computacional e obteve resultados com boa precisão e coerentes com a atual literatura relacionada. Com o processamento dos sinais de EEG foi possível detectar a preparação ou intenção de movimento. Para este sinal, duas abordagens foram realizadas, ambas também a partir do sinal cru: a primeira, que leva em conta várias épocas do sinal de EEG; e uma segunda, utilizando-se apenas uma época do sinal de EEG para detectar os momentos de intenção de movimento. O algoritmo utilizado nesta etapa

também não apresenta alto custo computacional, mesmo sendo aplicado em uma análise *offline*, e obteve resultados coerentes com as principais referências atuais relacionadas.

Uma análise acerca da correção dos métodos utilizados para o processamento e classificação dos sinais, mostrando a acurácia dos classificadores utilizados, bem como o tempo de antecipação ao movimento, foi realizada. Assim, fez-se uma comparação dos resultados entre os sujeitos submetidos aos testes e uma mensuração de como foi o desempenho geral das classificações deste sistema, quando os resultados do processamento de todos os sinais são apresentados de forma conjunta. Tais resultados se mostraram coerentes com a literatura relacionada à classificação de padrões em sinais de EMG e EEG. O primeiro apresentou melhor acurácia, menor desvio padrão entre os momentos de detecção de início da contração muscular e menor antecipação ao movimento. O segundo apresentou menor acurácia, maior variabilidade nas detecções de intenção de movimento, mas maior antecipação. A análise de ambos os sinais em conjunto aumentou consideravelmente a antecipação ao movimento, i.e., detecção de intenção de movimento, por parte da plataforma proposta.

Diante do exposto, conclui-se que a plataforma multimodal desenvolvida foi capaz de realizar o sensoriamento e o condicionamento dos sinais; a sincronia de dados; a extração de características para que pudesse ser realizada a detecção do início movimento, a medição dos ângulos da articulação do joelho e detectar, com percentuais e tempos relevantes, antecipações do movimento. Assim, os sinais foram combinadamente processados com êxito, o que mostra a viabilidade da interface multimodal e que os objetivos propostos para esta pesquisa foram alcançados. Então, conclui-se que a plataforma proposta pode ser usada no estudo e desenvolvimento de interfaces multimodais, próteses ou órteses, cujo propósito é a reabilitação motora adaptando o controle destes dispositivos de acordo com a intenção do paciente.

## 6.1 Principais Contribuições

A principal contribuição deste trabalho é o desenvolvimento de uma plataforma computacional, a partir da integração de *hardware* e *software*, para aquisição e processamento de sinais que pode ser utilizada na caracterização da antecipação do movimento de membros inferiores, i.e., reconhecer a intenção antes que o início efetivo do movimento seja realizado.

A plataforma proposta ainda traz contribuição na proposição de um protocolo experimental de testes para aquisição de dados de EEG, EMG e de sensores inerciais que envolve tarefas de membros inferiores. A medição dos ângulos da articulação do joelho durante os movimentos de flexão e extensão, através das IMUs que podem ser posicionadas sem localização específica ou alinhamento no membro inferior também é uma contribuição

inerente ao protocolo de testes.

O trabalho também traz uma contribuição técnica relativa ao desenvolvimento de um *software* que transmite, recebe e salva dados de forma integrada entre dois sistemas comerciais utilizados na área de Engenharia Biomédica, o BrainNet<sup>®</sup> BNT-36 e o TechMCS<sup>®</sup>. A partir desta plataforma desenvolvida podem ser implementadas técnicas para processamento *online* dos dados adquiridos.

Ressalta-se que este projeto de pesquisa obteve aceitação de dois artigos científicos, oriundos diretamente deste trabalho, em importantes congressos na área de Engenharia Biomédica, no decorrer de seu desenvolvimento: (??) e (??).

## 6.2 Trabalhos Futuros

Como trabalhos futuros acerca deste projeto de pesquisa podem ser citados alguns estudos com o intuito de desenvolver as técnicas aplicadas e melhorar a performance do sistema.

