

Thomaz Rodrigues Botelho

**Predição de Movimento Baseada em EEG e
sEMG para Controle de Exoesqueleto de
Membro Inferior**

Vitória - ES

2017

Thomaz Rodrigues Botelho

Predição de Movimento Baseada em EEG e sEMG para Controle de Exoesqueleto de Membro Inferior

Tese 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 Doutor em Engenharia Elétrica.

Universidade Federal do Espírito Santo – UFES
Programa de Pós-Graduação em Engenharia Elétrica

Orientador: Dr. Anselmo Frizera Neto
Coorientador: Dr. André Ferreira

Vitória - ES
2017

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Central da Universidade Federal do Espírito Santo, ES, Brasil)
Bibliotecária: Maria Margareth Fernandes – CRB-6 ES-173

B748p Botelho, Thomaz Rodrigues, 1978-
Predição de movimento baseada em EEG e sEMG para
controle de exoesqueleto de membro inferior / Thomaz Rodrigues
Botelho. – 2017.
133 f. : il.

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

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

CDU: 621.3

Thomaz Rodrigues Botelho


Predição de Movimento Baseada em EEG e sEMG para Controle de Exoesqueleto de Membro Inferior

Tese 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 Doutor em Engenharia Elétrica.

Trabalho aprovado. Vitória - ES, 16 de agosto de 2017:



Dr. Anselmo Frizzera Neto
PPGEE - UFES
Orientador



Dr. André Ferreira
PPGEE - UFES
Coorientador

Dr. Teodiano Freire Bastos Filho
PPGEE - UFES
Membro da Banca Avaliadora



Dr. Rodrigo Varejão Andreão
UFES
Membro da Banca Avaliadora



Dr. Patrick Marques Ciarelli
PPGEE - UFES
Membro da Banca Avaliadora



Dr. Eduardo Rocon
CSIC
Membro da Banca Avaliadora

Vitória - ES

2017

Dedico esta Tese aos que perderam sua mobilidade e um dia possam voltar a andar devido a avanços tecnológicos, e àqueles que não puderam esperar por estes avanços e não estão mais entre nós.

Agradecimentos

Primeiramente agradeço a Deus por ter me dado sabedoria e motivação para que eu superasse os obstáculos da vida e desenvolvesse este trabalho.

Agradeço aos meus pais, irmã, e minha noiva Alyne que me apoiaram e me incentivaram durante esta caminhada, me dando força e tendo paciência e compreensão por todo o tempo tomado por esta etapa da minha vida.

Agradeço também ao meu orientador e coorientador, e mais que isso, amigos, Anselmo Frizera Neto e André Ferreira, pela dedicação, empenho e paciência, e por terem, compartilhado comigo seus conhecimentos ao longo desta jornada.

Agradeço à CAPES (Processo 044/2010 – CAPG), a qual me proporcionou uma missão de Estudos no INAUT/UNSJ em San Juan - Argentina para aperfeiçoamento de minha pesquisa, agradecendo também ao meu co-tutor no exterior, o professor Vicente Mut, que me auxiliou na jornada longe de casa.

Agradeço também às agências de fomento CNPq (Processos 471804/2012-6 e 308529/2013-8), CAPES (Processo 88887.095626/2015-01) e FAPES (Processos 67566480 e 53666038/2011) que foram muito importantes no desenvolvimento desta pesquisa.

Agradeço ao meu amigo e colega de trabalho Douglas Ruy Soprani da Silveira Araujo que, através de nossa pesquisa conjunta proporcionou a primeira parte desta pesquisa, que foi a sua Dissertação de Mestrado, e que mesmo terminado seu trabalho, continua me apoiando e ajudando na pesquisa.

A todos os amigos que passaram pelo Laboratório de Automação Inteligente (LAI) e Núcleo de Tecnologias Assistivas (NTA), que foram muitos durante estes anos, mas que dividimos ótimos momentos juntos.

Agradeço ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo pela oportunidade de continuar aprendendo e proporcionado a conquista desta nova etapa em minha vida.

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

Anjezë Gonxhe Bojaxhiu
(Madre Teresa de Calcutá)

Resumo

Pessoas com deficiências motoras podem ser beneficiadas com o desenvolvimento de estratégias de reabilitação baseadas em sistemas robóticos. Dispositivos robóticos, como exoesqueletos, podem fazer uso de dados fisiológicos, como eletromiografia de superfície (sEMG) e eletroencefalografia (EEG), além de também sensores inerciais e de força, com o intuito de detectar a intenção de movimento e controlar estes dispositivos. Este trabalho apresenta o desenvolvimento de uma plataforma multimodal de aquisição e processamento de sinais de EEG, sEMG, inerciais e de força para aplicação no exoesqueleto robótico ALLOR (*Advanced Lower-Limb Orthosis for Rehabilitation*) da UFES, desenvolvido também no contexto desta pesquisa. Foram propostas novas estratégias de reabilitação neuro-motoras baseadas no controle do exoesqueleto a partir da intenção de movimento do paciente. Experimentos foram realizados com voluntários, executando as tarefas de extensão e flexão do joelho, com o objetivo de analisar a intenção de movimento, a ativação muscular e o início efetivo dos movimentos realizados. A partir da detecção da intenção de movimento, o sistema inicia a tarefa no exoesqueleto, sendo que os resultados demonstraram que o sistema foi capaz de adquirir, sincronizar, processar e classificar os sinais em combinação com o controle do dispositivo. Análises *off-line* da precisão dos classificadores de intenção de movimento utilizados mostraram que a interface foi capaz de identificar corretamente a intenção de movimento em $74,67 \pm 18,35\%$ dos casos utilizando uma lógica OU entre os sinais de EEG e sEMG, com uma média de tempo de antecipação do movimento através da análise do sinal de EEG, de $677,90 \pm 513,26$ milissegundos, sendo que, para o sinal de sEMG, este valor foi de $122,93 \pm 97,48$ milissegundos. Para os resultados obtidos de forma *on-line*, apenas o sinal de sEMG foi considerado, com identificação correta da identificação da intenção de movimento de $76,00 \pm 13,42\%$ dos casos e com uma antecipação do movimento de $200,45 \pm 50,71$ milissegundos. Os resultados das etapas de processamento desses sinais biológicos, bem como os valores de precisão e tempo de antecipação do movimento dos membros inferiores, se mostraram em conformidade com a literatura atual. Foi proposta também uma nova abordagem na classificação de sinais de EEG utilizando dois estágios de classificação, apresentando melhoria média de $38,00\%$ na precisão dos classificadores de EEG em relação aos classificadores probabilísticos tradicionais. Foram desenvolvidos controladores para o exoesqueleto em tarefas de reabilitação, os quais foram projetados para pacientes que realizaram artroplastia de joelho e pós-AVC, com comprometimentos na mobilidade dos membros inferiores.

Palavras-chave: Exoesqueleto, Robótica de Reabilitação, Plataforma Multimodal, Eletroencefalografia, Eletromiografia, Sensores Inerciais, Sensores de Força, Sistemas de Controle.

Abstract

People with physical disabilities can benefit from the development of rehabilitation strategies based on robotic systems. Robotic devices, such as exoskeletons, can make use of physiological data, such as surface electromyography (sEMG), electroencephalography (EEG) and also inertial and strength sensors, in order to detect movement intentions and to control these devices. This work presents the development of a multimodal platform for signal acquisition and processing of EEG, sEMG, inertial and strength signals, to be applied in the robotic exoskeleton ALLOR (Advanced Lower-Limb Orthosis for Rehabilitation) from UFES, also developed in the context of this research. The research seeks the development of new neuromotor rehabilitation strategies based on the control of the exoskeleton through patient's movement intention. So far, experiments were performed with volunteers executing knee flexion-extension. The goal is to analyze movement intention, muscle activation and movement onset. The system initiates the task in the exoskeleton from the detection of the movement intention, and the results showed that the system was able to acquire, synchronize, process and classify the signals in combination with the device control. Off-line analyses about the accuracy of the movement intention classifiers showed that the interface was able to correctly identify the movement intention in $74.67 \pm 18.35\%$ of the cases through an OR logic between the EEG and sEMG signals, with an average movement anticipation from EEG analysis, of 677.90 ± 513.26 milliseconds. From sEMG analysis, it was 122.93 ± 97.48 milliseconds. From the on-line results, only the sEMG signal was considered, with a correct identification of the movement intention of $76.00 \pm 13.42\%$ of the cases, with an average movement anticipation of 200.45 ± 50.71 milliseconds. The results of these biological signals processing stage, as well as the accuracy and the movement anticipation for lower limbs were similar to the current literature. It is also proposed a new approach to the EEG signals classification using two classification stages, presenting an average improvement of 38.00% in EEG classifiers accuracy in comparison to traditional probability classifiers. Controllers were developed to the exoskeleton, to be used during rehabilitation tasks projected to patients who suffered knee arthroplasty and post-stroke, with impairments in lower limb mobility.

Keywords: Exoskeleton, Robotic Rehabilitation, Multimodal Platform, Electroencephalography, Electromyography, Inertial Sensors, Strength Sensors Control System.

Lista de ilustrações

Figura 1 – Tipos de sistemas robóticos para reabilitação de membros inferiores: (a) treino de marcha em esteira; (b) treino baseado em placas nos pés; (c) treino suspenso de marcha sobre o solo; (d) treino estacionário de marcha; (e) órteses ativas para membros inferiores (DÍAZ; GIL; SÁNCHEZ, 2011).	34
Figura 2 – Dispositivo de Reabilitação Lokomat [®] (Hocoma, Zurique, Suíça). . .	34
Figura 3 – Protótipo do MotionMaker [™] (SCHMITT; MÉTRAILLER, 2004). . .	35
Figura 4 – Conceito do Robô Lambda (BOURI; GALL; CLAVEL, 2009).	36
Figura 5 – Robô para reabilitação de membros inferiores apresentado por Bouhabba et al. (2013)(BOUHABBA et al., 2013).	36
Figura 6 – Exoesqueleto ALLOR desenvolvido para reabilitação de membro inferior.	37
Figura 7 – Homúnculo de Penfield: grau de representação dos diferentes músculos do corpo no córtex motor. Adaptado de Guyton e Hall (2006).	42
Figura 8 – Interface multimodal proposta.	46
Figura 9 – Posicionamento dos eletrodos no padrão 10-20.	47
Figura 10 – Colocação dos eletrodos para obtenção de sinais de sEMG sobre o músculo reto femoral (CRISWELL, 2011).	48
Figura 11 – Posicionamento dos sensores inerciais na perna do usuário.	48
Figura 12 – Plataforma multimodal proposta em função dos equipamentos utilizados.	49
Figura 13 – Voluntário vestindo sensores durante uma sessão do experimento. . .	50
Figura 14 – Descrição de uma repetição do experimento.	51
Figura 15 – Interface do programa desenvolvido em Matlab para a análise multimodal.	51
Figura 16 – Ilustração do procedimento de alinhamento virtual (BOTELHO et al., 2015b).	53
Figura 17 – Deslocamento dos sensores inerciais em relação ao sensor virtual de referência durante os movimentos de extensão e flexão do joelho. . . .	54
Figura 18 – IMU utilizada e seus respectivos eixos de orientação (SOPRANI, 2014).	55
Figura 19 – Saída do classificador para o sinal inercial.	56
Figura 20 – Sinal de sEMG capturado.	57
Figura 21 – Sinal de sEMG registrado após eliminação de artefatos da rede elétrica e filtragem passa-banda de interesse (20 a 300 Hz).	58
Figura 22 – Sinal de sEMG pronto para ser classificado, após passar pelo filtro de variância.	59
Figura 23 – Processo de validação cruzada utilizando o método <i>Leave-one-out</i> para treinamento e teste do classificador de sEMG.	59

Figura 24 – Sinal de EEG do canal <i>Cz</i> (a) capturado; (b) após o filtro CAR.	60
Figura 25 – Esquerda: disposição dos eletrodos sobre o escalpo; Direita: mapeamento dos eletrodos referentes aos canais utilizados em um plano euclidiano. Adaptado de Benevides (2009) (SOPRANI, 2014).	61
Figura 26 – Sinal de EEG do canal <i>Cz</i> após a Separação Linear de Fontes.	62
Figura 27 – Sinal de EEG do canal <i>Cz</i> na banda μ (a) na escala das Figuras 24 e 26; (b) em escala adequada.	62
Figura 28 – Sincronismo das repetições com base na detecção do início do movimento. (a) Repetições antes do sincronismo; (b) repetições depois do sincronismo.	63
Figura 29 – Sinal EEG multi-repetições onde a Dessincronização Relacionada a Evento (ERD) pode ser identificada.	64
Figura 30 – Sinal EEG multi-repetições onde a Dessincronização Relacionada a Evento (ERD) não pode ser identificada.	64
Figura 31 – Classificador Bayesiano.	65
Figura 32 – Diferença entre os discriminantes das classes <i>movimento</i> e <i>estática</i> para os canais <i>C3</i> , <i>Cz</i> e <i>C4</i>	66
Figura 33 – Classificador Bayesiano com saída da diferença entre os discriminantes.	67
Figura 34 – (a) Variância da diferença entre os discriminantes das classes <i>movimento</i> e <i>estática</i> para os canais <i>C3</i> , <i>Cz</i> e <i>C4</i> ; e, (b) o mesmo sinal, porém com uma ampliação em torno do eixo do Tempo para melhor visualização.	67
Figura 35 – Classificação do sinal de EEG na abordagem tradicional.	68
Figura 36 – Processo de validação cruzada utilizando o método <i>Leave-one-out</i> para treinamento e teste do classificador EEG.	69
Figura 37 – Classificação do sinal de EEG proposta.	70
Figura 38 – Precisão para cada janela de tempo considerada para o sinal de EEG.	72
Figura 39 – Precisão para cada janela de tempo considerada para o sinal de sEMG.	73
Figura 40 – Distribuição de predições baseadas em EEG e sEMG.	74
Figura 41 – Comparativo entre o classificador Bayesiano puro e a proposta de reclassificação da variância da diferença entre os discriminantes.	75
Figura 42 – Precisão da antecipação para lógica EEG OU sEMG em cada janela de tempo considerada.	76
Figura 43 – Média e Desvio Padrão da antecipação do tempo.	77
Figura 44 – Taxa de Falsos-Positivos (FP) e Falsos-Negativos (FN) por voluntário para os sinais de EEG.	77
Figura 45 – Taxa de Falsos-Positivos (FP) e Falsos-Negativos (FN) por voluntário para os sinais de sEMG.	78
Figura 46 – Diagrama do exoesqueleto projetado na UFES.	86

Figura 47 – Articulação ativa EXO-H1 [®] (Technaid, Espanha), com destaque para a articulação do joelho e sensores.	87
Figura 48 – (a) Órtese passiva de quadril. (b) Órtese passiva de tornozelo.	87
Figura 49 – Exoesqueleto ALLOR desenvolvido para reabilitação de membro inferior.	88
Figura 50 – (a) Alinhamento da perna sem adaptadores. (b) Alinhamento da perna com adaptadores.	89
Figura 51 – Controlador de velocidade.	90
Figura 52 – Compensação de gravidade.	90
Figura 53 – Diagrama de força no modelo de espaço cartesiano.	91
Figura 54 – Controlador de admitância proposto.	92
Figura 55 – Gerador de cargas.	92
Figura 56 – Interface desenvolvida para configurar as tarefas no exoesqueleto.	95
Figura 57 – Exemplo onde o ângulo máximo de proteção é atingido.	96
Figura 58 – Sinais de ângulo e torque para um usuário realizando um treino passivo, com ângulos entre 40° e 70°.	97
Figura 59 – Sinais de ângulo e torque para um usuário realizando um treino ativo assistido, com ângulos entre 30° e 80°.	97
Figura 60 – Sinais de ângulo e torque para um usuário realizando um treino ativo, com ângulos entre 40° e 70°.	98
Figura 61 – Sinais de ângulo e torque para um usuário realizando um treino ativo assistido, com ângulos entre 50° e 70°.	98
Figura 62 – Resultado do questionário B-Quest (2.0), mensurando o grau de satisfação do usuário com o dispositivo de tecnologia assistiva.	99
Figura 63 – Resultado do questionário B-Quest (2.0), mensurando itens que o usuário considera importantes. Os itens são: 1 - dimensões; 2 - peso; 3 - ajustes; 4 - segurança; 5 - durabilidade; 6 - facilidade de uso; 7 - conforto; 8 - eficácia; 9 - entrega; 10 - reparos/assistência técnica; 11 - serviços profissionais; 12 - serviços de acompanhamento.	100
Figura 64 – Interface multimodal proposta nesta etapa.	104
Figura 65 – Interface desenvolvida para configurar a tarefa, e controle do dispositivo realizando uma detecção <i>on-line</i>	105
Figura 66 – Interface desenvolvida para receber dados coletados e realizar o treinamento dos classificadores de forma dedicada.	105
Figura 67 – Arquitetura de rede utilizada na tarefa.	106
Figura 68 – Diagrama da comunicação entre o programa de controle e o programa de treinamento.	108
Figura 69 – Precisão para cada janela de tempo considerada para o sinal de sEMG.	109
Figura 70 – Média e Desvio Padrão da antecipação do tempo.	110

Figura 71 – Taxa de Falsos-Positivos (FP) e Falsos-Negativos (FN) por voluntário para os sinais de sEMG.	111
Figura 72 – Distribuição de predições do sEMG para o voluntário 1.	112
Figura 73 – Distribuição de predições baseadas e sEMG para todos os voluntários.	113
Figura 74 – Precisão média por repetição, em relação a todos os voluntários. . . .	114

Lista de tabelas

Tabela 1 – Precisões dos sinais de EEG e sEMG desconsiderando o sujeito 6. . .	75
Tabela 2 – Parâmetros para os treinos nas diversas fases do experimento de treino para artroplastia.	94
Tabela 3 – Precisão do sinal de sEMG para o sistema <i>on-line</i>	109

Lista de abreviaturas e siglas

ALLOR	<i>Advanced Lower-Limb Orthosis for Rehabilitation</i>
AKROD	<i>Active Knee Rehabilitation Orthotic Device</i>
AVC	Acidente Vascular Cerebral
BCI	<i>Brain-Computer Interface</i>
CAN	<i>Controller Area Network</i>
CAR	<i>Common Average Reference</i>
DCM	<i>Direction Cosine Matrix</i>
DOF	<i>Degrees of Freedom</i>
EEG	Eletroencefalografia
EMG	Eletromiografia
EOG	Eletrooculografia
ERD	<i>Event-Related Desynchronization</i>
ERS	<i>Event-Related Synchronization</i>
FES	<i>Functional Electrical Stimulation</i>
HCI	<i>Human-Computer Interface</i>
HRI	<i>Human-Robot Interaction</i>
IMU	<i>Inertial Measurement Unit</i>
LAI	Laboratório de Automação Inteligente
MAFO	<i>Motorized Ankle-Foot Orthosis</i>
MRCP	<i>Movement-Related Cortical Potential</i>
NTA	Núcleo de Tecnologia Assistiva
PID	Proporcional, Integral e Derivativo
PSD	<i>Power Spectral Density</i>

sEMG	Eletromiografia de Superfície
SLF	Separação Linear de Fontes
SRM	<i>Sensory-Motor Rhythms</i>
UFES	Universidade Federal do Espírito Santo

Sumário

1	INTRODUÇÃO	25
1.1	Motivação	25
1.2	Contexto de realização desta pesquisa	28
1.3	Objetivos	28
1.4	Organização da Tese	29
2	MOBILIDADE HUMANA E TENDÊNCIAS NA REABILITAÇÃO DE MEMBROS INFERIORES	31
2.1	Introdução	31
2.2	Técnicas de Reabilitação de Membros Inferiores	31
2.3	Dispositivos Estacionários de Reabilitação de Membros Inferiores	32
2.4	Exoesqueleto ALLOR	37
2.5	Sistemas Multimodais Aplicados à Reabilitação	38
2.5.1	Interfaces Multimodais para a Predição de Movimento	38
2.6	Sistemas de Controle	43
2.7	Interface Multimodal Proposta	43
3	DESENVOLVIMENTO DA INTERFACE MULTIMODAL	45
3.1	Introdução	45
3.2	Materiais e Métodos	46
3.3	Protocolo Experimental	49
3.4	Processamento dos Dados	51
3.4.1	Processamento dos Sinais dos Sensores Inerciais	52
3.4.1.1	Alinhamento Virtual	52
3.4.1.2	Detecção do início do movimento	54
3.4.2	Processamento dos Sinais de sEMG	55
3.4.3	Processamento dos Sinais de EEG	58
3.4.3.1	Pré-processamento dos Sinais de EEG	60
3.4.3.2	Detecção da Intenção de Movimento Utilizando uma Única Repetição	63
3.5	Precisão dos classificadores	71
3.6	Resultados da Análise Multimodal	71
3.7	Discussão	79
3.8	Considerações	83
4	DESENVOLVIMENTO DO EXOESQUELETO ALLOR E DAS ESTRATÉGIAS DE CONTROLE	85

4.1	Introdução	85
4.2	O Exoesqueleto ALLOR	85
4.3	Estratégias de controle	89
4.4	Protocolo Experimental	93
4.5	Interface de configuração	94
4.6	Resultados do Sistema de Controle	96
4.7	Pesquisa de Satisfação do Usuário	99
4.8	Discussão e Conclusões	100
5	INTEGRAÇÃO DA INTERFACE MULTIMODAL COM O EXOES- QUELETO DE REABILITAÇÃO	103
5.1	Introdução	103
5.2	Materiais e Métodos	104
5.3	Protocolo Experimental	106
5.4	Interfaces de Controle e Treinamento	107
5.5	Resultados	108
5.6	Discussão	115
5.7	Considerações Finais	115
6	CONCLUSÕES E TRABALHOS FUTUROS	117
6.1	Contribuições	118
6.1.1	Contribuições Secundárias	118
6.2	Publicações	118
	REFERÊNCIAS	123

1 Introdução

Esta Tese de Doutorado está orientada ao desenvolvimento de um exoesqueleto robótico para reabilitação motora de membros inferiores, com controle baseado em uma interface multimodal de sinais biomédicos, para a predição de movimento. Esta interface permite a realização de novas terapias de reabilitação, com maior envolvimento do paciente e seus processos naturais de geração do movimento, as quais não seriam possíveis com exoesqueletos convencionais de reabilitação. Este capítulo apresenta a motivação para a realização desta pesquisa e seus objetivos. Ao final deste capítulo, é apresentada a estrutura da Tese.

1.1 Motivação

Nos últimos anos, o número de pessoas que apresentam alguma deficiência em membros inferiores vem aumentando, devido a diversos motivos normalmente relacionados a Acidentes Vasculares Cerebrais (AVC) ou lesões na medula espinhal (TSUKAHARA; HASEGAWA; SANKAI, 2009). Essas deficiências podem levar a problemas secundários, como a dependência de cadeira de rodas, e conseqüentemente ao aparecimento de osteoporose e escaras (TSUKAHARA; HASEGAWA; SANKAI, 2009). Tais problemas levam à diminuição da qualidade de vida do indivíduo por interferirem diretamente na realização de tarefas cotidianas (TSUKAHARA; HASEGAWA; SANKAI, 2009).

A nível global, de acordo com a OMS, cerca de 15 milhões de pessoas sofrem um AVC por ano (MACKAY; MENSAH, 2004), dos quais, aproximadamente 5 milhões enfrentam vários graus de dificuldade de mobilidade, incluindo perda das funções sensorial, motora e cognitiva, gerando um impacto negativo em sua capacidade de realizar tarefas da vida diária (STRONG; MATHERS; BONITA, 2007).

Por outro lado, a população, em geral, tem se tornado menos sedentária, com um maior número de indivíduos buscando a realização de exercícios físicos para manutenção da boa forma e saúde (CAVANAUGH; KILLIAN, 2012). Entretanto, como consequência, lesões do menisco tornaram-se muito comuns entre atletas profissionais e amadores, e são uma das causas mais comuns das cirurgias de joelho (CAVANAUGH; KILLIAN, 2012; BULSTRODE et al., 2011).

Adicionalmente, em uma sociedade em envelhecimento, a necessidade de fisioterapia para idosos continua crescendo, devido a perdas de funções motoras. Ainda existe um grande número de pessoas que sofrem de alguma deficiência motora causada por doenças ou acidentes prejudicando sua mobilidade.

Para todo esse grupo de pessoas, para recuperar ou melhorar as funções dos membros inferiores, normalmente são realizados diferentes programas de reabilitação. Mas, para isso, é necessária uma reabilitação efetiva, que tenha ênfase na repetição, no incremento progressivo da dificuldade da tarefa e na prática funcional (HUSEMANN et al., 2007; WINSTEIN et al., 2016).

Entretanto, ocorre que a reabilitação depende muito da experiência e do apresto manual do terapeuta (PFURTSCHELLER; Lopes da Silva, 1999), entretanto, o número de pacientes necessitando de reabilitação é grande em relação ao número de terapeutas, e o tempo consumido pela terapia muitas vezes é longo. Desta forma, robôs podem ajudar na realização da terapia de reabilitação, de maneira que um único terapeuta possa coordenar diversos robôs para realizar as terapias em vários pacientes simultaneamente (JU et al., 2005). Por exemplo, no Japão, grande parte dos fisioterapeutas trabalham em hospitais, o que significa que os pacientes estão privados de terapia contínua no momento em que saem da internação, agravando sua condição. Assim, uma solução para este problema é o uso de robôs para que a reabilitação possa ser executada sem a intervenção contínua de fisioterapeutas (HOMMA; FUKUDA; NAGATA, 2002).

Robôs de reabilitação têm demonstrado ser uma ferramenta significativa nos centros de tratamento de lesões na medula espinhal, primariamente por melhorar o desempenho da marcha em casos de pacientes com lesões incompletas da medula espinhal (ALCOBENDAS-MAESTRO et al., 2012), além de prover exercícios para melhorar o sistema cardiovascular em pacientes com lesões completas da medula espinhal (ZEILIG et al., 2015). Comparados com a fisioterapia tradicional, robôs de reabilitação podem prover estratégias específicas de treinamento, amplamente classificadas em treinamento passivo e ativo (tais estratégias serão abordadas na Seção 2.3), onde ambos têm se mostrado efetivos na reabilitação clínica (LOTZE et al., 2003; CAI et al., 2006; POHL et al., 2007; YANG; KONG, 2009).

Por outro lado, a identificação de intenção de movimento pode auxiliar no controle desses robôs de reabilitação para facilitar a tarefa de recuperação do indivíduo, sendo que o uso de sinais biológicos relacionados com a intenção de movimento viabiliza uma nova geração de terapias de reabilitação, com maior participação do indivíduo, incitando o uso dos caminhos ou vias convencionais de geração dos padrões motores (DONATI et al., 2016). De fato, estudos mostram que usando a atividade cerebral de pacientes que sofreram AVC para acionar um dispositivo de reabilitação através de movimentos voluntários repetitivos pode promover a recuperação motora e prover o treinamento da geração de planos motores no córtex cerebral reconstruindo o planejamento motor de atividades no cérebro (MURALIDHARAN; CHAE; TAYLOR, 2011).

Vários controladores digitais podem ser projetados para o controle de um robô para reabilitação baseado na intenção de movimento, os quais têm a finalidade de reduzir

o impacto que a adaptação à tecnologia assistiva pode causar ao indivíduo (IBÁÑEZ et al., 2013).

Esses controladores são acionados por Interfaces Cérebro-Computador (ICC ou BCI, do inglês *Brain-Computer Interfaces*), as quais têm sido implementadas a partir da aquisição não invasiva de sinais eletroencefalográficos (EEG). As BCIs utilizam eventos relacionados ao ritmo sensorio-motor (SMR, do inglês, *Sensorimotor Rhythm*), tais como as características relacionadas à dessincronização e à sincronização (*Event-Related Desynchronization and Synchronization* ERD/ERS) (KIRCHNER; TABIE; SEELAND, 2014; GALLEGO et al., 2012), que são a principal modalidade de sinal para BCIs motoras (GUGER; VAUGHAN; ALLISON, 2014), ou os potenciais corticais relacionados com o movimento (MRCP, do inglês, *Movement-Related Cortical Potential*) (JIANG et al., 2015; MRACHACZ-KERSTING et al., 2017). A primeira técnica apresenta uma melhor precisão na detecção da intenção de movimento em geral, contudo, uma precisão baixa quando se trabalha com membros inferiores. Desta forma, o uso de MRCP supera o uso de SMR em termos de precisão de controle de dispositivos para membros inferiores (XU et al., 2016), e, ao contrário dos sinais de ERD/ERS, são sempre detectados (uma porção não negligenciável de indivíduos (20 a 25%) não pode utilizar sistemas clássicos de BCIs baseadas em potenciais SMR por não apresentar em seus sinais padrões ERD/ERS observáveis (VIDAURRE et al., 2011; PFURTSCHELLER; Lopes da Silva, 1999)). Isto torna o uso de MRCP muito promissor para detecção do movimento, apesar de que sua antecipação na detecção do movimento ser pior do que em relação ao SMR, pois o MRCP usualmente detecta a intenção de movimento através do sinal de EEG alguns milissegundos depois do início do movimento (NIAZI et al., 2011; XU et al., 2014a; GUGER; VAUGHAN; ALLISON, 2014).

O uso do sinal mioelétrico de superfície (sEMG) também possibilita a detecção da intenção de movimento com uma alta acurácia quando comparado com o sinal de EEG, principalmente em membros inferiores (HUANG et al., 2011; NOVAK et al., 2013; KIRCHNER; TABIE; SEELAND, 2014). Assim, com o objetivo de aproveitar as vantagens da antecipação na detecção de movimento com SMR, e a precisão na detecção de intenção de movimento comparável com o MRCP, é possível combinar o sinal de SMR, proveniente do EEG com o sinal de sEMG, em uma interface multimodal, conseguindo uma melhora tanto na detecção da intenção de movimento quanto na antecipação do movimento, em lugar de utilizar os sinais individualmente. Vale ressaltar que a combinação de EEG e sEMG já foi usada para aprimorar a reabilitação neurológica com melhorias significativas na sensação somática de pacientes paraplégicos, até mesmo conseguindo progredi-los, em alguns casos, para um surpreendente nível de paraplegia incompleta (DONATI et al., 2016).

1.2 Contexto de realização desta pesquisa

O Grupo de Pesquisa em Robótica e Tecnologia Assistiva do Núcleo de Tecnologia Assistiva (NTA) do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo (UFES) tem um histórico de desenvolvimento de dispositivos assistivos robóticos, tais como cadeira de rodas robótica (FERREIRA, 2008), andadores robóticos (FRIZERA-NETO, 2010; CIFUENTES, 2015; VALADÃO, 2016) e diversos outros sistemas de interação humano-robô (HRI, do inglês, *Human-Robot Interaction*), inclusive com robôs desenvolvidos para a interação com crianças autistas (GOULART et al., 2015; VALADÃO, 2016). Pesquisadores do NTA também já desenvolveram diversas pesquisas envolvendo BCIs, através de aquisição de sinais cerebrais (EEG) (BENEVIDES; BASTOS-FILHO; SARCINELLI-FILHO, 2008; FERREIRA, 2008; BENEVIDES, 2009; MÜLLER, 2012; TELLO, 2016; BUENO, 2017), sinais mioelétricos de superfície (sEMG) (VELA, 2013; TELLO, 2013; SOPRANI et al., 2014; LOTERIO, 2015; ATENCIO, 2015; JIMÉNEZ, 2016; VILLAREJO-MAYOR, 2017), análise de movimentos corporais através de sensores inerciais e câmeras de profundidade (MELIM, 2013), e análise da marcha humana através de estudos de parâmetros biomecânicos (ELIAS, 2013; VARGAS, 2015).

A aquisição recente de um exoesqueleto ativo de membro inferior com um grau de liberdade possibilitou esta pesquisa de desenvolvimento de estratégias de controle aplicadas à reabilitação da locomoção humana e assistência à marcha. Assim, essa Tese de Doutorado representa o primeiro passo do Grupo no desenvolvimento de técnicas de detecção da intenção de movimento em interfaces multimodais, aplicadas ao controle de um exoesqueleto. Tal dispositivo, aliado à interface multimodal desenvolvida para a predição do movimento, representa uma poderosa ferramenta aplicada em diferentes estágios da reabilitação humana, se tratando de membros inferiores.

1.3 Objetivos

Essa tese de doutorado tem como objetivo o desenvolvimento de uma interface para controle de um exoesqueleto robótico em tempo real com o objetivo de realizar tarefas de reabilitação de membro inferior. Tal interface irá utilizar sinais biológicos, de forma multimodal, para detectar a intenção de movimento através dos potenciais SMR em sinais de EEG em conjunto com sinais de sEMG, conseguindo precisão e antecipação na detecção da intenção de movimento de modo que seja possível o controle do exoesqueleto sem causar desconforto ao usuário e cumpra o objetivo da tarefa de reabilitação.

Desta forma, o objetivo principal desta Tese é o desenvolvimento de uma interface multimodal e estratégias de controle aplicadas a um exoesqueleto voltado à reabilitação motora de membros inferiores.

Podem-se enumerar como objetivos específicos pertinentes ao trabalho:

1. Análise de estratégias de reabilitação convencionais que possam ser adaptadas ou melhoradas em função da utilização de um exoesqueleto ativo.
2. Análise do movimento de um paciente em uma atividade de reabilitação.
3. Desenvolvimento de protocolo de experimentos para reabilitação de membro inferior.
4. Proposta de estratégias de controle de exoesqueleto de membro inferior compatíveis com tarefas de reabilitação.
5. O desenvolvimento de uma interface multimodal para a detecção da intenção de movimento de membros inferiores.
6. O desenvolvimento de sistemas de controle integrados à interface multimodal que propiciem tarefas de reabilitação com o exoesqueleto de membro inferior.

1.4 Organização da Tese

Este documento está organizado da seguinte forma. O Capítulo 2 apresenta considerações a respeito das condições que podem afetar a mobilidade, das técnicas de reabilitação responsáveis pela reintegração do indivíduo à sociedade, e dos dispositivos que podem aprimorar as técnicas tradicionais de reabilitação. Também são apresentados alguns dispositivos utilizados na reabilitação de membros inferiores, suas características e classificação. Nesse capítulo também é realizada uma revisão da literatura relacionada às interfaces multimodais que são aplicadas ou podem ser aplicadas na reabilitação motora humana.

