



CONTROLE DE UM SISTEMA ASSISTIVO PARA MEMBRO SUPERIOR
ATIVADO COM MOVIMENTO DECODIFICADO ATRAVÉS DE SINAIS *EEG*

Elkin Yesid Veslin Díaz

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Mecânica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Mecânica.

Orientador: Max Suell Dutra

Rio de Janeiro
Abril de 2018

CONTROLE DE UM SISTEMA ASSISTIVO PARA MEMBRO SUPERIOR
ATIVADO COM MOVIMENTO DECODIFICADO ATRAVÉS DE SINAIS *EEG*

Elkin Yesid Veslin Díaz

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE)
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR
EM CIÊNCIAS EM ENGENHARIA MECÂNICA.

Examinada por:

Prof. Max Suell Dutra, Dr.-Ing.

Prof. Jules Ghislain Slama, D.Sc.

Prof. Luiz Bevilacqua, Ph.D.

Prof. Claudia Domingues Vargas, D.Sc.

Prof. Aline da Rocha Gesualdi Manhães, D.Sc.

Prof. Hans Ingo Weber, Dr.-Ing.

RIO DE JANEIRO, RJ – BRASIL

ABRIL DE 2018

Veslin Díaz, Elkin Yesid

Controle de um sistema assistivo para membro superior
ativado com movimento decodificado através de sinais
EEG/Elkin Yesid Veslin Díaz. – Rio de Janeiro:
UFRJ/COPPE, 2018.

XXIV, 225 p.: il.; 29,7cm.

Orientador: Max Suell Dutra

Tese (doutorado) – UFRJ/COPPE/Programa de
Engenharia Mecânica, 2018.

Referências Bibliográficas: p. 162 – 180.

1. Controle. 2. Bio-mecatrônica. 3. Interfaz
Cerebro Máquina. 4. Filtro de Kalman. I. Dutra, Max
Suell. II. Universidade Federal do Rio de Janeiro, COPPE,
Programa de Engenharia Mecânica. III. Título.

*A mi esposa, cuyo amor hace
todo posible.*

Agradecimentos

Quero agradecer primeiramente a Capes, CNPq e ao Finep pelo suporte no desenvolvimento deste projeto. Ao professor Max, meu orientador por me dar esta oportunidade de crescer; e aos professores Luciano e Juliana que aportaram tudo seu apoio e conhecimento durante as distintas etapas deste trabalho.

Quero agradecer a minha esposa Alejandra por tudo o apoio durante estes 4 anos de trabalho, por ser meu cômplice e me apoiar nesta etapa. A toda minha família que esteve na distância, mas sempre senti perto de mim.

Aos estudantes de Iniciação científica Gabriel, Aline, Marco, Edwiges e André, e ao técnico Marco, que suportaram e ajudaram durante toda a etapa experimental.

E a todos os amigos do *LabRob*, *CEFET* e o *Laboratorio de Fisiologia da Cognição* do *CCS* muito obrigado.

E ao pai Deus que sabe tudo, e tem certeza de tudo. Gracias totales!

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

CONTROLE DE UM SISTEMA ASSISTIVO PARA MEMBRO SUPERIOR
ATIVADO COM MOVIMENTO DECODIFICADO ATRAVÉS DE SINAIS *EEG*

Elkin Yesid Veslin Díaz

Abril/2018

Orientador: Max Suell Dutra

Programa: Engenharia Mecânica

Neste projeto de pesquisa foi estudado e desenvolvido um sistema *BCI* (*Brain Computer Interface*) para servir como plataforma de controle do movimento do cotovelo humano, usando sinais *EEG* (eletroencefalograma) relacionados com ações reais e imaginárias de flexão-extensão. Foi realizada uma ampla revisão bibliográfica nas áreas de processamento de sinais *EEG* e as respectivas estratégias para a decodificação, classificação e controle. Para decodificar a posição, velocidade e aceleração do movimento do cotovelo desde sinais *EEG* foi utilizado o Filtro de Kalman. Enquanto que, para a classificação foi usada uma integração de *SVM* (*Support Vector Machine*) com *LDA* (*Linear Discriminant Analysis*). A dinâmica modelada para o braço foi integrada ao Filtro de Kalman a partir da técnica de *Differential Flatness* para determinar a energia necessária para produzir o movimento desejado. Essa integração em um *BCI* de cadeia fechada através de um controlador *PID*, foi associada a um laço de referência para permitir que o sistema assistivo proposto pudesse dirigir o movimento do braço. Os resultados obtidos confirmaram a hipótese de que é possível controlar com maior precisão o movimento da articulação do cotovelo a partir de sinais *EEG* relacionadas com ações reais e imaginárias.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

CONTROL OF AN ASSISTIVE DEVICE FOR UPPER ACTIVATED WITH
DECODED MOVEMENTS THROUGH *EEG* SIGNALS

Elkin Yesid Veslin Díaz

April/2018

Advisor: Max Suell Dutra

Department: Mechanical Engineering

In this research project a *BCI* (*Brain Computer Interface*) system to serve as control platform for human elbow flexion/extension movement was studied and developed. *EEG* signals related with real and imaginary actions of arm flexion/extension movements were used. A comprehensive bibliographic revision in *EEG* signal processing and associated techniques for decoding, classification and control has been developed. In order to decode from *EEG* signals elbow related kinematics: position, velocity and acceleration; a Kalman Filter was used. While for signal classification was implemented an integration of *SVM* (*Support Vector Machine*) and *LDA* (*Linear Discriminant Analysis*). A dynamic model of the human arm was integrated with the Kalman Filter through *Differential Flatness* in order to determine the necessary amount of energy to produce the desired movement. Both systems was embedded into a close loop *BCI* through a *PID* controller, a reference loop that allows to the proposed assistive system to drive the arm movement was added. The results obtained confirms that it is feasible to control the elbow movement using *EEG* signals related with real and imaginary actions with a higher precision.

Sumário

Lista de Figuras	xii
Lista de Tabelas	xix
Lista de Símbolos	xx
Lista de Abreviaturas	xxiii
1 Introdução	1
1.1 Motivação	2
1.1.1 A Deficiência motora	3
1.2 Objetivo da pesquisa	5
1.2.1 Objetivos Secundários	6
1.3 Contribuições da pesquisa	7
2 Estado da Técnica	8
2.1 Os <i>Wearable Robots</i> e os primeiros conceitos de tecnologia robótica para o uso humano	8
2.2 Interfaces Cérebro Computador <i>BCI</i>	10
2.2.1 Interfaces Cérebro Computador <i>BCI</i> híbridos	11
2.2.2 <i>BCI</i> para a assistência motriz	13
2.3 <i>Wearable Robots</i> para a assistência motriz	14
2.3.1 Terapias Assistivas	14
2.4 Estratégias de controle para os exoesqueletos assistivos	16
2.4.1 Controle por impedância e admitância	17
2.4.2 Controle adaptativo	18
2.5 Comando dos movimentos angulares nos exoesqueletos assistivos	19
2.5.1 Decodificação da velocidade de movimento através do <i>EEG</i>	21
2.5.2 Decodificação da posição angular	22
3 Classificação de Sinais Cerebrais	27
3.1 Materiais e métodos	28

3.1.1	Paradigma Experimental	29
3.2	Comportamento oscilatório do sinal	30
3.3	Classificação do movimento	34
3.3.1	Pré-processamento	34
3.3.2	Determinação do Conjunto de Exemplos	35
3.3.3	Etapa de Classificação	39
3.3.4	Resultados do Treinamento	43
3.4	Discussão	57
4	Codificação da Cinemática do movimento do Cotovelo, métodos e treinamento	60
4.1	O Estimador de Kalman	60
4.1.1	Operação do Filtro	61
4.1.2	Algoritmo do Filtro de Kalman	64
4.2	Decodificação do movimento do cotovelo	65
4.2.1	Processo de aprendizado	66
4.3	Treinamento do Filtro de Kalman	67
4.3.1	Validação Cruzada	69
4.3.2	Resultados do Treinamento	70
4.3.3	Coefficiente de Correlação	74
4.3.4	Movimentos Descendentes	77
4.3.5	Variação da reposta do modelo	77
4.3.6	Relação entre as matrizes A e H com o Erro de Estimação do modelo	82
4.4	Imposição do movimento	85
4.5	Treinamento do filtro de Kalman para decodificar movimentos imaginários	91
4.5.1	Análise do modelo	92
4.6	Discussão	97
5	Dinâmica Sistema Antebraço - Motor	100
5.1	Estudo anatômico	100
5.1.1	Planos de Rotação	101
5.1.2	Anatomia do braço humano	102
5.1.3	Antropometria	103
5.2	Análise Dinâmica	106
5.2.1	Motor Elétrico	106
5.2.2	Modelo Matemático do Sistema	107
5.3	Comportamento plano do modelo dinâmico	111
5.3.1	Determinação da trajetória do movimento	112

5.4	Configuração do controlador	112
5.5	Integração do Filtro de Kalman com a dinâmica do braço	117
6	Resultados e Discussões	121
6.1	Resultados Validação Filtro de Kalman	121
6.1.1	Resposta do Filtro de Kalman	121
6.1.2	Resposta do Filtro de Kalman para processos imaginários . . .	126
6.2	Simulação da dinâmica do braço e controle	129
6.2.1	Observações	132
6.3	Integração Filtro de Kalman e a Dinâmica	134
6.3.1	Movimentos Ascendentes Reais	135
6.3.2	Movimentos Descendentes Reais	137
6.3.3	Movimentos ascendentes imaginários	143
6.3.4	Movimentos descendentes imaginários	145
6.3.5	Desempenho Classificador	149
6.4	Discussão	153
6.4.1	Filtro de Kalman	153
6.4.2	Dinâmica do Braço e integração com o Filtro de Kalman . . .	156
7	Conclusões e trabalhos futuros	159
7.1	Conclusões	159
7.2	Trabalhos futuros	161
	Referências Bibliográficas	162
A	Curvas de Erro de Generalização e F1 Score durante a Classificação	181
A.1	Janelas de 1000 ms	181
A.2	Janelas de 500 ms	184
A.3	Janelas de 70 ms	186
B	Respostas do Filtro de Kalman na fase de Treinamento	189
B.1	Treinamento movimento Descendente	189
B.2	Treinamento movimento Ascendente Imaginário	194
B.3	Treinamento movimento Descendente Imaginário	199
C	Biologia do Cérebro	204
C.1	A teoria do Movimento	205
C.2	O Sistema Nervoso Periférico	207
C.3	O Sistema Nervoso Central	208
C.3.1	O Córtex Cerebral	209
C.3.2	O Córtex Motor	211

C.3.3	A Biologia do Movimento	211
C.4	Descrição da Atividade Neural	212
C.4.1	Geração do <i>EEG</i>	214
C.4.2	Atividades rítmicas do <i>EEG</i>	216
C.5	Electroencefalograma	218
C.5.1	Preprocessamento do Sinal	220
C.6	Descrição da atividade elétrica	221
C.6.1	ERP	221
C.6.2	Eventos <i>time-locked</i> e <i>phase-locked</i>	222
C.6.3	Sincronização/Dessincronização Relacionada a Eventos	224

Lista de Figuras

1.1	Sistema <i>BCI</i> Proposto.	6
2.1	Estrutura de um hBCI	12
2.2	Esquema de controle clássico	17
3.1	Localização dos eletrodos em torno do crânio segundo a disposição do sistema 10-10 modificado. Imagem original obtida do software <i>EEGLab</i> do <i>MATLAB</i> ®.	29
3.2	Demonstração da rotina de toma de dados no voluntário.	30
3.3	Descrição dos comandos na tela.	31
3.4	Espectrograma do canal C_3 no voluntário 1 durante o movimento	32
3.5	Energia média do <i>EMG</i> e sensor de movimento ao longo dos trials em que se efetuara ação.	33
3.6	Espectrograma do canal C_3 no Voluntário 1 durante Não movimento	34
3.7	Etapas do pré-processamento para o <i>EEG</i> extraído em todos os voluntários.	35
3.8	Comparação do movimento com a atividade <i>EEG</i> da banda alfa	36
3.9	Etapas da conformação do conjunto de exemplos.	39
3.10	Atributos projetados no novo espaço dimensional, e a fronteira de decisão definida pela função $f(x)$	41
3.11	Validação cruzada de N -Folds O erro de Validação cruzada é a média dos erros de cada <i>fold</i>	43
3.12	Etapas da fase de treinamento	43
3.13	Resultado da Validação Cruzada.	46
3.14	F1 Score Médio da validação	47
3.15	Resultado de treinamento como os melhores parâmetros avaliados na Validação cruzada	48
3.16	Classificação do set de <i>teste</i>	48
3.17	Evolução da discriminação das classes ao adicionar mais canais no vetor de exemplos.	50
3.18	Resultado da Validação Cruzada.	51

3.19	F1 Score Médio da validação	52
3.20	Resultado de treinamento como os melhores parâmetros avaliados na Validação cruzada	52
3.21	Classificação do set de <i>teste</i>	53
3.22	Resultado da Validação Cruzada.	54
3.23	F1 Score Médio da validação	55
3.24	Resultado de treinamento como os melhores parâmetros avaliados na Validação cruzada	55
3.25	Classificação do set de <i>teste</i>	56
3.26	Redução do erro de classificação em todos os voluntários.	58
4.1	Descrição do algoritmo do Filtro de Kalman.	64
4.2	Mapa da coerência entre canais respeito ao canal C_3	68
4.3	Média da coerência ao longo dos trials em torno de C_3	69
4.4	Resposta da estimação de acordo à variância dos parâmetros <i>lag</i> e Δ_t nas fases de validação e treinamento para movimentos ascendentes. O intervalo delimitado pelo quadro vermelho na zona de baixo EQM é mostrado amplificado à direita.	71
4.5	Resposta da estimação de acordo com a variação de Δ_t nas fases de validação e treinamento para todos os voluntários.	72
4.6	Resposta da estimação de acordo com o número de canais nas fases de validação e treinamento para movimentos ascendentes.	73
4.7	Resposta da estimação de acordo com a frequência nas fases de va- lidação e treinamento para movimentos ascendentes.	74
4.8	Coefficiente de Correlação Médio para movimentos ascendentes em função do parâmetro Δ_t para todos os voluntários	75
4.9	Coefficiente de Correlação Médio para movimentos ascendentes em função do número de canais para todos os voluntários	75
4.10	Coefficiente de Correlação Médio para movimentos ascendentes em função da frequência para todos os voluntários	76
4.11	Distribuição do Erro Quadrático Médio para a estimação da posição, velocidade e aceleração angular	78
4.12	Variação dos coeficientes das matrizes \mathbf{A} e \mathbf{H} ao longo dos voluntários	79
4.13	Variação dos coeficientes das matriz \mathbf{H}	81
4.14	Distribuição do sinal <i>EEG</i> para os três canais implementados para treinar o modelo.	82

4.16	Variabilidade do movimento durante o ascenso e o descenso. Destaca-se a alta variância existente nos movimentos ascendentes, entretanto no descenso o comportamento do movimento é homogêneo ao longo dos trials.	83
4.15	Gráfico de dispersão que compara a magnitude da norma de Frobenius de \mathbf{H} com o <i>EQM</i> Médio ao longo dos voluntários.	84
4.17	Gráfico de dispersão que compara a magnitude da norma de Frobenius da matriz \mathbf{A} com o <i>EQM</i> Médio para os voluntários em movimentos ascendentes e descendentes.	86
4.18	Gráfico de dispersão que compara a magnitude da norma de Frobenius da matriz \mathbf{A} com o desvio padrão da posição, velocidade e aceleração no ascenso.	87
4.19	Gráfico de dispersão que compara a magnitude da norma de Frobenius da matriz \mathbf{A} com o desvio padrão da posição, velocidade e aceleração no descenso.	88
4.20	Variação do Erro Quadrático Médio durante o ascenso usando o modelo da matriz \mathbf{A} ideal em todos os voluntários.	90
4.21	Gráfico de dispersão que compara a magnitude da norma de Frobenius da matriz \mathbf{A} com o <i>EQM</i> Médio para os voluntários em movimentos ascendentes usando a matriz \mathbf{A} ideal.	90
4.22	Variação da frequência no canal C_3 no Voluntário 1. Pode-se observar a dessincronização na banda alfa com um incremento após os 2000 ms, quando se inicia o processo de imaginação motora.	92
4.23	Erro quadrático médio do movimento estimado para atividades imaginárias.	93
4.24	Variação dos coeficientes das matrizes \mathbf{A} e \mathbf{H} ao longo de todos os voluntários.	93
4.25	Variação das magnitudes dos coeficientes da matriz \mathbf{H} respeito ao estado.	94
4.26	Gráfico de dispersão que compara a magnitude da norma de Frobenius da matriz \mathbf{A} com o <i>EQM</i> Médio ao longo dos voluntários em movimentos imaginários ascendentes	95
4.27	Gráfico de dispersão que compara a magnitude da norma de Frobenius de \mathbf{H} com o <i>EQM</i> Médio ao longo dos voluntários.	95
4.28	Gráfico de dispersão que compara a magnitude da norma de Frobenius de \mathbf{H} com o <i>EQM</i> Médio ao longo dos voluntários. Usando $\ \mathbf{A}\ > 3$	96
4.29	Erro quadrático médio do movimento estimado para atividades imaginárias usando $\ \mathbf{A}\ > 3$	96

5.1	Planos de referência usados para descrever a orientação dos movimentos de cada articulação.	101
5.2	Divisão do braço através dos segmentos.	102
5.3	Estrutura do braço humano.	104
5.4	Mobilidade do braço ao longo do plano sagital.	104
5.5	Representação da Estrutura Antebraço/Mão.	107
5.6	Descrição da Trajetória de referência e a velocidade e aceleração respectivas.	113
5.7	Torque no Motor requerido para efetuar o Movimento	114
5.8	Sistema de Controle do braço	115
5.9	Laço aberto integrando o Filtro de Kalman com os Modelos plano e Dinâmico do braço.	118
5.10	Comparação de uma sequencia de entradas estimadas e real.	119
5.11	Sistema compensatório proposto para a entrada estimada.	120
6.1	Decodificação do movimento ascendente	122
6.2	Relação Norma de A e Erro Quadrático Médio	123
6.3	Decodificação do movimento	124
6.4	Relação Norma de A e Erro Quadrático Médio	125
6.5	Norma	127
6.6	Decodificação do movimento imaginário	128
6.7	Controle do Braço em movimento ascendente e descendente.	130
6.8	Erro de seguimento da trajetória	131
6.9	Descrição do Movimento do braço.	131
6.10	Controle da posição respeito a trajetória	132
6.11	Correção da posição de acordo com a ação de controle.	133
6.12	Corrente e tensão de entrada no motor elétrico	133
6.13	Corrente e tensão de entrada no motor elétrico com $\omega_n = 1.5$	134
6.14	Decodificação estados do braço e seguimento do movimento para um $\Delta_t = 1ms$	136
6.15	Decodificação estados do braço e seguimento do movimento para um $\Delta_t = 150ms$	138
6.16	Erros de estimação e seguimento da trajetória respeito ao parâmetro de configuração Δ_t	139
6.17	Erro de Seguimento da posição em função de Δ_t	139
6.18	Ação corretiva Média em Watios dos Controladores.	140
6.19	Decodificação estados do braço e seguimento do movimento descendente para um $\Delta_t = 70ms$	141

6.20	Erros de estimação e seguimento da trajetória descendente respeito ao parâmetro de configuração Δ_t	142
6.21	Erro de Seguimento do movimento descendente em função de Δ_t . . .	142
6.22	Ação corretiva Média em Vátios dos Controladores para movimentos descendentes.	143
6.23	Decodificação estados do braço e seguimento do movimento ascendente imaginário para um $\Delta_t = 30\text{ms}$	144
6.24	Erros de estimação e seguimento da trajetória ascendente imaginária e respeito ao parâmetro de configuração Δ_t	145
6.25	Erro de Seguimento do movimento descendente imaginário em função de Δ_t	146
6.26	Ação corretiva Média em Vátios dos Controladores para movimentos imaginários ascendentes.	146
6.27	Erros de estimação e seguimento da trajetória descendente imaginaria respeito ao parâmetro de configuração Δ_t	147
6.28	Erro de Seguimento do movimento descendente imaginário em função de Δ_t	147
6.29	Ação corretiva Média em Vátios dos Controladores para movimentos descendentes imaginários.	148
6.30	Distribuição do erro de seguimento.	149
6.31	Seguimento de uma trajetória puramente decodificada.	150
6.32	Distribuição do erro do movimento.	151
6.33	Erro de Classificação Médio durante o Ascenso.	152
6.34	Erro de Classificação durante o Descenso.	152
A.1	Resultado da Validação Cruzada e F1 Score No Voluntário 2.	181
A.2	Resultado da Validação Cruzada e F1 Score No Voluntário 3.	182
A.3	Resultado da Validação Cruzada e F1 Score No Voluntário 4.	182
A.4	Resultado da Validação Cruzada e F1 Score No Voluntário 5.	183
A.5	Resultado da Validação Cruzada e F1 Score No Voluntário 2.	183
A.6	Resultado da Validação Cruzada e F1 Score No Voluntário 2.	184
A.7	Resultado da Validação Cruzada e F1 Score No Voluntário 3.	184
A.8	Resultado da Validação Cruzada e F1 Score No Voluntário 4.	185
A.9	Resultado da Validação Cruzada e F1 Score No Voluntário 5.	185
A.10	Resultado da Validação Cruzada e F1 Score No Voluntário 2.	186
A.11	Resultado da Validação Cruzada e F1 Score No Voluntário 2.	186
A.12	Resultado da Validação Cruzada e F1 Score No Voluntário 3.	187
A.13	Resultado da Validação Cruzada e F1 Score No Voluntário 4.	187
A.14	Resultado da Validação Cruzada e F1 Score No Voluntário 5.	188

A.15	Resultado da Validação Cruzada e F1 Score No Voluntário 2.	188
B.1	Resposta da estimação de acordo à variação dos parâmetros lag de Δ_t nas fases de validação e treinamento para movimentos Descendentes.	189
B.2	Resposta da estimação de acordo à variação de Δ_t nas fases de validação e treinamento para todos os voluntários.	190
B.3	Resposta do Erro Quadrático Médio de acordo ao número de canais nas fases de validação e treinamento para movimentos descendentes.	191
B.4	Resposta do Erro Quadrático Médio de acordo à frequência nas fases de validação e treinamento para movimentos descendentes.	192
B.5	Coefficiente de Correlação Médio para movimentos descendentes em função do parâmetro Δ_t para todos os voluntários	192
B.6	Coefficiente do Erro Quadrático Médio para movimentos descendentes em função do número de canais para todos os voluntários	193
B.7	Coefficiente de Correlação Médio para movimentos descendentes em função da frequência para todos os voluntários	193
B.8	Resposta da estimação de acordo à variação dos parâmetros lag de Δ_t nas fases de validação e treinamento para movimentos ascendentes imaginários.	194
B.9	Resposta da estimação de acordo à variação de Δ_t nas fases de validação e treinamento para todos os voluntários.	195
B.10	Resposta do Erro Quadrático Médio de acordo ao número de canais nas fases de validação e treinamento para movimentos ascendentes.	196
B.11	Resposta do Erro Quadrático Médio de acordo à frequência nas fases de validação e treinamento para movimentos ascendentes.	197
B.12	Coefficiente de Correlação Médio para movimentos ascendentes em função do parâmetro Δ_t para todos os voluntários	197
B.13	Coefficiente do Erro Quadrático Médio para movimentos ascendentes em função do número de canais para todos os voluntários	198
B.14	Coefficiente de Correlação Médio para movimentos ascendentes em função da frequência para todos os voluntários	198
B.15	Resposta da estimação de acordo à variação dos parâmetros lag de Δ_t nas fases de validação e treinamento para movimentos descendentes imaginários.	199
B.16	Resposta da estimação de acordo à variação de Δ_t nas fases de validação e treinamento para todos os voluntários.	200
B.17	Resposta do Erro Quadrático Médio de acordo ao número de canais nas fases de validação e treinamento para movimentos descendentes imaginários.	201

B.18	Resposta do Erro Quadrático Médio de acordo à frequência nas fases de validação e treinamento para movimentos descendentes.	202
B.19	Coefficiente de Correlação Médio para movimentos descendentes em função do parâmetro Δ_t para todos os voluntários	202
B.20	Coefficiente do Erro Quadrático Médio para movimentos descendentes em função do número de canais para todos os voluntários	203
B.21	Coefficiente de Correlação Médio para movimentos descendentes em função da frequência para todos os voluntários	203
C.1	Controle do movimento do Braço segundo a teoria dos Modelos Internos	207
C.2	Esquema do Sistema Nervoso Central. Imagem extraída de [1]	208
C.3	Localização dos Giros Pré-Central e Pós-Central no Cérebro e regiões cerebrais. Imagem feita pelo autor.	210
C.4	Secção frontal do Córtex Motor no Hemisfério Direito do cérebro, relacionando cada parte do corpo com o tamanho da região usada para seu controle. Extraído de Noback et al., [2]	212
C.5	Ilustração do Neurônio. Imagem extraída e modificada do portal web GettyImages.	213
C.6	Potencial de Ação da membrana.	213
C.7	Movimentação da Corrente elétrica causado pela inibição e excitação do neurônio	215
C.8	Descrição dos ritmos EEG segundo a frequência.	217
C.9	Localização dos Eletrodos segundo o Sistema Internacional 10-20. . .	219
C.10	<i>ERP</i> resultante no movimento do braço direito no Canal C_1	223
C.11	Passos para a obtenção do ERD/ERS.	225

Lista de Tabelas

3.1	Descrição do Conjunto de exemplos final	39
3.2	Número de Exemplos usados pelo classificador em cada voluntário em função do janelamento dos intervalos do sinal de cada classe (1000, 500 e 70 ms).	45
3.3	Quantificação dos atributos segundo o <i>FDR</i> para todos os voluntários.	45
3.4	Resultados da classificação dos exemplos de <i>teste</i> em todos os voluntários usando janelas de 1000 ms. Apresenta-se o erro e o respectivo <i>F1 Score</i> , como também os parâmetros que minimizaram o erro de generalização em cada voluntário.	49
3.5	Resultados da classificação de <i>teste</i> para todos os voluntários usando janelas de 500 ms. Apresenta-se o erro e o respectivo <i>F1 Score</i> , como também os parâmetros usados para a redução dimensional e a classificação dos dados.	53
3.6	Resultados da classificação de <i>teste</i> para todos os voluntários usando janelas de 70 ms. Apresenta-se o erro e o respectivo <i>F1 Score</i> , como também os parâmetros usados para a redução dimensional e a classificação dos dados.	56
4.1	Distribuição dos Coeficientes da Matriz do Sistema A para todos os voluntários para movimentos ascendentes e descendentes.	80
5.1	Valores morfológicos dos segmentos do braço.	105
5.2	Dados do Motor Maxon CC RE 50. Fornecidos pelo fabricante.	106
6.1	Resultado da Validação por voluntário durante movimentos ascendentes.	123
6.2	Resultado da Validação por voluntário durante movimentos descendentes.	125
6.3	Resultado da Validação por voluntário durante movimentos ascendentes imaginários.	129

Lista de Símbolos

C	Coefficiente de Regularização do <i>SVM</i> , p. 64
I_m	Momento de Inércia do Motor, p. 126
I_n	Momento de inércia do n -ésimo segmento que conforma o braço, p. 125
L_m	Inductância de Armadura, p. 126
N	Relação do redutor, p. 126
$P(\mathbf{x}_k \mathbf{z}_k)$	Probabilidade do estado \mathbf{x}_k em função da medição \mathbf{z}_k , p. 83
R_m	Resistência de Armadura, p. 126
Δ_t	Parâmetro de configuração que define o tempo entre amostras em milissegundos., p. 87
$\hat{\mathbf{x}}_k$	Estado estimado de x_k <i>a posteriori</i> no tempo t_k ., p. 82
$\hat{\mathbf{x}}_k^-$	Estado estimado de x_k <i>a priori</i> no tempo t_k ., p. 82
$\ \cdot\ $	Norma da Matriz., p. 111
\mathbf{A}	Matriz que relaciona linearmente o estado \mathbf{x}_k com \mathbf{x}_{k+1} ., p. 81
\mathbf{H}	Matriz que relaciona linearmente o estado \mathbf{x}_k com a medição \mathbf{z}_k ., p. 81
\mathbf{I}	Matriz unitária., p. 82
\mathbf{K}_k	Matriz do ganho de Kalman no tempo t_k ., p. 81
\mathbf{P}_k	Matriz de covariância do erro estimado no tempo t_k ., p. 81
\mathbf{Q}	Matriz de covariância do ruído do modelo do estado., p. 81
\mathbf{R}	Matriz de covariância do ruído do modelo da medição., p. 81

T	Matriz do conjunto de exemplos , p. 59
\mathbf{T}_i	i -ésima janela do conjunto de exemplos , p. 57
W	Matriz de Autovetores, p. 60
X	Matriz de Atributos que faz parte do Conjunto de Exemplos, p. 59
\mathbf{X}_j	j -ésimo Canal da Matriz de Atributos , p. 59
Y	Vetor de etiquetas que faz parte do Conjunto de Exemplos , p. 59
Z	Conjunto de Atributos projetados pelos Autovetores W , p. 60
\mathbf{v}_k	Vetor do ruído branco do modelo da medição no tempo t_k ., p. 81
w	Conjunto de autovetores correspondentes a uma direção específica, p. 60
\mathbf{w}_k	Vetor do ruído branco do modelo do estado no tempo t_k ., p. 81
\mathbf{x}_k	Vetor de estados que representa a posição, velocidade e aceleração do cotovelo no tempo t_k ., p. 81
\mathbf{z}_k	Vetor de medições no tempo t_k ., p. 81
θ, θ_0	Coefficientes da função discriminante $f(x)$, p. 60
$\tilde{\mathbf{y}}_k$	Saída associada do modelo dinâmico com entrada estimada no tempo t_k , p. 138
b_m	Coefficiente de Atrito Dinâmico do Motor, p. 126
c	Parâmetro de configuração que define o número de canais usado , p. 87
$f(x)$	Função linear discriminante, p. 60
k_a	Constante de torque média do Motor, p. 126
k_b	Constante de velocidade média do Motor, p. 126
l_n	Comprimento do n -ésimo segmento que conforma o braço, p. 125

m_n	Masa do n -ésimo segmento que conforma o braço, p. 125
$x_{i,m}^j$	m -ésimo atributo do j -ésimo canal do i -ésimo exemplo , p. 59
y_i	Etiqueta do i -ésimo exemplo , p. 59
CM_n	Posição do centro de massa do n -ésimo segmento do braço, p. 127
Q_m	Torque total do sistema, p. 130
\ddot{q}_n, ω_n	Aceleração angular do n -ésimo segmento , p. 127
\dot{q}_m	Velocidade angular do motor , p. 129
\dot{q}_n, ω_n	Velocidade angular do n -ésimo segmento , p. 127
\hat{u}_k	Entrada estimada do sistema no tempo t_k , p. 138
$\mathbf{C}(q, \dot{q})$	Matriz de Forças Centrifugas e de Coriolis , p. 132
$\mathbf{K}(q)$	Matriz de Forças Gravitacionais , p. 132
$\mathbf{Q}(\dot{q}, q)$	Matriz que caracteriza os atuadores do sistema , p. 132
τ_d	Efeitos dissipativos relacionados com o amortecimento da junta, p. 130
τ_m	Torque motor, p. 130
$\mathbf{M}(q)\ddot{q}$	Matriz de Inercia, p. 132
b_l	Coefficiente de atrito dinâmico, p. 130
e_k	Erro entre a saída associada e a saída de referencia no tempo t_k , p. 140
g	Força de Gravidade, p. 129
q_m	Posição angular do motor , p. 129
q_n	Posição angular do n -ésimo segmento , p. 127
u_k	Entrada do sistema no tempo t_k , p. 132
y_k	Saída do sistema no tempo t_k , p. 132

Lista de Abreviaturas

BCI	Brain Computer Interface - Interface Cérebro Computador, p. 2
BMI	Brain Machine Interface - Interface Cérebro Máquina, p. 26
CC	Coefficiente de Correlação, p. 87
DAQ	Data Acquisition, p. 36
EEG	Electroencefalografia, p. 2
EMG	Electromiografia, p. 12
EQM	Erro Quadrático Médio, p. 87
ERD	Event Related Desynchronization - Dessincronização de Eventos Relacionados, p. 44
ERP	Event Related Potentials - Potenciais de Eventos Relacionado, p. 8
ERSP	Event Related Spectral Perturbation, p. 51
ERS	Event Related Synchronization - Sincronização de Eventos Relacionados, p. 44
FFT	Fast Fourier Transform, Transformada Rápida de Fourier, p. 52
HMI	Human Machine Interface - Interface Humano Máquina, p. 2
ICA	Independet Component Analisis, p. 41
IM	Imagética Matora, p. 10
LDA	Linear Discriminant Analysis, p. 60
M1	Córtex Motor, p. 85

MEG	Magnetoencefalograma, p. 8
NIRS	Near-infrared spectroscopy - Espectroscopia de Reflectância de Infravermelho Próximo, p. 8
PA	Potencial de Ação, p. 33
PCA	Principal Component Analysis, p. 60
SCP	Slow Cortical Potentials, p. 8
SNR	Signal-to-Noise Ratio - Relação Sinal Ruído, p. 41
SSEP	Somatosensory Evoked Potential - Potencias Evocados Somatosensitivos, p. 8
SVM	Support Vector Machine, p. 61
UFRJ	Universidade Federal do Rio de Janeiro, p. 2
fMRI	Functional Magnetic Resonance Imaging - Imagem por Resonância Magnética Funcional, p. 8

Capítulo 1

Introdução

O Laboratório de Robótica e Mecatrônica do Programa de Engenharia Mecânica da *COPPE/UFRJ* tem trabalhado em numerosos projetos de pesquisa nas áreas da engenharia mecânica, na robótica, e mais recentemente na emergente biomecatrônica, dada a crença que fomentar a implementação de novas tecnologias para o benefício da sociedade, contribui diretamente para o desenvolvimento integral do país. É por isso que é de vital importância a elaboração de projetos com alto impacto social, que procuram o benefício e bem-estar da sociedade, identificando os problemas do entorno e determinando como as tecnologias atuais podem ser usadas para sua resolução.

Recentemente, as inovações técnicas tem possibilitado com grande sucesso a introdução da engenharia mecatrônica em outras áreas do conhecimento, como as ciências biológicas e as ciências da saúde, criando um novo campo de pesquisa denominado como Engenharia Biomecatrônica [3]. Nesta nova área a eletrônica é usada para permitir ao sistema entrar em contato com distintos sinais biológicos, possibilitando a integração com dispositivos mecânicos e de controle adaptáveis e em sinergia ao sistema biológico alvo. Exoesqueletos assistivos, cadeiras de rodas automáticas, interfaces de comunicações, e próteses inteligentes são alguns exemplos destes dispositivos biomecatrônicos, cuja principal diferença com a ciência assistiva tradicional, é a existência de realimentação entre o sistema biológico e o equipamento assistivo. Contudo, se requiere de um conhecimento específico para integrar o sistema proposto com sinais cerebrais, portanto, em parceria com o Laboratório da Fisiologia da Cognição do *IBCCF/UFRJ* integramos conhecimentos para poder levar a cabo este projeto.

Através de sistemas bio-inspirados é possível desenvolver sistemas robóticos que são adequados e bem comportados à cinemática e dinâmica do corpo, desta forma, pode-se desenvolver dispositivos capazes de auxiliar na dinâmica de movimentação corporal de pessoas com limitações ao movimento, seja para atividades cotidianas ou para as de alto desempenho; ou sistemas robóticos que estendem as possibilidades

biológicas do organismo facilitando por exemplo, o levantamento de cargas; ou um mecanismo que substitua o membro perdido efetuando movimentos similares aos naturais, realizando a tarefa de uma prótese, com a mobilidade próxima ao membro natural.

As ferramentas de interação entre o dispositivo e o usuário são classificadas como *Interfaces Humano Máquina* (*HMI* pela abreviação em idioma inglês) e *Interfaces Cérebro Computador* (*BCI* pela abreviação em idioma inglês). Sensores, atuadores, dispositivos de energia, de processamento e conexão a redes complementam esta integração homem-máquina, criando um todo em que o objetivo está em tentar prever as necessidades do usuário, o mais rápido possível e com a maior precisão que o sistema possa fornecer.

O laboratório de robótica e mecatrônica da UFRJ tem apresentado interesse nesta área da engenharia, desenvolvendo projetos focados no entendimento do funcionamento do corpo humano visando criar adaptações robóticas baseadas na integração com o membro e seu uso em pessoas com incapacidade motriz ou para a substituição de membros amputados. Entre estes projetos de pesquisas se destaca o estudo de sistemas bípedes [4],[5], próteses para a mão [6],[7], [8] e o braço humano [9], [10].

Em um dos projetos citados [8] a informação proveniente do movimento muscular das articulações da mão foi usada para controlar a ativação dos atuadores de uma mão robótica, em tempo real através de redes neurais artificiais. Consequentemente o passo seguinte foi o início da pesquisa de como utilizar diretamente sinais do cérebro (captadas com *EEG*) para comandar um dispositivo. Trabalhos prévios sobre a cinemática e dinâmica de um exoesqueleto para membros superiores [11] cimentam a base para continuar com a linha de pesquisa e indagando sobre a possibilidade de integrar ao projeto o uso de sinais cerebrais integradas no sistema assistivo.

Por outro lado se fez necessário revisar o estado da técnica, com o objetivo de definir o caminho para a elaboração de um projeto de pesquisa de doutorado que pudesse produzir contribuições científicas para a área. É importante conhecer a direção das pesquisas sobre os sistemas assistivos para membros superiores controlados por sinais biológicos. Este levantamento fundamentará o presente trabalho.

1.1 Motivação

Existe uma potencial contribuição social do projeto, focada no desenvolvimento de uma ferramenta para a assistência de pessoal com deficiência, contudo se faz necessário recopilar informação que permita quantificar o impacto que o desenvolvimento deste trabalho pode ter tanto a nível regional como também internacional.

Nesta seção é explorada a realidade da deficiência motora, como doença e o que representa percentualmente na população.

1.1.1 A Deficiência motora

A paralisia causada por danos na medula espinhal ou no cérebro e outras doenças relacionadas, é um problema de saúde pública e tem-se convertido na segunda causa de mortalidade no Brasil e no mundo [12]. Estas doenças causam danos neurológicos que alteram as funções sensoriomotoras causando dificuldades no movimento das articulações, limitações sobre a postura, coordenação e manipulação. Estas lesões identificadas como deficiências motoras, podem ser adquiridas desde o nascimento, na gravidez, por infecções ou acidentes e trauma, e causam restrições no desempenho de atividades laborais, de circulação, de lazer, entre outras, gerando dificuldades para a integração social e produtiva do indivíduo. Problemas associados à funcionalidade motora geram no indivíduo debilidade muscular, espasticidade, decremento dos reflexos, perda de coordenação motora e apraxia [13].

Segundo o Censo 2010 [14] 7% da população total do país (4,4 milhões de pessoas) apresentam algum tipo de deficiência motora. Esta deficiência ocupa o segundo lugar entre as condições limitantes para a qualidade de vida da pessoa. Deste percentual, 2,33% da população apresenta deficiência motora severa, isto é, que não consegue se locomover. Segundo a distribuição etária do Censo, esta deficiência é mais comum em pessoas maiores de 65 anos alcançando 38,3% do total; o grupo de 15 a 64 anos apresenta um índice de 5,7% e, finalmente o grupo de 0 a 14 anos totaliza apenas 1,3%. Entanto a distribuição por sexo das deficiências motoras é maior nas mulheres com 8,5% da população total contra 5,3% nos homens. Infelizmente, o censo não ofereceu detalhes sobre os tipos de deficiências motoras e seus percentuais, mas oferece uma visão da dimensão da população alvo para este trabalho.

Os danos cerebrais, ainda não possuem tratamentos cirúrgicos ou farmacológicos que consigam restabelecer plenamente as funções motoras [15]. Como solução, terapias de neuroreabilitação restauram, minimizam ou compensam as alterações funcionais.

A reabilitação físico motora tem como objetivo a adaptação dos indivíduos com deficiência as suas novas condições de vida [16], restaurando as funções motoras necessárias para que o paciente consiga a mais ampla participação na vida social proporcionando a maior independência possível para atividades da vida diária [17]. A reabilitação também é descrita como um processo de reaprendizado motor ativo que deve iniciar em um período curto de tempo depois do início da paralisia [13].

O processo de identificação do tipo de deficiência é parte de um diagnóstico multidisciplinar, por outro lado, não existem grupos homogêneos de deficiências, isto

é, cada indivíduo pode ter um trauma distinto, sendo necessário encontrar respostas específicas para cada paciente, com base nas suas potencialidades e habilidades[18].

Uma avaliação correta do tipo de doença permite ao profissional da saúde estabelecer o protocolo de recuperação de acordo com as necessidades do paciente e as metas plausíveis, para se conseguir esta recuperação. Entretanto o tratamento pode evoluir de acordo com os progressos do paciente, mudando a complexidade do movimento [19]. O processo de reabilitação tem provado ser efetivo, quando é desenvolvido de forma intensiva e com a participação do paciente [20], gerando alterações diferenciais no desempenho motriz e a consequente reorganização cortical como resultado da estimulação dos nervos periféricos que levam a mudanças na excitabilidade dos neurônios da zona de controle motor.

Os sistemas robóticos são uma importante adesão no desenvolvimento das terapias, dada que sua flexibilidade na programação permite ajustá-lo às condições do paciente, permitindo treinamentos mais efetivos, com repetitividade e facilidade para criar registros biomecânicos do movimento que assistem. A literatura confirma que as terapias efetuadas por sistemas robóticos levam o paciente recuperar o controle motor nas articulações do braço e ombro de uma melhor forma que as terapias convencionais [21],[22].

Infelizmente, a evidência médica em neuroreabilitação é reduzida, em especial nos tratamentos que envolvem a recuperação motriz dos membros superiores. Os registros com validações de análises dos movimentos estão majoritariamente focados no ciclo da caminhada. Devido à complexidade do braço e o maior número de movimentos que pode desenvolver, não existe um consenso internacional que valide os protocolos de recuperação [15]. Assim, são encontradas na literatura diferentes estratégias de reabilitação para o movimento do braço, focadas em terapias através do controle de um, dois ,três ou mais graus de liberdade [22], ou em sistemas que forcem o movimento de todas as articulações com uma força aplicada sobre o efetor final que controla o movimento.

Estes trabalhos apresentam resultados quanto à aplicabilidade de sistemas assistivos robóticos em terapias de recuperação da mobilidade. No consenso geral se tem relatos de como eles efetivamente aportam na recuperação motriz, contribuindo para a recuperação dos pacientes. Este conjunto de resultados positivos motiva a criação de instrumentos assistivos que respondam às necessidades reais e que facilitem uma reabilitação adequada para o sistema muscular comprometido na deficiência motora.

Avanços na engenharia e nas neurociências tem convertido o *BCI* em uma área promissora para pesquisas em neuroreabilitação [23]. Ferramentas como o filtro de Kalman têm sido consideradas para projetar novos sistemas *BCI*. Diversas pesquisas demonstraram que seu uso em processamento de sinais cerebrais, permite extrair variáveis cinemáticas como a posição, velocidade e aceleração. Contudo, possíveis

aplicações destes movimentos codificados em sistemas *BCI* não invasivos de laço fechado ainda estão sendo abordadas, abrindo possibilidades para possíveis aplicações no controle de exoesqueletos e outros sistemas assistivos. Por outro lado, os estudos desenvolvidos com o filtro, estão baseados na decodificação do movimento aleatório da mão executados em espaços bi e tridimensionais, sem considerar movimentos de outros membros, como a rotação de articulações do braço, que desempenham um papel importante na movimentação e orientação da mão.

1.2 Objetivo da pesquisa

O sistema assistivo proposto parte da decodificação, mediante o filtro de Kalman, da posição, velocidade e aceleração angular do cotovelo efetuadas dentro de um espaço de trabalho definido em uma trajetória específica. Sinais *EEG* e de movimento serão captadas implementado um Paradigma Experimental diferente ao efetuado nos trabalhos de referência. Os estados decodificados serão integrados ao modelo dinâmico do sistema e realimentados através de um laço de controle, que compensará o movimento efetuado respeito a uma laço de referência. A integração destes elementos conformarão um sistema *BCI* em laço fechado, que assistirá o movimento do braço comandado unicamente a partir de sinais *EEG*.

O sistema *BCI* será composto por um classificador que discriminará a atividade cognitiva relacionada com ações voluntárias de movimento e não movimento do braço. O objetivo deste sistema será indicar ao Filtro de Kalman se a sinal *EEG* de entrada está relacionada com a ação de movimento.

Um controlador do tipo *Differential Flatness* será integrado ao sistema proposto através de um laço de realimentação. O *Differential Flatness* permitirá associar o Filtro de Kalman com o Modelo dinâmico do braço, determinando uma entrada estimada a partir de um modelo plano que usará as trajetórias obtidas mediante a decodificação do movimento angular do cotovelo. O modelo dinâmico do braço considerará o uso de um sistema de atuação baseado em um motor DC com redução através de engrenagens planetárias. Um laço de referência se integrará ao sistema para permitir que o sistema assistivo proposto consiga dirigir o movimento do braço com maior precisão.

De acordo com os resultados, se analisará também o uso dos estados decodificados a partir de atividade elétrica do cérebro relacionadas com processos de imaginação motora. Para isso, se integrará ao sistema *BCI*, sinais *EEG* relacionadas com imaginação motora do movimento do braço, obtidas usando o mesmo Paradigma experimental efetuado com movimentos reais. Os resultados desta análise permitirão estabelecer se é possível implementar o sistema em pacientes com impedimento motor devido a doenças neuromotoras como a tetraplegia.

Na Figura 1.1 se descreve o sistema *BCI* proposto nesta pesquisa.

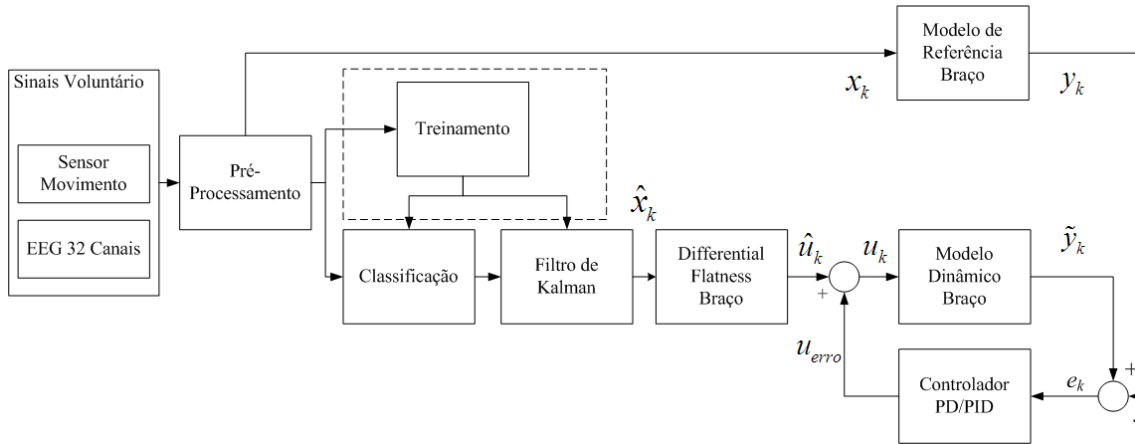


Figura 1.1: Sistema *BCI* Proposto.

1.2.1 Objetivos Secundários

Entretanto os objetivos secundários, requeridos para elaborar o objetivo principal do trabalho serão:

1. Detectar e classificar o movimento de flexão/extensão do cotovelo do braço direito em movimentos reais;
2. Codificar a posição angular do cotovelo a partir de sinal *EEG*, usando o Filtro de Kalman;
3. Analisar o desempenho do Filtro de Kalman na estimação de movimentos não aleatórios efetuados pelo voluntário;
4. Determinar uma trajetória de referência para o movimento da articulação, baseada nos registros dos movimentos dos voluntários, para ser usada na assistência a partir de sinais *EEG* relacionadas com a imaginação motora;
5. Validar o uso do filtro de Kalman para estimar movimento a partir de *EEG* relacionado com imaginação motora;
6. Projetar o modelo dinâmico do sistema braço/antebraço/mão e sistema de atuação elétrico;
7. Implementar e analisar o laço de controle para compensar a entrada estimada a partir do movimento codificado de a partir de sinais *EEG* relacionadas com movimentos reais e imaginários.

1.3 Contribuições da pesquisa

Este trabalho tem como contribuição com os seguintes pontos:

1. Estudo da decodificação do movimento do cotovelo usando o filtro de Kalman através de sinais *EEG* captados por métodos não invasivos;
2. Estudo da incidência da variabilidade do movimento do cotovelo na decodificação de movimentos não aleatórios usando o filtro de Kalman;
3. Estudo do comportamento de um sistema *BCI* em laço fechado com efeito compensador, que integre o filtro de Kalman com a dinâmica do braço e um controlador;
4. Estudo da aplicabilidade de movimentos codificados para controlar a atuação de um sistema assistivo através *EEG* relacionado com imaginação do movimento.

Capítulo 2

Estado da Técnica

2.1 Os *Wearable Robots* e os primeiros conceitos de tecnologia robótica para o uso humano

O termo *Wearable Robots*, que se poderia traduzir como robôs de vestir, resume um conjunto de dispositivos robóticos que podem ser portados ou vestidos. Os *Wearable Robots* fazem parte da área da robótica, e podem ser classificados segundo as características de seu uso em: 1) os sistemas robóticos que assistem ou estendem as capacidades biológicas do membro, conhecidos respectivamente como robôs **ortóticos** e **extensores**; 2) os sistemas robóticos que substituem um membro perdido imitando as características de mobilidade e trabalho, conhecidos como **próteses**.

Segundo José Pons [3], os *Wearable Robots* são um conjunto de sistemas biomecatrônicos, que possuem mecanismos adaptados à estrutura física do corpo humano, copiando suas características de mobilidade e adaptabilidade, sendo controlados através de sinais como: a atividade elétrica do cérebro, muscular, e sensores distribuídos ao longo do corpo que registram atividades biométricas na pele, movimento, atividade ocular, gestos faciais, corporais, entre outras. Um *Wearable Robot* é um mecanismo com possibilidades de trabalhar em conjunto com seu usuário, e possui capacidade similar de movimentação e resistência. Para conseguir esta sinergia, o sistema precisa imitar as características próprias do membro ao que esteja conectado, como a estrutura cinemática, a dinâmica da movimentação e algumas características morfológicas, como a forma, material e peso. Esta seleção de parâmetros obedece ao conceito de biomimética, que é a cópia de características biológicas para o projeto de estruturas artificiais.

Dentro desta nova classificação, os exoesqueletos formam parte dos *Wearable Robots*, embora estes sistemas sejam ainda mais antigos que o termo em que estão referenciados.

O nascimento dos exoesqueletos, data dos anos 60, quando o primeiro protótipo

foi criado no projeto *Hardiman* [24]. Este primeiro modelo consistiu em dois exoesqueletos conectados como mestre/escravo. Enquanto o escravo estava conectado com o corpo e se encarregava de copiar o movimento do operário, o mestre efetuava a força do sistema através de atuadores hidráulicos. O projeto foi um fracasso devido aos fatores limitantes da época, o sistema se movimentava de maneira incontrolável comprometendo à parte humana. Como solução, reduziram o sistema à parte superior, mas seu peso e tamanho impossibilitava o uso em áreas pequenas, e por isso o *Hardiman* foi descartado.

Trinta anos depois, Kazerooni [25] encontrou uma solução para o problema, eliminando a interação mestre/escravo por um único sistema de menor tamanho, que estava em contato direto com o corpo intercambiando informação através de sensores de força em contato com o membro que detectavam o movimento do usuário.

O *BLEEX* (*Berkeley Lower Extremity Exoskeleton*) foi o primeiro exoesqueleto desenvolvido pelo grupo de Kazerooni [26]. Ele é um sistema robótico para os membros inferiores criado na Universidade de Berkeley em conjunto com a *DARPA* (*Defense Advance Research Projects Agency*) ao longo de 10 anos. O *BLEEX* permite ao usuário carregar até 75 libras nas costas sem nenhuma resistência física e se trasladava com uma velocidade de 2 *mph* em ambientes diversos, como escadas ou pendentes.

O movimento do *BLEEX* é controlado pelo corpo, e suporta as carga por meio de atuadores hidráulicos e sensores de pressão localizados na planta dos pés. Para garantir uma mobilidade adaptável às circunstâncias do ambiente, o *BLEEX* possui uma estrutura antropomórfica de sete graus de liberdade, sendo quatro atuados. O *BLEEX* permite portanto acompanhar os movimentos voluntários e involuntários do usuário. Para garantir o alto grau de mobilidade, cada junta está conformada por um encoder e dois acelerômetros, que determinam a posição, velocidade e aceleração.

O *BLEEX* é considerado um extensor porque aumenta as possibilidades biológicas de carga que o corpo pode suportar, no entanto é o corpo que gera os comandos de posição e movimentação da estrutura, sendo o sistema encarregado de suportar a carga. Ele evoluiu para o *eLEGS* [27] que é um sistema robótico com propósitos terapêuticos, criado para usuários com problemas na medula espinhal e proporciona a um usuário em muletas a possibilidade de se levantar e caminhar; e o *HULC* [28] que tem o mesmo funcionamento do *BLEEX* mas pode suportar cargas maiores de até 200 lb com licença para uso militar.

O *eLEGS*, possui a implementação da Interação Humano Máquina (*HMI*) com a inclusão de um sistema que interpreta os gestos naturais do braço e da muleta ao longo da caminhada. Diferentes sensores medem o movimento humano para interpretar a pose atual do corpo, a qual logo é usada para determinar a posição mais adequada para as pernas robóticas. O sistema adquire a posição através de uma

Máquina de Estados Finitos, que conhece as transições possíveis do exoesqueleto. As entradas do sistema são as posições angulares do cinto e o joelho, o ângulo do braço, a carga da muleta e sensores de pressão nos pés que determinam quando o usuário está em contato com o piso. As informações dos sensores permitem ao sistema conhecer a fase atual da caminhada da pessoa e levar ao sistema a próxima fase segundo um mapeamento dos próximos estados permitidos e a informação fornecida pelos sensores.

2.2 Interfaces Cérebro Computador *BCI*

A interpretação e uso da atividade cerebral é a base dos sistemas *BCI* (*Brain Computer Interface* ou *Brain Machine Interface* por outros cientistas). O *BCI* é um sistema de comunicação que ignora as rotas naturais entre o membro e o cérebro para controlar dispositivos externos[29] com propósitos terapêuticos e assistivos [30]. Historicamente pode-se encontrar as primeiras interfaces cérebro máquina em dispositivos como: cadeiras de rodas [31]-[32] software para movimentar cursores em uma tela com propósitos comunicativos [29], mecanismos artificiais destinados à assistência de movimentos [33], exoesqueletos [34]- [35], dispositivos próstéticos [36] e manipuladores robóticos [37], entre outros.

Os sistemas terapêuticos que trabalham diretamente com sinais do cérebro estão focados em pacientes com deficiência motriz ou danos neuromotores cuja condição os impede de gerar movimentos voluntários, oferecendo uma nova alternativa para interagir autonomamente e ter certo nível de qualidade de vida. O uso destes dispositivos permite a os usuários interagir com o entorno, usar computadores, movimentar-se em sistemas virtuais e praticar jogos [30].

Segundo a técnica de captação da atividade elétrica, existem dois tipos de sistemas *BCI*: os invasivos, que usam eletrodos incrustados no cérebro; e não invasivos, que correspondem ao uso de um conjunto distribuído de sistemas de captação sobre a cabeça que registram a atividade elétrica do córtex motor através de tecido, pele e ossos. A vantagem dos sistemas não invasivos é que não requerem nenhum tratamento cirúrgico. Já a principal desvantagem é que o sinal elétrico captado apresenta uma queda considerável da amplitude devido às camadas existentes entre o electrodo e o cérebro. Esta redução leva a perda significativa de informação, como também a diminuição da relação sinal ruído *SNR*. Por outro lado, ao não ter uma leitura direta desde a origem ocorre uma mistura do sinal com outras fontes relacionadas a outros processos cognitivos, que podem acontecer ao mesmo tempo.

Os sistemas não invasivos existentes utilizam o Magnetoencefalograma (MEG), o *fMRI* (imagem por ressonância magnética funcional) o *EEG* (electroencefalograma) e o *NIRS* (Espectroscopia de reflectância de infravermelho próximo). Porém entre

os sinais mais comuns usadas para o processamento, estão o *ERP*, os potenciais evocados somatosensitivos (*SSEP*), a atividade sensorimotora e os *SCP* (em inglês *slow cortical potentials*) [38].