O uso de mais sensores inerciais tornará possível a caracterização de outras articulações. Naturalmente, esta etapa depende da tarefa motora proposta. Para uma tarefa análoga à proposta neste trabalho, sensores posicionados na pélvis e nos pés poderiam caracterizar as articulações do quadril e do tornozelo, respectivamente. Dessa forma, uma análise biomecânica completa e mais consolidada do movimento poderia ser realizada. Aplicações em análises de marcha, tema atual de pesquisas, também podem ser desenvolvidas a partir de técnicas para medição de ângulos dessas articulações.

Experimentos conduzidos em pessoas com problemas neuromusculares, e.g., pacientes portadores de tremores patológicos, serão importantes para verificar como o sistema se comporta nestes usuários. Dessa forma, poderá ser avaliada a capacidade de distinção entre movimentos voluntários de involuntários, principalmente através dos sinais de EEG, e ainda se é possível a caracterização do tremor a partir dos sinais de sEMG e IMU. Tal caracterização poderia ser realizada espacial ou temporalmente.

A implementação da análise dos sinais de forma *online* tornará a interface com o usuário mais natural, com interações ao longo do experimento, por ambas as partes. A implementação de realimentação, e.g., visual ou sonora, por parte do sistema ao usuário será possível, de forma que o segundo pode se adaptar ao primeiro em função dessas interações. Naturalmente, nesta etapa, um estudo do custo computacional das técnicas de pré-processamento dos sinais, bem como dos métodos de classificação, e.g., *Classificadores Bayesianos*, *Redes Neurais*, *Máquinas de Vetor Suporte*, entre outros, em contraste com a acurácia de cada um, deverá ser realizado. Um projeto correto dos filtros também deverá ser feito para que filtragens em frequência sejam realizadas e não se perca precisão temporal

por conta de possíveis distorções introduzidas ao sinal filtrado.

Por fim, sugere-se como trabalho futuro, após os estudos citados anteriormente, a aplicação da plataforma ao controle de um exoesqueleto. O exoesqueleto poderá ter suas ações de controle baseadas nos sinais processados pela plataforma para desempenhar, por exemplo, estratégias de controle de impedância, e.g., passiva, resistida ou assistida, de forma a atuar na reabilitação de membros inferiores.

## Referências

Araújo D. B., C. A. A. O. e. B. O. Localizando a atividade cerebral via magnetoencefalografia. *Socienda Brasileira para o Progresso da Ciência*, 2006. Citado na página 36.

Bear, M. F; Connors, B. W. e Paradiso, M. A. *Neurociências: Desvendando o Sistema Nervoso*. 3. ed. [S.l.]: Editora Artmed S. A., São Paulo, Brasil, 2008. Citado 5 vezes nas páginas 15, 16, 36, 43 e 52.

BENEVIDES, A. B. *PROPOSTA DE UM MODELO DE FONTES CEREBRAIS PARA CLASSIFICAÇÃO DE PADRÕES MENTAIS*. [S.l.]: Dissertação de Mestrado, Universidade Federal do Espírito Santo, 2009. Citado 9 vezes nas páginas 18, 35, 39, 41, 99, 100, 101, 102 e 103.

BENEVIDES, A. B. *PROPOSAL OF A BRAIN-COMPUTER INTERFACE FOR MOTOR MENTAL TASKS AND MUSIC IMAGERY*. Tese (Doutorado) — FEDERAL UNIVERSITY OF ESPÍRITO SANTO TECHNOLOGICAL CENTRE POST-GRADUATE PROGRAM IN ELECTRICAL ENGINEERING, 2013. Citado 3 vezes nas páginas 15, 45 e 111.

Benevides, A. B., Bastos Filho, T. F. e Sarcinelli Filho, M. Mental Task Recognition Based on EEG for Commanding a Robotic Wheelchair. In: : *3rd Applied Robotics and Collaborative Systems Engineering (Robocontrol 08)*. [S.l.: s.n.], 2008. p. 8. Citado 3 vezes nas páginas 99, 100 e 102.