No Capítulo 3 é apresentado o sistema multimodal proposto, os materiais e métodos utilizados para a aquisição dos dados, o protocolo experimental proposto para validar o sistema, as técnicas utilizadas no processamento dos dados obtidos, os resultados encontrados e uma discussão a respeito desses resultados.

No Capítulo 4 são apresentados os sistemas de controle propostos e implementados, os métodos e materiais utilizados, as propostas de protocolos experimentais para utilização do exoesqueleto com usuários e resultados encontrados, além de uma discussão dos resultados.

O Capítulo 5 apresenta as formas de integração planejadas entre a interface multimodal desenvolvida e o sistema de controle do exoesqueleto de reabilitação.

Finalmente, o Capítulo 6 apresenta as conclusões deste trabalho e recomendações para trabalhos futuros.

2 Mobilidade Humana e Tendências na Reabilitação de Membros Inferiores

2.1 Introdução

A mobilidade é uma das mais importantes faculdades humanas e pode ser definida como a habilidade de um indivíduo se mover livremente através de múltiplos ambientes e realizar tarefas cotidianas (WINTER, 2009).

Existem diversas patologias como, por exemplo, a poliomielite, as lesões da medula espinhal, a esclerose múltipla ou o traumatismo medular, os quais afetam ou reduzem a mobilidade de um indivíduo, acarretando diversos tipos de déficits motores (FRIZERANETO, 2010).

Evidências mostram que as restrições de mobilidade também estão associadas com distúrbios cognitivos e psicológicos, prejudicando, portanto, a qualidade de vida do indivíduo (BUCHMAN et al., 2011).

O número de pessoas com problemas motores, devido à degeneração neurológica, muscular e/ou osteoarticular irá crescer proporcionalmente ao envelhecimento da população (WALSH et al., 1998), sendo, portanto, necessários procedimentos cirúrgicos e programas de reabilitação apropriados para assegurar bons resultados na antecipação deste crescimento (MAXEY; MAGNUSSON, 2001).

2.2 Técnicas de Reabilitação de Membros Inferiores

A fisioterapia envolvendo reabilitação ajuda a recuperação de funções motoras perdidas devido a algum fator como AVC, lesões na medula ou alguma patologia que afete a mobilidade (SMITH et al., 1981; DAM et al., 1993). Os exercícios realizados na reabilitação se baseiam em movimentos específicos no membro afetado, os quais provocam a plasticidade motora do membro ajudando em sua recuperação (SCHMIDT et al., 2007).

Especificamente, a reabilitação de membros inferiores para pacientes que sofreram perda de mobilidade devido a um AVC pode ser dividida em três fases (SCHMIDT et al., 2007; DÍAZ; GIL; SÁNCHEZ, 2011): na primeira fase, o paciente acamado é colocado em uma cadeira assim que possível; na segunda fase, busca-se a restauração da marcha; e, por fim, na terceira fase busca-se a melhoria da marcha e, se possível, o caminhar livre.

Uma vez que a mobilidade é a prioridade entre os pacientes em todas as fases

de reabilitação, uma parte significativa dos especialistas indica a mobilidade através de cadeira de rodas independente do auxílio de outras pessoas, como objetivo final da reabilitação, fato atribuído à pressão dos pacientes devido às limitações de tempo do tratamento (DEL-AMA et al., 2012). Todavia, é importante ressaltar que restaurar a capacidade de caminhar é o principal objetivo da fisioterapia, independente do nível da lesão, do tempo desde o acidente, ou da idade (DITUNNO et al., 2008).

Visando recuperar ou melhorar as funções motoras do indivíduo, diferentes programas de reabilitação podem ser realizados. Entretanto, a reabilitação depende muito da experiência e da habilidade manual do fisioterapeuta (PFURTSCHELLER; Lopes da Silva, 1999). Assim, devido ao grande número de pacientes e ao tempo consumido pelo tratamento, um grande avanço pode ser alcançado com a utilização de um robô na realização do tratamento e na reabilitação do paciente (JU et al., 2005; HOMMA; FUKUDA; NAGATA, 2002).

Terapias convencionais de reabilitação são muito trabalhosas e custosas, especialmente a de reabilitação da marcha e, frequentemente, envolvem mais que três terapeutas em conjunto para assistir manualmente as pernas e tronco do paciente (DÍAZ; GIL; SÁNCHEZ, 2011). Entretanto, terapias convencionais, são baseadas em experiência e evidências clínicas, que, trabalhando em conjunto com novas tecnologias, podem se beneficiar da medição precisa de ângulos de mobilidade e esforço, de forma que é possível melhor avaliar a evolução do paciente durante o processo de reabilitação.

Neste contexto, novas tecnologias têm surgido para melhorar a qualidade de vida de pessoas com deficiências motoras, bem como novas técnicas e dispositivos de reabilitação vêm surgindo na tentativa de recuperar completamente ou parcialmente as capacidades motoras dos indivíduos.

Robôs de reabilitação surgem então como uma alternativa para automatizar a tarefa de reabilitação, permitindo a redução do esforço físico do fisioterapeuta durante as tarefas de reabilitação (HADJIDJ et al., 2013) e, permitindo a realização de tarefas repetitivas mais intensivas, fornecendo também o acesso aos dados quantitativos da recuperação motora, tais como medidas de força exercida e padrões de movimento executados (DÍAZ; GIL; SÁNCHEZ, 2011).

2.3 Dispositivos Estacionários de Reabilitação de Membros Inferiores

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, fornecendo uma resposta a partir dessa interação (PONS, 2008).

Um processo cognitivo pode ser definido como uma sequência de tarefas que incluam 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, os quais podem realizar uma sequência de tarefas citada anteriormente (PONS, 2008). Tais robôs podem ser utilizados no auxílio à reabilitação, reduzindo o custo do processo e introduzindo novas técnicas na terapia (YANG et al., 2006).

Dentre os dispositivos utilizados na reabilitação, exoesqueletos robóticos ou órteses ativas têm desempenhado um papel importante no campo da reabilitação, pois esses robôs podem definir a quantidade de torque aplicada na reabilitação através da identificação da intenção de movimento dos pacientes (TSUKAHARA; HASEGAWA; SANKAI, 2009; RIENER et al., 2005), proporcionando assim possibilidades de treino específicas e um melhor desempenho para recuperar a habilidade atlética do membro afetado. Tais estratégias de treino são amplamente classificadas em treino passivo e treino ativo (HU et al., 2012). No treinamento passivo, o robô é programado para fazer os movimentos de reabilitação enquanto o paciente apenas o acompanha, caso o paciente não possa realizar os movimentos, ou pelo paciente estar em um estágio da reabilitação em que o seu movimento não é possível. Já no treino ativo, o paciente realiza os movimentos e o robô é utilizado para auxiliar e mensurar seus movimentos.

É importante destacar que durante a reabilitação com sistemas robóticos, é necessário o contato direto entre o paciente e o robô de forma a assegurar a segurança dos pacientes além de controlar a força que o robô exerce no paciente. Para este tipo de reabilitação, o controle de impedância é usualmente escolhido, devido à possibilidade de implementar uma relação dinâmica entre as variáveis do manipulador, como posição, velocidade e força (HOGAN, 1984). Com este controlador, é possível controlar a rigidez da articulação do robô, podendo deixá-la livre, onde seria possível manipulá-la com um simples toque, ou rígida, a ponto de sustentar o peso da perna do paciente.

Díaz, Gil e Sánchez (2011) dividem os dispositivos de reabilitação robótica de membros inferiores conforme mostrado na Figura 1. Entre os dispositivos estacionários de marcha, o maior foco está nos de reabilitação do tornozelo, porém, em alguns casos têm-se dispositivos para reabilitação do joelho como apresentado a seguir.

Pode-se destacar como dispositivo de reabilitação robótica o Lokomat^{®1} (Figura 2), o qual é um dispositivo robótico para automatizar o treino motor de membros inferiores,

¹ <https://www.hocoma.com/solutions/lokomat/>




Figura 1 – Tipos de sistemas robóticos para reabilitação de membros inferiores: (a) treino de marcha em esteira; (b) treino baseado em placas nos pés; (c) treino suspenso de marcha sobre o solo; (d) treino estacionário de marcha; (e) órteses ativas para membros inferiores (DÍAZ; GIL; SÁNCHEZ, 2011).

comercializado pelo mundo todo. O Lokomat[®] é composto por um exoesqueleto, uma esteira e um sistema de suporte do peso corporal. O exoesqueleto possui quatro graus de liberdade, permitindo o controle do movimento do quadril e joelhos.



Figura 2 – Dispositivo de Reabilitação Lokomat[®] (Hocoma, Zurique, Suíça).

O MotionMakerTM ² (SCHMITT; MÉTRAILLER, 2004), é um dispositivo ativo funcional que utiliza um laço fechado de Estimulação Funcional Elétrica (FES, do inglês, *Functional Electrical Stimulation*) para reabilitação de indivíduos com lesões na coluna vertebral. Apesar de não ter o mesmo foco de reabilitação desta Tese, o MotionMakerTM se apresenta como um dispositivo estático com órteses robóticas nos membros inferiores, como

² <http://www.swortec.ch/index.php/products/motionmaker>

pode ser visto na Figura 3. O MotionMakerTM atualmente é uma plataforma comercial no ramo de reabilitação.



Figura 3 – Protótipo do MotionMakerTM (SCHMITT; MÉTRAILLER, 2004).

A Yaskawa Electric Corporation no Japão desenvolveu um robô estacionário de reabilitação de membros inferiores, o TEM LX2 (MIYAMURA; MURAI; TOMISAKI, 2003). Tal dispositivo é utilizado principalmente em pacientes com alguma degeneração nos membros inferiores em fase aguda, permitindo-lhes a reabilitação de suas funções físicas e motoras.

Nikitzuk et al. (2010) apresentaram um dispositivo portátil para reabilitação do joelho, o AKROD, um acrônimo para *Active Knee Rehabilitation Orthotic Device*, o qual provê um amortecimento variável na junta do joelho. O dispositivo possui um grau de liberdade (movimento de flexão e extensão) e um *encoder* óptico para cálculo de posição, velocidade e aceleração. Também possui sensores de força para medição do torque nos dois tipos de movimento (flexão e extensão). Entretanto, é exibido apenas o dispositivo mecânico, não sendo apresentadas técnicas de reabilitação ou controle do dispositivo.

Bouri, Gall e Clavel (2009) desenvolveram o robô Lambda, um dispositivo estacionário de baixo custo que pode ser utilizado para a reabilitação de membros inferiores, possuindo uma estrutura similar à letra grega Lambda (λ), como mostrado na Figura 4. O robô conta com um sistema de molas para compensação gravitacional e foi implementado com três tipos de controle básicos: controle Proporcional, Integral e Derivativo (PID) de posição, controle combinado com compensação do modelo estático do robô, e controle combinado com o modelo dinâmico do robô. Porém, alguns pontos ainda estão abertos nessa pesquisa, tais como fixação das pernas no plano sagital, integração com sensores de força e o desenvolvimento de protocolos e exercícios para a reabilitação.

Bouhabba et al. (2013) apresentaram uma proposta de um robô de baixo custo de reabilitação para membros inferiores com função de treino ativo, passivo e assistido,




Figura 4 – Conceito do Robô Lambda (BOURI; GALL; CLAVEL, 2009).

onde pretende-se, através do treino ativo, realizar um controle de velocidade, posição e torque. No treino passivo, utiliza-se um controle de velocidade e posição, e, no treino assistido, o controle é baseado no torque e sinais de sEMG. O conceito apresentado pode ser visualizado na Figura 5.




Figura 5 – Robô para reabilitação de membros inferiores apresentado por Bouhabba et al. (2013)(BOUHABBA et al., 2013).

Diversas plataformas já foram também apresentadas na literatura, algumas de baixo custo, mas que não apresentam mecânica compatível com a perna humana (compatibilidade cinemática), sendo necessário fazer adaptações nas modelagens, como é o caso do dispositivo Lambda, apresentado em Bouri, Gall e Clavel (2009). Em outros casos, as plataformas são dispositivos muito completos e complexos, elevando o custo da fisioterapia, como é o caso do Lokomat[®] ou o MotionMaker[™].

2.4 Exoesqueleto ALLOR

Nesta pesquisa, foi utilizada a órtese ativa desenvolvida no NTA/UFES, a ALLOR (*Advanced Lower-Limb Orthosis for Rehabilitation*) (VILLA-PARRA et al., 2016), a qual é baseada no exoesqueleto EXO-H1[®] (Technaid, Espanha), comercializado para fins de pesquisa e desenvolvimento. A ALLOR é uma órtese para perna esquerda, com três articulações em sua estrutura física: uma ativa no joelho, uma passiva no quadril (a qual é responsável por interligar a coxa com a estrutura de apoio no quadril do paciente) e uma passiva no tornozelo (responsável pela sustentação do pé do usuário), totalizando 3 graus de liberdade (DOF, do inglês, *Degrees of Freedom*). A órtese ALLOR proporciona uma solução simples, de baixo custo e fácil adaptação entre a mecânica do sistema e a biomecânica do corpo humano, conforme apresentado na Figura 6. Os sensores de torque, posição, velocidade e aceleração provêm toda a informação necessária para realizar controles ativo, passivo e assistido com o dispositivo. Além disso, ao ser aliado com uma interface multimodal de predição de movimentos, este dispositivo apresenta resultados promissores no auxílio à reabilitação motora de membros inferiores. É importante ressaltar que a limitação mecânica do sistema (posição dos motores e articulações) não permite que o mesmo seja utilizado na perna direita, sendo necessária a construção de uma segunda órtese caso seja necessária a utilização na referida perna.



Figura 6 – Exoesqueleto ALLOR desenvolvido para reabilitação de membro inferior.

2.5 Sistemas Multimodais Aplicados à Reabilitação

A predição de movimento pode melhorar a ação de controle de 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. Esta predição da intenção de movimento pode ser aperfeiçoada quando há análise combinada de dados, tais como diferentes dados fisiológicos ou até mesmo dados de questionários que mostrem preferências de atividades cotidianas do paciente (HUANG et al., 2011; CORBETT; PERREAULT; KÖRDING, 2012; NOVAK et al., 2013).

Oviatt (2002) define um sistema multimodal como um sistema com duas ou mais entradas combinadas de dados, em uma maneira coordenada com o sistema de saída.

Quase qualquer interação natural entre os seres humanos envolve múltiplos e simultâneos modos de comunicação. Desta forma, segundo (SHARMA; PAVLOVIC; HUANG, 1998), qualquer sistema de interface humano-computador (HCI) que aspira a ter a mesma naturalidade deveria ser multimodal.

A integração de sinais de entrada na forma multimodal em uma HCI também pode ser vista da perspectiva de fusão de dados multi-sensoriais (HALL; LLINAS, 1997), a qual se justifica porque vários tipos de sensores aumentam a precisão de uma medida através da redução da incerteza na tomada de decisão (HALL; LLINAS, 1997; MURPHY, 1996).

Sistemas multimodais para apoio à reabilitação de membros inferiores podem ter em suas entradas sinais biológicos (tais como sinais de EEG ou sEMG utilizados nessa pesquisa). Enquanto sinais de EEG permitem a percepção da intenção de movimento, os sinais de sEMG detectam a ativação muscular. Adicionalmente, o deslocamento efetivo do membro pode ser aferido através de outros dados, como, por exemplo, provenientes de sensores inerciais. Dessa forma, um sistema multimodal pode 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), aumentando, portanto, a robustez e confiabilidade das ações de controle desempenhadas pelos dispositivos utilizados em reabilitação robótica.

2.5.1 Interfaces Multimodais para a Predição de Movimento

Dentre as interfaces multimodais voltadas para a predição do movimento, pode-se destacar o trabalho de Novak et al. (2013), no qual são combinados dados de sensores de sEMG, EEG e eletrooculografia (EOG), sendo mostrados alguns objetos na tela de um computador, em diferentes instantes de tempo. É avaliada a acurácia do sistema combinando os múltiplos sinais, onde verificou-se uma melhora de aproximadamente 5%,

combinando o sinal de EEG com o sinal de sEMG, em relação à análise somente do sinal de sEMG. O estudo foi realizado com 10 sujeitos saudáveis, e foi feita a aquisição de dados de EEG, sEMG, EOG, identificação do início do movimento da mão, através de uma luva com marcadores, em conjunto com sistemas de visão computacional, e ainda foi utilizado um conhecimento prévio de preferências do sujeito relacionadas aos objetos mostrados. A tarefa consistia em agarrar os objetos virtuais mostrados na tela do computador. [Novak et al. \(2013\)](#) concluíram que o sinal de EEG possibilita uma melhor antecipação na predição de movimento, conseguindo acurácia de aproximadamente 70% para tentativas de predição, quando eram mostrados 2 objetos ao usuário, e aproximadamente 55% quando eram mostrados 3 objetos, ambos 1 segundo depois que os objetos eram mostrados. A acurácia foi calculada usando uma validação cruzada *leave-one-out* para cada possível entrada em cada possível ponto no tempo, separadamente, para experimentos com 2 e 3 objetos. Também foi realizada uma comparação com outro estudo, que alcançou 75% de acurácia ([LOGAR et al., 2008](#)) para predições de respostas utilizando opções de verdadeiro ou falso com EEG, e com o estudo de [Lee \(2012\)](#), que alcançou acurácia de aproximadamente 40% para tentativas onde eram apresentados ao usuário 4 objetos. Ao combinar sinais EEG com sinais de movimento, obteve-se uma pequena melhora nos resultados, entretanto, combinando-se sinais de sEMG com sinais de movimento resultou numa melhoria de aproximadamente 20% em relação à análise individual dos dados, o que enfatiza o potencial da fusão de dados.

Melhoria semelhante foi alcançada quando combinados os sinais de sEMG com os dados cinemáticos de membros inferiores no trabalho de ([HUANG et al., 2011](#)). No estudo de [Huang et al. \(2011\)](#), foram coletados dados de 5 pessoas com amputação transfemural através de uma interface baseada na fusão neuromuscular-mecânica utilizando dados de sEMG e dados de posição fornecidos pela prótese, de forma a reconhecer uma variedade de tarefas e prever transição entre as mesmas. Seus resultados mostraram que tal fusão fornece precisão superior aos métodos que utilizam uma única fonte de dados, apresentando uma classificação com mais de 99% de precisão na fase de apoio (período da marcha em que o pé do indivíduo se encontra em contato com o chão) e 95% de precisão na fase de balanço (período da marcha em que o pé do indivíduo não faz contato com o chão), durante a locomoção.

Em outro estudo, [Gallego et al. \(2012\)](#) propuseram um sistema multimodal para compensação funcional de tremores em membros superiores com um robô vestível, utilizando dados de EEG, sEMG e sensores inerciais ou Unidade de Medida Inercial (IMU - *Inertial Measurement Unit*) para realizar a estimulação elétrica dos músculos. Foram realizados experimentos com 5 pacientes com tremor essencial (uma patologia que, assim como a doença de Parkinson, provoca tremores involuntários nos membros do indivíduo) e foi apresentada uma prova de conceito da interface, para prever a intenção do usuário de

realizar um movimento voluntário, além de detectar e parametrizar o tremor concomitante, com o intuito de anular o tremor através de Estimulação Elétrica Funcional (FES).

Kirchner, Tabie e Seeland (2014) mostraram, através de uma análise *off-line*, que a combinação de EEG e sEMG pode ser usada na predição do movimento e no melhoramento da adaptabilidade de dispositivos assistivos. Apesar do estudo ter sido realizado com 8 sujeitos saudáveis, a combinação destes sinais pode ser utilizada potencialmente para pessoas com problemas de mobilidade.

Para membros superiores, Kirchner, Tabie e Seeland (2014) alcançaram precisões médias entre 88% e 94%, utilizando uma lógica OU entre os sinais de EEG e sEMG para a detecção da intenção de movimento. Notou-se uma piora considerável utilizando uma lógica E, apesar desta lógica reduzir a quantidade de falsos positivos (sinais de movimento detectados durante a fase de repouso) da combinação dos sinais.

Jiang et al. (2015) propuseram uma BCI para uma detecção, em uma única repetição, do início da marcha através de Potenciais Corticais Relacionados com Movimento (MRCP, do inglês, *Movement-Related Cortical Potential*), detectando o início do movimento de passos. Através do estudo com 9 sujeitos saudáveis, os autores obtiveram aproximadamente 77% de acurácia em uma única repetição do experimento, alcançando resultados compatíveis com estudos semelhantes realizados por Niazi et al. (2011), que detectaram a intenção de movimento de sujeitos sentados. Uma característica importante dos detectores de intenção motora baseados em MRCP é sua alta latência de detecção, podendo o movimento ser detectado até quase 1 segundo após ocorrido o movimento Niazi et al. (2011). Para estudos baseados em Ritmos Sensório-Motores (SMR, do inglês, *Sensory-Motor Rhythms*), as antecipações da detecção não foram avaliadas (PFURTS-CHELLER; SOLIS-ESCALANTE, 2009) e, geralmente, não foram relatadas. Entretanto, em estudos que verificaram esta latência, este valor foi de pelo menos 1 s (JIANG et al., 2015; HASHIMOTO; USHIBA, 2013).

Xu et al. (2014b) apresentaram uma interface multimodal baseada em sinais de EEG e sEMG para controle de uma órtese de membro inferior com foco em induzir a neuroplasticidade, utilizando, da mesma forma que Jiang et al. (2015), MRCPs para detecção de intenção do movimento no sinal de EEG. Porém, a latência foi da ordem de 1 segundo para a órtese ativa de 1 grau de liberdade para movimento do tornozelo, chamada de MAFO (do inglês, *Motorized Ankle-Foot Orthosis*) ou Órtese Motorizada para Tornozelo e Pé.

É importante neste ponto fazer um comentário a respeito de latência no controle de dispositivos robóticos. Segundo Hudgins, Parker e Scott (1993), 300 ms deveria ser o limite máximo para que um dispositivo robótico execute um movimento após dado o comando pelo usuário. Valores acima deste limiar levam à frustração e confusão do

usuário ao controlar o dispositivo. Autores mais recentes consideram ainda menor este tempo, indicando que o dispositivo deva mover-se em 100 ou, no máximo, em 200 *ms* após o comando do usuário (OSKOEI; HU, 2007; CELANI, 2010). Quanto aos sinais de EEG, os padrões de características relacionadas à dessincronização e à sincronização (ERD/ERS, do inglês, *Event-Related Desynchronization and Synchronization*) do SMR podem ocorrer desde 2 segundos antes do movimento, até 1 segundo após o movimento (PFURTSCHELLER; Lopes da Silva, 1999). Por outro lado, os sinais de MRCP ocorrem apenas alguns milissegundos antes do movimento (JIANG et al., 2015). Os sinais de sEMG podem ocorrer até 500 *ms* antes do movimento (KIRCHNER; TABIE; SEELAND, 2014).

Ibáñez et al. (2013) não apresentaram uma interface multimodal, mas propuseram técnicas para detecção de intenção de movimento baseadas em EEG e IMUs para aplicação em pacientes com tremor, sugerindo a combinação desses sinais com sinais de sEMG para melhoria da acurácia da detecção. Os autores propuseram também um protocolo de testes em que pessoas saudáveis e com tremor realizaram movimento de membros superiores e fizeram uma comparação entre os resultados, concluindo que os períodos de predição alcançados foram suficientes para que suas técnicas pudessem ser usadas por outros sistemas, detectando precisamente quando um movimento começa e, caracterizando o tremor indesejado de forma a cancelá-lo.

Ressalta-se que algumas pesquisas sobre reabilitação robótica utilizam IMUs, os quais, por serem pequenos e de baixo peso, estes podem ser colocados sobre segmentos do corpo humano sem interferir de forma significativa nos movimentos naturais do usuário. Dessa forma, é possível a obtenção de parâmetros biomecânicos, como a medição de ângulos entre as articulações. Apesar de ser um amplo campo de pesquisa, aplicações clínicas envolvendo o uso de IMUs continuam praticamente inexploradas na literatura, devido à falta de padrões para a colocação desses sensores nos segmentos do corpo, e definição de um sistema de coordenadas anatômico (VARGAS et al., 2014). Alguns desses trabalhos, como em Luinge, Veltink e Baten (2007), propõem um sistema de coordenadas para membros superiores de acordo com movimentos pré-definidos usando IMUs. Picerno, Cereatti e Cappozzo (2008) propõem uma técnica de calibração anatômica de IMUs usando um dispositivo externo. Cutti et al. (2010) desenvolveram um protocolo chamado “*Outwalk*”, o qual define o número de sistemas de coordenadas anatômicas de acordo com o número de articulações adjacentes ao segmento do corpo humano. Entretanto, nenhum deles é utilizado em interfaces multimodais. Ressalta-se ainda que, em relação a trabalhos da literatura, Novak et al. (2013), Gallego et al. (2012) e Kirchner, Tabie e Seeland (2014) alcançaram resultados satisfatórios utilizando interfaces multimodais para sistemas de reabilitação, contudo, todos eles para membros superiores. Trabalhando com membros inferiores, a predição de intenção motora através de sinais de EEG é muito mais complexa, uma vez que a aquisição do sinal de EEG para membros inferiores é mais

difícil do que para membros superiores, devido à localização das regiões das fontes de sinais cerebrais referentes a esses eventos ocuparem uma região reduzida no córtex motor cerebral e estarem localizadas em regiões de sulcos, conforme representa o Homúnculo de Penfield (PENFIELD; THEODORE, 1968; GUYTON; HALL, 2006) (Figura 7). Na Figura 7 é apresentado um corte no plano coronal do cérebro humano e apenas um dos hemisférios. Esta Figura representa através de um homúnculo a região do corpo humano e sua respectiva região cerebral responsável por seus movimentos. É possível perceber que a região responsável pelos movimentos dos membros inferiores encontra-se na parte superior, nos sulcos entre os dois hemisférios do cérebro humano.




Figura 7 – Homúnculo de Penfield: grau de representação dos diferentes músculos do corpo no córtex motor. Adaptado de Guyton e Hall (2006).

Dos trabalhos apresentados, Jiang et al. (2015), Niazi et al. (2011) e Xu et al. (2014b) mostram bons resultados com membros inferiores utilizando MRCP, entretanto, embora o alto tempo de antecipação de detecção do movimento não viabilize o uso deste potencial para detectar a intenção do movimento, ele pode ser utilizado para detectar a execução do movimento em si (JIANG et al., 2015).

2.6 Sistemas de Controle

Para dispositivos robóticos, sistemas de controle vêm sendo apresentados de forma a providenciar a interação homem-robô adequada, os quais em sua maioria se baseiam no controle de posição, ou através de uma trajetória pré estabelecida ou através da intensidade força aplicada ao dispositivo (PONS, 2008).

2.7 Interface Multimodal Proposta

Baseado no estudo de literatura realizado, esta Tese de Doutorado propõe uma interface multimodal que utiliza sinais de EEG, sEMG e sinais provenientes de sensores inerciais (IMUs) com o objetivo de obter a predição de movimento de membros inferiores humanos baseada no movimento de flexo-extensão do joelho, utilizando ritmos SMR com potenciais motores ERD/ERS do sinal de EEG por sua alta antecipação destes sinais (até 2 segundos antes do movimento), e sinais de sEMG, de forma a se obter uma boa predição do movimento, a fim de promover um controle de posição eficiente do dispositivo de reabilitação. A interface proposta é aplicada na órtese ALLOR, em desenvolvimento na UFES, que tem como objetivo auxiliar atividades de reabilitação das funções motoras de membros inferiores.

3 Desenvolvimento da Interface Multimodal

3.1 Introdução

Neste capítulo é apresentada a interface multimodal proposta, e os resultados obtidos nos experimentos realizados.

A interface multimodal proposta utiliza sinais de EEG e sEMG para a predição e detecção do movimento, além de sinais provenientes de sensores inerciais (IMUs) para a detecção do instante do início do movimento em membros inferiores, baseados no movimento de flexo-extensão do joelho. Desta forma, pode-se obter com esta interface não somente a intencionalidade do movimento, mas também mostrar sua execução efetiva, caracterizando, portanto, um movimento intencional desde seu planejamento até sua realização, tal como proposto por Gallego et al. (2012). É importante ressaltar que os sensores inerciais são utilizados nesta etapa do trabalho para identificar o início do movimento, uma vez que nesta etapa inicial do estudo os experimentos foram realizados sem o dispositivo robótico.

A integração da interface multimodal com o exoesqueleto robótico ALLOR será apresentada no Capítulo 5. Como os sensores inerciais são utilizados para a detecção do início efetivo do movimento, e considerando que tais dispositivos podem sofrer com perturbações causadas pelo campo magnético gerado pelo atuador do exoesqueleto, nessa etapa, a detecção do início efetivo do movimento será realizada com o sensor de força instalado na estrutura do exoesqueleto.

Neste capítulo também é apresentada a proposta de um protocolo experimental de testes, o qual envolve a colocação adequada de sensores, e uma proposta de utilização de classificadores de sinais de EEG, a qual possui duas etapas: uma baseada na análise em frequência e outra baseada na análise no tempo.

Este capítulo também apresenta uma análise *off-line* dos dados com o intuito de identificar a intenção de movimento, a ativação muscular e o movimento efetivo de membros inferiores através dos sinais de EEG, sEMG e IMU, respectivamente. Posteriormente, esta interface será integrada ao exoesqueleto robótico para a realização do controle em tempo real (Capítulo 5).

A Figura 8 ilustra como a interface multimodal proposta atua no contexto do controle de um dispositivo robótico utilizado em reabilitação. A aquisição de dados envolve o sensoriamento e o condicionamento dos sinais, e o processamento envolve a sincronia dos dados, a extração de características e classificação dos sinais, os quais serão aplicados

na estratégia de controle do dispositivo robótico.

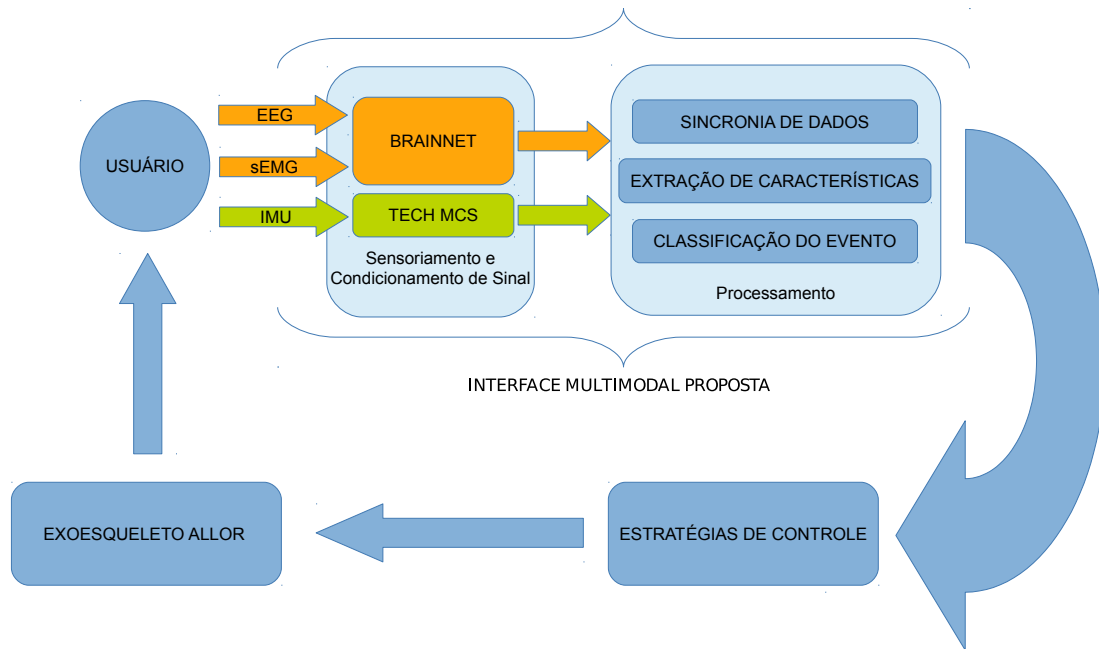


Figura 8 – Interface multimodal proposta.

Para o desenvolvimento dessa interface, é necessário fazer a integração dos sistemas que fazem a aquisição dos sinais biológicos, de forma que estes estejam sincronizados. Para o processamento dos sinais, utilizaram-se técnicas de detecção de intencionalidade de movimento através da análise de uma repetição de sinais de EEG, isto é, uma análise de repetição única, além de técnicas para a detecção do início da atividade muscular durante o movimento de flexão e extensão do joelho. Tais técnicas serão descritas no decorrer deste capítulo. Ainda neste capítulo são propostas 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. Finalmente, é realizada uma análise da correção dos métodos utilizados para o processamento e classificação dos sinais nos eventos citados, mostrando a precisão dos classificadores utilizados e os tempos obtidos de antecipação do movimento.

3.2 Materiais e Métodos

Dez voluntários rígidos (9 mulheres e 1 homem), destros, com idades entre 19 e 24 anos, participaram deste estudo. Este estudo tem aprovação do Comitê de Ética em Pesquisa com seres humanos da UNESA, CAAE número 51685515.3.0000.5284, número do parecer 1.863.539.

O equipamento utilizado para adquirir os dados de EEG e sEMG foi o BrainNet[®] BNT-36 (Lynx Eletrônica, Brasil). Os sinais de EEG foram adquiridos utilizando o padrão internacional 10-20. As posições utilizadas foram: $Fp1$, $Fp2$, $F7$, $F3$, Fz , $F4$, $F8$, $C3$, Cz , $C4$ e Pz e não só os canais do córtex motor ($C3$, Cz e $C4$), pois um maior número de canais facilitará a filtragem espacial (Seção 3.4.3). A Figura 9 ilustra o posicionamento dos eletrodos.




Figura 9 – Posicionamento dos eletrodos no padrão 10-20.