Quando uma tarefa mental é efetuada (movimento voluntário, fala, pensamento), mudanças na atividade elétrica relacionadas ao evento são disparadas ao redor do córtex motor. O *BCI* tem a capacidade de identificar padrões e relacioná-los com a tarefa. Para conseguir este reconhecimento, é necessário realizar um treinamento, que consiste na repetição voluntária do evento, e através de um conjunto de diferentes técnicas de pré-processamento de sinais e técnicas de aprendizado de máquinas, são identificadas características associadas ao evento que identificam a realização da tarefa mental [30].

2.2.1 Interfaces Cérebro Computador *BCI* híbridos

Os sistemas híbridos, são identificados como a nova etapa no desenvolvimento de protótipos de assistência. Misturam protótipos assistivos baseados em *HMI* e implementam algum tipo (ou mistura) de interfaces *BCI*. Como exemplo pode-se destacar um dispositivo que se desliga de acordo com o ritmo cardíaco [39], através de um exercício respiratório, o paciente reduz a frequência do batimento se liberando da necessidade de assistência externa para a operação. Outros exemplos, se adaptam de acordo com as respostas do ambiente, atuam identificando o estado mental e deduzindo o propósito da ação mais conveniente, como uma mudança na trajetória ou uma parada de emergência. *BCI* híbridos tem sido aplicados em cadeira de rodas [40],[30] e robôs moveis [41].

A estrutura do *BCI* híbrido se descreve na Figura 2.1 [38]. Na etapa de modalidade é escolhido o tipo de sinal para a tomada de decisões, onde a caixa *modalidade cerebral* está relacionada com os sinais captados do córtex e inclui todo sinal sem importar o tipo de técnica de extração. A caixa, *outras sinais* faz referência às modalidades suplementárias que o sistemas poderia ter além do *EEG*.

A segunda etapa descrita na mesma figura, é o *processamento do sinal*. Esta fase está encarregada desde a captação do sinal até a tomada da decisão. Dada a natureza biológica do sinal, existe a necessidade de eliminar artefatos como ruídos de alta e baixa frequência (movimentos musculares, estática ou sinais que não tem relação com a tarefa).

A etapa de *Geração de exemplos* extrai informações relevantes para a classificação. O pré-processamento amplifica e isola os componentes do sinal, enquanto a extração escolhe a informação mais relevante. Finalmente a classificação se encarrega de reduzir dimensionalmente o conjunto de características e facilitar a fase de seleção que identifica o estado mental observado. Esta decisão é processada na

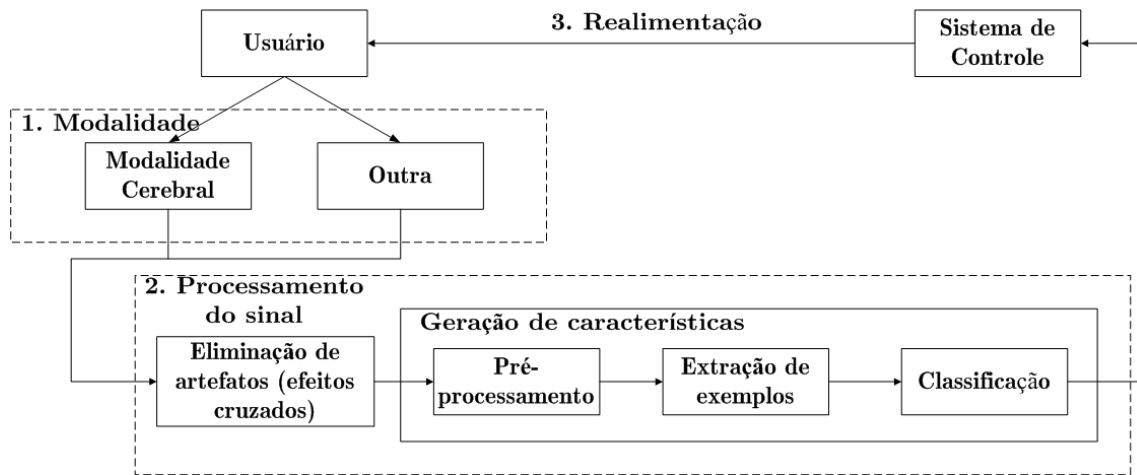


Figura 2.1: Estrutura de um *hBCI*, adaptado de [38]

etapa de controle e faz a realimentação correspondente, como um movimento ou a apresentação de uma imagem, que gera um novo estímulo para ser processado.

Sistemas híbridos *BCI* similares trasladam, com vontade do usuário ou autonomamente o canal de operação conseguindo uma auto adaptação e certa autonomia segundo o sinal que possui a melhor interação com a atividade. Um sistema de reconhecimento de padrões identifica o tipo de sinal que o usuário está elaborando e infere o estado mental [42].

A vantagem dos sistemas híbridos com relação aos *BCI* tradicionais, é a possibilidade de facilitar o treinamento, escolhendo o sinal que apresenta maior proeminência para descrever a atividade mental. A implementação destes modelos híbridos apresenta também vantagens na exatidão da classificação do evento. Um sistema que dedica múltiplas entradas para detectar a tarefa mental melhora sua robustez, diminuindo o número de falsos positivos, melhorando a discriminação com respeito a outros eventos, e aumenta o desempenho em ambientes com altas perturbações [38].

Os sistemas *BCI* evoluíram de protótipos de interação com o usuário que interpretavam os estados mentais para a tomada de decisões até sistemas que ainda se encontram em desenvolvimento que captam outros sinais biológicos, e informações das condições ambientais para fornecer um sistema *BCI* com maior autonomia, flexibilidade e precisão. Esta estrutura aponta para a criação de sistemas mais eficiente, porém mais complexos e adequados para as possibilidades de cada usuário. Para contribuir na eficiência do sistema é necessário promover um treinamento no paciente e um adequado sistema de processamento de sinais.

2.2.2 *BCI* para a assistência motriz

A perda de funções motoras leva a restrições de mobilidade e desenvolvimento de atividades cotidianas, um paciente está sujeito por tanto, à dependência e perda total ou parcial da autonomia.

Os sistemas de recuperação motora estão baseados na estimulação espontânea tanto das funções motrizes do membro, como também, das zonas cerebrais encarregadas de movimentá-lo [43]. Este fenômeno de recuperação cerebral é chamado de plasticidade adaptativa [44], que é a alteração da organização funcional do córtex cerebral, logo após um acidente pode levar a alterações que comprometem a movimentação. Os tratamentos terapêuticos para a recuperação motora consistem de mobilização passiva ou ativa do membro danificado [45], através de movimentação repetitiva e intensa. Mesmo que o voluntário possua capacidades motrizes ou não, a atividade intensa pode ativar os mecanismos de plasticidade adaptativa depois de um dano e melhorar a recuperação motora através do aprendizado. Estudos tem demonstrado que as terapias baseadas em *BCI* induzem a plasticidade e por tanto incrementam o sucesso na recuperação motriz [46].

Diferentes paradigmas de dispositivos *BCI* para assistência motriz podem ser encontrados na literatura, como: os sistemas de assistência baseados no uso da realidade virtual [47], focados na recuperação das zonas cerebrais danificadas através de terapias virtuais; os sistemas de estimulação motora por ondas elétricas [48], que atuam através de choques elétricos no membro imobilizado; as cadeiras de rodas [49]-[50]-[51] e finalmente os sistemas robóticos para terapias que são abordados na próxima seção.

Imagética Motora

Seja por danos cerebrais ou por impedimento físico, para os pacientes que não podem exercer voluntariamente a ação de movimentação em terapias de recuperação motora, uma alternativa é implementar a prática mental do movimento impedido. Este exercício é conhecido como Imagética Motora (*IM*). Estudos têm demonstrado que o uso da *IM* pode melhorar os desempenhos motrizes e produzir mudanças plásticas no cérebro [30], modificando a atividade neural nas zonas motrizes do cérebro da mesma maneira que o movimento executado [52].

A *IM* tem como propósito ativar as redes motrizes do cérebro por tanto é importante que o paciente desenvolva a tarefa mental em uma perspectiva da primeira pessoa. Os estudos na área, explicam que as visualizações próprias e de terceiros são efetuadas em diferentes regiões do cérebro, porém a contribuição da imaginação fora da introspecção não forneceria os mesmos resultados já que estaria habilitando outros circuitos neurais [53].

2.3 *Wearable Robots* para a assistência motriz

Dada as capacidades de um sistema robótico, existem vantagens no seu uso para reabilitação de movimentos em comparação com as técnicas convencionais. Estes sistemas possibilitam o desenvolvimento de terapias por períodos de longa duração, com alta repetitividade, com movimentos precisos, consistentes e sem fadiga, e unicamente quando o paciente a requer detectando a intenção de movimento [54]. Por outro lado, o dispositivo robótico oferece vantagens técnicas, como a facilidade para ser reprogramado em diferentes funções terapêuticas, o armazenamento e uso da informação biomecânica [55], ser usados em funções remotas próprias da telereabilitação [56], fornecer reabilitação com segurança e especificidade que não pode ser efetuada por terapias convencionais, sendo adaptado para diferentes pacientes com diversas necessidades terapêuticas [57].

Os sistemas robóticos para reabilitação são divididos em três classes, agrupados segundo seja a estratégia de reabilitação[22]:

- **Assistência:** o robô está encarregado de suportar o peso do membro total o parcialmente, fornecendo força para completar a tarefa. Esta tarefa pode ser efetuada de forma passiva ou ativa.
- **Correção:** quando a reabilitação do movimento não é efetuada corretamente pelo paciente, o robô tem a função de corrigir o movimento forçando-o a modificar a trajetória.
- **Resistência:** Nestas terapias o robô gera uma força oposta ao movimento, permitindo aumentar sua complexidade, treinando-o, corrigindo-o ou adaptando-o a perturbações externas.

2.3.1 Terapias Assistivas

As terapias por movimentação assistiva do membro oferecem uma recuperação significativa das funções neuromotoras em pacientes com paralisia por dano na espinha ou no cérebro. De acordo com a ação sobre o paciente: é possível identificar dois tipos de terapias assistivas: as atividades terapêuticas ativas, e as atividades terapêuticas passivas. No primeiro tipo é o voluntário que intenta executar o movimento, exercendo o sistema robótico um suporte; entretanto no segundo tipo é o robô que efetua a movimentação, exercendo a força suficiente para movimentar o membro afetado.

As técnicas passivas são implementadas nos primeiros estágios de reabilitação, quando o paciente não tem nenhuma capacidade de efetuar movimentação voluntária. Na medida que o voluntário melhora sua mobilidade, o sistema vai reduzindo a assistência, adaptando-se às circunstâncias de recuperação, induzindo menor força sobre o membro.

Assistência Passiva

É a ação mais simples de assistência, levando o membro através de uma trajetória desejada. Ao longo do movimento, distintas patologias no paciente podem levar ao sistema a se desviar da trajetória, como a presença de contração muscular ou espasticidade. Porém, o controle deste mecanismo requer de uma sintonização adequada dos ganhos para evitar prejudicar o paciente.

Variações das técnicas passivas são o movimento espelhado *passive mirroring*, em que um sistema escravo imita os movimentos de um sistema mestre [58]; e o alongamento passivo *passive stretching*, onde cada junta é alongada passivamente com o objetivo de encontrar uma relação ângulo da articulação e momento [59] conseguindo reduzir a rigidez do músculo e incrementar sua força.

Assistência Ativa

Tem-se evidencia que as terapias passivas são insuficiente para melhorar as condições motrizes [60]. As terapias que induzem movimentação voluntaria fornecem maiores benefícios na capacidade motora, na medida em que o sistema se adapta as novas possibilidades de movimentação incrementando o grau de dificuldade. Esta evolução progressiva induz a acelerar a plasticidade neural da zona afetada melhorando as capacidades de movimentação [61], [62]. A assistência, portanto deve ser aplicada na medida que seja necessário reduzir erros, evitando um reforço negativo, conservando a motivação no paciente, a intensidade do treinamento e a confiança no uso do membro afetado [22].

Na medida em que o paciente recupere a mobilidade, o sistema reduz a intervenção, permitindo ao paciente expressar o movimento que possa realizar sem reprimir qualquer capacidade motriz [63].

Técnicas para a assistência passiva e ativa

Os primeiros dispositivos robóticos com propósito assistivo forneciam terapia passiva [64], entre as primeiras aplicações pode-se encontrar o uso de robôs planares acoplados a um membro [65].O dispositivo fornecia uma movimentação contínua é reprogramável para um membro em recuperação pós-operatória e permitia inserir um conjunto de trajetórias que efetuavam um conjunto de exercícios terapêuticos.

Posteriormente a detecção da intenção de movimento, integrou a iniciativa do paciente para efetuar o movimento que, de acordo com a intenção [35], se ajusta ao nível de força. Os exoesqueletos de assistência ativa utilizam a força, posição, e a intenção de movimento [54] detectada por *EMG* ou por *EEG* como sinal para a ativação do sistema atuador.

Os dispositivos que são iniciados por um sinal de força detectam o movimento através da pressão do membro numa direção. Se o sinal ultrapassa certo limite o exoesqueleto é ativado [66]-[67]. Sistemas deste tipo são convenientes para pacientes que não se encontram totalmente impedidos para movimentar o membro. O corpo se encarrega de dar a ordem e o sistema se encarrega de mover o membro. Os sistemas de velocidade, similar aos de força, requerem a ativação do paciente através do movimento do braço dentro de uma velocidade limite [61].

Os sistemas que implementam o *EMG* comandam o dispositivo usando os sinais elétricos captados no músculo [61]. Um exemplo é o sistema de Song et al. [68], onde o exoesqueleto fornece força proporcional ao nível do *EMG* que apresenta o braço ao longo da movimentação. Um problema do uso *EMG* é a geração de espasmos musculares durante as terapias, outro é a tendência do paciente à ativação de grupos musculares que não precisem de terapia, reforçando um movimento patológico e não recuperando o movimento normal do paciente [54].

Outra forma de captar a intenção de movimento é usando o *EEG*, aqui a recuperação favorece as regiões cerebrais ligadas ao movimento danificado, incrementando assim sua plasticidade neural e impulsionando uma movimentação efetiva dos músculos do membro impedido. O *EEG*, pode ser implementado em pacientes com mobilidade nula [46] através da imaginação motora para gerar a ordem que controla a movimentação do dispositivo assistivo.

2.4 Estratégias de controle para os exoesqueletos assistivos

O mecanismo usado para terapia é projetado para que acompanhe o movimento do membro ao longo de seu espaço de trabalho, assistindo o movimento suavemente e sem impor restrições de mobilidade[3]. Estes sistemas geralmente possuem um sistema de controle clássico, (Fig. 2.2), que é formado por um laço de realimentação que compara a posição atual com uma referência, e segundo seja o desvio, o controle gera a correção modificando a posição da articulação. Estes sistemas de controle estão as vezes acompanhado de um laço de pré-alimentação (*feedforward control*) usado para gerar uma compensação quando perturbações que se podem prever sobre o modelo (como o peso do exoesqueleto e do braço que podem ser modelados).

Os controles por realimentação são usados tanto em exoesqueletos de tipo passivo como ativos. Seção 2.3. Exemplos de sistemas desenvolvidos com controle clássico, o controle de posição que assegura que o sistema atinja a posição angular desejada, como o controle *PD* [11],[69], o controle por *differential flatness* [9], dispositivos com

compensação da gravidade para braços superiores [70], sistemas ativados através de cabos de aço que requerem seguimento da posição angular das articulações [71], [72] e sistemas de movimentação passivos ativados por atuadores pneumáticos que requerem de um controle para converter o sinal de pressão que posiciona o atuador em um sinal elétrico que ativa as válvulas de pressão que os dirigem [70].




Figura 2.2: Esquema de controle clássico. Adaptado de [73]

2.4.1 Controle por impedância e admitância

Em contrapartida ao esquema de controle clássico, existem dois controles com alto compromisso entre seguimento do movimento e a rigidez do mecanismo, que são categorizados de acordo com as entradas e as saídas do sistema [74]. O primeiro, é controle por impedância [75], onde a entrada é o movimento efetuado pelo usuário, resultando uma força proporcional na saída do controlador. O segundo esquema de controle é denominado de admitância, onde o usuário exerce uma força que é registrada pelos dispositivos e o sistema responde com um deslocamento proporcional a ela.

Os controles por impedância e admitância são uma extensão do controle clássico por posição, que não controlam unicamente posição e força, mais também controlam a interação entre o exoesqueleto e o corpo [76].

Ambos os tipos de controle são comuns em sistemas *HMI* (comerciais ou em desenvolvimento), onde a interação humano máquina está relacionada como a medição do movimento ou da força entre o voluntário e o exoesqueleto. Os controles por impedância se caracterizam por serem sistemas com baixa inercia, baixa fricção e de fácil transmissão do movimento em uma direção (do motor para a carga) [77], evitando que forças externas desempenhem o movimento, tarefa que é exclusiva do motor. Entretanto, os controles por admitância, presumem que a força externa que atua sobre o exoesqueleto é captada por sensores com alta resolução [78], sendo sistemas mais adequados quando a inércia requer ser compensada e também outros efeitos dinâmicos na articulação, como o atrito [73].

Os controles por impedância são efetivos em exoesqueletos assistivos ligeiros com baixa capacidade de se adaptar às forças externas, sistemas com transferência

de movimento através de cabos de aço são exemplo. Por outro lado, nos sistemas que possuem alta sensibilidade à força e capacidade de adaptação ao impacto de forças externas, o controle por admitância é mais recomendado, dado que eles devem se adaptar à força de contacto com o paciente para movimentar o robô. [22].

A integração dos sinais biológicos *EGG* e *EMG* cria um novo vínculo que permite ao controlador se adaptar e gerar respostas mais adequadas às circunstâncias do paciente e, também entre pacientes cujo sinal pode mudar por variações biológicas, como a fadiga muscular [79], propriedades mecânicas dos músculos e tecido conectivo, os efeitos dos tecidos macios na transferência da carga e a resistência do indivíduo [80] para o *EMG*. Entretanto para o *EEG* existem dificuldades devido à variação dos estados mentais no sujeito e entre distintos indivíduos, e também a grande quantidade de dados que podem ser extraídos para codificar uma intenção claramente [38].

2.4.2 Controle adaptativo

Uma forma de comandar os sistemas de controle baseado em sinais biológicos é mudando o tipo de sinal a ser processado, como o caso da atividade muscular dos membros em movimentos através do *EMG* [81] que fornece informação sobre as intenções do paciente. Este tipo de controle é denominado de *Controle Adaptativo* [80], onde o controlador muda automaticamente segundo as necessidades do paciente que veste o sistema.

Um exemplo de adaptabilidade está em modelos que supervisionam a intensidade do sinal *EMG* para determinar a existência de movimento. Neste caso, quando a energia do sinal supera um umbral o controlador considera que existe uma quantidade de movimento suficiente para ativar o motor. Sistemas similares podem ser encontrados em [82],[83], [84], [85].

Também se pode encontrar sistemas de controle com adaptação entre ensaios [86],[87], que, baseado no erro em cada ensaio, modula o grau de assistência do mecanismo através da manipulação dos ganhos do controlador, que opera ao nível da articulação. Em [88] um controlador PD também foi usado, adaptando-se durante o movimento segundo a dinâmica da extremidade do paciente, modificando a força sobre o braço na medida que os erros na execução da tarefa diminuísse.

Um sistema assistivo de sete graus de liberdade [85] usa o sinal *EMG* proveniente do músculo através de um controle por impedância. Este controle modula em tempo real os parâmetros de impedância do controlador considerando a postura do membro e o nível de atividade do *EMG*. Contudo, o sistema apresenta inconvenientes devido à relação sinal ruído do sinal e a dificuldade de extrair os perfis de ativação de um único músculo, pois o sinal pode ter interferências causadas pelo suor e fadiga muscular.

Proietti et al.[89] propôs um sistema que muda entre assistência passiva para ativa, diminuindo a rigidez da estrutura de acordo com a possibilidade de movimentação de um voluntário saudável. O sistema é treinado entre ensaios aumentando a dificuldade do movimento e reduzindo a assistência do dispositivo mecânico. Durante o ensaio os ganhos de um controlador PD adaptativo mudam, sendo menos restritivo na medida que o paciente desenvolve o movimento com maior independência. O sistema não possui realimentação com nenhum tipo de sinal e a adaptação do controlador é feita segundo uma taxa de adaptação, tendo ganhos maiores para indicar menor assistência ou ganhos baixos indicando uma menor modificação do controlador entre ensaios.

Nos projetos de controle adaptativo estudados, sinais *EMG* e sensores de posição são usados para validar o movimento do paciente de acordo com a posição desejada. Entretanto sinais *EEG* não foram utilizadas como método de referência para a adaptação do controlador ao longo do movimento. Este é um espaço existente para inovar no desenvolvimento de terapias assistivas com exoesqueletos de membros superiores.

2.5 Comando dos movimentos angulares nos exoesqueletos assistivos

Feita a descrição dos tipos de controladores mais comuns usados nos exoesqueletos assistivos *HMI* e *BCI*, nesta seção é abordado o tema de comando e seguimento dos movimentos angulares. Segundo [73], a maior parte dos exoesqueletos usam uma trajetória de referência nas articulações, que se encontra associada ao movimento que o sistemas deve seguir. Estas trajetórias estão contidas dentro do espaço de trabalho do mecanismo, que descreve o conjunto de posições que o sistema pode atingir segundo as restrições cinemáticas impostas por cada articulação [9].

No caso de sistemas assistivos, as trajetórias das articulações são definidas pelo profissional da área, que desenvolve um conjunto de movimentos terapêuticos requeridos para a recuperação do membro. Estas trajetórias variam em tempo, em velocidade e o tipo de movimento, podendo ser parametrizadas de acordo com a movimentação que se deseja desenvolver. Isto é, o movimento do paciente junto com o exoesqueleto assistivo se encontra limitado aos movimentos específicos que a terapia requer [73]. Sistemas passivos e ativos possuem dispositivos de seguimento de trajetórias para comandar a movimentação sendo uma das mais simples é a realimentação PID, que pode ser implementada tanto na articulação como no efetuator final [22].

Quando os movimentos envolvem o uso de múltiplas articulações, é necessário

estabelecer uma relação entre os deslocamentos das diferentes trajetórias. Uma estratégia tradicional define uma posição final e uma inicial no efeitor final, o sistema desenvolve uma trajetória entre esses dois pontos, e através da cinemática direta são definidas as posições angulares para cada ponto da trajetória (um análise de cinemática inversa pode ser desenvolvida para descobrir as posições angulares que resolvem o sistema) [90]. Em seguida, um controlador ponto a ponto leva o sistema ao longo das posições. Este é um método rígido já que restringe a movimentação num conjunto de pontos fixos, sem nenhuma flexibilidade para atingir outras posições além da resposta proposta.

São encontradas na literatura estratégias que relacionam o movimento do braço a uma trajetória definida, e brinda certa liberdade no movimento. O *TIFT* [91] (*time-independent functional training*), gera um espaço virtual de movimentação em torno da trajetória desejada, permitindo um movimento próximo ao ideal, sem ser rígido, e ajustado as restrições cinemáticas do conjunto membro/exoesqueleto. Esta modalidade trabalha tanto em sistemas com movimento em múltiplas articulações como simples. Esta aproximação, contudo, não envolve avaliações da efetividade da terapia com o uso do controlador.

Uma alternativa interessante para a produção de modelos de trajetórias, foi apresentada por Proietti [22], consistindo na criação de modelos de movimento contidos dentro do espaço de operação da articulação através da validação de padrões estatisticamente consistentes desenvolvidos por um número suficiente de sujeitos saudáveis. Porém esta técnica não é usada em sistemas robóticos assistivos, existindo unicamente um exemplo [15] explicado no próximo parágrafo.

O sistema assistivo de múltiplos graus de liberdade para fornecer assistência quando o paciente necessita (*assistance-as-needed*). O controle do sistema tenta se antecipar à intenção de movimento do paciente, predizendo a trajetória a ser executada. Esta predição é feita por meio da leitura biomecânica da posição angular do respectivo grau de liberdade. 40 pacientes saudáveis foram estudados para gerar uma base de dados das características do movimento, A partir desta base de dados, foram quantificados os padrões biomecânicos e os limites superior e inferior da trajetória que estão sujeitos à variabilidade entre os indivíduos. Conforme a evolução do movimento, o sistema determina se o paciente requer ou não de assistência. O comportamento antecipatório deste controlador foi testado unicamente através de simulações em ambientes virtuais.

2.5.1 Decodificação da velocidade de movimento através do *EEG*

A decodificação da velocidade de movimento tem aplicações nos sistemas assistivos como uma estratégia para determinar o grau de intenção de movimento que de um membro para ser aplicados em sistemas assistivos ativos.

Tem-se evidências que é possível extrair informação da posição e velocidade do braço pelo *EEG* usando métodos não invasivos [92], através de métodos de predição baseados na regressão linear (Ver Seção 2.5.2) e *EEG* de baixa frequência ($> 2Hz$). O uso desta informação permite ao sistema detectar o movimento da mão em três dimensões, determinando a velocidade e posição. Lu et al., [93] e Yuan et al.[94], também conseguiram decodificar a velocidade de uma mão durante tarefas de desenho em duas dimensões, e preensão, usando filtros de Kalman, indicando o autor que, as áreas do cérebro mais adequadas para captar o movimento por métodos não invasivos são: o *córtex motor*, o *córtex parietal* e o *córtex occipital*.

Outra técnica para determinar a velocidade sem o uso de filtros pode ser vista em [95], usando a atividade nas bandas e sua classificação. Neste trabalho, os pesquisadores projetaram uma plataforma planar holonômica de três graus de liberdade, ativada com atuadores elásticos sobre uma base que se encontra unida ao braço direito. Durante o teste, o voluntário imaginava um movimento seguindo um contorno reto, o sistema classificava-o, discriminando entre execução ou não do movimento, e através de uma análises da probabilidade era medido o nível de intenção. Este nível era utilizado para regular a velocidade do movimento do sistema.

Em outro trabalho [96], diferentes níveis de força e velocidade são determinados através da interpretação do *MRCP* (Potencial Cortical Relacionado ao Evento), que é um sinal de baixa frequência com deflexão negativa que aparece nas leituras de *EEG* associados ao planejamento e execução do movimento voluntário, usado como sinal característica da atividade. O trabalho permitiu estabelecer que é possível detectar através do processamento do *MRCP*, intenções de movimentação com latência limitada e dela extrair e classificar dois níveis de força e velocidade no movimento do tornozelo, usando seções do sinal que para cada ação apresentavam um comportamento bem definido.

Dentro deste conjunto de sistemas assistivos, se encontra um documento que relata o interesse em codificar a velocidade angular do movimento do cotovelo através do processamento da atividade elétrica do córtex obtida por *EEG* [35]. Este trabalho retoma o uso de filtros baseados em regressão linear para codificar a posição angular, porém faz uso de algoritmos genéticos para determinar os coeficientes do filtro.

2.5.2 Decodificação da posição angular

Nesta seção são analisados os trabalhos que têm como objetivo decodificar a posição angular de um membro. A leitura desta magnitude através do *EEG* possibilita sua implementação como referência no controle em tempo real, servindo como parâmetro de correção durante o movimento, visando processos assistivos em pacientes com mobilidade deficiente.

Previamente foram mencionadas metodologias, como a de Lu [93], que codificavam a velocidade de movimento da mão usando filtros de Kalman, e outros como [35] implementavam a regressão linear com os mesmos propósitos. Estas estratégias foram usadas com sucesso na detecção da velocidade em trabalhos posteriores que se focaram no seguimento da posição e velocidade espacial de determinado membro.

Pesquisas efetuadas dos padrões neurais responsáveis da cinemática do movimento da mão tem encontrado que existe uma sintonização direcional entre os ritmos de disparo (*firing rate*) de um conjunto de neurônios e distintos aspectos do movimento como a posição, velocidade, direção ou aceleração [23], permitindo estabelecer um conjunto de métodos matemáticos de decodificação que produzem um valor estimado do estado do voluntário (\mathbf{x}) como função dos disparos neurais (\mathbf{z}) [97].

$$\mathbf{x} = f(\mathbf{z}) \quad (2.1)$$

Pelo outro lado, o modelo inverso ou modelo de codificação [97] se entende como uma função matemática que relacionam a atividade neural (\mathbf{z}) com um determinado estímulo (\mathbf{x}) acompanhado por um ruído.

$$\mathbf{z} = f(\mathbf{x}) \quad (2.2)$$

Uma das primeiras aproximações do modelo descrito em 2.2 é proposta por Georgopoulos et al., [98], estudando o movimento bidimensional do braço em macacos. Aqui encontrou que os ritmos de disparo provenientes do córtex motor associados ao movimento, se podem aproximar a função cosseno da forma:

$$z_k = h_0 + h_p \cos(\theta_k - \theta_p) \quad (2.3)$$

Onde θ_k indica a direção do movimento efetada no tempo t_k , θ_p é a direção preferida (*preferred direction*), ou direção de máxima resposta de um neurônio e h_n são coeficientes encontrados por regressão. As direção preferidas são distintas para cada neurônio, de forma que as curvas do modelo se sobrepor entre elas. Assim a trajetória do movimento em uma direção desejada pode ser gerada pela cooperação de múltiplos neurônicos através destas funções sobrepostas [98].

Dado que o modelo descrito por Georgopoulos et al., está baseado unicamente na

direção do movimento, não consegue capturar toda a cinemática do movimento da mão; o modelo proposto por Schwartz [99] e Moran [100] estendem 2.3 adicionando a velocidade da forma:

$$z_k = h_0 + h_x v_{x,k} + h_y v_{y,k} \quad (2.4)$$

Este modelo relaciona linearmente os ritmos de disparo com a velocidade $\mathbf{v}_k = [v_{x,k}, v_{y,k}]$ nos planos x e y . Sendo h_x e h_y coeficientes que se ajustam de acordo aos dados usados para treinar o modelo. Um modelo similar também tinha sido proposto por Georgopoulos et al., [101], como avanço ao trabalho desenvolvido em [98] neste caso o modelo ajusta os ritmos de disparo a posição no plano da mão da forma:

$$z_k = h_0 + h_x x_k + h_y y_k \quad (2.5)$$

Baseados na teoria da codificação, distintos métodos tem sido propostos para decodificar atividade neural que reconstrua o movimento da mão. Por mencionar, o Vetor de Populações [102], os filtros lineares [103],[104], as redes neurais [105],[106] e o filtro de Kalman [107],[108] e [109].

Entre os trabalhos mais antigos, encontram-se os estudos de decodificação de parâmetros cinemáticos (movimentos horizontais e verticais, e sua velocidade) em primatas, através de a análise cognitiva durante atividades de aproximação e preensão [103] e velocidade [110], eles revelaram que, através de modelos de regressão linear multidimensional, também conhecido como filtro Wiener [103] é possível extrair estes parâmetros.

O modelo de regressão linear multidimensional é expressado como:

$$x(t) = b + \sum_{n=1}^N \sum_{k=0}^L a_n(k) S_n[t - k] \quad (2.6)$$

Onde $x(t)$ é o estado da variável cinemática (p. ex. o ângulo da articulação) no tempo t e $S_n[t - k]$ é a tensão captada no eletrodo n no tempo $t-k$. L é o número de atrasos k usados para prever a variável, N o número de canais. O termo b e a intercepção da função linear com o eixo Y e $a_n(k)$ é o peso no atraso k para o canal n ambos os pesos podem ser obtidos através de métodos de regressão linear. O modelo, decodifica a variável cinemática no tempo t usando um conjunto de dados atrasados provenientes da atividade elétrica do cérebro cuja quantidade depende do termo k .

Posteriormente, este sistema foi levado a modelos humanos usando tecnologia invasiva, podendo-se captar a velocidade de movimento de um cursor em uma tela [111]. Posteriormente em modelos não invasivos, reconstruíram trajetórias bi [93] e

tridimensionais [92], [112] da mão a partir de *MEG*.

Presacco et al [113] demonstraram que é possível usar os modelos de regressão linear para decodificar movimentos angulares em articulações individuais dos membros inferiores através de componentes de baixa frequência do *EEG*. Ubeda [114],[115], posteriormente conseguiu reduzir significativamente a influência dos artefatos ocasionados pelo movimento, decodificando unicamente o movimento de uma única articulação da perna. Neste trabalho movimentos isotônicos (mesma força no músculo, posição angular variável) de flexão e extensão do joelho foram decodificados em pacientes com danos na medula espinal e saudáveis. Um total de 16 eletrodos, localizados sobre a zona prefrontal, central e parietal, foram utilizados junto com regressão linear multidimensional. Entretanto, a posição angular da perna foi medida com um sistema de sensores inerciais.

O valor ótimo no número de atrasos k na equação 2.6 depende de cada voluntário [115]. O sinal usado nesta codificação teve os tratamentos de pré-processamento comuns, como: normalização, remoção de artefatos e filtragem por bandas. O modelo obteve o parâmetro cinemático usando uma combinação linear dos canais, sujeito ao valor do vetor de pesos \mathbf{a}_k que define a relevância em cada canal no atraso k . Este resultado é comparado com a magnitude real para determinar a correlação final de decodificação através de correlação cruzada.

Este modelo permite decodificar a posição angular do joelho de acordo com uma correta seleção dos parâmetros do modelo. Segundo [114] o modelo tem a possibilidade de codificar movimentos de outras articulações, incluindo a análise de movimentos de maior complexidade com mais graus de liberdade envolvidos. Por outro lado, artefatos gerados pelo movimento não afetam o desempenho do decodificador dado que este reduz ou até elimina seus efeitos.

O modelo obtido a partir da equação 2.6 precisa de treinamento para obter um conjunto ótimo de coeficientes que descrevam a atividade cinemática exibida. Segundo Carmena et al., [103] ao longo das repetições da tarefa, as populações de neurônios exibem modulações relacionados ao movimento durante suas ativações, onde o uso deste modelo linear permite a extração dessas modulações. Este treinamento deve ser avaliado em novos ensaios para testar sua capacidade de predição. Para ajustar o resultado, se deve ter em conta dois parâmetros de configuração do modelo. O primeiro é ajustar as populações de neurônios corticais escolhidas. Respostas ao redor do córtex motor, por exemplo, são as melhores para a predição de variáveis motoras [103]. O segundo parâmetro de desempenho da decodificação é o tempo de atraso usado para prever o sinal. Ensaios feitos para a posição mostraram que uma resposta significativa é encontrada usando dados 2,5 segundos prévios ao ângulo codificado [114].

Contudo, os modelos mencionados previamente consideram o problema de co-

dificação baseado no uso de cada estado de forma isolada, por exemplo posição ou velocidade. Wu et al. [107] encontrou que o desempenho da decodificação pode-se incrementar se o modelo de codificação toma em conta de forma simultânea todas os estados do modelo proposto, por exemplo, posição, velocidade e aceleração. O feito por Wu et al., foi reconstruir o movimento contínuo da mão em tempo real, usando técnicas de inferência Bayesiana para estimar a posição da mão a partir dos ritmos de disparo de múltiplos neurônios.

Os sinais *EEG* eram captados através de *microarrays* de 100 eletrodos implantados por cirurgia no córtex motor de dois macacos. O paradigma experimental reconstruía o movimento bidimensional da mão captado a través de um manipulador de dois graus de liberdade que se movimentava sobre uma tableta paralela ao piso, entretanto uma tela frontal era usada para gerar a ordem de movimento. O objetivo do experimento era que o macaco mediante o manipulador, conseguira seguir um objetivo que se movia de forma suave e aleatória sobre a tela, as amostras do sinal consistiam na atividade *EEG* provenientes dos eletrodos durante a execução do movimento e a posição, velocidade e aceleração da mão.

A inferência Bayesiana consiste em computar a probabilidade *a posteriori* do movimento da mão condicionada á uma sequência de ritmos de disparo [107]. A decodificação foi efetuada usando o filtro de Kalman, que de acordo com o autor, gera um método eficiente para estimar otimamente a probabilidade *a posteriori* quando os modelos de verossimilhança e *a priori* são lineais e gaussianos. Assim, se assume que os ritmos de disparo \mathbf{z} são uma função linear do estado \mathbf{x} mais um ruído gaussiano. Da mesma forma, se assume que o estado da mão no tempo t_k é uma função linear do instante de tempo prévio t_{k-1} mais um ruído gaussiano.

A resolução do modelo, permitiu encontrar um matriz de observação \mathbf{H} que relaciona linearmente os movimentos da mão com a atividade neural. Quando Wu et al. analisaram os coeficientes da matriz, encontraram que tanto a posição como a velocidade da mão estão relacionadas com os ritmos de disparo, entanto que a aceleração é um estado redundante. Estes resultados foram constatados no presente trabalho. Por outro lado, ao comparar o resultado do Filtro de Kalman com filtros lineares, encontrou-se que o primeiro fornece melhores resultados.

Posteriormente o filtro de Kalman foi implementado em modelos humanos, concretamente Pistohl et al., [109] usou sinais de Electroencefalografia (*ECoG*) para determinar a direção do movimento da mão no controle bidimensional para cursores de uma tela. Os eletrodos foram implantados em baixo da dura-máter em seis voluntários. Os resultados encontraram que é possível prever posição e velocidade da mão desde regiões do córtex motor associadas ao movimento da mão com alta correlação. Homer et al., [116] usou o filtro para decodificar a posição e velocidade de um cursor em uma tela movimentado por pacientes con tetraplegia. Hochberg

et al., [117] implementou também o filtro usando implantes para que pessoas com tetraplegia movimentassem um braço robótico decodificado a posição e velocidade da garra do atuador. Finalmente Robinson et al., [108] replicaram o experimento de Wu, usando modelos humanos e dando um passo ao considerar eletrodos localizados externamente. Os resultados permitiram decodificar posição e velocidade em tempo real usando uma integração do filtro de Kalman com sinais *EEG* filtradas com *wavelets*.

Capítulo 3

Classificação de Sinais Cerebrais

Este capítulo apresentará o desenvolvimento de um classificador que interprete a informação cognitiva referente ao movimento do braço em atividades voluntárias para identificar a existência ou não de movimento. Este procedimento permitirá ao *BCI* proposto, discriminar a informação cognitiva extraída do córtex, habilitando o uso de sinais relacionadas com a execução de movimento que serão processadas posteriormente na etapa de decodificação.

As atividades elétricas do cérebro estão relacionadas às ações do corpo humano e suas funções biológicas. Estes processos cognitivos são produto de estímulos aferentes e eferentes, respostas emocionais, pensamentos, controle de funções básicas, entre outros. De fato, se diz que o cérebro recebe 11 milhões de informações por segundo através dos sentidos¹, e processa uma pequena porcentagem de forma consciente, deixando para o subconsciente o resto do trabalho.

O processamento dos Sinais Cerebrais é um conjunto de técnicas matemáticas, físicas e estatísticas usadas para analisar a atividade cognitiva que acontece no córtex cerebral e extrair informações relevantes que consigam relacionar estes processos com funções biológicas do corpo. A partir deste processamento se pode descrever e diferenciar entre eventos cognitivos, dando senso ao caótico comportamento que pode ser captado desde o cérebro.

A classificação de dados consiste na estimação de uma variável qualitativa, denominada *classe*, usando um conjunto de variáveis. Os algoritmos de classificação cognitiva, ajudam a prever as propriedades qualitativas do estado mental do voluntário através da extração de informação útil das leituras da atividade cerebral. Entende-se informação útil aqueles exemplos (*features*) que ajudem a caracterizar uma atividade ou tarefa e, portanto, contribuam na construção dos conjuntos de dados que conformam as classes. Os algoritmos de classificação, portanto, permitem estimar a resposta funcional do cérebro[118].

¹O cérebro consumista: Instituto Brasileiro de *Neuromarketing* e Neuroeconomía, palestra dada na cidade de São Paulo, Março de 2016.

O capítulo é distribuído da seguinte forma: primeiramente serão apresentados os materiais e métodos, onde se descreve o protocolo de captura da atividade elétrica; logo os sinais obtidos a partir de este protocolo serão avaliados para verificar sua correlação com as atividades de movimentação; posteriormente, o sinal será processado, para fazer uma análise comparativo entre as duas atividades cognitivas desenvolvidas, identificando os atributos que permitam classificá-las. Finalmente, uma validação cruzada e fase de *teste* é usada para validar a generalização do algoritmo de classificação.

3.1 Materiais e métodos

Um total de seis voluntários (2 mulheres e 4 homens) com preferência na movimentação do braço direito, sem treinamento prévio para o experimento, participaram nas medições. Os voluntários não reportaram doenças respiratórias, cardíacas, nem outros desordens de tipo metabólico ou uso de medicações e substâncias que alterarem o sinal cerebral. Antes de iniciar o experimento, o voluntário assina um formulário em que aceita as condições do experimento e libera o uso dos dados capturados. Todos os testes seguem o procedimento aceitado pelo comitê de ética do *CCS* da Universidade Federal do Rio de Janeiro, com número de aprovação: 851.521.

Para a tomada de dados, um total de trinta e dois eletrodos passivos *Ag-AgCl* foram distribuídos em torno do crânio seguindo a distribuição de um sistema 10-10 modificado (Figura 3.1). Utilizou-se uma touca (*MCScap da Medical Computer Systems Ltd, Moscow, Russia*) que permitia a locação de eletrodos removíveis. Durante a gravação dos dados, a impedância de todos os eletrodos se preservou menor a $10\text{ K}\Omega$. A referência elétrica foi efetuada nos lóbulos auditivos ($A_1 - A_2$), para evitar interferência com movimentos musculares involuntários. Adicionalmente, dois eletrodos *EMG*, localizados nos bíceps do braços, foram usados para captar a movimentação com duas intenções: determinar o tempo de movimentação para cada voluntário e verificar se a ordem foi executada corretamente.

Paralelamente, um acelerômetro, de referência *MPU6050*, localizado no punho do braço direito, foi usado para captar a posição angular respeito ao cotovelo. O sinal foi processado usando um microcontrolador *Arduino UNO* para obter a posição angular, cujo valor é condicionado para ser transmitido via *PWM*. Um filtro Passa-Baixo (*RC Circuit*) foi usado na saída do dispositivo para converter o *PWM* em um sinal analógico de voltagem de 0 a 3 Volts.

Todos os sinais foram gravados continuamente usando o sistema *Neuron Spectrum 4/EP, NeurosoftLtd*, os sinais *EEG* foram amplificados e digitalizados com uma frequência de amostragem de 1000 Hz e filtradas na frequência de 0.5-100 Hz. Artefatos, como o piscar de olhos e movimentações musculares involuntárias foram




Figura 3.1: Localização dos eletrodos em torno do crânio segundo a disposição do sistema 10-10 modificado. Imagem original obtida do software *EEGLab* do *MATLAB*®.

removidas via *ICA* (*Independent Component Analysis*) usando o software *EEGLab* no *MATLAB*®.

3.1.1 Paradigma Experimental

Durante o experimento, o voluntário encontrou-se sentado dentro de um ambiente com temperatura controlada, livre de ruídos externos e qualquer outra interferência (Figura 3.2). Os braços do voluntário repousaram sobre os apoios da cadeira com as palmas das mãos orientadas para cima e prestes para se movimentar. Entretanto, uma tela localizada à frente do voluntário foi usada para apresentar os comandos de movimentação. Para minimizar o movimento ocular foi localizada uma cruz de fixação no centro da tela. Antes de iniciar a captação dos dados é solicitado a cada voluntário de minimizar os movimentos e o piscar de olhos durante a etapa experimental.

Considera-se um teste como o período de tempo em que o voluntário efetua uma única ação. Cada teste tem uma duração de 10,000 ms (milissegundos), e encontra-se dividido em três intervalos. O intervalo de *Repouso* com duração de 2000 ms, que consistia em um tempo de espera em que o voluntário aguardava a aparição de uma ordem, representada através de um estímulo visual em forma de seta que se localizava no centro da tela.

O intervalo de *Preparação* inicia com a aparição do estímulo e tem uma duração



Figura 3.2: Demonstração da rotina de toma de dados no voluntário.

de 2000 ms. Neste intervalo o voluntário processava a ordem enquanto esperava a desapareção do estímulo. A cor e inclinação da seta indicavam ao voluntário a ação que se devia executar, sendo uma cor preta para execução do movimento, e branca para a não execução. Entretanto a inclinação indicava ao voluntário se o braço a movimentar era o direito e o esquerdo. Para evitar por parte do voluntário, um antecipo do movimento, cada estímulo era gerado por de forma aleatória.

Finalmente no intervalo de execução, que iniciava prontamente o estímulo desaparecia da tela. Este intervalo tinha uma duração de 6000 ms no a qual o voluntário realizava a ação solicitada. Na Figura 3.3 descreve-se o protocolo.

Durante o intervalo de movimento, a ação foi efetuada num período médio de 3000 a 4000 ms, deixando o tempo restante para descanso. De acordo com experimentações prévias, este prolongado tempo é necessário para ajudar na readaptação da atividade cortical reduzindo as variações que existam pela ação executada ao longo dos testes [119].

3.2 Comportamento oscilatório do sinal

Na seção C.6.3 do Anexo C, é mencionada da importância da atividade oscilatória do cérebro durante a execução de tarefas (Seção C.4.2), especialmente no córtex motor onde acontece a atividade cognitiva relacionado ao controle dos movimentos voluntários (Seção C.3.2). Esta atividade oscilatória é dividida em bandas de frequência próximas: Delta (0.1 - 2 Hz), Teta (3 - 7 Hz), Alfa (7 - 16 Hz), Beta (17-30 Hz) e Gama (30 Hz e superior).

Diferentes pesquisas na área da neurociência, têm relatado que o movimento voluntário do membro está relacionado com a aparição de comportamentos oscilatórios espaço temporais bem definidos nas bandas [120], que se manifestam com o incre-

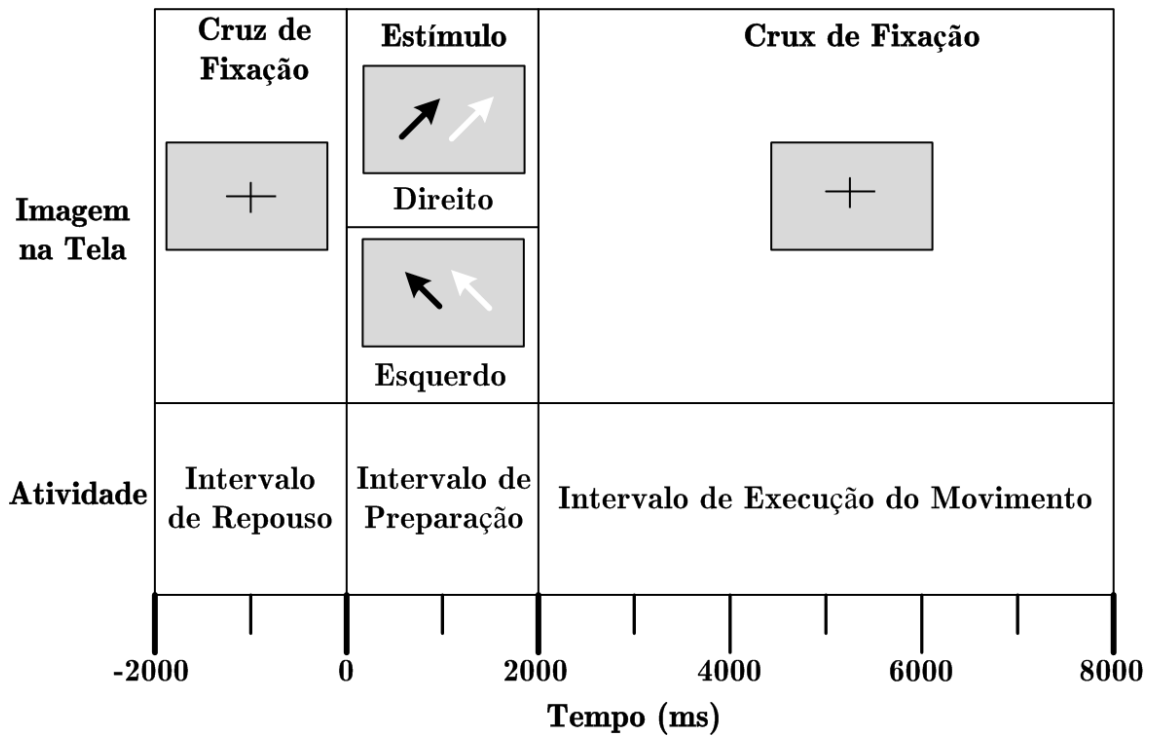


Figura 3.3: Descrição dos comandos na tela, a cor da seta determina a tarefa a ser efetuada, entanto sua inclinação o braço sobre o qual é efetuado o movimento.

mento (*ERS*) ou decremento (*ERD*) da atividade oscilatória (Secção C.6.3). No caso de execução de movimento, manifesta-se esta atividade através de um *ERD* na banda alfa. Esta ação apresenta-se de forma bilateral e simetricamente na zona sensorimotora em movimentos distais e proximais. Na banda beta, se manifesta com um *ERS* ao final do movimento.

Para analisar o comportamento das bandas do sinal *EEG*, foi revisada a informação captada através do canal C_3 , dado que se encontra mais próxima a área do córtex em que se efetua o controle motor do movimento do cotovelo do braço direito, segundo a teoria da distribuição cognitiva do movimento motor vista na seção C.3. Para efetuar esta validação foi usado o o *ERSP* (*Event Related Spectral Perturbation*) do canal. O *ERSP* é uma generalização do *ERD*, mede a média das variações da amplitude em todas as bandas que conformam o sinal em função do tempo de um conjunto de eventos experimentais similares [121]. O *ERSP* estimado pelo *EEGLab*, usa a informação de um único canal ao longo de todos os trials do experimento, plotando um espectrograma normalizado respeito a o intervalo de referência.

Para calcular o *ERSP* é requerido computar a potência espectral de uma janela deslizante e posteriormente calcular o valor médio entre trials. Tipicamente, a estimação espectral é definida como [122]:

$$ERSP(f, t) = \frac{1}{n} \sum_{k=1}^n |F_k(f, t)|^2 \quad (3.1)$$

Sendo n , o número de trials e $F_k(f, t)$ a estimação espectral do k -ésimo teste à frequência f e tempo t . Para computar a estimação espectral a função usa tanto o *FFT* (*Fast Fourier Transform*) como transformada Wavelet. Através de decomposição wavelet, a função constrói o mapa num intervalo de frequências definido pelo usuário. Para visualizar as mudanças na potência através do intervalo de frequência analisado, o logaritmo da potência média do intervalo de referência é subtraído de cada estimação espectral.

Na figura 3.4 é apresentada a resposta do *ERSP* na banda de 2-50 Hz no voluntário 1. O espectrograma usou como sinal de referência a atividade prévia ao estímulo ($t < 0$). A estimação espectral foi calculada usando de wavelets da família Morlet, cujo número de ciclos por frequência foi configurado segundo o padrão do software (3 - 0.5 ciclos distribuídas desde a menor até a maior frequência). Na Figura 3.4 a curva lateral esquerda representa a média do poder espectral, e as curvas localizadas na parte inferior a envolvente média mínima (azul) e máxima (verde) do *ERSP*. Uma escala de cores representa a potência relativa em *dB* da frequência no tempo t .




Figura 3.4: Espectrograma do canal C_3 em do voluntário 1 durante o movimento. O mapa foi construído usando *EEGLab*. Uma aparente dessincronização é vista ao longo da banda alfa (8-15 Hz aproximadamente) após os 2000 milissegundos. Imagem gerada pelo *EEGLab*.

Tendo-se a resposta cortical do voluntário durante o experimento, procedeu-se a comparar com a ação voluntária exercida durante os mesmos trials, na figura 3.5 se apresenta o *EMG* médio do Voluntário 1, cuja amplitude esta expressada em milivolts ao quadrado (mV^2), e a resposta do sensor durante a execução do movimento em Volts (V). Pode-se encontrar que o intervalo médio em que oscila a ação foi aproximadamente de $t = 2500 - 5000$ Este tempo é coincidente com a redução da atividade oscilatória na banda $[7 - 15]$ Hz de acordo com a resposta do *ERSP*. Um posterior *ERD* na banda alfa e beta, coincide com a finalização do movimento executado.

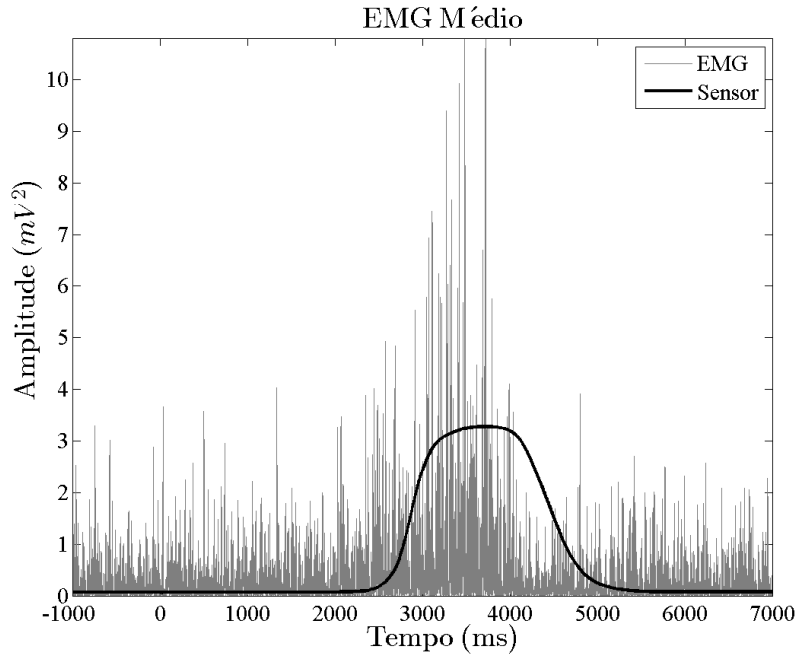


Figura 3.5: Energia média do *EMG*, expressada em milivolts ao quadrado (mV^2), e o sensor de movimento (V) ao longo dos trials de movimento.

Entretanto na Figura 3.6 se apresenta o *ERSP* no canal C_3 para o mesmo voluntário durante os trials em que não efetuou-se movimento. Nas observações analisadas, não se apresentaram as mesmas alterações na atividade oscilatória, tendo a banda um comportamento homogêneo durante estes trials.

De acordo com a comparação feita, considera-se que o sinal *EEG* filtrado na banda $[8 - 15]$ Hz, também conhecida como alfa, poderia fornecer a informação suficiente para ser usado no algoritmo de classificação dado que a dessincronização desta banda está relacionada com a execução do movimento.




Figura 3.6: Espectrograma do canal C_3 no Voluntário 1 durante Não movimento. Construído usando *EEGLab*.

3.3 Classificação do movimento

A classificação do movimento, entende-se, como a diferenciação da atividade cognitiva no córtex, para identificar a execução do movimento. Para que o algoritmo seja preciso no processo de detecção, deve-se garantir que o sinal elétrico usado corresponda à descrição da atividade efetuada. Porém, a informação que acompanha a o sinal que não seja relevante, como outras atividades cognitivas, ruído elétrico e sinais provenientes musculares devem ser removidas.

3.3.1 Pré-processamento

Artefatos como os movimentos musculares, são de fácil detecção, já que possuem uma amplitude claramente maior em comparação com o sinal *EEG*. Os testes que contiveram este tipo de oscilações foram eliminados manualmente. Durante o experimento, a média de testes captados por cada voluntário foi de 60 repetições, assim que foi necessário minimizar o número de testes removidos, maximizando a informação nele contidos.

Existem métodos matemáticos, como o *ICA* (*Independent Component Analysis*), que ajudam neste propósito, ele está incluso em pacotes de processamento de sinais neurais como o *EEGLab*. O método parte do princípio que o sinal captado em cada eletrodo é um somatório linear de fontes independentes, cada uma com fatores

atenuantes ou amplificadores como a distância de origem ou a natureza da geração, que afetam a amplitude do sinal. Estes sinais podem porém ser separados através da medição da independência estatística de cada componente [123], ainda tendo pouco conhecimento acerca da natureza das fontes dos sinais. O *ICA* determina as distâncias existentes entre as fontes e descompõe o sinal. Individualmente cada fonte é avaliada e aquelas que tenham natureza distinta à atividade neural (artefatos), são eliminadas. O sinal, posteriormente é reconstruído sem o artefato.

Desta forma artefatos como o piscar de olhos e movimentos na cabeça são removidos do *EEG* usando o *ICA*. A remoção de componentes, segue os procedimentos sugeridos pelo manual do software, usando como método de decomposição *runica* durante os 10 segundos que tem o sinal em todos os trials.