BLANCO, S. Stationarity of the EEG Series. *IEEE Engineering in Medicine and Biology*, 1995. Citado na página 46.

BONATO, P.; D'ALESSIO, T.; KNAFLITZ, M. A statistical method for the measurement of muscle activation intervals from surface myoelectric signal during gait. *IEEE transactions on bio-medical engineering*, v. 45, n. 3, p. 287–99, mar. 1998. ISSN 0018-9294. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/9509745>>. Citado na página 56.

BRACEWELL, R. *The Fourier Transform and its Applications*. [S.l.]: New York: McGraw-Hill, 2000. ISBN 978-0-1381-4757-0. Citado na página 111.

Buffa, C., Langfelder, G., Longoni, A., Frangi, A., e Lasalandra, E. Compact MEMS magnetometers for inertial measurement units. *IEEE Sensors*, 2012. Citado 2 vezes nas páginas 57 e 58.

CELANI, N. M. L. *Procesamiento de Señales Electromiográficas Superficiales para el Control de Dispositivos Robóticos*. Tese (Doutorado) — Universidad Nacional de San Juan, Argentina, 2010. Citado 6 vezes nas páginas 16, 49, 50, 54, 55 e 56.

CHEEÍN. *Diseño de una Interfase Cerebro-computadora para la Navegación de Robots Móviles*. [S.l.]: Argentina; Dissertação de Mestrado; Universidad Nacional de San Juan, 2005. Citado 3 vezes nas páginas 40, 41 e 96.

- COMON, P. J. C. *Handbook of Blind Source Separation, Independent Component Analysis and Applications*. [S.l.]: Academic Press, Oxford UK, 2010. ISBN 978-0-12-374726-6. Citado na página 99.
- CORBETT, E. a.; PERREAULT, E. J.; KÖRDING, K. P. Decoding with limited neural data: a mixture of time-warped trajectory models for directional reaches. *Journal of neural engineering*, v. 9, n. 3, p. 036002, jun. 2012. ISSN 1741-2552. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/22488128>>. Citado na página 30.
- CRISWELL, E. *Introduction to Surface Eletromyography*. [S.l.: s.n.], 2011. 363 p. ISBN 9780763732745. Citado 5 vezes nas páginas 16, 17, 54, 72 e 119.
- Davidson, R. J; Jackson, D. C and Larson, C. L. *Human Electroencephalography*. 2nd. ed. [S.l.]: Handbook of Psychophysiology. Cambridge University Press, 2000. Citado 2 vezes nas páginas 43 e 44.
- Duda, R. O.; Hart, P. E. e Stork, D. G. *Pattern Classification*. 2nd. ed. [S.l.]: New York: John Wiley & Sons Inc, 2001. Citado 5 vezes nas páginas 18, 19, 108, 109 e 110.
- FABIO, R. Reliability of computerized surface electromyography for determining of onset of muscle activity. *Physical Therapy*, 1987. Citado na página 56.
- FAVRE, J. et al. Functional calibration procedure for 3D knee joint angle description using inertial sensors. *Journal of biomechanics*, Elsevier, v. 42, n. 14, p. 2330–5, out. 2009. ISSN 1873-2380. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/19665712>>. Citado 2 vezes nas páginas 85 e 117.
- FISCHER, H. . *A History of the Central Limit Theorem*. [S.l.]: Springer, 2011. Citado na página 107.
- FRIEDMAN, J. Regularized discriminant analysis. *Journal of the American Statistical Association*, p. 84(405):165–175, 1989. Citado na página 106.
- Fuglevand, A., Winter, D., Patla, A. Models of recruitment and rate coding organization in motor-unit pools. *Journal of Neurophysiology*, 1993. Citado na página 49.
- FUKUNAGA, K. *Statistical Pattern Recognition*. 2nd. ed. [S.l.]: Academic Press, San Diego, California, USA., 1990. Citado na página 107.
- GALLEGO, J. A. et al. A Multimodal Human – Robot Interface to Drive a Neuroprosthesis for Tremor Management. *Ieee transactions on systems, man and cybernetics*, v. 42, n. 6, p. 1159–1168, 2012. Citado 9 vezes nas páginas 17, 21, 30, 59, 64, 65, 83, 129 e 131.
- GARCIA, A. *Probability and Random Process for Electrical Engineering*. 2nd. ed. [S.l.]: Addison-Wesley Publishing Coompany, 1994. Citado 4 vezes nas páginas 46, 105, 106 e 107.
- GEISINGER, D. Electrodo Implantable En El Cerebro en Aplicaciones de Prótesis Neuralis. In: *XIV Seminario de Engenharia Biomédica, Universidad de La República Oriental Del Uruguay*. [S.l.: s.n.], 2005. Citado na página 43.
- GRAIMANN, B. et al. Visualization of Significant ERD/ERS Patterns in Multichannel EEG and ECoG data. *Clinical Neurophysiology. Vol. 113*, 2002. Citado na página 36.