Adicionalmente, um canal bipolar foi utilizado para adquirir o sinal de sEMG, utilizando eletrodos passivos de Ag/AgCl com gel, posicionados na coxa direita do voluntário, de acordo com o protocolo SENIAM (HERMENS et al., 1999) (protocolo para o posicionamento dos eletrodos em função da localização dos músculos), especificamente no músculo reto femoral, que está diretamente relacionado com o movimento de flexão e extensão do joelho (CRISWELL, 2011), como pode ser visto na Figura 10.

Também foram utilizados dois sensores inerciais, do sistema Tech MCS[®] (Technaid, Espanha), os quais fornecem orientação espacial dos membros inferiores em tempo real. Os sensores foram posicionados na coxa e na perna, conforme mostrado na Figura 11. A utilização desse sistema inercial viabiliza a análise cinemática do movimento, uma vez que não há necessidade de ambientes estruturados, tais como os utilizados em sistemas baseados em visão computacional (fotogrametria). Adicionalmente, é um sistema móvel e pequeno, portanto, mais flexível, possuindo erros de medida menores que 1 grau, segundo o fabricante, e interferindo de forma pouco significativa com os movimentos naturais do corpo humano.

Um software para integrar e sincronizar os sistemas de aquisição também foi desenvolvido neste trabalho. A taxa de amostragem do BrainNet[®] BTN-36 foi configurada

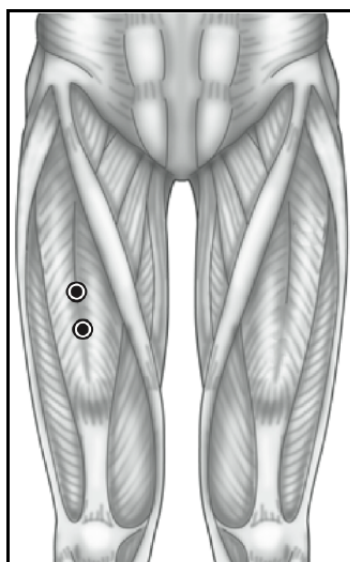


Figura 10 – Colocação dos eletrodos para obtenção de sinais de sEMG sobre o músculo reto femoral (CRISWELL, 2011).




Figura 11 – Posicionamento dos sensores inerciais na perna do usuário.

para 600 Hz , a máxima disponível, a qual é utilizada para obter os sinais de EEG e sEMG. Por outro lado, a taxa de amostragem do sistema de aquisição de sinais dos sensores inerciais foi configurada para 50 Hz , valor compatível com os movimentos da perna executados nos experimentos, já que movimentos naturais de membros inferiores são compostos por movimentos de frequência inferiores a 5 Hz (YANG; KONG, 2009).

A Figura 12 representa a interface multimodal proposta em função dos equipamentos utilizados. Nela é possível observar a integração dos sinais de EEG e sEMG adquiridos pelo BrainNet[®] BNT-36, e os sinais das IMUs adquiridos pelo sistema Tech MCS[®]. Todos esses dados são armazenados, sincronizados e processados. A sincronia dos dados é

necessária, pois os dois sistemas de aquisição operam independentemente.

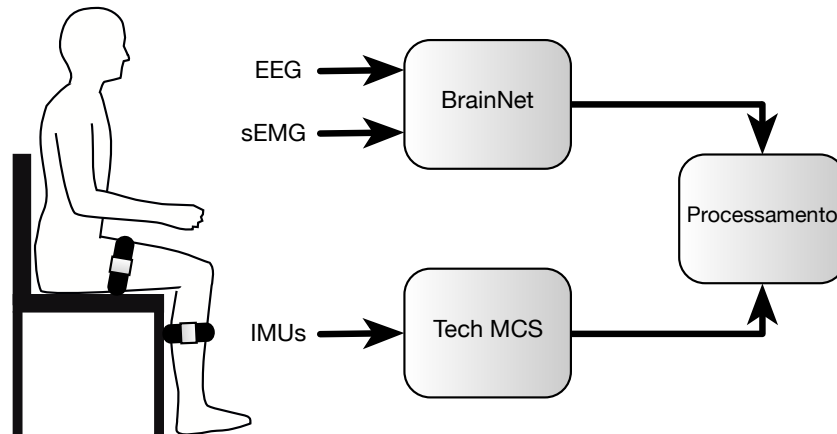


Figura 12 – Plataforma multimodal proposta em função dos equipamentos utilizados.

3.3 Protocolo Experimental

Cada experimento foi composto por 30 repetições de extensão e flexão dos joelhos, sendo que cada repetição dura, aproximadamente, 30 s, incluindo a execução do movimento e a fase de descanso.

Durante a sessão experimental os voluntários estavam confortavelmente sentados com as mãos relaxadas e com os pés suspensos, sem tocar o chão. Ressalta-se que a aquisição dos sinais biológicos foi realizada com os voluntários descansados e que a influência do esforço muscular ao longo das repetições de um experimento foi considerada desprezível para análise dos sinais de sEMG. Assumiu-se que a coxa permaneceu imóvel, pois estava em cima de uma superfície plana e rígida, e houve somente o movimento da perna durante a tarefa. Durante o experimento, o examinador do experimento solicitou que o voluntário realizasse o movimento normalmente, e que mantivesse os olhos abertos, evitando piscar e engolir.

A Figura 13 ilustra um voluntário em posição inicial com eletrodos fixados em fase de calibração dos sensores. Na figura, é possível observar o voluntário com os sensores inerciais posicionados na parte externa da coxa e da perna 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, pois este processo será realizado virtualmente na etapa de processamento dos dados.

Uma representação gráfica de uma repetição do experimento (30 s) pode ser vista na Figura 14. Ela se inicia após uma indicação acústica, e o voluntário realiza o movimento de acordo com sua vontade após a segunda indicação acústica (10 s após o início). A




Figura 13 – Voluntário vestindo sensores durante uma sessão do experimento.

linha-base (intervalo entre os instantes 5 s e 8 s) é um período durante a repetição em que o voluntário não deve se mover e tampouco deve ter a intenção de fazê-lo. Os dados dos sinais coletados durante o intervalo da linha-base são utilizados pelos classificadores para compará-los com dados coletados durante o movimento e durante o intervalo onde o usuário tem intenção de se movimentar. Em razão da diferença intrínseca entre tais momentos, propicia-se a diferenciação dos padrões nos sinais. A duração do movimento de extensão e flexão do joelho não é contabilizada, uma vez que o que se deseja analisar é apenas o início do movimento. O período de tempo dependente do voluntário realizar o movimento após a segunda indicação acústica é necessário para evitar que artefatos relativos à indicação acústica contaminem o sinal relacionado ao movimento nos sinais de EEG.

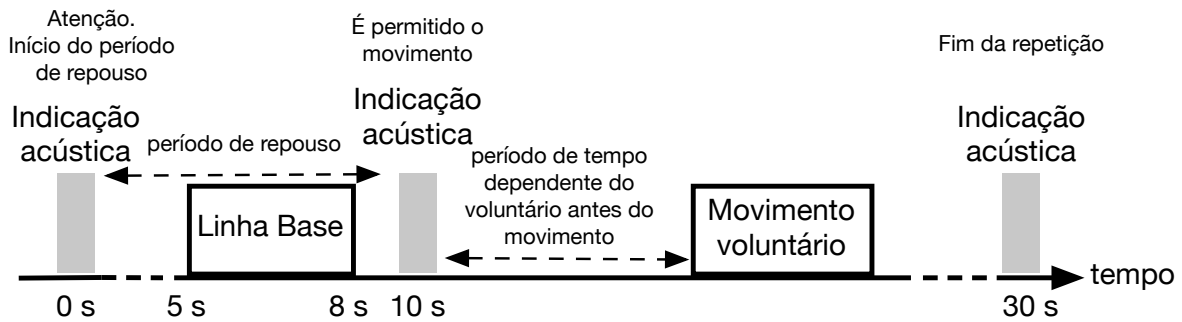


Figura 14 – Descrição de uma repetição do experimento.

3.4 Processamento dos Dados

Os sinais coletados (IMU, sEMG e EEG) foram então sincronizados e processados de forma *off-line* através de um programa desenvolvido em Matlab. A interface principal do programa pode ser observada na Figura 15, onde as partes responsáveis pela leitura dos dados capturados, sincronismo entre as repetições, processamento dos sinais das IMUs, processamento dos sinais de EEG, processamento dos sinais de sEMG, geração dos resultados, e uma análise *pseudo-online*, simulando a aquisição *on-line* dos sinais.

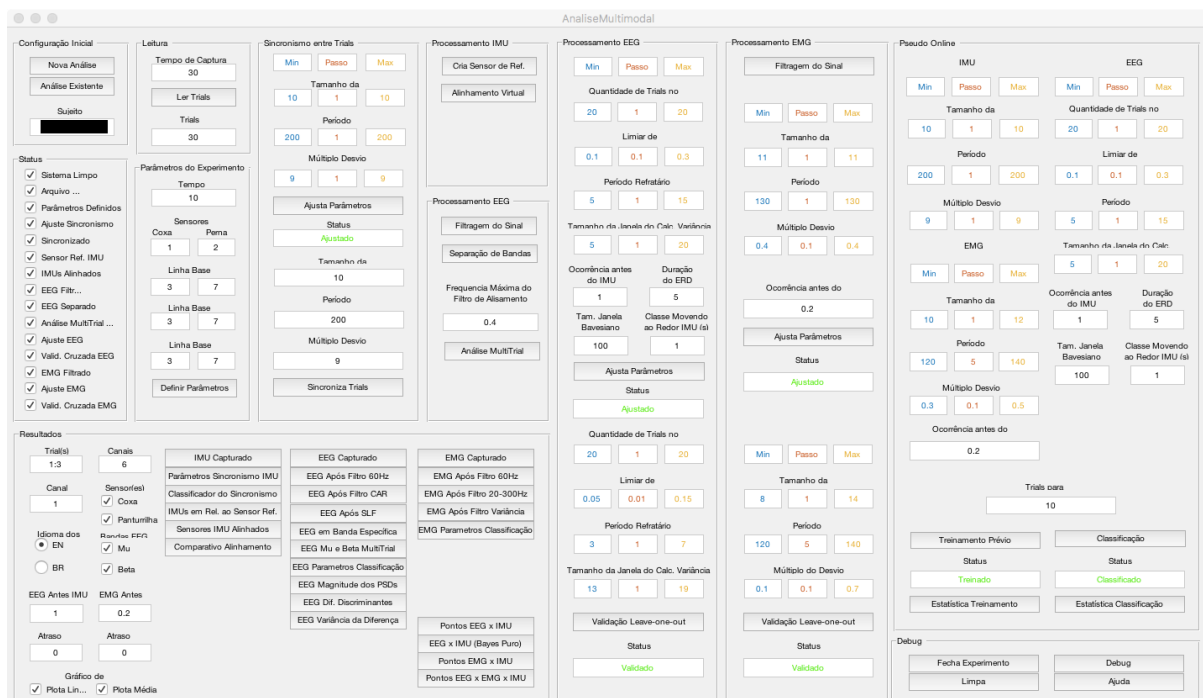


Figura 15 – Interface do programa desenvolvido em Matlab para a análise multimodal.

3.4.1 Processamento dos Sinais dos Sensores Inerciais

Nesta etapa da pesquisa, os sinais provenientes dos sensores inerciais (IMUs) foram utilizados para detectar o início do movimento, ou seja, o começo do deslocamento efetivo do membro inferior para cada repetição de movimento realizada nos experimentos, uma vez que o exoesqueleto ainda não estava conectado à perna do usuário.

3.4.1.1 Alinhamento Virtual

As três rotações que ocorrem em movimentos naturais no joelho são flexão/extensão, abdução/adução e rotação interna/externa (FAVRE et al., 2009). Entretanto, o processo de alinhamento virtual aqui descrito foi focado apenas no movimento de flexão/extensão, que é o movimento que será utilizado no sistema proposto.

Os sensores inerciais foram configurados para fornecerem representação espacial através de matrizes de cossenos diretores (DCM, do inglês, *Direction Cosine Matrix*), sendo que os dados representam a posição espacial em relação à referência global, ou seja, a posição em relação ao campo magnético terrestre e à gravidade. Assim, para se medir os ângulos relativos entre os sensores da coxa e da perna, a referência do sensor da perna foi transformada de sua referência global para a orientação do sensor da coxa. Essa operação é representada pela Equação 3.1.

$$M_{pc} = M_c^{-1}M_p, \quad (3.1)$$

onde M_{pc} representa a DCM do sensor da perna referenciada ao sensor da coxa, enquanto M_c e M_p representam as DCMs dos sensores da coxa e da perna, 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 obter 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 aqui proposto. Em tal procedimento, foi considerado que, no momento da calibração, o ângulo de flexão/extensão do joelho é de 90° , ou seja, a coxa e a perna estão a 90° uma da outra (este ângulo foi ajustado fisicamente através de um goniômetro). Também foi considerado não haver rotação interna/externa, tampouco adução/abdução nesse momento. Conseqüentemente, os sensores da coxa e da perna foram assumidos alinhados no plano XY e rotacionados de -90° em relação ao eixo Z no momento da calibração do sistema. Como a colocação manual dos sensores não garante essa configuração, um sensor virtual foi criado para que tal posicionamento seja alcançado. A Figura 16 ilustra o procedimento, onde: (a) representa o sensor da coxa, enquanto (b) representa

o sensor da perna, colocado sem se preocupar com o alinhamento, e (c) representa um sensor virtual alinhado de acordo com o protocolo experimental, ou seja, a 90° do sensor da coxa.




Figura 16 – Ilustração do procedimento de alinhamento virtual (BOTELHO et al., 2015b).

O sensor virtual foi criado pela rotação do sensor da coxa em -90° em 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 perna e a posição do sensor virtual seja conhecida. Para tanto, fez-se a DCM do sensor real da perna referenciada em relação ao sensor virtual. Essa operação é realizada através da Equação 3.2.

$$M_{pv} = (R_z M_{cc})^{-1} M_p, \quad (3.2)$$

onde M_{pv} representa a DCM do sensor real da perna (sensor (b)), referenciada ao sensor virtual (sensor (c)), no momento de calibração do sistema; M_{cc} representa o sensor da coxa (sensor (a)), referenciado a ele próprio, ou seja, uma matriz identidade. R_z representa a matriz de rotação de -90° em torno do eixo z , e M_p representa a DCM do sensor real da perna (sensor (b)).

Para que o alinhamento seja realizado, a diferença entre o sensor virtual e o sensor real da perna, que está contida em M_{pv} , é aplicada ao sensor real da perna ao longo do experimento. Esse passo é representado pela Equação 3.3. Dessa forma, é como se os sensores fossem posicionados de acordo com a configuração desejada.

$$M_{pcalinhado} = M_{pc} M_{pv}^{-1}, \quad (3.3)$$

onde $M_{pcalinhado}$ representa a DCM atual do sensor da perna já alinhada ao sensor da coxa, como suposto no protocolo, enquanto M_{pc} representa a DCM do sensor real da perna referenciada ao sensor da coxa ao longo do experimento.

Ressalta-se que a referência utilizada em ambos os sensores é a orientação do sensor da coxa no momento de calibração. Supõe-se que não há movimento da coxa durante a tarefa realizada, mas somente movimento da perna. Tal consideração é feita, pois, como já mencionado, a coxa está apoiada sobre uma superfície plana e rígida. A Figura 17 ilustra os movimentos dos dois sensores em relação ao sensor de referência.

Os dados da DCM $M_{pcalinhado}$ foram então convertidos, por meio de operações com matrizes, em ângulos de Euler, para que o movimento do joelho no plano sagital pudesse ser representado.

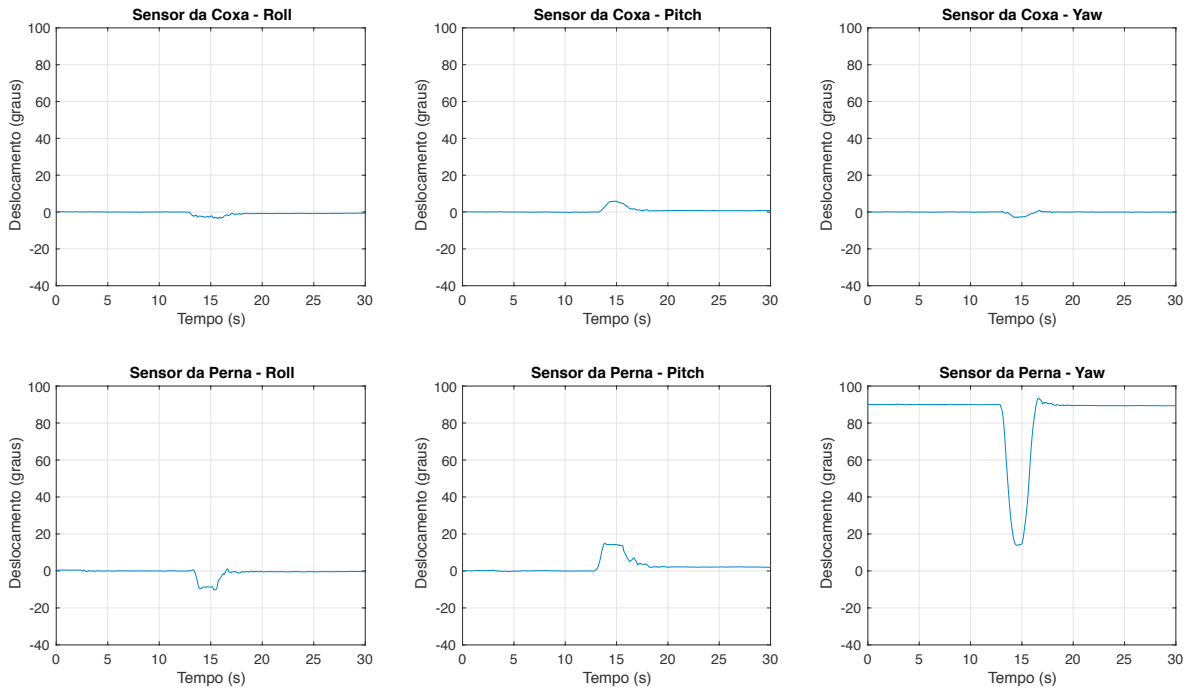


Figura 17 – Deslocamento dos sensores inerciais em relação ao sensor virtual de referência durante os movimentos de extensão e flexão do joelho.

3.4.1.2 Detecção do início do movimento

Para que o início efetivo do deslocamento seja detectado, são obtidos os ângulos de Euler (*Roll*, *Pitch* e *Yaw*, com rotações em torno dos eixos x , y e z respectivamente conforme a Figura 18) relativos ao sensor colocado na perna. Um classificador de limiar avalia o deslocamento do movimento realizado pelo joelho (flexão/extensão) no plano sagital. Observou-se através dos experimentos que o deslocamento neste plano é, naturalmente, mais expressivo, e ocorre antes que o dos outros planos. A Equação 3.4 descreve o classificador de limiar.

$$T_N = m_N - p \cdot d_N, \quad (3.4)$$




Figura 18 – IMU utilizada e seus respectivos eixos de orientação (SOPRANI, 2014).

onde T é o limiar, m é a média, d é 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. As janelas são sobrepostas e deslocadas de 1 em 1 amostra. Os parâmetros p e N foram escolhidos através de uma etapa de seleção de parâmetros. O objetivo desta seleção foi encontrar o sinal de movimento que depois de 10 segundos estivesse na maior quantidade de repetições. Desta maneira, foi garantido que os parâmetros dos classificadores estivessem bem ajustados para o sinal utilizado. Na etapa de seleção, o parâmetro p variou de 1 a 10, e o parâmetro N variou de 5 a 50, nos dois casos, com incrementos de 1. Além dos parâmetros p e N , foi utilizado um período refratário para que o classificador pudesse detectar o início do movimento, variando de 10 a 200 amostras, com um incremento de 5, sendo assim, as amostras classificadas corretamente em sequência foram consideradas como verdadeiro-positivo. Esta técnica permitiu que os falsos-positivos fossem reduzidos na seleção de parâmetros do classificador. O início da classificação do movimento se refere à primeira amostra das janelas que estão acima do limiar. A Figura 19 ilustra a saída do classificador.

3.4.2 Processamento dos Sinais de sEMG

Os sinais de sEMG foram utilizados para fornecer a ativação muscular durante o experimento, com o objetivo específico de detectar o início da ativação muscular. A Figura 20 apresenta um exemplo do sinal capturado sem qualquer processamento.

Artefatos provenientes da rede elétrica (60 Hz) foram atenuados usando um filtro *Notch Butterworth* de 4ª ordem, como feito por Novak et al. (2013). Foi realizada uma filtragem para que se preservassem as componentes inerentes ao sinal de sEMG do músculo reto femoral, a partir do qual foram feitas as aquisições do sinal. Como sugerido pelas recomendações europeias de sEMG (HERMENS et al., 1999), foi realizada uma filtragem passa-banda (20 a 300 Hz) a fim de limitar a faixa de frequência de interesse do sinal de

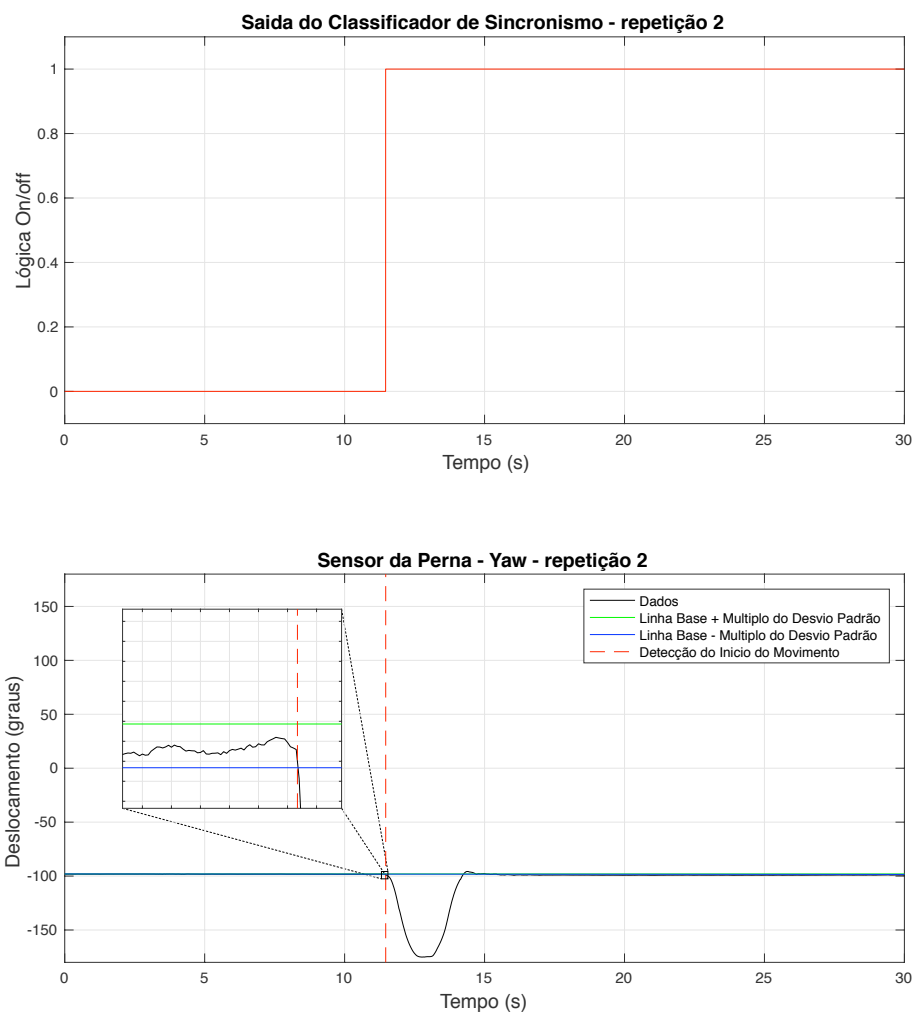


Figura 19 – Saída do classificador para o sinal inercial.

sEMG. A Figura 21 exemplifica este sinal.

O próximo processamento foi a realização de uma filtragem no domínio do tempo através de um filtro de variância definido pela Equação 3.5 (KIRCHNER; TABIE; SEELAND, 2014),

$$v(t) = \frac{1}{N-1} \sum_{i=0}^N [x(t-i)]^2 - \left(\frac{1}{N-1} \sum_{i=0}^N x(t-i) \right)^2, \quad (3.5)$$

onde, 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 trabalho. Sua característica é 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

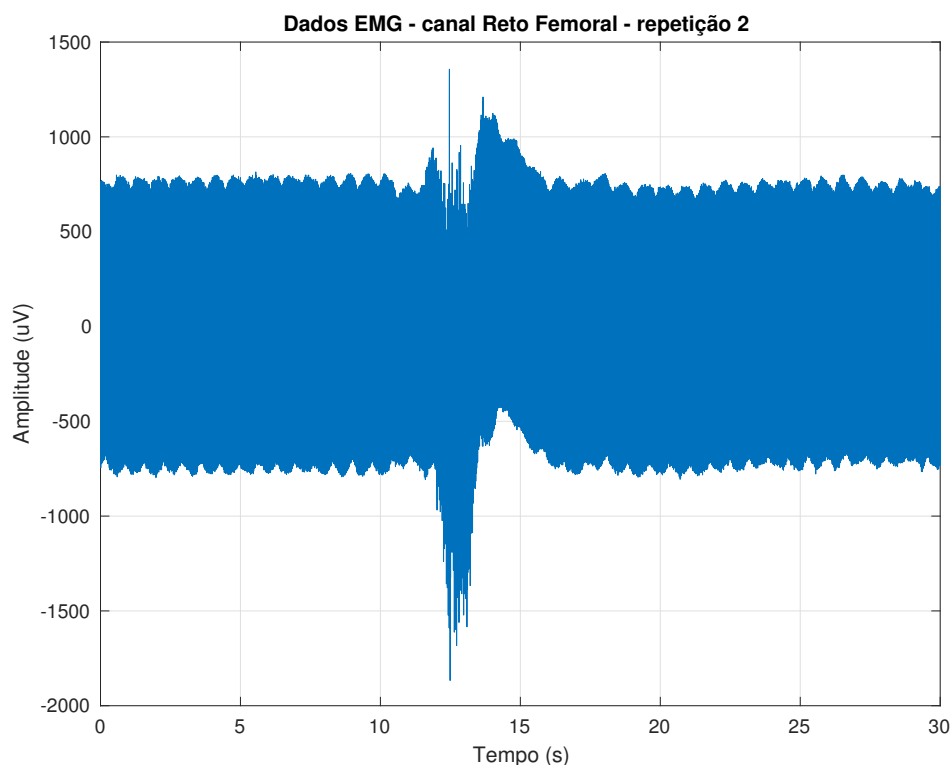


Figura 20 – Sinal de sEMG capturado.

ruídos. O sinal filtrado com o filtro de variância pode ser observado na Figura 22.

O sinal de sEMG filtrado com o filtro de variância 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 (linha-base). Esse classificador é análogo ao classificador utilizado para detecção do início do movimento utilizando sensores inerciais (Equação 3.4) e, neste ponto, é utilizado para a detecção do início da ativação muscular. Para este sinal, o parâmetro p variou de 0,1 a 5, com incrementos de 0,1. O parâmetro N variou de 5 a 20 com um incremento de 1 e o período refratário variou de 20 a 150 amostras, com incremento de 5, classificadas corretamente em sequência para considerar um verdadeiro-positivo. O início da classificação do movimento se refere à primeira amostra das janelas que estão acima do limiar.

A procura pelos parâmetros de configuração do classificador, para treinamento e classificações, é feita através do procedimento de validação cruzada utilizando o método *Leave-one-out*, como realizado por Gallego et al. (2012), que consiste em deixar uma das repetições de fora do treinamento, e após encontrar parâmetros adequados no treinamento, esta repetição é então classificada (Figura 23).

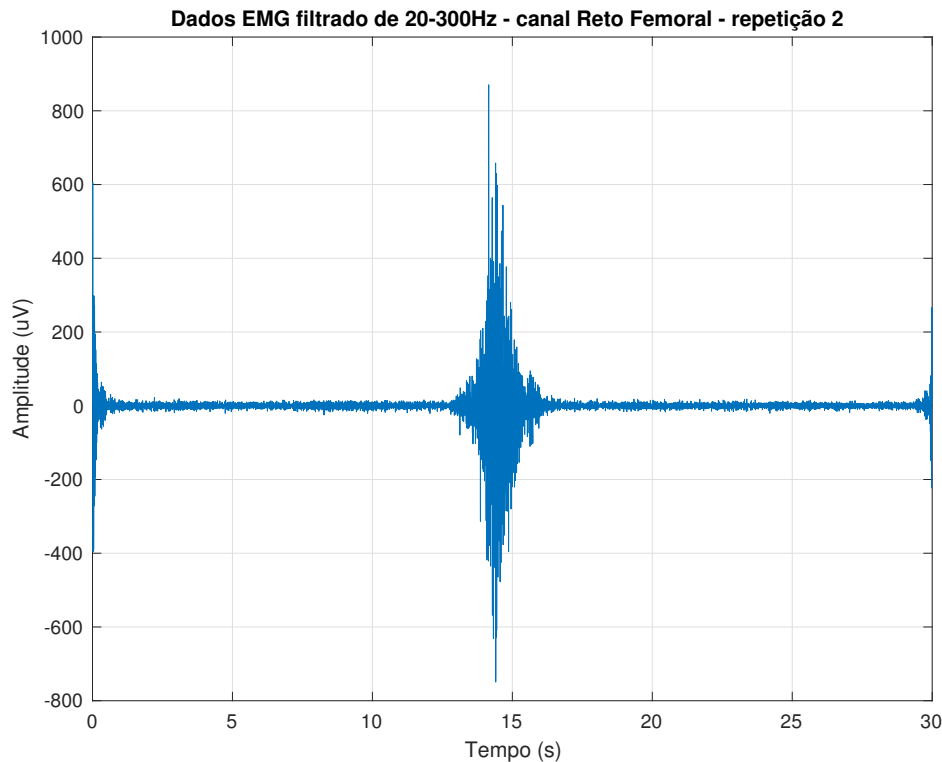


Figura 21 – Sinal de sEMG registrado após eliminação de artefatos da rede elétrica e filtragem passa-banda de interesse (20 a 300 Hz).

3.4.3 Processamento dos Sinais de EEG

Os sinais de EEG foram utilizados para estimar a intenção de movimento do voluntário, ou seja, detectar um tempo no qual o voluntário teve intencionalidade de mover o joelho mesmo que o movimento ainda não tenha efetivamente começado.

Inicialmente, foi realizada uma análise qualitativa, em que se consideram várias repetições do sinal de EEG. Esta análise é conhecida como abordagem *multi-trial*, multi-repetições ou método clássico de observação das características de Dessincronização e Sincronização Relacionadas ao Evento (ERD/ERS), como descrito por [Pfurtscheller e Lopes da Silva \(1999\)](#). Esta técnica foi também utilizada para eliminar os voluntários de teste que não possuíam características ERD/ERS observáveis ([PFURTSCHELLER; Lopes da Silva, 1999](#)).

Após este primeiro passo, uma análise envolvendo uma única repetição do movimento (abordagem *single-trial*) foi aplicada para identificar a intencionalidade do movimento, com uma abordagem quantitativa acerca de acertos por parte dos classificadores.

O processamento total dos sinais de EEG envolve duas etapas: o pré-processamento dos sinais e a classificação dos sinais, que também inclui o treinamento dos classificadores. A parte de pré-processamento engloba a retirada de artefatos dos sinais, uma filtragem

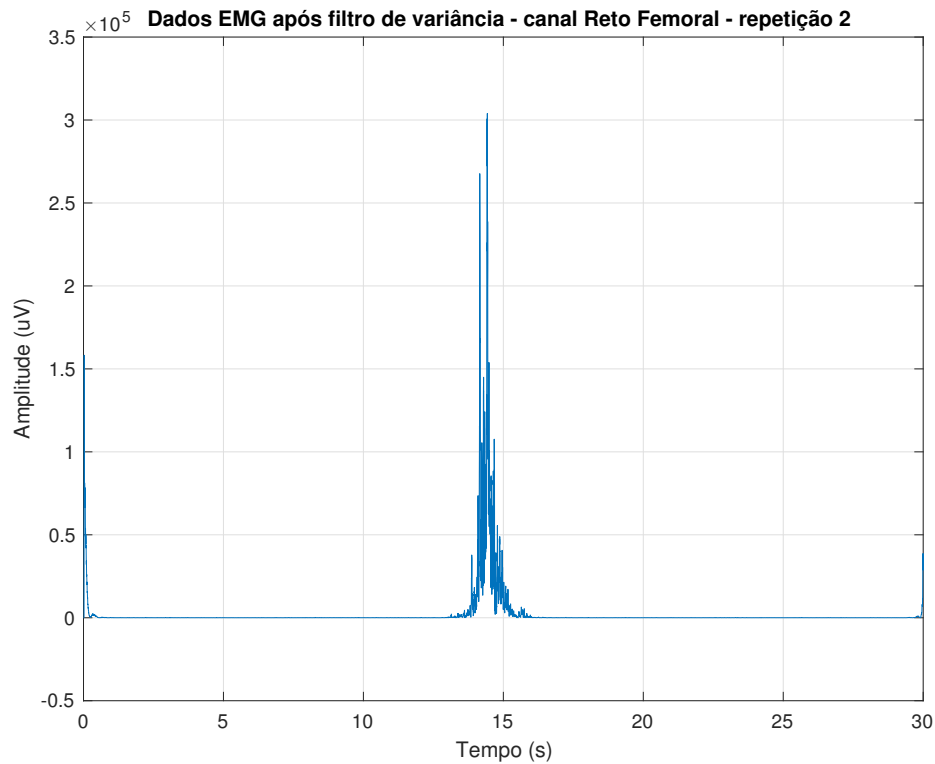


Figura 22 – Sinal de sEMG pronto para ser classificado, após passar pelo filtro de variância.