Logo da remoção de componentes, um filtro Butterworth Passa-Banda de quarta ordem configurado na banda de 1-55 Hz é usado para remover sinais de baixa frequência (0 -0.015 Hz) atribuídas a ruído fisiológico ou movimentação do voluntário [124], e sinais de 60 Hz atribuídas ao sinal elétrico e harmônicos de alta frequência [125].

O sinal finalmente é filtrado na banda alfa (7-16 Hz) usando um filtro passa banda de quarta ordem. Na Figura 3.7 se apresenta o processo de pré-processamento do sinal prévio à fase de classificação.

Pré-Processamento




Figura 3.7: Etapas do pré-processamento para o *EEG* extraído em todos os voluntários.

3.3.2 Determinação do Conjunto de Exemplos

O conjunto de exemplos, é uma matriz de informações que reúne os componentes mais relevantes das classes dentro de um grupo de dados. A etapa de classificação dos comportamentos é sensível a seleção destes exemplos, dado que, um ótimo conjunto de componentes permitirá uma melhor discriminação entre as classes.

Para a construção do conjunto, foi usada a atividade oscilatória da banda alfa. Segmentos do sinal relacionados para os dois comportamentos a serem identificados: movimento e não movimento, foram extraídos do sinal preprocessado. Na Figura

3.8 se ilustra a delimitação das duas ações, comparando o sinal médio do sensor com a atividade média da banda alfa para trials em movimento (indicado no quadro preto da figura superior) como também naqueles em que não foi desenvolvida a ação, ambos sinais encontram-se referenciados ao intervalo de repouso $t < 0ms$. A variação da atividade oscilatória durante a execução ou não de movimento foi similar à vista como o *ERSP*, encontrando-se picos de energia menores a $1\mu V$ durante a execução, e picos que excedem este valor em intervalos de não movimento.

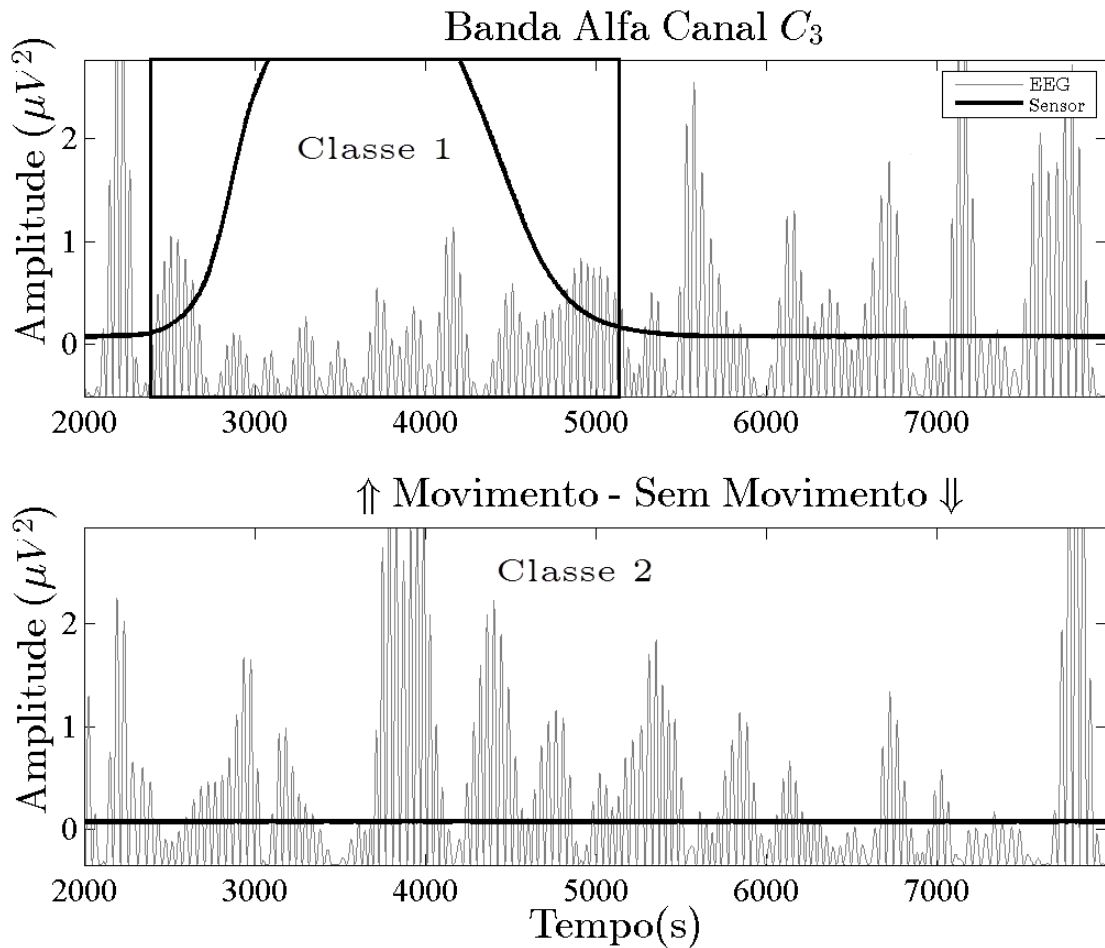


Figura 3.8: Comparação do movimento com a atividade *EEG* da banda alfa. A energia do sinal *EEG* em microvolt ao quadrado (μV^2), referenciada a o intervalo de Repouso ($t < 0$). Observa-se um decremento da amplitude do sinal no intervalo definido pelo quadro preto. Este decremento está associado ao movimento. Entretanto, nas etapas de inatividade do braço o sinal da banda apresenta oscilações com uma amplitude maior respeito ao intervalo descrito.

Besserve et al. [118], considera que, se as sincronizações e dessincronizações de uma determinada banda sejam construídas respeito a uma linha base, este com-

portamento pode ser considerado como um evento que foi induzido por uma ação. Porém, uma atividade contínua, como a execução ou não de um movimento, pode ser caracterizada por medições do *ERD/ERS*. Esta informação pode ser extraída do *EEG* usando estimação espectral ou filtração da banda, como no caso particular.

Portanto, foi definida a *Classe 1*, como a atividade cognitiva relacionada com a execução do movimento, a qual foi conformada por componentes do sinal que se encontraram dentro do intervalo da ação de movimento. E sinais dos testes de não movimento para um $t > 2000ms$ foram usados para conformar a *Classe 2*.

Janelamento

Assumindo que as propriedades do sinal são invariantes ao longo dos segmentos, uma subdivisão T_i foi feita para cada classe. Isto permitiu aplicar análise estatística no sinal *EEG* [126] e também gerar um maior número de janelas as quais foram processadas como múltiplos trials que descrevem a mesma condição experimental [118]. Janelas com divisões do sinal de 1000, 500 e 100 ms, foram criadas para analisar sua influência durante a classificação. O número de exemplos n que compõem cada classe dependerá do valor da subdivisão.

Caracterização da atividade neural

Um conjunto de atributos foram extraídos de cada janela para representar a distribuição tempo-frequência do sinal *EEG*: média, *RMS* e valor máximo; e mudanças na distribuição do sinal *EEG*: desvio padrão e curtoses. [127]. Esta seleção de valores permite que cada janela \mathbf{T}_i seja representada como um ponto pertencente a um espaço de dimensão m .

$$\mathbf{T}_i^{\{k\}} = [x_{1i}, x_{2i}, \dots, x_{mi}] \quad (3.2)$$

Sendo que $x_{mi} \therefore m = [1, 2, \dots, 5], i = [1, 2, \dots, n]$, representa cada um dos 5 atributos que caracterizam $\mathbf{T}_i \in \mathfrak{R}^{1 \times 5}$ das k -ésima, sendo $k = [1, 2]$.

Normalização

Dado que os valores entre atributos possuem distintas magnitudes, é necessário efetuar uma normalização. Assim, evita-se que valores demasiado grandes tenham influência no resultado da classificação. A normalização foi aplicada de forma que os dados tiveram média zero ($\mu = 0$) e variância unitária ($\sigma^2 = 1$).

Uma forma de normalizar um valor é aplicando nele o *Z-score* [128] cuja fórmula é:

$$\hat{x}_{mi} = \frac{x_{mi} - \bar{x}_m}{\sigma}, i = 1, 2, \dots, n \quad (3.3)$$

Sendo: \bar{x}_m a média, σ o desvio padrão de $\mathbf{x}_m \in \mathfrak{R}^{m \times 1}$, e \hat{x}_{mi} é o valor normalizado do i -ésimo atributo de \mathbf{x}_m .

Quantificação da capacidade discriminatória de cada atributo

É necessário quantificar cada atributo normalizado do conjunto de exemplos respeito à sua capacidade de discriminação entre as classes, para isto foi usado o critério de discriminação de *Fisher* (*FDR*) [128]:

$$FDR = \frac{(m_1 - m_2)^2}{\sigma_1^2 + \sigma_2^2} \quad (3.4)$$

Sendo m_1 e m_2 a respectiva média e σ_1^2 e σ_2^2 a variância de associada aos valores de um atributo x_m das classes $c = [1, 2]$. É esperado que atributos com um *FDR* alto sejam aqueles com maior distância entre suas médias e menor variância entre seus valores, entanto, aqueles atributos cujas distribuições se encontrem mais próximas entre si ou superpostas, terão um *FDR* menor.

Seleção de atributos para formar o conjunto de exemplos final

Tendo-se a quantificação da discriminação dos atributos acorde com o *FDR*, o valor numérico correspondente foi organizado decrescentemente. Unicamente os três primeiros parâmetros foram escolhidos, sendo eliminado os restantes. Esta eliminação de atributos é comumente usada para prevenir o *overfitting* e projetar classificadores que possam responder bem no momento de usar dados fora do conjunto de treinamento [128].

A quantificação dos atributos foi efetuada unicamente com sinais do canal C_3 , e posteriormente replicada nos canais adjacentes ordenados de acordo com a coerência de seu sinal. É razoável pensar que esta valoração, é mais precisa naqueles canais que se encontram próximos a C_3 , dado que as oscilações geralmente refletem sincronismo entre regiões próximas[118]. No capítulo 4 encontrou-se que os canais mais afastados localizados na região oposta a C_3 apresentam uma coerência menor a 0.5; portanto, é possível que tenham uma organização de atributos distinta, mais por conveniência, se assume que o critério de seleção de atributos seja similar para todos os canais que conformaram o classificador.

Portanto, o conjunto de exemplos \mathbf{T} descreve-se como:

Tabela 3.1: Descrição do Conjunto de exemplos final

	\mathbf{X}_1			\mathbf{X}_2			\dots	\mathbf{X}_j			\mathbf{Y}
\mathbf{T}_1	$x_{11}^{\{1\}}$	$x_{12}^{\{1\}}$	$x_{13}^{\{1\}}$	$x_{11}^{\{2\}}$	$x_{12}^{\{2\}}$	$x_{13}^{\{2\}}$	\dots	$x_{11}^{\{j\}}$	$x_{12}^{\{j\}}$	$x_{13}^{\{j\}}$	y_1
\mathbf{T}_2	$x_{21}^{\{1\}}$	$x_{22}^{\{1\}}$	$x_{23}^{\{1\}}$	$x_{21}^{\{2\}}$	$x_{22}^{\{2\}}$	$x_{23}^{\{2\}}$	\dots	$x_{21}^{\{j\}}$	$x_{22}^{\{j\}}$	$x_{23}^{\{j\}}$	y_2
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots	\vdots	\vdots
\mathbf{T}_i	$x_{i,1}^{\{1\}}$	$x_{i,2}^{\{1\}}$	$x_{i,3}^{\{1\}}$	$x_{i,1}^{\{2\}}$	$x_{i,2}^{\{2\}}$	$x_{i,3}^{\{2\}}$	\dots	$x_{i,1}^{\{j\}}$	$x_{i,2}^{\{j\}}$	$x_{i,3}^{\{j\}}$	y_i

Na tabela 3.1, cada linha i representa o i -ésimo exemplo ($i = 1, 2, \dots, n$) conformado por j canais ($j = 1, 2, \dots, c$) cada um descrito por três atributos. Se abandonou o uso do subíndice $\{k\}$ para denominar a classe, sendo substituído por o vetor de etiquetas $\mathbf{Y} \in \mathcal{R}^{i \times 1}$ que armazena o valor da k classe do i -ésimo exemplo \mathbf{T}_i , sendo que $y_i \in [c_1, c_2]$. O conjunto de exemplos se pode separar na matriz $\mathbf{X} \in \mathcal{R}^{i \times 3c}$, que contém os valores dos atributos das duas classes distribuídos em colunas, e o vetor \mathbf{Y} que contém as etiquetas contendo a classe que pertence o atributo.

Na figura 3.9 se resume os passos a seguir no processo de extração de exemplos que procede a etapa de pré-processamento descrita na figura 3.7.




Figura 3.9: Etapas da conformação do conjunto de exemplos.

3.3.3 Etapa de Classificação

A etapa de classificação se divide em duas partes: uma redução dimensional feita por *Linear Discriminant Analysis (LDA)*, em português Análise de Discriminantes Lineares, para converter o espaço multidimensional criado pela combinação dos atributos de múltiplos canais em um novo espaço bidimensional conformado pelos dois primeiros discriminantes; uma etapa de classificação dos dados dimensionalmente reduzidos, por uma função discriminante determinada através de *Support Vector Machines (SVM)*, em português Máquina de Vetores de Suporte.

Redução dimensional dos atributos

Foi determinado o uso de *LDA* para reduzir dimensionalmente a matriz do conjunto de Exemplos \mathbf{T} dado que este método, não só cria um novo espaço, mais também ajuda a preservar tanto seja possível a informação discriminatória, calculando a direção do discriminante que maximiza a separação linear entre as classes. Esta

característica diferencia o *LDA* de outros algoritmos para redução dimensional, como o *PCA* [126], quem, cria uma nova dimensão para os atributos através da redução da redundância e minimização do ruído. Esta dimensão encontra-se na direção que maximiza a variância de todos os atributos sem importar a classe.

Ao aplicar o *LDA* no conjunto de exemplos \mathbf{T} , obtêm-se um conjunto de autovetores $\mathbf{W} \in \mathfrak{R}^{3c \times 3c}$, os quais foram organizados decendentemente de acordo à magnitude do respectivo autovalor $\lambda \in \mathfrak{R}^{3c}$. Cada autovetor $\mathbf{w} \in \mathfrak{R}^{3c}$ indica uma direção específica para a projeção dos dados a um espaço unidimensional. A magnitude do respectivo autovalor λ indica a capacidade de discriminação do autovetor.

A projeção dos atributos através dos autovetores é feita com a operação:

$$\mathbf{Z} = \mathbf{X} * \mathbf{W} \quad (3.5)$$

Sendo $\mathbf{Z} \in \mathfrak{R}^{i \times 3c}$ um conjunto de projeções ao longo de todos os autovetores. O modelo descrito em 3.5 é usado quando a matriz \mathbf{X} encontra-se orientada horizontalmente. Atributos alinhados verticalmente requerem do uso da expressão $\mathbf{Z} = \mathbf{W}^T \mathbf{X}$ [129]. O valor projetado \mathbf{z}_i é a soma ponderada dos atributos $\mathbf{x}_i \in \mathfrak{R}^{3c}$ com cada um dos componentes do autovetor \mathbf{w} .

Uma projeção bidimensional dos atributos pode ser feita selecionando os dois primeiros componentes da matriz \mathbf{Z} ou realizando a operação da equação 3.5 usando os dois primeiros autovetores $\mathbf{W} \in \mathfrak{R}^{3c \times 2}$ obtendo $\mathbf{Z} \in \mathfrak{R}^{i \times 2}$.

Classificação

O novo espaço reduzido apresenta a forma descrita na figura 3.10, com elementos das duas classes projetadas no novo espaço bidimensional. Se espera que os dados projetados sejam linearmente separáveis para ser classificados, para isto se precisa de um hiperplano h que classifique os novos pontos para C_1 si $f(x) \geq h$ ou C_2 caso contrário.

Existem múltiplos mecanismos para gerar a fronteira de decisão, como regressão logística, redes neurais, modelos discriminativos baseados na probabilidade, entre outros. O algoritmo selecionado para classificar os dados foi o *SVM*, que descreve uma função linear discriminante da forma $f(x) = \theta \mathbf{x} + \theta_0$, onde θ_0 é o bias e θ o vetor normal à fronteira de decisão $f(x) = 0$.

O *SVM* foi selecionado a partir de uma análise prévia com oito classificadores distintos [130]. Encontrou-se que este classificador oferecia melhor resultado dado que as fronteiras de decisão não lineares poderiam levar a problemas de *overfitting*, em especial quando existia uma grande superposição entre as classes.

Um termo de regularização C é usado durante o treinamento da função de discriminação, que controla a sensibilidade do classificador para alterar a fronteira de




Figura 3.10: Atributos projetados no novo espaço dimensional, e a fronteira de decisão definida pela função $f(x)$.

decisão na presença de *outliers* (valores atípicos). Assim com C grande o processo de treinamento corrigiria a posição da fronteira de forma que o *outlier* seja classificado corretamente, entanto que valores pequenos de C não a alterariam a posição, sendo o algoritmo insensível à presença destes elementos. Os componentes que conformam o hiperplano θ e θ_0 são determinados de forma que minimize $\|\theta\|$ sujeito a que $\theta^T x_i \geq 1$ se $y_i = 1$ e $\theta^T x_i \leq -1$ se $y_i = 0$.

Apesar de o *LDA* poder gerar uma fronteira de decisão também, o *SVM* minimiza o erro de separação focando na vizinhança de pontos da fronteira de linear [131]. Esta propriedade foi aproveitada por [118], que encontrou uma melhoria na classificação dos dados usando *SVM* do que com *LDA* quando são usados mais de 100 exemplos no conjunto usado para treinar o classificador.

Em resumo, aproveitaram-se as propriedades de preservar a informação discriminatória do *LDA* para reduzir dimensionalmente o conjunto de exemplos maximizando a discriminação entre classes e separando-os de forma que possam ser classificados com uma fronteira linear, e também as propriedades do *SVM* para classificar os dados, criando uma função de decisão minimizando o erro de separação entre classes.

Validação cruzada

É necessário avaliar o conjunto de exemplos com todas as alternativas de configuração, no caso, dois parâmetros de configuração requerem ser estimados, o número de canais c e o parâmetro de regularização C . A seleção dos parâmetros do modelo é essencial, para determinar a combinação mais adequada que minimize o erro de classificação. Não obstante, se deve garantir que os parâmetros selecionados se generalizem adequadamente no momento de classificar novos exemplos.

O erro de generalização permite quantificar a capacidade de um modelo de esti-

mar o desempenho do futuro do algoritmo, permitindo selecionar com uma margem de confiança à configuração de parâmetros mais confiável para projetar um algoritmo de classificação com o menor erro [132].

O procedimento para avaliar o algoritmo, requer de dividir o conjunto de exemplos em dois subconjuntos independentes e complementários. O primeiro, o conjunto de *treinamento*, é usado para avaliar os parâmetros do modelo. O segundo, o conjunto de *teste*, é usado para testar o modelo estimado com um conjunto de dados independentes. A comparativa da evolução dos erros durante a etapa de treinamento e validação a partir das mudanças na configuração do modelo é a curva do erro de generalização.

Se o classificador configurado é constituído a partir de poucos exemplos ou se tem um tamanho que seja insuficiente para representar a distribuição dos exemplos, o modelo pode induzir uma hipótese com alto erro durante o treinamento e também na validação. Neste caso, o classificador ajusta-se muito pouco ao conjunto de treinamento acontecendo o que é denominado de *underfitting* ou *bias*. Por outra parte, se o classificador se ajusta de forma específica ao conjunto de exemplos usados durante o treinamento, o modelo pode induzir uma hipótese que tenha ótimos resultados, mas com exemplos diferentes aos usados no treinamento não. Neste caso, a hipótese se ajusta em excesso ao conjunto de treinamento, o que é denominado de *overfitting* [133].

Para resolver o problema de *underfitting* e *overfitting* do modelo, a validação cruzada é aplicada para generalizar o comportamento de um algoritmo de classificação [132], sendo o *k-fold* o método mas usado de validação cruzada [133].

Na figura 3.11 se descreve o funcionamento do *k-fold*. Os dados são divididos em k conjuntos, de igual tamanho. O modelo é treinado k vezes, usando para cada iteração a combinação de $k - 1$ *folds*, o *fold* restante é usado para avaliar o modelo treinado. Na etapa seguinte, um novo modelo é treinado, selecionando um novo *fold* para validação, e usando os restantes para treinamento. O processo se repete até que todos os dados sejam usados para validação e treinamento. O erro da validação cruzada é o erro médio dos k modelos estimados.

Validando todos os parâmetros se pode configurar uma curva de erro de generalização, que permite determinar qual combinação de parâmetros tem o menor erro. Dado que esta curva é criada através da validação cruzada, se espera que o resultado apresentado sejam uma representação do modelo que deve ter uma boa generalização com um conjunto de exemplos novos.

Para assegurar a generalização do modelo, pode-se separar o conjunto de dados em um grupo de *validação cruzada* e um grupo de *teste*. O primeiro grupo treinaria o modelo, encontrado o conjunto de parâmetros que minimiza o erro de classificação, entanto que o segundo, avaliaria a capacidade de generalização do modelo proposto.

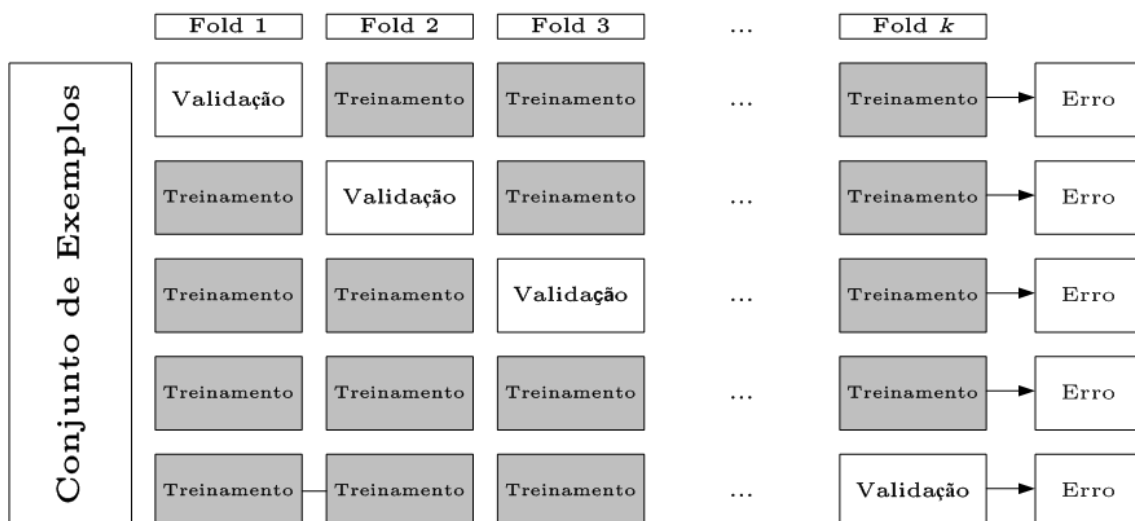


Figura 3.11: Validação cruzada de N -Folds O erro de Validação cruzada é a média dos erros de cada *fold*.

Geralmente é esperado que a resposta da fase de teste seja próxima à de o erro de validação cruzada, dado que o resultado do segundo é uma estimativa do primeiro [128].

Na figura 3.12 se apresenta os passos da etapa de classificação que precede a etapa de conformação do conjunto de exemplos descrita na Figura 3.9 .




Figura 3.12: Etapas da fase de treinamento

3.3.4 Resultados do Treinamento

Dados pertencentes aos 6 voluntários foram usados para o exercício de classificação. O treinamento do sistema de classificação se realizou através de uma validação cruzada de 10 *fold*s. 20 % dos dados foram separados previamente para serem usados na etapa de *Teste*. Dados para treinamento, validação e *teste*, são selecionados aleatoriamente antes de cada corrida.

Os parâmetros de configuração do modelo a serem estudados tiveram as seguintes magnitudes: o número de canais $c = [1 - 34]$, e o coeficiente de regularização $C = [0.03, 0.07, 0.1, 0.7, 1, 7, 10, 70]$. Um procedimento de busca exaustiva foi implementado para avaliar todas as combinações de parâmetros. Os autovetores \mathbf{W} foram treinados de acordo a quantidade de canais usados para realizar a redução di-

mensional. Os dados projetados no novo espaço foram posteriormente usados para treinar o classificador usando a função *svmtrain* do *Matlab*®^(R), sendo configurada com o respectivo coeficiente de regularização encontrando assim os parâmetros θ do modelo.

Posteriormente na fase de validação, a matriz de autovetores \mathbf{W} treinada foi usada para reduzir dimensionalmente os novos dados os quais são testados no modelo de classificador usando a função *svmclassify* do *Matlab*®^(R). O erro de validação é calculado com a porcentagem da razão entre os dados classificados incorretamente f (falsos positivos e negativos) e o total de dados usados durante a validação n_v .

$$Erro = \frac{f}{n_v} \times 100\% \quad (3.6)$$

Na etapa de *teste* se validaram os parâmetros c e C que apresentaram o menor erro de generalização. O erro de classificação foi calculado de acordo a Equação (Equação 3.6) tendo-se em conta o número de exemplos no conjunto de *teste*. Para validar a precisão do classificador, usou-se o *F1 score* como métrica.

Validaram-se janelas de 1000, 500 e 100 ms para analisar seus efeitos no resultado de classificação. Na tabela 3.2 se apresenta a variação da quantidade de exemplos \mathbf{T}_n de acordo com o janelamento feito no sinal em todos os voluntários. Como se obtiveram mais amostras da *Classe 2* C_2 , optou-se por igualar o tamanho deste conjunto à *Classe 1* C_1 , de forma que $n = N_{C_1}$, assim evitou-se treinar classificadores sem balanço entre as classes.

Os gráficos apresentados nesta seção correspondem ao mesmo voluntário. As curvas do erro de generalização e o respectivo *F1 Score* para o resto de voluntários encontram-se no Anexo A.

Tabela 3.2: Número de Exemplos usados pelo classificador em cada voluntário em função do janelamento dos intervalos do sinal de cada classe (1000, 500 e 70 ms).

		Número de Exemplos			
Janela	Voluntário	N_{C1}	N_{C2}	Validação Cruzada (n_v)	teste
1000 ms	1	150	240	240	60
	2	220	240	352	88
	3	235	240	376	94
	4	160	240	256	64
	5	155	240	248	62
	6	122	240	195	49
500 ms	1	338	540	541	135
	2	473	540	757	189
	3	518	540	829	207
	4	351	540	562	140
	5	341	540	546	136
	6	265	540	424	106
70 ms	1	2600	4080	4160	1040
	2	3583	4080	5733	1433
	3	3900	4080	6240	1560
	4	2682	4080	4291	1073
	5	2640	4080	4224	1056
	6	2048	4080	3277	819

Seleção dos atributos

Na Tabela 3.3 se apresenta a quantificação dos atributos de acordo ao valor *FDR*. Pode-se ver que para a maioria dos voluntários o Desvio Padrão, o *RMS* e a Curtoses são os atributos que mais contribuíram com a discriminação entre as classes.

Tabela 3.3: Quantificação dos atributos segundo o *FDR* para todos os voluntários.

Voluntario	Média	Desvio Padrão	Valor Máximo	RMS	Curtoses
1	4	1	5	2	3
2	3	1	5	4	2
3	3	1	4	4	2
4	4	1	5	2	3
5	2	1	5	2	3
6	4	5	1	2	3

Janelas de 1000 ms

Sinais da banda alfa pertencentes a C_1 e C_2 dividiram-se em janelas de 1000 ms. Na figura 3.13 se apresenta a curva de erro de generalização para um dos voluntários. Curvas em preto representam o erro de classificação durante o treinamento, e as cinzas as de validação na medida que aumenta c . Cada curva representa a evolução do erro de segundo o valor do parâmetro C ; dada suas semelhanças o aporte de C na configuração do modelo é mínima.

Na figura 3.14 se apresenta a evolução do *F1 Score* para o mesmo voluntário de acordo ao número de canais. A curva representa a média da métrica ao longo dos 8 parâmetros de regularização, enquanto que as linhas verticais representam o respectivo desvio padrão. A precisão do resultado de classificação aumenta de acordo com a adição de mais canais, não obstante, o efeito de C diminui na media que o numero de canais aumenta, dada a visível redução do desvio padrão em cada ponto.




Figura 3.13: Resultado da Validação Cruzada. A linha preta indica a evolução do resultado da classificação durante o treinamento enquanto aumenta o número de canais c . As linhas cinza indicam o resultado da classificação durante a etapa de validação. As múltiplas linhas ao longo da curva indicam a evolução da resposta de acordo aos valores do Coeficiente de Regularização C .




Figura 3.14: F1 Score Médio da validação, a curva apresenta a variação do resultado na medida que aumenta o número de canais.

Na figura 3.15 se apresenta a matriz de exemplos da validação \mathbf{T} após a redução dimensional junto com a função de discriminação configurados a partir de os parâmetros com menor erro de generalização. A cruz vermelha representa a exemplos de C_1 , entretanto os asteriscos verde a exemplos de C_2 , dados rodeados em círculos pretos indicam a posição dos *support vectors* (vetores de suporte) usados para estimar a posição da função discriminadora descrita pela linha preta.

Ao aplicar os elementos treinados no conjunto de *teste*, obtêm-se o resultado descrito na figura 3.16. Os atributos do conjunto foram reduzidos dimensionalmente com os dois primeiros autovetores da matriz \mathbf{W} , e posteriormente classificados usando a estrutura do *SVM*. O erro de classificação do *teste* foi próximo ao apresentado durante a curva de erro de generalização, usando um total de 27 canais com um coeficiente de regularização 0.03.

Na tabela 3.4 se apresenta o resultados da classificação do conjunto de *teste* para todos os voluntários usando janelas de 1000 ms.




Figura 3.15: Resultado de treinamento como os melhores parâmetros avaliados na Validação cruzada. Atributos do sinal *EEG* relacionada ao movimento (cruz) e não movimento (asterisco) após a redução dimensional. A linha é a função de discriminação, entanto que os círculos pretos indicam os dados usados como *Support Vectors* durante o treinamento do classificador.

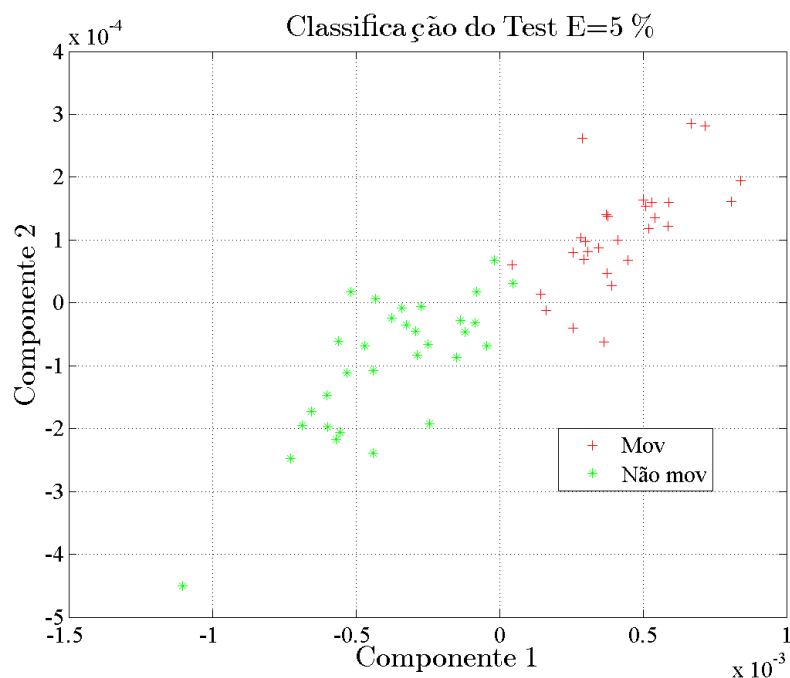


Figura 3.16: Classificação do set de *teste*. Atributos do sinal *EEG* relacionada ao movimento (cruz) e não movimento (asterisco) após a redução dimensional são classificados usando os autovetores \mathbf{W} e os coeficientes θ que minimizaram o erro de classificação durante a etapa de validação cruzada.

Tabela 3.4: Resultados da classificação dos exemplos de *teste* em todos os voluntários usando janelas de 1000 ms. Apresenta-se o erro e o respectivo *F1 Score*, como também os parâmetros que minimizaram o erro de generalização em cada voluntário.

Voluntário	Error Teste (%)	F1 Score	C	Canais
1	5	0,98	0,03	27
2	1,14	0,99	0,01	10
3	0	1	0,01	33
4	9,3	0,97	0,01	30
5	6,4	0,97	70	33
6	10,4	0,96	0,03	32

Segundo estes resultados, encontrou-se que os erros de treinamento e validação tendem a diminuir na medida que aumenta o número de canais do conjunto de exemplos. Entretanto, o parâmetro de regularização C usado para configurar o *SVM* não alterou o comportamento das curvas significativamente, em consequência, encontram-se tendências similares em cada erro de generalização sem importar o valor do parâmetro.

Ao verificar esta tendência em todos os voluntários (Ver Anexo A), se pode concluir que o desempenho do algoritmo de classificação depende significativamente da adição de atributos ao vetor de características, cujo valor discriminatório aporta na etapa de redução dimensional, alterando a separabilidade entre as classes avaliadas. Isto pode ser comprovado ao comparar distintas etapas da redução dimensional ao longo dos canais. Na Figura 3.17 se apresenta a tendência do *FDR* do primeiro discriminante, obtido após redução dimensional das classes. Ao longo de todos os voluntários na medida que eram adicionados mais canais ao vetor de exemplos. A métrica apresenta um aumento progressivo da discriminação, indicando que as classes após a redução dimensional, tendem a se separar entre elas.

Um efeito desta separação é que o número de exemplos que ultrapassam a função de discriminação tende a diminuir (*outliers*), porém, modelos treinados com valores de C próximos a zero podem ser similares como também, seus resultados de classificação. Mesmo seja aumentado o valor de C , e o classificador altere a posição da fronteira de decisão, este valor de erro não mudará significativamente. Em efeito que, qualquer correção da estimacão da classe destes exemplos, sendo de um número menor em comparação ao total existente, não alterará significativamente o resultado do classificador, consequentemente o desvio padrão do parâmetro C durante o *F1 Score* tenderá a cair na medida que c aumenta.

Por outro lado, no caso de existir muitos destes *outliers* por efeito da menor discriminação entre classes, encontra-se que a fronteira de decisão ótima não é mais linear, ante esta situação uma recomendação é diminuir o parâmetro de regularização

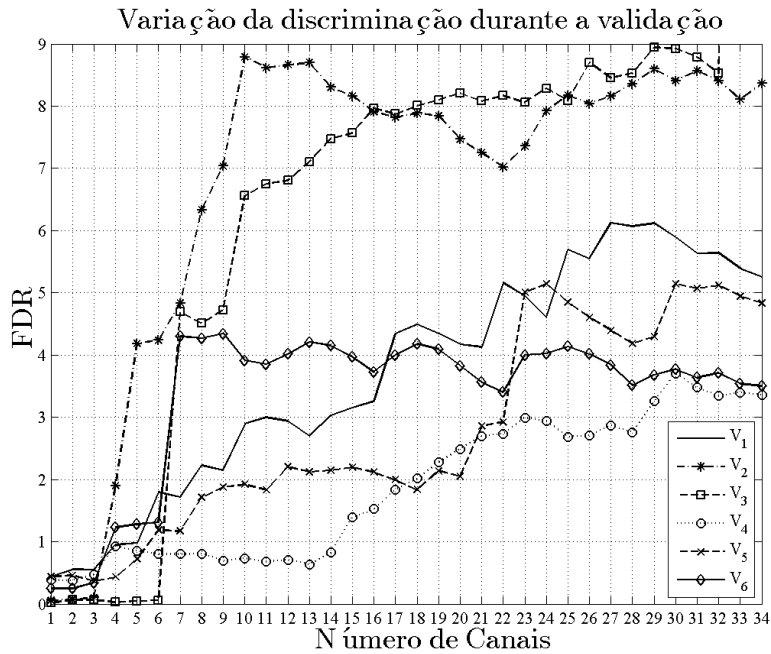


Figura 3.17: Evolução da discriminação das classes ao adicionar mais canais no vetor de exemplos. Pode-se ver que a discriminação cresce progressivamente na medida que aumenta o número de canais, indicando que, as classes tendem-se a separar respeito a adição de mais atributos.

C para que o classificador seja mais sensível aos *outliers* admitindo-os dentro da região que configura o hiperplano. Isto faz incrementar o valor do margem do discriminador, como também da generalização do modelo. Esta ação em consequência pode levar a um aumento do erro de classificação. Se o parâmetro C fosse maior, o treinador tentará encontrar o melhor modelo que minimize o erro de classificação. É dizer, que sim importar qual seja o valor de C , quando se aplicam poucos atributos no vetor de exemplos, é altamente provável que exista um maior erro na estimação da classe por causa da menor discriminação entre elas.

Janelas de 500 ms

Sinais da banda alfa pertencentes a C_1 e C_2 dividiu-se em janelas de 500 ms. Na figura 3.18 se apresenta a curva de erro de generalização no voluntário escolhido de exemplo.

Na Figura 3.19 se apresenta a variação do *F1 Score*, e a na Figura 3.20 se apresenta o respectivo resultado do treinamento. Entretanto na Figura 3.21 se apresenta o resultado da classificação do conjunto de *teste* aplicando os parâmetros treinados.




Figura 3.18: Resultado da Validação Cruzada. A linha preta grossa indica a evolução do resultado da classificação durante o treinamento enquanto aumenta o número de canais c . As linhas cinza indicam o resultado da classificação durante a etapa de validação. As múltiplas linhas ao longo da curva indicam a evolução da resposta de acordo aos distintos valores do Coeficiente de Regularização C usando durante o treinamento.




Figura 3.19: F1 Score Médio da validação, a curva apresenta a variação do resultado na medida que aumenta o número de canais.

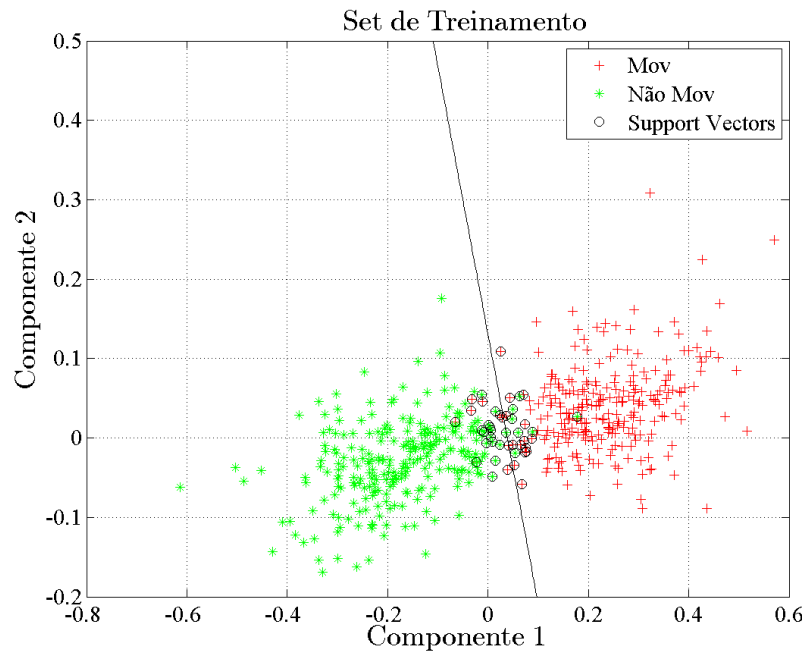


Figura 3.20: Resultado de treinamento como os melhores parâmetros avaliados na Validação cruzada. Atributos do sinal *EEG* relacionada ao movimento (cruz) e não movimento (asterisco) após a redução dimensional. A linha é a função de discriminação, entanto que os círculos pretos indicam os dados usados como *Support Vectors* durante o treinamento do classificador.

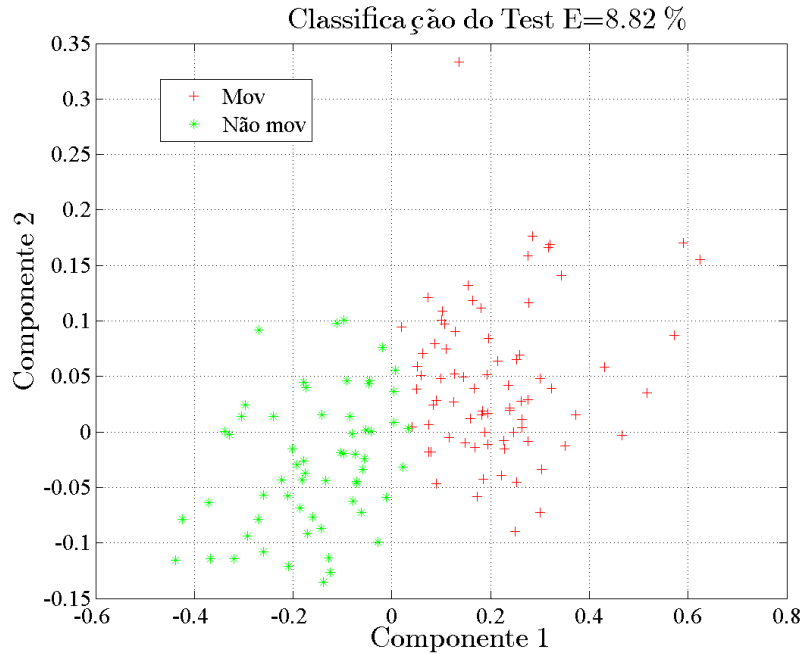


Figura 3.21: Classificação do set de *teste*. Atributos do sinal *EEG* relacionada ao movimento (cruz) e não movimento (asterisco) após a redução dimensional são classificados usando os autovetores \mathbf{W} e os coeficientes θ que minimizaram o erro de classificação durante a etapa de validação cruzada.

Na tabela 3.5 se descreve os resultados da classificação do conjunto de *teste* para todos os voluntários usando janelas de 500 ms.

Tabela 3.5: Resultados da classificação de *teste* para todos os voluntários usando janelas de 500 ms. Apresenta-se o erro e o respectivo *F1 Score*, como também os parâmetros usados para a redução dimensional e a classificação dos dados.

Voluntário	Error Teste (%)	F1 Score	C	Canais
1	8,85	0,98	10	30
2	0,53	0,99	0,03	32
3	0,48	0,99	0,7	33
4	12,1	0,95	0,1	30
5	8,09	0,96	7	30
6	9,43	0,94	70	24

Ao diminuir o tamanho da janela, perdeu-se exatidão na classificação dos dados do voluntário de exemplo. Tanto a curva de treinamento como de validação aumentaram seu erro mínimo de estimação com respeito ao uso de janelas de maior valor. Por outro lado, a variabilidade por causa do parâmetro de regularização C é menor, sendo evidente na curva do *F1 Score*, onde, o comprimento das linhas de

variança tem decaído em magnitude. Em consequência o erro de *teste* aumenta em comparação às janelas maiores em todos os voluntários.

Janelas de 70 ms

Sinais da banda alfa pertencentes a C_1 e C_2 dividiu-se em janelas de 70 ms. Na figura 3.22 se apresenta um exemplo de curva de erro de generalização no voluntário escolhido de exemplo.




Figura 3.22: Resultado da Validação Cruzada. A linha preta grossa indica a evolução do resultado da classificação durante o treinamento enquanto aumenta o número de canais c . As linhas cinza indicam o resultado da classificação durante a etapa de validação. As múltiplas linhas ao longo da curva indicam a evolução da resposta de acordo aos distintos valores do Coeficiente de Regularização C usando durante o treinamento.

Na figura 3.23 se apresenta a variação do *F1 Score* para o mesmo voluntário, na figura 3.24 se apresenta um resultado do treinamento. Entretanto na figura 3.25 se apresenta o resultado da classificação do conjunto de *teste* aplicando os parâmetros treinados.

Na tabela 3.5 se apresenta o resultados da classificação do conjunto de *teste* para todos os voluntários usando janelas de 70 ms.




Figura 3.23: F1 Score Médio da validação, a curva apresenta a variação do resultado na medida que aumenta o número de canais.

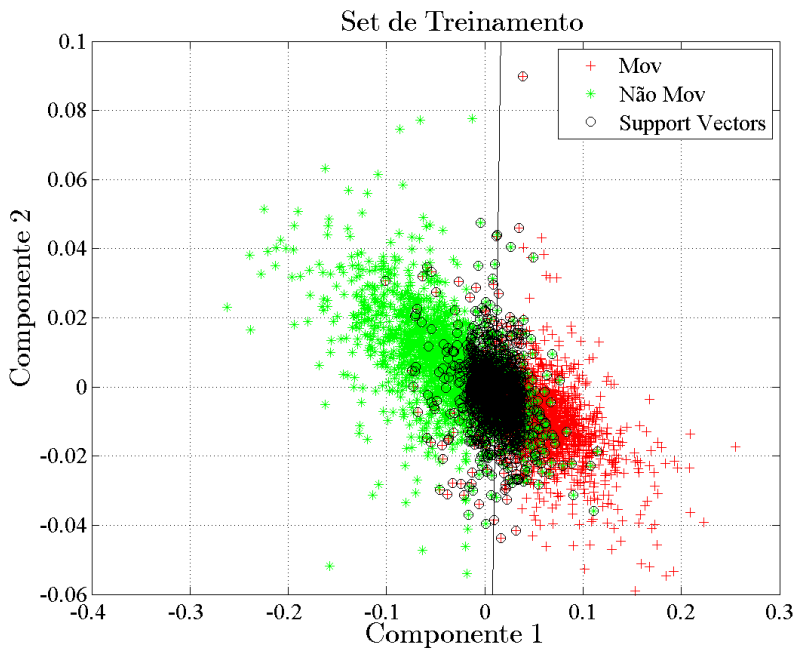


Figura 3.24: Resultado de treinamento como os melhores parâmetros avaliados na Validação cruzada. Atributos do sinal *EEG* relacionada ao movimento (cruz) e não movimento (asterisco) após a redução dimensional. A linha é a função de discriminação, entanto que os círculos pretos indicam os dados usados como *Support Vectors* durante o treinamento do classificador.

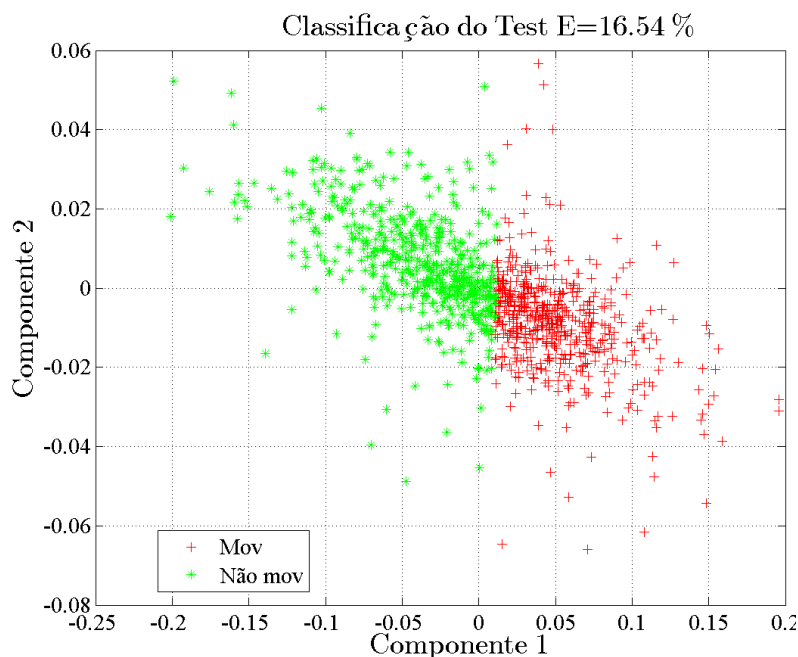


Figura 3.25: Classificação do set de *teste*. Atributos do sinal *EEG* relacionada ao movimento (cruz) e não movimento (asterisco) após a redução dimensional são classificados usando os autovetores \mathbf{W} e os coeficientes θ que minimizaram o erro de classificação durante a etapa de validação cruzada.

Tabela 3.6: Resultados da classificação de *teste* para todos os voluntários usando janelas de 70 ms. Apresenta-se o erro e o respectivo *F1 Score*, como também os parâmetros usados para a redução dimensional e a classificação dos dados.

Voluntário	Error Teste (%)	F1 Score	C	Canais
1	16,5	0,92	7	33
2	4,2	0,98	0,7	33
3	0,58	0,99	1	34
4	17,7	0,93	0,03	34
5	15,2	0,93	0,03	31
6	17,6	0,89	0,1	34

O erro de classificação aumentou ao encontrado com as janelas prévias. Embora, apesar de este aumento, o *overfitting* entre as curvas de treinamento e validação diminuiu a menos de 5 pontos percentuais, isto é consequência de o aumento do número de exemplos.

Se pode ver também que um alto número de *Support Vectors* são considerados para estimar a função de classificação, evidenciando a alto margem dado a baixa discriminabilidade das classes, mesmo sejam aumentados o número de canais. Esta configuração dos exemplos explica porque aumentou o erro de *teste* em estas ja-

nelas. Entretanto o efeito do coeficiente de regularização C é nulo para janelas deste tamanho, dado que não consegue alterar o resultado da estimação da classe em nenhum dos valores avaliados, isto se evidencia com as pequenas linhas de desvio padrão presentes na curva do $F1$ -Score.

3.4 Discussão

Neste capítulo estudou-se a classificação offline de sinais EEG para estimar a existência de movimento ou não através do processamento da atividade cognitiva que acontece durante a manifestação da ação.

Para determinar que sinais poderiam conformar o vetor de exemplos, efetuou-se uma análise do sinal usando $ERSP$. Através deste método foi possível constatar que o comportamento da atividade elétrica no córtex motor é próximo ao encontrado na literatura [120], com dessincronizações na banda alfa acompanhando o movimento e sincronizações da banda beta ao final do movimento, estes eventos não foram encontrados durante as ações de não movimento.

Para representar a classe 1 (C_1) do classificador, intervalos de inibição da banda alfa em trials de movimento foram usados, e para a classe 2 C_2 , usando os trials de não movimento, consideraram-se os intervalos de sinal EEG posteriores aos 2000 ms. Comparando a resposta encontrada na classificação dos conjuntos de *teste* com as curvas de generalização, pode-se aceitar a generalização dos intervalos de ativação e inibição. Isto, sempre e quando se tenha boa regularização das práticas experimentais, com controle da frequência dos estímulos e geração aleatória das ordens que leva a criação de amostras independentes, e também com um conjunto alto de repetições que permita desenvolver resultados estatisticamente significativos com alta reprodutibilidade.

Também conseguiu-se uma classificação dos dados com uma resposta aceitável sendo $> 90\%$ na maioria dos voluntários usando janelas de 1000 ms. Com uma redução $> 80\%$ usando janelas de 100 ms. Entretanto o $F1$ Score manteve-se superior ao 0,9 em todos os casos, indicando a precisão do algoritmo. A integração do LDA para reduzir dimensionalmente os atributos extraídos e o SVM para determinar a hipótese da classe ajudou a conseguir estes resultados.

Encontrou-se que ao aumentar o número de canais, pode-se incrementar a discriminação entre as classes após a redução dimensional, conseguindo melhorar o erro de classificação para todos os casos avaliados. Também encontrou-se que o parâmetro de regularização C do classificador não é significativo para o resultado do algoritmo, dado que seu aporte a melhorar a estimação da classe do ponto diminuiu na medida que são usados mais canais. Este resultado é coincidente com o apresentado por Besserve et al., [118], afirma que, o SVM tende a ser menos sensível à dimensão

dos vetor de exemplos, característica que foi constatada ao apreciar a pouca variação do resultado às mudanças do parâmetro de regularização C . Assim de acordo com as respostas obtidas, em geral pode-se trabalhar com SVM treinados com parâmetros C grandes, maiores a 10. Assim quando existir baixa separação entre as classes o classificador possa generalizar um resultado em função dos *support vectors* admitidos para construir a função de discriminação.

Foi usado um classificador linear para estimar a classe dos dados. Experiências prévias usando modelos não lineares [130], nos permitiram levar a conclusão que, porém o resultado fosse aceitável, seu uso não conseguiu melhorar a resposta à encontrada com classificadores lineares. Conclusões similares podem ser encontradas em [118], que cita: um classificador linear é o suficientemente robusto e flexível como para desenvolver o problema de classificação com uma precisão aceitável.

A adição de canais contribui ao aumento da discriminação entre as classes. Ao constatar as curvas de erro generalizado, pode-se encontrar intervalos onde o erro de classificação não é reduzido significativamente, sendo em alguns casos o aporte menor ao 1 %. Na figura 3.26 se apresenta um análise da variação do erro de classificação durante a validação em função do número de canais em todos os voluntários.

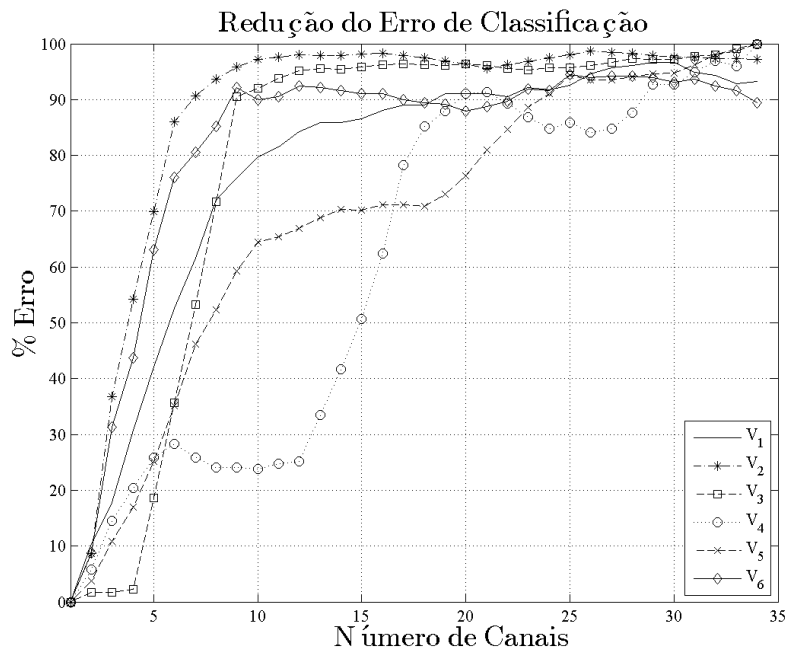


Figura 3.26: Redução do erro de classificação em todos os voluntários. O gráfico apresenta a contribuição que um grupo de canais fez durante a classificação. Na maioria dos voluntários a contribuição decai na medida que o número de canais aumenta.

No gráfico o eixo vertical apresenta o percentual que mede a contribuição na discriminação até um determinado número de canais em função do erro máximo

de classificação encontrado em cada voluntário. Assim, pode-se ver que em 3 voluntários com um total de 10 canais se pode encontrar uma redução do erro de classificação próximo ao 90%, e em 4, com 15 canais um erro maior ao 80%. Tendo em conta que, canais foram organizados descendentemente em função da coerência com o canal C_3 o aporte dos canais mais distantes é menor e sendo sua contribuição uma consequência do efeito acumulativo.

Por tanto, os canais mais próximos ao canal de referência têm maiores probabilidades de aumentar o efeito discriminador, sendo na maior parte dos voluntários aqueles canais localizados na zona contralateral ao movimento. A resposta do classificador é dependente do voluntário, assim em casos específicos é necessário ajustar o conteúdo dos atributos para melhorar a resposta de classificação, é dizer, que este fator não necessariamente pode-se generalizar entre todos os voluntários. Por exemplo, em alguns voluntários a dessincronização se evidenciou mais próxima a alfa baixa, porém, a banda do sinal tampouco pode ser um parâmetro que se pode generalizar entre os voluntários.

Entretanto, o *overfitting* da curva do erro de generalização não ultrapassou o 10% para alguns voluntários. Se acredita que que o uso de atributos reduzidos para caracterizar as classes ajudou a incrementar a discriminação entre os dados sem comprometer a generalização do classificador. Na medida que o número de exemplos aumentava, por conta de a redução do tamanho da janela, encontrou-se um aumento tanto do erro de treinamento como de validação, contudo, o *overfitting* entre as curvas não foi superior em alguns voluntários aos 5 pontos percentuais. O uso de mais exemplos para diminuir o *overfitting* é uma prática comum na área de Aprendizado de Máquinas para corrigir o desempenho de um algoritmo ².