- Guyton, A. C. e Hall, J. E. *Textbook of Medical Physiology*. 11. ed. [S.l.]: Elsevier Saunders, Philadelphia, Pennsylvania, USA,, 2006. Citado 8 vezes nas páginas 15, 35, 37, 38, 39, 40, 41 e 48.
- Hayt, W. H. Jr., Buck, J. A. *Eletromagnetismo*. Sexta edição. [S.l.: s.n.], 2001. Citado na página 101.
- HERMENS, H. J. et al. European Recommendations for Surface ElectroMyoGraphy. *Results of the SENIAM project*, 1999. Citado 4 vezes nas páginas 54, 72, 92 e 119.
- HODGES, B. A comparison of computer-based methods for determination of onset of muscle contraction using electromyography. *Electroenceph Clin Neurophysiol*, 1996. Citado na página 56.
- HUANG, H. et al. Continuous locomotion-mode identification for prosthetic legs based on neuromuscular-mechanical fusion. *IEEE transactions on bio-medical engineering*, v. 58, n. 10, p. 2867–75, out. 2011. ISSN 1558-2531. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3235670&tool=pmcentrez&rendertype=abstract>>. Citado na página 30.
- IBANEZ, J. et al. Online detector of movement intention based on EEG—Application in tremor patients. *Biomedical Signal Processing and Control*, v. 8, n. 6, p. 822–829, nov. 2013. ISSN 17468094. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1746809413001067>>. Citado 13 vezes nas páginas 17, 29, 63, 64, 83, 90, 96, 98, 104, 110, 111, 129 e 131.
- Kawano, K., Kobashi, S., e Yagi, M. Analyzing 3D knee kinematics using accelerometers, gyroscopes and magnetometers. In: *System of Systems Engineering*. [S.l.: s.n.], 2007. Citado na página 59.
- KIRCHNER, E. A.; TABIE, M.; SEELAND, A. Multimodal movement prediction - towards an individual assistance of patients. *PloS one*, v. 9, n. 1, p. e85060, jan. 2014. ISSN 1932-6203. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3885685&tool=pmcentrez&rendertype=abstract>>. Citado 10 vezes nas páginas 16, 29, 56, 61, 62, 83, 92, 128, 129 e 131.
- LOPES, C. *Análise de Sinais de EEG Utilizando a Transformada Wavelet Discreta e as Redes Neurais Artificiais*. [S.l.]: Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, 2005. Citado na página 36.
- LOU, L. Sensor fusion-based attitude estimation using low-cost MEMS-IMU for mobile robot navigation. In: *6th IEEE Joint International Information Technology and Artificial Intelligence Conference*,. [S.l.: s.n.], 2011. p. 465–468. Citado na página 61.
- LU, M.-K. et al. The Bereitschaftspotential in essential tremor. *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology*, International Federation of Clinical Neurophysiology, v. 121, n. 4, p. 622–30, abr. 2010. ISSN 1872-8952. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/20097128>>. Citado na página 29.
- LUCK, S. J. *An Introduction to the Event-Related Potential Technique*. [S.l.]: Cambridge, MA, London: The Mit Press, 2005. Citado 2 vezes nas páginas 44 e 45.