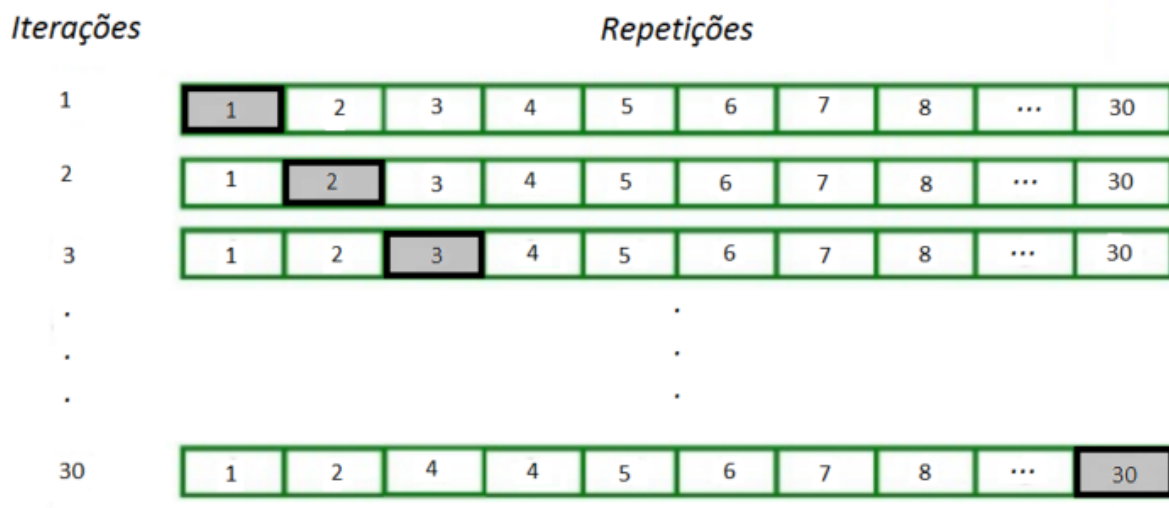


Figura 23 – Processo de validação cruzada utilizando o método *Leave-one-out* para treinamento e teste do classificador de sEMG.

espacial, um processo de Separação Linear de Fontes e a filtragem em frequência na banda, cujas características desejadas são observadas (ERD/ERS). O estágio de classificação do sinal é realizado por um classificador Bayesiano (MITCHELL, 1997) combinado com um classificador de limiar para detectar a intenção de movimento (BOTELHO et al., 2017). As seções seguintes apresentam em detalhes estas etapas.

3.4.3.1 Pré-processamento dos Sinais de EEG

Foi realizada uma filtragem espacial através de um filtro espacial do tipo CAR (do inglês, *Common Average Reference*). 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 (BERTRAND; PERRIN; PERNIER, 1985). Neste processamento se obtém a média entre todos os canais de EEG analisados, e este valor é subtraído do valor do sinal em cada canal, alterando portanto seu valor, porém sem alterar a referência inicial dos canais. O filtro CAR pode ser definido pela equação 3.6.

$$v_i^{CAR} = v_i^{RC} - \frac{1}{N} \sum_{j=0}^N v_j^{RC}, \quad (3.6)$$

onde, 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. Uma vez que a média comum prioriza os sinais que estão presentes em uma grande quantidade de canais, a subtração leva à eliminação destes sinais.

As Figuras 24a e 24b exemplificam o sinal de EEG capturado para o canal Cz, antes e após a filtragem CAR, respectivamente.




Figura 24 – Sinal de EEG do canal Cz (a) capturado; (b) após o filtro CAR.

O sinal EEG resultante passa por um processo de Separação Linear de Fontes (SLF). Nesta abordagem, as fontes cerebrais foram modeladas como dipolos elétricos perpendiculares à superfície, devido à orientação dos neurônios piramidais e à distribuição bipolar de seu campo eletromagnético (BENEVIDES; BASTOS-FILHO; SARCINELLI-FILHO, 2008). 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 (Figura 25). 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. Com esse modelo considera-se 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, 2009). A Figura 26 exemplifica o sinal após este processo.

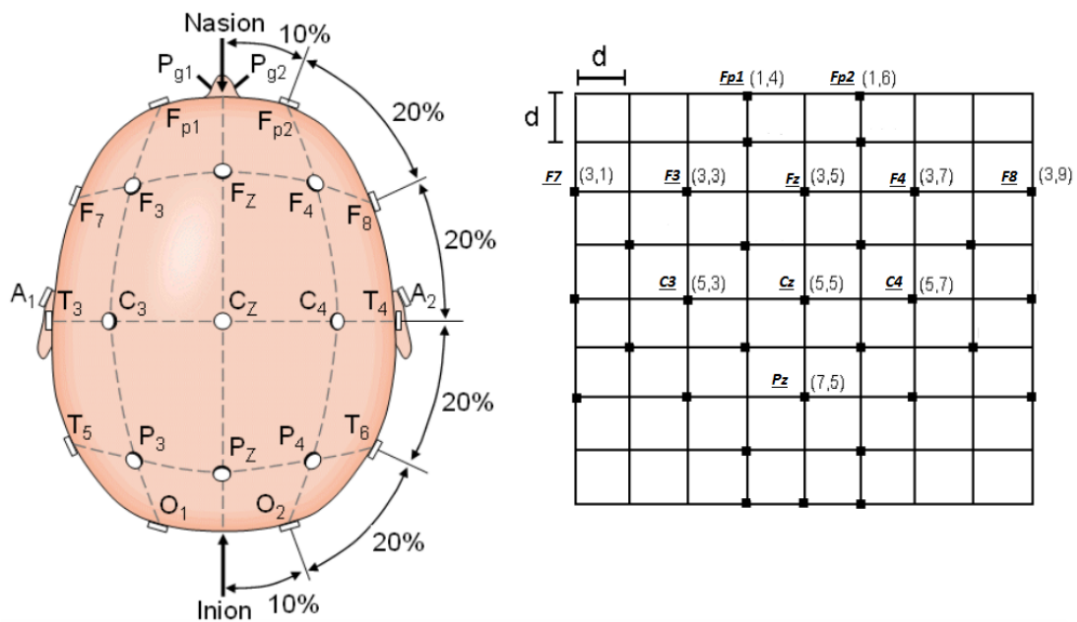


Figura 25 – Esquerda: disposição dos eletrodos sobre o escalpo; Direita: mapeamento dos eletrodos referentes aos canais utilizados em um plano euclidiano. Adaptado de Benevides (2009) (SOPRANI, 2014).

A próxima etapa do pré-processamento dos sinais de EEG trata da filtragem no domínio da frequência na banda μ ($8 - 12Hz$) (CHENG et al., 2004), na qual ocorre predominantemente a característica ERD, relacionada à intenção de movimento (PFURTSCHELLER; Lopes da Silva, 1999). Os sinais, nesta etapa, foram filtrados por filtros passa-banda *Butterworth* de 4ª ordem, como proposto por Ibáñez et al. (2013). A Figura 27 exemplifica o sinal após este processo.

A última etapa trata do sincronismo dos sinais. Os segundos iniciais foram descartados, pois referem-se à estabilização dos sinais e não podem ser considerados. Além disso, foram descartados os segundos finais, pois variam entre as repetições e dependem da duração de cada movimento. Eles foram descartados com a finalidade de sincronizar o início do movimento entre as repetições, como se indica na Figura 28.

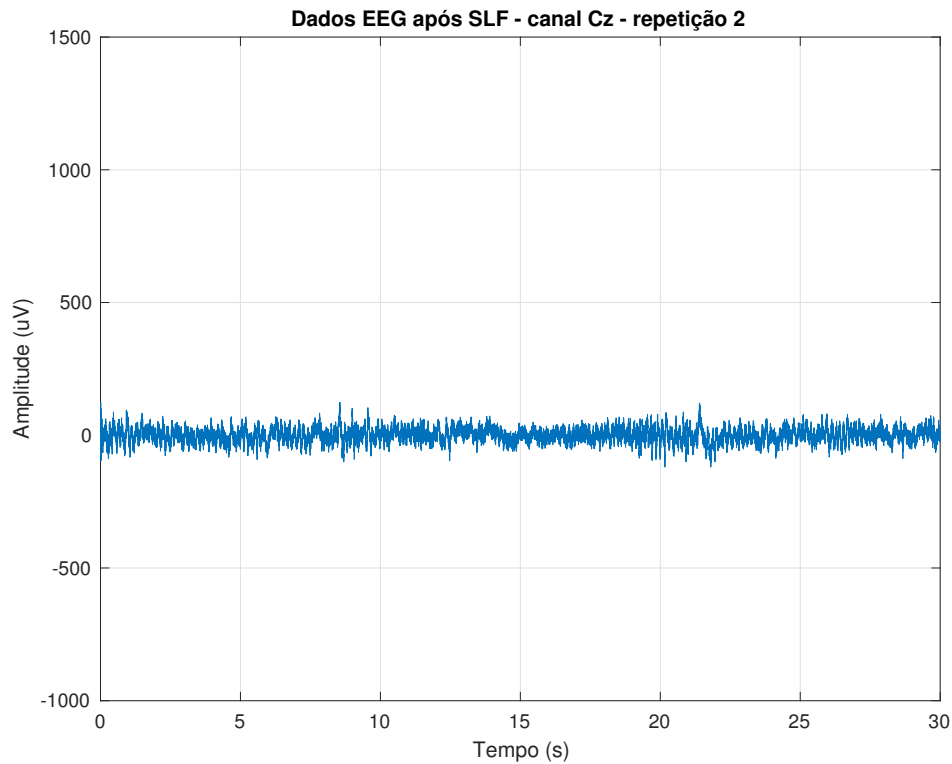


Figura 26 – Sinal de EEG do canal Cz após a Separação Linear de Fontes.

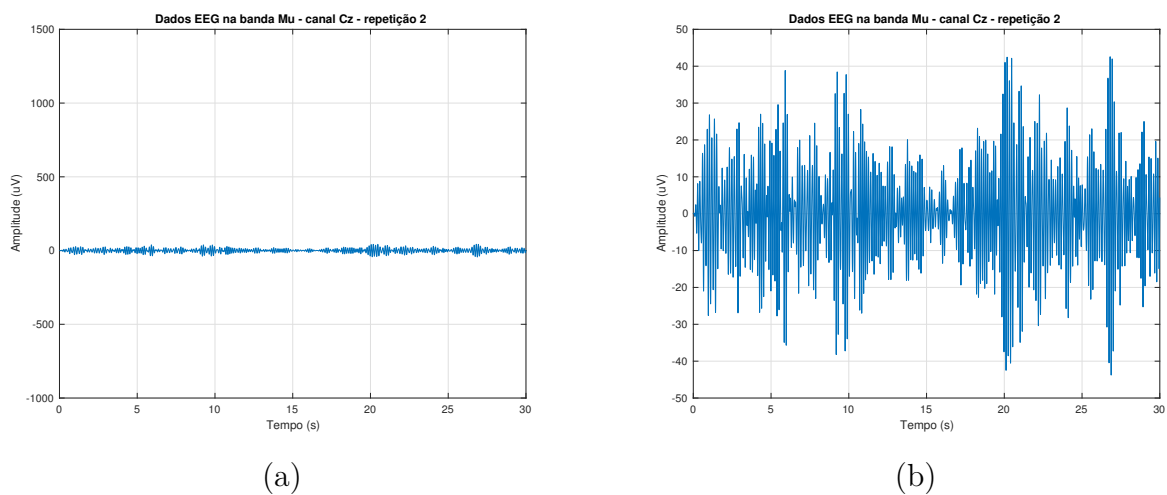


Figura 27 – Sinal de EEG do canal Cz na banda μ (a) na escala das Figuras 24 e 26; (b) em escala adequada.

Para observar as características ERD/ERS nos sinais de EEG (abordagem multi-repetições), basta elevar estes sinais ao quadrado, obtendo as amostras de energia. Se calcula a média da energia de todos os instantes, e a curva é suavizada através do cálculo da média dos pontos em um pequeno intervalo de tempo (janelas com N amostras com N variando de 1 a 100, para menor ou maior suavização). Para obter a porcentagem de

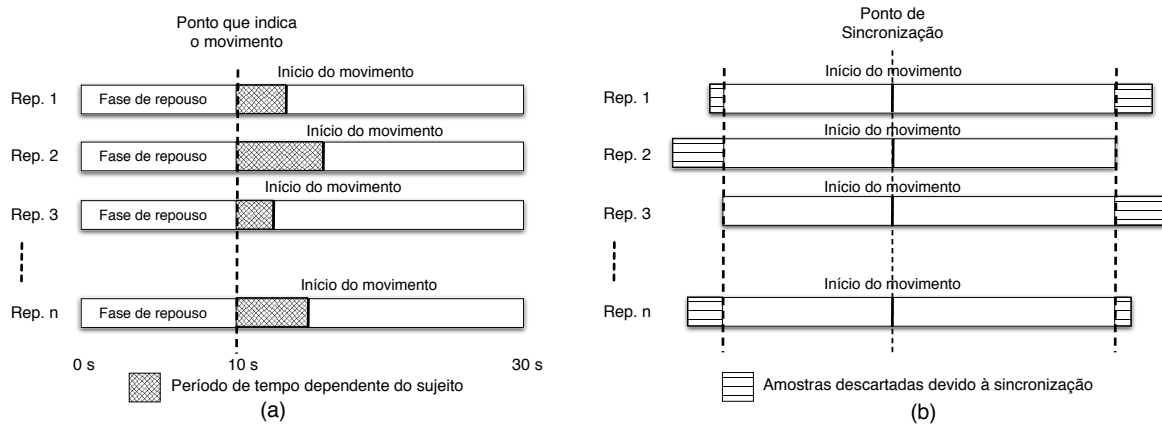


Figura 28 – Sincronismo das repetições com base na detecção do início do movimento. (a) Repetições antes do sincronismo; (b) repetições depois do sincronismo.

ERD/ERS, se calcula a energia na banda de frequência de interesse A (banda μ) e a energia média de um período de referência anterior ao evento R (linha base). O ERD e ERS se definem como porcentagens de incremento ou decremento respectivamente, de acordo com a Equação 3.7 proposta por Pfurtscheller e Lopes da Silva (1999).

$$ERD(\%) = \frac{(A - R)}{R \times 100} \quad (3.7)$$

A Figura 29 apresenta a análise multi-repetições para um voluntário, onde foram identificadas as características de ERD coincidindo com o início do movimento (pouco após os 10 segundos da tarefa). Pode-se perceber claramente uma diminuição da energia do sinal durante o movimento. A Figura 30 apresenta a análise multi-repetições, para um dos voluntários, onde não foram identificadas as características de ERD.

3.4.3.2 Detecção da Intenção de Movimento Utilizando uma Única Repetição

Este trabalho utilizou um classificador Bayesiano alimentado por valores de Densidade Espectral de Potência (PSD, do inglês, *Power Spectral Density*) dos sinais de EEG na banda μ , com o objetivo de detectar o início da intenção de movimento (IBÁÑEZ et al., 2013). Foram utilizadas duas classes: a classe *movimento* e a classe *estática*. A primeira diz respeito aos momentos de intenção de movimento e o movimento efetivo. Se considera movimento todo o intervalo da tarefa onde o usuário realiza a extensão da perna e posteriormente a flexão. A segunda classe diz respeito aos instantes em que o voluntário não se movimenta, e tampouco tem intenção de fazê-lo.

As características observadas que definem as classes citadas são valores de PSD nos canais $C4$, $C3$ e Cz em frequências específicas na banda μ , com uma resolução de $0,125 \text{ Hz}$ por amostra. Estas características geram funções que se chamam discriminantes

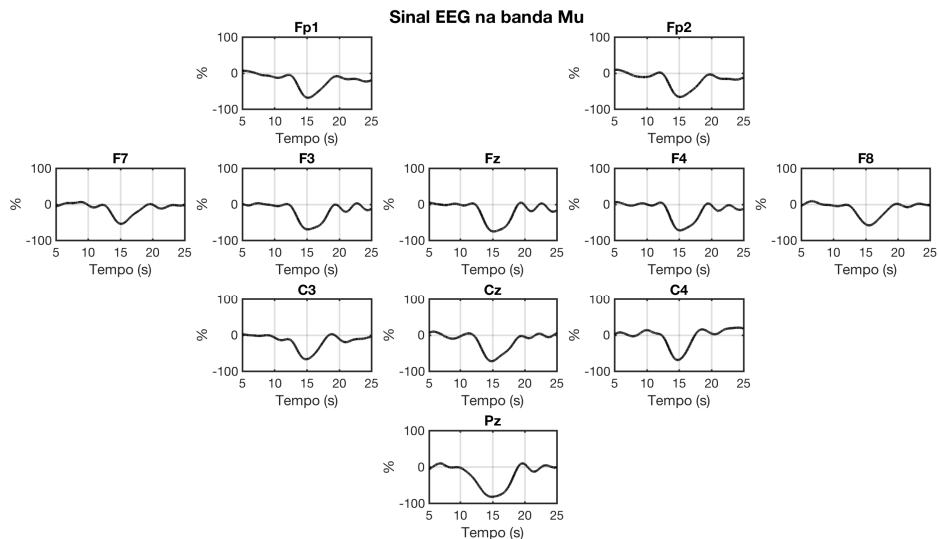


Figura 29 – Sinal EEG multi-repetições onde a Dessincronização Relacionada a Evento (ERD) pode ser identificada.

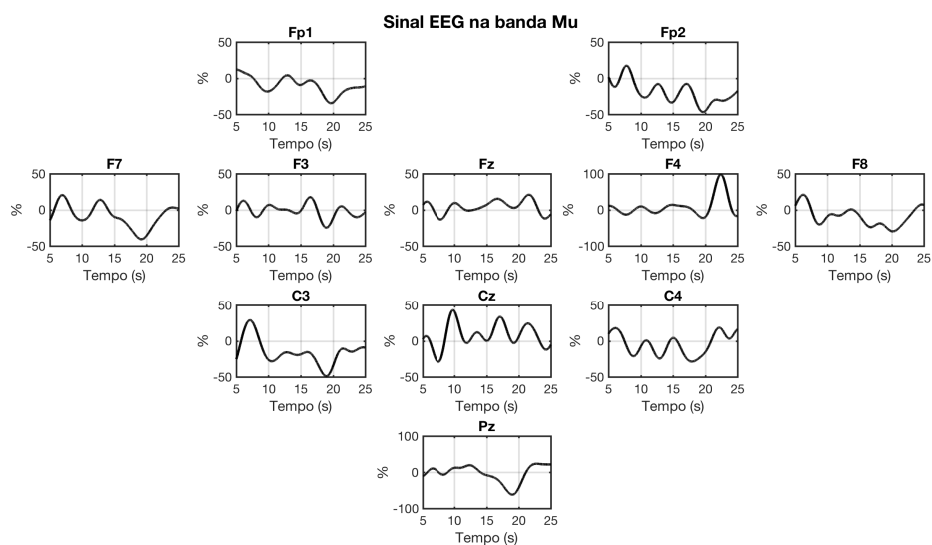


Figura 30 – Sinal EEG multi-repetições onde a Dessincronização Relacionada a Evento (ERD) não pode ser identificada.

das classes do classificador. O diagrama em blocos de um classificador Bayesiano está apresentado na Figura 31. Os canais $C4$, $C3$ e Cz foram selecionados em detrimento dos outros, pois estão diretamente relacionados às áreas motoras do córtex cerebral, e são os eletrodos nos quais melhor pode ser observada a Dessincronização Relacionada ao Evento (ERD) (PFURTSCHELLER; Lopes da Silva, 1999).

A seleção das frequências da banda μ foi realizada na etapa de treinamento, a

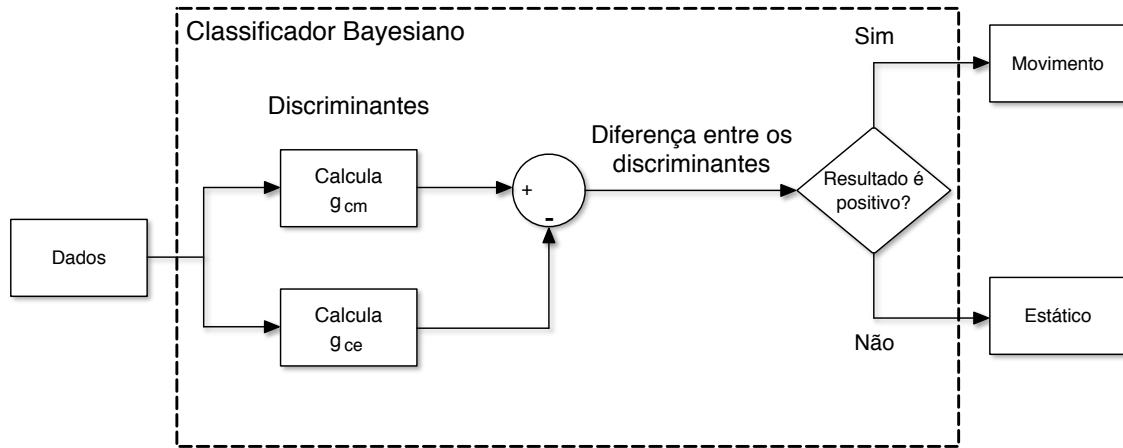


Figura 31 – Classificador Bayesiano.

partir da maior diferença entre os discriminantes referentes às classes: *movimento* (m) e *estática* (e). Esta diferença é calculada em função do resultado da diferença da média do PSD na banda μ entre um instante e outro, ou seja, para a classe *estática* e para a classe *movimento*, como descrita na Equação 3.8 (MITCHELL, 1997).

$$D(f_i) = \max(Avg_{j,f_k}(PSD(f_i)_e) - Avg_{j,f_k}(PSD(f_i)_m)), \quad (3.8)$$

onde $D(f_i)$ refere-se ao maior valor, representado pelo operador \max , da diferença dos valores da média dos valores PSD entre as j janelas (tomando-se os valores médios por frequências correspondentes f_k) das classes e e m , variando-se as frequências f_i do espectro dentro da banda μ . Para o cálculo da diferença entre os discriminantes foram utilizadas janelas de 100 amostras sobrepostas, com um deslocamento de 1 em 1 amostra entre as janelas.

As frequências no espectro que apresentam as maiores diferenças de seus valores de densidade espectral de potência foram obtidas na etapa de treinamento, e o valor do PSD dessas frequências foi utilizado na etapa de classificação.

Os sinais de EEG foram analisados no intervalo de 5 a 20 segundos durante cada repetição do experimento, uma vez que o tempo do movimento é dependente do voluntário. Os sinais, a partir das funções discriminantes do classificador, são classificados de acordo com a regra da máxima verossimilhança. A Figura 32 exemplifica, para uma repetição, a diferença entre os discriminantes das classes *movimento* e *estática*.

Uma das contribuições desta Tese foi observar que a característica de variância da diferença entre os discriminantes da classe *estática* e da *movimento* é mais estável e pro-

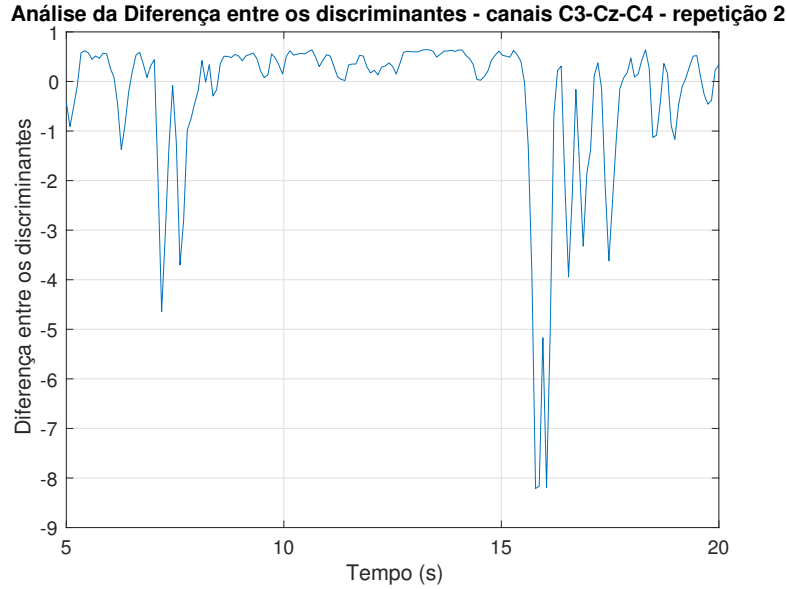


Figura 32 – Diferença entre os discriminantes das classes *movimento* e *estática* para os canais *C3*, *Cz* e *C4*.

porciona uma classificação mais precisa do que apenas a diferença entre os discriminantes. Isto ocorre pois a classificação é para a classe com maior discriminante (BOTELHO et al., 2017). A variância acentua as variações na diferença entre os discriminantes e atenua os momentos em repouso, tornando o sinal mais estável. Isto também torna o sistema mais adaptável ao inserir mais uma análise individual à característica do sinal. Para se obter a diferença entre os discriminantes, obteve-se o sinal antes da saída definitiva do classificador como apresentado na Figura 33. Esta operação está descrita na Equação 3.9, e um exemplo do sinal resultante pode ser visualizado na Figura 34.

$$VarDif(i) = var(g_{c_m}(\bar{x}_j) - g_{c_e}(\bar{x}_j)), \quad (3.9)$$

onde, $VarDif(i)$ refere-se à variância da diferença entre as funções discriminantes do classificador Bayesiano $g_{c_m}(\bar{x}_j)$ e $g_{c_e}(\bar{x}_j)$ em cada janela de dados j . O termo var refere-se à aplicação da variância no argumento entre parênteses, ou seja, da diferença entre os discriminantes. Naturalmente, a classificação envolve a análise da variância e do maior valor do discriminante da classe classificada. Para isso, utiliza-se um classificador de limiar, baseado nos valores de média e desvio padrão do sinal resultante obtido a partir da Equação 3.9, obtidos na linha-base, para determinar a pertinência das amostras entre as classes. O classificador de limiar utilizado nesta etapa é análogo aos utilizados nos sinais de EEG multi-repetições, sEMG e das IMUs (Equação 3.10). Para este sinal, o parâmetro p variou de 0,1 a 1, com incrementos de 0,1. O parâmetro N variou de 5 a 20 com um incremento de 1, e o período refratário variou de 2 a 20 amostras, com incremento de 1, classificadas corretamente em sequência para considerar verdadeiro-positivo. O início da

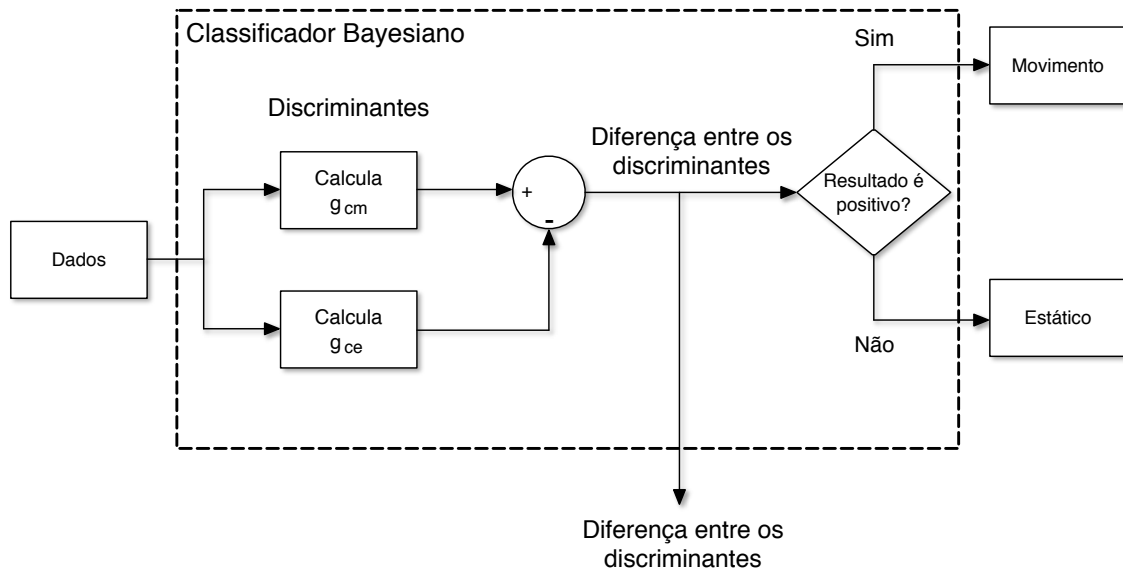


Figura 33 – Classificador Bayesiano com saída da diferença entre os discriminantes.

classificação do movimento se refere à primeira amostra das janelas que estão acima do limiar.

$$T_N = m_N - p \cdot d_N \quad (3.10)$$

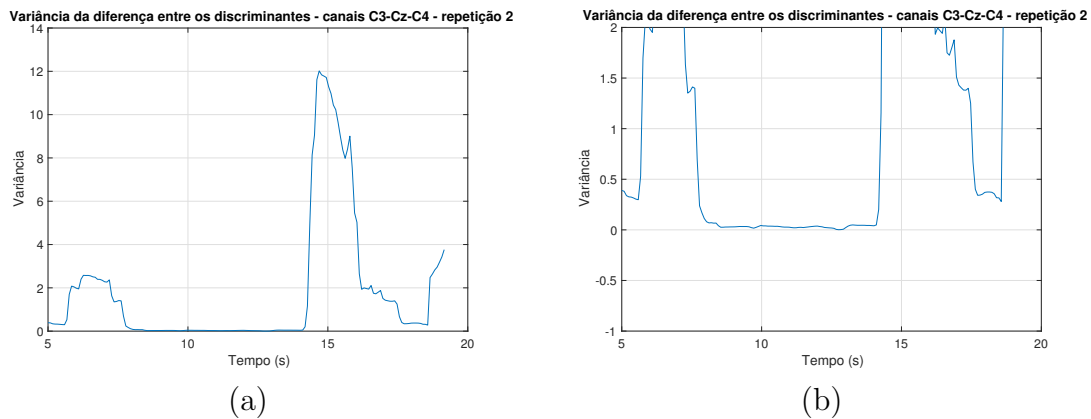


Figura 34 – (a) Variância da diferença entre os discriminantes das classes *movimento* e *estática* para os canais *C3*, *Cz* e *C4*; e, (b) o mesmo sinal, porém com uma ampliação em torno do eixo do Tempo para melhor visualização.

O sinal de EEG pode sofrer variações entre voluntários pelas diferenças na condutividade da pele e do cabelo devido à oleosidade, temperatura e biotipo do voluntário (LATIKKA et al., 2001). Por esta razão, realizou-se o treinamento do classificador com algumas repetições do mesmo voluntário ao invés de dividir os voluntários em um grupo para treinamento e outro grupo para classificação do sinal.

Destá maneira, para classificar os sinais de EEG, é necessário dividir as repetições de cada voluntário em 2 grupos: (1) grupo para o treinamento do classificador Bayesiano que está composto de 20 repetições; e (2) grupo para a classificação composto por 10 repetições. Na abordagem tradicional, o sistema ficaria como apresentado na Figura 35.

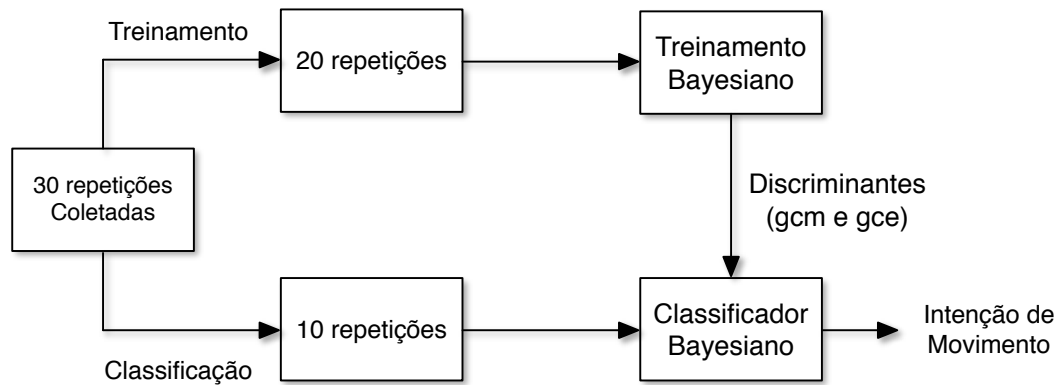


Figura 35 – Classificação do sinal de EEG na abordagem tradicional.

Porém, na nova abordagem, o último grupo (10 repetições para a classificação) é utilizado para treinamento do classificador limiar (9 repetições), e a repetição restante é classificada com base no procedimento de validação cruzada utilizando o método *Leave-one-out*, como ilustrado na Figura 36 (GALLEGO et al., 2012). Para isso, das 10 repetições escolhidas para a classificação, 1 será classificada, enquanto as outras 9 restantes serão utilizadas para treinar o classificador limiar que é utilizado para identificar a intenção de movimento a partir da variância da diferença entre os discriminantes do classificador Bayesiano, como indicado na Figura 37.

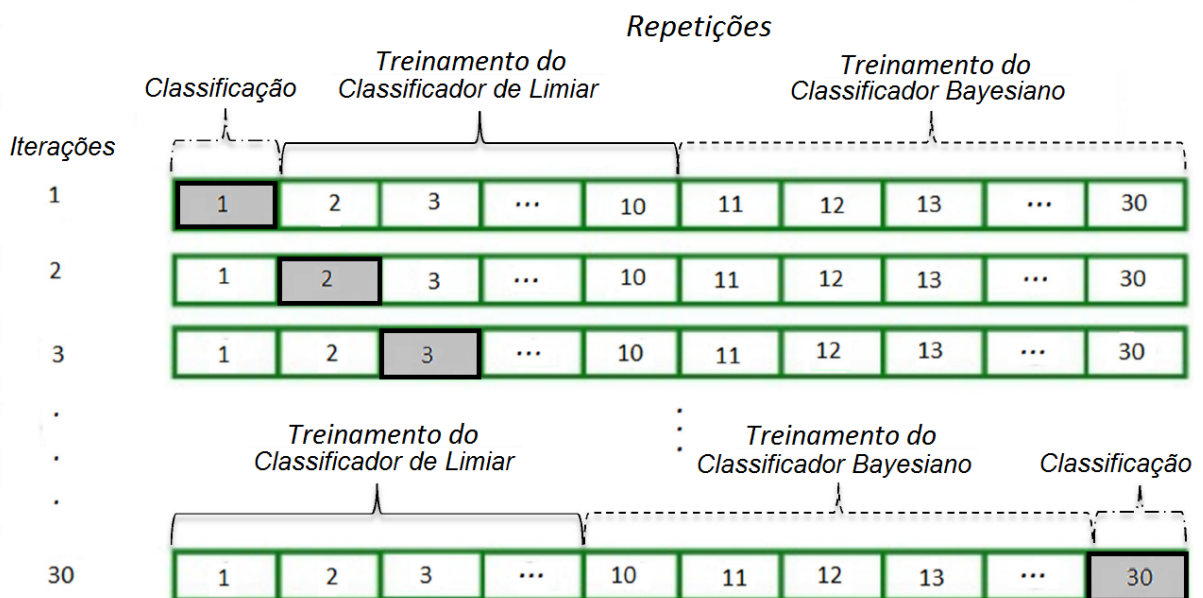


Figura 36 – Processo de validação cruzada utilizando o método *Leave-one-out* para treinamento e teste do classificador EEG.