Seguindo com o tópico da precisão, se tem que considerar o efeito do comprimento da janela. Pode-se pensar que na hora de comparar atributos, construídos por janelas de menor tamanho, aumenta a probabilidade de encontrar data sets com a mesma informação. Por tanto, janelas maiores aportam maior informação discriminatória dado que sua informação é menos invariante em comparação com as pequenas.

Os resultados encontrados neste capítulo serão considerados para configurar o classificador no modelo *BCI* de laço fechado a ser implementado no Capítulo 6.

²Edward Ng. 2016. *Machine Learning Introduction*. Curso Virtual.

Capítulo 4

Codificação da Cinemática do movimento do Cotovelo, métodos e treinamento

Desde seu descobrimento na década de 60, o Filtro de Kalman tem sido aplicado extensivamente em diversas áreas como: processos contínuos de manufatura, navegação de aviões, barcos e naves espaciais e mais recentemente em codificação de atividade motora no córtex cerebral.

O Filtro de Kalman é definido como um conjunto de equações matemáticas que fornecem um método computacional eficiente para estimar o estado de um modelo, em uma forma que minimiza o erro médio quadrático. O filtro permite estimar o passado, presente e o futuro de um estado, fazendo-o incluso mesmo quando a natureza do modelo é desconhecida [134].

O Filtro de Kalman é útil para ser aplicado em sistemas de controle onde, por causa do ruído não é sempre possível ter medições de cada variável a ser controlada, fornecendo uma forma de inferir as informações faltantes destas medições. Kalman propaga toda a distribuição de probabilidade da variável que se deseja estimar, caracterizando o estado atual do modelo tendo em conta as influencias de todas as medições prévias [135].

4.1 O Estimador de Kalman

Kalman funciona como um estimador, resolvendo o problema de estimar o estado instantâneo de um sistema linear dinâmico perturbado com ruído branco (Equação 4.1), usando medições relacionadas linearmente como o estado, corrompidas com ruído branco(Equação 4.2).

Formalmente, sendo o estado $\mathbf{x} \in \mathbb{R}^n$ de um modelo que é determinado pela

equação linear de diferenças:

$$\mathbf{x}_k = \mathbf{A}x_{k-1} + \mathbf{B}u_{k-1} + \mathbf{w}_{k-1} \quad (4.1)$$

Com uma medição $\mathbf{z} \in \mathfrak{R}^m$

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k \quad (4.2)$$

Representando \mathbf{w}_k e \mathbf{v}_k o ruído branco do estado e da medição respectivamente. Eles são assumidos independentes um do outro e com função de probabilidade normal com media 0 e matrizes de covariância \mathbf{Q} para o estado e \mathbf{R} para a medição:

$$\begin{aligned} p(\mathbf{w}) &\sim (0, \mathbf{Q}), \\ p(\mathbf{v}) &\sim (0, \mathbf{R}) \end{aligned} \quad (4.3)$$

A matriz \mathbf{A} de dimensão $n \times n$ na equação 4.1 relaciona tempo prévio $t_k - 1$ com o atual t_k . Na prática \mathbf{A} é variável para cada t_k , mais é assumida como constante [134]. A matriz \mathbf{B} de $n \times l$ relaciona a entrada opcional de controle $\mathbf{u} \in \mathfrak{R}^l$ com o estado \mathbf{x} . A matriz \mathbf{H} de dimensão $m \times n$ na equação 4.2 relaciona o estado \mathbf{x}_k com a medição \mathbf{z}_k . Da mesma forma que \mathbf{A} , esta matriz pode variar, mais é assumida constante.

4.1.1 Operação do Filtro

O filtro funciona definindo dois estados: o estado *a priori* $\hat{\mathbf{x}}_k^- \in \mathfrak{R}^n$, estimando no tempo t_k através do conhecimento prévio do modelo, e o estado *a posteriori* $\hat{\mathbf{x}}_k \in \mathfrak{R}^n$, estimado no tempo t_k dada a medição \mathbf{z}_k . São definidos os erros de estimação do estado *a priori* e *a posteriori* como:

$$\begin{aligned} \mathbf{e}_k^- &\equiv \mathbf{x}_k - \hat{\mathbf{x}}_k^-, \\ \mathbf{e}_k &\equiv \mathbf{x}_k - \hat{\mathbf{x}}_k \end{aligned} \quad (4.4)$$

Sendo a covariância do erro estimado *a priori* e *a posteriori* no tempo t_k :

$$\begin{aligned} \mathbf{P}_k^- &= E[\mathbf{e}_k^- \mathbf{e}_k^{-T}] \\ \mathbf{P}_k &= E[\mathbf{e}_k \mathbf{e}_k^T] \end{aligned} \quad (4.5)$$

O objetivo é encontrar uma equação que computa o estado estimado *a posteriori* $\hat{\mathbf{x}}_k$ como uma combinação linear de um estado estimado *a priori* $\hat{\mathbf{x}}_k^-$ e a diferença entre a medição atual \mathbf{z}_k com a predição da medição $\mathbf{H}\hat{\mathbf{x}}_k^-$ que se encontra multiplicada por uma matriz de pesos \mathbf{K} . A solução para este problema se descreve na equação:

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}(\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-) \quad (4.6)$$

A diferença $(\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-)$ é denominada de resíduo [134], e mede a discrepância entre a predição da medição $\mathbf{H}\hat{\mathbf{x}}_k^-$ e a medição atual \mathbf{z}_k . Entretanto os ganhos da matriz \mathbf{K} de dimensão $n \times m$ são aqueles que minimizam o erro quadrático médio da estimação. Esta expressão é formada a partir da covariância do erro estimado *a posteriori*, substituindo 4.4 em 4.5, tendo-se:

$$\mathbf{P}_k = E[(\mathbf{x}_k - \hat{\mathbf{x}}_k)(\mathbf{x}_k - \hat{\mathbf{x}}_k)^T] \quad (4.7)$$

Substituindo 4.6 em 4.7, e desenvolvendo o valor esperado E obtêm-se a expressão:

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k^- (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k)^T + \mathbf{K}_k \mathbf{R}_k \mathbf{K}_k^T \quad (4.8)$$

Deseja-se encontrar o valor particular de \mathbf{K}_k que minimiza os termos individuais da diagonal principal de \mathbf{P}_k dado que eles representam a estimação das variâncias dos erros dos elementos do estado que querem ser estimados. Para resolver o problema de otimização, pode-se achar a minimização do termo derivando-se 4.8 com respeito a \mathbf{K} e igualando-se a zero [136], obtendo-se finalmente:

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}^T (\mathbf{H} \mathbf{P}_k^- \mathbf{H}^T + \mathbf{R})^{-1} \quad (4.9)$$

Este é o valor de \mathbf{K}_k que minimiza o erro quadrático médio da estimação, sendo denominado como *Ganho de Kalman*. De acordo com 4.9 na medida em que a covariância do erro da medição \mathbf{R} aproxima-se de zero, o ganho \mathbf{K} pondera maiormente o valor do resíduo, levando a que:

$$\lim_{\mathbf{R}_k \rightarrow 0} \mathbf{K}_k = \mathbf{H}^{-1} \quad (4.10)$$

Entretanto na medida em que a covariância do erro estimado *a priori* \mathbf{P}_k^- aproxima-se de zero, o ganho \mathbf{K} pondera o resíduo minoritariamente, levando a que:

$$\lim_{\mathbf{P}_k^- \rightarrow 0} \mathbf{K}_k = 0 \quad (4.11)$$

Finalmente, a matriz de covariância associada com o valor ótimo estimado \mathbf{P}_k é calculada substituindo 4.9 em 4.8:

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k^- \quad (4.12)$$

A equação 4.12 é usada pelo filtro para atualizar a matriz de covariância do erro após de corrigir a estimação do estado. Entanto a covariância do erros estimado *a priori* \mathbf{P}_k^- é calculada substituindo 4.1 em 4.4 e resolvendo se encontra a expressão:

$$\mathbf{P}_k^- = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q} \quad (4.13)$$

Abordagem probabilística condicionada do filtro de Kalman

A forma da equação 4.6 está justificada de um ponto de vista gaussiano, assumindo uma distribuição de probabilidade condicional [136] em que o valor estimado de \mathbf{x}_k está condicionado com todas las medições prévias \mathbf{z}_k , é dizer $P(\mathbf{x}_k | \mathbf{z}_k)$.

Resolvendo o modelo de probabilidade condicional aplicando o teorema de Bayes, encontra-se uma nova distribuição normalmente distribuída sempre e quando o ruído que acompanha o sinal tenha as características descritas em 4.5. Nesta nova distribuição o valor do estado estimado *a posteriori* em 4.6 expressa sua media, com uma variância da distribuição igual à covariância do erro estimado a posteriori 4.13:

$$\begin{aligned} P(\mathbf{x}_k | \mathbf{z}_k) &= N(\hat{\mathbf{x}}_k, \mathbf{P}_k) \\ P(\mathbf{x}_k | \mathbf{z}_k) &= N(\hat{\mathbf{x}}_k^- + \mathbf{K}(\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-), (\mathbf{I} - \mathbf{K}_k\mathbf{H}_k)\mathbf{P}_k^-) \end{aligned} \quad (4.14)$$

É dizer que de um ponto de vista probabilístico condicionado é possível encontrar a forma da equação 4.6, onde $\hat{\mathbf{x}}_k$ é o valor estimado mais provável, dado que ele representa o máximo da distribuição. A solução desta equação também pode ser encontrada a partir do modelo que relaciona a estimação *a posteriori* com uma combinação linear da estimação *a priori* $\hat{\mathbf{x}}_k^-$ mais a medição \mathbf{z} :

$$\hat{\mathbf{x}}_k = \mathbf{K}_k^1 \hat{\mathbf{x}}_k^- + \bar{\mathbf{K}}_k \mathbf{z}_k \quad (4.15)$$

Sendo as matrizes \mathbf{K}_k^1 e $\bar{\mathbf{K}}_k$ encontradas resolvendo o problema de otimização do modelo 4.15 usando mínimos quadrados,[135], encontra-se que os valores destas matrizes equivalem a:

$$\begin{aligned} \mathbf{K}_k^1 &= \mathbf{I} - \mathbf{K}_k\mathbf{H}_k \\ \bar{\mathbf{K}}_k &= \mathbf{K}_k \end{aligned} \quad (4.16)$$

Substituindo 4.16 em 4.15, encontra-se uma forma reescrita da Equação 4.6. O resultado expressa à estimação encontrada como uma combinação linear de duas medições independentes de x_k , sendo a primeira a estimação *apriori* que é o resultado cumulativo de todas as medições prévias, e a segunda, a nova informação acerca do estado segundo as medições.

4.1.2 Algoritmo do Filtro de Kalman

O algoritmo de Kalman trabalha de forma cíclica usando as equações 4.1,4.6, 4.9, 5.13 e 4.13. O filtro estima os estados do modelo no tempo t_k obtendo uma resposta que é realimentada para atualizar os valores estimados. Este procedimento é realizado em duas fases: a primeira denominada de *predição* do estado, e a segunda denominada de *correção* do estado. Na primeira fase, Kalman estima os valores do estado atual $\hat{\mathbf{x}}_k^-$, posteriormente, em função da variável medida \mathbf{z}_k esta estimação é atualizada incorporando uma correção ao valor $\hat{\mathbf{x}}_k^-$, atualizando posteriormente o erro de estimação, e iniciando assim o processo novamente.

Na figura 4.1 se apresenta o funcionamento do filtro adicionando as equações envolvidas em cada fase. Na etapa de predição, o filtro propaga o valor da variável estimada e seu respectivo erro de covariância no tempo t_k de acordo com a resposta no tempo prévio t_{k-1} . As condições iniciais para o tempo t_0 são definidas dependendo do conhecimento do modelo.

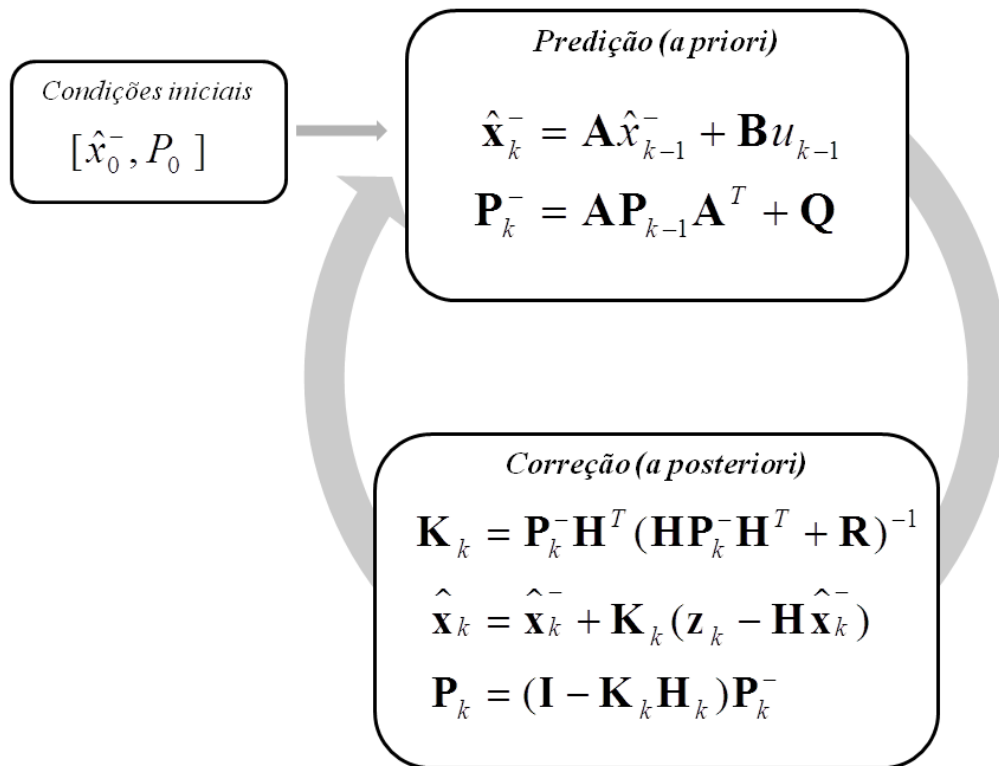


Figura 4.1: Descrição do algoritmo do Filtro de Kalman.

Na etapa de correção, o ganho de Kalman para o tempo t_k é computado, depois o valor estimado é corrigido em função do erro existente entre a estimação *a priori* e a medição. Aqui o filtro "acreditará" maiormente no valor estimado *a priori* na medida

que a covariância do erro estimado \mathbf{P}_k aproxima-se a zero. Caso contrario seguirá realizando a comparação com a medição e portanto corrigindo o valor da estimação *a posteriori*. Quando existir uma correção, a covariância do erro estimado é atualizada.

4.2 Decodificação do movimento do cotovelo

O processo de decodificação do movimento do cotovelo está baseado nos trabalhos prévios de Wu et al. realizado em macacos utilizando eletrodos implantados [107], [97] e posteriormente replicados em humanos usando métodos não invasivos por Robinson et al., [108].

Nos casos citados no parágrafo anterior, as variáveis estimadas (estados) foram os movimentos da mão no espaço bidimensional $(x_x, x_y, \dot{x}_x, \dot{x}_y, \ddot{x}_x, \ddot{x}_y)$. As discussões correspondentes se focaram em como os movimentos inferem na atividade elétrica dos neurônios e na qualidade da estimação destes estados usando o Filtro de Kalman, sendo que, movimentos da mão em certas direções levam a alterar de forma equivalente o potencial elétrico de grupos de células específicas localizadas no Córtex Motor (M1) (*preferred motions*) [107].

Fazendo uma variação destes experimentos, queremos constatar se é possível transferir o comportamento dos neurônios localizados em *M1* que se encontram relacionados com o movimento da mão a outros movimentos intrinsecamente relacionados, como o caso da flexão e extensão do cotovelo usando o Filtro de Kalman e métodos não invasivos. Modificando por tanto, o paradigma experimental e a variável a ser decodificada, sem alterar o método de estimação dos estados. Comprovado isto, queremos constatar também, se é possível treinar o conjunto de modelos para o filtro de Kalman para movimentos imaginários, tendo como base, os modelos treinados durante o movimento.

Definindo formalmente o problema, o modelo de decodificação proposto tem como propósito estimar o estado \mathbf{x}_k , que representa o movimento do cotovelo no instante de tempo $t_k = k\Delta_t$. Os estados representam a evolução da posição, velocidade e aceleração angular do cotovelo $\mathbf{x}_k = [\theta, \dot{\theta}, \ddot{\theta}]_k^T$ para cada instante de tempo k . Como medição z , será usada o sinal *EEG* captado no córtex por métodos não invasivos.

O filtro é determinado assumindo uma relação linear entre o estado \mathbf{x}_k e as observações $\mathbf{z}_k \in \mathfrak{R}^c$ onde c representa o número de sinais (canais) *EEG* usados para estimar o movimento. O modelo de decodificação proposto é portanto:

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \quad (4.17)$$

Neste caso a matriz $\mathbf{H}_k \in \mathfrak{R}^{c \times 3}$ relaciona linearmente a atividade captada nos

eletrodos com o movimento efetuado pelo cotovelo. Esta matriz tem uma dimensão de $cx3$, dado que são 3 estados que descrevem o movimento. O ruído \mathbf{v}_k é assumido que tem média zero com covariância \mathbf{R}_k e distribuição normal portanto, $\mathbf{v}_k \sim N(0, \mathbf{R}_k), \mathbf{R}_k \in \mathfrak{R}^{cx3}$.

Portanto os estados se propagam de acordo com o modelo do sistema:

$$\mathbf{x}_{k+1} = \mathbf{A}_k \mathbf{x}_k + \mathbf{w}_k \quad (4.18)$$

Note-se a alteração da notação para definir a propagação entre os tempos anterior e atual. A matriz $\mathbf{A}_k \in \mathfrak{R}^{3x3}$ relaciona a cinemática do antebraço no tempo $k + 1$ linearmente com o estado no tempo k . O ruído do modelo \mathbf{w}_k também é assumido normal com média zero e covariância \mathbf{Q}_k , $\mathbf{w}_k \sim N(0, \mathbf{Q}_k)$, $\mathbf{Q}_k \in \mathfrak{R}^{3x3}$.

4.2.1 Processo de aprendizado

É necessário aprender os parâmetros que caracterizam as matrizes $\mathbf{A}_k, \mathbf{H}_k, \mathbf{R}_k, \mathbf{Q}_k$. Na prática estas matrizes podem variar para cada tempo t_k , contudo, uma simplificação pode ser assumida, declarando que os modelos que descrevem o estado e a medição são invariante no tempo.

Assumindo que se tem M passos nos dados de treinamento $k = 1, \dots, M$, de forma que os estados \mathbf{x}_k e as observações \mathbf{z}_k são um conjunto de M pontos. É definido $x_{i,k}$ como o i -ésimo elemento de \mathbf{x}_k no tempo t_k , sendo $i = 1, \dots, 3$. E $z_{j,k}$ e o valor j -ésimo canal no tempo t_k , sendo $j = 1, \dots, C$.

Usando mínimos quadrados nas equações 4.17 e 4.18 os coeficientes das matrizes \mathbf{A} e \mathbf{H} são determinados:

$$\mathbf{A} = \min_{\mathbf{A}} \sum_{k=1}^{M-1} \|\mathbf{x}_{k+1} - \mathbf{A}\mathbf{x}_k\|^2 \quad (4.19)$$

$$\mathbf{H} = \min_{\mathbf{A}} \sum_{k=1}^M \|\mathbf{z}_k - \mathbf{H}\mathbf{x}_k\|^2 \quad (4.20)$$

Sendo $\|\cdot\|$ a norma \mathbf{L}^2 . Derivando parcialmente 4.19 com respeito a \mathbf{A} e 4.20 com respeito a \mathbf{H} e posteriormente igualando-se a zero, encontra-se a solução para as equações.

$$\begin{aligned} \mathbf{A} &= \mathbf{X}_2 \mathbf{X}_1^T (\mathbf{X}_1 \mathbf{X}_1^T)^{-1} \\ \mathbf{H} &= \mathbf{Z} \mathbf{X}^T (\mathbf{X} \mathbf{X}^T)^{-1} \end{aligned} \quad (4.21)$$

Onde $\mathbf{X} \in \mathfrak{R}^{3 \times M}$, $\mathbf{X}_1 \in \mathfrak{R}^{3 \times M-1}$ e $\mathbf{Z} \in \mathfrak{R}^{C \times M}$. Entretanto $\mathbf{X}_2 \in \mathfrak{R}^{3, M-1}$ corresponde aos dados desde o passo $t = 2 \dots M$. Usando as soluções apresentadas na equação 4.21, encontra-se as estimações para as matrizes \mathbf{R} e \mathbf{Q} .

$$\begin{aligned}\mathbf{Q} &= \frac{(\mathbf{X}_2 - \mathbf{A}\mathbf{X}_1)(\mathbf{X}_2 - \mathbf{A}\mathbf{X}_1)^T}{(M - 1)} \\ \mathbf{R} &= \frac{(\mathbf{Z} - \mathbf{H}\mathbf{X})(\mathbf{Z} - \mathbf{H}\mathbf{X})^T}{M}\end{aligned}\tag{4.22}$$

Encontrados estes modelos, a próxima fase foi encontrar o melhor conjunto de parâmetros de configuração que permitam minimizar o erro de estimação do estado x , usando o conjunto de dados de treinamento: o sinal do sensor de movimento que descreve o estado desejado, e o sinal *EEG* que descreve a medição. Devido às diferenças do sinal entre voluntários, o conjunto de matrizes treinada corresponderá às informações por eles aportadas durante o paradigma experimental, porém, se espera que existam diferenças entre os modelos resultantes de cada um deles.

4.3 Treinamento do Filtro de Kalman

Nesta seção, se descreverá o processo de treinamento do filtro de Kalman que se efetuará em cada voluntário. Os valores da matriz \mathbf{A} , que conforma o modelo do sistema \mathbf{x}_k e da matriz \mathbf{H} , que conforma o modelo de decodificação \mathbf{z}_k são dependente dos dados de treinamento. Estes dados podem ser configurados de acordo com um conjunto de parâmetros, sendo estes, o número de canais C o valor do Δ_t e o retardo entre o movimento e a atividade neural [97] *lag*. Os sinais *EEG* por outro lado, foram filtrados em 4 bandas: delta, alfa, beta e gama. Por tanto, a banda do sinal foi um quarto parâmetro de configuração.

Todas as possíveis combinações dos parâmetros foram analisadas usando o critério de *Busca Exaustiva*. No teste, cada combinação de parâmetros terá uma resposta de codificação, que será avaliada usando o Erro Quadrático Médio (*EQM*) que mede a distância euclidiana entre a estimação e o valor desejado, e o Coeficiente de Correlação (*CC*) que descreve a semelhança entre o valor estimado e o desejado.

Sendo \mathbf{x}_k a cinemática do cotovelo (posição, velocidade e aceleração angular) e $\hat{\mathbf{x}}_k$ os estados decodificados, eles são descritos por um conjunto de pontos amostrados a Δ_t , da extensão $k = 1, \dots, M$. Tem-se as equações do *EQM* e *CC*:

$$EQM = \frac{1}{M} \sum_{k=1}^M (\mathbf{x}_k - \hat{\mathbf{x}}_k)^2 \tag{4.23}$$

$$CC = \frac{\sum_k (\mathbf{x}_k - \bar{\mathbf{x}})(\hat{\mathbf{x}}_k - \bar{\hat{\mathbf{x}}})}{\sqrt{\sum_k (\mathbf{x}_k - \bar{\mathbf{x}})^2 \sum_k (\hat{\mathbf{x}}_k - \bar{\hat{\mathbf{x}}})^2}} \tag{4.24}$$

Onde \bar{x} representa a média da cinemáticas descritas. Se definirá como a melhor configuração do filtro aquela em que os parâmetros de configuração estimem \mathbf{x} com

EQM mais próximo a 0 e CC mais próximo de 1. Ou seja: $[A, H, Q, R]_{min}EQM$ e $[A, H, Q, R]_{max}CC$

O sinal dos canais foram organizados de forma descendente de acordo com a coerência com respeito ao canal C_3 usando a Magnitude Quadrática da Coerência (Equação 4.25). Usando este método, se pode estudar a relação entre as zonas do córtex determinando qual é sua contribuição durante a execução do movimento [108].

$$C_{xy}(\omega) = \frac{|P_{xy}(\omega)|^2}{P_{xx}(\omega)P_{yy}(\omega)} \quad (4.25)$$

Para analisar a contribuição de cada zona estimou-se para cada voluntário, a coerência de todos os canais com respeito a C_3 em torno de um conjunto de frequências (determinada pelas bandas a analisar), posteriormente estimou-se o valor médio da Equação 4.23 em cada trial. No mapa da Figura 4.2 se apresenta este resultado .

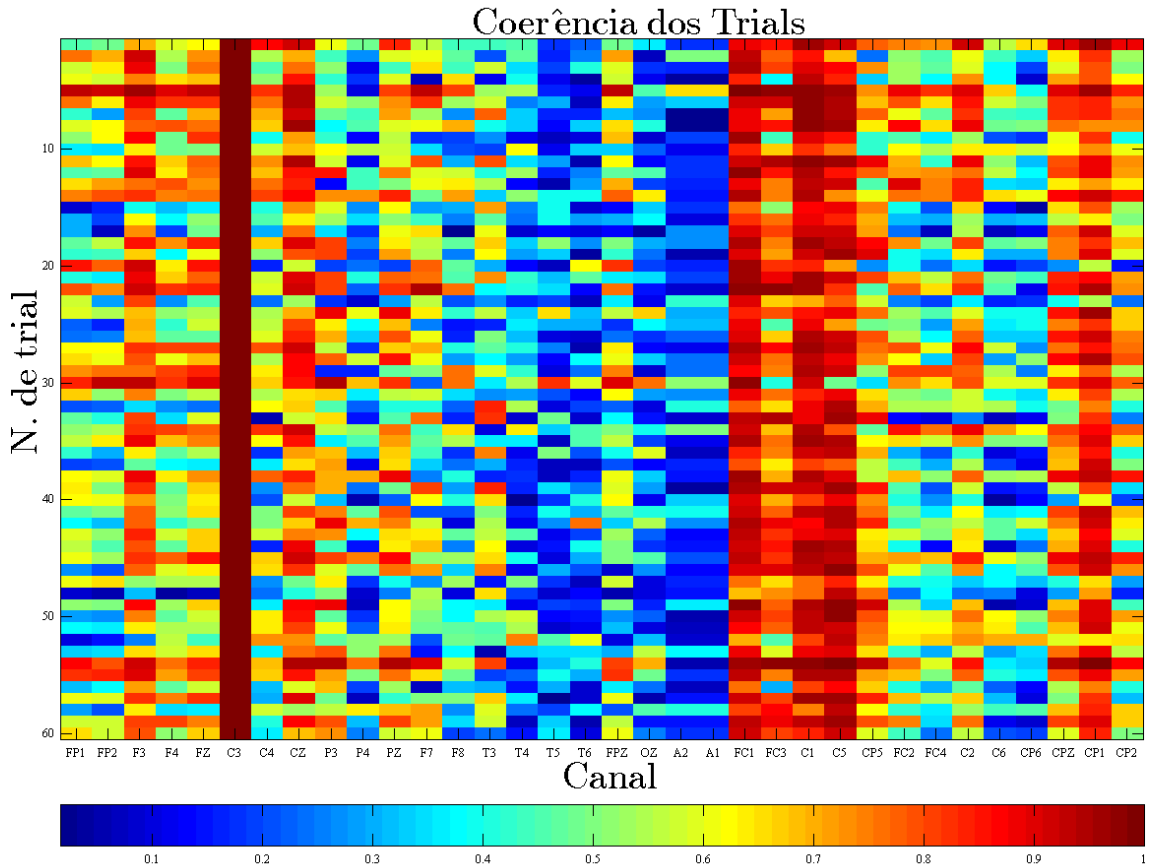


Figura 4.2: Mapa da coerência entre canais com respeito ao canal C_3 . Na figura se apresenta a variação da coerência entre os trials de acordo com a escala de cores, sendo os vermelhos os valores de maior coerência.

Na Figura 4.3 é apresentada a tendencia da coerência de cada canal ao longo dos

trials organizada decendentemente. Pode-se observar que canais mais próximos a C_3 tiveram a maior coerência ao longo dos trials, sendo isto razoável dada sua proximidade. Encontra-se também que os maiores valores correspondem àqueles canais que se encontram na região do córtex localizado na posição contralateral ao movimento, canais mais afastados não manifestam as mesmas respostas indicando que essas regiões têm uma menor contribuição para o controle do movimento.

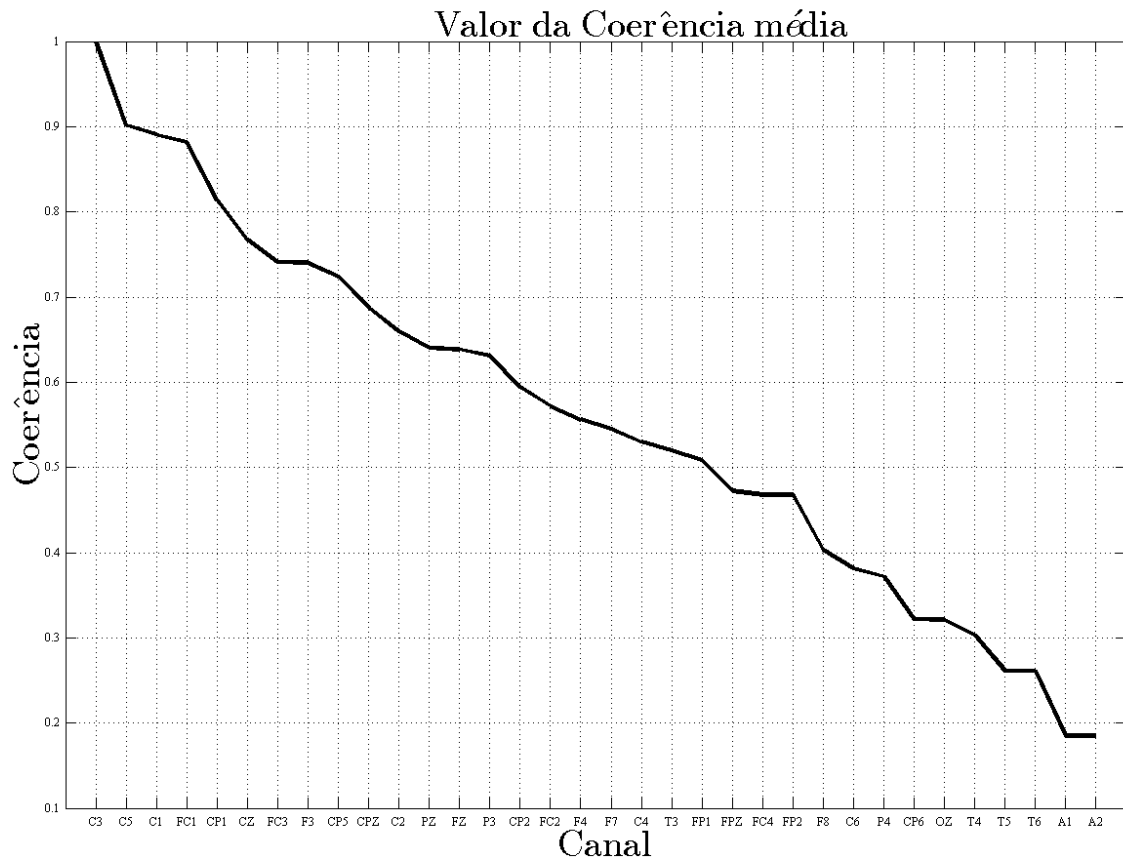


Figura 4.3: Média da coerência ao longo dos trials entorno de C_3 .

4.3.1 Validação Cruzada

O treinamento foi realizado para cada voluntário usando os dados coletados de acordo com o paradigma experimental descrito no Capítulo 3. Foi usada a *Validação Cruzada de K iterações (K-Fold Cross-Validation)* para testar a resposta do *EQM*. Nesta análise, os dados se dividiram em 6 subconjuntos (6 *folds*) compostos cada um por 10 trials. A validação cruzada permite testar o modelo em todos os trials de forma que os dados de validação sempre estejam excluído dos dados de treinamento, este método permite generalizar um modelo para ser posteriormente usado no sistema *BCI*.

Os parâmetros de configuração do modelo a serem estudados tiveram as seguintes magnitudes: $\Delta_t = (1\ 25\ 50\ 70\ 100\ 150\ 200)$ ms; $lag = (0\ 50\ 100\ 150\ 200\ 300)$ ms; e o número de canais c , agrupado-se em conjuntos de $(3\ 5\ 7\ 10\ 15\ 20\ 34)$ canais. O parâmetro Δ_t configura a frequência de amostragem tanto do sinal *EEG* como do sensor de movimento, o *lag* especifica o retardo entre a resposta do cérebro e o movimento do braço e c indica o número de sinais usados para decodificar o movimento.

Para cada iteração o modelo é treinado com 5 dos subconjuntos obtendo-se as estimações para as matrizes **A**, **H**, **R** e **Q**, posteriormente o modelo é avaliado (*test*) com o subconjunto restante. Este processo se repetirá K vezes, de forma que todos os dados sejam usados para validação e treinamento. O *EQM* e *CC* para cada conjunto de parâmetros é calculando com a média de todas as validações através de todas as iterações.

As condições iniciais t_0 do filtro de Kalman serão as mesmas que as usadas por Wu et al., [97], sendo $\hat{x}_0^- = x_0$ e conseqüentemente $P_0 = 0$. O Sinal *EEG* em todas as bandas foi centralizado (aplicando transformação raiz quadrada do quadrado do sinal), como também os dados do movimento (subtraindo a média do sinal) para que todos tenham média zero. Esta transformação acontece tanto no treinamento como na validação do modelos.

4.3.2 Resultados do Treinamento

Efetuando-se o algoritmo de validação cruzada usando *Matlab*® se obtiveram um conjunto de resultados que descrevem a incidência de cada parâmetro na resposta do filtro.

Um total de 6 voluntários encontraram-se envolvidos no experimento, o paradigma experimental usado foi descrito na seção 3.1. O movimento decodificado foi do braço direito tanto para movimentos ascendentes (flexão) como descendentes (extensão), tomou-se esta determinação pela diferença de resultados para cada tarefa, que permitiram entender o a relação entre o movimento com o resultado da estimação

Incidência do retardo e o Δ_t na decodificação

Na Figura 4.4 se apresenta uma curva de treinamento típica para um dos voluntários durante a decodificação do movimento de ascenso nas fases de validação (linha grossa e continua) e treinamento (pontilhada). O eixo y apresenta o valor do *EQM* Médio (média da estimação da posição, velocidade e aceleração), o eixo x apresenta os valores de Δ_t , as linhas de variância, localizadas verticalmente ao longo da curva descrevem a variação do *EQM* de acordo com o valor do retardo.

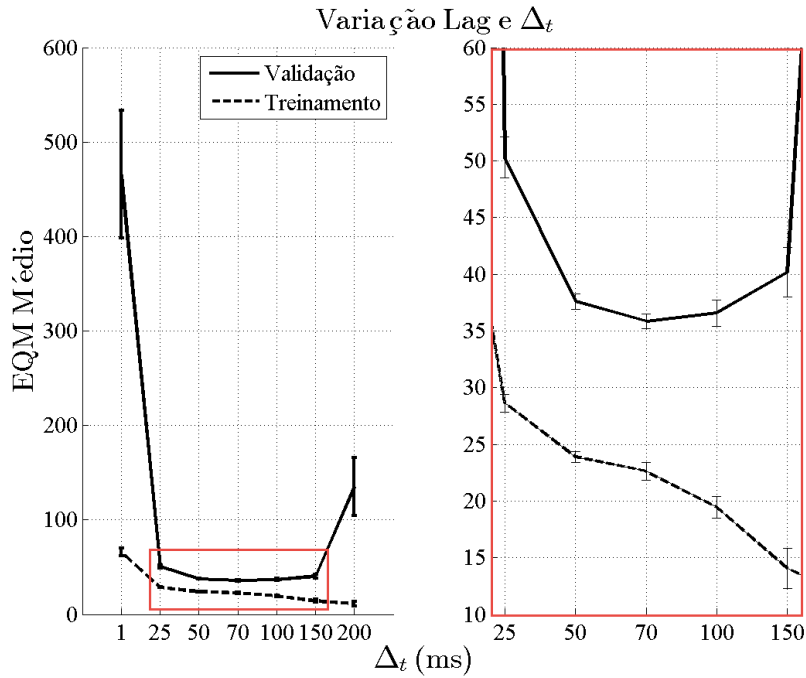


Figura 4.4: Resposta da estimação de acordo à variância dos parâmetros lag e Δ_t nas fases de validação e treinamento para movimentos ascendentes. O intervalo delimitado pelo quadro vermelho na zona de baixo EQM é mostrado amplificado à direita.

Esta figura é típica porque se apresenta em todos os voluntários. Nela se aprecia que o EQM tendeu a diminuir durante o treinamento na medida que o parâmetro Δ_t aumentou seu valor, porém, durante a validação encontrou-se um alto $bias$ para $\Delta_t < 25$ ms. Encontrou-se também, um intervalo de baixo erro de estimação $25 < \Delta_t \leq 150$, para finalmente ter um $overfitting$ para valores $\Delta_t > 150$ ms.

Ao aumentar a visualização da zona de baixo EQM (ressaltada no quadro vermelho à direita da Figura 4.4), encontrou-se uma curva que descreve um mínimo em torno dos 70 ms. As linhas de variância em cada valor de Δ_t descrevem a variabilidade do EQM de acordo com o valor do lag , sendo menor na área de baixo erro e alto nas zonas que apresentaram $bias$ e $overfitting$.

Uma nova curva foi realizada tendo-se em conta a resposta em todos os voluntários (Figura 4.5). Aqui se descreveu como a alteração do parâmetro Δ_t feita o resultado da estimação em todos os voluntários, representados pelas linhas de variância verticais.




Figura 4.5: Resposta da estimação de acordo com a variação de Δ_t nas fases de validação e treinamento para todos os voluntários.

Encontrou-se por tanto um intervalo para $50 \leq \Delta_t \leq 150$ ms, que minimiza o erro de estimação; indicando que uma redução da frequência de amostragem melhora a estimação do filtro. Entretanto, o retardo entre a medição e o movimento não altera significativamente o resultado da estimação para cada valor da faixa, cuja variação atuaria como um processo de ajuste fino.

Incidência do número de canais na decodificação

Na Figura 4.6 se apresenta a variação do EQM em todos os voluntários segundo o número de canais c nas fases de treinamento e validação. Sete curvas descrevem o comportamento do erro para cada Δ_t na medida em que o número de canais (eixo vertical) aumenta.

No treinamento, encontrou-se que aumentar o valor de c melhora a estimação da cinemática para qualquer Δ_t . Não obstante, durante a validação, encontrou-se que aumentar c melhora a resposta dos valores de Δ_t unicamente em 1 e 200 ms. Os parâmetros considerados de melhor resposta, tenderam a aumentar o erro de estimação de forma aproximadamente linear, ocasionando um *overfitting* por causa do número de canais usados no modelo.

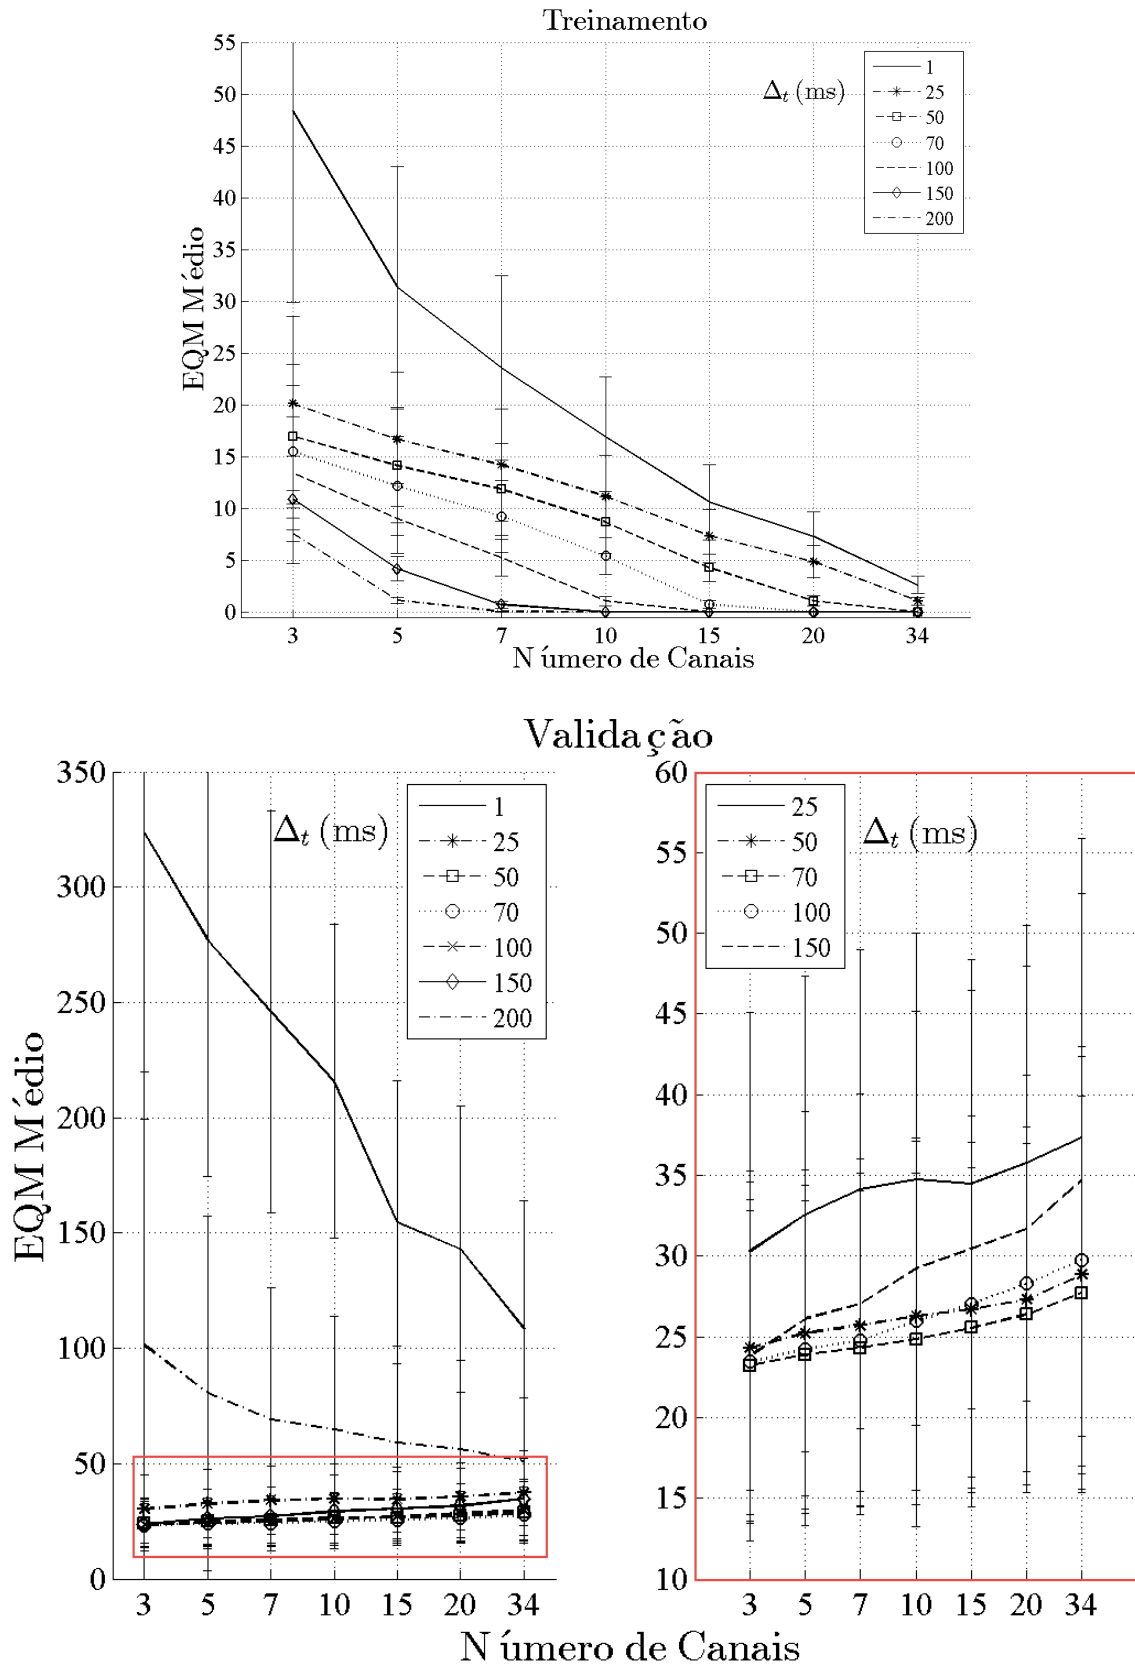


Figura 4.6: Resposta da estimação de acordo com o número de canais nas fases de validação e treinamento para movimentos ascendentes.

Incidência das bandas na decodificação

Na Figura 4.7 se apresenta a variação do EQM para os sete parâmetros Δ_t de acordo com a frequência do sinal EEG em todos os voluntários.




Figura 4.7: Resposta da estimação de acordo com a frequência nas fases de validação e treinamento para movimentos ascendentes.

Tanto para o treinamento como para o intervalo ótimo Δ_t da validação, a variação da frequência não leva a alterações significativas do EQM . A resposta conserva-se estável ao longo dos testes em todas as frequências.

4.3.3 Coeficiente de Correlação

O Coeficiente de Correlação (CC) é usado como critério de validação da resposta de decodificação da cinemática através do uso do filtro de Kalman, descrevendo a semelhança entre o parâmetro real e o estimado [97]. Para avaliar este critério, usou-se a média dos CC da posição, velocidade e aceleração. Assim procurou-se o conjunto de parâmetros cuja combinação, fornecerá o maior CC médio possível. As Figuras 4.8 - 4.10 descrevem a variação do critério de acordo com os parâmetros ao longo de todos os voluntários.

A resposta do filtro tende a melhorar o valor de CC na media que aumenta o valor de Δ_t (Figura 4.8) até 150 ms, caindo em 200 ms *overfitting*.

Tendo em conta o número de canais c se encontraram diferentes tendências (Figura 4.9). Para $\Delta_t < 70$ ms, o CC aumenta progressivamente; para $\Delta_t = 70$ a tendência é constante, e para $\Delta_t > 70$ a tendência diminui progressivamente.

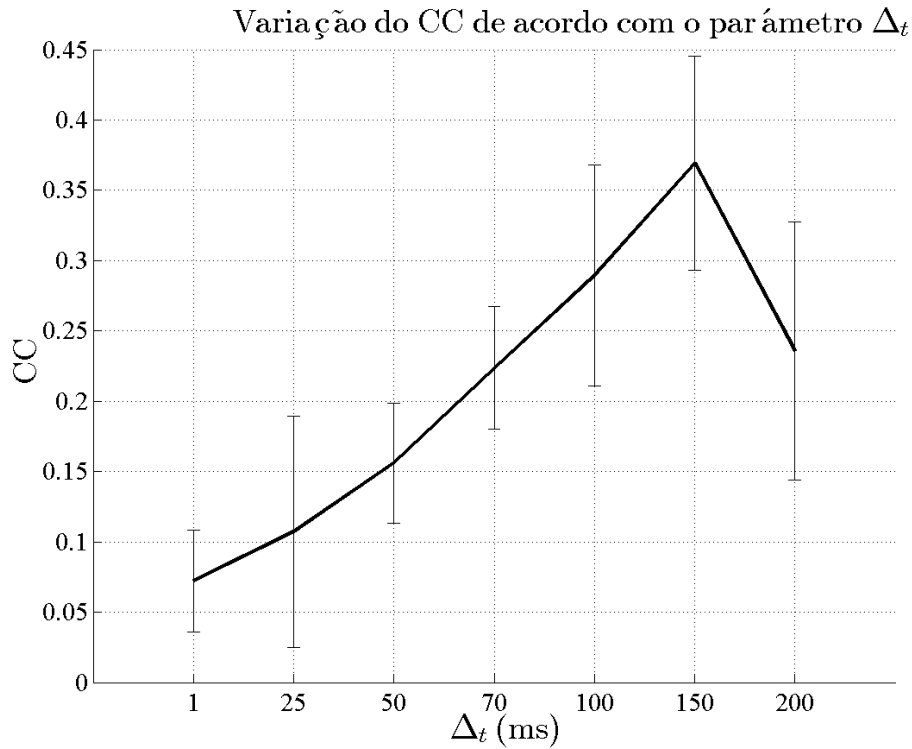


Figura 4.8: Coeficiente de Correlação Médio para movimentos ascendentes em função do parâmetro Δ_t para todos os voluntários .




Figura 4.9: Coeficiente de Correlação Médio para movimentos ascendentes em função do número de canais para todos os voluntários .




Figura 4.10: Coeficiente de Correlação Médio para movimentos ascendentes em função da frequência para todos os voluntários .

Finalmente para as frequências (Figura 4.10) tem-se que o sinal filtrado na banda Alfa, apresenta o melhor CC do conjunto de parâmetros avaliados para todas as condições analisadas.

Em resumo, durante a etapa de validação, considerando a resposta do EQM para os vários parâmetros de configuração do modelo, encontramos que para os 6 voluntários um intervalo ótimo $50 \leq \Delta_t \leq 150$. Tendo-se em conta que o aumento da frequência de amostragem provoca um retardo na obtenção do estado, uma situação não conveniente para movimentos rápidos e também, causa uma perda de definição na trajetória do movimento, situação indesejável quando se quer um sistema assistivos que guie o braço através de uma trajetória de forma suave e transitiva.

Também encontrou-se que o número de canais adequado para o intervalo de Δ_t não pode ser maior de 3, sendo estes canais: C_3 , C_5 e C_1 , que se encontram localizados na região do córtex motor contralateral ao movimento. Estes canais possuem uma coerência média próxima a 0.9 indicando uma alta inter-relação linear entre eles que tende a ser constante ao longo dos trials, constituindo uma matriz \mathbf{H} com maior correlação entre a atividade cognitiva e o movimento.

Finalmente, se estabeleceu que os parâmetros lag e a frequência do sinal EEG não afetam significativamente o valor do EQM , contudo, recomenda-se usar a banda alfa, dado que na presença do movimento ela responde com um CC mais alto em

comparação com as outras bandas, possivelmente porque esta banda tem uma amplitude relacionada com a presença de movimento.

4.3.4 Movimentos Descendentes

Os resultados do treinamento para o modelo que decodifica o movimento descendente podem ser encontrados no Anexo B. O conjunto de resultados apresenta uma resposta para o *EQM* menor em comparação aos movimentos ascendentes. A curva do erro médio em função do Δ_t foi decrescente, entretanto que o *CC* foi crescente até ultrapassar uma correlação do movimento de 0.8 para todos os voluntários.

Da mesma forma, como no treinamento do modelo para movimentos ascendentes, a resposta do *EQM* aumenta na medida que são usados mais canais na estimação do movimento, e o *CC* diminui, apresentando-se o mesmo limite de 3 canais para $\Delta_t > 25$ ms. Entretanto a variação da frequência dos sinais *EEG* não alterou significativamente a resposta da decodificação tanto no *EQM* como no *CC*.

Ambos movimentos apresentam comportamentos similares em referência à variação dos parâmetros de configuração, podendo-se usar os mesmos para cada caso e esperar resultados equivalentes. Contudo, em respeito a magnitude do *EQM*, é necessário entender o porque das diferenças encontradas entre os modelos. Esta variação será analisada na próxima subsecção.

4.3.5 Variação da resposta do modelo


Depois de escolhidos os parâmetros de configuração de acordo com as respostas encontradas na seção prévia: $\Delta_t = 70$, $Lag=0$, *Número de Canais* = 3, e o sinal *EEG* filtrado na frequência Alfa (8-16 Hz), o filtro de Kalman é treinado e validado.

Na Figura 4.11 se apresenta o resultado da variação do erro de estimação do modelo em movimentos ascendentes (ilustração superior) e descendentes (ilustração inferior) durante a validação. A média da magnitude do *EQM* é maior nos casos ascendentes para os três estados, apresentando a mesma tendência do treinamento.

Na Figura 4.12 e a tabela 4.1 se apresentam as variações dos coeficientes das matrizes **A** e **H** em todos os voluntários durante o treinamento.

Encontra-se que para a matriz **A**, os elementos correspondentes à estimação da aceleração (coeficientes A_{31} , A_{32} e A_{33}) possuem um desvio padrão (DP) maior em comparação à posição (coeficientes A_{11} , A_{12} e A_{13}). A velocidade (coeficientes A_{21} , A_{22} e A_{23}) encontra-se num ponto intermediário. Esta organização é semelhante à distribuição do *EQM* descrita na figura 4.11, indicando as dificuldades durante o treinamento de se encontrar um valor estável para um estado (entendendo-se estável por invariante ao longo dos voluntários), impossibilitam uma estimação correta. Esta suposição é suportada, ao analisar o modelo durante o descenso.

Erro de Estimação do Movimento



Erro de Estimação do Movimento





Figura 4.11: Distribuição do Erro Quadrático Médio para a estimação da posição, velocidade e aceleração angular do cotovelo do braço direito usando os parâmetros de configuração: $\Delta_t = 70$, $Lag=0$, *Número de Canais* = 3, e o sinal *EEG* filtrado na frequência Alfa (8-16 Hz). As figuras descrevem a variação para movimentos ascendentes (superior) e descendentes (inferior)

Variação Coeficientes nos Voluntários



Variação Coeficientes nos Voluntários




Figura 4.12: Variação dos coeficientes das matrizes **A** e **H** para todos os voluntários. Na figura superior se apresenta a variação do modelo para movimentos ascendentes e a inferior para os movimentos descendentes.

Tabela 4.1: Distribuição dos Coeficientes da Matriz do Sistema **A** para todos os voluntários para movimentos ascendentes e descendentes.

Ascenso								
	V1	V2	V3	V4	V5	V6	μ	DP
A_{11}	1,02	1	1,01	1,01	1,01	1,06	1,02	0,02
A_{21}	0,44	0,09	0,11	0,13	0,23	1,77	0,46	0,65
A_{31}	2,96	-1,28	-2,62	-0,34	1,25	10,55	1,75	4,73
A_{12}	0,07	0,07	0,07	0,07	0,07	0,06	0,07	0,00
A_{22}	0,83	0,91	0,9	0,91	0,87	0,6	0,84	0,12
A_{32}	-3,02	-1,55	-1,97	-1,55	-2,67	-6,03	-2,80	1,69
A_{13}	0	0	0	0	0	0	0,00	0,00
A_{23}	0,07	0,07	0,07	0,07	0,07	0,08	0,07	0,00
A_{33}	0,65	0,56	0,53	0,6	0,65	0,51	0,58	0,06
Descenso								
A_{11}	1	1	1	1	1	1	1,00	0,00
A_{21}	-0,25	-0,26	-0,08	-0,21	-0,17	-0,25	-0,20	0,07
A_{31}	-8,18	-8,56	-3,21	-6,93	-6,07	-7,97	-6,82	1,99
A_{12}	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,00
A_{22}	0,89	0,85	0,94	0,88	0,91	0,87	0,89	0,03
A_{32}	-3,21	-3,63	-1,65	-2,95	-2,58	-3,56	-2,93	0,74
A_{13}	0	0	0	0	0	0	0,00	0,00
A_{23}	0,06	0,05	0,06	0,05	0,06	0,05	0,06	0,01
A_{33}	0,34	0,18	0,33	0,25	0,3	0,3	0,28	0,06

Neste movimento o desvio padrão dos coeficientes é menor ($DP > 0.2$), levando a um correspondente EQM baixo.

Através do resultado descrito na figura 4.12, percebe-se que existem diferenças entre os coeficientes da Matriz **H** treinada para cada voluntário. Este resultado é usado para estimar o sinal EEG a partir do valor do modelo descrito na equação 4.17. O sinal resultante é a soma ponderada de cada estado estimado \hat{x} multiplicado por um coeficiente da matriz $H_{c,j} \therefore j = [1 \dots 3]$. Portanto, existe uma relação causa-efeito entre o valor \hat{x} e a medida z que poderia afetar a resposta encontrada.