Luinge, H. J. e Veltink, P. H. Measuring orientation of human body segments using miniature gyroscopes and accelerometers. *Medical & biological engineering & computing*, 2005. Citado na página 59.

M., E. J. *EEG-Based Analysis for the Design of Adaptive Brain Interfaces*. Tese (Doutorado) — Centre de Recerca en Enginyeria Biomèdica, Espanha, 2003. Citado 3 vezes nas páginas 36, 40 e 99.

Malmivuo, J., Plonsey, R. *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*. [S.l.]: Oxford University Press, 1995. Citado na página 35.

MELIM, R. S. *Desenvolvimento de Sistema de Análise da Marcha Humana Utilizando Sensores Inerciais e Câmera de Profundidade*. [S.l.]: Dissertação de Mestrado, Universidade Federal do Espírito Santo, 2013. Citado na página 87.

MERLETTI. *Electromyography: Physiology, Engineering and Noninvasive Applications*. [S.l.]: John Wiley and Sons, 2004. Citado 3 vezes nas páginas 16, 50 e 51.

Millán J. R. et. al. Toward Brain-Computer Interfacing. p. 261–277, 2007. Citado na página 108.

Moreno, J., Rocon, E., Ruiz, A. F., Brunetti, F., e Pons, J. L. Design and implementation of an inertial measurement unit for control of artificial limbs: application on leg orthoses. *Sensors and Actuators B*, 2006. Citado na página 59.

MRACHACZ-KERSTING, N. et al. Precise temporal association between cortical potentials evoked by motor imagination and afference induces cortical plasticity. *The Journal of physiology*, v. 590, n. Pt 7, p. 1669–82, abr. 2012. ISSN 1469-7793. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3413497&tool=pmcentrez&rendertype=abstract>>. Citado na página 29.

MURALIDHARAN, A.; CHAE, J.; TAYLOR, D. M. Extracting Attempted Hand Movements from EEGs in People with Complete Hand Paralysis Following Stroke. *Frontiers in neuroscience*, v. 5, n. March, p. 39, jan. 2011. ISSN 1662-453X. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3066795&tool=pmcentrez&rendertype=abstract>>. Citado na página 30.

NOVAK, D. et al. Predicting targets of human reaching motions using different sensing technologies. *IEEE transactions on bio-medical engineering*, v. 60, n. 9, p. 2645–54, set. 2013. ISSN 1558-2531. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/23674417>>. Citado 5 vezes nas páginas 17, 30, 62, 63 e 92.

Oppenheim, Alan V., Ronald W. Schafer; BUCK., J. R. *Discrete-Time Signal Processing*. 2nd. ed. [S.l.]: Upper Saddle River, NJ: Prentice Hall, 1999. Citado na página 95.

P., A. A. *Estudo do Sinal Eléctroencefalográfico (EEG) Aplicado a Interfaces Cérebro Computador com uma Abordagem de Reconhecimento de Padrões*. [S.l.]: Dissertação de Mestrado. Universidade Federal do Espírito Santo, 2005. Citado 4 vezes nas páginas 36, 40, 41 e 99.

Pardy, J., Roberts, S. e Tarassenko, L. A Review of Parametric Modeling Techniques for EEG Analysis. *Medical Engineering & Physics*, 1996. Citado na página 46.