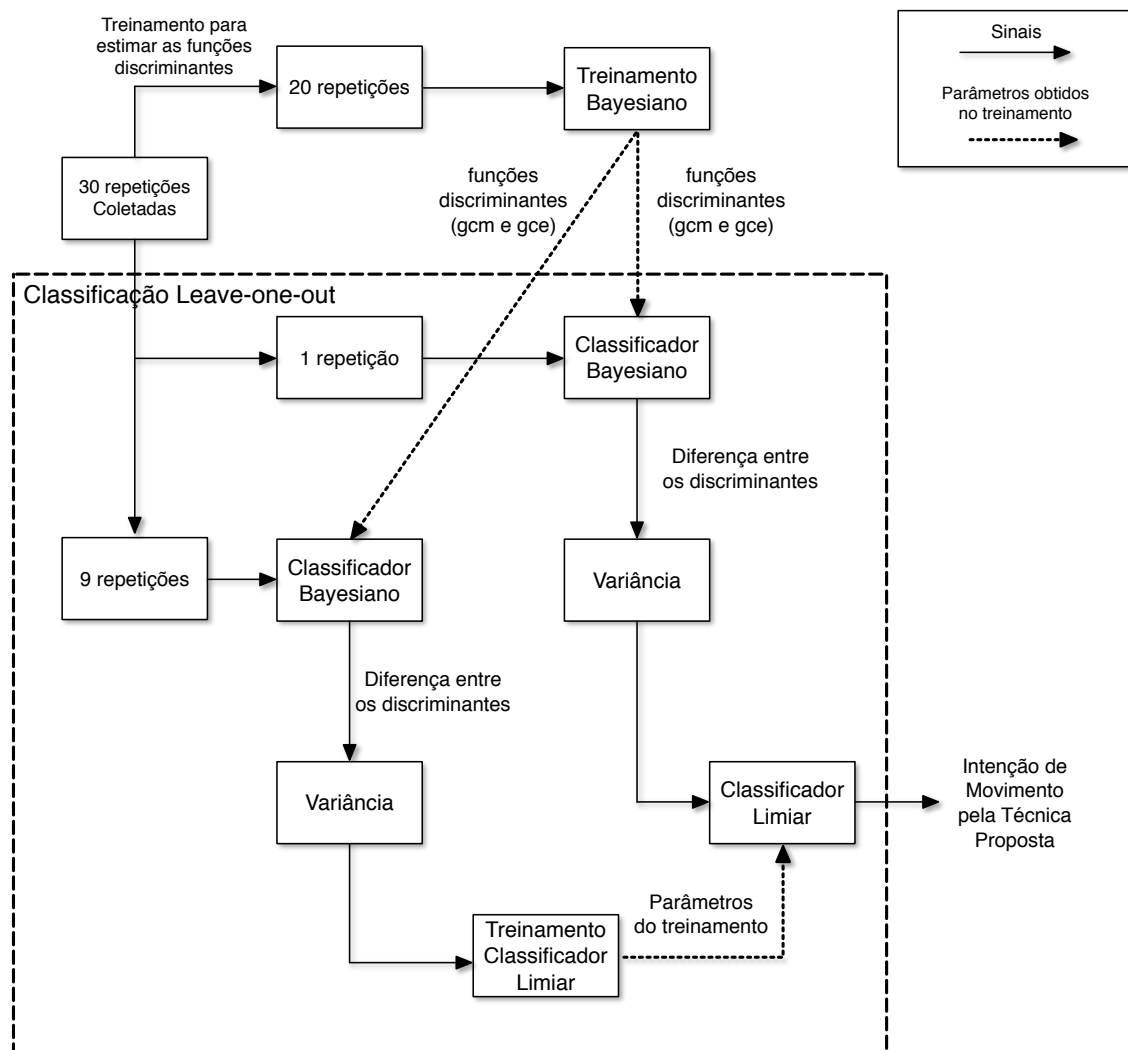


Figura 37 – Classificação do sinal de EEG proposta.

3.5 Precisão dos classificadores

Para os sinais de sEMG, a ativação muscular pode ser identificada no intervalo entre 0,5 s antes do movimento até o fim do movimento (KIRCHNER; TABIE; SEELAND, 2014).

Os sinais de EEG são considerados classificados corretamente entre 2 segundos antes do movimento até 1 segundo depois do movimento, pois a característica ERD que avalia a intenção de movimento normalmente se apresenta neste intervalo (PFURTSCHELLER; Lopes da Silva, 1999; IBÁÑEZ et al., 2013; KIRCHNER; TABIE; SEELAND, 2014). Uma vez que se deseja a predição do movimento, o intervalo que se considera corretamente classificado é aquele antes do movimento, entre 2 segundos antes e o movimento em si.

Através das detecções nesta janela de tempo, a precisão dos classificadores se definiu pela Equação (3.11), onde $P(\%)$ representa a porcentagem de precisão, R_{cc} representa a quantidade de repetições corretamente classificadas, e R_t é a quantidade total de repetições.

$$P(\%) = \frac{R_{cc}}{R_t} \times 100\% \quad (3.11)$$

3.6 Resultados da Análise Multimodal

Dos voluntários analisados qualitativamente, tal como proposto por Pfurtscheller e Lopes da Silva (1999), em 40% deles não foram identificados os padrões para análise da intenção de movimento através das características ERD/ERS durante a análise multi-repetições do experimento. Baseado no pequeno espaço amostral de indivíduos analisados (dez indivíduos), tomou-se como aceitável este percentual, uma vez que uma porção não negligenciável de indivíduos (20 a 25%) não pode utilizar sistemas clássicos de Interfaces Cérebro-Computador (BCI) baseadas em potenciais motores de EEG, tais como ritmos sensorio-motores (SMR) (VIDAURRE et al., 2011; PFURTSCHELLER; Lopes da Silva, 1999). Desta forma, os resultados aqui apresentados se resumem aos 60% dos voluntários, os quais apresentaram tais características (ERD/ERS desejáveis).

O intervalo de identificação dos sinais de EEG (2 segundos antes do movimento até 1 segundo depois do movimento) será chamado de “Janela Total do EEG”. O intervalo de antecipação do movimento, ou seja, o intervalo antes do movimento, entre 2 segundos antes do movimento até o início do movimento, será chamado de “Janela Anterior do EEG”, e o intervalo após o início do movimento será chamado de “Janela Posterior do EEG”.

Para o sinal de sEMG, a ativação muscular pode ser identificada no intervalo entre 0,5 s antes do movimento até o fim do movimento. Foi considerado um atraso

pequeno de 100 milissegundos como aceitável no sistema, uma vez que um valor de 100 a 300 milissegundos é o limite máximo (nível de frustração) que pode decorrer entre o início do movimento pelo usuário e a resposta do dispositivo. Um maior tempo de espera leva à frustração e confusão do usuário, que pode tentar um novo movimento ou corrigir o anterior, levando a manobras inesperadas e perda do controle do dispositivo (OSKOEI; HU, 2007; CELANI, 2010). Considerou-se então, como detecção correta da ativação muscular, os sinais detectados entre 0,5 s antes do movimento até 0,1 s depois do movimento. Este intervalo será chamado de “Janela Total do sEMG”. O intervalo de antecipação do movimento, ou seja, o intervalo entre 0,5 segundos e o movimento, será considerado “Janela Anterior do sEMG” e o intervalo entre o movimento e os 100 milissegundos aceitáveis (para evitar frustração no controle) será chamado de “Janela Posterior do sEMG”.

A precisão dos classificadores está apresentada nas Figuras 38 e 39 que mostram a precisão do sistema proposto para cada janela de tempo considerada para os sinais de EEG e sEMG. A janela de tempo é um intervalo onde a classificação é considerada como sucesso. As janelas de tempo apresentadas neste trabalho foram sugeridas por Ibáñez et al. (2013) e Kirchner, Tabie e Seeland (2014).




Figura 38 – Precisão para cada janela de tempo considerada para o sinal de EEG.

Nas Figuras 38 e 39, o voluntário 6 apresentou uma discrepância em relação aos demais voluntários na precisão de seus sinais de EEG e sEMG. Tal fato deve-se ao ruído




Figura 39 – Precisão para cada janela de tempo considerada para o sinal de sEMG.

externo não identificado no equipamento de aquisição. Como a análise foi realizada de forma *off-line*, tal interferência não pôde ser detectada no momento da captura. Mesmo este voluntário prejudicando a média geral de precisão, ele foi mantido nos resultados.

Na Figura 40 são mostradas marcações em que foram identificadas intenções de movimento baseadas na análise de EEG (triângulos) e de sEMG (pontos) para um voluntário. O tempo zero é relativo ao movimento efetivo do membro reconhecido através dos dados fornecidos pelos sensores inerciais. Nessa figura, as janelas de tempo em que se permitem predições baseadas em EEG e sEMG são de 2 s e 0,5 s antes do movimento, respectivamente, ou seja, “Janela Anterior do EEG” e “Janela Anterior do sEMG” como sugerido por Pfurtscheller e Lopes da Silva (1999) e Kirchner, Tabie e Seeland (2014). A partir da Figura 40, alguns dados relevantes podem ser obtidos, como a antecipação média das detecções de EEG em relação às detecções de sEMG, nas repetições onde os dois sinais foram detectados (Lógica E). Neste caso, a antecipação foi de aproximadamente 725 ms. O percentual de repetições detectadas corretamente utilizando uma lógica E, neste caso, foi de 53,33% enquanto que utilizando uma lógica OU, este percentual sobe para 86,67%. A lógica OU, permite que a detecção da intenção de movimento possa ocorrer nos sinais de EEG (maior antecipação) e, uma vez que esta detecção é mais difícil de ser observada nestes sinais, a mesma possa ser detectada através dos sinais de sEMG nos casos em que não tenha sido encontrada nos primeiros sinais (EEG), aumentando a precisão do sistema

como um todo.




Figura 40 – Distribuição de predições baseadas em EEG e sEMG.

Considerando estas janelas de tempo, a Figura 41 apresenta os resultados de classificação da antecipação de movimento no sinal do EEG (Janela Anterior do EEG) aplicando um classificador Bayesiano com a regra da máxima verossimilhança, em comparação com a abordagem aqui apresentada, onde a reclassificação é feita através de um classificador limiar baseado na variância da diferença entre os discriminantes do classificador Bayesiano. Percebe-se claramente uma melhora de 32,78% na média da precisão do classificador em todos os voluntários analisados. Desconsiderando o voluntário 6, esta melhora foi de aproximadamente 38,00%. Portanto, todos os resultados obtidos nesta pesquisa utilizaram a abordagem aqui proposta.

A precisão média total do EEG alcançada foi de $65,55 \pm 17,97\%$, como pode ser calculada através dos dados da Figura 38. Considerando uma média harmônica, a precisão foi de aproximadamente 60%. A média harmônica é definida como,

$$H = \frac{n}{\frac{1}{x_1} + \frac{1}{x_2} + \dots + \frac{1}{x_n}}, \quad (3.12)$$

onde H é a média harmônica e x_n são os n valores que se deseja calcular a média. Esta média, embora apresente o menor valor entre as outras médias, é menos sensível a valores discrepantes.

Considerando somente antecipação do movimento, ou seja, o intervalo antes do movimento (Janela Anterior do EEG), a precisão da antecipação do sinal de EEG foi de $42,78 \pm 19,71\%$, e considerando a média harmônica, a precisão foi de aproximadamente 33%. Desconsiderando o voluntário 6, tem-se uma precisão total média de aproximadamente




Figura 41 – Comparativo entre o classificador Bayesiano puro e a proposta de reclassificação da variância da diferença entre os discriminantes.

72%, e calculando através da média harmônica, 71%. Para antecipação de movimento somente, tem-se uma precisão média de aproximadamente 48%, e média harmônica de aproximadamente 42%.

Para o sinal de sEMG, a precisão média total foi de $62,22 \pm 32,29\%$, e, considerando uma média harmônica, aproximadamente 27%. Considerando apenas a antecipação do movimento (Janela Anterior do sEMG), sua precisão foi de $50 \pm 30,40\%$, e sua média harmônica de aproximadamente 24%. Estes dados estão calculados com base nos dados apresentados na Figura 39. Desconsiderando o voluntário 6, tem-se uma média total de aproximadamente 73%, com sua média harmônica de aproximadamente 69%. Considerando apenas a antecipação do movimento, a precisão média foi de aproximadamente 59%, e sua média harmônica, aproximadamente 51%.

Tabela 1 – Precisões dos sinais de EEG e sEMG desconsiderando o sujeito 6.

	EEG		sEMG	
	Janela Anterior	Janela Total	Janela Anterior	Janela Total
Intervalo	-2 s até 0 s	-2 s até 1 s	-0,5 s até 0 s	-0,5 s até 0,1 s
Precisão Média	48%	72%	59%	73%
Média Harmônica	42%	71%	51%	69%

Os valores encontrados estão sintetizados na Tabela 1. Na Figura 42 é mostrada a precisão do sistema proposto, levando-se em consideração a Janela Anterior dos sinais de EEG e sEMG, através de uma lógica OU entre estes sinais. Fica clara a relevância de combinar diferentes sinais para a detecção da intenção de movimento em um sistema multimodal, levando a uma precisão de detecção média de $65,56 \pm 27,70\%$. Desconsiderando o voluntário 6, uma precisão média de detecção de $74,67 \pm 18,35\%$. Percebe-se, em todos os casos, um aumento da precisão do sistema, para todos os voluntários em análise, em relação à precisão de um único sinal (EEG ou sEMG), para os mesmos voluntários (Figuras 38 e 39, respectivamente).




Figura 42 – Precisão da antecipação para lógica EEG OU sEMG em cada janela de tempo considerada.

A Figura 43 apresenta a média de tempo de antecipação por voluntário para os sinais de EEG e sEMG, bem como a média de tempo entre os voluntários, o que apresentou uma antecipação média de $677,90 \pm 513,26$ milissegundos para o sinal de EEG, e $122,93 \pm 97,48$ milissegundos para o sinal de sEMG.

As Figuras 44 e 45 apresentam os falsos-positivos e falsos-negativos para os sinais de EEG e sEMG, respectivamente, considerando as Janelas Anterior do EEG e sEMG (antecipação do movimento). Detecções antes das janelas de tempo propostas são consideradas falsos-positivos, enquanto detecções que ocorrem depois da janela de tempo são consideradas falsos-negativos. Os falsos-negativos sugerem que não ocorreu movimento nas janelas de tempo desejadas (antecipação do movimento), contudo, sempre ocorreu movimento em todas as repetições do experimento. Normalmente, o número de falsos-positivos e falsos negativos para os sinais de EEG é maior que para os sinais de sEMG. Isto é esperado após a análise das Figuras 38 e 39.




Figura 43 – Média e Desvio Padrão da antecipação do tempo.




Figura 44 – Taxa de Falsos-Positivos (FP) e Falsos-Negativos (FN) por voluntário para os sinais de EEG.




Figura 45 – Taxa de Falsos-Positivos (FP) e Falsos-Negativos (FN) por voluntário para os sinais de sEMG.

3.7 Discussão

Os resultados obtidos com essa nova abordagem na classificação dos sinais de EEG através de SMR mostram uma melhora significativa na precisão da classificação (38,00% no caso desta pesquisa) para membros inferiores.

Os voluntários participantes foram em sua maioria do gênero feminino. Este fator não deveria influenciar nos resultados, já que a literatura demonstra que não existem diferenças nos sinais de sEMG e padrões ERD/ERS em voluntários do gênero feminino e masculino (GOURAB; SCHMIT, 2010). O fato do grupo de voluntários analisados ser de jovens e rígidos pode influenciar nos resultados em termos de precisão. Outros estudos com indivíduos rígidos e com deficiência motora, que usaram SMR, demonstraram uma diferença na precisão do sistema (MÜLLER-PUTZ; DALY; KAISER, 2014). Nesta etapa da pesquisa, o fator idade não foi considerado, devido ao fato que o objetivo foi demonstrar o funcionamento da interface multimodal, bem como o ganho do classificador de EEG, a partir de uma variação do método tradicional de classificação.

Os resultados mostram que ambos os sinais de EEG e sEMG podem ser utilizados para prever movimento. Isso significa que em voluntários rígidos, ambos os sinais podem ser utilizados potencialmente para controlar dispositivos e auxiliar na terapia de pacientes que precisem de reabilitação.

Uma vez que as predições baseadas em EEG podem ser feitas muito antes das predições baseadas em sEMG, o sinal de EEG é mais adequado para fornecer ao usuário o controle de um dispositivo ou sistema sem o problema de latência. Por outro lado, foi mostrado que a análise EEG pode apresentar mais falsos-positivos que a análise sEMG, a qual apresenta resultados mais satisfatórios, porém, com um intervalo menor entre a detecção e a efetiva realização do movimento.

Há diferentes explicações para isso. Primeiro, a razão mais importante para as maiores taxas de falsos-positivos nas predições baseadas em EEG é que o planejamento do movimento (intenção de movimento) pode ser detectado, e o mesmo pode não resultar no movimento (DEECKE; SCHEID; KORNHUBER, 1969). Segundo, para alguns voluntários, as predições baseadas em EEG não funcionam tão bem (como as informações dadas para a análise do sinal EEG multi-repetições aplicada para um dos voluntários, como mostrado na Figura 30), agravando as taxas de erro. Conforme apresentado, neste estudo não foram avaliados os efeitos de cada voluntário em específico, uma vez que o estudo se focou numa avaliação geral do potencial, combinando diferentes métodos para que, no futuro, possa ser possível adaptar um dispositivo assistivo em relação ao estado da terapia que o paciente se encontra. Em alguns casos, devido a desordens neuromusculares, AVC ou até mesmo o estágio da terapia em que o voluntário se encontra, podem afetar ambos, ou apenas um dos sinais de EEG ou sEMG, impossibilitando uma predição de movimento com níveis

satisfatórios.

É possível verificar, através dos dados apresentados, que a análise do sinal de EEG provê uma maior antecipação, contudo uma menor precisão. Já o sinal de sEMG provê uma menor antecipação com uma maior precisão, justificando mais uma vez a eficiência de se trabalhar com uma abordagem multimodal com estes dois sinais para predição de movimento. Tais predições podem ser utilizadas no controle de dispositivos robóticos para auxiliar em processos de reabilitação, aumentando a confiabilidade do sistema em relação a apenas um único sinal.

Se o objetivo da terapia é o estágio inicial da reabilitação de pacientes, que provavelmente não produzem sinais de sEMG com alta amplitude, é mais relevante detectar a intenção de movimento com sinais de EEG. Já em estágios avançados de reabilitação, os sinais de sEMG já deve apresentar bons resultados, portanto, são mais precisos de detectar o movimento. Desta forma, a combinação de sinais em uma lógica OU pode ser a melhor escolha comparada com um único sinal, como também observado por [Pfurtscheller e Lopes da Silva \(1999\)](#), [Ibáñez et al. \(2013\)](#) e [Kirchner, Tabie e Seeland \(2014\)](#).

Dependendo do tipo de desordem neuromuscular e estado da terapia, a predição baseada em ambos sinais, EEG ou sEMG, pode não resultar em um bom desempenho. Por exemplo, para pacientes que sofrem espasmos, sEMG pode não ser uma fonte confiável para predição de movimento ([PFURTSCHELLER; Lopes da Silva, 1999](#); [IBÁÑEZ et al., 2013](#); [KIRCHNER; TABIE; SEELAND, 2014](#)).

Nesta pesquisa também foi proposto um protocolo experimental para colocação dos sensores inerciais e coleta dos dados, o qual foi aplicado em voluntários rígidos para adquirir os dados através da plataforma desenvolvida, não exigindo total alinhamento físico dos sensores, uma vez que o alinhamento é feito de forma virtual ([BOTELHO et al., 2015b](#)).

Da perspectiva dos resultados obtidos, é possível preparar uma ação de controle em dispositivos de reabilitação para um movimento assistido, por exemplo, com o intervalo de predição de movimento alcançado. O protocolo não levou em consideração o nível de fadiga muscular durante a tarefa, uma vez que foram executadas 30 repetições espaçadas entre si, e tampouco realizou-se uma análise de concentração do voluntário na tarefa. Considera-se a portabilidade do protocolo como aceitável, uma vez que depende apenas de dois sensores inerciais, os quais não precisam de muita precisão no momento de colocação, pois o alinhamento dos mesmos ocorre de forma virtual, além do uso de apenas um eletrodo bipolar de sEMG no músculo reto femoral, e um gorro de EEG no padrão internacional 10-20.

Os resultados mostraram que uma plataforma multimodal, utilizando diferentes

dados fisiológicos, como EEG e sEMG, pode ser utilizada no controle de dispositivos assistivos. Este fato corrobora os resultados obtidos em outros estudos, nos quais a combinação de diferentes sinais pode aumentar o desempenho de detecção das intenções dos voluntários, ou seja, neste caso, a predição do movimento (CORBETT; PERREAULT; KÖRDING, 2012; NOVAK et al., 2013).

Portanto, a plataforma multimodal desenvolvida pode ser utilizada no estudo e desenvolvimento de outras interfaces multimodais, e pode ser integrada ao exoesqueleto em desenvolvimento, adaptando seu controle em relação à intenção de movimento do paciente.

À primeira vista, os resultados obtidos podem ser considerados pouco satisfatórios, comparados com outros trabalhos de SMR em membros superiores. Kirchner, Tabie e Seeland (2014) alcançaram uma precisão de aproximadamente 85% com sinais de EEG para a predição de movimento em membros superiores, enquanto que Gallego et al. (2012) alcançaram uma precisão do classificador de EEG de aproximadamente 90% trabalhando também com membros superiores. Contudo, é importante destacar que estes resultados foram obtidos com membros superiores. Por outro lado, trabalhando com membros inferiores a detecção motora através de sinais de EEG é muito mais complexa, devido ao fato da aquisição da ativação do sinal de EEG para membros inferiores ser mais difícil que para membros superiores, em função da localização das regiões das fontes de sinal no cérebro (GUYTON; HALL, 2006; PENFIELD; THEODORE, 1968).

BCIs motoras aplicadas ao estudo da intenção de movimento de membros inferiores utilizando SMR são pouco estudadas, devido a sua baixa eficiência em termos de precisão. Por esta razão, novas técnicas como MRCP estão sendo sugeridas para melhorar a precisão da classificação, os quais estão começando a serem consideradas em estudos focados em membros inferiores.

Jiang et al. (2015) apresentaram bons resultados em termos de precisão trabalhando com membros inferiores utilizando MRCP no lugar de SMR. O uso da técnica de detecção de MRCP proporciona uma melhor precisão de detecção de movimento nos sinais de EEG e, diferentemente do ERD/ERS do SMR, este tipo de potencial se pode detectar sempre. Este fato faz com que esta técnica seja muito promissora para detectar o movimento através de MRCP, apesar de ter uma predição de movimento com menos antecipação que utilizando SMR, detectando a intenção de movimento através dos sinais de EEG usualmente alguns milissegundos depois do início do movimento (NIAZI et al., 2011; XU et al., 2014a; GUGER; VAUGHAN; ALLISON, 2014).

Comparados com os resultados desta Tese (precisão média de $42,78 \pm 19,71\%$, considerando apenas a Janela Anterior do EEG, e antecipação média de $677,91 \pm 127,45$ ms, e, no caso de desconsiderar o voluntário 6, precisão média de $48,00 \pm 24,68\%$ e antecipação

média de $654,48 \pm 127.24$ ms), [Jiang et al. \(2015\)](#) alcançaram uma precisão média de 76.9 ± 8.97 e um tempo médio de antecipação de 156 ± 369 ms trabalhando com 9 voluntários. E neste caso, é importante mencionar, que para alguns voluntários, a detecção se obteve centenas de milissegundos depois do movimento.

Apesar dos padrões ERD do SMR poderem ocorrer até 2 segundos antes do movimento ou durante todo o movimento, o classificador desta pesquisa só considerou corretos os sinais detectados antes do início do movimento. Tal medida diminui a taxa de precisão do classificador em relação aos outros trabalhos aqui apresentados, cujo objetivo era detectar o movimento em sinais cerebrais, sem importar se ocorreu antes ou depois do movimento.

Sendo assim, a proposta desta Tese, que usa SMR para membros inferiores, se limita à comparação com outros trabalhos da literatura, que em sua maioria usam SMR em membros superiores ou usam MRCP em membros inferiores. Cabe ressaltar novamente, que uma das limitações do uso de SMR é que normalmente há um grupo de indivíduos (de 20 a 25%) que não apresenta as características descritas por [Pfurtscheller e Lopes da Silva \(1999\)](#).

Ainda assim, foi apresentada uma nova abordagem na classificação de sinais SMR para obter um aumento da precisão, possibilitando a aplicação em membros inferiores (aproveitando a boa capacidade de antecipação proporcionada pela análise SMR), sendo importante considerar as comparações entre SMR e MRCP em uma BCI, a partir das limitações de cada uma destas técnicas.

Quando se necessita uma melhor taxa de antecipação, em detrimento de uma perda de precisão na detecção do movimento, o uso do sinal de SMR pode ser uma boa alternativa, sobretudo com a abordagem proposta neste trabalho, que apresentou uma eficácia média de 30% em comparação com o método de classificação tradicional. Ainda assim, tal perda de precisão pode ser compensada com a análise multimodal em conjunto com o sinal de sEMG como a aqui apresentada, aumentando a precisão do sistema em mais de 20% em relação ao sinal de EEG sendo analisado individualmente.

A taxa de antecipação alcançada pode permitir uma sequência maior de comandos de controle em um intervalo de tempo para o movimento mais natural e ágil do usuário. Permitiria também o uso de sistemas de controle mais complexos, nos quais o sistema pode trabalhar com um maior tempo de decisão entre os comandos. Esta antecipação pode oferecer a possibilidade do uso de sistemas de controle em sistemas embarcados com baixo poder de processamento, nos quais, a partir da intenção de movimento detectada pela interface multimodal, o sistema poderia executar a ordem para o movimento de um dispositivo num tempo maior, e ainda assim, antes do movimento em si.

3.8 Considerações

Os resultados mostram que é viável trabalhar com sinais SMR de EEG para predição da intenção de movimento, inclusive trabalhando com membros inferiores.

Sendo assim, a análise SMR em uma interface multimodal com sEMG pode ser uma alternativa para a predição de movimento, inclusive em comparação com o uso de MRCP (JIANG et al., 2015), na qual é necessário um maior tempo de antecipação. Estes resultados podem ser utilizados no controle de um dispositivo robótico para tarefas de reabilitação, com um adequado nível de detecção sem sobrecarregar o sistema de controle.

Foi proposto também um protocolo experimental, aplicado em voluntários rígidos para adquirir os dados com a interface desenvolvida. No Capítulo 5 será apresentada a integração deste sistema com um dispositivo robótico para reabilitação, baseado na predição do movimento aqui apresentada. No protocolo não foi considerada a concentração do voluntário ao realizar as tarefas. A portabilidade do protocolo é considerada aceitável, porque o gorro de EEG é do padrão internacional 10-20 e a detecção do movimento depende somente de sensores inerciais, que não apresentam limitações para a colocação devido ao fato de seu alinhamento se realizar de maneira virtual. A detecção do movimento também pode ser detectada por outros meios, como através de sensor de força, como será apresentado nos Capítulos 4 e 5.

O método de classificação de sinais de EEG apresentado nesta pesquisa, executando uma classificação baseada na frequência e outra no tempo, através de um classificador Bayesiano e posteriormente um classificador limiar baseado na variância da diferença de seus discriminantes, conseguiu um aumento de precisão média de aproximadamente 30% em relação ao método tradicional de análise, sendo que para alguns voluntários chegou a um ganho de 50% na precisão, podendo ser implementado em outros sistemas que envolvam este tipo de sinal.

Ressalta-se que os resultados apresentados neste capítulo foram alcançados utilizando um processamento *off-line*. Uma detecção *on-line* da intenção de movimento será apresentada no Capítulo 5.

4 Desenvolvimento do Exoesqueleto ALLOR e das Estratégias de Controle

4.1 Introdução

Neste capítulo é apresentada a construção do exoesqueleto robótico de membro inferior, o sistema de controle desenvolvido e os resultados obtidos a partir do uso do controlador.

A proposta do exoesqueleto desenvolvido pela UFES é que tivesse uma articulação ativa no joelho e pudesse ser utilizado tanto em tarefas de marcha quanto de reabilitação estacionária.

Os pré-requisitos básicos foram que tivesse sensor de força de forma a medir a interação com o usuário, e sensor de posição a fim de identificar o ângulo da perna em relação à coxa, na articulação do joelho. Outra necessidade é que tivesse um sistema de controle no qual fosse possível integrar a interface multimodal desenvolvida.

Para o caso de reabilitação do joelho, os procedimentos manuais para o fortalecimento muscular exigem esforços para a execução de movimentos repetitivos (MITHOEFER et al., 2012). Desta forma, foi proposto que o sistema de controle pudesse ser validado em pacientes que realizaram artroplastia de joelho, ou seja, a substituição do joelho por uma prótese mecânica. Tais pacientes necessitam que seja realizada a mobilização da articulação logo após a cirurgia, evitando a fibrose da prótese e, conseqüentemente, a remoção da mesma e a repetição do processo cirúrgico (MAXEY; MAGNUSSON, 2001). Tal estudo de caso foi escolhido também pelo fato dos pacientes não necessitarem de limitações da amplitude do movimento logo após a intervenção cirúrgica. Adicionalmente, podem utilizar as estratégias de controle a partir de treinos passivos e ativos, não necessitando da intenção de movimento provida pelo sistema multimodal desenvolvido. Desta forma é, possível validar o sistema de controle independentemente da interface multimodal. Por se tratar de um projeto piloto, a validação foi realizada com voluntários rígidos, porém com o protocolo já adequado para testes com pacientes.

4.2 O Exoesqueleto ALLOR

O exoesqueleto ALLOR de membro inferior (perna esquerda) desenvolvido na UFES possui três articulações (graus de liberdade) em sua estrutura física: uma ativa no joelho, uma passiva no quadril (a qual é responsável por interligar a coxa com a estrutura

de apoio no quadril do usuário), e uma passiva no tornozelo (responsável pela sustentação do pé do usuário) (Figura 46).

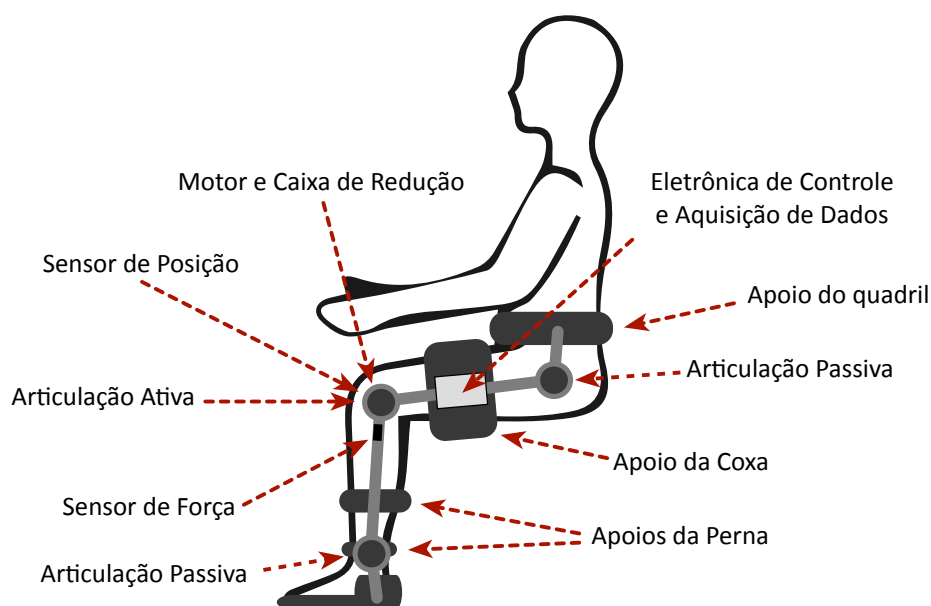


Figura 46 – Diagrama do exoesqueleto projetado na UFES.

Para sua concepção, foi adquirida uma articulação ativa EXO-H1[®] (Technaid, Espanha) utilizada para desenvolvimento de trabalhos de investigação em diversos grupos de pesquisa (BAYON et al., 2016; FIGUEIREDO; MORENO; SANTOS, 2017) (Figura 47), a qual utiliza sensores de força capazes de medir o torque nos movimentos de extensão e flexão do joelho, formados por uma ponte com 4 *strain gages* modelo 632-180 de 120 Ω (RS Pro) fixados em extremidades opostas na articulação da perna, no plano sagital. A articulação também possui um potenciômetro de precisão, Modelo 157 de 10 $k\Omega$ (Vishay), capaz de determinar o grau de flexão entre as duas extremidades da perna do usuário, variando de 0° a 90°. O motor do sistema, modelo EC 60 flat Brushless 408057 (Maxon), possui um *harmonic drive* CSD-20-160-2A-GR (Harmonic Drive LCC), como caixa de redução, proporcionando um compromisso entre o espaço, torque e redução oferecidos. O sistema possui um *driver* de corrente, AZBH12A8 (Advanced Motion Controls), o qual é utilizado para acionamento do motor, podendo ser operado no modo tensão, fornecendo um sinal analógico de $\pm 10 V$, e no modo controle interno de velocidade, uma vez que o próprio *driver* possui um controlador PID de velocidade interno que fornece a velocidade para o motor através do sinal analógico de $\pm 10 V$. O conjunto de sensores e motor descritos podem ser observados na Figura 47.