Na figura 4.13 se apresentam os valores dos coeficientes da matriz **H** escalados. Esta mudança permite determinar qual é a significância de cada estado na construção do sinal EEG . De acordo com as magnitudes observadas, o aporte que faz a aceleração na reconstrução do sinal é menor dado que ela possui os coeficientes de menor valor, seguido logo pela velocidade, e sendo a posição o elemento que mais aporta na reconstrução do sinal. Para o modelo descendente encontra-se a mesma distribuição.







Figura 4.13: Variação dos coeficientes da matriz \mathbf{H} . Na figura superior se apresenta a variação do modelo para movimentos ascendentes e a inferior para os movimentos descendentes.

Esta situação foi reportada por Wu [107], e serviu como base para teorizar que

os movimentos comandados pelos neurônios do córtex motor, estão unicamente relacionados com a posição e em menor grau com a velocidade. Sendo a aceleração um resultado da derivada destes dois sinais, seu valor é redundante para o modelo, podendo portanto ser omitido inteiramente do filtro de Kalman. Desta forma, mesmo a aceleração tendo um EQM maior, os erros na sua decodificação não afetaram significativamente a estimação da medição \mathbf{Z} .

Esta compensação entre modelos faz que a resposta do filtro aparentemente, tenha maior dependência da matriz \mathbf{A} e não de \mathbf{H} .

4.3.6 Relação entre as matrizes \mathbf{A} e \mathbf{H} com o Erro de Estimação do modelo

Aqui analisamos o resultado das matrizes \mathbf{A} e \mathbf{H} e sua correspondência com a estimação do modelo, tendo-se como precedente a resposta de variabilidade entre os distintos resultados dos coeficientes da matriz do sistema.

Na Figura 4.14 se apresenta o histograma do sinal EEG (nos três canais escolhidos) para movimentos ascendentes e descendentes. A dispersão deles resulta em uma curva de frequência assimétrica positiva causada pela normalização do sinal. O sinal de ascenso tem um desvio padrão menor (≈ 2.7 contra ≈ 3.2) apresentando menor dispersão. Este fator não influi no resultado do EQM , dado que para o descenso o erro de estimação foi menor.




Figura 4.14: Distribuição do sinal EEG para os três canais implementados para treinar o modelo.

Ao relacionar o EQM com os coeficientes da Matriz \mathbf{H} encontra-se o gráfico de dispersão da Figura 4.15, que compara a norma de *Frobenius* da matriz \mathbf{H} , (eixo x), com o EQM Médio (eixo y) para os movimentos ascendentes (superior) e descendentes (inferior) em todos os voluntários.

A distribuição dos pontos estima-se usando os vizinhos mais k -próximos [128], com 200 pontos como parâmetro de configuração. De acordo com a dispersão, aparentemente, as matrizes com norma inferior a 5 possuem maior probabilidade de obter um EQM Médio menor que 10. Este resultado não é regra, dado que pode-se observar $\|\mathbf{H}\|$ inferior a 5 com EQM Médio maior a 40, portanto, a distribuição encontrada apresenta o comportamento mais provável do modelo de acordo com a resposta do filtro.

Pode-se interpretar que esta tendência obedece à distribuição dos sinais EEG usados durante o treinamento, e indicam que os sinais que contribuem a construção da $\|\mathbf{H}\|$ menor são mais comuns. Contudo também é provável que quando estes sinais, são combinados com certos movimentos existe uma alteração no EQM da resposta, que leva a aumentar a estimatão.

Na Figura 4.16 se apresenta, a variação ao longo dos trials da posição angular em radianos para movimentos de ascenso e descenso em um voluntário após a normalização.




Figura 4.16: Variabilidade do movimento durante o ascenso e o descenso. Destaca-se a alta variância existente nos movimentos ascendentes, entretanto no descenso o comportamento do movimento é homogêneo ao longo dos trials.





Figura 4.15: Gráfico de dispersão que compara a magnitude da norma de Frobenius de \mathbf{H} com o EQM Médio ao longo dos voluntários.

Inspecionando os pontos que conformam os dados, aparentemente o sinal nos movimentos ascendentes possui maior variabilidade. Esta variação pode se relacionar com a reação do voluntário ao estímulo visual que ordena efetuar o movimento, encontrando-se retardos entre os trials, movimentos mais rápidos ou curtos influenciados por fatores como a fadiga.

Ao comparar a matriz \mathbf{A} com o erro de estimação para ambos movimentos, encontra-se uma correspondência entre a norma da matriz com o EQM (Figura 4.17). Neste gráfico EQM Médio aumenta junto com a $\|\mathbf{A}\|$, incrementando também a dispersão da resposta, indicando que $\|\mathbf{A}\|$ altas são menos confiáveis para a estimação dos estados.

O incremento da $\|\mathbf{A}\|$ está relacionado com a variabilidade do movimento, especificamente, com a variação da velocidade e da aceleração. As figuras 4.18 e 4.19 comparam os desvios padrões da posição, velocidade e aceleração com $\|\mathbf{A}\|$. Movimentos com maior dispersão, que apresentam maiores velocidades e acelerações têm maior probabilidade de ter norma alta. Em consequência, quando o treinamento da matriz \mathbf{A} envolve movimentos com alta variabilidade o modelo resultante terá dificuldades em projetar o valor do estado \mathbf{x} durante a validação, dado que não existe uma correspondência entre o movimento e o estado.

Esta análise leva a pensar que treinar a matriz \mathbf{A} tendo em conta unicamente movimentos com menor desvio, resultaria em uma matriz com menor norma, melhorando consequentemente a estimação dos estados. Assim, teria que se escolher um limiar λ , cujo valor pode ser estimado por inspeção a partir dos resultados descritos na figura 4.17. Embora, provas posteriores que validaram esta hipótese, apresentaram que, ao forçar o treinamento baixo estas condições não levou-se ao melhoramento da resposta na fase de validação, sendo o resultado similar aos treinamentos prévios, Assim o modelo não conseguiu-se adaptar às distintas variações do movimento.

4.4 Imposição do movimento

Na figura 4.12, apresentou-se a variação dos coeficientes da matriz \mathbf{A} treinada para cada voluntário que participou no experimento. Previamente, comprovou-se que um maior valor destes coeficientes aumenta linearmente (com certa variabilidade) o erro da estimação dos estados.

Dado que a resposta apresentada era discriminada por voluntário, tem-se que em alguns deles a possibilidade de estimar adequadamente o movimento foi menor. Como os movimentos executados durante o experimento não diminuíam sua variação foi possível melhorar os resultados de estimação do estado durante os experimentos.

Porém, se considerou que ao modificar o valor da matriz \mathbf{A} treinada para um





Figura 4.17: Gráfico de dispersão que compara a magnitude da norma de Frobenius da matriz A com o EQM Médio para os voluntários em movimentos ascendentes e descendentes.

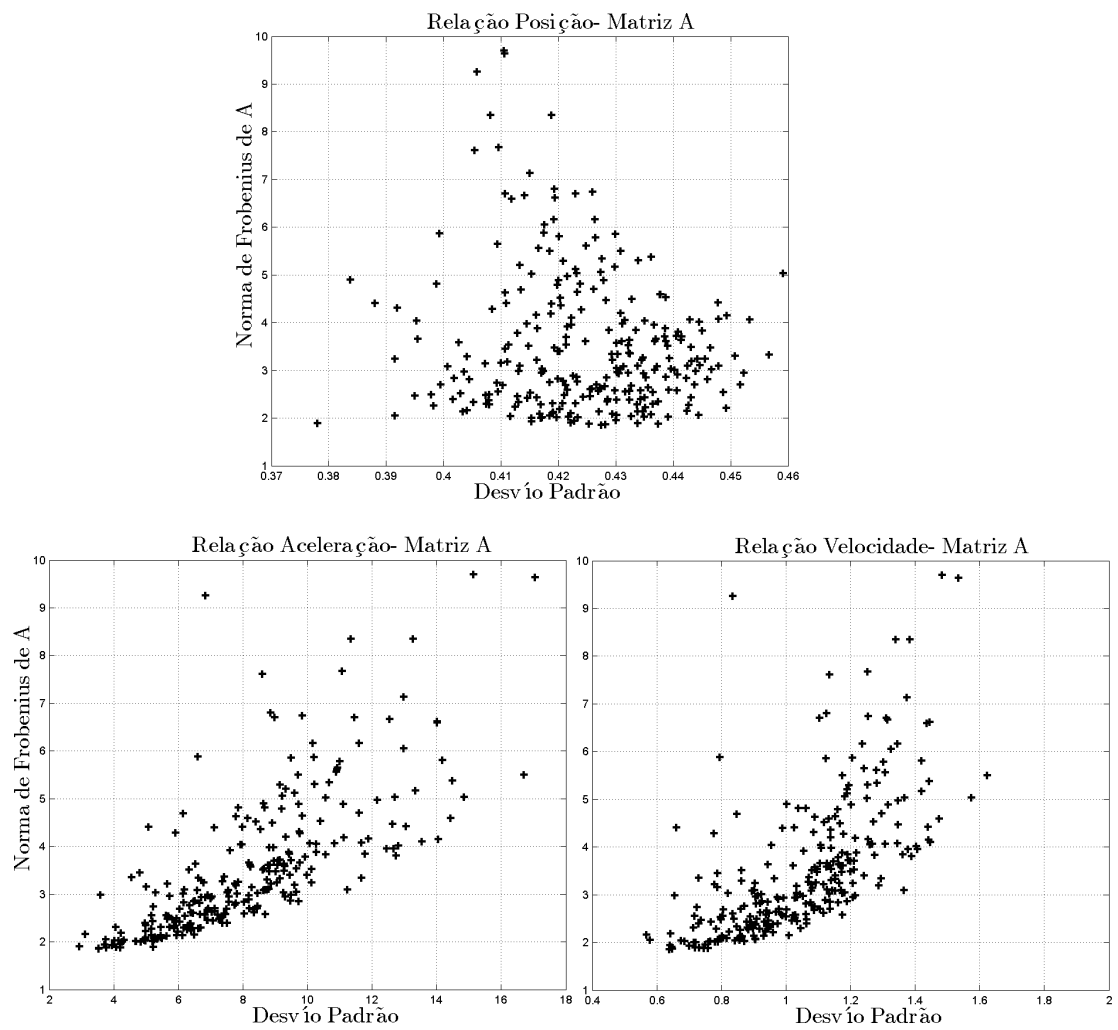


Figura 4.18: Gráfico de dispersão que compara a magnitude da norma de Frobenius da matriz A com o desvio padrão da posição, velocidade e aceleração no ascenso.

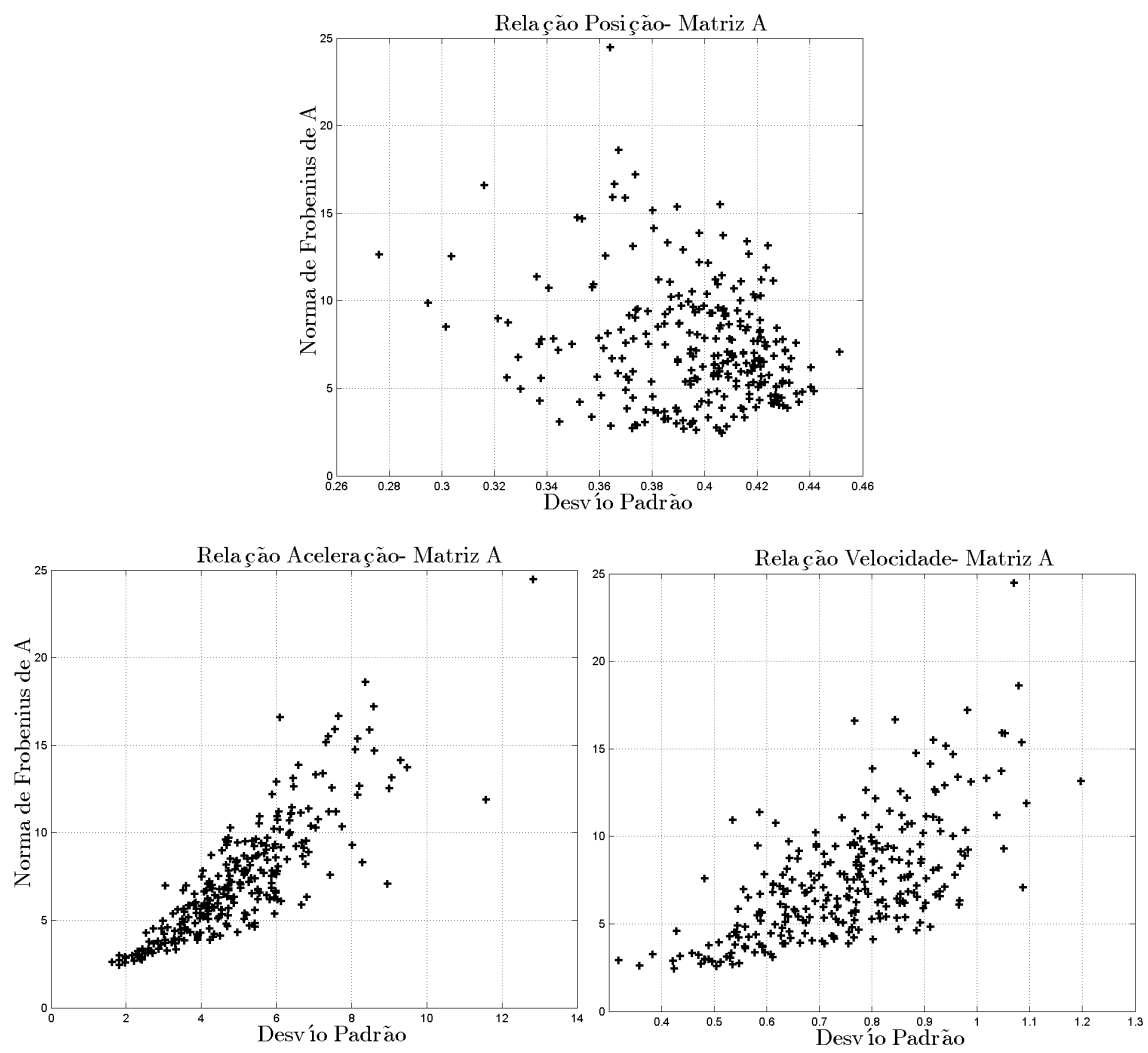


Figura 4.19: Gráfico de dispersão que compara a magnitude da norma de Frobenius da matriz \mathbf{A} com o desvio padrão da posição, velocidade e aceleração no descenso.

estado próximo ao ideal, a estimação dos estados no voluntário teria um erro menor. Contudo quando se aplicou esta hipótese não se conseguiu encontrar uma melhora da resposta nos voluntários. Isto quer dizer que, mesmo o modelo seja treinado com condições controladas, não consegue descrever variações do movimento. Portanto, eliminar os casos de maior variabilidade não só do treinamento mas também da validação poderia levar a um melhoramento da resposta.

Para provar esta hipótese se considera que um valor ideal da matriz \mathbf{A}_i é atingido usando para o treinamento unicamente os estados que forneceram a menor norma para esta matriz, escolhendo os movimentos \mathbf{x} que apresentem o menor desvio padrão na velocidade e na aceleração, que são aqueles estados onde $\|\mathbf{A}\| \leq \lambda$. Este conjunto de modelo será denominado de \mathbf{x}_i , finalmente, se estima um movimento médio $\bar{\mathbf{x}}_i$, e sua respectiva matriz $\bar{\mathbf{A}}_i$ para o modelo do sistema:

$$\bar{\mathbf{A}}_i = \begin{bmatrix} 0.997 & 0.06 & 0.001 \\ -0.02 & 0.95 & 0.07 \\ -0.012 & -0.37 & 0.94 \end{bmatrix} \quad (4.26)$$

Note-se a aproximação à matriz identidade. Para aplicar esta matriz se estabelece um intervalo de tempo fixo T_j para cada voluntário j no qual x_i seja escalada, neste intervalo encontra-se determinado o tempo médio em que j executa os movimento ao longo dos trials. T_j será também usado para extrair a atividade *EEG* dos respectivos canais c , relacionados com a ação executada para cada trial.

Dado que c possui alta variabilidade ao longo dos trials, a matriz \mathbf{H} deve ser treinada em todos os passos usando \bar{x}_i através do modelo de treinamento já estabelecido. Efetuando-se uma validação cruzada de 6 *folds* para treinar e avaliar o modelo em todos os voluntários, tem-se os resultado descritos na Figura 4.20:

Comparando estes resultados com os apresentados na Figura 4.11 pode-se apreciar que o *EQM* da estimação da velocidade e da aceleração diminuí, enquanto que a posição não varia. Por tanto se pode estabelecer que o modelo proposto para propagar o estado tem limitações relacionadas com a variação do movimento, neste caso o modelo não se ajusta a movimentos rápidos.

Na Figura 4.21 se apresenta a relação da $\|\bar{\mathbf{A}}_i\|$ em função do *EQM* Médio. Os valores da norma variam ao longo dos voluntários por causa do ajuste do modelo ao intervalo de tempo T_j . O *EQM* apresenta variabilidade devido a c e influenciadas por \mathbf{H} , esta variabilidade se propaga com o aumento da $\|\mathbf{A}\|$ como foi visto previamente. Portanto se pode concluir que é a variabilidade do sinal *EEG* influencia significativamente na estimação dos estados.

A imposição do movimento levou a melhorar a estimação da velocidade e aceleração do movimento, com a restrição de diminuir a variabilidade do mesmo. Esta




Figura 4.20: Variação do Erro Quadrático Médio durante o ascenso usando o modelo da matriz \mathbf{A} ideal em todos os voluntários.




Figura 4.21: Gráfico de dispersão que compara a magnitude da norma de Frobenius da matriz \mathbf{A} com o EQM Médio para os voluntários em movimentos ascendentes usando a matriz \mathbf{A} ideal.

condição não é a ideal é não será tida em conta para projetar um sistema assistivo, onde o voluntário possa movimentar o braço, mais será útil para implementar o filtro de Kalman em condições onde não se tem uma noção do movimento efetuado, como o caso da imaginação motora.

4.5 Treinamento do filtro de Kalman para decodificar movimentos imaginários

Nesta seção se faz o treinamento e se analisam os resultados do uso do filtro de Kalman para decodificar movimentos imaginários. Dado que, não se tem trajetórias para treinar as matrizes do modelo do sistema \mathbf{A} e da decodificação \mathbf{H} em função do movimento executado, foi implementada a mesma estratégia da seção anterior.

Usou-se um conjunto de trials de forma que a matriz \mathbf{A}_i foi construída a partir de movimentos \mathbf{x} que cumprem a condição $\|\mathbf{A}\| \leq \lambda$ onde $\lambda = 3$. Este valor foi determinado visualmente de acordo com os resultados do experimento, dado que as normas menores têm maior probabilidade de ter um EQM inferior a 10.

Para este experimento 7 voluntários desenvolveram movimentos reais e imaginários do cotovelo dos braços esquerdo e direito, seguindo o mesmo paradigma experimental descrito no capítulo 3, com a diferença que as setas brancas indicaram ao voluntário a execução do movimento imaginário, da mesma forma o pré-processamento é feito com as mesmas condições descritas na seção. Durante o experimento, o voluntário foi instruído para imaginar a ação em primeira pessoa, tentando replicar a ação efetuada durante ações reais. Também, se solicitou minimizar outras ações como piscar de olhos ou o movimento mesmo do braço.

Na Figura 4.22 se apresenta o comportamento da atividade espectral no canal C_3 durante a imaginação em um dos voluntários, apresentando-se uma dessincronização em torno da banda alfa (10-15 Hz), desde $t = 0$ ms sendo maior depois dos 2000 ms, tempo em que o voluntário executa a tarefa ordenada. Esta dessincronização é similar à apresentada quando o voluntário efetua o movimento real.

O treinamento efetuou-se através da validação cruzada com 6 *folds* com os mesmos parâmetros usados nos movimentos reais. Os gráficos ilustrando a variação do EQM de acordo com as distintas combinações dos parâmetros podem ser encontrados no Anexo B. As diferenças com os registros apresentados previamente são mínimas, salvo que o erro de estimação é menor devido ao uso de $\bar{\mathbf{x}}_i$ para treinar o modelo. Portanto tem-se que com $c = 3$, $50 \leq \Delta_t \leq 200$, um $lag = 0$ e a frequência *alfa*, se conseguem valores ótimos de decodificação do movimento em processos imaginários. Este procedimento repetiu-se para movimentos descendentes com resultados similares.




Figura 4.22: Variação da frequência no canal C_3 no Voluntário 1. Pode-se observar a dessincronização na banda alfa com um incremento após os 2000 ms, quando se inicia o processo de imaginação motora.

4.5.1 Análise do modelo

Nesta seção analisam-se os resultados para a determinação do filtro de Kalman tendo como parâmetros de configuração $\Delta_t = 70\text{ms}$, $c = 3$, $lag = 0$ e a frequência do sinal na banda *alfa* [8 – 16] Hz.

Na figura 4.23 se apresenta o erro de estimação do movimento, sendo este erro menor em comparação ao obtido com o movimento dado que o conjunto de movimentos usados para o treinamento foi restrito às condições mencionadas previamente.

As matrizes usadas no modelo do sistema \mathbf{A} e da decodificação \mathbf{H} apresentam a variação ilustrada na figura 4.24, entretanto \mathbf{A} tem alterações pela adaptação ao intervalo de tempo de cada voluntário, da mesma forma que \mathbf{H} que depende da atividade cognitiva usada para decodificar o movimento. Não obstante os valores dos respectivos coeficientes (Figura 4.25), apresentam a mesma escala de magnitude do movimento real, sendo a posição o estado que mais ajuda a construir o modelo e a aceleração a que menos ajuda.

A variação da norma da matriz \mathbf{A} em função do EQM (Figura 4.26) apresenta a mesma distribuição do caso imposto da seção prévia. Dado que esta matriz é constante, a variação da estimação é dependente do resultado do treinamento da matriz \mathbf{H} . Esta matriz conserva o comportamento de experiências prévias, onde normas menores tem a maior probabilidade de apresentar menor EQM (Figura




Figura 4.23: Erro quadrático médio do movimento estimado para atividades imaginárias.




Figura 4.24: Variação dos coeficientes das matrizes A e H ao longo de todos os voluntários.




Figura 4.25: Variação das magnitudes dos coeficientes da matriz H respeito ao estado.

4.27).

Valores similares podem ser encontrados para o movimento descendente. Estas respostas encontram-se no Anexo B.

Um novo teste foi feito com uma matriz \mathbf{A} constituída por movimentos $\|\mathbf{A}\| > 3$. Nas figuras 4.28 e 4.29 apresentam-se os resultados da decodificação do movimento ascendente. Pode ser visto que um aumento da $\|\mathbf{A}\|$ leva a o incremento do erro de estimação tanto para a posição, velocidade e aceleração ao longo de todos os voluntários.

Em conclusão, é possível decodificar movimentos a partir de sinais *EEG* relacionados com a imaginação motora, embora, a precisão deste modelo seja totalmente dependente do conjunto de movimentos usado para treinar o filtro, cuja variabilidade pode afetar o resultado final da estimação. A imposição do movimento por sua vez, pode ser implementada em qualquer voluntário, esperando resultados próximos entre eles.

A aplicação do filtro de Kalman é dependente também da atividade do sinal *EEG* usado para estimar o movimento. Este processo de decodificação foi possível de ser aplicado unicamente porque a natureza dos exercícios efetuados era a mesma, contado que, o voluntário tenha efetuado o processo cognitivo correspondente. Tendo como único critério a análise espectral do sinal, é difícil ter a certeza que a atividade




Figura 4.26: Gráfico de dispersão que compara a magnitude da norma de Frobenius da matriz A com o EQM Médio ao longo dos voluntários em movimentos imaginários ascendentes .




Figura 4.27: Gráfico de dispersão que compara a magnitude da norma de Frobenius de H com o EQM Médio ao longo dos voluntários.




Figura 4.28: Gráfico de dispersão que compara a magnitude da norma de Frobenius de \mathbf{H} com o *EQM* Médio ao longo dos voluntários. Usando $\|\mathbf{A}\| > 3$.




Figura 4.29: Erro quadrático médio do movimento estimado para atividades imaginárias usando $\|\mathbf{A}\| > 3$.

cognitiva efetuada seja a correspondente à ação esperada.

Talvez a possibilidade de estimar o modelo seja mais pelo treinamento das matrizes \mathbf{A} e \mathbf{H} , que ligam o comportamento da atividade elétrica ao movimento associado, e não porque realmente se esteja aproveitando um comportamento neural associado com o movimento. Se isto é certo, a possibilidade de decodificar qualquer movimento fica dependente de como se integram os sinais, e definir-se adequadamente os modelos a serem implementados. Sem dúvida, trabalhos futuros podem esclarecer estas perguntas.

4.6 Discussão

Este capítulo apresentou o filtro de Kalman como técnica para decodificar o movimento do cotovelo do braço direito a partir de sinais *EEG* extraídos por métodos não invasivos. Para tal fim o filtro proposto teve que ser treinado usando dados reais para determinar um conjunto de matrizes que iriam construir o modelo de decodificação \mathbf{z}_k e o modelo da propagação do estado \mathbf{x}_k . Os sinais foram tratados em função de um conjunto de parâmetros que modificavam as entradas do filtro. Para escolher estes parâmetros uma validação cruzada de 6 *k-folds* foi efetuada com finalidade de encontrar a melhor combinação de variáveis que minimizavam o Erro Quadrático Médio do estado estimado relativo ao estado esperado.

Foi encontrado que, dos parâmetros avaliados os fatores mais determinantes foram Δ_t que configurava a sequência temporal, variando o número de pontos que a conformam, e o número de Canais c que configurava o número de sinais requeridos do córtex para estimar o valor do estado. O primeiro parâmetro influenciava na estimação do estado, na medida que a variável aumentava de magnitude. Esta configuração era vantajosa para o filtro, porém diminuía o detalhe do movimento, e portanto, também dificulta o controle assistivo do mesmo, restringindo a aplicação a movimentos lentos, como foi mencionado por Wu et al., [107] sem indagar mais ao respeito.

Por outro lado, o número de canais necessários para a estimação (3 neste trabalho) foi menor em comparação com o citado texto e também menor comparando com o trabalho de Robinson et al., [108] (35). Contudo, acreditamos que estas diferenças estão relacionadas com a natureza do movimento, dado que nos trabalhos citados, se tenta decodificar trajetórias aleatórias com alterações permanentes do movimento do braço. Esta é uma diferença com o presente trabalho, dado que aqui estudou-se a decodificação de um movimento simplificado, com condições restritas do espaço de trabalho, efetuando uma trajetória constante ao longo do estudo.

Os resultados deste trabalho, permitiram avaliar os seguintes quesitos: primeiro, que os trabalhos de Wu et al., e Robinson et al., são reproduzíveis, tendo como

resultado um movimento decodificado com as mesmas dificuldades como a estimação da aceleração do sinal decodificada; segundo, que a decodificação pode-se estender a outros membros relacionados com o movimento da mão, neste caso a rotação do cotovelo; e terceiro, que a decodificação do movimento se pode estender a outros estados mentais como a imaginação motora.

A possibilidade de poder decodificar do movimento do cotovelo levanta outras hipóteses. Como a possibilidade de estimar outras articulações relacionados com a posição e orientação da mão, como a flexão do braço ou a pronação do antebraço; e também para outros membros, como as pernas em tarefas de caminhada. Movimentos simplificados focados em um articulação, portanto, podem ser estimados usando o filtro de Kalman a partir de configurações menos complexas, abrindo o caminho para a projeção de sistemas assistivos focados na recuperação de movimentos específicos.

Ao analisar o filtro configurado com os parâmetros que minimizavam o erro de estimação, foi encontrado que a decodificação do movimento tem maior dependência ao modelo do sistema do que ao modelo de decodificação. Ao longo de todos os voluntários, o maiores erros na decodificação do movimento durante a etapa de treinamento estavam associados com matrizes \mathbf{A} conformadas a partir de movimentos com maior velocidade e aceleração, cuja característica principal era ter uma alta norma. Certamente, o valor ótimo $\Delta_t = 70ms$ apresenta dificuldades em propagar movimentos efetuados em um intervalo de tempo menor. Sendo os movimentos executados com um grau de variabilidade que depende das condições físicas e mentais do voluntário, o comportamento da curva de EQM tenderiam a favorecer aqueles parâmetros que se ajustem aos movimentos mais repetidos ou prováveis.

Entretanto, valores da matriz \mathbf{H} associada como modelo de decodificação, tiveram uma dispersão que se concentrou maioritariamente em zonas de baixo EQM sem encontrar uma relação específica entres estas magnitudes. Contudo, o sinal EEG tem um efeito de propagação do erro de estimação que é maximizado quando o modelo avaliado não se ajusta ao movimento executado. Assim, movimentos com alta variação e aceleração apresentavam uma maior dispersão no resultado do EQM formando o efeito de cone visto na Fig. 4.17. Ao treinar o modelo com condições específicas de movimento, por exemplos com movimentos cuja matriz resultante tivesse norma menor a um valor, encontrou-se que este efeito de dispersão era minimizado ate encontrar condições de codificação com $EQM < 3$.

Por tanto, a procura de um sistema de decodificação ótimo leva a encontrar um conjunto de parâmetros que se ajusta a condições especificadas pela regularidade do experimento. Isto, provavelmente também explique a dificuldade dos sistemas propostos por Wu et al., e Robinson et al., em estimar com maior precisão o valor do estado, dado que no caso deles, as magnitudes da velocidade e da aceleração variam

aleatoriamente. Portanto, consideramos que para conseguir estimar modelos que se ajustem a diferentes condições de velocidade e aceleração, se deve reconfigurar o paradigma experimental, solicitando por exemplo ao voluntário efetuar a flexão extensão num menor tempo. Ao levar estes dados a uma nova validação cruzada, o modelo treinado baixo estas condições provavelmente seja distinto ao apresentado neste capítulo, ajustado às condições de velocidade e aceleração mais prováveis efetuadas pelo voluntário durante o experimento. Por outro lado, se podem considerar também modelos de propagação não lineares que consigam interpretar distintas variações do movimento, o Filtro Estendido de Kalman ou redes neurais podem ser propostos para a projeção destes novos modelos.

Finalmente, mesmo se tenha determinado um sistema de decodificação a partir de condições reguladas, como foi o caso da estimação do movimento a partir de *EEG* relacionado com ações imaginárias, que levaram a encontrar uma estimação com um *EQM* menor tanto na posição, como na velocidade e na aceleração. A resposta deste modelo não conseguiu que a decodificação do estado associado com a aceleração apresentara um *EQM* com uma magnitude equivalente à posição e velocidade (Figura 4.23 e Figura 4.29). Adicionando que os coeficientes da matriz **H** associados à aceleração continuam tendo o menor valor. Conclui-se que o aporte do terceiro estado para a codificação da atividade cognitiva continua sendo menor, e não afeita significativamente a qualidade da resposta.

Os resultados do filtro durante a etapa de Validação usando os parâmetros com melhor desempenho tanto com *EEG* relacionado com ações reais como imaginárias serão apresentados no Capítulo 6.

Capítulo 5

Dinâmica Sistema Antebraço - Motor

Este capítulo descreve a obtenção e estudo da dinâmica de um sistema assistivo de membro superior, que será posteriormente integrado ao sistema de decodificação do movimento obtido no capítulo anterior e complementarará ao sistema *BCI* proposto neste trabalho.

Para obter o modelo matemático que descreve a dinâmica do braço humano é preciso fazer um estudo biomecânico do mesmo. Para tal fim, é feito neste capítulo, uma análise do membro superior tendo em conta aspectos morfológicos, detalhando através de estudos anatômicos as propriedades físicas do mesmo. Paralelamente, visando a construção de um sistema robótico assistivo, é integrado ao modelo dinâmico do braço um motor elétrico que fornecerá a energia para efetuar a movimentação quando o braço se encontre incapacitado. Medições reais do movimento integram este análise, permitindo desta forma, ter uma simulação aproximada do que seria um sistema real.

O capítulo é distribuído da seguinte forma: na seção 5.1 é elaborado o estudo anatômico do braço, a seção 5.2 descreve o modelo dinâmico braço-motor desenvolvido, na seção 5.3 é implementada a trajetória obtida através das medições dos movimentos dos voluntários e finalmente na seção 5.4 a estratégia de controle proposta ao modelo.

5.1 Estudo anatômico

O movimento do corpo humano é o resultado da interação entre vários sistemas. Como base, se tem uma estrutura óssea que suporta o corpo e conforma os segmentos do mesmo, encontrando-se unidos pelas articulações que fornecem a direção do movimento e têm uma faixa de mobilidade com restrições físicas. Cada articulação




Figura 5.1: Planos de referência usados para descrever a orientação dos movimentos de cada membro. Adaptado de Pons, [3]

consegue ser movimentada através da ação dos músculos comandados pelo cérebro mediante uma rede que conforma o sistema nervoso. Estes movimentos, que se desenvolvem em um espaço de três dimensões, são descritos em relação à posição anatômica do corpo dividida em planos que conformam este espaço.

5.1.1 Planos de Rotação

Três planos perpendiculares são usados como referência para descrever o movimento do membro (Figura 5.1): o *plano médio*, que divide ao corpo em esquerda e direita. Auxiliando este plano, são considerados um conjunto de planos paralelos denominados *planos sagitais*. O *plano frontal*, perpendicular ao plano médio divide o corpo na parte posterior e anterior. E finalmente, o *plano transversal* que divide o corpo entre as partes superior e inferior.

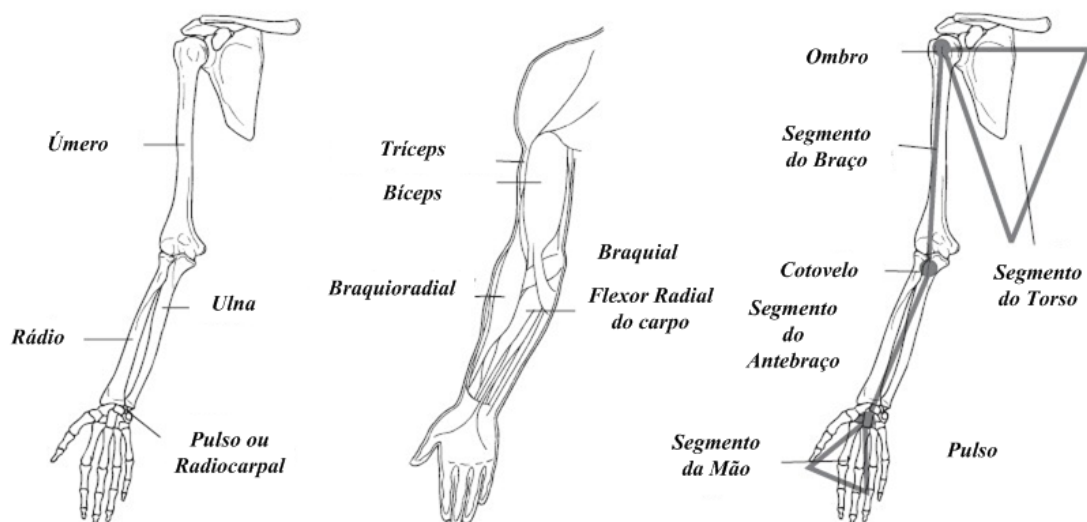


Figura 5.2: Divisão do braço através dos segmentos. Adaptado de Pons, [3]

5.1.2 Anatomia do braço humano

O braço humano é descrito como uma extremidade superior que vai desde o ombro até a ponta dos dedos da mão, dividido por três segmentos (Figura 5.2): braço, antebraço e a mão. O braço está unido ao corpo através da junta do ombro e ao antebraço através da junta do cotovelo, enquanto o antebraço se une à mão através da junta do pulso.

A articulação do ombro, une o braço com o tronco, segundo Calais [137] tem duas funções: permitir à mão e braço uma ampla faixa de movimentos; e fornecer um ponto fixo forte e estável para o desenvolvimento das ações próprias do membro.

O ombro pode ser descrito como uma junta esférica que permite a rotação do braço em três eixos. O primeiro movimento consiste na *flexão* e *extensão* efetuada no plano sagital. O segundo movimento de *abdução* e *adução*, feito no plano frontal, e o terceiro movimento em torno do plano transversal que desenvolve a *supinação* e *pronação*.

O cotovelo tem dois graus de liberdade, o primeiro desenvolve a *flexão* e *extensão* do antebraço que se mede sobre o plano sagital, este movimento decrementa e incrementa respectivamente o ângulo entre o braço e o antebraço. A extensão fornece também a possibilidade do antebraço de retornar a posição anatômica, que é o alinhamento entre todos os segmentos que conformam o braço, nesta posição o osso do úmero que suporta o braço, e o rádio e ulna que suporta o antebraço tem o maior ângulo de afastamento (180°).

O movimento de extensão é desenvolvido pelo tríceps que se encontra localizado na parte posterior do braço sobre o úmero, enquanto a flexão é desenvolvida em conjunto pelo bíceps localizado na parte frontal do braço, o braquial na parte posterior

do braço e o músculo braquiorradial localizada no antebraço. Este movimento é o que tem maior interesse para o trabalho, já que a rotação desta articulação foi o estímulo motor que se analisou na atividade cortical da zona motora do cérebro, cujo movimento tem se o interesse de assistir.

O segundo grau de liberdade do cotovelo é denominado de pronação e supinação e consiste em uma rotação em torno do eixo do membro no plano transversal, esta rotação muda a direção da mão. Nesta rotação a ulna e o rádio mudam sua posição para modificar a orientação do membro. A pronação consiste no cruzamento destes ossos para orientar a palma da mão para baixo, entanto na supinação os ossos se localizam paralelamente para orientar a palma da mão para acima. Esta ação é desenvolvida em conjunto pelo músculo flexor radial do carpo e o músculo braquiorradial que se encontram ao redor dos ossos do antebraço.

A mão é o terceiro elemento que conforma o braço, está constituída pela articulação do pulso, a palma e os dedos, cujo controle tem a maior área de processamento no córtex motor do cérebro. Fora dos múltiplos movimentos dos dedos, nã mão se podem distinguir dois movimentos: a *flexão* e *extensão*, que similar ao antebraço, gira a mão em torno do plano sagital, aproximando-a e afastando-a do antebraço; e a abdução e adução, que se desenvolve no plano frontal, e desvia o ângulo entre a mão e o antebraço.

Na figura 5.3 se resumem os movimentos do braço, descrevendo as articulações como pontos de rotação com seus respectivos movimentos, entanto os segmentos que complementam a estrutura do braço se descrevem com braço l_1 , antebraço l_2 e mão l_3 .

Finalmente, na figura 5.4 é apresentado o conjunto de restrições anatômicas que limitam a mobilidade do sistema.

5.1.3 Antropometria

Um estudo antropométrico do braço é fundamental para projetar o sistema mecânico que pretende descrever o movimento, para tal fim certas considerações foram feitas: a primeira, o conjunto antebraço mão foi considerado como um único segmento, uma vez que esta última articulação estará imobilizada e, por tanto, não exercerá nenhum tipo de rotação que aporte modificações ao comportamento do movimento do cotovelo. A segunda consideração é que o ombro também estará imobilizado, logo apenas o cotovelo efetuará os movimentos.

De acordo com a estrutura descrita previamente na Figura 5.3, o braço, representado como L_1 , estará estendido de forma vertical e paralelo ao plano sagital do corpo. O afastamento produzido pela abdução do ombro é mínimo de acordo com a estrutura anatômica de uma pessoa sentada sobre uma cadeira que repousa o an-

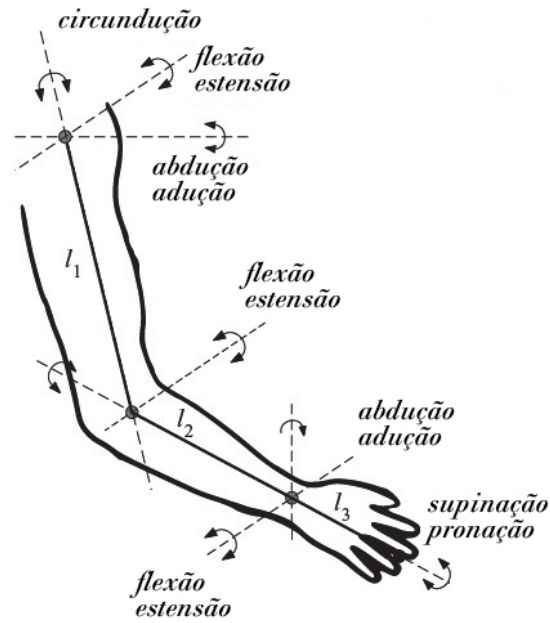


Figura 5.3: Estrutura do braço humano. Adaptado de Pons, [3]




Figura 5.4: Mobilidade do braço o longo do plano sagital. Imagem adaptada da *American Academy of Orthopaedic Surgeons*.

tebraço sobre o apoio do braço, forçando ao antebraço adaptar-se a uma posição ortogonal com respeito ao braço . Durante as leituras, as mãos ficaram apoiadas sobre a cadeira com as palmas orientadas para cima imobilizada durante a ação de flexão.

Entretanto, valores reais para a massa, posição dos centros de inercia e comprimento do braço, estão descritas na Tabela 5.1. Estas medições antropométricas foram obtidas através de estudos do corpo humano em cadáveres, tanto de homens como mulheres [138] e [139].

Tabela 5.1: Valores morfológicos dos segmentos do braço. H é a altura do individuo, CM é a distância proximal do Centro de Masa relativo ao comprimento do segmento e $r\%$ é a ubicação do raio de giro quando o corpo gira respeito a um eixo localizado no Centro de Gravidade (CG) ou num dos extremos Proximal ou Distal do segmento. Extraído de Winter [139].

Segmento	Comp.(m)	Masa (%)	CM (%)	Raio de Giro r (%)		
				CG	Proximal	Distal
Braço (l_A)	$H*0.186$	2.71	43.6	32.2	54.2	64.5
Antebraço (l_1)	$H*0.146$	1.62	43	30.3	52.6	64.7
Mão (l_2)	$H*0.108$	0.61	50.6	29.7	58.7	57.7

O Momento de Inercia do segmento pode ser encontrado usando a expressão:

$$I_n = (M * \%m_n) * (l_n * r)^2 \quad (5.1)$$

Onde, M é a massa total do individuo expressada em Kg ; $\%m_n$ é a massa relativa do segmento n determinada a partir da massa total do corpo; l_n é o comprimento do segmento obtido através de uma relação porcentual que depende da altura do individuo, e cujo valor se pode encontrar na Tabela 5.1; finalmente, r é o raio de giro que refere a ubicação da masa do segmento respeito ao plano em que se efetua a rotação.

Dado que a rotação do antebraço sucede respeito a cotovelo o raio de giro (r) se localiza proximalmente à articulação. Entretanto, como não existe movimento de rotação em torno do pulso, o Momento de Inercia da mão I_2 respeito ao cotovelo é encontrado usando o teorema de Steiner:

$$I_2 = I_{2/CG} + (M * \%m_2) * d^2 \quad (5.2)$$

Onde $I_{2/CG}$ é o momento de inercia da mão respeito ao Centro de Gravidade (CG) e d é a distância entre o Centro de Massa (CM) e o eixo de rotação.

Finalmente, a massa M do individuo foi calculada a partir da altura usando o índice de *Quetelet*:

$$M = IMC * H^2 \quad (5.3)$$

Utilizando um *IMC* (Índice de Massa Corporal) de 24 que é associado com uma distribuição saudável da massa do indivíduo. A altura do individuo H foi escolhida em $1.70\ m$, que é a estatura meia da população masculina brasileira segundo o Censo do ano 2010 [14].

5.2 Análise Dinâmica

Esta pesquisa desenvolve o controle da movimentação assistiva do braço através de uma atuador elétrico localizado acima do cotovelo. O sistema será projetado para acompanhar os movimentos de flexão/extensão da articulação, para tal propósito se efetuará um análise dinâmica do antebraço. Com o objetivo de controlar o movimento do sistema, o *Differential Flatness* será usado para determinar a entrada necessária para efetuar o movimento de acordo com um trajetória que descreve a variação angular num período de tempo. Para corrigir a posição da articulação em caso de desvios, um laço de realimentação com um controlador PID será adicionado ao sistema. Movimentos das articulações do ombro e da mão não serão considerados para este estudo.

5.2.1 Motor Elétrico

Na tabela 5.2 se detalha os parâmetros do accionamento *Maxon CC RE 50* fornecidos pelo fabricante. O atuador está conformado por um motor DC com escovas de imã permanente, que conta com um redutor planetário para a transmissão de potencia e redução da velocidade, e um encoder na parte posterior para as medições da posição e velocidade.

Tabela 5.2: Dados do Motor Maxon CC RE 50. Fornecidos pelo fabricante.

Motor CC RE 50	
Parametro	Valor
$R_m(\Omega)$	0.103
$L_m(H)$	0.000072
$k_a(Nm/A)$	0.0385
$k_b(Hz/V)$	4.13
$I_m(Kgm^2)$	0.0000548
$b_m(Nm/Hz)$	0.00014802
N	4.3:1

Onde R_m é a resistência de armadura, L_m é a indutância da armadura, k_a é a constante de torque média do motor, k_b é a constante de velocidade média do motor,

I_m é o momento de Inércia do motor junto com o redutor, b_m é o coeficiente de atrito dinâmico do motor e N é a relação do redutor.

5.2.2 Modelo Matemático do Sistema

Uma representação do sistema em movimento é resumida na Figura 5.5. A partir dos valores expostos na Tabela 5.1, pode-se calcular o Modelo matemático do sistema Antebraço-Mão-Motor.




Figura 5.5: Representação da Estrutura Antebraço/Mão.

Onde l_A representa o segmento do braço, estático para o modelo e orientado ao longo do eixo z . Em P_0 , que representa a posição do cotovelo, é localizado o Referencial Inercial do Sistema e o sistema de atuação. O segmento antebraço/mão é representado por l_1 e l_2 respectivamente e se estendem ao longo do eixo z . O movimento do cotovelo assistido é representado por q_1 e gira em torno do eixo x , representando o movimento de flexão/extensão assistido. Este ângulo tem uma posição inicial de 90° , imitando a posição de repouso do braço sobre o apoio da cadeira. CM_1 e CM_2 representam as posições dos centros de massa relativos ao segmento do antebraço (P_0) e mão (P_1) respectivamente. O motor e o braço se encontram unidos através de uma junta que se combina a um elo paralelo ao antebraço, cuja massa se considerará nula para este modelo.

Usando as matrizes de transformação homogênea é definido o modelo cinemático que determina a posição do ponto d_n localizado ao longo do comprimento do conjunto antebraço/mão respeito ao referencial inercial:

$${}^0\mathbf{T}_n = \mathbf{R}_x(q_1)\mathbf{T}_z(-d_n) \quad (5.4)$$

Onde $\mathbf{R}_x(q_1)$ é a matriz de transformação rotacional em torno do eixo X representada como:

$$\mathbf{R}^x(q_1) = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos(q_1) & -\text{sen}(q_1) & 0 \\ 0 & \text{sen}(q_1) & \cos(q_1) & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (5.5)$$

E $\mathbf{T}_z(-d_n)$ é a matriz de transformação translacional respeito ao eixo z para o deslocamento d_n , a magnitude negativa enfatiza a direção do deslocamento no eixo:

$$\mathbf{T}_z(d_n) = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & -d_n \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (5.6)$$

O modelo dinâmico do Sistema é determinado através de uma perspectiva Lagrangiana, cujo conjunto de equações que definem o modelo é definido como:

$$\frac{d}{dt}\left(\frac{\partial L}{\partial \dot{q}_n}\right) - \frac{\partial L}{\partial q_n} = Q_n, \forall n = 1, \dots, m \quad (5.7)$$

Onde q_n representa o vetor de coordenadas generalizadas do sistema, Q_n é o conjunto de forças generalizadas, L é a função lagrangiana do robô calculada a partir da energia cinética T é a energia potencial V do sistema antebraço/motor:

$$L = \sum_{n=1}^2 T_n + T_m - \sum_{n=1}^2 V_n - V_m \quad (5.8)$$

Energia cinética

A energia cinética do n -ésimo segmento do sistema e o motor será dada pela relação:

$$\sum_{n=1}^2 T_n + T_m = \sum_{n=1}^2 \left(\frac{1}{2}I_n\omega_n\omega_n^T\right) + \sum_{n=1}^2 \left(\frac{1}{2}m_n\mathbf{v}_n\mathbf{v}_n^T\right) + \frac{1}{2}I_m\omega_m\omega_m^T \quad (5.9)$$

Sendo $n = 1, 2$ a energia cinética aportada pelos dois segmentos que conformam o sistema. Esta expressão determina os aportes energéticos causados tanto pela rotação como a traslação de cada um dos corpos que compõem o modelo. I_n é o

momento de Inercia de cada segmento determinado segundo as equações 5.1 e 5.2 e I_m o momento de Inercia do motor conforme foi descrito na tabela 5.2, sendo ω_m a velocidade angular deste.

A velocidade angular absoluta ω_n para cada centro de masa CM_n é a mesma ao longo do eixo de rotação, esta representada pela velocidade do movimento rotacional no cotovelo \dot{q}_1 que se efetua no eixo x . Portanto a velocidade angular absoluta é:

$$\omega_n = \dot{q}_1 \quad (5.10)$$

Por outro lado a velocidade angular do motor ω_m esta descrita pela velocidade de rotação do elo do atuador também no eixo x , esta magnitude descreve-se:

$$\omega_m = \dot{q}_m \quad (5.11)$$

Na formula geral descrita em 5.9, no entanto, o modelo adotado para o braço trabalha com uma rotação do braço em torno de um eixo fixo que define o grau de liberdade de flexão/extensão da articulação do cotovelo. Assim, a expressão de energia cinética será simplificada para apenas a parcela referente à energia cinética da rotação:

$$\sum_{n=1}^2 T_n + T_m = \sum_{n=1}^2 \left(\frac{1}{2} I_n \dot{q}_1^2 \right) + \frac{1}{2} I_m \dot{q}_m^2 \quad (5.12)$$

Energia Potencial

Sendo que a força de gravidade g atua ao longo do eixo z , a energia potencial de cada segmento é dada pela relação:

$$V_n = m_n g d_n \cos(q_1) \quad (5.13)$$

Onde m_n é a massa do segmento, g é a força de gravidade ($9.81m/s^2$) e d_n é a distância do centro de massa do segmento n até o centro de rotação:

$$\begin{aligned} d_1 &= -CM_1 \\ d_2 &= -(l_1 + CM_2) \end{aligned} \quad (5.14)$$

Dado que motor se encontra fixo no cotovelo, o aporte dele respeito à parcela da energia potencial é nulo, portanto $V_m = 0$.

Modelo Dinâmico

Determinando as respectivas energias cinética e potencial para cada segmento através das equações 5.9 e 5.13 é estabelecido o modelo matemático do sistema.

Sabendo que existe uma relação entre a velocidade angular do motor e do sistema antebraço/mão de $\dot{q}_1 = \dot{q}_m/N$, o modelo dinâmico do sistema em função do movimento do motor é:

$$Q_m = \ddot{q}_m \left(I_m + \frac{m_1 \text{CM}_1^2 + I_1 + I_2 + m_2 (\text{CM}_2 + \text{L}_1)^2}{N^2} \right) + g \sin\left(\frac{q_m}{N}\right) \left(\frac{m_2 (\text{CM}_2 + \text{L}_1) + \text{CM}_1 m_1}{N} \right) \quad (5.15)$$

Tendo em conta no sistema os efeitos dissipativos τ_d relacionados com o amortecimento da junta conectada ao elo do motor e o rolamento do mesmo, o torque total do sistema será calculado como:

$$Q_m = \tau_m - \tau_d \quad (5.16)$$

Onde a dissipação total do sistema, tendo em conta a relação de velocidade N entre o motor e o sistema antebraço/mão é:

$$\tau_d = \dot{q}_m \left(b_m + \frac{b_l}{N^2} \right) \quad (5.17)$$

Onde b_l é o coeficiente de atrito dinâmico médio da junta do elo [140]. Adicionando o termo dissipativo 5.17 na equação 5.16 tem-se o modelo do torque no motor:

$$\tau_m = \ddot{q}_m \left(I_m + \frac{m_1 \text{CM}_1^2 + I_1 + I_2 + m_2 (\text{CM}_2 + \text{L}_1)^2}{N^2} \right) + \dot{q}_m \left(b_m + \frac{b_l}{N^2} \right) + g \sin\left(\frac{q_m}{N}\right) \left(\frac{m_2 (\text{CM}_2 + \text{L}_1) + \text{CM}_1 m_1}{N} \right) \quad (5.18)$$

Usando a constante de torque do motor k_a se pode expressar a equação 5.18 em função da corrente de subministro do motor i_m sendo:

$$i_m = \frac{\ddot{q}_m}{k_a} \left(I_m + \frac{m_1 \text{CM}_1^2 + I_1 + I_2 + m_2 (\text{CM}_2 + \text{L}_1)^2}{N^2} \right) + \frac{\dot{q}_m}{k_a} \left(b_m + \frac{b_l}{N^2} \right) + \frac{g}{k_a} \sin\left(\frac{q_m}{N}\right) \left(\frac{m_2 (\text{CM}_2 + \text{L}_1) + \text{CM}_1 m_1}{N} \right) \quad (5.19)$$

Este modelo permite implementar um sistema de controle em função da corrente elétrica do motor porém da tensão de entrada, dado que é conhecido o valor da resistência de armadura.

5.3 Comportamento plano do modelo dinâmico

Para determinar o conjunto de forças necessárias para movimentar o modelo obtido na equação 5.19, será implementado o conceito de *Differential Flatness* no modelo dinâmico do braço. Neste modelo um sistema não diferencial pode ser transformado em um modelo algébrico não linear usando um conjunto de saídas denominadas *saídas planas* (*flat outputs*) e suas derivadas [141].

Formalmente, um sistema composto de estados $\mathbf{x} \in \mathbb{R}^n$ e entradas $\mathbf{u} \in \mathbb{R}^m$ é dito plano, se existem um conjunto de saídas $\mathbf{y} \in \mathbb{R}^m$ escritas da forma:

$$\mathbf{y} = h(\mathbf{x}, \mathbf{u}, \dot{\mathbf{u}}, \dots, \mathbf{u}^P) \quad (5.20)$$

Tais que o sistema \mathbf{x} e as entradas \mathbf{u} podem ser descritas por o conjunto de saídas e suas derivadas:

$$\mathbf{x} = x(\mathbf{y}, \dot{\mathbf{y}}, \dots, \mathbf{y}^q) \quad (5.21)$$

$$\mathbf{u} = u(\mathbf{y}, \dot{\mathbf{y}}, \dots, \mathbf{y}^q) \quad (5.22)$$

Se o sistema cumpre estas condições é dito plano, que é considerada uma propriedade geométrica do sistema, e de nenhuma forma é uma aproximação linear do mesmo, conservando o sistema suas propriedades não lineares. Um sistema não linear plano possui uma estrutura bem caracterizada, que possibilita a criação de algoritmos de controle para o planejamento e geração de trajetórias, como também para sua estabilização [142].

Dado que as entradas e estados de um sistema plano são função das saídas planas, é possível criar trajetórias no espaço das saídas, e determinar com elas o conjunto de entradas que o estado necessita para atingi-las. Pode-se encontrar um catálogo de sistemas mecânicos que tem propriedades planas em Murray et. al [143].

A demonstração da propriedade plana dos manipuladores robóticos pode ser encontrada em Levine [144]. Partindo da definição de um braço robótico com n graus de liberdade atuados se tem a equação

$$\mathbf{M}(\mathbf{q})\ddot{\mathbf{q}} + \mathbf{C}(\mathbf{q}, \dot{\mathbf{q}}) + \mathbf{K}(\mathbf{q}) = \mathbf{Q}(\dot{\mathbf{q}}, \mathbf{q}) \mathbf{u} \quad (5.23)$$

Onde, \mathbf{q} representa as coordenadas generalizadas, \mathbf{u} são as entradas do sistema (é importante que tanto \mathbf{q} como \mathbf{u} tenham a mesma dimensão, isto é $\dim \mathbf{q} = \dim \mathbf{u}$), e \mathbf{Q} é uma matriz que caracteriza os atuadores do sistema.