- PFURTSCHELLER. Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology*, v. 110, n. 11, p. 1842–57, nov. 1999. ISSN 1388-2457. Citado 12 vezes nas páginas 15, 40, 41, 42, 90, 95, 97, 104, 111, 122, 123 e 129.
- PFURTSCHELLER, G. et al. Brain oscillations control hand orthosis in a tetraplegic. *Neuroscience letters*, v. 292, n. 3, p. 211–4, out. 2000. ISSN 0304-3940. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/11018314>>. Citado na página 29.
- PONS, J. *Wearable Robots: Biomechatronic Exoskeletons*. [S.l.]: John Wiley & Sons Ltd, 2008. Capítulo 4 p. Citado 8 vezes nas páginas 15, 16, 33, 34, 37, 48, 49 e 117.
- PONS, J. L. *Wearable Robots: Biomechatronic Exoskeletons*. [S.l.]: John Wiley & Sons Ltd, 2008. Capítulo 7 p. Citado 4 vezes nas páginas 16, 57, 58 e 60.
- Popivanov, D. e Mineva, A. Testing Procedures for Non-Stationarity and NonLinearity in physiological signals. *Mathematical Biosciences*, 1999. Citado na página 46.
- Ratanaswasd, P., Dodd, W., Kawamura, K., Noelle, D. Modular behavior control for a cognitive robot. In: *Proceedings of the 12th International Conference on Advanced Robotics*. [S.l.: s.n.], 2005. Citado na página 33.
- RAYA, R. et al. Wearable inertial mouse for children with physical and cognitive impairments. *Sensors and Actuators A: Physical*, 2010. Citado na página 59.
- RECHY-RAMIREZ, E. J. e. H. *Stages for developing control systems using EMG and EEG signals*. [S.l.]: Biological procedures online, 2011. Citado 2 vezes nas páginas 16 e 52.
- ROCON, E. et al. Application of inertial sensors in rehabilitation robotics. *2007 IEEE 10th International Conference on Rehabilitation Robotics*, Ieee, p. 145–150, jun. 2007. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4428420>>. Citado na página 59.
- RUGG, M.D. e COLES, M. *Electrophysiology of Mind Event-Related Brain Potentials and Cognition*. [S.l.]: Oxford Psychology Series, 1996. Citado na página 40.
- SANCHEZ, M. R. *Rede de Sensores Inericaís para Monitoramento de Membro Inferior*. [S.l.]: Dissertação de Mestado, Universidade Federal do Espírito Santo, 2014. Citado na página 61.
- 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*, Elsevier Ltd, v. 22, n. 6, p. 878–885, 2012. ISSN 1050-6411. Disponível em: <<http://dx.doi.org/10.1016/j.jelekin.2012.04.010>>. Citado na página 56.
- SHIBASAKI, H.; HALLETT, M. What is the Bereitschaftspotential? *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology*, v. 117, n. 11, p. 2341–56, nov. 2006. ISSN 1388-2457. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/16876476>>. Citado na página 29.
- STAUDE, G. Onset Detection in Surface Electromyographic Signals :. p. 67–81, 2001. Citado 2 vezes nas páginas 16 e 56.

- TSUKAHARA, A.; HASEGAWA, Y.; SANKAI, Y. Standing-up motion support for paraplegic patient with Robot Suit HAL. *2009 IEEE International Conference on Rehabilitation Robotics*, Ieee, p. 211–217, jun. 2009. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5209567>>. Citado na página 29.
- VAN DEN NOORT. Gait analysis in children with cerebral palsy via inertial and magnetic sensors. *Medical & Biological Engineering & Computing*, 2013. Citado na página 59.
- W, G. *Fisiología Médica*. [S.l.]: Ed. Manual Moderno, 1996. Citado 3 vezes nas páginas 15, 47 e 48.
- WHITTLE, M. *Gait Analysis*. 4th. ed. [S.l.]: Heidi Harrison, 2008. Citado 2 vezes nas páginas 17 e 85.
- XU, R. et al. A Closed-Loop Brain-Computer Interface Triggering an Active Ankle-Foot Orthosis for Inducing Cortical Neural Plasticity. *IEEE transactions on bio-medical engineering*, v. 9294, n. c, mar. 2014. ISSN 1558-2531. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/24686231>>. Citado 3 vezes nas páginas 17, 65 e 66.
- Yang, S. e Kong, L. Research on Characteristic Extraction of Human Gait. In: *3rd International Conference on Bioinformatics and Biomedical Engineering*. [S.l.: s.n.], 2009. p. 1–4. Citado na página 73.
- Zwillinger, D., Kokoska, S. *Standard Probability and Statistics Tables and Formulae*. [S.l.: s.n.], 2000. 31 p. ISBN 1-58488-059-7. Citado na página 105.