Todo o sistema está interligado através de um barramento CAN (*Controller Area Network*), o qual fornece informações dos sensores em um computador industrial (PC-104) executando *SIMULINK real-time*.

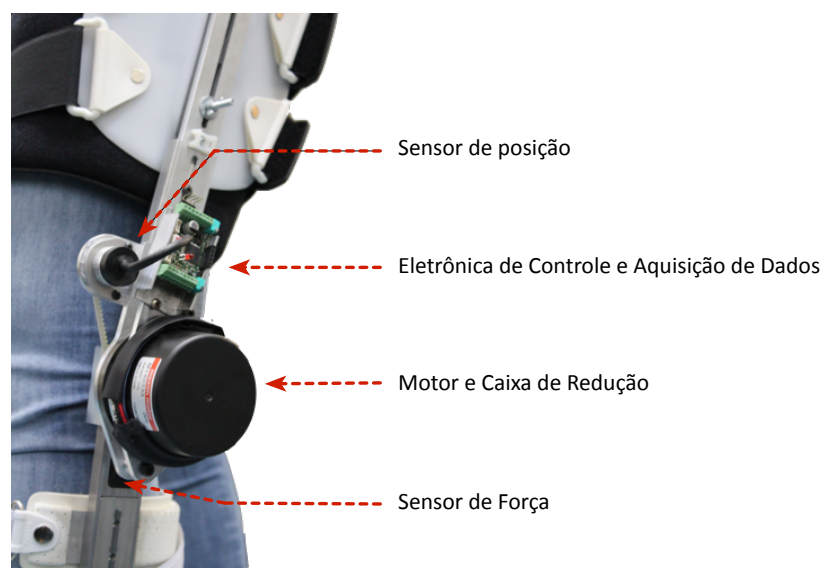


Figura 47 – Articulação ativa EXO-H1[®] (Technaid, Espanha), com destaque para a articulação do joelho e sensores.

Para formar todo o conjunto do exoesqueleto, foram adquiridas 2 órteses passivas acopladas ao sistema, uma órtese passiva de quadril (Figura 48a) e uma órtese passiva de tornozelo (Figura 48b). Desta forma, o exoesqueleto possui sustentação necessária para tarefas de marcha ou reabilitação estacionária.



Figura 48 – (a) Órtese passiva de quadril. (b) Órtese passiva de tornozelo.

Ainda para tarefas de reabilitação estacionárias, foi desenvolvida uma estrutura de apoio em uma cadeira, de forma que a mesma pudesse suportar o exoesqueleto e fosse de fácil ajuste para diversos biotipos de sujeito, e, também, de fácil remoção. A cadeira possui apoio nos pés, necessários para aumentar sua altura, permitindo que usuários com pernas maiores possam utilizar o sistema, além de dar maior sustentação e firmeza à

montagem. Sua estrutura de sustentação permite o ajuste vertical, de altura, e horizontal, para ajustar o joelho do usuário à articulação do exoesqueleto. Uma foto do sistema como um todo é apresentada na Figura 49.

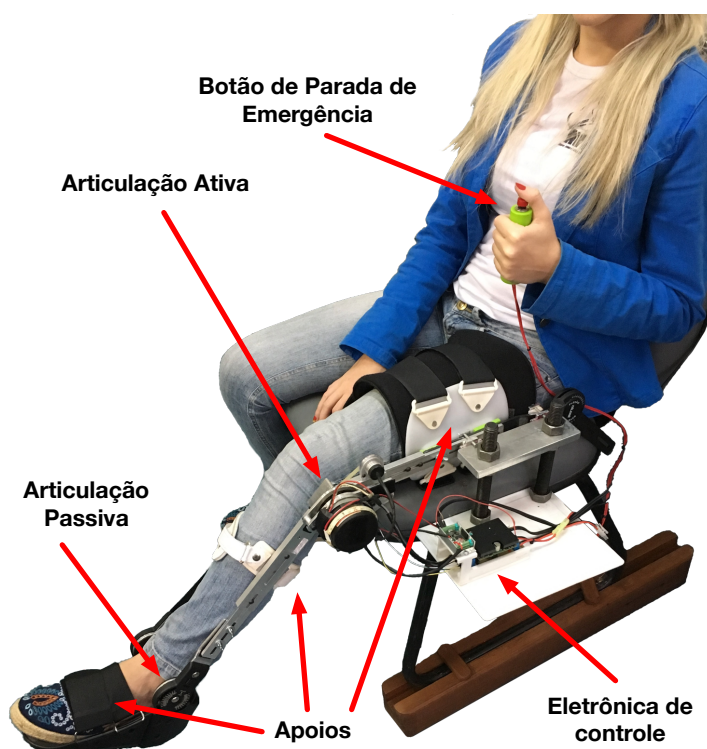


Figura 49 – Exoesqueleto ALLOR desenvolvido para reabilitação de membro inferior.

O exoesqueleto foi adaptado pelos pesquisadores do NTA para melhorar o acoplamento entre a anatomia dos usuários e a estrutura mecânica do sistema robótico. Na Figura 50a é possível perceber a perna esquerda do usuário conectada ao exoesqueleto, com um leve desalinhamento. Na Figura 50b, o mesmo usuário está conectado ao exoesqueleto, agora com adaptadores. É possível perceber que o desalinhamento existente no acoplamento foi atenuado pelos adaptadores desenvolvidos. Os adaptadores foram elaborados de forma modular, a fim de proporcionar ajustes adequados para diversos biotipos.

O dispositivo possui limitação mecânica em 0° e 90° , restringindo os movimentos de extensão e flexão da perna, como medida de segurança e um botão de parada de emergência, que interrompe a corrente do motor imediatamente (Figura 49). A utilização de um *harmonic drive* como caixa de redução proporciona uma segurança ao sistema, pois em caso de um corte na corrente elétrica do motor, é possível manusear a posição da articulação facilmente, colocando-o em uma posição desejada.

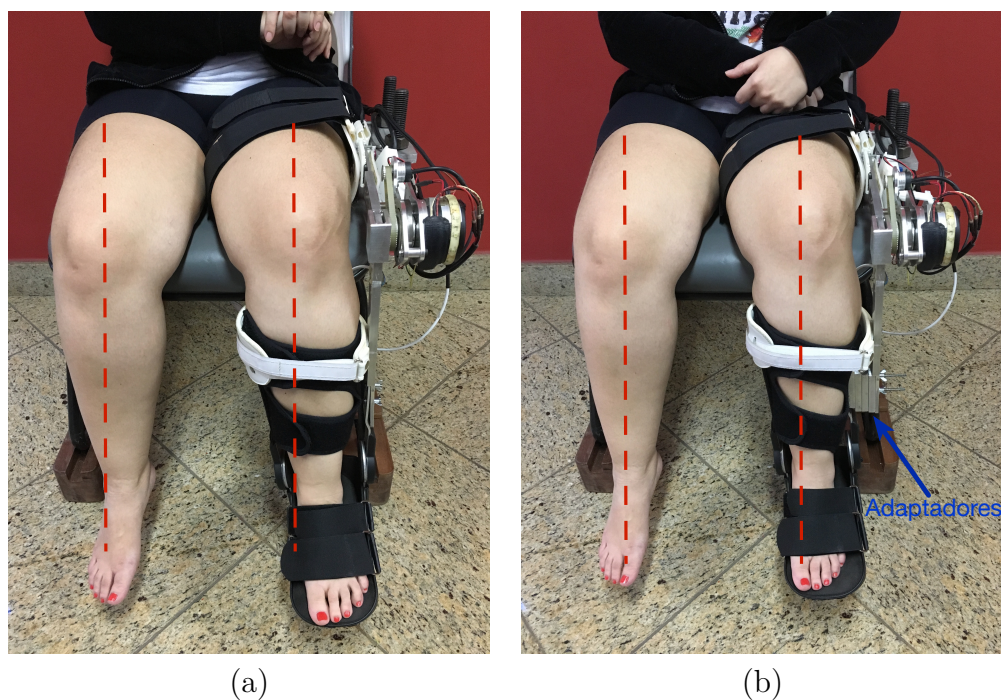


Figura 50 – (a) Alinhamento da perna sem adaptadores. (b) Alinhamento da perna com adaptadores.

4.3 Estratégias de controle

As estratégias de controle do exoesqueleto robótico foram implementadas em um computador industrial (PC-104) executando *SIMULINK real-time*, software que garante a execução e controle do sistema em tempo real, o qual está interligado através de um barramento CAN (*Controller Area Network*) ao exoesqueleto, onde é possível receber as informações provenientes dos sensores.

O PC-104 é um computador embarcado com arquitetura x86, possibilitando a execução de programas compatíveis com IBM-PC, possuindo as diversas interfaces de computadores convencionais.

É importante deixar claro que todo o processo foi acompanhado e aconselhado por um fisioterapeuta.

Para treinos passivos, foi realizado o controle de velocidade já implementado no *driver* do motor, simplificando o sistema. Tal laço de controle pode ser observado na Figura 51. Neste caso é necessário selecionar um perfil de velocidade em relação ao ângulo do joelho no planejamento de caminho do sistema $\dot{q}_a(q)$. Tal controle não considera o torque τ exercido na perna do usuário, porém este torque é considerado na rotina de proteção da terapia de reabilitação, parando o sistema de atuação caso situações de torque excessivo entre usuário e robô sejam detectadas.

Uma compensação gravitacional dada pela Equação 4.1 é utilizada no sistema para




Figura 51 – Controlador de velocidade.

a medição do torque do usuário (τ_u), desconsiderando o torque exercido pela gravidade (τ_g) (Figura 52), independentemente da posição da perna do paciente. Tal compensação está apresentada em Botelho et al. (2015a) e se baseia em anular a componente P_y' da força gravitacional exercida no conjunto formado pelo exoesqueleto e perna do usuário representada por P na Figura 53. Esta força é responsável pelo torque no ponto o (articulação do joelho), e que pode ser descrita conforme a Equação 4.1, a qual deve ser anulada para que o sistema se comporte como um sistema sem gravidade. Desta forma, a única componente na saída do sistema é a componente de torque voluntário, quer seja exercido pelo usuário, quer seja pelo exoesqueleto atuando na perna do usuário. Uma vez eliminado o torque causado por forças gravitacionais (τ_g), todo o torque resultante do sistema (τ_u) é levado em conta na verificação do valor de torque de segurança, responsável por parar o sistema caso o torque ultrapasse o limite estabelecido pelo fisioterapeuta.

$$P_y' = mg \cos q \quad (4.1)$$

A compensação gravitacional depende do peso do usuário, com a qual é possível estimar o peso de sua perna baseado em proporções antropométricas (HUSTON, 2008). É utilizado um fator de correção para este peso, que não passa de um ganho próximo do unitário, o qual depende do ângulo horizontal da haste, para o caso de parte da coxa estar inclinada. Por padrão este valor é 0° .




Figura 52 – Compensação de gravidade.




Figura 53 – Diagrama de força no modelo de espaço cartesiano.

Também foi implementado um sistema de contagem de repetições e um sistema de contagem de tempo da tarefa, onde o fisioterapeuta pode basear o treino em tempo, ou número de repetições. Para treinos ativos, foi implementado um controlador de admitância baseado em posição, de ordem 2, trabalhando com parâmetros de inércia, amortecimento e elasticidade Botelho et al. (2015a). Um controlador de impedância, para este caso pode ser definido de acordo com a Equação 4.2 (SPONG; VIDYASAGAR, 2004),

$$f(s) = (Ms^2 + Ds + K) \cdot q(s), \quad (4.2)$$

onde, a partir da posição $q(s)$ se estima a força $f(s)$, baseada nos parâmetros de Inércia (M), Amortecimento (D) e Elasticidade (K).

Utilizando o mesmo raciocínio, é possível estimar a posição da articulação do exoesqueleto através da força utilizando um controle de admitância (Equação 4.3) (SPONG; VIDYASAGAR, 2004),

$$q(s) = f(s) \cdot (Ms^2 + Ds + K)^{-1} \quad (4.3)$$

Verificou-se que, ao se trabalhar com um controlador de admitância baseado em velocidade, o sistema simplificava-se para apenas 2 parâmetros para que fosse possível ajustar sua impedância. Desta forma, utilizou-se um controlador de admitância baseado em velocidade com uma função de primeira ordem, apresentando apenas os parâmetros de Inércia (M) e Amortecimento (D) (SPONG; VIDYASAGAR, 2004) conforme a Figura 54. Tal controlador, além de mais simples, evita possíveis erros iniciais de posição, que ocorrem em controladores convencionais de posição, melhorando a estabilidade do sistema.

O parâmetro M variou de 0,5 a 5, enquanto o parâmetro D variou de 2,5 a 25, ajustando então a viscosidade da articulação, desde mais maleável, com parâmetros menores, até mais rígida, com parâmetros maiores, conforme solicitado pelos fisioterapeutas.

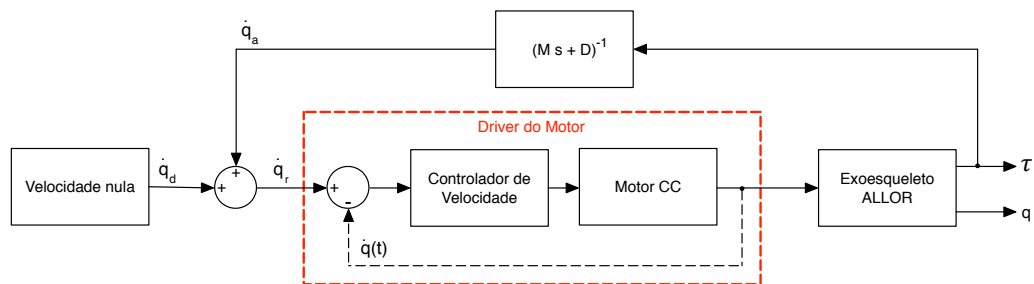


Figura 54 – Controlador de admitância proposto.

Em treinos ativos, o compensador de gravidade também pode ser habilitado quando for desejável que o peso da perna do usuário influencie no sistema.

Um gerador de cargas virtuais (esforço) também foi implementado no sistema, conforme mostra a Figura 55, para que fosse possível a inserção de cargas virtuais nas tarefas de reabilitação sem a necessidade de se utilizar pesos físicos, fazendo com que o usuário “sentisse” o efeito real de carga no exoesqueleto. Tal gerador, assim como o compensador gravitacional, depende do ângulo horizontal de referência da coxa para gerar o torque necessário (τ_c) em função da carga utilizada.

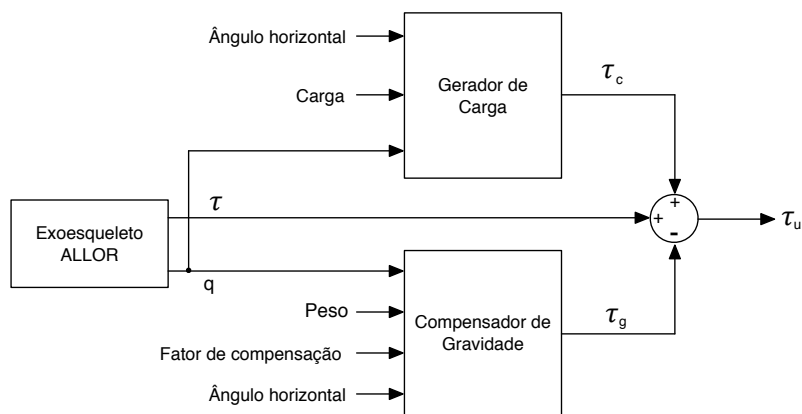


Figura 55 – Gerador de cargas.

O torque entre o usuário e o robô pode ser calculado a partir da Equação 4.4,

$$\tau_u = \tau - \tau_g + \tau_c, \quad (4.4)$$

onde, τ representa o torque medido pelo *strain gage* do exoesqueleto, τ_g representa o torque gravitacional, ou seja, o torque gerado pelo peso da perna, τ_c é o torque gerado caso seja necessário a inserção de um peso no processo de reabilitação do paciente e, τ_u , o torque resultante entre o usuário e o robô.

4.4 Protocolo Experimental

O teste piloto do sistema de controle foi realizado com 5 voluntários (4 do gênero feminino e 1 do gênero masculino), com idades entre 20 e 29 anos, com o intuito de validar o sistema. É importante ressaltar que este estudo tem aprovação do Comitê de Ética em Pesquisa com seres humanos da UNESA, CAAE número 51685515.3.0000.5284, número do parecer 1.863.539.

Para tal, foi escolhido como simulação de tratamento a reabilitação de pacientes que sofreram cirurgia de artroplastia, a qual é dividida em 4 fases como proposto por Maxey e Magnusson (2001).

Na primeira fase, chamada de treino passivo, o paciente tem dificuldade de executar os movimentos de extensão e flexão do joelho por conta própria, uma vez que as estruturas de seu joelho (ossos e músculos) acabaram de ser fixadas na prótese. Estes movimentos devem ser realizados por um fisioterapeuta logo após a cirurgia, evitando a fibrose da prótese e, conseqüentemente, a remoção da mesma, através de processo cirúrgico. Nesta fase, é requerida velocidade constante durante a terapia. Utilizou-se, portanto, o controlador interno de velocidade do *driver* do motor, com um perfil de velocidade constante para os movimentos de extensão e flexão do joelho. O compensador gravitacional também permaneceu ativado, de forma a medir o torque exercido pela perna do usuário no eixo do motor, executando a parada do sistema, caso este torque se afastasse do valor nulo. A partir da experiência do terapeuta e do uso do sistema, verificou-se que o valor de proteção para o torque podia ser $|0, 3| N.m$.

Na segunda fase, chamada de treino ativo assistido, o paciente deve começar a realizar os movimentos de extensão e flexão do joelho por conta própria, porém as estruturas do joelho não estão totalmente recuperadas e tais movimentos devem ser realizados com o auxílio de um fisioterapeuta. Nesta fase, utilizou-se o controlador de admitância, e o peso da perna foi anulado (compensação gravitacional ativa) através da substituição por um peso menor (carga), inserido através do gerador de cargas, de acordo com as necessidades do fisioterapeuta.

Na terceira fase, chamada de treino ativo, o paciente deve realizar os movimentos de extensão e flexão do joelho por conta própria, sem o auxílio de um fisioterapeuta. Nesta fase foi utilizado o controlador de admitância, com parâmetros ajustados para uma articulação solta do joelho ($M = 0,5$ e $D = 2,5$) e com compensação gravitacional desativada, para que o usuário tivesse que suportar o peso da própria perna nos movimentos de extensão e flexão do joelho.

Na quarta e última fase da reabilitação, chamada de treino ativo resistivo, o paciente deve realizar os movimentos de extensão e flexão do joelho em aparelhos de fortalecimento muscular, com cargas variáveis resistindo aos movimentos. Nesta etapa,

estavam ativos o controlador de admitância e o gerador de cargas. A rigidez da articulação nesta etapa é escolhida pelo fisioterapeuta de acordo com a recuperação do paciente.

Para fins do experimento, com o auxílio de fisioterapeutas, as fases de treino foram agrupadas em conjuntos de 5 sessões, onde os ângulos máximo e mínimo de flexão e extensão, a velocidade do movimento, a quantidade de carga e o número de repetições variaram conforme a Tabela 2. É importante acrescentar que, conforme os dados apresentados no Capítulo 3, a referência de ângulo é entre a coxa e a perna, ou seja, em uma perna completamente estendida, o ângulo é de aproximadamente 0° . Os treinos foram elaborados respeitando os limites de ângulo máximo e mínimo de um paciente pós artroplastia (MAXEY; MAGNUSSON, 2001).

Tabela 2 – Parâmetros para os treinos nas diversas fases do experimento de treino para artroplastia.

Treino	Sessão	Ângulo mínimo ($^\circ$)	Ângulo máximo ($^\circ$)	Carga (<i>kg</i>)	Repetições	Velocidade
Treino Passivo	1	50	70	0	10	Muito Lenta
	2	40	70	0	10	Muito Lenta
	3	35	75	0	10	Muito Lenta
	4	30	80	0	15	Lenta
	5	30	80	0	20	Lenta
Treino Ativo Assistido	6	50	70	0	5	Muito Lenta
	7	40	70	0	5	Muito Lenta
	8	35	75	0	8	Lenta
	9	30	80	0	10	Lenta
	10	30	80	0	15	Lenta
Treino Ativo	11	40	70	0	5	Lenta
	12	40	80	0	8	Lenta
	13	30	80	0	10	Lenta
	14	30	80	0	15	Lenta
	15	30	80	0	20	Lenta
Treino Ativo Resistivo	16	50	70	1	10	Lenta
	17	40	70	1	10	Média
	18	40	80	2	15	Lenta
	19	30	80	2	15	Média
	20	30	80	3	20	Média

4.5 Interface de configuração

Foi desenvolvida uma interface em C# para que o fisioterapeuta pudesse configurar os parâmetros para cada treino, inserir os dados de peso do usuário e valores de proteção para evitar lesões ao utilizar o dispositivo. Tais valores são ângulos máximo e mínimo do sistema, velocidade máxima e torque máximo. O fisioterapeuta controla a tarefa, nesta interface, através de um computador, e a mesma se comunica com o computador do exoesqueleto (PC-104) através de rede Ethernet cabeada ou Wi-Fi. Um exemplo desta interface pode ser visto na Figura 56.

Tal interface é responsável também por armazenar os dados de tempo de experimento, ângulo, velocidade, dados do sensor de força, torque resultante do sistema



Figura 56 – Interface desenvolvida para configurar as tarefas no exoesqueleto.

desconsiderando o peso da perna, número de repetições do movimento, cargas utilizadas e sensibilidade da articulação. Estes parâmetros são armazenados, podendo ser utilizados para uma análise *off-line* pelo fisioterapeuta.

Quanto aos valores de proteção mencionados, os ângulos de proteção máximos e mínimos são limitadores para o movimento: quando um destes ângulos é atingido, só é permitido o movimento em sentido contrário ao do ângulo limite alcançado. Também são definidos o máximo torque e a máxima velocidade do dispositivo robótico. O máximo torque é uma exigência no treino passivo, pois um torque muito grande do exoesqueleto na perna do usuário pode resultar em lesão. A Figura 57 ilustra um caso onde o ângulo máximo de proteção (neste caso 85°) foi atingido. Os ângulos máximo e mínimo de proteção estipulam as limitações do movimento, impedindo que o mesmo seja executado além destes limites, enquanto o torque máximo ou velocidade máxima quando alcançados, resultam em parada do sistema, sendo que o mesmo deve ser rearmado manualmente pelo fisioterapeuta após a avaliação da ocorrência.

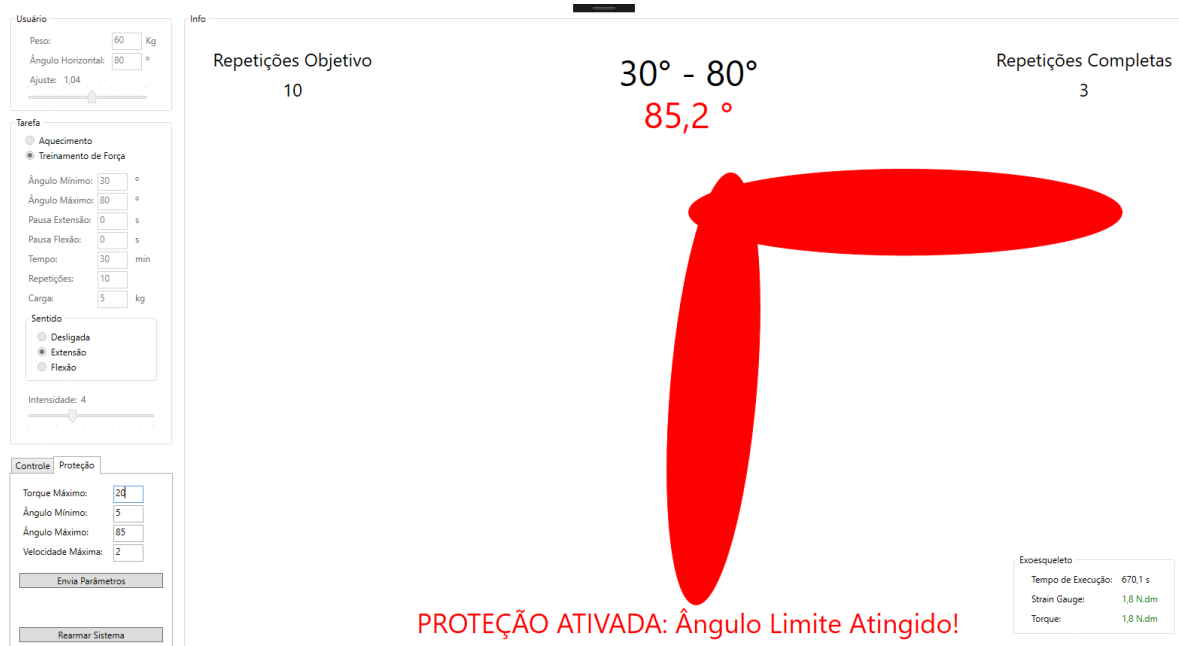


Figura 57 – Exemplo onde o ângulo máximo de proteção é atingido.

4.6 Resultados do Sistema de Controle

Quanto aos dados coletados durante os experimentos, a Figura 58 apresenta um usuário realizando o treino passivo, com ângulos entre 40° e 70° , sem carga, realizando 10 repetições na velocidade muito lenta (Sessão 2, Tabela 2). Nesta sessão, o usuário permaneceu com a perna em repouso, permitindo que o robô realizasse o movimento. O sinal verificado no *strain gage* corresponde ao peso da perna, enquanto é possível perceber que, uma vez que o compensador gravitacional está ativado, o torque voluntário realizado pelo usuário é muito baixo.

A Figura 59 apresenta um usuário realizando o treino ativo assistido, com ângulos entre 30° e 80° , sem carga, realizando 10 repetições na velocidade lenta (Sessão 9, Tabela 2). Nesta sessão, o usuário realizou os movimentos, porém a compensação gravitacional estava ativada de forma a compensar 50% do peso da perna do usuário, auxiliando-o no movimento. É possível perceber que o torque realizado pelo usuário durante as tarefas de extensão (aumento do ângulo) é aproximadamente reduzido pela metade, devido à assistência do dispositivo.

A Figura 60 apresenta um usuário realizando o treino ativo, com ângulos entre 40° e 70° , sem carga, realizando 5 repetições na velocidade lenta (Sessão 11, Tabela 2). Nesta sessão, o usuário realizou os movimentos de forma natural, sem o auxílio do robô, o qual estava com seu controlador de admitância de forma a deixar a articulação da perna o mais leve possível (condição de impedância zero), de forma que a estrutura do robô fosse “transparente” ao movimento do usuário. Uma vez que a compensação gravitacional




Figura 58 – Sinais de ângulo e torque para um usuário realizando um treino passivo, com ângulos entre 40° e 70° .




Figura 59 – Sinais de ângulo e torque para um usuário realizando um treino ativo assistido, com ângulos entre 30° e 80° .

estava desabilitada, pois o objetivo era que o usuário pudesse sustentar o próprio peso de sua perna, os torques medidos pelo *strain gage* coincidiram com o torque que o usuário aplica ao sistema.

A Figura 61 apresenta um usuário realizando o treino ativo resistivo, com ângulos entre 50° e 70° , com uma carga de 1 kg somente no sentido de extensão do movimento,




Figura 60 – Sinais de ângulo e torque para um usuário realizando um treino ativo, com ângulos entre 40° e 70° .

realizando 10 repetições na velocidade lenta (Sessão 16, Tabela 2). Neste treino, o usuário necessitou realizar um torque maior em função da carga de 1 kg adicionada ao movimento. O torque referente à carga também está representado na Figura 61, e o sinal resultante é calculado de acordo com o diagrama de blocos apresentado na Figura 55.




Figura 61 – Sinais de ângulo e torque para um usuário realizando um treino ativo assistido, com ângulos entre 50° e 70° .

4.7 Pesquisa de Satisfação do Usuário

Uma vez que o sistema não foi testado em pacientes, o mesmo não pôde ser avaliado na recuperação clínica dos mesmos. A avaliação realizada foi apenas a avaliação de satisfação do usuário na utilização do dispositivo. Para isso utilizou-se a avaliação B-Quest (2.0) (CARVALHO; Gois Júnior; SÁ, 2014). Seus resultados estão sumarizados na Figura 62, com as notas de: 1 para insatisfeito, 2 para pouco satisfeito, 3 para mais ou menos satisfeito, 4 para bastante satisfeito e, 5 para totalmente satisfeito. Os resultados foram levantados a partir de 5 usuários e as perguntas foram:

Qual seu grau de satisfação com:

1. as dimensões do seu recurso de tecnologia assistiva?;
2. o peso do seu recurso de tecnologia assistiva?;
3. a facilidade de ajustar as partes do seu recurso de tecnologia assistiva?;
4. a estabilidade e a segurança do seu recurso de tecnologia assistiva?;
5. a durabilidade do seu recurso de tecnologia assistiva?;
6. a facilidade de uso do seu recurso de tecnologia assistiva?;
7. o conforto do seu recurso de tecnologia assistiva?;
8. a eficácia do seu recurso de tecnologia assistiva.




Figura 62 – Resultado do questionário B-Quest (2.0), mensurando o grau de satisfação do usuário com o dispositivo de tecnologia assistiva.

Para os itens que os usuários consideram importantes em dispositivos de tecnologia assistiva, os resultados estão apresentados na Figura 63.

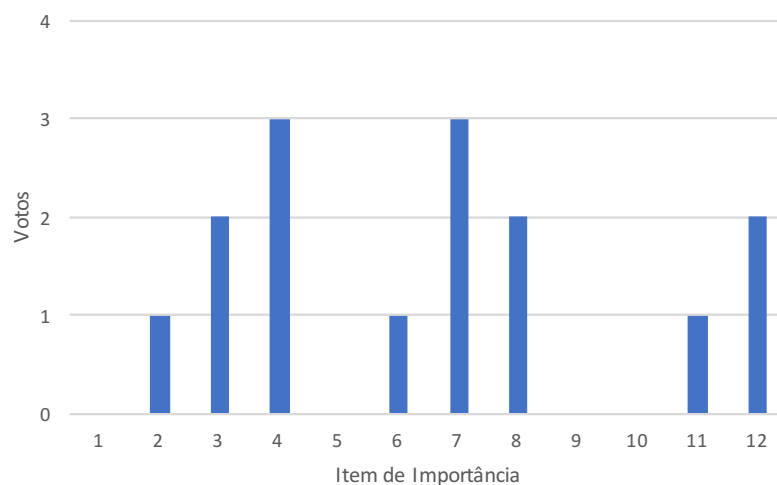


Figura 63 – Resultado do questionário B-Quest (2.0), mensurando itens que o usuário considera importantes. Os itens são: 1 - dimensões; 2 - peso; 3 - ajustes; 4 - segurança; 5 - durabilidade; 6 - facilidade de uso; 7 - conforto; 8 - eficácia; 9 - entrega; 10 - reparos/assistência técnica; 11 - serviços profissionais; 12 - serviços de acompanhamento.

4.8 Discussão e Conclusões

Os controladores desenvolvidos nesta pesquisa foram capazes de realizar as tarefas propostas, nos quatro treinos estabelecidos para uma reabilitação voltada para pacientes com artroplastia. A partir destes controladores e dependendo de necessidades futuras, novas estratégias de controle podem ser desenvolvidas, como controle de parada ativa durante a tarefa, onde o usuário através de sua força pode interromper o movimento, ou controles para a marcha como proposto por [Villa-Parra et al. \(2016\)](#).

A estrutura apresentada, apesar de mais simples, pode ser uma solução viável, em termos de custo em relação às soluções já consolidadas no mercado como o Lokomat[®] ou o MotionMaker[™].

Ao contrário de outros dispositivos estacionários para reabilitação de membros inferiores como os apresentados por [Bouhabba et al. \(2013\)](#) e [Bouri, Gall e Clavel \(2009\)](#), o ALLOR apresenta sua estrutura mecânica compatível com a perna humana, o que o torna compatível tanto com reabilitação estática, acoplado a uma cadeira, quanto em reabilitação de marcha, tornando-se uma solução versátil não limitada apenas à reabilitação estática.

Quanto à análise de satisfação dos usuários utilizando o questionário B-Quest (2.0) (Figura 62), as maiores deficiências encontradas estão na dificuldade de ajuste

ao corpo humano e no conforto no uso do dispositivo. Ressalta-se que, por se tratar da primeira versão do protótipo, o objetivo estava no desenvolvimento da estrutura, ergonomia, implementação das estratégias de controle que atendessem as tarefas e, principalmente, nas rotinas de segurança do usuário. Pesquisas futuras com pacientes podem ser realizadas, de forma a avaliar possíveis melhorias no conforto e praticidade no ajuste do dispositivo.

5 Integração da Interface Multimodal com o Exoesqueleto de Reabilitação

5.1 Introdução

Neste capítulo é apresentada a integração do exoesqueleto de membros inferiores, apresentado no Capítulo 4, com a interface multimodal desenvolvida para a predição de movimento, apresentada no Capítulo 3.

Foi proposta uma tarefa que pudesse ser utilizada em pacientes com mobilidade parcial nos membros inferiores e que precisem de auxílio na reabilitação, como pacientes que sofreram AVC (TSUKAHARA; HASEGAWA; SANKAI, 2009) ou com paraplegia incompleta (DONATI et al., 2016).

Após uma análise *pseudo-online* das capturas de dados apresentadas no Capítulo 3, onde os dados foram enviados amostra por amostra, a uma taxa de 600 Hz, simulando um comportamento *on-line*, percebeu-se que, com a capacidade computacional disponível no NTA da UFES onde a pesquisa foi realizada, não seria possível a classificação *on-line* dos sinais de EEG. Sendo assim, a pesquisa apresentada neste Capítulo considera apenas os sinais de sEMG para detecção *on-line* de intenção de movimento. Contudo, vale ressaltar que os sinais de EEG continuam sendo capturados para futuras análises *off-line*, e, uma vez que o sistema multimodal já foi validado de forma *off-line* (Capítulo 3), o sistema também é capaz de processar a intenção de movimento através dos sinais de EEG com um hardware adequado.