Se $x_1 = q_1, x_2 = \dot{q}_1$ a equação 5.23 pode ser transformada em um conjunto de equações diferenciais ordinárias da forma:

$$\begin{aligned}\dot{x}_1 &= x_2 \\ \dot{x}_2 &= \mathbf{M}(x_1)^{-1}(\mathbf{C}(x_1, x_2) - \mathbf{Q}(x_1, x_2)\mathbf{u})\end{aligned}\tag{5.24}$$

Sendo que a dimensão de \mathbf{Q} é n , o conjunto de entradas \mathbf{u} pode ser determinado como:

$$\mathbf{u} = \mathbf{Q}^{-1}(x_1, \dot{x}_1)(M(x_1, \ddot{x}_1) + \mathbf{C}(x_1, \dot{x}_1))\tag{5.25}$$

Onde x_1 representa o vetor de saídas planas, que neste caso, representa a posição angular da coordenada generalizada. Este modelo pode ser implementado na equação 5.19 para obter em função da posição do braço, o torque ou a corrente necessária para atingir a posição do antebraço desejado. Esta técnica para a determinação dos controles é conhecida como torque computado ou *IDC (Inverse Dynamic Controller)* e geralmente é acompanhada por um controlador PD, PID, ou um controle adaptativo que modifica o valor dos ganhos de acordo com o comportamento do sistema.

5.3.1 Determinação da trajetória do movimento

Em trabalhos anteriores [11] a trajetória de referência do movimento da articulação era definido por modelos cúbicos $q(t)$, estes polinômios eram substituídos no modelo definido pela equação 5.25 para calcular a entrada $u(t)$ para cada intervalo de tempo, fornecendo assim as entradas necessárias para que o modelo adotasse o comportamento desejado.

Devido a que é desejado o uso de parâmetros reais, um movimento médio, resultado de múltiplas capturas do de flexão e extensão do braço direito do voluntario é usado como trajetória de referencia, estes movimentos foram captados durante a etapa de leitura dos sinais EEG, porém respondem ao mesmo paradigma experimental.

Usando a derivada numérica, é calculada a velocidade e a aceleração respectiva do movimento, obtendo assim o conjunto de variáveis de referência entrada para o modelo. Estas magnitudes se descrevem na Figura 5.6.

De acordo com estas entradas, e tendo em conta a relação N entre o motor e o antebraço, é usando o modelo descrito na equação 5.25 para obter o conjunto de torques que deve fornecer o motor para que o braço se movimente de acordo com a trajetória (Figura5.7).

5.4 Configuração do controlador

Um controlador *PID* foi integrado junto com o *differential flatness* como se descreve na Figura 5.8. Este controlador tem a capacidade de eliminar o erro em estado




Figura 5.6: Descrição da Trajetória de referência e a velocidade e aceleração respectivas

estacionário que é gerado pela presença de perturbações externas, no caso do BCI proposto, estas perturbações poder ser provenientes dos possíveis erros da decodificação do sinal de entrada ou parâmetros não modelados do braço.

O erro e descrito na figura, é a diferencia entre a saída nominal e a saída real do sistema. Esta diferencia é normalmente denominada como erro de seguimento, sendo definida como $e = q_d - q_r$. Diferenciando-se o modelo, tem-se:

$$\begin{aligned}\dot{e} &= \dot{q}_d - \dot{q}_r \\ \ddot{e} &= \ddot{q}_d - \ddot{q}_r\end{aligned}\tag{5.26}$$

Uma lei de controle c que pode gerar um seguimento da trajetória q_d é [145]:

$$\begin{aligned}c &= -k_p(x_n - x_r) - k_d(\dot{x}_n - \dot{x}_r) - k_i \int (x_n - x_r) \\ c &= -k_p e - k_d \dot{e} - k_i \int e\end{aligned}\tag{5.27}$$

Com o objetivo de adicionar o laço de controle no sistema se procurará uma relação entre o sinal de controle c e a saída do sistema q_r . Para isto, se parte do modelo da equação 5.23 e agrupando os termos de Coriolis e gravitacionais em uma nova variável denominada $\mathbf{N}(q, \dot{q})$ se tem o modelo dinâmico do sistema em laço aberto:




Figura 5.7: Torque no Motor requerido para efetuar o Movimento

$$\mathbf{M}(q)\ddot{q} + \mathbf{N}(q, \dot{q}) = \tau \quad (5.28)$$

Destacando-se \ddot{q} se tem:

$$\ddot{q} = \mathbf{M}(q)^{-1}(\tau - \mathbf{N}(q, \dot{q})) \quad (5.29)$$

Da equação 5.29 se pode determinar que a aceleração do sistema é uma relação entre a matriz de inercia e a diferença da matriz de forças gravitacionais e de Coriolis com o torque, isto é que quanto maior for a masa do sistema maior oposição terá para acelerar.

Substituindo a equação 5.26 em 5.29 se tem a relação entre a dinâmica do sistema e a aceleração desejada:

$$\ddot{e} = \ddot{q}_d - \mathbf{M}(q)^{-1}(\tau - \mathbf{N}(q, \dot{q})) \quad (5.30)$$

A equação 5.30 também relaciona o erro na aceleração em função da entrada no sistema τ . Pode-se ver que variações nesta entrada afetam a variação do erro dinâmico, que é uma uma relação da variação entre a posição real e desejada. Portanto, modificações na entrada podem diminuir ou aumentar esta diferença. Esta diferença pode ser usada como função de entrada do controle:

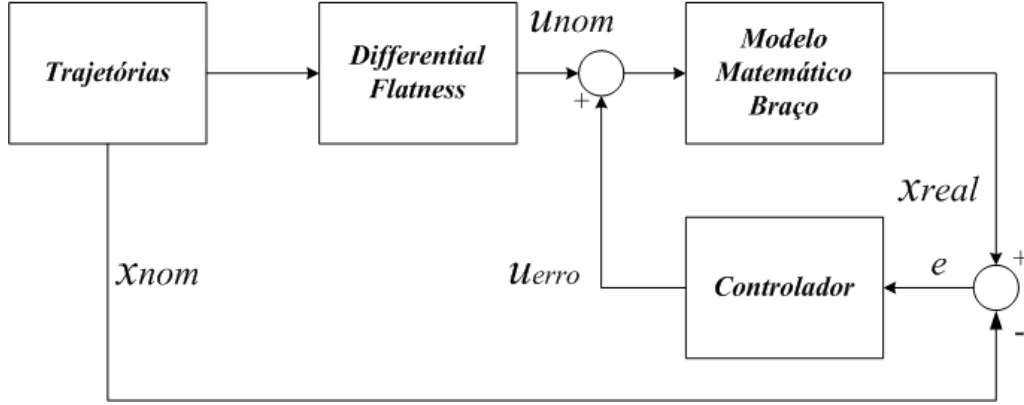


Figura 5.8: Sistema de controle do braço

$$c = \ddot{q}_d + \mathbf{M}(q)^{-1}(\mathbf{N}(q, \dot{q}) - \tau) \quad (5.31)$$

Pode-se descrever um estado $x \in \mathbb{R}^2$ que relacione o conjunto de equações 5.26 com 5.31 a partir de:

$$\tilde{x} = \begin{bmatrix} e \\ \dot{e} \end{bmatrix} \quad (5.32)$$

E linearizando a dinâmica do erro de seguimento como:

$$\frac{d}{dt} \begin{bmatrix} e \\ \dot{e} \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} e \\ \dot{e} \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} c \quad (5.33)$$

Pode-se ver que a variação do erro de seguimento depende da entrada de controle c . Si é invertida a equação 5.31, tem-se que:

$$\tau = \mathbf{M}(q)(\ddot{q}_d - c) + \mathbf{N}(q, \dot{q}) \quad (5.34)$$

Esta relação é chamada lei de controle do torque computado [146], o que diz esta equação é que de acordo com a seleção de um sinal de controle c se pode estabilizar a variação do erro descrita em 5.33, de forma que e tenda a zero.

Se 5.34 é substituída em 5.28 se tem:

$$\mathbf{M}(q)\ddot{q} + \mathbf{N}(q, \dot{q}) = \mathbf{M}(q)(\ddot{q} - c) + \mathbf{N}(q, \dot{q}) \quad (5.35)$$

Resolvendo a igualdade se encontra que $\ddot{q} = c$, pode-se demonstrar que a variação na aceleração angular da coordenada generalizada pode ser usada como sinal de controle. Tendo em conta esta relação, se pode substituir a lei de controle PID 5.27 em 5.34 obtendo-se:

$$\tau = \mathbf{M}(q)(\ddot{q}_d + k_p e + k_d \dot{e} + k_i \int e) + \mathbf{N}(q, \dot{q}) \quad (5.36)$$

Para determinar como as magnitudes das constantes k_p , k_d e k_i influem no sistema, se estabelece um laço fechado entre a entrada de controle e o sistema, igualando 5.36 com 5.28. Encontrando a dinâmica do erro no laço fechado, que pode ser reescrito como:

$$\begin{aligned} \ddot{e} + k_d \dot{e} + k_p e + k_i \int e &= c \\ \ddot{e} + k_d \ddot{e} + k_p \dot{e} + k_i e &= c \end{aligned} \quad (5.37)$$

Reescrevendo a equação 5.37 no espaço de estados, permite-se entender como as constantes do controlador interferem na variação do erro dinâmico no sistema:

$$\frac{d}{dt} \begin{bmatrix} e \\ \dot{e} \\ \ddot{e} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ -k_i & -k_p & -k_d \end{bmatrix} \begin{bmatrix} e \\ \dot{e} \\ \ddot{e} \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} u \quad (5.38)$$

O polinômio característico de 5.38 no domínio da frequência é:

$$\Delta_c(s) = s^3 + k_d s^2 + k_p s + k_i \quad (5.39)$$

Característica de um sistema dinâmico de terceira ordem. Que é reescrito com um sistema de segunda ordem em série com um de primeira.

$$P(s) = (s^2 + \lambda_1 s + \lambda_2)(s + \lambda_3) \quad (5.40)$$

O valor da constante k_i não deve ser muito grande, de acordo com Lewis et al., [146], para garantir a estabilidade em laço fechado se deve cumprir que: $k_i < k_p k_d$. Este valor pode ser o suficientemente pequeno tal que o sistema tenha um comportamento próximo ao de segunda ordem [145], uma sugestão, é que este terceiro polo (λ_3) seja alocado a uma década de distância da frequência natural do sistema, desta forma sua dinâmica será rápida e não atrapalhará o funcionamento do sistema de segunda ordem [140].

Entanto para definir o sistema de segunda ordem que complementa ao modelo, se parte da equação característica [146]:

$$P_2(s) = s^2 + 2\zeta\omega_n s + \omega_n^2 \quad (5.41)$$

Sendo ζ o coeficiente de amortecimento e ω_n a frequência natural do sistema. Dado que se deseja anular a oscilação enquanto o atuador se posiciona respeito a referência, o coeficiente de amortecimento ζ deve ser igual a 1. O que quer dizer que

a seleção dos coeficientes é função do coeficiente proporcional ou mesmo a frequência natural ω_n . O modelo final do controlador é por tanto:

$$P(s) = (s^2 + 2\omega_n s + \omega_n^2)(s + 10\omega_n) \quad (5.42)$$

A frequência natural do sistema ω_n é determinada segundo o comportamento que se deseje induzir no sistema, embora, ele dependa da rigidez e a inercia do modelo, existem modelos matemáticos que relacionam estas magnitudes em sistemas robóticos [146]. Seu valor deve ser escolhido de forma que a recuperação da posição não leve ao controlador ter mudanças abruptas na velocidade do motor elétrico, realizando um processo de correção suave, isto com o objetivo de não causar incômodos no voluntário durante a correção de posição.

5.5 Integração do Filtro de Kalman com a dinâmica do braço

No Capítulo 4 foi introduzido o Filtro De Kalman como técnica para estimar os estados de um modelo \mathbf{x} a partir de um conjunto de observações \mathbf{z} . Os estados deste modelo representavam a evolução da posição, velocidade e aceleração angular do cotovelo num instante de tempo k , enquanto o sinal *EEG* proveniente do córtex motor foi usado como observações.

Previamente, na seção 5.3, tinha-se planteado o comportamento plano do modelo dinâmico do cotovelo, obtendo uma equação 5.24 que permitia em função das saídas planas, representadas pelas coordenadas generalizadas do sistema e suas derivadas, obter o conjunto de entradas u relacionadas com essas entradas.

Considerado que os estados estimados $\hat{\mathbf{x}}$ a partir do filtro de Kalman são uma aproximação aos estados resultantes do modelo dinâmico do braço \mathbf{x} , é proposto integrar a saída do filtro com a dinâmica do braço a través do respetivo modelo plano (*differential flatness*) de forma que seja obtida uma entrada estimada \hat{u} relacionada ao sinal decodificado para ser usado como sinal de ativação do sistema.

Na Figura 5.9 se representa esta integração:

Sendo \mathbf{X}_k um conjunto de j sinais *EEG* preprocessadas e filtradas na banda alfa de 8-16 Hz, sendo $j = [1, \dots, c]$ a quantidade de canais c usados para estimar o estado do modelo $\hat{\mathbf{x}}_k$ para cada instante de tempo k . A combinação de estados estimados calcula a través do modelo plano uma entrada estimada \hat{u}_k , cuja resposta do sistema dinâmico é descrita como $\tilde{\mathbf{y}}_k$ e será denominada de saída associada.

O filtro de Kalman se encargará de estimar os movimentos ascendentes e descendentes a partir do sinal *EEG* usando as matrizes $\mathbf{A}, \mathbf{B}, \mathbf{Q}$ e \mathbf{R} treinadas pelo procedimento descrito no capítulo 4. Este modelo está baseado na proposta de [147]

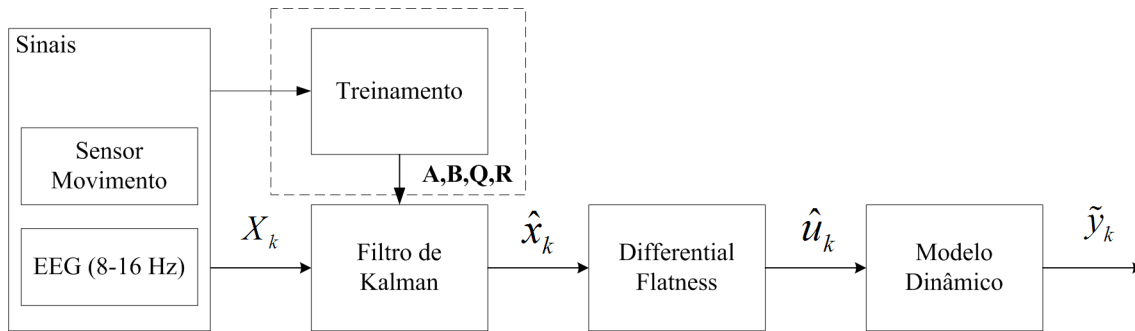


Figura 5.9: Laço aberto integrando o Filtro de Kalman com os modelos plano e Dinâmico do braço.

na que, decodifica o ângulo do cotovelo a partir de múltiplos sinais *EMG* usando redes neurais. Os ângulo estimado é posteriormente processado em uma interface computacional para gerar o sinal de controle que ativa um compressor de ar que posiciona o sistema no ângulo estimado.

É razoável pensar que, as entradas estimadas \hat{u}_k não são apropriadas para guiar o movimento do braço dado que, a estimação destes valores nunca foi exata. Assim, torques resultantes poderiam levar ao sistema a configurações não aceitáveis, nas que por exemplo, se ultrapasse o espaço de trabalho da articulação do cotovelo. Na figura 5.10 se apresenta um exemplo de uma sequência temporal de entradas estimadas \hat{u} , representada pela linha a traços, comparada com, o resultado equivalente se os sinais originais não fossem decodificados, linha preta contínua.

Considerando que a informação dos estados provenientes do filtro de Kalman são uma aproximação do movimento desenvolvido pelo voluntário cujo comportamento varia entre trials, existiria uma variação permanente entre a entrada estimada \hat{u} e a desejada u . É necessário compensar o valor a entrada estimada \hat{u}_k de forma que seja minimizado a diferença entre a saída associado \tilde{y}_k e a saída desejada y .

Na Figura 5.11 se apresenta o sistema de compensação proposto neste trabalho, este modelo é uma adaptação do modelo de Controle Adaptativo, mais especificamente o *Model-Reference Adaptive Control* (MRAC) [148], tendo em conta que aqui o modelo da planta considera-se invariante ao longo do tempo e não existirá uma sintonização das constantes do controlador, o laço de adaptação é substituído por um laço de controle compensatório.

O sistema compensatório compara a saída associada \tilde{y}_k com a saída desejada y_k no instante k proveniente de um modelo dinâmico com seu próprio laço de controle que usa a trajetória de referência como entrada. A estrutura do modelo de referência já foi descrita na Figura 5.8. A integração do *flatness* com o controle *PID* faz que o laço de realimentação se comporte como um par calculado, modificando o valor da entrada estimada, a través da relação descrita na equação 5.36. Sistemas




Figura 5.10: Comparação de uma sequencia de entradas estimadas e real.

compensatórios tem sido considerados em aplicações assistivas, no caso do trabalho de Mudiyansele [149] que aplica Par calculado para compensar os efeitos da fadiga muscular em um sistema assistivo baseado em *EMG*.

A integração do Flatness com o laço compensatório permite que a entrada estimada \hat{u}_k possa ser compensada em tempo real em função do erro de seguimento entre as saídas de associada com a desejada no tempo $k - 1$. Esta aplicação implica que no tempo t_0 não exista ação de controle, de forma que a correção do movimento aconteça a partir do instante t_1 .

O sistema assistivo é ativado unicamente com a entrada de sinal *EEG*, é assume que a trajetória a desenvolver é conhecida, porém este o modelo proposto pode ser usado em terapias assistivas baseadas na execução de movimentos repetitivos e controlados.

Uma variação do modelo pode ser feita retirando o movimento desejado \mathbf{x} , sendo o sistema de atuação similar ao visto na figura 5.8, onde o estado estimado se converte na trajetória de referência. Uma aplicação deste tipo, levaria a que a movimentação do braço seja dependente da entrada estimada, sem nenhum tipo de

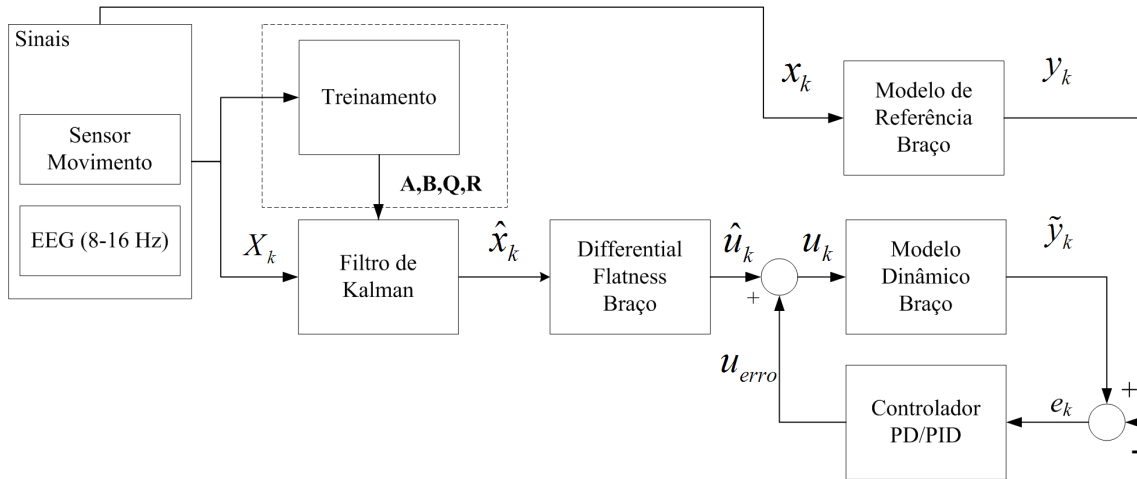


Figura 5.11: Sistema compensatório proposto para a entrada estimada.

restrição sobre o espaço de trabalho em que atua o braço. Neste caso, a precisão do movimento é totalmente dependente de \hat{x}_k .

No Capítulo 6 se apresenta a resposta do modelo de compensação usando como sinal de entrada sinais *EEG* associadas com atividade motora real e imaginária, controladores *PD* e *PID* são usados para comparar o desempenho do modelo para distintos valores de Δ_t . O erro de seguimento e energia são considerados para analisar o comportamento do modelo.

Capítulo 6

Resultados e Discussões

Neste capítulo são apresentados os resultados dos diferentes testes e simulações do modelo *BCI* proposto, analisando o Filtro de Kalman e o sistema dinâmico do braço e posteriormente sua integração. Ao final uma discussão dos resultados é apresentada e as conclusões e trabalhos futuros completam o conteúdo do capítulo.

6.1 Resultados Validação Filtro de Kalman

No Capítulo 4 se fez um extensa análise do filtro de Kalman, em que, foram definidos o conjunto de parâmetros para configurar os modelos do sistema \mathbf{x} e de codificação \mathbf{z} que minimizaram o Erro Quadrático Médio (*EQM*) dos estados estimados, sendo estes: $50 \leq \Delta_t \leq 150$, o número de canais $C = 3$, $lag = 0$ ms e a frequência do sinal *EEG* $F = [8 - 16]$ correspondente a banda *alfa*. Para evitar a simplificação do movimento por causa do parâmetro Δ_t , escolheu-se um valor intermédio de 70 ms.

Todos os resultados aqui apresentados foram determinados através de uma validação cruzada de 6 *folds*.

6.1.1 Resposta do Filtro de Kalman

Na Figura 6.1 se apresenta um exemplo da estimação do estados \mathbf{x} com seus respectivos valores de *EQM* e Coeficiente de Correlação (*CC*) para dois voluntários, o resumo por voluntário encontra-se compilado na Tabela 6.1, onde se apresenta o *EQM*, *EQM* Médio, *CC* e $\|\mathbf{A}\|$.

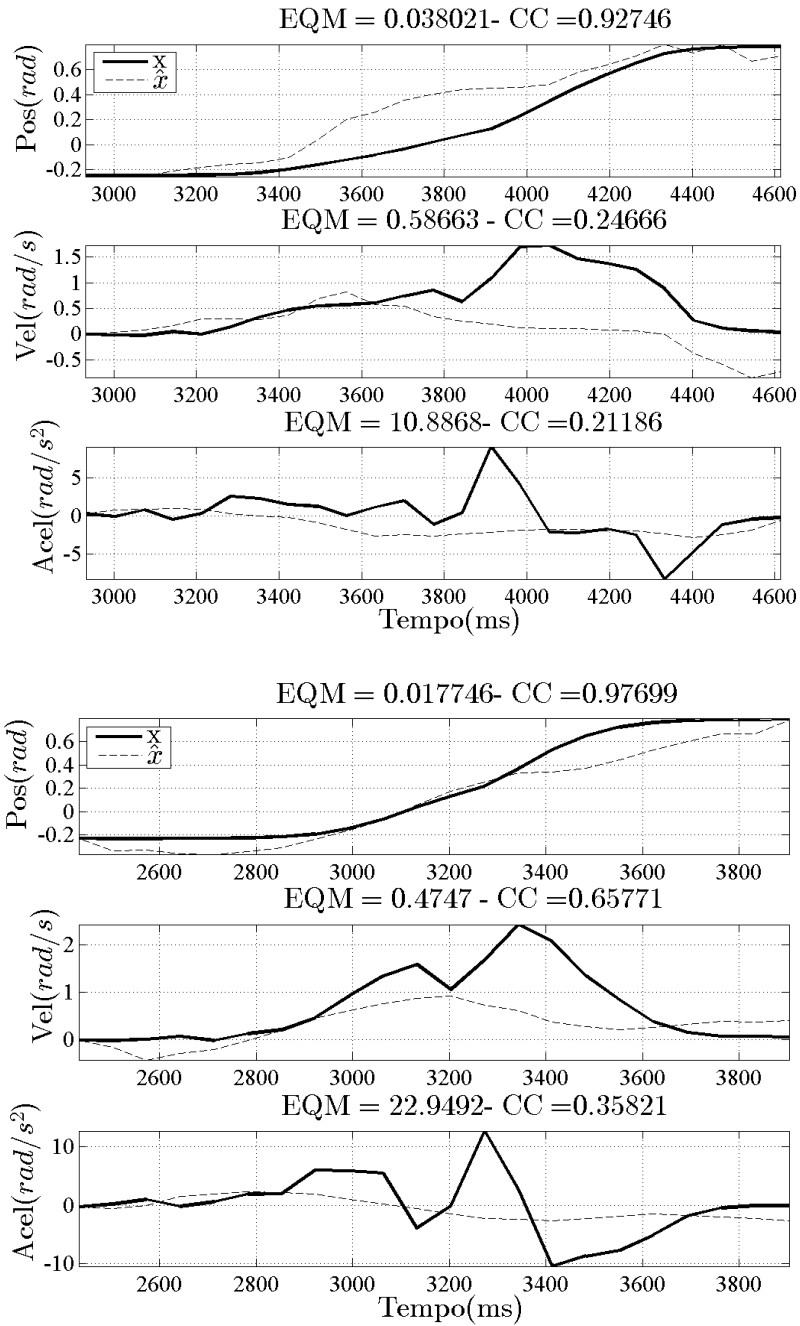


Figura 6.1: Decodificação do movimento ascendente, compara-se os estados estimados $\hat{\mathbf{x}}$, (linha a traços), em comparação com o estado ideal \mathbf{x} , (linha continua). Em cada figura se apresenta o respectivo Erro Quadrático Médio e Coeficiente de Correlação. Pode-se ver que o estado que representa a posição angular, tem o menor erro de estimação.

O processo de validação analisa um conjunto de estados não considerados durante o treinamento e aplica o conjunto de matrizes treinadas \mathbf{A} , \mathbf{H} , \mathbf{Q} e \mathbf{W} . A resposta é dependente da relação sinal *EEG*-estado que tem o conjunto de dados, de existir uma aproximação entre eles, o filtro poderá estimar uma trajetória equivalente à

Tabela 6.1: Resultado da Validação por voluntário durante movimentos ascendentes.

Voluntario		V_1	V_2	V_3	V_4	V_5	V_6
EQM	x_1	0,45	0,23	0,24	0,23	0,67	1,18
	x_2	2,33	1,22	1,69	1,17	2,31	10,41
	x_3	115,5	38,88	74,77	39,41	93,13	436,69
	μ	39,43	13,44	25,57	13,60	32,04	149,43
CC	x_1	0,56	0,53	0,51	0,75	0,54	0,33
	x_2	0,09	0,32	0,24	0,18	0,15	0,15
	x_3	-0,06	0,22	0,16	0,19	0,06	0,12
	μ	0,20	0,36	0,30	0,37	0,25	0,20
$\ A\$		4,5	2,5	3,59	2,18	3,31	12,35

informação cognitiva captada. Durante o processo de validação os estados desejados, apresentados no gráfico como a linha grossa, fornecem a condição inicial para k_0 , e são usados para estimar o *EQM* e o *CC*.

Durante a validação, a relação $\|A\|$ e *EQM*, conserva suas características lineais (Figura 6.2), destaca-se o resultado do voluntário 6, que apresentou um valor alto da norma durante o treinamento, em contraste, os estados estimados tem uma média do *EQM* por acima do 100, bem distante da media dos dados que está próxima aos 25.




Figura 6.2: Relação Norma de A e Erro Quadrático Médio durante movimentos de Ascenso, na medida que o voluntário treine matrizes com valores da norma altos, o resultado da sua estimativa decairá.

Em contraste são apresentados os resultados do movimento descendente, na figura 6.3 se apresenta um exemplo para a estimação dos estados em 2 voluntários, e

na tabela 6.2 se compila toda a informação relacionada ao experimento.




Figura 6.3: Descodificação do movimento descendente, compara-se os estados estimados $\hat{\mathbf{x}}$, (linha a traços) em comparação com o estado desejado \mathbf{x} , (linha grossa). Em cada figura se apresenta o respectivo Erro Quadrático Médio e Coeficiente de Correlação. Aqui os três movimentos apresentam uma aproximação maior em comparação ao caso ascendente.

Em comparação com os movimentos ascendentes, o descenso apresenta um EQM menor em todos os voluntários. Como tinha-se discutidos no capítulo 4, os movimen-

Tabela 6.2: Resultado da Validação por voluntário durante movimentos descendentes.

Voluntário		V_1	V_2	V_3	V_4	V_5	V_6
EQM	x_1	0,02	0,04	0,04	0,02	0,02	0,02
	x_2	0,34	0,25	0,12	0,3	0,25	0,24
	x_3	21,87	27,74	7,38	22,28	15,27	23,33
	μ	7,41	9,34	2,51	7,53	5,18	7,86
CC	x_1	0,97	0,98	0,98	0,97	0,98	0,98
	x_2	0,8	0,79	0,84	0,75	0,79	0,83
	x_3	0,65	0,54	0,5	0,49	0,57	0,58
	μ	0,81	0,77	0,77	0,74	0,78	0,80
$\ A\ $		8,9	9,4	3,87	7,66	6,74	8,84

tos descendentes apresentaram menor variação durante sua execução, assim a matriz treinada consegue se ajustar ao trials testados, apresentando estimativas próximas ao estado ideal. Na figura 6.4 se apresenta a relação entre $\|A\|$ e o *EQM* Médio, que continua sendo linear crescente, dado o tipo de movimento, a magnitude apresenta outras características sendo os valores ótimos de A distintos para o movimento descendentes.

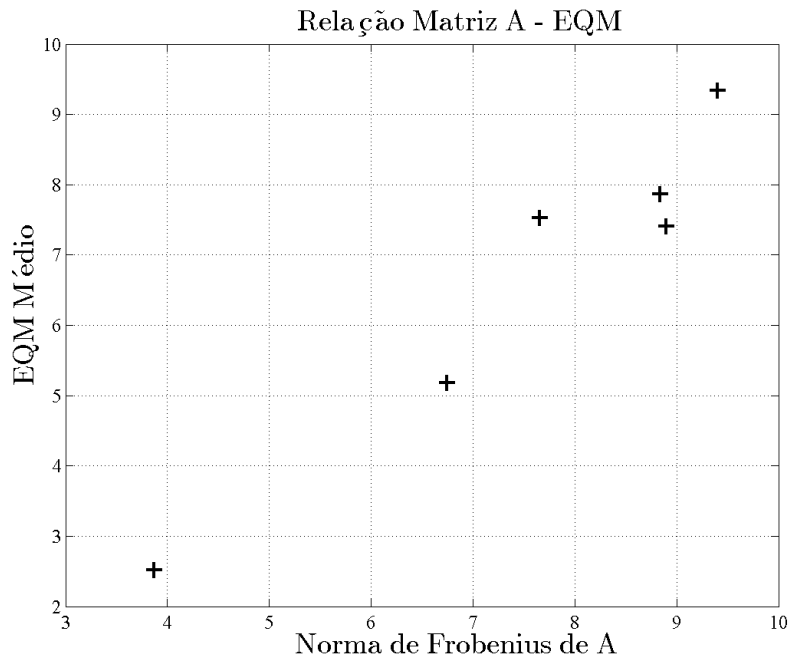


Figura 6.4: Relação Norma de A e Erro Quadrático Médio durante movimentos de Descenso, na medida que o voluntário treine matrizes com valores da norma altos, o resultado da sua estimativa decairá.

Um fator que não foi mencionado, é a variação da constante de Kalman K e a respectiva matriz de covariância do erro de estimação P . Durante o processo de estimação o valor da constante K muda aproximado-se a 0 se P também

aproxima-se a este valor. Na figura 6.5 se apresenta a evolução ao longo de um processo de estimação, a través da norma da diferencia de duas matrizes consecutivas ($\|K_{k+1} - K_k\|$, $\|P_{k+1} - P_k\|$). Segundo Wu et al., [97] para estimaciones de confianza estas matrizes devem ser estáveis, no gráfico pode-se ver o processo de estabilização para logo, permanecer constantes na medida que t_k aumenta. Em estimaciones onde não se consegue encontrar o valor desejado, tem-se oscilações permanentes desta norma, uma não convergência pode implicar que a matriz do ruido treinada \mathbf{R} não corresponde, ou se aproxima com o comportamento do sinal ao longo do trial validado [107].

6.1.2 Resposta do Filtro de Kalman para processos imaginários

Uma segunda experiencia, implementou o conjunto de sinais relacionadas com a imaginação do movimento. Dado que aqui não se tem sinais de movimento para treinar a matriz \mathbf{A} . Tem-se que estimar um conjunto de dados para que possam ser usado com o sinal *EEG* e a partir dai treinar todos os elementos que requiere o filtro para processo de estimação.

Desta forma um conjunto de movimentos ascendentes ao longo de todos dos voluntários que fizeram o experimento com sensor de movimento, sendo eles considerados para formar parte sempre que: $\|\mathbf{A}\| < 3$. As trajetórias selecionadas treinaram o modelo de $\mathbf{A}_{i.}$, logo usando-o junto com a atividade *EEG* relacionada foi treinada a matriz \mathbf{H} , \mathbf{Q} e \mathbf{R} .

Devido a dificuldade de estimar quando inicia ou termina o processo de imaginação ao longo dos trials, estimou-se um intervalo T_i médio para cada voluntário, em função dos movimentos reais efetuados durante o experimento, esperando que a ação efetuada durante a execução real do movimento seja replicada também durante a imaginação do mesmo. ¹.

Na figura 6.6 se apresenta os resultados desta nova estimação em 2 voluntários. Na tabela 6.3 se apresenta o resultados para todos os experimentos realizados

¹Durante o desenvolvimento destes experimento ainda não se contava com o sensor de movimento, porém não se tinha integrados às medições.

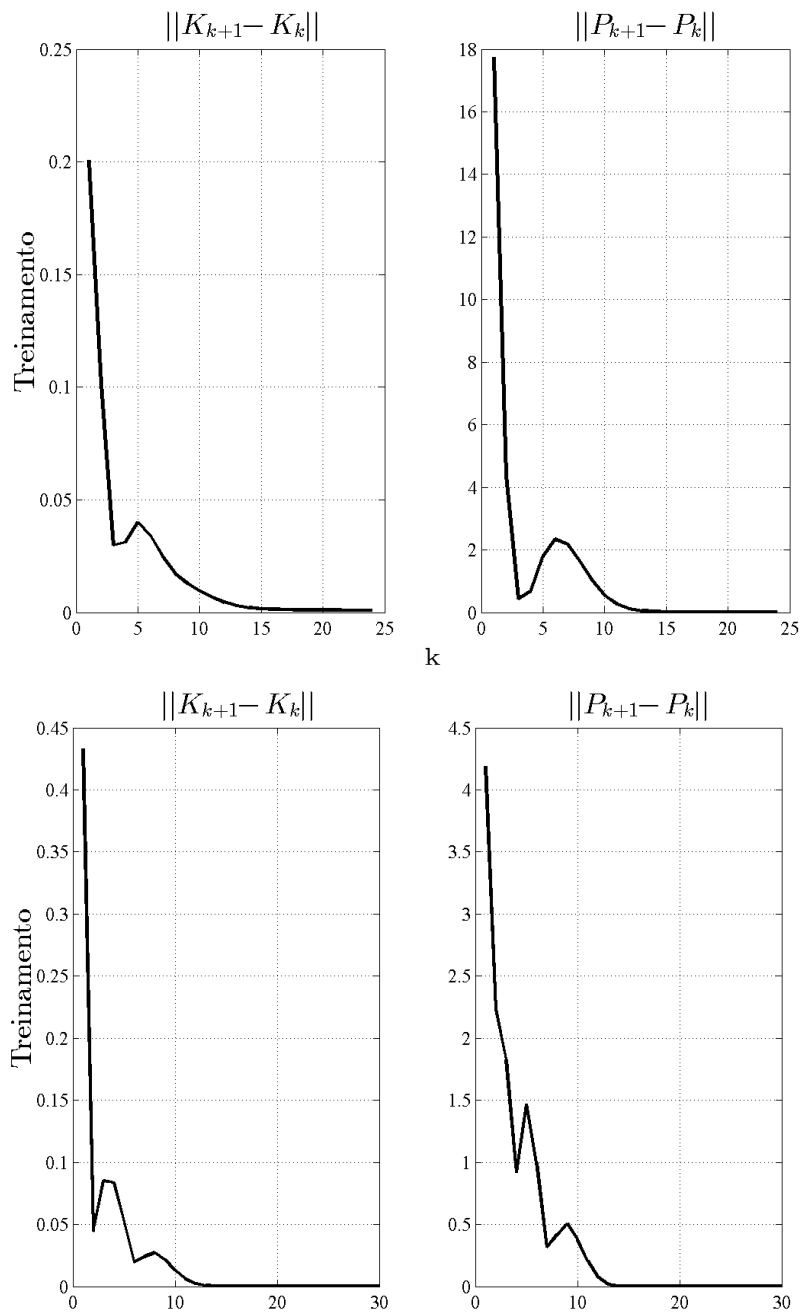


Figura 6.5: Exemplos de variação de $\|K_{k+1} - K_k\|$, $\|P_{k+1} - P_k\|$ durante a validação. Os dois casos apresentam distintas condições de estabilidade, onde ambas matrizes oscilam em função do erro de estimação para logo convergir.

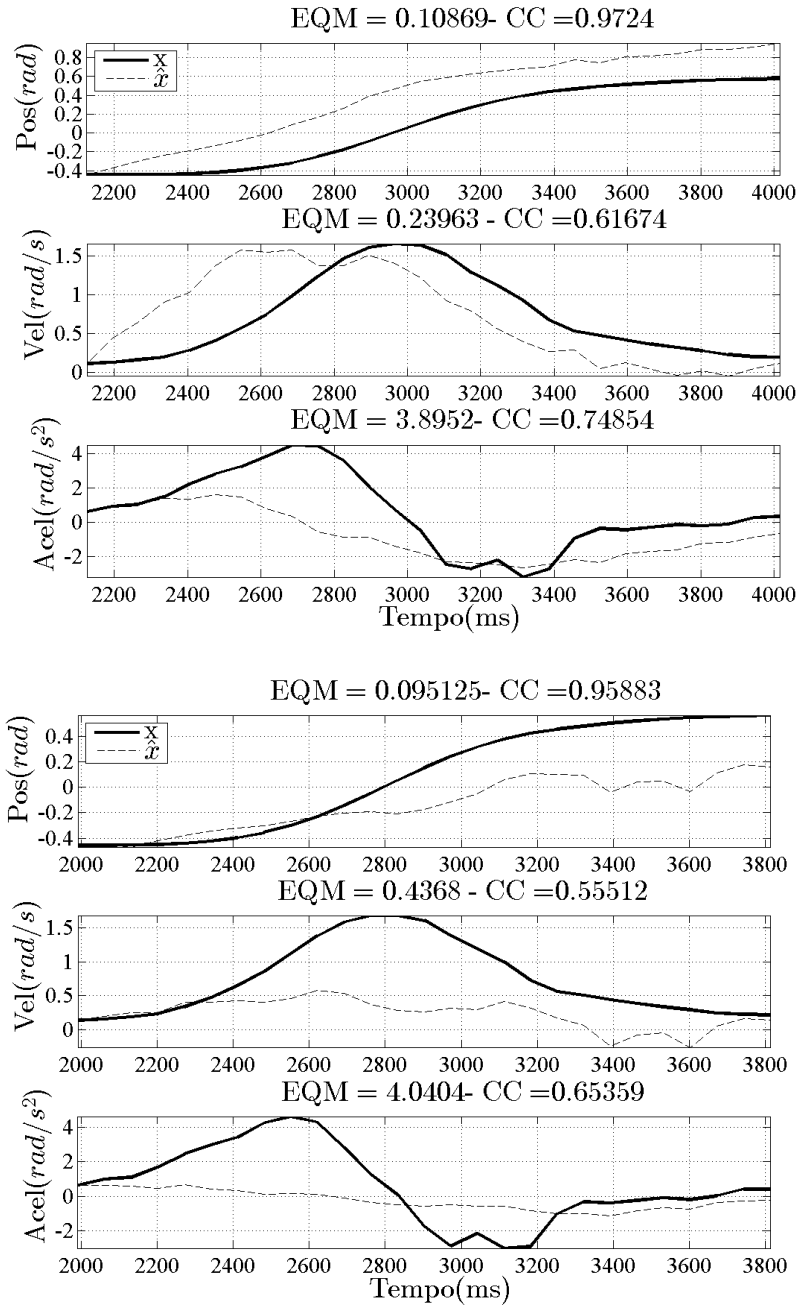


Figura 6.6: Decodificação do movimento ascendente imaginário, compara-se os estados estimados \hat{x} , (linha a traços) em comparação com o estado desejado x , (linha grossa). Em cada figura se apresenta o respectivo Erro Quadrático Médio e Coeficiente de Correlação. O seguimento da trajetória em função do pensamento imaginário é complexo dadas as diferenças do sinal EEG.

Encontramos que existem uma dificuldade de obter uma estimação de estados precisas tando do movimento real como do imaginário ($EQM \approx 0$). Os resultados em ambos casos são fortemente dependentes do conjunto de movimentos executados para treinar o modelo, e posteriormente, dependentes da variabilidade do sinal *EEG*. Encontrou-se por exemplo, que é possível minimizar o erro de estimação durante a

Tabela 6.3: Resultado da Validação por voluntário durante movimentos ascendentes imaginários.

Voluntário		V_1	V_2	V_3	V_4	V_5	V_6	V_7
EQM	x_1	0,1	0,22	0,17	0,28	0,36	0,19	0,12
	x_2	0,34	0,5	0,53	0,6	0,6	0,52	0,51
	x_3	4,71	5,2	4,56	4,63	4,61	5	4,79
	μ	1,72	1,97	1,75	1,84	1,86	1,90	1,81
CC	x_1	0,86	0,64	0,69	0,63	0,31	0,66	0,85
	x_2	0,5	0,37	0,38	0,3	0,18	0,35	0,31
	x_3	0,5	0,41	0,47	0,34	0,24	0,39	0,4
	μ	0,62	0,47	0,51	0,42	0,24	0,47	0,52
$\ \mathbf{A}\$		1,14	1,13	1,13	1,13	1,14	1,14	1,14

imaginação sempre e quando seja possível reduzir a variabilidade do movimento utilizado durante o treinamento do modelo. Mesmo assim, com a diminuição de $\|\mathbf{A}\|$ não foi suficiente para reduzir o valor do EQM e que o valor da trajetória decodificada se aproxime ao estado desejado.

6.2 Simulação da dinâmica do braço e controle

Para efetuar a simulação do modelo matemático, pode-se reescrever a equação 5.15 em um conjunto de equações em espaço de estados da forma:

$$\begin{aligned}\dot{x}_1 &= x_2 \\ \dot{x}_2 &= \ddot{q}\end{aligned}\tag{6.1}$$

Onde \ddot{q} é a equação da aceleração angular obtida a partir de 5.13 e cuja estrutura é igual a 5.29. Para integrar numericamente o sistema, um modelo *Runge-Kutta* de quarta ordem foi usado. Para cada passo do tempo $\Delta(t)$ é determinado o erro na posição e velocidade usando 5.27, se existir diferença o $\tau(t)$ é modificado.

Selecionando um valor para a frequência natural ω_n de 3 Hz [150] e ζ de 1, o controlador PID proposto:

$$\begin{aligned}P(s) &= (s^2 + 6s + 9)(s + 30) \\ P(s) &= s^3 + 36s^2 + 189s + 270\end{aligned}\tag{6.2}$$

A través da comparação com a equação 5.39 se podem determinar os valores para as constantes k_p , k_i e k_d .

$$\begin{aligned}k_p &= 189 \\ k_i &= 270 \\ k_d &= 36\end{aligned}\tag{6.3}$$




Figura 6.7: Controle do Braço em movimento ascendente e descendente.. A superposição das trajetórias real (linha pontilhada cinza) e desejada (preta contínua) da posição e velocidade se deve a atividade nula do controlador ao longo do movimento dado que a velocidade e posição inicial do sistema são coincidentes.

Numa primeira experiência se descrevem os valores dos momentos requeridos para efetuar movimentos de flexão e extensão apresentando na figura 5.6, sem modificar a posição e velocidade inicial, desta forma se espera que a ação de correção do controlador c seja aproximada a zero. Posteriormente, se modificará a posição inicial do sistema para verificar as ações corretivas do esquema de controle na posição angular da articulação de acordo com a trajetória de referência.

Os resultados da primeira experiência estão descritos nas figuras 6.7 e 6.8, onde se apresenta o comportamento da posição e velocidade respeito ao desejado. Um mínimo desvio se apresenta ao longo da trajetória sem deslocar o braço significativamente da posição. Entanto se pode apreciar uma correção do torque estimado respeito a entrada obtida com o *differential flatness*, possivelmente pelo ruído no sinal de referência. Um último gráfico, representa o conjunto braço-antebraço ilustrando o movimento do sistema 6.3. Nesta figura se integra o comportamento do modelo junto com o controlador ao longo do trajeto desejado.

O valor do momento requerido no motor é máximo quando inicia a elevação do braço, e se aproxima a 0 quando este se encontra na posição máxima (2.6 rad ou 150°). Para movimentos descendentes o torque requerido não ultrapassa o pico máximo, sendo menor na medida que se aproxima a posição de repouso de ($\pi/2$ rad ou 90°), nesta posição o motor se mantém energizado no sentido positivo para permitir ao braço se manter na posição.

Uma segunda experiência modificará as condições iniciais do sistemas, esta mu-




Figura 6.8: Descrição do erro de seguimento da trajetória, a ação de controle do controlador PID, permite um seguimento do trajeto desejado com o mínimo desvio.




Figura 6.9: Descrição do Movimento do braço num modelo de três dimensões.




Figura 6.10: Controle da posição respeito a trajetória ascendente. A ação corretiva do controlador aproxima a posição do sistema à trajetória desejada, as configurações do controlador PID definem o tempo de correção.

dança forçara ao controlador a desenvolver uma ação corretiva às entradas do Sistema. Os resultados para situações de movimento ascendente e descendente são apresentados nas figuras 6.10 e 6.11 respectivamente.

No movimento ascendente a posição inicial do sistema é menor que a desejada, a ação de controle faz ao motor aumentar sua velocidade angular e recuperar assim a posição desejada, para posteriormente estabilizar-se na trajetória 2 segundos após iniciar o movimento. O aumento da velocidade levou a aumentar o torque, porém, é incrementada a energia consumida pelo motor (Figura 6.12), o que pode ser indesejado se os requerimentos energéticos do movimento ultrapassam as capacidades técnicas do atuador.

Na Figura 6.12 se apresenta o comportamento da tensão e corrente aplicadas no motor nos primeiros 100 ms da simulação, a ação corretiva do controle gera um sobre impulso na entrada que ultrapassa as capacidades físicas do motor dado que a tensão máxima que se pode aplicar nele é de 24 Volts. Isto pode ser corrigido de duas formas, adicionando um saturador na entrada do motor, ou reduzindo o valor de ω_n do controlador (Figura 6.13), com o resultante de retardar a correção do movimento. Estes parâmetros de configuração de controlador se devem considerar no momento de definir a melhor constate para o sistema numa aplicação real.

6.2.1 Observações

A aplicação do controlador com comportamento de amortecimento crítico limita a aparição de oscilações durante a correção da posição. O controlador conseguiu corri-




Figura 6.11: Correção da posição de acordo com a ação de controle. Se apresenta um overshoot entre os 500 e 1000 ms, como produto da ação integral do modelo. O controlador corrige a posição do braço em aproximadamente 2 segundos.




Figura 6.12: Entrada de corrente e tensão na armadura do motor. Ação de controle leva a que a entrada requerida no modelo ultrapasse as capacidades técnicas do dispositivo.

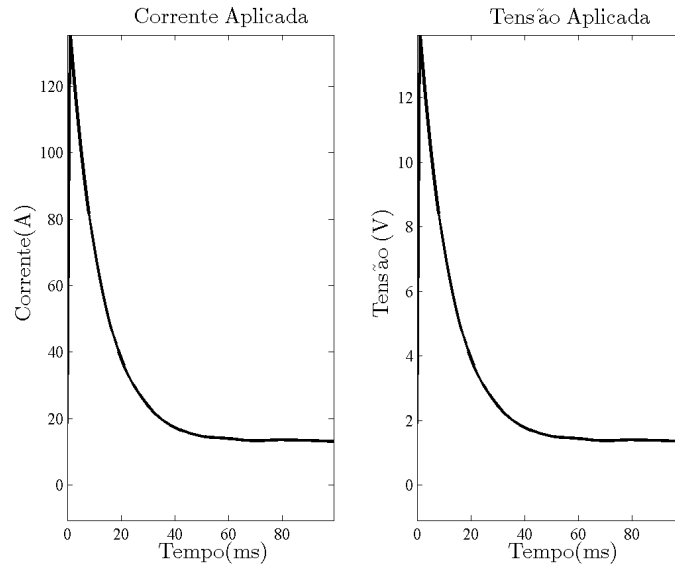


Figura 6.13: Entrada de corrente e tensão na armadura do motor com $\omega_n = 1.5$.

gir as variações do erro, contudo as limitações técnicas do sistema de accionamento e o tipo de aplicação não permite a aparição de respostas rápidas durante a correção. Por outro lado, os ganhos apresentados no teste unicamente são úteis para uma mesma configuração do sistema, alturas maiores ou menores de pacientes impõem a determinação de outro valor para estas constantes.

6.3 Integração Filtro de Kalman e a Dinâmica

Usando a configuração do sistema compensatório descrito na Figura 5.11 do Capítulo 5 estudou-se a integração do Filtro de Kalman com o Sistema Dinâmico do Braço para movimentos ascendentes e descendentes usando como parâmetro de validação $\Delta_t = [1 - 30 - 70 - 100 - 150]$, referente ao tempo de amostragem ente pontos. Sinais *EEG* relacionadas com atividade cognitiva associada a trials de movimento e imaginação foram usadas para validar o comportamento do filtro.

O teste foi efetuado através de uma validação cruzada de 6 *Folds* de 10 trials cada um, para 6 voluntários em movimentos reais e 7 em imaginários. As matrizes **A**, **H**, **Q** e **R** foram treinadas e validadas em cada iteração, de forma que todos os trials de cada voluntário fossem testados. O controle do movimento foi efetuado durante a etapa de validação, um erro de seguimento médio foi estimado para testar o comportamento do controlador.

O filtro de Kalman foi configurado com um *Lag* de 0 ms, três canais $c = 3$, e sinal EEG filtrada na banda alfa [8 – 16] Hz. Tanto o sistema dinâmico do laço compensado como o sistema dinâmico do laço de referência foram integrados numericamente usando *Runge Kutta* de quarta ordem usando um $\tau = \Delta_t$ com passo $\Delta_t/10$,

entretanto o valor da frequência natural ω_n oscilou entre 1.5 até 7, incrementando-se conforme aumentava o passo para garantir um seguimento apropriado da trajetória de referência \mathbf{y} . Estes valores foram determinados de forma heurística.

6.3.1 Movimentos Ascendentes Reais

Durante o movimentos ascendentes reais encontrou-se uma redução significativa da decodificação do movimento por causa da variabilidade do movimento durante o teste. Na figura 6.14 se apresenta o comportamento do filtro (esquerda) e do sistema de compensação em tempo real (direita) para cada amostra k usada com um $\Delta_t = 1$ ms.

Na figura se apresenta ao lado esquerdo o resultado da decodificação da posição, velocidade e aceleração durante um dos trials para o primeiro voluntário. Este sinal resultante do treinamento do modelo do sistema e de medição é comparada com o sinal real. No capítulo 4 encontrou-se que a resposta do filtro é dependente do valor do passo da amostragem do sinal, sendo que os passo pequenos resultaram em valores de estimação com um alto *EQM*. A entrada estimada \hat{u}_k resultado do uso do modelo plano é apresentada na parte inferior das figuras da esquerda.

Entanto que na figura esquerda são apresentados os resultados da dinâmica do modelo para o mesmo trial, usando como entrada o sinal estimada $\hat{\mathbf{x}}$ e como sinal de referência o comportamento do sistema tendo como entrada o sinal real \mathbf{x} . O compensador compara o resultado esperado \mathbf{y} contra o resultado associado $\tilde{\mathbf{y}}$ e a ação corretiva associada à diferença entre magnitudes compensa o valor da entrada estimada. As magnitudes comparadas pelo controlador são a posição angular do cotovelo $x_1 = q$ e a velocidade angular $x_2 = \dot{q}$, ao longo de um intervalo de tempo $T = [1, \dots, k]$, sendo o valor de k dependente do parâmetro Δ_t .

A ação de correção do controlador modifica o valor de \hat{u}_{k+1} em função da diferença existente entre a resposta do sistema dinâmico ou saída associada \tilde{y}_k e a saída de referência y_k em cada intervalo de tempo k desde $k = 1$. Para o tempo $k = 0$ as condições iniciais do integrador numérico e filtro de kalman são as mesmas do valor real $\hat{\mathbf{x}}_0 = \mathbf{x}_0$ [107].

O comportamento do sistema após a correção da entrada é apresentado como uma linha pontilhada cujo erro de seguimento foi de 0,0008 *radianos* para a posição é 0,2 (*rad/seg*) para a velocidade angular. A ação corretiva do controlador permitiu ao sistema acompanhar a trajetória de referência, com um baixo erro de seguimento respeito a posição angular com leves alterações da velocidade do braço. Entretanto as diferenças entre o torque estimado e corrigido indicam que o controlador teve que modificar permanentemente o valor da entrada para garantir um seguimento aproximado.

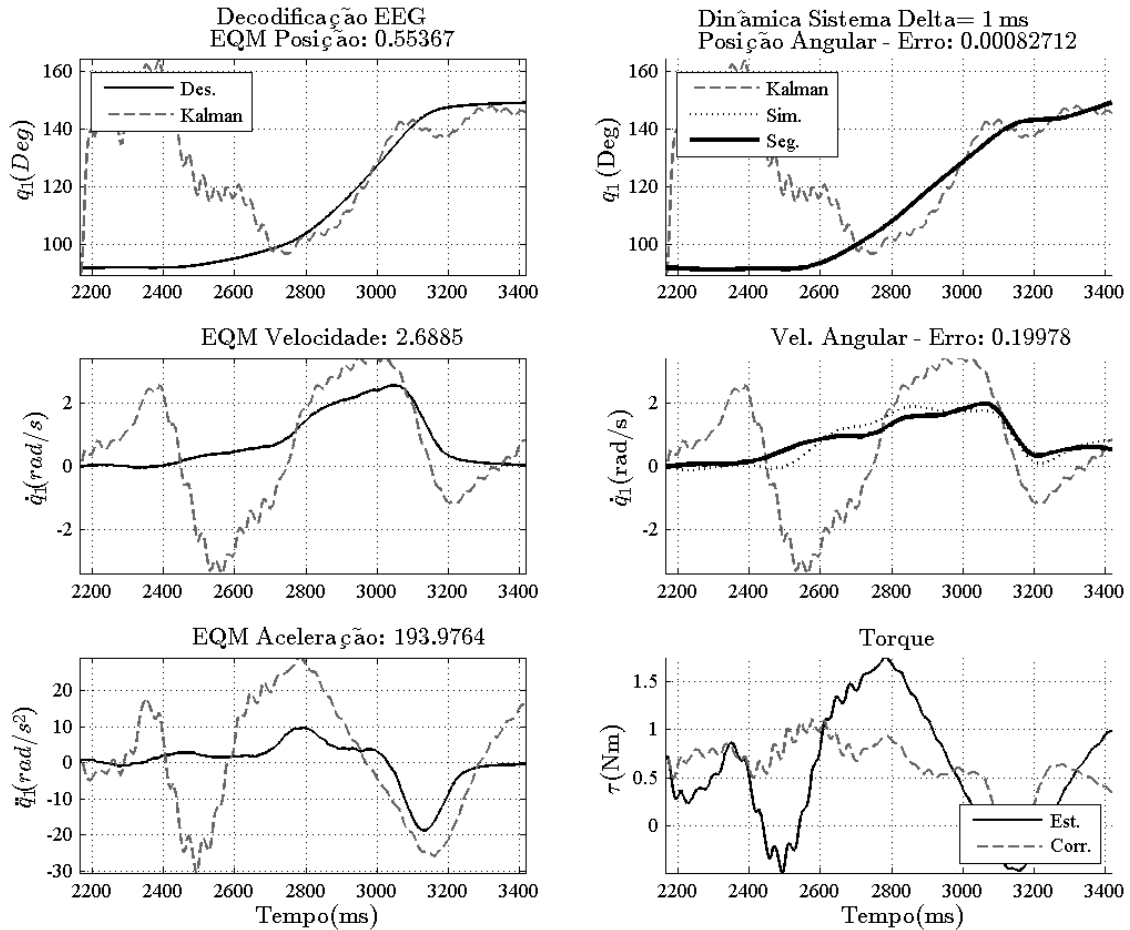


Figura 6.14: Decodificação estados do braço e seguimento do movimento para um $\Delta_t = 1$ ms. As figuras da parte esquerda apresentam a variável desejada (preta) e estimada (cinza) usando o filtro de Kalman. As figuras da parte direita descrevem o comportamento do sistema dinâmico (preta pontilhada) usando como sinal de referência a trajetória de seguimento (preta grossa). A linhas cinzas descrevem o estado estimado \hat{x}_k usada para calcular a entrada estimada \hat{u}_k (preta), descrita na terceira figura à direita, a correção da entrada é descrita na mesma figura (cinza a traços).