A interface está apresentada na Figura 64, a qual é uma evolução da interface apresentada no no Capítulo 3 (Figura 8).

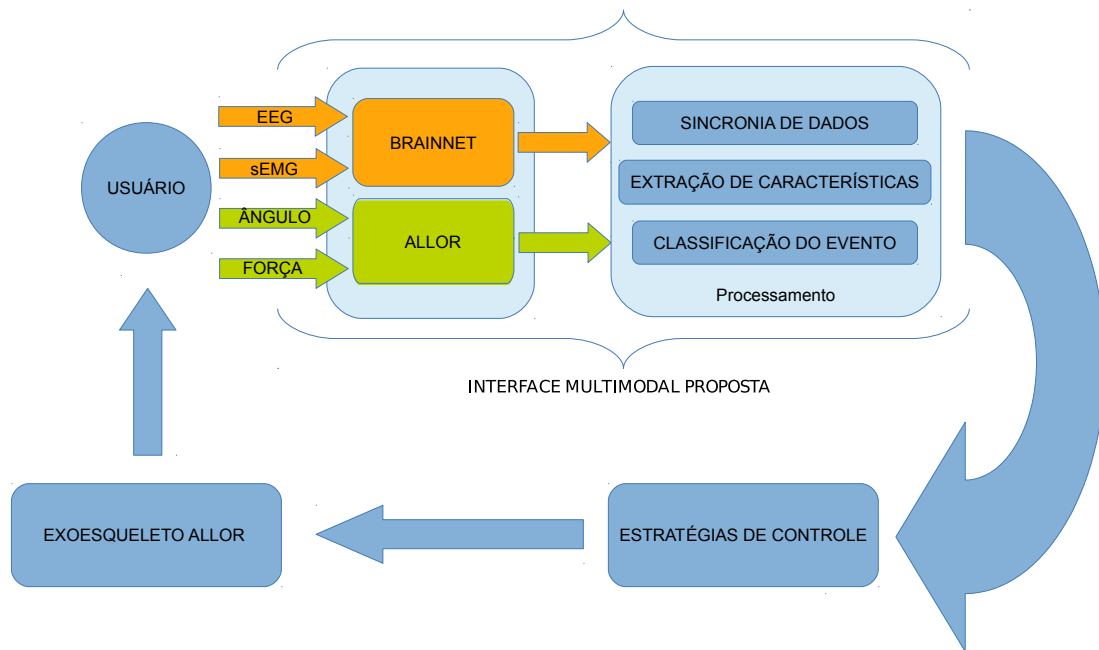


Figura 64 – Interface multimodal proposta nesta etapa.

5.2 Materiais e Métodos

O teste piloto foi realizado com 6 voluntários rígidos (3 do gênero feminino e 3 do gênero masculino), com idades entre 22 e 27 anos, com o intuito de validar a plataforma, que se voluntariaram em participar deste estudo. Este estudo tem aprovação do Comitê de Ética em Pesquisa com seres humanos da UNESA, CAAE número 51685515.3.0000.5284, número do parecer 1.863.539.

Além do sistema de controle implementado no computador industrial (PC-104) executando *SIMULINK real-time*, dois outros programas foram implementados em C#: uma interface para que o fisioterapeuta pudesse acompanhar e controlar a tarefa (Figura 65), e outro programa, o sistema de treinamento, executado em um computador independente, responsável por receber os dados das repetições capturadas pelo sistema de controle e então executar o treinamento dos classificadores de forma *on-line*, adaptativa (baseada nas últimas repetições) e dedicada (Figura 66). Os dados das repetições (sinais de sEMG e EEG) são enviados a um computador de controle pelo BrainNet através de rede Ethernet.

Serão então necessários, além do PC-104, mais 2 computadores, um para o controle da tarefa (PC Controle) e um para o treinamento dos classificadores (PC Treinamento), além do BrainNet, equipamento responsável pela coleta dos dados de sEMG e EEG, e o roteador sem fio responsável por gerenciar a conexão de rede.

A Figura 67 apresenta a arquitetura de rede utilizada para realização da tarefa. Nela é possível identificar os dois computadores: PC Controle e PC Treinamento. Também pode



Figura 65 – Interface desenvolvida para configurar a tarefa, e controle do dispositivo realizando uma detecção *on-line*.

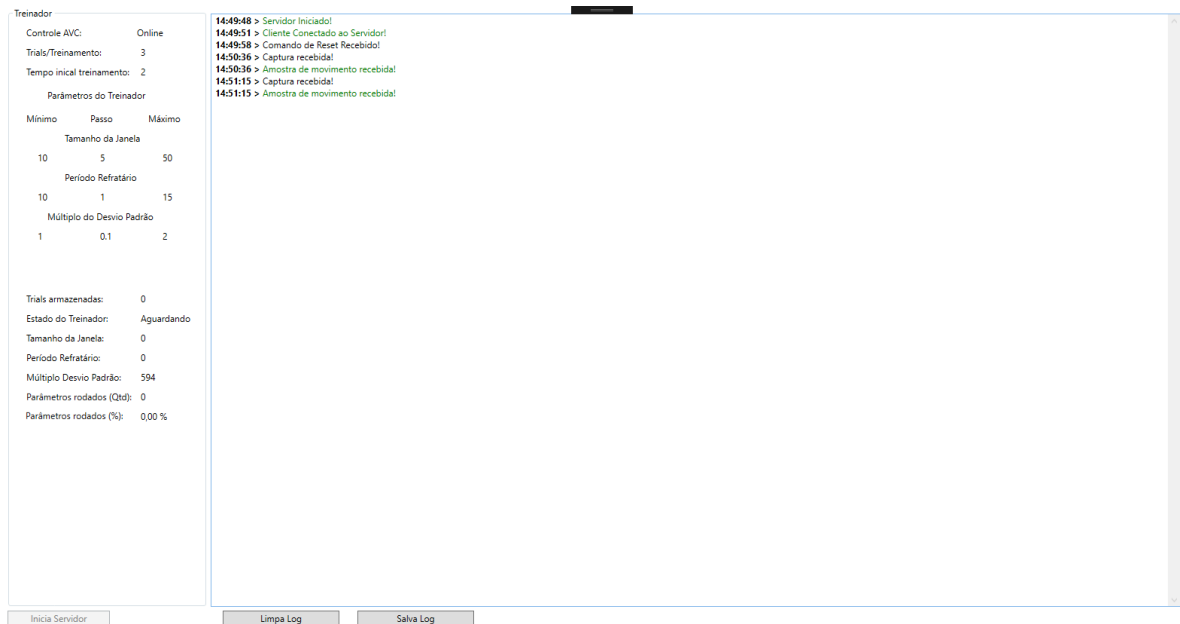


Figura 66 – Interface desenvolvida para receber dados coletados e realizar o treinamento dos classificadores de forma dedicada.

ser identificado o PC-104, onde estão implementadas as estratégias de controle utilizadas para executar a tarefa, o BrainNet, e o roteador sem fio. São também apresentados na figura os fluxos de informação, ou seja, todos os dispositivos se comunicam diretamente com o PC Controle, sendo este o responsável por gerenciar toda a tarefa.




Figura 67 – Arquitetura de rede utilizada na tarefa.

5.3 Protocolo Experimental

A tarefa proposta para a reabilitação neste estágio consiste de 3 fases. Na primeira fase, ou “fase de treinamento”, o paciente realiza 7 repetições de extensão e flexão do joelho de forma ativa, com amplitude e velocidade de movimento confortáveis para o paciente. Em cada repetição é coletado o sinal de sEMG e o início de movimento detectado pelo *strain gage*, os quais serão responsáveis pelo treinamento do classificador.

Após esta fase, o paciente realiza um período de repouso de 2 minutos, possibilitando seu descanso após a tarefa realizada e, por outro lado, possibilitando também que o sistema de treinamento do classificador encontre parâmetros minimamente aceitáveis para classificação. Tal período de tempo será chamado de “fase de repouso”.

Na terceira e última fase, ou “fase de classificação”, o paciente realiza 10 repetições de extensão e flexão do joelho de forma passiva, onde o comando para o início de cada movimento é adquirido através da intenção de movimento adquirida pelo sinal de sEMG. A amplitude e velocidade do movimento são definidas pelo fisioterapeuta de acordo com o estágio de reabilitação do paciente.

Como apresentado no Capítulo 3, cada repetição dura, aproximadamente, 30 s (Figura 14), iniciando-se após a indicação acústica, e o voluntário pode tentar realizar o movimento de acordo com sua vontade após a segunda indicação acústica (10 s depois do início). A linha-base (intervalo entre os instantes 5 s e 8 s) é novamente o período durante a repetição em que o voluntário não se move e tampouco deve ter a intenção de fazê-lo.

5.4 Interfaces de Controle e Treinamento

A Figura 68 ilustra a comunicação entre o programa de controle e o programa de treinamento. São estipulados inicialmente a quantidade de repetições n para o treinamento, e a quantidade de repetições k para a classificação, bem como o período de tempo de repouso.

O número de repetições n para o treinamento define a quantidade de espaços simultâneos para análise dos dados das repetições no treinamento, ou seja, a cada novo conjunto de dados (nova repetição) recebido pelo sistema de treinamento, os dados mais antigos são descartados para dar lugar aos novos.

Após cada repetição durante as aquisições na fase de treinamento, os dados da mesma são enviados para o sistema de treinamento e, ao completar seus n espaços para dados, período este que coincide com a fase de repouso, o sistema de treinamento inicia a varredura por parâmetros.

Após a fase de repouso, parâmetros de classificação são recebidos pelo programa de controle, o qual irá classificar as próximas repetições (fase de classificação). Em seguida, enviará os dados da repetição atual ao sistema de treinamento, o qual irá eliminar os dados da repetição mais antiga em sua base de dados para dar lugar aos novos dados. Os dados mais antigos são eliminados devido à mudança na característica do sinal ao longo das repetições devido ao ressecamento do gel com o passar do tempo e fadiga do voluntário (LATIKKA et al., 2001). Finalmente, o sistema de treinamento enviará um novo conjunto de parâmetros, os quais o programa de controle irá utilizar em seu classificador, realizando assim um treinamento adaptativo, baseado nos dados das últimas repetições executadas. Uma vez que o treinamento é realizado em um computador dedicado, ele se inicia em conjunto com a fase de repouso e permanece buscando melhores parâmetros para os classificadores através de uma busca exaustiva durante todo o processo de classificação.

Com a detecção do movimento utilizando os sinais de sEMG, a interface de controle envia um comando de início de movimento para o PC-104, e este, por sua vez, realiza o movimento de extensão e flexão do joelho na amplitude e velocidade definidas pelo fisioterapeuta. Este procedimento se repete durante todas as repetições da fase de classificação.

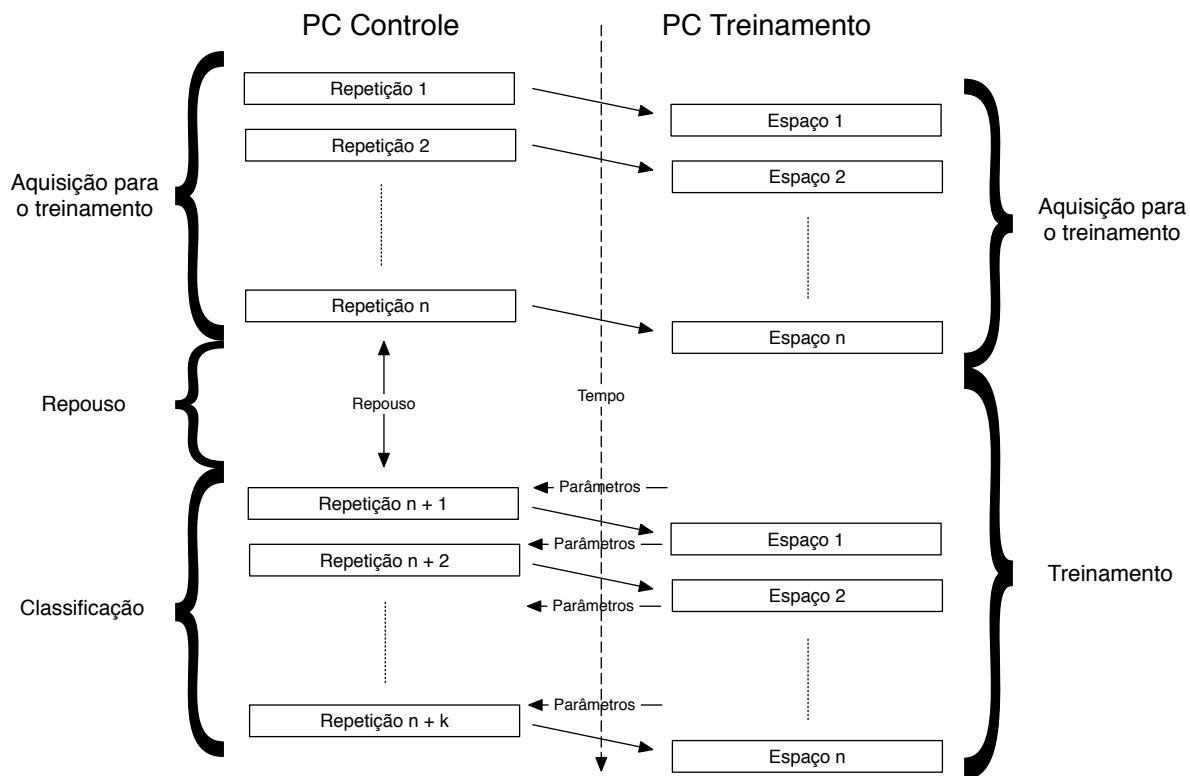


Figura 68 – Diagrama da comunicação entre o programa de controle e o programa de treinamento.

5.5 Resultados

Conforme anteriormente mencionado, para o sinal de sEMG, a ativação muscular pode ser identificada no intervalo entre 0,5 s antes do movimento até o fim do movimento. Considerando um atraso de 100 ms como aceitável no sistema, considerou-se mais uma vez como detecção correta da ativação muscular os sinais detectados entre 0,5 s antes do movimento até 0,1 s depois do início do movimento. Este intervalo será chamado de “Janela Total do sEMG”. O intervalo de antecipação do movimento, ou seja, o intervalo entre 0,5 s antes do movimento até o início do movimento, será considerado “Janela Anterior do sEMG”, e o intervalo entre o início do movimento e os 100 milissegundos aceitáveis após o início do movimento será chamado de “Janela Posterior do sEMG”.

A precisão do classificador está apresentada na Figura 69, a qual mostra a precisão do sistema proposto para cada janela de tempo considerada para o sinal de sEMG. A janela de tempo é um intervalo onde a classificação é considerada como sucesso. As janelas de tempo apresentadas nesta etapa do trabalho foram as mesmas utilizadas na análise *off-line*, e foram sugeridas por Ibáñez et al. (2013) e Kirchner, Tabie e Seeland (2014).

Para o sinal de sEMG, a precisão média total foi de $76,67 \pm 12,11\%$, e, considerando uma média harmônica, aproximadamente 75%. Considerando apenas a antecipação do




Figura 69 – Precisão para cada janela de tempo considerada para o sinal de sEMG.

movimento (Janela Anterior do sEMG), sua precisão foi de $71,67 \pm 16,02\%$, e sua média harmônica de aproximadamente 69%. Estes dados estão calculados com base nos dados apresentados na Figura 69. Esses dados são compatíveis com a análise *off-line* apresentada na Figura 39 do Capítulo 3, onde, desconsiderando o voluntário 6, obteve-se uma precisão média total de aproximadamente $78,00 \pm 13,04\%$, com sua média harmônica de aproximadamente 76%, e considerando apenas a antecipação do movimento, a precisão média foi de aproximadamente $76,00 \pm 13,42\%$, e sua média harmônica, aproximadamente 74%.

Tabela 3 – Precisão do sinal de sEMG para o sistema *on-line*.

	Janela Anterior	Janela Total
Intervalo	-0,5 s até 0 s	-0,5 s até 0,1 s
Precisão Média	$71,67 \pm 16,02\%$	$76,67 \pm 12,11\%$
Média Harmônica	69%	75%

Os valores encontrados estão sintetizados na Tabela 3. A Figura 70 apresenta a média de tempo de antecipação por voluntário para o sinal sEMG, bem como a média de tempo entre os voluntários, que apresentou uma antecipação média de $200,45 \pm 69,31$ ms, compatível com os $122,93 \pm 97,48$ ms alcançados na análise *off-line* apresentada na Figura 43 do Capítulo 3.




Figura 70 – Média e Desvio Padrão da antecipação do tempo.

A Figura 71 apresenta os falsos-positivos e falsos-negativos para o sinal de sEMG, considerando a Janela Anterior do sEMG (antecipação do movimento). Detecções antes das janelas de tempo propostas são consideradas falsos-positivos, enquanto detecções que ocorrem depois da janela de tempo são consideradas falsos-negativos. Como explicado anteriormente, os falsos-negativos sugerem que não ocorreu movimento nas janelas de tempo desejadas (antecipação do movimento), contudo, sempre ocorreu movimento em todas as repetições do experimento. Em relação à análise *off-line*, a taxa média de falsos-positivos obteve um pequeno aumento (20% para 23%) em relação à análise *on-line*, mantendo sua compatibilidade, e um decréscimo de falsos-negativos (de 30% na análise *off-line* para 5% na análise *on-line*).

Na Figura 72 são mostradas marcações em que foram identificadas intenções de movimento baseadas na análise de sEMG para o voluntário 1. O tempo zero é relativo ao movimento efetivo do membro reconhecido através dos dados fornecidos pelo *strain gage*. Nessa figura, a janela de tempo em que se permitem predições baseadas em sEMG é de 0,5 s antes do movimento, ou seja, “Janela Anterior do sEMG”, assim como realizado na análise *off-line* (Capítulo 3) e como sugerido por Pfurtscheller e Lopes da Silva (1999) e Kirchner, Tabie e Seeland (2014). A partir da Figura 72 é possível notar que o percentual de repetições detectadas corretamente neste caso foi de 90%. Também é possível perceber




Figura 71 – Taxa de Falsos-Positivos (FP) e Falsos-Negativos (FN) por voluntário para os sinais de sEMG.

que apenas a repetição 2 não foi detectada corretamente no intervalo de tempo esperado.

Na Figura 73 são mostradas marcações em que foram identificadas intenções de movimento baseadas na análise de sEMG para todos os voluntários. A partir da análise individual de cada repetição, percebe-se, que nas repetições iniciais do treinamento, a precisão é menor, e vai aumentando à medida que as repetições vão sendo usadas para treinamento através da regressão linear plotada no gráfico. Este comportamento era esperado, uma vez que o sistema de treinamento está procurando por parâmetros melhores para o classificador durante todo o tempo da fase de classificação. Tal melhoria na precisão pode ser observada na Figura 74, na qual, a partir de uma linha de tendência linear tracejada, é possível perceber melhor este comportamento.

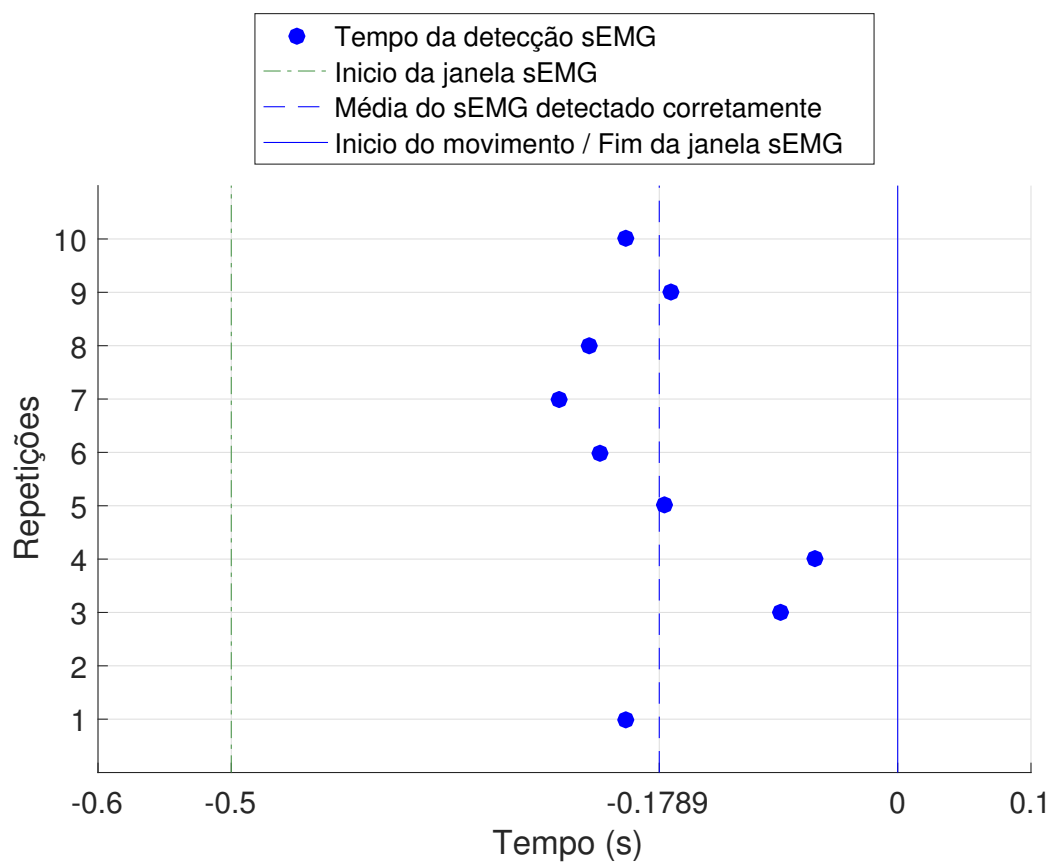


Figura 72 – Distribuição de predições do sEMG para o voluntário 1.




Figura 73 – Distribuição de predições baseadas e sEMG para todos os voluntários.




Figura 74 – Precisão média por repetição, em relação a todos os voluntários.

5.6 Discussão

Os resultados obtidos de forma *on-line* foram compatíveis com os obtidos de forma *off-line* e mostram que é possível a detecção da intenção de movimento para o controle do dispositivo robótico com uma antecipação de movimento que não traz atrasos e, conseqüentemente, desconforto para o usuário.

Embora a análise *on-line* tenha sido realizada apenas com o sinal de sEMG, uma análise *pseudo-online* com os dados coletados *off-line* mostrou que com um computador com melhor capacidade computacional já seria possível trabalhar com os sinais de EEG em conjunto com o sinal de sEMG de forma multimodal. Trabalhos futuros, com um hardware apropriado, podem ser realizados utilizando os dois sinais, de forma a aumentar a antecipação e precisão do sistema como comprovado através da análise *off-line*.

Na análise *on-line*, o número de falsos-positivos (sinais detectados antes do intervalo possível do sEMG, ou seja, 0,5 ms antes do movimento) aumentou, enquanto o número de falsos-negativos (sinais detectados depois do início do movimento) diminuiu. Tal fato é previsível, uma vez que na análise *off-line* os classificadores estão mais ajustados. Embora falsos-negativos indiquem que o classificador não conseguiu antecipar o movimento, tais sinais correspondem a sinais de ativação válidos no sinal de sEMG, que ocorrem durante todo o movimento de extensão e flexão do joelho.

5.7 Considerações Finais

Os resultados *on-line* mostram que é possível utilizar a interface proposta, inicialmente com sinal de sEMG e futuramente com sinais de EEG, para controlar um dispositivo robótico para tarefas de reabilitação com um adequado nível de detecção, sem sobrecarregar o sistema de controle. Vale ressaltar que está sendo adquirido pelo NTA um sistema de maior capacidade computacional para que seja possível incluir os sinais de EEG nas análises *on-line*.

6 Conclusões e Trabalhos Futuros

Este trabalho apresentou o desenvolvimento de uma interface multimodal para predição de movimentos em membros inferiores, utilizando tanto os potenciais de SMR dos sinais de EEG quanto sinais de sEMG, de sensores inerciais e de força, alcançando resultados satisfatórios na precisão da detecção da intenção de movimento e na antecipação da mesma ao início do movimento. Foi desenvolvida uma nova abordagem para classificação de sinais de EEG através de SMR, a qual apresentou uma melhora significativa na acurácia da classificação da intenção de movimento (entre 30% e 40% superior à abordagem clássica no caso desta pesquisa) para membros inferiores.

Para a validação da interface multimodal para identificação de movimentos de flexo-extensão do joelho, foi apresentado um protocolo de colocação de sensores inerciais para detecção do início do movimento. Tal protocolo é independente do alinhamento inicial entre os sensores, pois o mesmo é realizado de forma virtual.

A interface multimodal desenvolvida foi integrada ao exoesqueleto ALLOR de membros inferiores com 3 graus de liberdade, com uma articulação ativa no joelho e duas passivas no quadril e tornozelo. Esse sistema robótico também foi desenvolvido no contexto desta Tese de Doutorado e foi implementado de maneira que pudesse ser utilizado tanto na reabilitação estacionária, composta pelas tarefas de extensão e flexão do joelho apresentadas nesta Tese, quanto em tarefas de marcha.

Foram desenvolvidas estratégias de controle passiva, ativa, ativa assistida e ativa resistiva do exoesqueleto robótico, para reabilitação motora de pacientes, e foram propostos protocolos de reabilitação para pacientes que realizaram a artroplastia do joelho.

A integração da interface multimodal com o sistema de controle proposto e o exoesqueleto permitiu o desenvolvimento de tarefas de reabilitação com antecipação do movimento e funcionamento *on-line* (extensão e flexão do joelho) utilizando sinais de sEMG. Obteve-se uma acurácia média de $71,67 \pm 16,02\%$ na antecipação do movimento, com antecipação ao movimento média de $200,45 \pm 50,71$ ms.

Considerando o pioneirismo deste trabalho no Núcleo de Tecnologias Assistivas (NTA) da UFES e a necessidade de validação, tanto dos componentes individuais (interface multimodal, exoesqueleto robótico e estratégias de controle) como da plataforma de reabilitação completa, os experimentos de validação ficaram restritos a voluntários rígidos. Pesquisas atuais em desenvolvimento no NTA se encarregarão da validação clínica do sistema.

Com a aquisição de um sistema computacional mais potente, será possível incluir os

sinais de EEG na análise *on-line* e, conseqüentemente, a interface multimodal desenvolvida poderá funcionar integralmente na predição do movimento utilizando sinais de EEG e sEMG.

Atualmente, duas etapas de testes com pacientes estão sendo planejadas. A primeira, com pacientes que realizaram artroplastia do joelho, e a segunda, com pacientes que sofreram AVC e apresentam alguma deficiência motora em membros inferiores. Desta forma, serão realizados ajustes e verificada a eficácia das soluções apresentadas.

Trabalhos futuros também podem ser realizados de forma a otimizar as etapas de treinamento (buscas por parâmetros dos classificadores) experimentando métodos de busca mais inteligentes e classificação dos sinais com outros classificadores.

6.1 Contribuições

A principal contribuição desta Tese é o desenvolvimento de uma interface multimodal para predição de movimento que possa ser utilizada num dispositivo de reabilitação de membros inferiores.

Também é proposta uma nova abordagem para classificação de sinais de EEG utilizando dois estágios de classificação. Como será apresentada, esta contribuição provê uma melhora média de 30% na acurácia de classificadores de EEG em comparação com os classificadores probabilísticos tradicionais (BOTELHO *et al.*, 2017).

6.1.1 Contribuições Secundárias

É proposto adicionalmente um protocolo de medição de ângulos do joelho a partir de dois sensores inerciais, protocolo este que é independente da colocação precisa dos sensores na perna do usuário, pois o alinhamento se dá de forma virtual (BOTELHO *et al.*, 2015b).

6.2 Publicações

O trabalho apresentado nesta Tese originou o seguinte artigo científico em periódico:

1. Botelho, T.; D. Ruy Soprani S. Araujo; Carvalho, C. R.; Ferreira, A.; Frizera, A. “Nuevo enfoque para la clasificacion de señales EEG usando la varianza de la diferencia entre las clases de un clasificador Bayesiano”. Revista Iberoamericana de Automática e Informática Industrial (RIAI), v. 14, n. 4, p. 362–371, oct 2017. ISSN 16977912.

Além deste, foram publicados os seguintes artigos científicos em conferências:

1. Botelho, T., D. Soprani, P. Schneider, C. Carvalho, L. Vargas, and A. Frizera. “Uma Proposta de Protocolo de Colocação de Sensores Inerciais Utilizando Alinhamento Virtual para Aplicações em Análise de Movimento de Membros Inferiores.” *Anais Do V Encontro Nacional de Engenharia Biomecânica - ENEBI 2015*, 511–15. Uberlândia, Brasil, 2015.
2. Botelho, T., D. Soprani, C. Carvalho, V. Mut, A. Frizera, and A. Ferreira. “Control of a Lower Limb Robotic Exoskeleton Using Impedance Control”. *Proceedings of the 1st International Workshop on Assistive Technology - IWAT 2015*, 23–26. Vitória, Brasil, 2015.
3. Botelho, T.; Soprani, D. ; Carvalho, C. ; Schneider, P. ; Frizera-Neto, A. ; Ferreira, A. “Pseudo-online Multimodal Interface Based on Movement Prediction for Lower Limbs Rehabilitation”. *Proceedings of the 3rd International Conference on NeuroRehabilitation (ICNR2016)*. p. 1415-1419, Segovia, Espanha, 2016.

Também foram publicados os seguintes capítulos de livro:

1. Azorin, J. M.; Pons, J. L.; Frizera, A.; Botelho, T. R.; Gil, A.; Roa, J. “Introducción y Orientación del Libro”. Em: José María Azorín Poveda; José Luis Pons Rovira; Anselmo Frizera Neto; Thomaz Rodrigues Botelho; Ángel Manuel Gil Agudo; Javier Orlando Roa Romero. (Org.). “Exoesqueletos Robóticos para Rehabilitación y Asistencia de Pacientes con Daño Neurológico: Experiencias y Posibilidades en Iberoamérica”. 1a ed. Madrid, Espanha: Programa Iberoamericano de Ciencia y Tecnología para el Desarrollo, 2017, v. 1, p. 9-14.
2. Azorin, J. M.; Pons, J. L.; Frizera, A.; Botelho, T. R.; Gil, A.; Roa, J. “Conclusiones” Em: José María Azorín Poveda; José Luis Pons Rovira; Anselmo Frizera Neto; Thomaz Rodrigues Botelho; Ángel Manuel Gil Agudo; Javier Orlando Roa Romero. (Org.). “Exoesqueletos Robóticos para Rehabilitación y Asistencia de Pacientes con Daño Neurológico: Experiencias y Posibilidades en Iberoamérica”. 1a ed. Madrid, Espanha: Programa Iberoamericano de Ciencia y Tecnología para el Desarrollo, 2017, v. 1, p. 167-167.
3. Botelho, T.; Resquin, F.; Moreno, J. C.; Casco, S.; Martinez, F.; Mendoza, R.; Rocon, E. “Sistema de control y medida”. Em: José María Azorín Poveda; José Luis Pons Rovira; Anselmo Frizera Neto; Thomaz Rodrigues Botelho; Ángel Manuel Gil Agudo; Javier Orlando Roa Romero. (Org.). “Exoesqueletos Robóticos para Rehabilitación y Asistencia de Pacientes con Daño Neurológico: Experiencias y

Posibilidades en Iberoamérica”. 1a ed. Madri, Espanha: Programa Iberoamericano de Ciencia y Tecnología para el Desarrollo, 2017, v. 1, p. 89-124.

4. Botelho, T.; Soprani, D.; Carvalho, C.; Rodrigues, P.; Schneider, P. ; Frizera-Neto, A.; Ferreira, A. “Pseudo-online Multimodal Interface Based on Movement Prediction for Lower Limbs Rehabilitation”. *Biosystems & Biorobotics*. 1ed. Springer International Publishing, 2017, v. , p. 1415-1419.

Alguns outros trabalhos foram publicados como consequência da interação com outros pesquisadores durante o desenvolvimento desta pesquisa. Os mais importantes estão listados a seguir:

1. Ruy Soprani S. Araujo, Douglas, Thomaz Rodrigues Botelho, Camila Rodrigues C. Carvalho, Anselmo Frizera, Andre Ferreira, and Eduardo Rocon. “Platform for Multimodal Signal Acquisition for the Control of Lower Limb Rehabilitation Devices.” *Proceedings of the 2nd International Congress on Neurotechnology, Electronics and Informatics - Neurotechnix 2014*, 49–55. Roma, Itália. SCITEPRESS - Science and Technology Publications, 2014. doi:10.5220/0005138900490055.
2. Soprani, D., T. Botelho, C. Rodrigues, A. Frizera, A. Ferreira, and E. Rocon. “Plataforma Multimodal Para Controle de Dispositivos de Reabilitação de Membros Inferiores”. *Anais Do XXIV Congresso Brasileiro de Engenharia Biomédica – CBEB 2014*. Uberlândia, Brasil, 2014.
3. Soprani, D., T. Botelho, C. Rodrigues, A. Frizera, A. Ferreira, and E. Rocon. “Multimodal Interface Based on Movement Prediction for the Use in Lower Limbs Rehabilitation.” *Proceedings of the 1st International Workshop on Assistive Technology - IWAT 2015*, 59–62. Vitória, Brasil, 2015.
4. Carvalho, C., T. Botelho, D. Soprani, A. Frizera, and E. Rocon. “A Study of EEG and EMG Signals Associated with Inertial Sensors Applied in a Multimodal Platform for Rehabilitation Control.” *Proceedings of the 1st International Workshop on Assistive Technology - IWAT 2015*, 1–4. Vitória, Brasil, 2015.
5. Villa-Parra, A. C.; Botelho, T.; Delisle-Rodriguez, D.; Gomes, A.; Bastos, T.; Frizera-Neto, A. “Controle de um Exoesqueleto para Reabilitação de Joelho Baseado em Intenção de Movimento”. *Anais do XXI Congresso Brasileiro de Automática - CBA 2016*. v. 1. p. 2601-2605, Vitória, Brasil, 2016.
6. Villa-Parra, A. C.; Delisle-Rodriguez, D.; Botelho, T.; Frizera, A.; Freire-Bastos, T. “Knee-exoskeleton control for gait rehabilitation based on sEMG of trunk muscles”. *ICyathlon Symposium*. Zurich: ETH Zurich, 2016. v. 1. p. 59-60.

É importante ainda mencionar a participação como editor em um livro recente que recolhe os principais desenvolvimentos de exoesqueletos na Iberoamérica:

1. José María Azorín Poveda; José Luis Pons Rovira; Anselmo Frizera Neto; Thomaz Rodrigues Botelho; Ángel Manuel Gil Agudo; Javier Orlando Roa Romero. (Org.). “Exoesqueletos Robóticos para Rehabilitación y Asistencia de Pacientes con Daño Neurológico: Experiencias y Posibilidades en Iberoamérica”. 1a ed. Madri, Espanha: Programa Iberoamericano de Ciencia y Tecnología para el Desarrollo, 2017, ISBN-13: 978-84-15413-29-5.

Referências

- ALCOBENDAS-MAESTRO, M. et al. Lokomat Robotic-Assisted Versus Overground Training Within 3 to 6 Months of Incomplete Spinal Cord Lesion. *Neurorehabilitation and Neural Repair*, v. 26, n. 9, p. 1058–1063, 2012. ISSN 1545-9683. Disponível em: <<http://journals.sagepub.com/doi/10.1177/1545968312448232>>. Citado na página 26.
- ATENCIO, A. C. *A Novel Stimulation Paradigm for a Brain-Computer Interface Based on SSVEP*. 144 p. Tese (Tese de Doutorado) — Universidade Federal do Espírito Santo, 2015. Citado na página 28.
- BAYON, C. et al. CPWalker: Robotic platform for gait rehabilitation in patients with Cerebral Palsy. In: *2016 IEEE International Conference on Robotics and Automation (ICRA)*. Stockholm, Sweden: IEEE, 2016. v. 70, n. 3, p. 3736–3741. ISBN 978-1-4673-8026-3. ISSN 1488-2159. Disponível em: <<http://ieeexplore.ieee.org/document/7487561/>>. Citado na página 86.
- BENEVIDES, A. B. *Proposta de um Modelo de Fontes Cerebrais para Classificação de Padrões Mentais*. Tese (Dissertação de Mestrado) — Universidade Federal do Espírito Santo, 2009. Citado 3 vezes nas páginas 16, 28 e 61.
- BENEVIDES, A. B.; BASTOS-FILHO, T. F.; 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 2 vezes nas páginas 28 e 60.
- BERTRAND, O.; PERRIN, F.; PERNIER, J. A theoretical justification of the average reference in topographic evoked potential studies. *Electroencephalography and clinical neurophysiology*, v. 62, n. 6, p. 462–464, 1985. ISSN 01685597. Citado na página 60.
- BOTELHO, T. et al. Control of a Lower Limb Robotic Exoskeleton using Impedance Control. In: *Proceedings of the 1st International Workshop on Assistive Technology - IWAT 2015*. Vitória, Brasil: [s.n.], 2015. p. 23–26. ISBN 2359-2346. Citado 2 vezes nas páginas 90 e 91.
- BOTELHO, T. et al. Uma Proposta De Protocolo De Colocação De Sensores Inerciais Utilizando Alinhamento Virtual Para Aplicações Em Análise De Movimento De Membros Inferiores. In: *Anais do V Encontro Nacional de Engenharia Biomecânica - ENEBI 2015*. Uberlândia, Brasil: [s.n.], 2015. p. 511–515. Citado 4 vezes nas páginas 15, 53, 80 e 118.
- BOTELHO, T. R. et al. Nuevo Enfoque para la Clasificación de Señales EEG usando la Varianza de la Diferencia entre las Clases de un Clasificador Bayesiano. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, v. 14, n. 4, p. 362–371, oct 2017. ISSN 16977912. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1697791217300432>>. Citado 3 vezes nas páginas 59, 66 e 118.

- BOUHABBA, E. M. et al. Lower-Limb Rehabilitation Robot Design. *IOP Conference Series: Materials Science and Engineering*, v. 53, p. 012038, dec 2013. ISSN 1757-8981, 1757-899X. Disponível em: <<http://stacks.iop.org/1757-899X/53/i=1/a=012038?key=crossref.f2df1292f34501f3ffe9989fed0ea8c9>>. Citado 4 vezes nas páginas 15, 35, 36 e 100.
- BOURI, M.; GALL, B. L.; CLAVEL, R. A new concept of parallel robot for rehabilitation and fitness: The Lambda. In: *Proceedings of the 2009 IEEE International Conference on Robotics and Biomimetics*. Guilin, China: IEEE, 2009. p. 2503–2508. Disponível em: <<http://ieeexplore.ieee.org/xpls/abs/all.jsp?arnumber=5420>>. Citado 4 vezes nas páginas 15, 35, 36 e 100.
- BUCHMAN, A. S. et al. Cognitive Function Is Associated With the Development of Mobility Impairments in Community-Dwelling Elders. *The American Journal of Geriatric Psychiatry*, v. 19, n. 6, p. 571–580, jun 2011. ISSN 10647481. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1064748112601195>>. Citado na página 31.
- BUENO, L. *Interface Cérebro-Computador Baseada em EEG Utilizando Redes Neurais Interface Cérebro-Computador Baseada em EEG Utilizando Redes Neurais Auto-Organizadas*. Tese (Tese de Doutorado) — Universidade Federal do Espírito Santo, 2017. Citado na página 28.
- BULSTRODE, C. et al. *Oxford Textbook of Trauma and Orthopaedics*. Oxford University Press, 2011. v. 1. (Oxford Textbook, v. 1). ISBN 9780199550647. Disponível em: <<https://books.google.com.br/books?id=72XUnQEACAAJ>>. Citado na página 25.
- CAI, L. L. et al. Implications of Assist-As-Needed Robotic Step Training after a Complete Spinal Cord Injury on Intrinsic Strategies of Motor Learning. *Journal of Neuroscience*, v. 26, n. 41, p. 10564–10568, oct 2006. ISSN 0270-6474. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/17035542>>. Citado na página 26.
- CARVALHO, K. E. C. de; Gois Júnior, M. B.; SÁ, K. N. Tradução e validação do Quebec User Evaluation of Satisfaction with Assistive Technology (QUEST 2.0) para o idioma português do Brasil. *Revista Brasileira de Reumatologia*, v. 54, n. 4, p. 260–267, 2014. ISSN 04825004. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/25627220>>. Citado na página 99.
- CAVANAUGH, J. T.; KILLIAN, S. E. Rehabilitation following meniscal repair. *Current Reviews in Musculoskeletal Medicine*, v. 5, n. 1, p. 46–58, mar 2012. ISSN 1935-973X, 1935-9748. Disponível em: <<http://link.springer.com/10.1007/s12178-011-9110-y>>. Citado na página 25.
- CELANI, N. M. L. *Procesamiento de Señales Electromiográficas Superficiales para el Control de Dispositivos Robóticos*. Tese (Tese de Doutorado) — Universidad Nacional de San Juan, 2010. Citado 2 vezes nas páginas 41 e 72.
- CHENG, M. et al. Mu rhythm-based cursor control: An offline analysis. *Clinical Neurophysiology*, v. 115, n. 4, p. 745–751, 2004. ISSN 13882457. Citado na página 61.
- CIFUENTES, C. A. *Human-Robot Interaction Strategies for Walker-Assisted Locomotion*. Tese (Tese de Doutorado) — Universidade Federal do Espírito Santo, Vitória, Brasil, 2015. Citado na página 28.

- 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 2 vezes nas páginas 38 e 81.
- CRISWELL, E. *Cram's introduction to surface electromyography*. 2nd. ed. Sudbury, MA: Jones and Bartlett, 2011. 412 p. ISSN 00652156. ISBN 978-0-7637-3274-5. Citado 3 vezes nas páginas 15, 47 e 48.
- CUTTI, A. G. et al. 'Outwalk': a protocol for clinical gait analysis based on inertial and magnetic sensors. *Medical & biological engineering & computing*, v. 48, n. 1, p. 17–25, jan 2010. ISSN 1741-0444. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/19911214>>. Citado na página 41.
- DAM, M. et al. The effects of long-term rehabilitation therapy on poststroke hemiplegic patients. *Stroke*, v. 24, n. 8, p. 1186–1191, 1993. Disponível em: <<http://stroke.ahajournals.org/content/24/8/1186.short>>. Citado na página 31.
- DEECKE, L.; SCHEID, P.; KORNUBER, H. H. Distribution of readiness potential, pre-movement positivity, and motor potential of the human cerebral cortex preceding voluntary finger movements. *Experimental Brain Research*, v. 7, n. 2, p. 158–168, 1969. ISSN 00144819. Disponível em: <<http://www.springerlink.com/index/8D1692D0EB3C6074.pdf>>. Citado na página 79.
- DEL-AMA, A. J. et al. Review of hybrid exoskeletons to restore gait following spinal cord injury. *The Journal of Rehabilitation Research and Development*, v. 49, n. 4, p. 497, 2012. ISSN 0748-7711. Disponível em: <<http://www.rehab.research.va.gov/jour/2012/494/pdf/delama494.pdf>>. Citado na página 32.
- DÍAZ, I.; GIL, J. J.; SÁNCHEZ, E. Lower-Limb Robotic Rehabilitation: Literature Review and Challenges. *Journal of Robotics*, v. 2011, n. i, p. 1–11, 2011. ISSN 1687-9600. Disponível em: <<http://www.hindawi.com/journals/jr/2011/759764/>>. Citado 5 vezes nas páginas 15, 31, 32, 33 e 34.
- DITUNNO, P. L. et al. Who wants to walk? Preferences for recovery after SCI: a longitudinal and cross-sectional study. *Spinal Cord*, v. 46, n. 7, p. 500–506, 2008. ISSN 1362-4393. Disponível em: <<http://www.nature.com/doifinder/10.1038/sj.sc.3102172>>. Citado na página 32.
- DONATI, A. R. C. et al. Long-Term Training with a Brain-Machine Interface-Based Gait Protocol Induces Partial Neurological Recovery in Paraplegic Patients. *Scientific Reports*, Nature Publishing Group, v. 6, n. April, p. 30383, 2016. ISSN 2045-2322. Disponível em: <<http://www.nature.com/articles/srep30383>>. Citado 3 vezes nas páginas 26, 27 e 103.
- ELIAS, A. *Estudo dos parametros biomecânicos da marcha humana assistida por andador robótico*. 15–132 p. Tese (Tese de Mestrado) — Universidade Federal do Espírito Santo, Vitória, Brasil, 2013. Citado na página 28.
- 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, oct 2009. ISSN 1873-2380. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/19665712>>. Citado na página 52.

- FERREIRA, A. *Uma Proposta de Interface Cérebro-Computador para Comando de Cadeira de Rodas*. 144 p. Tese (Tese de Doutorado) — Universidade Federal d Espírito Santo, 2008. Citado na página 28.
- FIGUEIREDO, J.; MORENO, J. C.; SANTOS, C. P. Assistive locomotion strategies for active lower limb devices. *ENBENG 2017 - 5th Portuguese Meeting on Bioengineering, Proceedings*, v. 611695, 2017. Citado na página 86.
- FRIZERA-NETO, A. *Interfaz multimodal para modelado, estudio y asistencia a la marcha humana mediante andadores robóticos*. 270 p. Tese (Tesis Doctoral) — Universidad de Alcalá, Madrid, Espanha, 2010. Disponível em: <<http://dspace.uah.es/dspace/handle/10017/9641>>. Citado 2 vezes nas páginas 28 e 31.
- GALLEGO, J. A. et al. A Multimodal Human-Robot Interface to Drive a Neuroprosthesis for Tremor Management. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, v. 42, n. 6, p. 1159–1168, nov 2012. ISSN 1094-6977. Disponível em: <http://ieeexplore.ieee.org/xpls/abs{_}all.jsp?arnumber=6392454http://ieeexplore.ieee.org/document/63924>. Citado 8 vezes nas páginas 27, 38, 39, 41, 45, 57, 68 e 81.
- GOULART, C. et al. MARIA: Um Robô para Interação com Crianças com Autismo. In: *XII Simpósio Brasileiro de Automação Inteligente (SBAI)*. Natal, Brasil: [s.n.], 2015. p. 557–562. Disponível em: <<http://swge.inf.br/SBAI2015/anais/164.pdf>>. Citado na página 28.
- GOURAB, K.; SCHMIT, B. D. Changes in movement-related u-band EEG signals in human spinal cord injury. *Clinical Neurophysiology*, International Federation of Clinical Neurophysiology, v. 121, n. 12, p. 2017–2023, 2010. ISSN 13882457. Disponível em: <<http://dx.doi.org/10.1016/j.clinph.2010.05.012>>. Citado na página 79.
- GUGER, C.; VAUGHAN, T.; ALLISON, B. *Brain-Computer Interface Research: A State-of-the-Art Summary 3*. Springer International Publishing, 2014. (SpringerBriefs in Electrical and Computer Engineering). ISBN 9783319099798. Disponível em: <<https://books.google.com.br/books?id=sLQjBQAAQBAJ>>. Citado 2 vezes nas páginas 27 e 81.
- GUYTON, A. C.; HALL, J. E. *Textbook of medical physiology*. 11th ed. ed. Philadelphia: Elsevier Saunders, 2006. 1116 p. ISBN 978-0-7216-0240-0. Citado 3 vezes nas páginas 15, 42 e 81.
- HADJIDJ, A. et al. Wireless sensor networks for rehabilitation applications: Challenges and opportunities. *Journal of Network and Computer Applications*, Elsevier, v. 36, n. 1, p. 1–15, 2013. ISSN 10848045. Disponível em: <<http://dx.doi.org/10.1016/j.jnca.2012.10.002>>. Citado na página 32.
- HALL, D.; LLINAS, J. An Introduction to Multisensor Data Fusion. *Proceedings of the IEEE*, v. 85, n. 1, p. 6–23, 1997. ISSN 00189219. Disponível em: <<http://ieeexplore.ieee.org/document/554205/>>. Citado na página 38.
- HASHIMOTO, Y.; USHIBA, J. EEG-based classification of imaginary left and right foot movements using beta rebound. *Clinical Neurophysiology*, v. 124, n. 11, p. 2153–2160, 2013. ISSN 13882457. Citado na página 40.

- HERMENS, H. J. et al. *European recommendations for surface electromyography*. [s.n.], 1999. 8–11 p. Disponível em: <<http://www.seniam.org/pdf/contents8.PDF>>. Citado 2 vezes nas páginas 47 e 55.
- HOGAN, N. Impedance Control: An Approach to Manipulation. In: *1984 American Control Conference*. IEEE, 1984. p. 304–313. Disponível em: <<http://ieeexplore.ieee.org/xpls/abs/all.jsp?arnumber=4788>>. Citado na página 33.
- HOMMA, K.; FUKUDA, O.; NAGATA, Y. Study of a wire-driven leg rehabilitation system. In: *IEEE/RSJ International Conference on Intelligent Robots and System*. IEEE, 2002. v. 2, p. 1451–1456. ISBN 0-7803-7398-7. Disponível em: <<http://ieeexplore.ieee.org/document/1043959/>>. Citado 2 vezes nas páginas 26 e 32.
- HU, J. et al. Training strategies for a lower limb rehabilitation robot based on impedance control. *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, v. 2012, n. 3, p. 6032–5, jan 2012. ISSN 1557-170X. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/23367304>>. Citado na página 33.
- 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, oct 2011. ISSN 1558-2531. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3235670&tool=pmcentrez&rendertype=ab>>. Citado 3 vezes nas páginas 27, 38 e 39.
- HUDGINS, B.; PARKER, P.; SCOTT, R. N. A New Strategy for Multifunction Myoelectric Control. *IEEE Transactions on Biomedical Engineering*, v. 40, n. 1, p. 82–94, 1993. ISSN 1558-2531. Citado na página 40.
- HUSEMANN, B. et al. Effects of locomotion training with assistance of a robot-driven gait orthosis in hemiparetic patients after stroke: A randomized controlled pilot study. *Stroke*, v. 38, n. 2, p. 349–354, 2007. ISSN 00392499. Citado na página 26.
- HUSTON, R. pdf. *Principles of Biomechanics*. 1st. ed. [S.l.]: CRC Press, 2008. 442 p. ISBN 9780849334948. Citado na página 90.
- IBÁÑEZ, 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 8 vezes nas páginas 27, 41, 61, 63, 71, 72, 80 e 108.
- JIANG, N. et al. A brain-computer interface for single-trial detection of gait initiation from movement related cortical potentials. *Clinical Neurophysiology*, International Federation of Clinical Neurophysiology, v. 126, n. 1, p. 154–159, 2015. ISSN 18728952. Disponível em: <<http://dx.doi.org/10.1016/j.clinph.2014.05.003>>. Citado 7 vezes nas páginas 27, 40, 41, 42, 81, 82 e 83.
- JIMÉNEZ, N. J. V. *Sistema de Reabilitação de Membros Superiores Através de Ambiente Virtual Baseado em Kinect e Sinais Mioelétricos*. Tese (Dissertação de Mestrado) — Universidade Federal do Espírito Santo, Vitória, Brasil, 2016. Citado na página 28.

- JU, M.-S. et al. A Rehabilitation Robot With Force-Position Hybrid Fuzzy Controller: Hybrid Fuzzy Control of Rehabilitation Robot. *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, v. 13, n. 3, p. 349–58, sep 2005. ISSN 1534-4320. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/16200758>>. Citado 2 vezes nas páginas 26 e 32.
- 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=ab>>. Citado 11 vezes nas páginas 27, 40, 41, 56, 71, 72, 73, 80, 81, 108 e 110.
- LATIKKA, J. A. et al. The conductivity of brain tissues: Comparison of results in vivo and in vitro measurements. *Annual Reports of the Research Reactor Institute, Kyoto University*, v. 1, p. 910–912, 2001. ISSN 04549244. Citado 2 vezes nas páginas 67 e 107.
- LEE, E. L. Y. *Decoding Self-paced Upper Limb Reaching Movements from Brain Signals*. Tese (Tese de Doutorado), Suisse, 2012. Disponível em: <<http://dx.doi.org/10.5075/epfl-thesis-5282>>. Citado na página 39.
- LOGAR, V. et al. Using ANNs to predict a subject's response based on EEG traces. *Neural Networks*, v. 21, n. 7, p. 881–887, sep 2008. ISSN 08936080. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0893608008000786>>. Citado na página 39.
- LOTERIO, F. A. *Análise do Padrão de Ativação Muscular de Indivíduos Hemiparéticos Pós-AVC em Marcha Assistida por Andador Robótico*. Tese (Doutorado) — Universidade Federal do Espírito Santo, Vitória, Brasil, 2015. Citado na página 28.
- LOTZE, M. et al. Motor learning elicited by voluntary drive. *Brain : a journal of neurology*, v. 126, n. Pt 4, p. 866–72, apr 2003. ISSN 0006-8950. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/12615644>>. Citado na página 26.
- LUINGE, H.; VELTINK, P.; BATEN, C. Ambulatory measurement of arm orientation. *Journal of Biomechanics*, v. 40, n. 1, p. 78–85, jan 2007. ISSN 00219290. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0021929005005282>>. Citado na página 41.
- MACKAY, J.; MENSAH, G. Global Burden of Stroke. In: *The Atlas of Heart Disease and Stroke*. World Health Organization, 2004. cap. The Burden, p. 50–51. ISBN 9789241562768. Disponível em: <http://www.who.int/cardiovascular{_}diseases/resources/atlas/>. Citado na página 25.
- MAXEY, L.; MAGNUSSON, J. *Rehabilitation for the postsurgical orthopedic patient*. St. Louis: Mosby, 2001. 382 p. ISBN 978-0-323-00166-3. Citado 4 vezes nas páginas 31, 85, 93 e 94.
- MELIM, R. S. *Desenvolvimento de Sistema de Análises da Marcha Humana Utilizando Sensores Inerciais e Câmera de Profundidade*. 129 p. Tese (Dissertação de Mestrado) — Universidade Federal do Espírito Santo, 2013. Citado na página 28.
- MITCHELL, T. M. *Machine Learning*. New York: McGraw-Hill, 1997. 414 p. (McGraw-Hill series in computer science). ISBN 978-0-07-042807-2. Citado 2 vezes nas páginas 59 e 65.

- MITHOEFER, K. et al. Current Concepts for Rehabilitation and Return to Sport After Knee Articular Cartilage Repair in the Athlete. *Journal of Orthopaedic & Sports Physical Therapy*, v. 42, n. 3, p. 254–273, 2012. ISSN 0190-6011. Disponível em: <<http://www.jospt.org/doi/10.2519/jospt.2012.3665>>. Citado na página 85.
- MIYAMURA, T.; MURAI, S.; TOMISAKI, H. Therapeutic Exercise Machine LX2. *Yaskawa Technical Review*, v. 67(3), p. 224–228, 2003. Citado na página 35.
- MRACHACZ-KERSTING, N. et al. An Associative Brain-Computer-Interface for Acute Stroke Patients. In: IBÁÑEZ, J. et al. (Ed.). *Converging Clinical and Engineering Research on Neurorehabilitation II: Proceedings of the 3rd International Conference on NeuroRehabilitation (ICNR2016), October 18-21, 2016, Segovia, Spain*. Cham: Springer International Publishing, 2017. p. 841–845. ISBN 978-3-319-46669-9. Disponível em: <<http://dx.doi.org/10.1007/978-3-319-46669-9>>. Citado na página 27.
- MÜLLER-PUTZ, G. R.; DALY, I.; KAISER, V. Motor imagery-induced EEG patterns in individuals with spinal cord injury and their impact on brain-computer interface accuracy. *Journal of neural engineering*, v. 11, n. 3, p. 035011, 2014. ISSN 1741-2552. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/24835837>>. Citado na página 79.
- MÜLLER, S. M. T. *Interface Cérebro-computador Baseada em Potenciais Evocados Visuais em Regime Permanente para Comando de uma Cadeira de Rodas Robótica*. 141 p. Tese (Tese de Doutorado) — Universidade Federal do Espírito Santo, 2012. Citado na página 28.
- 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=ab>>. Citado na página 26.
- MURPHY, R. Biological and Cognitive Foundations of intelligent Sensor Fusion. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, v. 26, n. 1, p. 42–51, 1996. ISSN 10834427. Disponível em: <<http://ieeexplore.ieee.org/document/477859/>>. Citado na página 38.
- NIAZI, I. K. et al. Detection of movement intention from single-trial movement-related cortical potentials. *Journal of Neural Engineering*, v. 8, n. 6, p. 066009, oct 2011. ISSN 1741-2560, 1741-2552. Disponível em: <<http://stacks.iop.org/1741-2552/8/i=6/a=066009?key=crossref.41c0c847059277825197d6300aacc6bc>>. Citado 4 vezes nas páginas 27, 40, 42 e 81.
- NIKITCZUK, J. et al. Active Knee Rehabilitation Orthotic Device With Variable Damping Characteristics Implemented via an Electrorheological Fluid. *IEEE/ASME Transactions on Mechatronics*, dec 2010. ISSN 1083-4435. Disponível em: <<http://ieeexplore.ieee.org/document/5353649/>>. Citado na página 35.
- NOVAK, D. et al. Predicting Targets of Human Reaching Motions Using Different Sensing Technologies. *IEEE Transactions on Biomedical Engineering*, v. 60, n. 9, p. 2645–2654, sep 2013. ISSN 0018-9294, 1558-2531. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6515157>>. Citado 6 vezes nas páginas 27, 38, 39, 41, 55 e 81.

OSKOEI, M. A.; HU, H. Myoelectric control systems-A survey. *Biomedical Signal Processing and Control*, v. 2, n. 4, p. 275–294, oct 2007. ISSN 17468094. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1746809407000547>>. Citado 2 vezes nas páginas 41 e 72.

OVIATT, S. Multimodal Interfaces. In: *The Human-Computer Interaction Handbook*. 2nd. ed. CRC Press, 2002. p. 413–432. ISBN 978-1-4106-1586-2. Disponível em: <https://books.google.com.br/books?id=A8TPF{_}O38>. Citado na página 38.

PENFIELD, W.; THEODORE, R. Book; Book/Illustrated. *The cerebral cortex of man : a clinical study of localization of function*. [S.l.]: New York : Hafner Pub. Co, 1968. Citado 2 vezes nas páginas 42 e 81.

PFURTSCHELLER, G.; Lopes da Silva, F. Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, v. 110, n. 11, p. 1842–1857, nov 1999. ISSN 13882457. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/10576479>>. Citado 13 vezes nas páginas 26, 27, 32, 41, 58, 61, 63, 64, 71, 73, 80, 82 e 110.

PFURTSCHELLER, G.; SOLIS-ESCALANTE, T. Could the beta rebound in the EEG be suitable to realize a “brain switch”? *Clinical Neurophysiology*, v. 120, n. 1, p. 24–29, jan 2009. ISSN 13882457. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1388245708010079>>. Citado na página 40.

PICERNO, P.; CEREATTI, A.; CAPPOZZO, A. Joint kinematics estimate using wearable inertial and magnetic sensing modules. *Gait & posture*, v. 28, n. 4, p. 588–95, nov 2008. ISSN 0966-6362. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/18502130>>. Citado na página 41.

POHL, M. et al. Repetitive locomotor training and physiotherapy improve walking and basic activities of daily living after stroke: a single-blind, randomized multicentre trial (DEutsche GAngtrainerStudie, DEGAS). *Clinical rehabilitation*, v. 21, n. 1, p. 17–27, jan 2007. ISSN 0269-2155. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/17213237>>. Citado na página 26.

PONS, J. L. *Wearable Robots: Biomechatronic Exoskeletons*. Chichester, UK: John Wiley & Sons, Ltd, 2008. 338 p. ISBN 9780470987667. Disponível em: <<http://doi.wiley.com/10.1002/9780470987667>>. Citado 2 vezes nas páginas 33 e 43.

RIENER, R. et al. Patient-cooperative strategies for robot-aided treadmill training: first experimental results. *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, v. 13, n. 3, p. 380–94, sep 2005. ISSN 1534-4320. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/16200761>>. Citado na página 33.

SCHMIDT, H. et al. Gait rehabilitation machines based on programmable footplates. *Journal of NeuroEngineering and Rehabilitation*, v. 4, n. 1, p. 2, 2007. ISSN 17430003. Disponível em: <<http://jneuroengrehab.biomedcentral.com/articles/10.1186/1743-0003-4-2>>. Citado na página 31.

SCHMITT, C.; MÉTRAILLER, P. The Motion MakerTM: a rehabilitation system combining an orthosis with closed-loop electrical muscle stimulation. In: *8th Vienna*

International Workshop on Functional Electrical. Vienna, Austria: [s.n.], 2004. p. 117–120. Disponível em: <http://infoscience.epfl.ch/record/81393/files/Paper{_}FESWS2004>. Citado 3 vezes nas páginas 15, 34 e 35.

SHARMA, R.; PAVLOVIC, V.; HUANG, T. Toward multimodal human-computer interface. *Proceedings of the IEEE*, v. 86, n. 5, p. 853–869, may 1998. ISSN 00189219. Disponível em: <http://ieeexplore.ieee.org/xpls/abs{_}all.jsp?arnumber=664275http://ieeexplore.ieee.org/document/6642>. Citado na página 38.

SMITH, D. S. et al. Remedial therapy after stroke: a randomised controlled trial. *British Medical Journal (Clinical Research Edition)*, v. 282, n. 6263, p. 517–520, 1981. Disponível em: <<http://www.ncbi.nlm.nih.gov/pmc/articles/PMC1504295/>>. Citado na página 31.

SOPRANI, D. et al. Plataforma Multimodal para Controle de Dispositivos de Reabilitação de Membros Inferiores. In: *Anais do XXIV Congresso Brasileiro de Engenharia Biomédica - CBEB 2014*. Uberlândia, Brasil: [s.n.], 2014. p. 1916–1919. ISBN 2359-3164. Disponível em: <http://www.canal6.com.br/cbeb/2014/artigos/cbeb2014{_}submission{_}5>. Citado na página 28.

SOPRANI, D. R. *Interface Multimodal com Predição de Movimentos para Uso em Reabilitação de Membros Inferiores*. Tese (Dissertação de Mestrado) — Universidade Federal do Espírito Santo, 2014. Citado 4 vezes nas páginas 15, 16, 55 e 61.

SPONG, M. W.; VIDYASAGAR, M. *Robot Dynamics and Control*. 2nd. ed. [S.l.]: Wiley, 2004. ISBN 978-0-471-61243-8. Citado na página 91.

STRONG, K.; MATHERS, C.; BONITA, R. Preventing stroke: saving lives around the world. *Lancet Neurology*, v. 6, n. 2, p. 182–187, 2007. ISSN 14744422. Citado na página 25.

TELLO, R. J. M. G. *Extração de Características e Classificação de Sinais sEMG Aplicados a Uma Prótese de Mão Virtual*. Tese (Dissertação de Mestrado) — Universidade Federal do Espírito Santo, Vitória, Brasil, 2013. Citado na página 28.

TELLO, R. J. M. G. *A Novel Approach of Independent Brain-Computer Interface Based on SSVEP*. 128 p. Tese (Tese de Doutorado) — Universidade Federal do Espírito Santo, 2016. Citado na página 28.

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 3 vezes nas páginas 25, 33 e 103.

VALADÃO, C. T. *Sistema de Supervisão e Controle para Interação Assistiva Humano-Robô*. 169 p. Tese (Tese de Doutorado) — Universidade Federal do Espírito Santo, Vitória, Brasil, 2016. Citado na página 28.

VARGAS, L. *Sensor-to-body Calibration Procedure And Definition Of Anatomical References For Gait Analysis Based On Inertial Sensors*. Tese (Dissertação de Mestrado) — Universidade Federal do Espírito Santo, Vitória, Brasil, 2015. Citado na página 28.

- VARGAS, L. et al. Body to sensor calibration procedure for lower limb joint angle estimation applied to IMU-based gait analysis. In: *proceedings of XXIV Brazilian Congress of Biomedical Engineering*. [s.n.], 2014. Disponível em: <http://www.canal6.com.br/cbeb/2014/artigos/cbeb2014{_}submission{_}2>. Citado na página 41.
- VELA, J. F. S. *Protocolos e Técnicas de Análise de Sinais sEMG Aplicados à Avaliação Motora e Robótica*. Tese (Tese de Doutorado) — Universidade Federal do Espírito Santo, Vitória, Brasil, 2013. Citado na página 28.
- VIDAURRE, C. et al. Co-adaptive calibration to improve BCI efficiency. *Journal of Neural Engineering*, v. 8, n. 2, p. 1–8, 2011. ISSN 1741-2560. Disponível em: <<http://stacks.iop.org/1741-2552/8/i=2/a=025009?key=crossref.e66f0904facbdfa5bd85770ab85085e4>>. Citado 2 vezes nas páginas 27 e 71.
- VILLA-PARRA, A. C. et al. Controle de um Exoesqueleto para Reabilitação de Joelho Baseado em Intenção de Movimento. In: *Anais do XXI Congresso Brasileiro de Automática - CBA2016*. Vitória, Brasil: [s.n.], 2016. p. 2601–2605. Citado 2 vezes nas páginas 37 e 100.
- VILLAREJO-MAYOR, J. J. *Muscle-Computer Interface Based on Pattern Recognition of Myoelectric Signals for Control of Dexterous Hand and Finger Movements of Prostheses for Forearm Amputees*. Tese (Tese de Doutorado) — Universidade Federal do Espírito Santo, Vitória, Brasil, 2017. Citado na página 28.
- WALSH, M. et al. Physical Impairments and Functional Limitations: A Comparison of Individuals 1 Year After Total Knee Arthroplasty With Control Subjects. *Physical Therapy*, v. 78, n. 3, p. 248–258, mar 1998. ISSN 0031-9023. Disponível em: <<https://academic.oup.com/ptj/article/2633260/Physical>>. Citado na página 31.
- WINSTEIN, C. J. et al. *AHA / ASA Guideline: Guidelines for Adult Stroke Rehabilitation and Recovery*. [S.l.: s.n.], 2016. 1–73 p. ISSN 0039-2499. ISBN 0000000000000. Citado na página 26.
- WINTER, D. *Biomechanics and Motor Control of Human Movement*. Fourth edi. John Wiley & Sons, 2009. ISBN 978-0-470-39818-0. Disponível em: <<https://books.google.com.br/books?id=UE-wQgAACAAJ>>. Citado na página 31.
- XU, R. et al. Enhanced low-latency detection of motor intention from EEG for closed-loop brain-computer interface applications. *IEEE Transactions on Biomedical Engineering*, v. 61, n. 2, p. 288–296, 2014. ISSN 00189294. Citado 2 vezes nas páginas 27 e 81.
- 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 2 vezes nas páginas 40 e 42.
- XU, R. et al. Factors of influence on the performance of a short-latency non-invasive brain switch: Evidence in healthy individuals and implication for motor function rehabilitation. *Frontiers in Neuroscience*, v. 9, n. JAN, p. 1–9, 2016. ISSN 1662453X. Citado na página 27.

YANG, S.; KONG, L. Research on characteristic extraction of human gait. *3rd International Conference on Bioinformatics and Biomedical Engineering, iCBBE 2009*, p. 2–5, 2009. Citado 2 vezes nas páginas 26 e 48.

YANG, Y. et al. Arm Rehabilitation Robot Impedance Control and Experimentation. In: *2006 IEEE International Conference on Robotics and Biomimetics*. IEEE, 2006. p. 914–918. ISBN 1-4244-0570-X. Disponível em: <[http://ieeexplore.ieee.org/xpls/abs{_}all.jsp?arnumber=4141987http://ieeexplore.ieee.org/document/41419](http://ieeexplore.ieee.org/xpls/abs/all.jsp?arnumber=4141987http://ieeexplore.ieee.org/document/41419)>. Citado na página 33.

ZEILIG, G. et al. Lokomat walking results in increased metabolic markers in individuals with high spinal cord injury. *International Conference on Virtual Rehabilitation, ICVR*, p. 119–120, 2015. ISSN 23319569. Citado na página 26.