Na Figura 6.15 se apresenta o resultado da estimação para o mesmo voluntário usando um $\Delta_t = 150$ ms. Esta figura tem a mesma organização que a prévia.

Tendo-se diminuído a amostragem do sinal, encontrasse com um movimento caracterizado por uma menor resolução. Em consequência, o erro de estimação do movimento diminuiu, mas o erro de seguimento da trajetória aumentou, levando a um sistema com um comportamento menos preciso respeito a trajetória de seguimento.

Esta variabilidade em função do parâmetro de configuração Δ_t é apresentado na figura 6.16.

Nesta Figura descreve-se que o incremento do parâmetro de configuração Δ_t leva a aumentar o erro de seguimento na posição e velocidade ao longo dos seis voluntário, ao mesmo tempo que consegue diminuir o erro de estimação do estado. Os erros dada a diferença de magnitudes se encontram normalizados. Ambos controladores, apresentam um comportamento similar ao longo do estudo. Um teste de equivalência *t-student*, usado para pequenas amostras, [151] comparou a média de ambas distribuições, encontrando que, o comportamento dos controladores não teve diferenças significativas entre eles, o teste foi corrido com um nível de significância $\alpha = 0,05$ e teve um *p-value* de 0,99.

As duas curvas tiveram um ponto coincidente em $\Delta_t = 30$ ms, posterior a esta, o erro de seguimento tende a aumentar entanto o erro de estimação a decair. Para um $\Delta_t = 1$ ms, os controladores apresentaram o menor erro de seguimento, sendo este o melhor parâmetro de configuração para esta parte do laço. Na figura 6.17 se apresenta o valor do erro de seguimento durante a posição para os dois controladores sem aplicar a normalização.

Finalmente se apresenta o valor da energia média dos seis voluntários usada pelo controlador para compensar a entrada ao sistema dinâmico. A curva é calculada como a potência em wátios (W) da diferencia entre o sinal de entrada estimado e o corregido, sendo esta uma medição da ação corretiva efetuada pelo controlador para efetuar o seguimento da trajetória.

Na medida que a diferença entre a variável estimada e a desejada diminui, por efeito do aumento do parâmetro Δ_t a ação de correção efetuada pelos controladores tende a decair. Portanto, a eficiência do sistema de estimação e seguimento é fortemente dependente do sinal estimado, levando a que, decodificações menos precisas requeiram por parte do controlador de maiores ações corretivas.

6.3.2 Movimentos Descendentes Reais

Na figura 6.19 se apresenta um exemplo de estimação para o movimento descendente. O comportamento do controle não variou respeito aos movimentos ascendentes. A

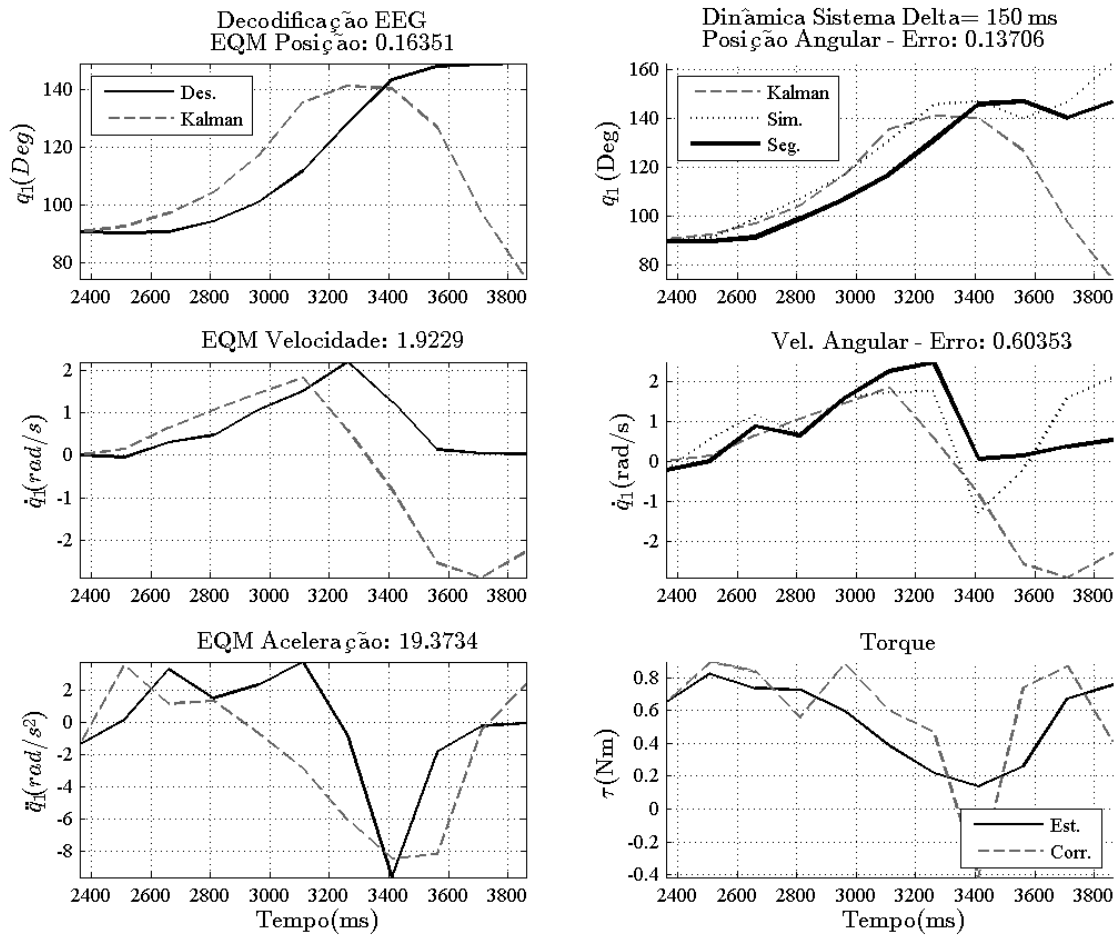


Figura 6.15: Decodificação estados do braço e seguimento do movimento para um $\Delta_t = 150\text{ms}$. As figuras da parte esquerda apresentam a variável desejada (preta) e estimada (cinza) usando o filtro de Kalman. As figuras da parte direita descrevem o comportamento do sistema dinâmico (preta pontilhada) usando como sinal de referência a trajetória de seguimento (preta grossa). A curva cinza descrevem o estado estimado \hat{x}_k usada para calcular a entrada estimada \hat{u}_k (preta), descrita na terceira figura a direita, a correção da entrada é descrita na mesma figura (cinza a traços).




Figura 6.16: Erros de estimação e seguimento da trajetória respeito ao parâmetro de configuração Δ_t nos 6 voluntários. A linha preta descreve o erro de estimação normalizado produto do filtro de Kalman. Linhas a traços descrevem o comportamento do seguimento da trajetória usando como controlador um sistema PID (quadro) e PD (diamante). As linhas de variação descrevem a variação ao longo dos 6 voluntários para cada parâmetro.




Figura 6.17: Erro de Seguimento da posição em função de Δ_t . A gráfica compara a posição angular do braço usando um controle PD e PID. A diferença da ação de controle para os dois casos é mínima.




Figura 6.18: Ação corretiva Média em Watios dos Controladores. A linha contínua descreve a variação da diferença entre a estrada estimada e a corrigida para o controlador PD e a pontilhada para o controlador PID.

diferença aqui, está relacionada com a maior precisão do estado estimado dada a menor variabilidade destes movimentos ao longo de todos os voluntários.

Os resultados descritos na figura permitem detalhar a diferença entre a variável estimada e a corrigida, no caso da velocidade angular por exemplo, o controle consegue aumentar a velocidade do movimento em relação com prevista a través da variável estimada, isto permite que o movimento apresente um decaimento mais rápido aproximando-se à posição final desejada.

Na figura 6.20 são apresentas as curvas de estimação e seguimento para movimentos descendentes ao longo de todos os voluntários.

A curva não apresenta diferenças respeito aos movimentos ascendentes dada a normalização dos valores, o parâmetro $\Delta_t = 30$ ms apresenta-se também como o termo médio de configuração do sistema. A variação das curvas de controle PD e PID são similares de acordo com teste de significância com um *p-value* de 0.99. Em relação a magnitude da diferença em radianos na Figura 6.21 se apresenta os erros de seguimento para os controladores PD e PID em função do parâmetro Δ_t .

O erro de seguimento em comparação com os movimentos descendentes foi menor, com uma desviação máxima de 9 graus. Para validar a ação corretiva do controlador também foi avaliada a potência Média da diferencia entre o sinal estimado de entrada e o corrigido (Figura 6.22). Aqui apresentaram-se valores de menor magnitude em comparação com o movimento descendente, esta diminuição esta relacionada com o melhoramento na estimação dos estados do movimento, que leva a uma menor

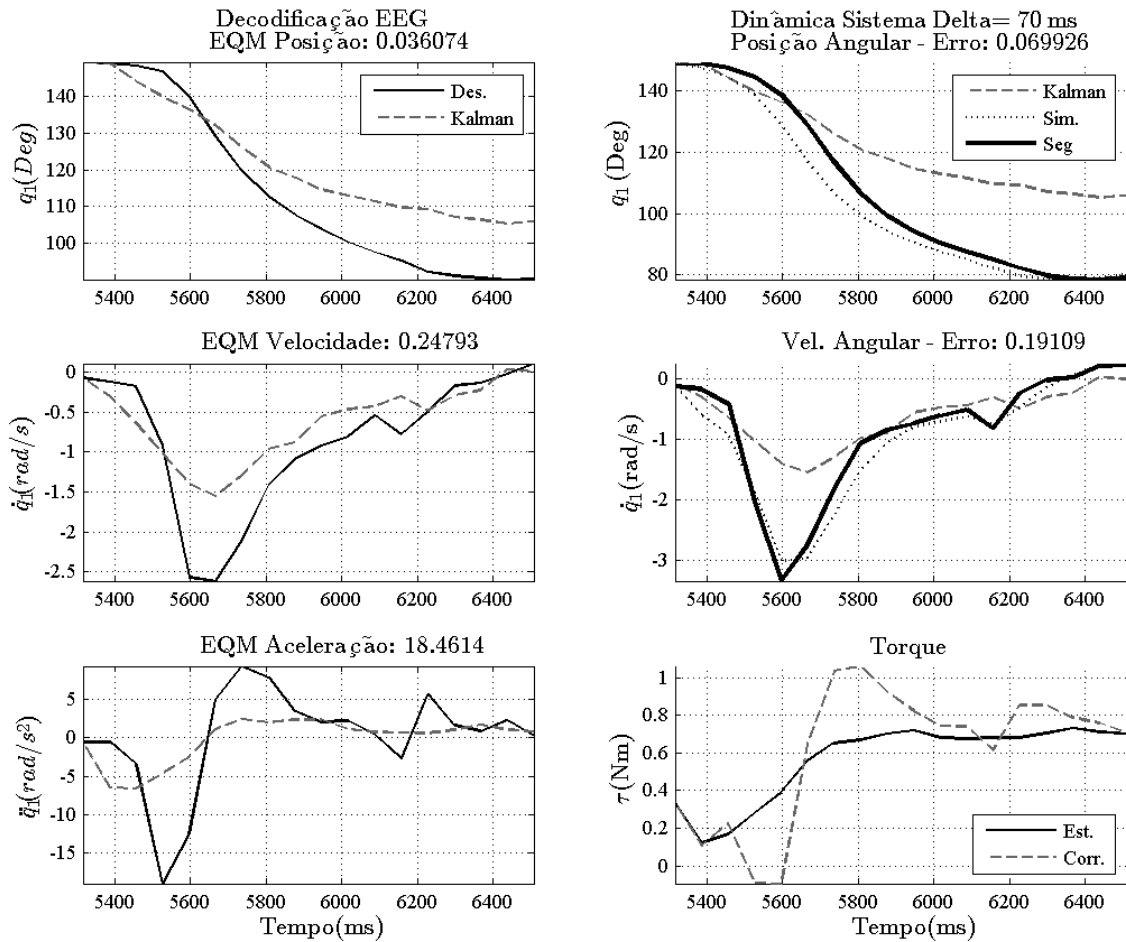


Figura 6.19: Decodificação estados do braço e seguimento do movimento descendente para um $\Delta_t = 70\text{ms}$. As figuras da parte esquerda apresentam a variável desejada (preta) e estimada (cinza) usando o filtro de Kalman. As figuras da parte direita descrevem o comportamento do sistema dinâmico (preta pontilhada) usando como sinal de referência a trajetória de seguimento (preta grossa). A curva cinza descrevem o estado estimado \hat{x}_k usada para calcular a entrada estimada \hat{u}_k (preta), descrita na terceira figura a direita, a correção da entrada é descrita na mesma figura (cinza a traços).




Figura 6.20: Erros de estimação e seguimento da trajetória descendente respeito ao parâmetro de configuração Δ_t nos 6 voluntários. A linha preta descreve o erro de estimação normalizado produto do filtro de Kalman. Linhas a traços descrevem o comportamento do seguimento da trajetória usando como controlador um sistema PID (quadro) e PD (diamante). As linhas de variação descrevem a variação ao longo dos 6 voluntários para cada parâmetro.




Figura 6.21: Erro de Seguimento do movimento descendente em função de Δ_t . A gráfica compara a posição angular do braço usando um controle PD e PID. A diferença da ação de controle para os dois casos é mínima.




Figura 6.22: Ação corretiva Média em Vátios dos Controladores para movimentos descendentes. A linha contínua descreve a variação da diferença entre a estrada estimada e a corregida para o controlador PD e a pontilhada para o controlador PID.

correção da entrada estimada por parte do sistema compensatório.

6.3.3 Movimentos ascendentes imaginários

Avaliou-se o seguimento de trajetórias estimadas a partir de sinas EEG provenientes de *trials* de imaginação motora de 7 voluntários. Os parâmetros de configuração se conservaram equivalentes aos apresentados nos movimentos ascendentes. Aqui a trajetória usada para treinar o filtro e ser referência ao movimento esperado foi construída a partir de aqueles movimentos que apresentaram $\|\mathbf{A}\| < 3$.

Na Figura 6.23 se apresenta um exemplo da estimação e controle do movimento ascendente ativado a partir de imaginação motora.

Consegue-se corrigir o movimento estimado integrando-se a compensação do movimento. Como se pode ver a estimação do movimento não é aproximada e requere acompanhar a trajetória estimada atingir um movimento aceitável dentro de espaço de trabalho da junta. A capacidade de decodificação encontra-se dependente dos movimentos usados para treinar o filtro, contudo, apresentando um melhoramento do resultado médio, a aproximação em vários trials não é precisa, causando uma sinal oscilatória que requere de uma alta contribuição do compensador para aproximar o movimento ao esperado.

Na Figura 6.24 se apresenta a variação do erro de seguimento e decodificação

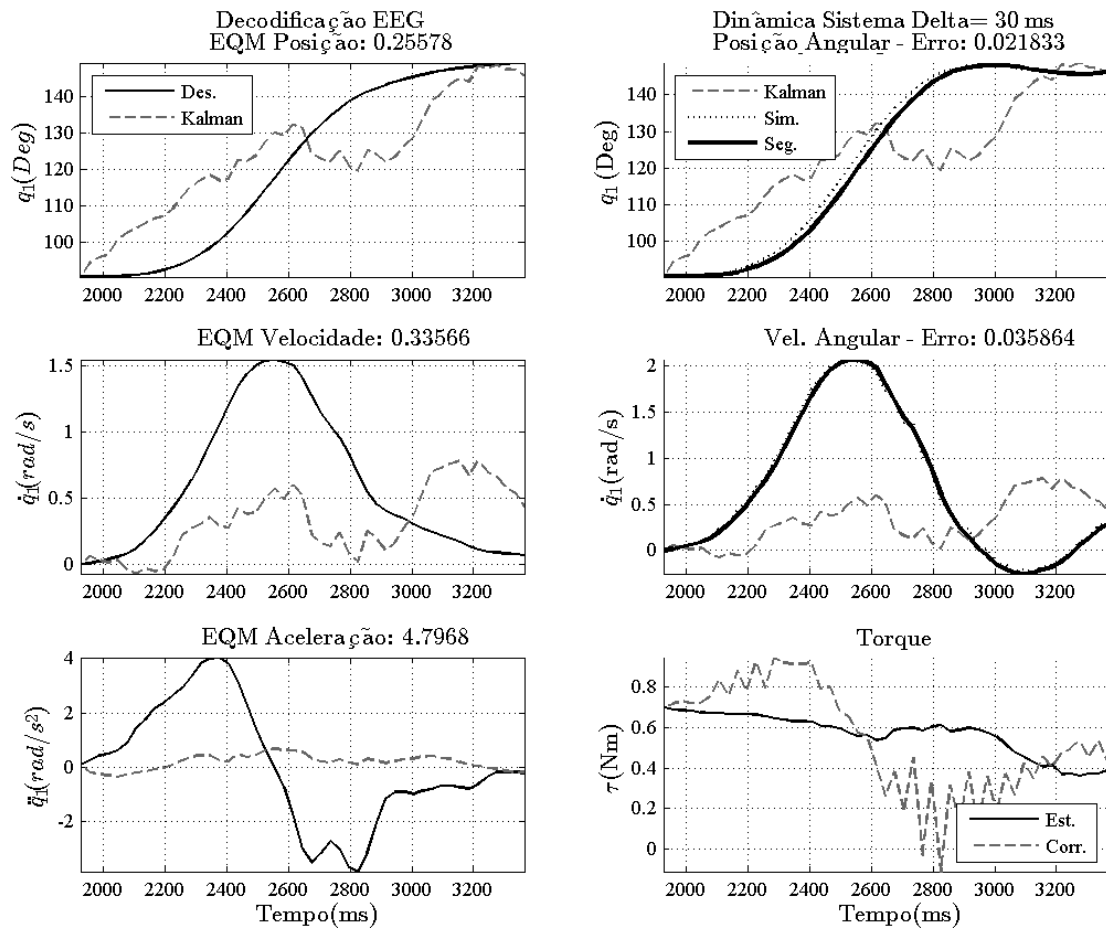


Figura 6.23: Decodificação estados do braço e seguimento do movimento ascendente imaginário para um $\Delta_t = 70\text{ms}$. As figuras da parte esquerda apresentam a variável desejada (preta) e estimada (cinza) usando o filtro de Kalman. As figuras da parte direita descrevem o comportamento do sistema dinâmico (preta pontilhada) usando como sinal de referência a trajetória de seguimento (preta grossa). A curva cinza descrevem o estado estimado \hat{x}_k usada para calcular a entrada estimada \hat{u}_k (preta), descrita na terceira figura a direita, a correção da entrada é descrita na mesma figura (cinza a traços).




Figura 6.24: Erros de estimação e seguimento da trajetória ascendente imaginária respeito ao parâmetro de configuração Δ_t nos 7 voluntários. A linha preta descreve o erro de estimação normalizado produto do filtro de Kalman. Linhas a traços descrevem o comportamento do seguimento da trajetória usando como controlador um sistema PID (quadro) e PD (diamante). As linhas de variação descrevem a variação ao longo dos 6 voluntários para cada parâmetro.

de acordo ao parâmetro Δ_t . A variação do erro não apresentou diferenças com as respectivas versões do movimento real.

O erro de seguimento da trajetória de referência de acordo ao controlador é apresentado na figura 6.25. Não se apresentam diferenças significativas com a curva associada a movimentos reais.

Entanto que ao verificar a contribuição do controlador (Figura 6.26) apresta-se uma mudança na variação, apresentando um aumento crescente da energia para $\Delta_t > 30$ ms, contudo, a energia usada foi menor, esta diminuição da potência da correção é causada pela restrição de movimentos.

6.3.4 Movimentos descendentes imaginários

Na Figura 6.27 se apresenta a variação do erro de estimação e de seguimento em função do parâmetro de configuração Δ_t . A relação entre ambos erros é similar as apresentadas previamente.

O erro de seguimento da trajetória de referência de acordo ao controlador ao longo dos 7 voluntários é apresentado na figura 6.28. A variação do descenso foi similar ao ascenso imaginário.

Finalmente na Figura 6.29 é apresentada a medição do aporte do controlador. Aqui, mesmo o aporte seja menor aos efetuados em ações reais, encontra-se com um




Figura 6.25: Erro de Seguimento do movimento descendente imaginário em função de Δ_t . A gráfica compara a posição angular do braço usando um controle PD e PID. A diferença da ação de controle para os dois casos é mínima.




Figura 6.26: Ação corretiva Média em Vátios dos Controladores para movimentos imaginários ascendentes. A linha contínua descreve a variação da diferença entre a estrada estimada e a corrigida para o controlador PD e a pontilhada para o controlador PID.




Figura 6.27: Erros de estimação e seguimento da trajetória descendente imaginaria respeito ao parâmetro de configuração Δ_t nos 7 voluntários. A linha preta descreve o erro de estimação normalizado produto do filtro de Kalman. Linhas a traços descrevem o comportamento do seguimento da trajetória usando como controlador um sistema PID (quadro) e PD (diamante). As linhas de variação descrevem a variação ao longo dos 6 voluntários para cada parâmetro.




Figura 6.28: Erro de Seguimento do movimento descendente imaginário em função de Δ_t . A gráfica compara a posição angular do braço usando um controle PD e PID. A diferença da ação de controle para os dois casos é minima.




Figura 6.29: Ação corretiva Média em Wátios dos Controladores para movimentos descendentes imaginários. A linha contínua descreve a variação da diferença entre a estrada estimada e a corrigida para o controlador PD e a pontilhada para o controlador PID.

aumento da ação corretiva para $\Delta_t > 70$ ms.

Todos os movimentos ao longo dos 6 voluntários guardam similitude em seu comportamento, tanto de forma ascendente como descende. O erro de seguimento aumenta na media que o valor de Δ_t é incrementado guardando suas respectivas diferenças respeito a magnitude do erro que é menor durante a imaginação. Ao contrastar as curvas de erro de seguimento com o de decodificação foi encontrado um ponto intermédio $\Delta_t = 30$, que pode ser usado como referência para sincronizar o comportamento de ambas etapas. Na figura 6.30 se apresenta a distribuição do erro de seguimento usando este parâmetro para movimentos ascendentes e descendentes reais ao longo dos seis voluntários usando controle *PID*.

O controlador consegue ajustar a trajetória do movimento com um baixo erro de seguimento em todos os voluntários, indicando que a integração entre o filtro e o controlador consegue com sucesso compensar os erros de decodificação da variável estimada e levar ao braço com uma relativa boa precisão ($e \approx 0$) radianos. Entretanto para a velocidade, mesmo que o algoritmo conseguia alterar a aceleração do movimento, existem diferenças entre os movimentos executados com uma média de variação menor a um $1rad/seg$, velocidade que tem que ser revisada para verificar si estas diferenças podem ser seguras para funções assistivas.

Pode-se também ajustar o controlador de forma que não seja usada uma trajetória de referência, usando a mesma informação decodificada como referência, nesse caso toda a ação de movimentação depende do filtro de kalman. O sistema teria uma configuração similar á vista na figura 5.8. Um exemplo do comportamento do




Figura 6.30: Distribuição do erro de seguimento para movimentos ascendentes (esquerda) e descendentes (direita) usando $\Delta_t = 30$ ms ao longo dos 6 voluntários.

movimento é exposto na Figura 6.31.

Neste tipo de montagens dado que o movimento é dependente da variável estimada, é recomendável usar valores do parâmetro $\Delta_t > 70$. Certamente, foi visto que o erro de seguimento respeito parâmetros desta magnitude tendem a aumentar, entanto que para o filtro a decodificação tem maiores probabilidades de estimar um movimento com EQM baixo, assim, também e mais possível que o movimento desenvolvido pelo braço seja próximo ao desejado ou pelo menos tenha um desvio menor. Contudo, ao depender totalmente do sinal EEG para controlar o movimento, o comportamento geral do sistema tende a ser incerto (Figura 6.32), e necessariamente se deverá requerer de mais elementos dentro do laço de controle, para impedir que o movimento se aproxime a valores não desejados, como um saturador por exemplo.

6.3.5 Desempenho Classificador

O sistema BCI inclui um segmento de classificação que valida os intervalos do sinal EEG dividido pela ação do parâmetro Δ_t para determinar se o sinal corresponde ao processamento do movimento ou não.

O classificador analisado no Capítulo 3, foi validado para cada parâmetro $\Delta_t > 1$ ms, durante o controle de movimentos ascendentes e descendentes. A matriz de Autovetores \mathbf{W} da fase de redução dimensional e o vetor de coeficientes \mathbf{w} da fase de classificação foram treinados em cada *fold* da validação cruzada, usando EEG provenientes de exemplos de movimento e não movimento. Foram considerados como parâmetros de configuração um total de $c = 34$ canais e um coeficiente de regularização $C = 1$, procurando a maior discriminação entre as classes com a maior generalização possível, caso não se tenha alta separação entre dados. Os atributos

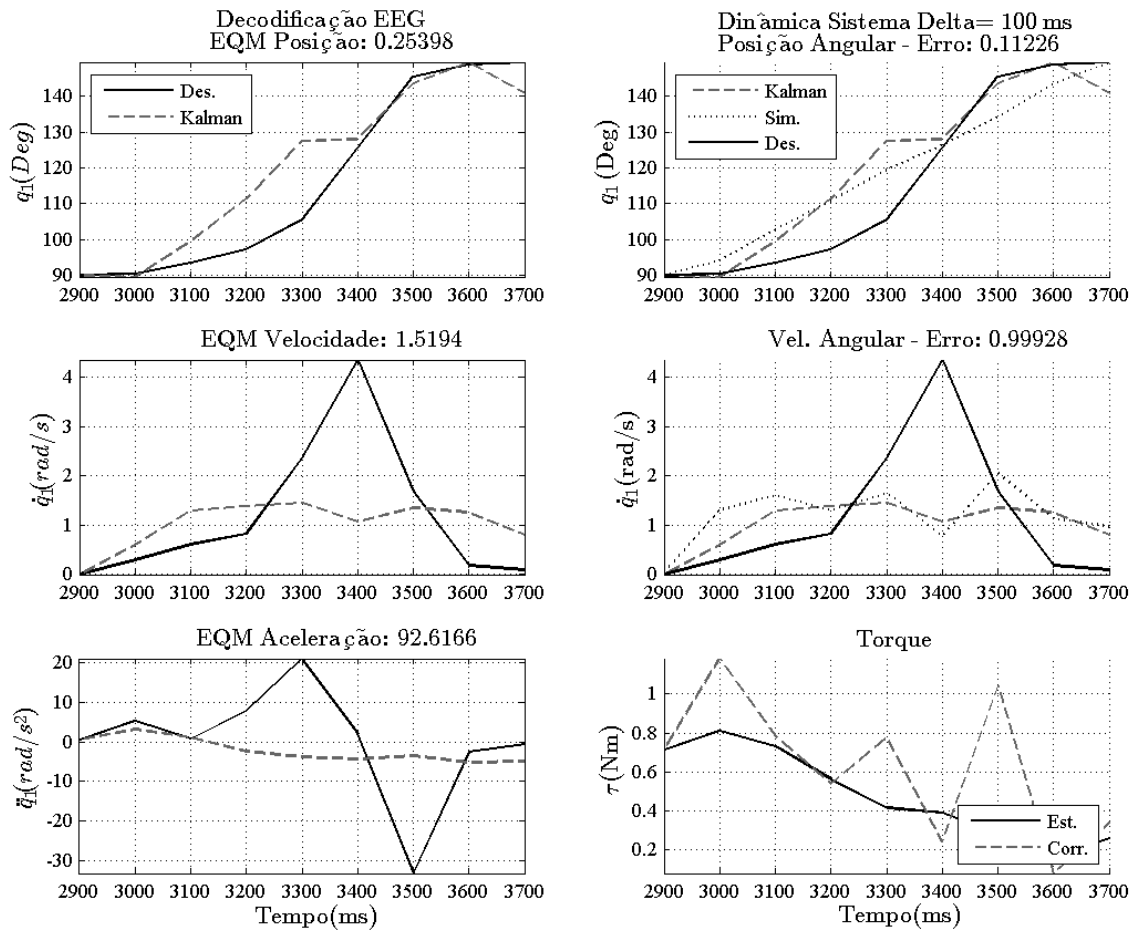


Figura 6.31: Seguimento de uma trajetória puramente decodificada. Na figura é comparado o movimento desejado com o estimado durante um trial. As figuras da direita comparam a trajetória desejada junto com a estimada e a efetuada pelo controlador.




Figura 6.32: Distribuição do erro do movimento para movimentos ascendentes (esquerda) e descendentes (direita) usando $\Delta_t = 100$ ms ao longo dos 6 voluntários. As medições foram realizadas comparando o sinal de movimento efetuada com a trajetória real.

usados para cada voluntário foram selecionados de acordo com a informação encontrada no capítulo 3, portanto cada conjunto de exemplos foi configurado de acordo aos melhores parâmetros de cada indivíduo.

Na etapa de teste, sinais *EEG* de cada intervalo de tempo foram submetidos à redução dimensional e posteriormente classificados usando os parâmetros configurados durante o treinamento. Para não alterar o funcionamento do decodificador, o resultado da classificação efetuada em cada intervalo não foi tomando em conta, mas o desempenho do algoritmo foi levantado para analisar se, as seções do sinal *EEG* relacionados com o movimento eram corretamente discriminadas.

Nas figuras 6.33 e 6.34 se apresenta o Erro de Classificação médio (eixo vertical) ao longo dos 6 voluntários (eixo horizontal) durante a etapa de validação do algoritmo considerando movimentos ascendentes e descendentes. Todos os Parâmetros com $\Delta_t \geq 30ms$ foram usados durante o teste.

Encontraram-se poucas alterações significativas respeito ao valor do erro de classificação segundo a variação do parâmetro Δ_t em cada voluntário. Com exceções encontradas nos voluntários 2 e 5 (com Δ_t de 70 e 150 ms) durante o controle do movimento de ascenso; e no voluntário 5 durante o descenso (com $\Delta_t = 30$ ms). Contudo, exceptuando as exceções mencionadas, o desempenho do algoritmo de classificação foi estável ao longo de todos os voluntários.

Evidenciou-se que a generalização dos parâmetros c e C afetam o desempenho




Figura 6.33: Erro de Classificação Médio durante o Ascenso, ao longo dos 6 voluntários (eixo horizontal), o erro de classificação (eixo vertical) é a porcentagem de pontos incorretamente discriminados respeito ao total de pontos avaliados.




Figura 6.34: Erro de Classificação durante o Descenso, ao longo dos 6 voluntários (eixo horizontal), o erro de classificação (eixo vertical) é a porcentagem de pontos incorretamente discriminados respeito ao total de pontos avaliados.

de forma particular. Por exemplo, a variação do erro de classificação em V_4 indicam que estes parâmetros definidos podem ser reconsiderados. Contudo, a generalização proposta entregou um resultado aceitável com um erro de classificação menor ao 2% na maior parte dos voluntários.

6.4 Discussão

Neste capítulo se apresentaram os resultados do filtro de Kalman e a dinâmica do sistema, como também da integração entre os dois conceitos em um *BCI* em laço fechado para projetar como funcionaria o sistema assistivo em tempo real guiado por movimento decodificado a partir de sinais *EEG* relacionados com movimento real e imaginário. A metodologia desenvolvida aqui foi o resultado de múltiplos estudos, tentativas e erros que finalmente levaram como resultado sistema assistivo proposto, que se espera, construa as bases para projetos futuros visando desenvolvimentos em humanos, e também mudanças na metodologia com o objetivo de melhorar os resultados encontrados. A discussão se dividirá em função das seções aqui apresentadas.

6.4.1 Filtro de Kalman

A aplicação do Filtro de Kalman para estimar o movimento foi o eixo central desta dissertação. Sobre ele construiu-se a proposta de pesquisa realizando outra aproximação ao uso do filtro das encontradas na revisão do estado da técnica. O filtro de Kalman é uma de distintas técnicas consideradas para a decodificação do movimento. Sendo abordada inicialmente por Brown et al. em ratos [152], para estimar sua posição espacial a partir da leitura de atividade elétrica desde células do hipocampo, e posteriormente por Wu et al. [107], [97] em macacos para estimar a posição bidimensional da mão usando eletrodos implantados; posteriormente Pistohl et al., [109] levou o experimento a humanos usando Eletrocorticografia (*ECoG*) que é um método invasivo, para controlar o movimento de um cursor numa tela, e finalmente com Robinson et al., [108] replicando o experimento de Wu et la., usando métodos não invasivos em seres humanos. Em [107], [97] [108] tanto a posição como a velocidade são decodificados a partir do sinal *EEG* associado a movimento aleatório, sendo a aceleração descartada por ser um movimento redundante que não contribuía significativamente a codificação da posição da mão.

Uma contribuição deste trabalho, foi encontrar uma incidência entre a variabilidade do movimento e a precisão do resultado. Nos trabalhos mencionados, movimentos aleatórios da mão desenvolvidos em um plano bidimensional foram estimados. Estes movimento se caracterizava por ter altas mudanças na velocidade e aceleração ocasionadas pela aleatoriedade do sinal de seguimento. Neste trabalho, a trajetória

do movimento não tinha um comportamento estocástico, dado que a proposta do mesmo era de desenvolver um sistema assistivo que ajudasse ao paciente a efetuar movimentos de flexão e extensão do braço. A trajetória descrita ao longo de todas as repetições se caracterizou por ser uma curva de variação suave, com velocidade inicial e final nula, similar a um polinômio cúbico.

Ao treinar o filtro baixo estas condições controladas de movimento, foi encontrado que, o processo de treinamento da matriz \mathbf{A} , encargada de propagar o movimento do tempo k para o tempo $k + 1$ é suscetível à alta variação do mesmo, assim, matrizes treinadas a partir de realizações com alta variabilidade tinham o maior Erro Quadrático Médio na estimação da posição, velocidade e aceleração. Esta hipótese foi comprovada ao treinar o Filtro para estimar movimentos a partir de sinais relacionadas com imaginação motora usando duas matrizes \mathbf{A} uma com menor norma do que a outra, entanto que ao longo dos 7 voluntários a matriz com $\|\mathbf{A}\| < 2$ apresentou um $EQM < 3$, a segunda com $\|\mathbf{A}\| > 2$ apresentou estimações com um $EQM < 10$, indicando que com a segunda era mais provável obter melhores estimações sem importar a variabilidade do sinal *EEG* dos voluntários entre trials.

A segunda diferença, se encontra relacionada com a variável estimada. Sendo os trabalhos mencionados e outros artigos publicados [23], baseados na decodificação do movimento espacial da mão usando *EEG*. Aqui se analisou a possibilidade de usar Kalman para decodificar outros movimentos. Encontrou-se que é possível estimar movimentos associados à mão, como foi o caso da rotação do cotovelo com a mesma precisão. Este resultado nos permite pensar que é possível associar à atividade *EEG* com outros movimentos, como por exemplo, as variações angulares do ombro para movimentos de flexão/extensão, ou a pronação do braço. Possivelmente o alvo das pesquisas era estimar o movimento da mão, para a partir daí realizar uma cinemática inversa que permita, por exemplo, a um sistema robótico externo, desempenhar as funções do braço [103], [153], [117].

O método de treinamento do filtro de Kalman é um aspecto pouco aprofundado dos artigos de referência. Dos aspectos conhecidos, ambas pesquisas aplicaram uma validação cruzada nas medições realizadas, sem especificar como os dados ao longo dos distintos trials foram conformados. Se pode pensar que, dada a metodologia de treinamento proposta, os vetores que descrevem o comportamento do movimento dos trials de treinamento foram concatenados para posteriormente encontrar o valor das matrizes que caracterizaram o movimento e a relação movimento/sinal *EEG*. Além desta metodologia, outras possibilidades foram avaliadas outras possibilidades, como treinar intervalos menores, e encontrar um modelo associado com essa porção da trajetória. Contudo, problemas com o modelo de propagação eram encontrados, por exemplo que o erro de estimação de movimento nos pontos de concatenação aumentava dado que nestes intervalos a regra linear imposta pelo modelo não se

cumpria.

Porém foi decidido treinar cada trial por separado e posteriormente extrair um modelo geral relacionado com os coeficientes da matriz que eram mais prováveis analisando a distribuição da resposta ao longo dos trials de treinamento que conformavam cada *fold*. Esta conformação do sistema de treinamento nos permitiu testar o comportamento do filtro para movimentos ascendentes e descendentes por separado. Isto permitiu encontrar que na maioria dos voluntários os movimentos descendentes apresentavam menor erro de estimação, ao indagar ao respeito, foi encontrada uma relação Desvio padrão da velocidade e aceleração com o valor do Erro Quadrático Médio.

Ao estudar os movimentos de forma separada, foi encontrado que as variações do mesmo podem afeitar a generalização do modelo. Por tanto, alterações do movimento que foram efetuadas com menor frequências tiveram maior erro de estimação. Aqui ressaltamos que o modelo linear proposto, foi treinado de acordo às condições de movimento mais prováveis, porém, não conseguem abarcar todas as variações do mesmo, focando-se em uma região de todo o conjunto de possibilidades.

Pode-se propor variações ao paradigma experimental, explorando por exemplo trials de movimento efetuados com maior velocidade, assim posteriores treinamentos permitiram encontrar o modelo que se ajuste a estas novas condições. Também pode-se considerar outras técnicas como a clusterização que permitam detectar variações do movimento e daí, propor o modelo de filtro que mais se ajuste ao movimento, sempre e quando continuem sendo considerados modelos de propagação lineares.

Também seria interessante estudar um modelo não linear que considere todas as variações possíveis durante o treinamento. Dado que a matriz \mathbf{A} é usada no modelo de propagação do estado e na estimação da matriz de ruído do respectivo modelo, pode-se considerar outra metodologia para estimar este modelo, por exemplo, redes neurais que tem sido usada também para efetuar processos de decodificação [154],[155],[156] e [157].

Finalmente, explorou-se o uso do filtro de Kalman para decodificar o movimento do braço a partir de *EEG* relacionado com imaginação motora. Considerações tiveram que ser feitas para poder realizar este exercício, como foi o caso de estimar um intervalo de tempo provável em que se efetua o processo de imaginação apos o estímulo visual ter dada a ordem, baseado no tempo de resposta que fez durante o movimento. Este procedimento, ainda que consegue estimar um valor para os estados do movimento, consideramos que requiere de maiores revisões. Como é, determinar um processo de seleção do intervalo em função da atividade espectral nas diferentes bandas [118].

Trabalhos prévios tem mencionado que a imaginação de uma atividade motora pode ser considerada como um ensaio mental da ação [158]. Dado que a imaginação

motora pode envolver as mesmas regiões do cérebro do que as atividades motoras [159], foi considerada a mesma zona próxima ao canal C_3 para estimar este movimento. As leituras feitas através do *ERSP* amostraram padrões aproximados aos apresentados durante ações de movimento real ao comparar as dessincronizações na banda alfa durante um intervalo de tempo associado á execução da atividade mental do voluntário. Por outro lado, as curvas do erro de generalização das duas atividades mentais apresentaram comportamentos similares, indicando que os parâmetros usados para configurar o filtro de Kalman tem os mesmos efeitos para a decodificação a partir de sinais relacionadas com a imaginação e o movimento.

Consideramos que é possível minimizar o erro de estimação tanto na imaginação como o movimento ao reforçar o processo de treinamento efetuado durante o paradigma experimental, experimento prévios tem demonstrado que as pessoas podem aprender a usar o sinal *EEG* para controlar dispositivos adquirindo controle do sinal [160], modulando a amplitude de seus ritmos sensorimotores [161] e capacidades de sincronização e dessincronização [162].

Durante o treinamento, encontrou-se que o filtro proposto apresentou um limite de operação, definido pelo valor dos parâmetros de configuração. Este limite, define o mínimo erro de estimação do movimento ao longo dos voluntários, atingindo uma capacidade de estimação aceitável, mas que não é homogênea ao longo dos trials. Portanto foi proposto adicionar á variável estimada uma fase de compensação baseada na integração da dinâmica do membro a ser assistido junto com um laço de controle.

6.4.2 Dinâmica do Braço e integração com o Filtro de Kalman

Foi estudada a dinâmica do membro superior tendo em conta certas considerações: a primeira foi que o conjunto antebraço/mão se considerou como um único segmento, indicando que durante o movimento o membro mais externo não efetuara movimentos que alterem o comportamento do sistema. O modelo matemático do braço foi construído baseado em dados morfológicos reais [138]. Esta aproximação nos permitiu avaliar um membro com características específicas baseadas na estatura e peso de um individuo médio, cujos parâmetros foram usados posteriormente durante o análise do comportamento do *BCI*, para trabalhos posteriores se pode plantear o uso de modelos dinâmicos projetados de acordo com as características físicas de cada voluntário, planteando assim um experimento mais heterogêneo.

Foi considerado também que a estrutura do sistema assistivo fosse definida unicamente pela morfologia do braço. Pesquisas futuras devem considerar si, uma estrutura que acompanha o sistema gerará aportes significativos que mudem a dinâmica,

mais isso dependerá de como seja o sistema projetado. Também foi integrado ao sistema um motor elétrico, considerando a hipótese de ter um sistema accionado eletricamente, estimando a energia requerida para efetuar o movimento em condições normais e baixo a ação de controle.

O controlador projetado foi testado usando trajetórias reais baseadas em leituras do acelerômetro obtidas durante os experimentos. Foi integrado o *differential flatness* junto com um controlador *PID*, sendo o primeiro usado para estimar uma entrada para o sistema, e o segundo para garantir que o movimento do sistema seja próximo ao esperado, de acordo a uma variável de referência. A combinação dos dois subsistemas permitiu estimar o valor da entrada necessária para movimentar o braço durante ações de flexão e extensão. Esta integração permitiu visualizar como funcionaria o *BCI* no momento de enlaçar a dinâmica com o filtro de Kalman.

Foi adicionado ao sistema controle/filtro, um laço autônomo de referência conformado pelo mesmo modelo do braço com seu próprio laço de controle que efetuou o movimento em função da variável de desejada. Sendo as respostas comparadas para que o controle do sistema accionado pela variável estimada corrija a entrada estimada em função do erro entre os dois movimentos.

Controladores *PD* e *PID* foram usados para testar o dispositivo, respeito ao erro de seguimento da trajetória do cotovelo. Encontrou-se que não existiram diferenças significativas entre os comportamentos dos dois modelo usando um teste *t-student* com um nível de significância do 0,05, encontrando que, nos quatro testes efetuados, movimentos ascendentes e descendentes, reais e imaginários, o teste falhou em rejeitar a hipótese nula ($H = 0$) com um *p-value* maior a 0,9 em todos os casos.

A resposta do erro foi avaliada ao longo de todos os voluntários, encontrado que o controlador consegue compensar a entrada estimada e corrigir o movimento do braço com uma diferencia próxima aos 0 radianos e uma velocidade do movimento inferior a 1 *rad/seg*. Encontrou-se também que este erro aumentava para as duas variáveis controladas conforme se incrementava o valor de Δ_t , para minimizar este erro foi necessário aumentar o valor da frequência natural W_n do controlador comprometendo a precisão do controle.

Também se encontrou que a compensação, usada para medir a diferencia entre o sinal de entrada estimado e o corrigido pela ação do controlador, tendia a diminuir conforme o valor de Δ_t aumentava, por tanto reduções do erro de estimação contribuíam no *BCI* a reduzir o aporte efetuado pelo controle, contribuindo também a um decremento da energia extra requerida para dirigir o sistema, contudo, a diminuição do aporte do controlador levou a um aumento do erro de seguimento do movimento do braço.

Finalmente, foram feitos testes sem o laço de referência, neste caso o desempenho do movimento é dependente da capacidade de decodificação do filtro de Kalman. Se

espera que com esta configuração o paciente possa ter liberdade de desenvolver o movimento, sem restringir o tempo de efetuação ou trajetória. Consideramos que para este tipo de aplicações se faz necessário restringir as possibilidades de movimento do dispositivo assistivo adicionando saturadores para as posições finais é iniciais de forma que não se ultrapasse o espaço de trabalho da articulação.

Dado que não foi efetuado nenhum tipo de controle em tempo real com um voluntário, não conhecemos como pode ser o impacto no resultado dos dados ao introduzir um sistema assistivo ao *BCI* proposto. Trabalhos efetuados com macacos [103], advertem que o uso de um dispositivo impacta significativamente no desempenho em tarefas de aprendizado e desenvolvimento da atividade. Os macacos tiveram que adaptar-se a dinâmica do artefacto, que como consequência levou a uma queda do desempenho do sistema, que só foi recuperada através do treinamento. Baxter et al. [153] também encontrou dificuldades similares ao tentar controlar um braço robótico com imaginação motora, indicando que se requerem mais estudos para entender a interação humano/robot quando se tenta controlar um objeto num ambiente físico.

Capítulo 7

Conclusões e trabalhos futuros

7.1 Conclusões

Neste trabalho se integrou um filtro linear de Kalman para estimar o movimento do cotovelo do braço direito a partir de sinais *EEG* relacionadas com movimento e imaginação motora em um *BCI* em laço fechado. Foi efetuado um estudo de Validação cruzada para testar a resposta do modelo baseado em diferentes parâmetros de configuração. A Validação cruzada permitiu encontrar um conjunto de valores para esses parâmetros que conseguiram minimizar o Erro Quadrático Médio e maximizar o Coeficiente de Correlação.

A variabilidade das amostras relacionadas com o movimento, usadas para o treinamento, podem alterar a resposta do filtro, determinando que uma menor variabilidade dos movimentos treinam um modelo de estimação melhor. Este critério permitiu, por exemplo, melhorar o resultado da estimação de movimento a partir de *EEG* relacionado com imaginação motora. Se considera que mais estudos podem ser efetuados nessa área, como, por exemplo, a implementação de Filtros de Kalman não lineares ou redes neurais. Acreditamos que, modelos com maior flexibilidade no momento de analisar movimentos com alta variação possibilitarão uma redução do Erro de estimação.

Sinais na banda alfa do córtex motor provenientes do canal C_3 e suas proximidades possibilitam a discriminação e decodificação do movimento no braço direito. A contribuição desta área já tem sido reportada em trabalhos prévios [23]. Os resultados deste trabalho permitem concluir que estes sinais podem ser considerados, porém para aplicações em tempo real. O uso de outros canais também foi explorado, encontrando que para atividades de classificação, zonas do córtex motor afastadas de C_3 fornecem pouca atividade discriminatória, sendo sua contribuição um efeito da acumulação de mais atributos para caracterizar o conjunto de exemplos. Para a decodificação só foi estudada a incidência desde a região mencionada, o uso de

outras regiões do córtex não foi considerada, possibilidade que se pode explorar em trabalhos futuros.

Dadas as limitações na qualidade do resultado estimado, foi necessário um sistema de compensação baseado em um laço de controle e um laço de referência, para ajustar valores estimados em função do erro de seguimento. Usando este método de compensação foi possível melhorar o resultado do movimento do sistema assistivo.

A integração do filtro de Kalman junto com o controlador permite considerar a proposta em projetos de tempo real de assistência motriz do membro superior. Encontrou-se uma relação entre o parâmetro de configuração Δ_t e os erros de seguimento e de estimação. Um *trade off* entre estes valores possibilita, por exemplo, a construção de um *BCI* sem compensação, com um menor erro de estimação, mas um maior erro de seguimento, que garante ao paciente uma maior liberdade para efetuar a ação.

Embora apenas o movimento do braço direito foi analisado, se acredita que o braço esquerdo, como também outras articulações associadas ao movimento da mão, podem ser considerados para implementações similares. Dado que o trabalho efetuado nesta tese foi executado de forma *offline*, se considera que a precisão do método proposto deve ser avaliada através de experimentação em tempo real.

Também foi proposto um sistema de classificação que permita ao *BCI* discriminar sinas *EEG* relacionadas com o movimento do braço. O estudo encontrou que com um máximo de 10 canais localizados na zona contralateral ao movimento se pode classificar a atividade cognitiva com uma precisão próxima ao 80%, com possibilidade de aumentar a discriminação se mais canais são adicionados. Este classificador foi integrado ao sistema *BCI* em laço fechado encontrando que sinais de movimentos podem ser discriminadas com um erro de classificação inferior ao 10%. Contudo, a classificação de sinais *EEG* relacionadas a eventos imaginários não foi considerada durante este trabalho, considera-se importante integrar este tipo de atividade cognitiva em futuros projetos, existindo múltiplos trabalhos existentes que podem ser considerados como referência.

Finalmente, considera-se que é possível projetar um sistema *BCI* para assistência do movimento do cotovelo a partir de movimento decodificado desde sinais *EEG* relacionados com movimentos reais e imaginários. Contudo, é necessário continuar explorando alternativas para melhorar o desempenho do sistema de estimação do movimento e, aplicar os conceitos aqui estudados em aplicações *on line*, onde movimentos decodificados em tempo real possam ser controlados enquanto o voluntário efetua o movimento.

7.2 Trabalhos futuros

Consideramos que os resultados de este trabalho podem ser explorados para futuras aplicações, aqui enumeramos elementos a ser considerados:

1. Aplicar um método de estimação não linear para o modelo de propagação do movimento usado o Filtro de Kalman.
2. Adicionar ao sistema um controlador Adaptativo que se ajuste à variação do movimento causadas por mudanças no modelo.
3. Estudar o uso de outras outras regiões corticais para melhorar o desempenho do Filtro de Kalman.
4. Projetar uma estrutura que auxiliará ao braço durante o processo assistencial.
5. Integrar o sistema de classificação imaginário ao sistema *BCI* proposto.
6. Projetar e avaliar o dispositivo assistivo para aplicações em tempo real, ajustando o modelo à morfologia do voluntário e integrando classificação, decodificação e controle do movimento.

Referências Bibliográficas

- [1] KANDEL, E. R., SCHWARTZ, J. H., JESSELL, T. M. *Principles of Neural Science*. McGraw-Hill, 2000.
- [2] NOBACK, C. R., STROMINGER, N. L., DEMAREST, R. J., et al. *The Human Nervous System: Structure and Function*. Humana Press Inc, 2005.
- [3] PONS, J. L. *Wearable Robots: Biomechatronic Exoskeletons*. John Wiley & Sons, Ltd, 2008.
- [4] RAPTOPOULOS, L. S. C., DUTRA, M. S., PINTO, F. A. D. N. C., et al. “Alternative approach to modal gait analysis through the Karhunen–Loève decomposition: An application in the sagittal plane”, *Journal of biomechanics*, v. 39, n. 15, pp. 2898–2906, 2006.
- [5] DUTRA, M. S., DE PINA FILHO, A. C., ROMANO, V. F. “Modeling of a bipedal locomotor using coupled nonlinear oscillators of Van der Pol”, *Biological Cybernetics*, v. 88, n. 4, pp. 286–292, 2003.
- [6] DUTRA, M. S., MALIK, R. A. “Study of a Shape Memory Alloy Driven Mechanical Hand with Five Fingers”. In: Schneider, M., Woernle, C. (Eds.), *Advances in Multibody Systems and Mechatronics*, pp. 131–139, 1999.
- [7] AVILÉS, O. F., MAULEDOUX, M. F., RUBIANO, O. G., et al. “FEA of Bioabsorbable Material to Repair Hand Fractures”. In: *Applied Mechanics and Materials*, v. 823, pp. 173–178. Trans Tech Publ, 2016.
- [8] VICENTE, G. L. F., DUTRA, M. S. “MYOELECTRIC CONTROL OF MANIPULATOR BY FUSION WITH VISION INFORMATION”, 2007.
- [9] VESLIN, E., SLAMA, J., DUTRA, M. S., et al. “Motion planning on mobile robots using differential flatness”, *IEEE Latin America Transactions*, v. 9, n. 7, pp. 1006–1011, 2011.
- [10] VESLIN DIAZ, E., SLAMA, J., DUTRA, M., et al. “Trajectory tracking for robot manipulators using differential flatness”, *Ingeniería e Investigación*, v. 31, n. 2, pp. 84–90, 2011.

- [11] VESLIN, E. *Implementação dos sistemas diferencialmente planos para o controle de um manipulador robótico tipo braço humano*. Tese de Mestrado, Universidade Federal do Rio de Janeiro, Fevereiro 2010.
- [12] PASSOS, V., ISHITANI, L. H., FRANCO, G. C., et al. “Consistent declining trends in stroke mortality in Brazil: mission accomplished?” *Arquivos de neuro-psiquiatria*, v. 74, n. 5, pp. 376–381, 2016.
- [13] BASTERIS, A., NIJENHUIS, S. M., STIENEN, A. H., et al. “Training modalities in robot-mediated upper limb rehabilitation in stroke: a framework for classification based on a systematic review”, *Journal of neuroengineering and rehabilitation*, v. 11, n. 1, pp. 1, 2014.
- [14] SDH/PR, S. D. D. H. D. P. D. R. . “Cartilha do Censo 2010: Pessoas com Deficiência”. 2012.
- [15] PÉREZ-RODRÍGUEZ, R., RODRÍGUEZ, C., COSTA, Ú., et al. “Anticipatory assistance-as-needed control algorithm for a multijoint upper limb robotic orthosis in physical neurorehabilitation”, *Expert Systems with Applications*, v. 41, n. 8, pp. 3922–3934, 2014.
- [16] LEITE, V. B. E., MANCUSSI, A. C., OTHERS. “O cuidar do enfermeiro especialista em reabilitação físico-motora”, *Revista da Escola de Enfermagem da USP*, v. 39, n. 1, pp. 92–96, 2005.
- [17] CARDOSO, V. D. “A reabilitação de pessoas com deficiência através do desporto adaptado”, *Revista Brasileira de Ciências do Esporte*, v. 33, n. 2, 2011.
- [18] VITORINO, A., MONTEIRO, D., MOUTÃO, J., et al. “Atividade física adaptada na população com necessidades especiais”, *Revista Científica da FPDD–Desporto e Atividade Física para Todos*, v. 1, n. 1, pp. 47p–51p, 2015.
- [19] LAMBERCY, O., MAGGIONI, S., LÜNENBURGER, L., et al. “Robotic and wearable sensor technologies for measurements/clinical assessments”. In: *Neurorehabilitation Technology*, Springer, pp. 183–207, 2016.
- [20] LOTZE, M., BRAUN, C., BIRBAUMER, N., et al. “Motor learning elicited by voluntary drive”, *Brain*, v. 126, n. 4, pp. 866–872, 2003.
- [21] PRANGE, G. B., JANNINK, M. J., GROOTHUIS-OUDSHOORN, C. G., et al. “Systematic review of the effect of robot-aided therapy on recovery of

the hemiparetic arm after stroke”, *Journal of rehabilitation research and development*, v. 43, n. 2, pp. 171, 2006.

- [22] PROIETTI, T., CROCHER, V., ROBY-BRAMI, A., et al. “Upper-limb robotic exoskeletons for neurorehabilitation: a review on control strategies”, 2016.
- [23] ROBINSON, N., VINOD, A. “Noninvasive Brain-Computer Interface: Decoding Arm Movement Kinematics and Motor Control”, *IEEE Systems, Man, and Cybernetics Magazine*, v. 2, n. 4, pp. 4–16, 2016.
- [24] CROSHAW, P. *Hardiman I Arm Test-Hardiman I Prototype Project*. Relatório técnico, DTIC Document, 1969.
- [25] KAZEROONI, H. “Exoskeletons for human power augmentation”. In: *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3459–3464. IEEE, 2005.
- [26] ZOSS, A. B., KAZEROONI, H., CHU, A. “Biomechanical design of the Berkeley lower extremity exoskeleton (BLEEX)”, *IEEE/ASME Transactions On Mechatronics*, v. 11, n. 2, pp. 128–138, 2006.
- [27] STRAUSSER, K. A., KAZEROONI, H. “The development and testing of a human machine interface for a mobile medical exoskeleton”. In: *2011 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 4911–4916. IEEE, 2011.
- [28] MERTZ, L. “The next generation of exoskeletons: Lighter, cheaper devices are in the works”, *IEEE pulse*, v. 3, n. 4, pp. 56–61, 2012.
- [29] WOLPAW, J. R., BIRBAUMER, N., MCFARLAND, D. J., et al. “Brain-computer interfaces for communication and control”, *Clinical neurophysiology*, v. 113, n. 6, pp. 767–791, 2002.
- [30] MILLÁN, J. D. R., RUPP, R., MÜLLER-PUTZ, G. R., et al. “Combining brain-computer interfaces and assistive technologies: state-of-the-art and challenges”, 2010.
- [31] SIM, K. S., KIANG, K. D. T., YOU, L. Z. “EEG Controlled Wheelchair”. In: *MATEC Web of Conferences*, v. 51. EDP Sciences, 2016.
- [32] ZHANG, R., LI, Y., YAN, Y., et al. “Control of a Wheelchair in an Indoor Environment Based on a Brain-Computer Interface and Automated Navigation”, *IEEE transactions on neural systems and rehabilitation engineering*, v. 24, n. 1, pp. 128–139, 2016.

- [33] FROLOV, A., BIRYUKOVA, E., BOBROV, P., et al. “Principles of neurorehabilitation based on the brain-computer interface and biologically adequate control of the exoskeleton”, *Human Physiology*, v. 39, n. 2, pp. 196–208, 2013.
- [34] SOEKADAR, S. R., WITKOWSKI, M., VITIELLO, N., et al. “An EEG/EOG-based hybrid brain-neural computer interaction (BNCI) system to control an exoskeleton for the paralyzed hand”, *Biomedical Engineering/Biomedizinische Technik*, v. 60, n. 3, pp. 199–205, 2015.
- [35] LALITHARATNE, T. D., YOSHINO, A., HAYASHI, Y., et al. “Toward EEG control of upper limb power-assist exoskeletons: A preliminary study of decoding elbow joint velocities using eeg signals”. In: *Micro-NanoMechatronics and Human Science (MHS), 2012 International Symposium on*, pp. 421–424. IEEE, 2012.
- [36] HOCHBERG, L. R., SERRUYA, M. D., FRIEHS, G. M., et al. “Neuronal ensemble control of prosthetic devices by a human with tetraplegia”, *Nature*, v. 442, n. 7099, pp. 164–171, 2006.
- [37] ROY, R., MAHADEVAPPA, M., KUMAR, C. “Trajectory Path Planning of EEG Controlled Robotic Arm Using GA”, *Procedia Computer Science*, v. 84, pp. 147–151, 2016.
- [38] BANVILLE, H., FALK, T. “Recent advances and open challenges in hybrid brain-computer interfacing: a technological review of non-invasive human research”, *Brain-Computer Interfaces*, v. 3, n. 1, pp. 9–46, 2016.
- [39] SCHERER, R., MÜLLER-PUTZ, G., PFURTSCHELLER, G. “Self-initiation of EEG-based brain-computer communication using the heart rate response”, *Journal of neural engineering*, v. 4, n. 4, pp. L23, 2007.
- [40] VANACKER, G., DEL R MILLÁN, J., LEW, E., et al. “Context-based filtering for assisted brain-actuated wheelchair driving”, *Computational intelligence and neuroscience*, v. 2007, pp. 3–3, 2007.
- [41] TONIN, L., LEEB, R., TAVELLA, M., et al. “The role of shared-control in BCI-based telepresence”. In: *Systems Man and Cybernetics (SMC), 2010 IEEE International Conference on*, pp. 1462–1466. IEEE, 2010.
- [42] BRUNNER, C., ALLISON, B. Z., KRUSIENSKI, D. J., et al. “Improved signal processing approaches in an offline simulation of a hybrid brain-computer interface”, *Journal of neuroscience methods*, v. 188, n. 1, pp. 165–173, 2010.

- [43] NUDO, R. J. “Mechanisms for recovery of motor function following cortical damage”, *Current opinion in neurobiology*, v. 16, n. 6, pp. 638–644, 2006.
- [44] NUDO, R. J. “Plasticity”, *NeuroRx*, v. 3, n. 4, pp. 420–427, 2006.
- [45] SUBRAMANIAN, S. K., MASSIE, C. L., MALCOLM, M. P., et al. “Does provision of extrinsic feedback result in improved motor learning in the upper limb poststroke? A systematic review of the evidence”, *Neurorehabilitation and neural repair*, v. 24, n. 2, pp. 113–124, 2010.
- [46] WANG, W., COLLINGER, J. L., PEREZ, M. A., et al. “Neural interface technology for rehabilitation: exploiting and promoting neuroplasticity”, *Physical medicine and rehabilitation clinics of North America*, v. 21, n. 1, pp. 157–178, 2010.
- [47] MERIANS, A. S., POIZNER, H., BOIAN, R., et al. “Sensorimotor training in a virtual reality environment: does it improve functional recovery poststroke?” *Neurorehabilitation and neural repair*, v. 20, n. 2, pp. 252–267, 2006.
- [48] ALON, G., LEVITT, A. F., MCCARTHY, P. A. “Functional electrical stimulation enhancement of upper extremity functional recovery during stroke rehabilitation: a pilot study”, *Neurorehabilitation and neural repair*, v. 21, n. 3, pp. 207–215, 2007.
- [49] JUNICHI, H., SAKANO, K., SAITOH, Y. “Development of a communication support device controlled by eye movements and voluntary eye blink”, *IEICE transactions on information and systems*, v. 89, n. 6, pp. 1790–1797, 2006.
- [50] GAJWANI, P. S., CHHABRIA, S. A. “Eye motion tracking for wheelchair control”, *International Journal of Information Technology*, v. 2, n. 2, pp. 185–187, 2010.
- [51] ITURRATE, I., ANTELIS, J. M., KUBLER, A., et al. “A noninvasive brain-actuated wheelchair based on a P300 neurophysiological protocol and automated navigation”, *IEEE Transactions on Robotics*, v. 25, n. 3, pp. 614–627, 2009.
- [52] PFURTSCHELLER, G., NEUPER, C. “Motor imagery and direct brain-computer communication”, *Proceedings of the IEEE*, v. 89, n. 7, pp. 1123–1134, 2001.

- [53] GUILLOT, A., COLLET, C., NGUYEN, V. A., et al. “Brain activity during visual versus kinesthetic imagery: an fMRI study”, *Human brain mapping*, v. 30, n. 7, pp. 2157–2172, 2009.
- [54] BLANK, A. A., FRENCH, J. A., PEHLIVAN, A. U., et al. “Current trends in robot-assisted upper-limb stroke rehabilitation: promoting patient engagement in therapy”, *Current physical medicine and rehabilitation reports*, v. 2, n. 3, pp. 184–195, 2014.
- [55] LUM, P. S., BURGAR, C. G., SHOR, P. C., et al. “Robot-assisted movement training compared with conventional therapy techniques for the rehabilitation of upper-limb motor function after stroke”, *Archives of physical medicine and rehabilitation*, v. 83, n. 7, pp. 952–959, 2002.
- [56] TAKAHASHI, C. D., DER-YEGHIAIAN, L., LE, V., et al. “Robot-based hand motor therapy after stroke”, *Brain*, v. 131, n. 2, pp. 425–437, 2008.
- [57] FASOLI, S. E., KREBS, H. I., HOGAN, N. “Robotic technology and stroke rehabilitation: translating research into practice”, *Topics in stroke rehabilitation*, 2015.
- [58] PIGNOLO, L., DOLCE, G., BASTA, G., et al. “Upper limb rehabilitation after stroke: ARAMIS a “robo-mechatronic” innovative approach and prototype”. In: *2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob)*, pp. 1410–1414. IEEE, 2012.
- [59] REN, Y., KANG, S. H., PARK, H.-S., et al. “Developing a multi-joint upper limb exoskeleton robot for diagnosis, therapy, and outcome evaluation in neurorehabilitation”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 21, n. 3, pp. 490–499, 2013.
- [60] LYNCH, D., FERRARO, M., KROL, J., et al. “Continuous passive motion improves shoulder joint integrity following stroke”, *Clinical rehabilitation*, v. 19, n. 6, pp. 594–599, 2005.
- [61] KREBS, H. I., PALAZZOLO, J. J., DIPIETRO, L., et al. “Rehabilitation robotics: Performance-based progressive robot-assisted therapy”, *Autonomous robots*, v. 15, n. 1, pp. 7–20, 2003.
- [62] KAHN, L. E., LUM, P. S., RYMER, W. Z., et al. “Robot-assisted movement training for the stroke-impaired arm: Does it matter what the robot does?” *Journal of rehabilitation research and development*, v. 43, n. 5, pp. 619, 2006.

- [63] HOGAN, N., KREBS, H. I. “Interactive robots for neuro-rehabilitation”, *Restorative neurology and neuroscience*, v. 22, n. 3-5, pp. 349–358, 2004.
- [64] ERLANDSON, R. F. “Applications of robotic/mechatronic systems in special education, rehabilitation therapy, and vocational training: A paradigm shift”, *IEEE Transactions on Rehabilitation Engineering*, v. 3, n. 1, pp. 22–34, 1995.
- [65] KHALILI, D., ZOMLEFER, M. “An intelligent robotic system for rehabilitation of joints and estimation of body segment parameters”, *IEEE transactions on biomedical engineering*, v. 35, n. 2, pp. 138–146, 1988.
- [66] HU, X. L., TONG, K.-Y., SONG, R., et al. “A comparison between electromyography-driven robot and passive motion device on wrist rehabilitation for chronic stroke”, *Neurorehabilitation and Neural Repair*, v. 23, n. 8, pp. 837–846, 2009.
- [67] COLOMBO, R., PISANO, F., MICERA, S., et al. “Robotic techniques for upper limb evaluation and rehabilitation of stroke patients”, *IEEE transactions on neural systems and rehabilitation engineering*, v. 13, n. 3, pp. 311–324, 2005.
- [68] SONG, R., TONG, K.-Y., HU, X., et al. “Myoelectrically controlled wrist robot for stroke rehabilitation”, *Journal of neuroengineering and rehabilitation*, v. 10, n. 1, pp. 1, 2013.
- [69] NEF, T., GUIDALI, M., RIENER, R. “ARMin III—arm therapy exoskeleton with an ergonomic shoulder actuation”, *Applied Bionics and Biomechanics*, v. 6, n. 2, pp. 127–142, 2009.
- [70] MOUBARAK, S., PHAM, M. T., MOREAU, R., et al. “Gravity compensation of an upper extremity exoskeleton”. In: *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*, pp. 4489–4493. IEEE, 2010.
- [71] MAO, Y., AGRAWAL, S. K. “Design of a cable-driven arm exoskeleton (CAREX) for neural rehabilitation”, *IEEE Transactions on Robotics*, v. 28, n. 4, pp. 922–931, 2012.
- [72] MAO, Y., JIN, X., DUTTA, G. G., et al. “Human movement training with a cable driven arm exoskeleton (carex)”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 23, n. 1, pp. 84–92, 2015.

- [73] JARRASSÉ, N., PROIETTI, T., CROCHER, V., et al. “Robotic exoskeletons: a perspective for the rehabilitation of arm coordination in stroke patients”, *Frontiers in human neuroscience*, v. 8, pp. 947, 2014.
- [74] SONG, Z., GUO, S., PANG, M., et al. “Implementation of resistance training using an upper-limb exoskeleton rehabilitation device for elbow joint”, *J. Med. Biol. Eng.*, v. 34, pp. 188–196, 2014.
- [75] HOGAN, N. “Impedance control: An approach to manipulation”. In: *American Control Conference, 1984*, pp. 304–313. IEEE, 1984.
- [76] ANAM, K., AL-JUMAILY, A. A. “Active exoskeleton control systems: State of the art”, *Procedia Engineering*, v. 41, pp. 988–994, 2012.
- [77] ISHIDA, T., TAKANISHI, A. “A robot actuator development with high back-drivability”. In: *2006 IEEE Conference on Robotics, Automation and Mechatronics*, pp. 1–6. IEEE, 2006.
- [78] AUGUGLIARO, F., D’ANDREA, R. “Admittance control for physical human-quadrocopter interaction”. In: *12th European Control Conference, Zurich, Switzerland*, pp. 1805–1810, 2013.
- [79] ÖBERG, T. “Muscle fatigue and calibration of EMG measurements”, *Journal of Electromyography and Kinesiology*, v. 5, n. 4, pp. 239–243, 1995.
- [80] LO, H. S., XIE, S. Q. “Exoskeleton robots for upper-limb rehabilitation: state of the art and future prospects”, *Medical engineering & physics*, v. 34, n. 3, pp. 261–268, 2012.
- [81] TSAI, B.-C., WANG, W.-W., HSU, L.-C., et al. “An articulated rehabilitation robot for upper limb physiotherapy and training”. In: *Intelligent Robots and Systems (IROS), 2010 IEEE/RSJ International Conference on*, pp. 1470–1475. IEEE, 2010.
- [82] SONG, R., TONG, K.-Y., HU, X., et al. “Assistive control system using continuous myoelectric signal in robot-aided arm training for patients after stroke”, *IEEE transactions on neural systems and rehabilitation engineering*, v. 16, n. 4, pp. 371–379, 2008.
- [83] KIGUCHI, K., ESAKI, R., TSURUTA, T., et al. “An exoskeleton system for elbow joint motion rehabilitation”. In: *Advanced Intelligent Mechatronics, 2003. AIM 2003. Proceedings. 2003 IEEE/ASME International Conference on*, v. 2, pp. 1228–1233. IEEE, 2003.

- [84] MAYR, A., KOFLE, M., SALTUARI, L. “[ARMOR: an electromechanical robot for upper limb training following stroke. A prospective randomised controlled pilot study].” *Handchirurgie, Mikrochirurgie, plastische Chirurgie: Organ der Deutschsprachigen Arbeitsgemeinschaft für Handchirurgie: Organ der Deutschsprachigen Arbeitsgemeinschaft für Mikrochirurgie der Peripheren Nerven und Gefäße: Organ der V.*, v. 40, n. 1, pp. 66–73, 2008.
- [85] GOPURA, R. A. R. C., KIGUCHI, K., LI, Y. “SUEFUL-7: A 7DOF upper-limb exoskeleton robot with muscle-model-oriented EMG-based control”. In: *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 1126–1131. IEEE, 2009.
- [86] BALASUBRAMANIAN, S., WEI, R., PEREZ, M., et al. “RUPERT: An exoskeleton robot for assisting rehabilitation of arm functions”. In: *2008 Virtual Rehabilitation*, pp. 163–167. IEEE, 2008.
- [87] WEI, R., BALASUBRAMANIAN, S., XU, L., et al. “Adaptive iterative learning control design for RUPERT IV”. In: *2008 2nd IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics*, pp. 647–652. IEEE, 2008.
- [88] WOLBRECHT, E. T., CHAN, V., REINKENSMAYER, D. J., et al. “Optimizing compliant, model-based robotic assistance to promote neurorehabilitation”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 16, n. 3, pp. 286–297, 2008.
- [89] PROIETTI, T., JARRASSÉ, N., ROBY-BRAMI, A., et al. “Adaptive control of a robotic exoskeleton for neurorehabilitation”. In: *2015 7th International IEEE/EMBS Conference on Neural Engineering (NER)*, pp. 803–806. IEEE, 2015.
- [90] VESLIN, E. Y., DUTRA, M. S., LENGGERKE, O., et al. “A hybrid solution for the inverse kinematic on a seven DOF robotic manipulator”, *IEEE Latin America Transactions*, v. 12, n. 2, pp. 212–218, 2014.
- [91] BROKAW, E. B., HOLLEY, R. J., LUM, P. S. “Comparison of joint space and end point space robotic training modalities for rehabilitation of interjoint coordination in individuals with moderate to severe impairment from chronic stroke”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 21, n. 5, pp. 787–795, 2013.

- [92] OFNER, P., MÜLLER-PUTZ, G. R. “Decoding of velocities and positions of 3D arm movement from EEG”. In: *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 6406–6409. IEEE, 2012.
- [93] LV, J., LI, Y., GU, Z. “Decoding hand movement velocity from electroencephalogram signals during a drawing task”, *Biomedical engineering online*, v. 9, n. 1, pp. 1, 2010.
- [94] YUAN, H., PERDONI, C., HE, B. “Relationship between speed and EEG activity during imagined and executed hand movements”, *Journal of neural engineering*, v. 7, n. 2, pp. 026001, 2010.
- [95] SARAC, M., KOYAS, E., ERDOGAN, A., et al. “Brain computer interface based robotic rehabilitation with online modification of task speed”. In: *Rehabilitation Robotics (ICORR), 2013 IEEE International Conference on*, pp. 1–7. IEEE, 2013.
- [96] JOCHUMSEN, M., NIAZI, I. K., MRACHACZ-KERSTING, N., et al. “Detection and classification of movement-related cortical potentials associated with task force and speed”, *Journal of neural engineering*, v. 10, n. 5, pp. 056015, 2013.
- [97] WU, W., GAO, Y., BIENENSTOCK, E., et al. “Bayesian population decoding of motor cortical activity using a Kalman filter”, *Neural computation*, v. 18, n. 1, pp. 80–118, 2006.
- [98] GEORGOPOULOS, A., KALASA, J., CAMINITI, R., et al. “On the relations between the direction of two-dimensional arm movements and cell discharge in primate motor cortex”, *J. Neurosci.*, 1982.
- [99] SCHWARTZ, A. B. “Motor cortical activity during drawing movements: population representation during sinusoid tracing”, *Journal of neurophysiology*, v. 70, n. 1, pp. 28–36, 1993.
- [100] MORAN, D. W., SCHWARTZ, A. B. “Motor cortical activity during drawing movements: population representation during spiral tracing”, *Journal of neurophysiology*, v. 82, n. 5, pp. 2693–2704, 1999.
- [101] GEORGOPOULOS, A. P., KETTNER, R. E., SCHWARTZ, A. B. “Primate motor cortex and free arm movements to visual targets in three-dimensional space. II. Coding of the direction of movement by a neuronal population”, *Journal of Neuroscience*, v. 8, n. 8, pp. 2928–2937, 1988.

- [102] GEORGOPOULOS, A. P., SCHWARTZ, A. B., KETTNER, R. E. “Neuronal population coding of movement direction”, *Science*, v. 233, n. 4771, pp. 1416–1419, 1986.
- [103] CARMENA, J. M., LEBEDEV, M. A., CRIST, R. E., et al. “Learning to control a brain–machine interface for reaching and grasping by primates”, *PLoS biol*, v. 1, n. 2, pp. e42, 2003.
- [104] PANINSKI, L., FELLOWS, M. R., HATSOPOULOS, N. G., et al. “Spatio-temporal tuning of motor cortical neurons for hand position and velocity”, *Journal of neurophysiology*, v. 91, n. 1, pp. 515–532, 2004.
- [105] WESSBERG, J., STAMBAUGH, C. R., KRALIK, J. D., et al. “Real-time prediction of hand trajectory by ensembles of cortical neurons in primates”, *Nature*, v. 408, n. 6810, pp. 361, 2000.
- [106] CHOI, K. “Reconstructing for joint angles on the shoulder and elbow from non-invasive electroencephalographic signals through electromyography”, *Frontiers in neuroscience*, v. 7, pp. 190, 2013.
- [107] WU, W., BLACK, M., GAO, Y., et al. “Inferring hand motion from multi-cell recordings in motor cortex using a Kalman filter”. In: *SAB’02-workshop on motor control in humans and robots: On the interplay of real brains and artificial devices*, pp. 66–73, 2002.
- [108] ROBINSON, N., GUAN, C., VINOD, A. “Adaptive estimation of hand movement trajectory in an EEG based brain–computer interface system”, *Journal of neural engineering*, v. 12, n. 6, pp. 066019, 2015.
- [109] PISTOHL, T., BALL, T., SCHULZE-BONHAGE, A., et al. “Prediction of arm movement trajectories from ECoG-recordings in humans”, *Journal of neuroscience methods*, v. 167, n. 1, pp. 105–114, 2008.
- [110] VELLISTE, M., PEREL, S., SPALDING, M. C., et al. “Cortical control of a prosthetic arm for self-feeding”, *Nature*, v. 453, n. 7198, pp. 1098–1101, 2008.
- [111] KIM, S.-P., SIMERAL, J. D., HOCHBERG, L. R., et al. “Point-and-click cursor control with an intracortical neural interface system by humans with tetraplegia”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 19, n. 2, pp. 193–203, 2011.

- [112] BRADBERRY, T. J., GENTILI, R. J., CONTRERAS-VIDAL, J. L. “Reconstructing three-dimensional hand movements from noninvasive electroencephalographic signals”, *The journal of Neuroscience*, v. 30, n. 9, pp. 3432–3437, 2010.
- [113] PRESACCO, A., GOODMAN, R., FORRESTER, L., et al. “Neural decoding of treadmill walking from noninvasive electroencephalographic signals”, *Journal of neurophysiology*, v. 106, n. 4, pp. 1875–1887, 2011.
- [114] UBEDA, A., COSTA, A., IÁÑEZ, E., et al. “Single joint movement decoding from EEG in healthy and incomplete spinal cord injured subjects”. In: *Intelligent Robots and Systems (IROS), 2015 IEEE/RSJ International Conference on*, pp. 6179–6183. IEEE, 2015.
- [115] ÚBEDA, A., HORTAL, E., IÁÑEZ, E., et al. “Passive robot assistance in arm movement decoding from EEG signals”. In: *Neural Engineering (NER), 2013 6th International IEEE/EMBS Conference on*, pp. 895–898. IEEE, 2013.
- [116] HOMER, M. L., HARRISON, M. T., BLACK, M. J., et al. “Mixing decoded cursor velocity and position from an offline Kalman filter improves cursor control in people with tetraplegia”. In: *Neural Engineering (NER), 2013 6th International IEEE/EMBS Conference on*, pp. 715–718. IEEE, 2013.
- [117] HOCHBERG, L. R., BACHER, D., JAROSIEWICZ, B., et al. “Reach and grasp by people with tetraplegia using a neurally controlled robotic arm”, *Nature*, v. 485, n. 7398, pp. 372, 2012.
- [118] BESSERVE, M., JERBI, K., LAURENT, F., et al. “Classification methods for ongoing EEG and MEG signals”, *Biological research*, v. 40, n. 4, pp. 415–437, 2007.
- [119] PFURTSCHELLER, G., GRAIMANN, B., HUGGINS, J. E., et al. “Spatio-temporal patterns of beta desynchronization and gamma synchronization in corticographic data during self-paced movement”, *Clinical neurophysiology*, v. 114, n. 7, pp. 1226–1236, 2003.
- [120] PFURTSCHELLER, G., DA SILVA, F. L. “Event-related EEG/MEG synchronization and desynchronization: basic principles”, *Clin. Neurophysiol.*, v. 110, pp. 1842 – 1857, 1999.
- [121] MAKEIG, S. “Auditory event-related dynamics of the EEG spectrum and effects of exposure to tones”, *Electroencephalography and clinical neurophysiology*, v. 86, n. 4, pp. 283–293, 1993.

- [122] DELORME, A., MAKEIG, S. “EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis”, *Journal of neuroscience methods*, v. 134, n. 1, pp. 9–21, 2004.
- [123] SANEI, S., CHAMBERS, J. *EEG SIGNAL PROCESSING*. John Wiley & Sons, Ltd, 2007.
- [124] SMITH, A. M., LEWIS, B. K., RUTTIMANN, U. E., et al. “Investigation of low frequency drift in fMRI signal”, *Neuroimage*, v. 9, n. 5, pp. 526–533, 1999.
- [125] PARRA, L. C., SPENCE, C. D., GERSON, A. D., et al. “Recipes for the linear analysis of EEG”, *Neuroimage*, v. 28, n. 2, pp. 326–341, 2005.
- [126] SUBASI, A., GURSOY, M. I. “EEG signal classification using PCA, ICA, LDA and support vector machines”, *Expert Systems with Applications*, v. 37, n. 12, pp. 8659–8666, 2010.
- [127] KANDASWAMY, A., KUMAR, C. S., RAMANATHAN, R. P., et al. “Neural classification of lung sounds using wavelet coefficients”, *Computers in biology and medicine*, v. 34, n. 6, pp. 523–537, 2004.
- [128] THEODORIDIS, S., PIKRAKIS, A., KOUTROUMBAS, K., et al. *Introduction to pattern recognition: a matlab approach*. Academic Press, 2010.
- [129] BISHOP, C. M. *Pattern recognition & Machine Learning*, v. 128. 2006.
- [130] VESLIN DIAZ, E., DUTRA, M., L, B., et al. “CLASSIFICATION OF RIGHT AND LEFT ELBOWMOVEMENT WITH LOWER GAMMA ACTIVITY”. In: *24th ABCM International Congress of Mechanical Engineering*, 2017.
- [131] VAPNIK, V. *The nature of statistical learning theory*. Springer science & business media, 2013.
- [132] LEMM, S., BLANKERTZ, B., DICKHAUS, T., et al. “Introduction to machine learning for brain imaging”, *Neuroimage*, v. 56, n. 2, pp. 387–399, 2011.
- [133] MONARD, M. C., BARANAUSKAS, J. A. “Conceitos sobre aprendizado de máquina”, *Sistemas inteligentes-Fundamentos e aplicações*, v. 1, n. 1, pp. 32, 2003.
- [134] BISHOP, G., WELCH, G. “An introduction to the kalman filter”, *Proc of SIGGRAPH, Course*, v. 8, n. 27599-23175, pp. 41, 2001.

- [135] GREWAL, M. S. “Kalman filtering”. In: *International Encyclopedia of Statistical Science*, Springer, pp. 705–708, 2011.
- [136] BROWN, R. G. *Introduction to random signal analysis and Kalman filtering*. John Wiley & Sons, 1983.
- [137] CALAIS-GERMAIN, B., LAMOTTE, A. *Anatomy of movement*, v. 2. Kagaku Shinbun Sha, 1997.
- [138] DE LEVA, P. “Adjustments to Zatsiorsky-Seluyanov’s segment inertia parameters”, *Journal of biomechanics*, v. 29, n. 9, pp. 1223–1230, 1996.
- [139] WINTER, D. A. *Biomechanics and motor control of human movement*. John Wiley & Sons, 2009.
- [140] BRANDÃO, E. *Modelagem, controle e implementação do mecanismo de acionamento de um cotovelo robótico*. Tese de Mestrado, Universidade Federal do Rio de Janeiro, 2017.
- [141] FLIESS, M., LÉVINE, J., MARTIN, P., et al. “Flatness and defect of nonlinear systems: introductory theory and examples”, *International journal of control*, v. 61, n. 6, pp. 1327–1361, 1995.
- [142] MARTIN, P., MURRAY, R. M., ROUCHON, P. “Flat systems, equivalence and trajectory generation”, 2003.
- [143] MURRAY, R. M., RATHINAM, M., SLUIS, W. “Differential flatness of mechanical control systems: A catalog of prototype systems”. In: *ASME International Mechanical Engineering Congress and Exposition*. Citeseer, 1995.
- [144] LEVINE, J. *Analysis and control of nonlinear systems: A flatness-based approach*. Springer Science & Business Media, 2009.
- [145] CRAIG, J. J. *Introduction to robotics: mechanics and control*, v. 3. Pearson Prentice Hall Upper Saddle River, 2005.
- [146] LEWIS, F. L., DAWSON, D. M., ABDALLAH, C. T. *Robot manipulator control: theory and practice*. CRC Press, 2003.
- [147] TANG, Z., ZHANG, K., SUN, S., et al. “An upper-limb power-assist exoskeleton using proportional myoelectric control”, *Sensors*, v. 14, n. 4, pp. 6677–6694, 2014.

- [148] LAVRETSKY, E. “Adaptive control: Introduction, overview, and applications” . .
- [149] MUDIYANSELAGE, S. W. H. *A Study of Controlling Upper-Limb Exoskeletons Using EMG and EEG signals*. Tese de Doutorado, School of Science and Engineering, Saga University, Japan, 2014.
- [150] BENNETT, D., HOLLERBACH, J., XU, Y., et al. “Time-varying stiffness of human elbow joint during cyclic voluntary movement”, *Experimental Brain Research*, v. 88, n. 2, pp. 433–442, 1992.
- [151] SPIEGEL, M. *Estatística*. McGraw-Hill, 1994.
- [152] BROWN, E. N., FRANK, L. M., TANG, D., et al. “A statistical paradigm for neural spike train decoding applied to position prediction from ensemble firing patterns of rat hippocampal place cells”, *Journal of Neuroscience*, v. 18, n. 18, pp. 7411–7425, 1998.
- [153] BAXTER, B. S., DECKER, A., HE, B. “Noninvasive control of a robotic arm in multiple dimensions using scalp electroencephalogram”. In: *Neural Engineering (NER), 2013 6th International IEEE/EMBS Conference on*, pp. 45–47. IEEE, 2013.
- [154] WARLAND, D. K., REINAGEL, P., MEISTER, M. “Decoding visual information from a population of retinal ganglion cells”, *Journal of neurophysiology*, v. 78, n. 5, pp. 2336–2350, 1997.
- [155] FAVIEIRO, G. W., BALBINOT, A., BARRETO, M. M. “Decoding arm movements by myoelectric signals and artificial neural networks”. In: *Biosignals and Biorobotics Conference (BRC), 2011 ISSNIP*, pp. 1–6. IEEE, 2011.
- [156] KIGUCHI, K., LALITHARATNE, T. D., HAYASHI, Y. “Estimation of forearm supination/pronation motion based on EEG signals to control an artificial arm”, *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, v. 7, n. 1, pp. 74–81, 2013.
- [157] LALITHARATNE, T. D., TERAMOTO, K., HAYASHI, Y., et al. “Towards hybrid EEG-EMG-based control approaches to be used in bio-robotics applications: Current status, challenges and future directions”, *Paladyn, Journal of Behavioral Robotics*, v. 4, n. 2, pp. 147–154, 2013.
- [158] KRISHNA, D. H., PASHA, I., SAVITHRI, T. S. “Classification of EEG motor imagery multi class signals based on cross correlation”, *Procedia Computer Science*, v. 85, pp. 490–495, 2016.

- [159] JEANNEROD, M. “Mental imagery in the motor context”, *Neuropsychologia*, v. 33, n. 11, pp. 1419–1432, 1995.
- [160] MCFARLAND, D. J., SARNACKI, W. A., WOLPAW, J. R. “Electroencephalographic (EEG) control of three-dimensional movement”, *Journal of neural engineering*, v. 7, n. 3, pp. 036007, 2010.
- [161] WOLPAW, J. R., MCFARLAND, D. J., NEAT, G. W., et al. “An EEG-based brain-computer interface for cursor control”, *Electroencephalography and clinical neurophysiology*, v. 78, n. 3, pp. 252–259, 1991.
- [162] PFURTSCHELLER, G., BRUNNER, C., SCHLO, A., et al. “Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks”, *NeuroImage*, v. 31, pp. 153 – 159, 2006.
- [163] RIEHLE, A. “Preparation for Action: One of the Key Functions of the Motor Cortex”. In: Riehle, A. (Ed.), *Motor Cortex in Voluntary Movements: A distributed system for distributed functions*, cap. 8, John Wiley & Sons, Ltd, 2005.
- [164] SCOTT, S. H. “Conceptual Frameworks for Interpreting Motor Cortical Function: New Insights from a Planar Multiple-Joint Paradigm”. In: Riehle, A. (Ed.), *Motor Cortex in Voluntary Movements: A distributed system for distributed functions*, cap. 6, John Wiley & Sons, Ltd, 2005.
- [165] KAWATO, M. “Internal models for motor control and trajectory planning”, *Curr. Opin. Neurobiol.*, v. 9, pp. 718–727, 1999.
- [166] COOPER, R. P. “Forward and inverse models in motor control and cognitive control”. In: Chappell, J., Thorpe, S., Hawes, N., et al. (Eds.), *Proceedings of the Symposium on AI-Inspired Biology*, pp. 108–110, SSAISB: The Society for the Study of Artificial Intelligence and the Simulation of Behaviour, 2010.
- [167] MIALL, R. C., WOLPERT, D. M. “Forward models for physiological motor control”, *Neural networks*, v. 9, n. 8, pp. 1265–1279, 1996.
- [168] WOLPERT, D. M., FLANAGAN, J. R. “Motor prediction”, *Current biology*, v. 11, n. 18, pp. R729–R732, 2001.
- [169] WOLPERT, D. M., GHAHRAMANI, Z., FLANAGAN, J. R. “Perspectives and problems in motor learning”, *Trends in cognitive sciences*, v. 5, n. 11, pp. 487–494, 2001.

- [170] CHERIAN, A., FERNANDES, H. L., MILLER, L. E. “Primary motor cortical discharge during force field adaptation reflects muscle-like dynamics”, *Journal of neurophysiology*, v. 110, n. 3, pp. 768–783, 2013.
- [171] BAŞAR, E., BAŞAR-EROGLU, C., KARAKAŞ, S., et al. “Gamma, alpha, delta, and theta oscillations govern cognitive processes”, *International journal of psychophysiology*, v. 39, n. 2, pp. 241–248, 2001.
- [172] ASHE, J. “What Is Coded in the Primary Motor Cortex?” In: Riehle, A. (Ed.), *Motor Cortex in Voluntary Movements: A distributed system for distributed functions*, cap. 5, John Wiley & Sons, Ltd, 2005.
- [173] EVARTS, E. “Relation of pyramidal tract to force exerted during voluntary movement”, *J. Neurophysiol.*, 1968.
- [174] MORAN, D., SCHWARTS, A. B. “Motor cortical representation of speed and direction during reaching”, *J. Neurophysiol.*, 1999.
- [175] CACIOPPO, J. T., TASSINARY, L. G., BERNTSON, G. G. *HANDBOOK OF PSYCHOPHYSIOLOGY*. CAMBRIDGE UNIVERSITY PRESS, 2007.
- [176] OLEJNICZAK, P. “Neurophysiologic Basis of EEG”, *J. Clin. Neurophysiol.*, v. 23, n. 3, pp. 186–189, June 2006.
- [177] COHEN, M. X. *Analyzing Neural Time Series Data: Theory and Practice*. The MIT Press, 2014.
- [178] NUNEZ, P. L., SRINIVASAN, R. *Electric Fields of the Brain*. Oxford University Press, 2006.
- [179] PIZZAGALLI, D. A. “Electroencephalography and High-Density Electrophysiological Source Localization”. In: Davidson, R. J. (Ed.), *HANDBOOK OF PSYCHOPHYSIOLOGY*, cap. 3, pp. 56–84, CAMBRIDGE UNIVERSITY PRESS, 2007.
- [180] PFURTSCHELLER, G., NEUPER, C. “Dynamics of Sensorimotor Oscillations in a Motor Task”. In: Graimann, B., Allison, B., Pfurtscheller, G. (Eds.), *Brain Computer Interfaces: Revolutionizing Human Computer Interaction*, cap. 3, pp. 47–66, Springer, 2010.
- [181] STERADE, M. “Cellular substrates of brain rhythms.” In: Niedermeyer, E., da Silva, F. L. (Eds.), *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*, third ed., p. 27–62, Williams & Wilkins., 1997.

- [182] BUZSAKI, G., DRAGUHM, A. “Neuronal oscillations in cortical networks”, *Science*, v. 304, pp. 1926–1929, 2004.
- [183] GRØNLI, J., REMPE, M. J., CLEGERN, W. C., et al. “Beta EEG reflects sensory processing in active wakefulness and homeostatic sleep drive in quiet wakefulness”, *Journal of sleep research*, 2016.
- [184] JAIME, M., MCMAHON, C. M., DAVIDSON, B. C., et al. “Brief Report: Reduced Temporal-Central EEG Alpha Coherence During Joint Attention Perception in Adolescents with Autism Spectrum Disorder”, *Journal of autism and developmental disorders*, v. 46, n. 4, pp. 1477–1489, 2016.
- [185] BERK, L., LEE, J., MALI, D., et al. “Humor associated mirthful laughter increases the intensity of power spectral density (μV^2) EEG gamma wave band frequency (31–40Hz) which is associated with neuronal synchronization, memory, recall, enhanced cognitive processing and other brain health benefits when compared to distress”, *The FASEB Journal*, v. 30, n. 1 Supplement, pp. 1284–9, 2016.
- [186] QIU, S., YI, W., XU, J., et al. “Event-Related Beta EEG Changes During Active, Passive Movement and Functional Electrical Stimulation of the Lower Limb”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 24, n. 2, pp. 283–290, 2016.
- [187] KLIMESCH, W. “EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis”, *Brain Res. Rev.*, v. 29, pp. 169–195, 1999.
- [188] LANA, E. P., ADORNO, B. V., TIERRA-CRIOLLO, C. J. “Detection of movement intention using EEG in a human-robot interaction environment”, *Research on Biomedical Engineering*, v. 31, n. 4, pp. 285–294, 2015.
- [189] TAN, H. G., SHEE, C. Y., KONG, K. H., et al. “EEG controlled neuromuscular electrical stimulation of the upper limb for stroke patients”, *Front. Mech. Eng.*, v. 6, n. 1, pp. 71–81, 2011.
- [190] TATUM, W. O., HUSAIN, A. M., BENBADIS, S. R., et al. *Handbook of EEG Interpretation*. Demos Medical Publishing, 2008.
- [191] ENGEL, A. K., FRIES, P. “Beta-band oscillations—signalling the status quo?” *Current Opinion in Neurobiology*, v. 20, pp. 156–165, Marçó 2010.

- [192] RIEDER, M. K., RAHM, B., WILLIAMS, J. D., et al. “Human gamma-band activity and behavior”, *Int. J. Psychophysiol.*, v. 79, n. 1, pp. 39–48, Janeiro 2011.
- [193] SUBHA, D. P., JOSEPH, P. K., U, R. A., et al. “EEG Signal Analysis: A Survey”, *J Med Syst*, v. 34, pp. 195–212, 2010.
- [194] CANTOR, D. S. “AN OVERVIEW OF QUANTITATIVE EEG AND ITS APPLICATIONS TO NEUROFEEDBACK”. In: Evans, J. R., Abarbanel, A. (Eds.), *QUANTITATIVE EEG AND NEUROFEEDBACK*, cap. 1, pp. 3–23, ACADEMIC PRESS, 1999.
- [195] MALMIVUO, J., PLANSEY, R. *Bioelectromagnetism*. OXFORD UNIVERSITY PRESS, 1995.
- [196] DA SILVA, F. L. “EEG: Origin and Measurement”. In: Mulert, C., Lemieux, L. (Eds.), *EEG-fMRI: Physiological Basis, Technique and Applications*, cap. 2, pp. 19–34, Springer, 2010.
- [197] KROPOTOV, J. D. *Quantitative EEG, Event-Related Potentials and Neurotherapy*. ELSEVIER, 2009.
- [198] PICTON, T., BENTIN, S., BERG, P., et al. “Guidelines for using human event-related potentials to study cognition: Recording standards and publication criteria”, *Psychophysiology*, v. 37, pp. 127–152, 2000.
- [199] DURKA, P. *Matching Pursuit and Unification in EEG Analysis*. Artech House Engineering in Medicine and Biology Series, 2007.
- [200] PFURTSCHELLER, G., ARANIBAR, G. “EVALUATION OF EVENT-RELATED DESYNCHRONIZATION (ERD) PRECEDING AND FOLLOWING VOLUNTARY SELF-PACED MOVEMENT”, *Electroencephalogr. Clin. Neurophysiol.*, v. 46, pp. 138–146, 1979.
- [201] JEON, Y., NAM, C. S., KIM, Y.-J., et al. “Event-related (De)synchronization (ERD/ERS) during motor imagery tasks: Implications for brain-computer interfaces”, *Int. J. Ind. Ergon.*, v. 41, pp. 428–436, 2011.

Apêndice A

Curvas de Erro de Generalização e F1 Score durante a Classificação

Neste anexo se incluem as curvas de erro de generalização e F1 Score de todos os voluntários avaliados na etapa de classificação efetuada no Capítulo 3, usando janelas de 1000, 500 e 70 ms.

A.1 Janelas de 1000 ms




Figura A.1: Resultado da Validação Cruzada e F1 Score No Voluntário 2.




Figura A.2: Resultado da Validação Cruzada e F1 Score No Voluntário 3.




Figura A.3: Resultado da Validação Cruzada e F1 Score No Voluntário 4.




Figura A.4: Resultado da Validação Cruzada e F1 Score No Voluntário 5.




Figura A.5: Resultado da Validação Cruzada e F1 Score No Voluntário 6.

A.2 Janelas de 500 ms




Figura A.6: Resultado da Validação Cruzada e F1 Score No Voluntário 2.




Figura A.7: Resultado da Validação Cruzada e F1 Score No Voluntário 3.




Figura A.8: Resultado da Validação Cruzada e F1 Score No Voluntário 4.




Figura A.9: Resultado da Validação Cruzada e F1 Score No Voluntário 5.




Figura A.10: Resultado da Validação Cruzada e F1 Score No Voluntário 6.

A.3 Janelas de 70 ms




Figura A.11: Resultado da Validação Cruzada e F1 Score No Voluntário 2.




Figura A.12: Resultado da Validação Cruzada e F1 Score No Voluntário 3.




Figura A.13: Resultado da Validação Cruzada e F1 Score No Voluntário 4.




Figura A.14: Resultado da Validação Cruzada e F1 Score No Voluntário 5.




Figura A.15: Resultado da Validação Cruzada e F1 Score No Voluntário 6.

Apêndice B

Respostas do Filtro de Kalman na fase de Treinamento

Neste anexo se apresentam os resultados do treinamento do filtro de Kalman, para as etapas de descenso tanto para o movimento real como imaginário. Os parâmetros de ajustes estão descritos no Capítulo 4.

B.1 Treinamento movimento Descendente




Figura B.1: Resposta da estimação de acordo à variação dos parâmetros lag de Δ_t nas fases de validação e treinamento para movimentos Descendentes.




Figura B.2: Resposta da estimação de acordo à variação de Δ_t nas fases de validação e treinamento para todos os voluntários.

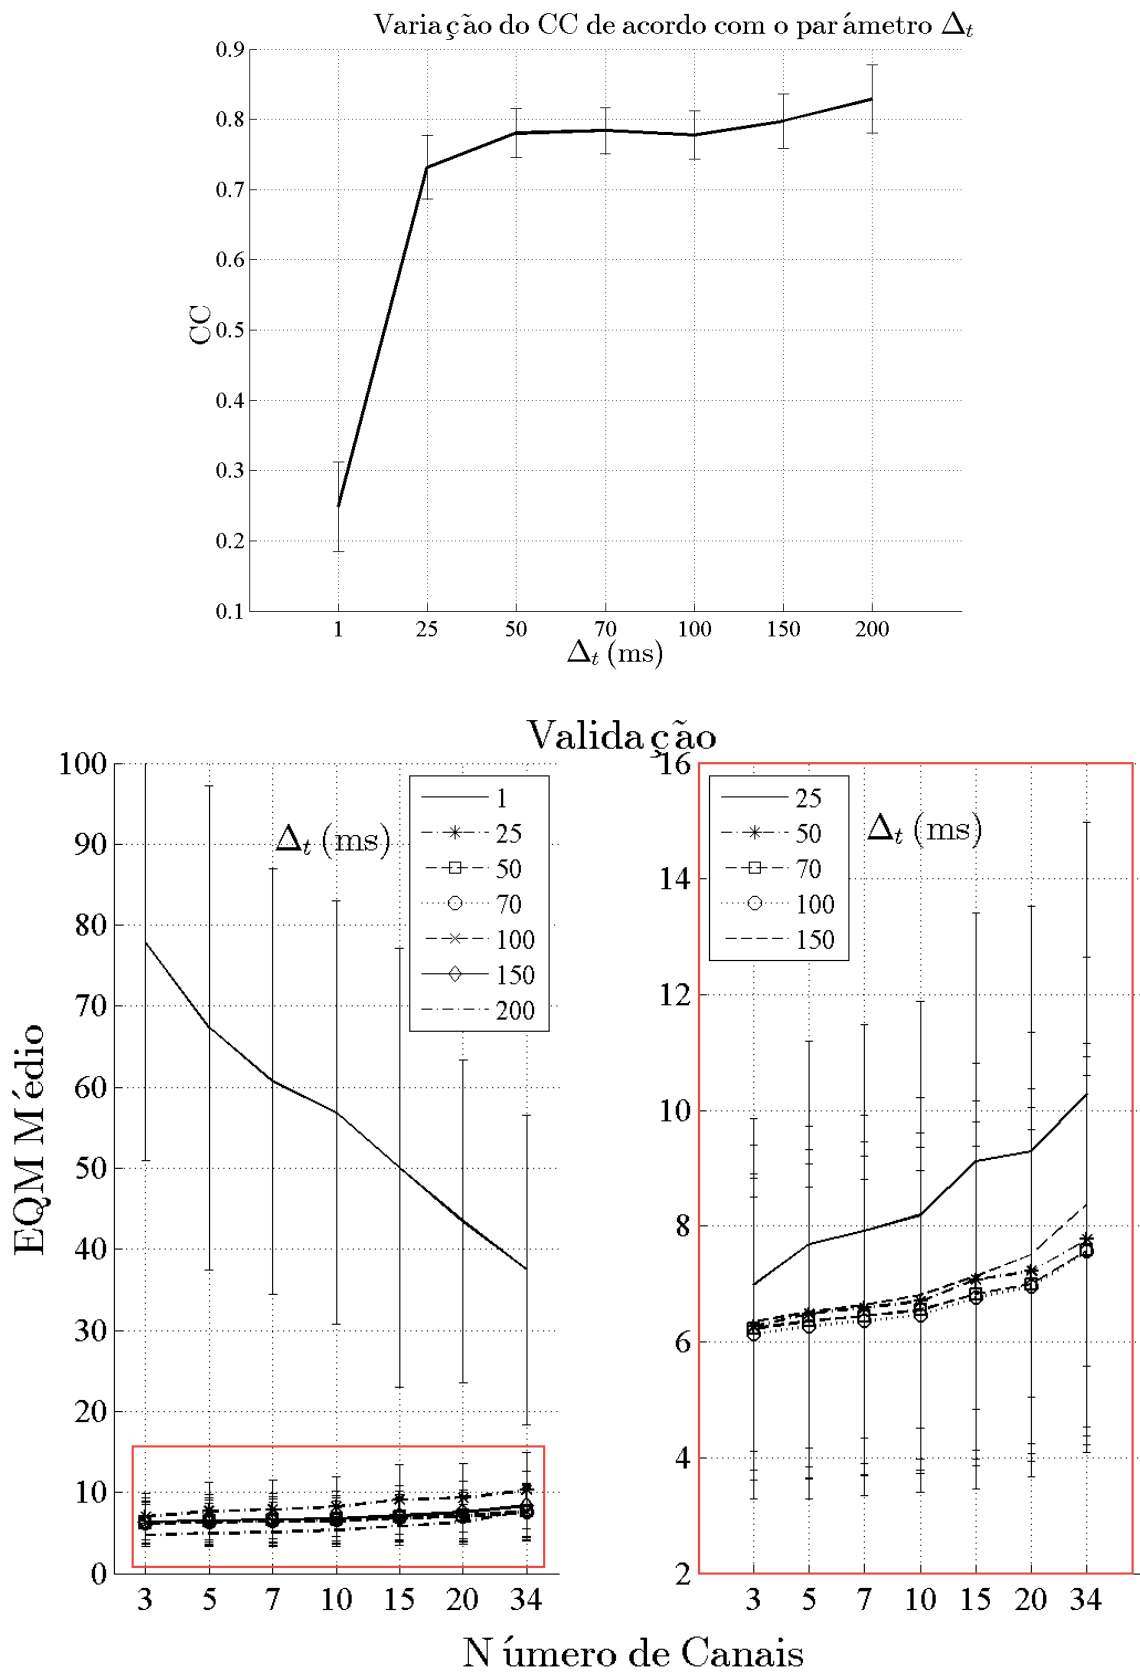


Figura B.3: Resposta do Erro Quadrático Médio de acordo ao número de canais nas fases de validação e treinamento para movimentos descendentes.




Figura B.4: Resposta do Erro Quadrático Médio de acordo à frequência nas fases de validação e treinamento para movimentos descendentes.

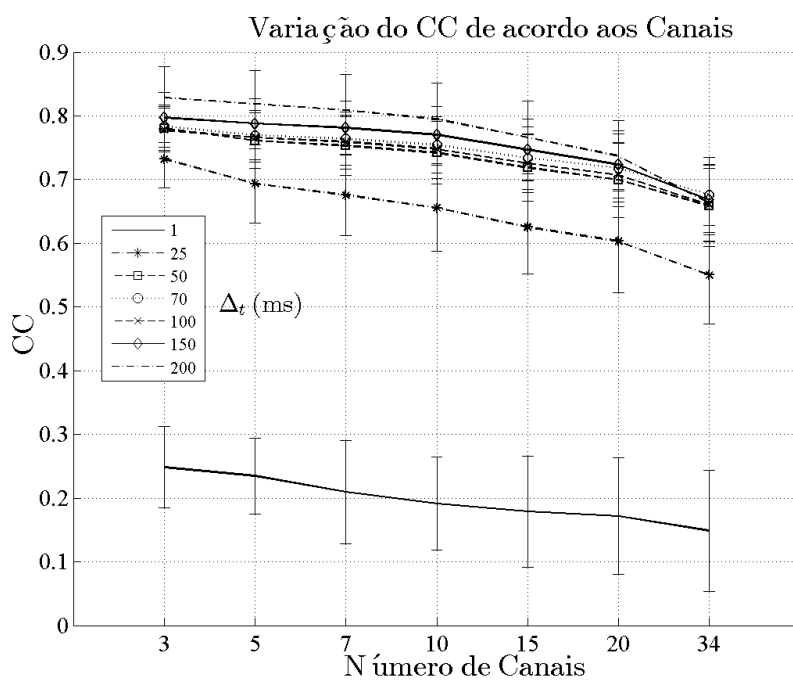


Figura B.5: Coeficiente de Correlação Médio para movimentos descendentes em função do parâmetro Δ_t para todos os voluntários .




Figura B.6: Coeficiente do Erro Quadrático Médio para movimentos descendentes em função do número de canais para todos os voluntários




Figura B.7: Coeficiente de Correlação Médio para movimentos descendentes em função da frequência para todos os voluntários .

B.2 Treinamento movimento Ascendente Imaginário




Figura B.8: Resposta da estimação de acordo à variação dos parâmetros lag de Δ_t nas fases de validação e treinamento para movimentos ascendentes imaginários.




Figura B.9: Resposta da estimação de acordo à variação de Δ_t nas fases de validação e treinamento para todos os voluntários.

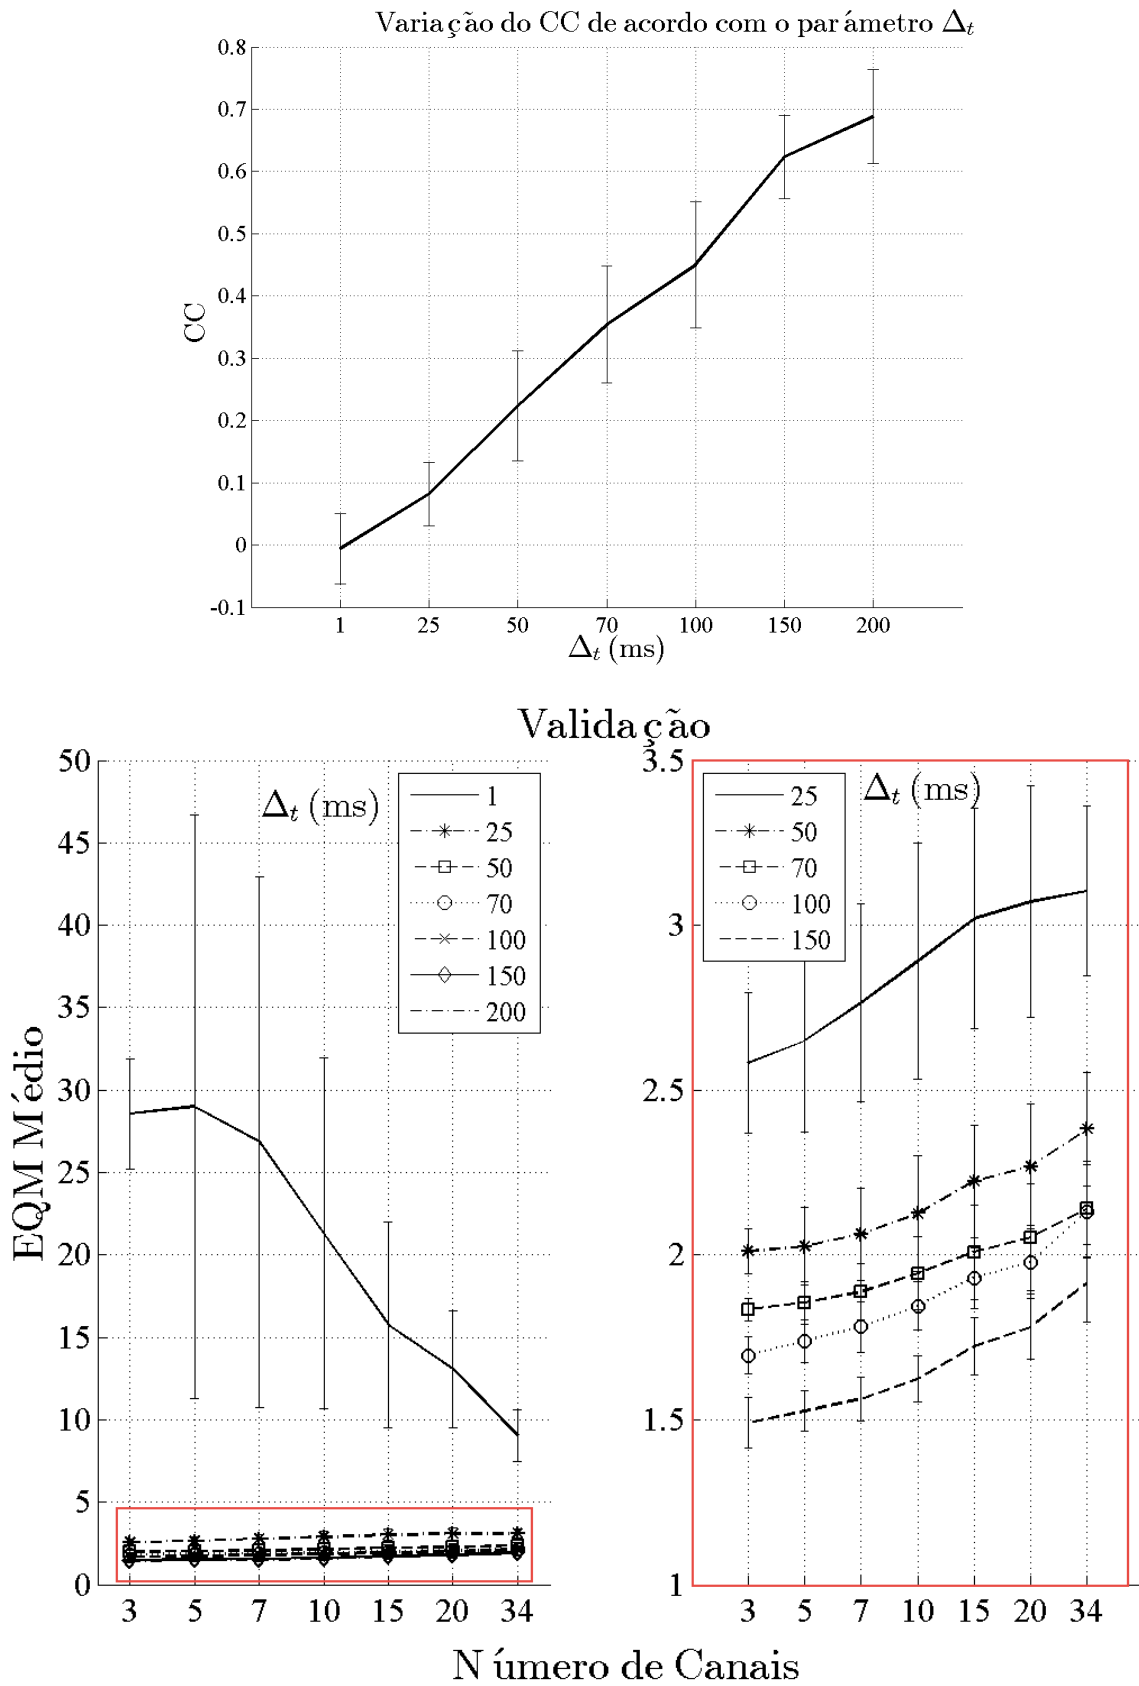


Figura B.10: Resposta do Erro Quadrático Médio de acordo ao número de canais nas fases de validação e treinamento para movimentos ascendentes.




Figura B.11: Resposta do Erro Quadrático Médio de acordo à frequência nas fases de validação e treinamento para movimentos ascendentes.




Figura B.12: Coeficiente de Correlação Médio para movimentos ascendentes em função do parâmetro Δ_t para todos os voluntários .




Figura B.13: Coeficiente do Erro Quadrático Médio para movimentos ascendentes em função do número de canais para todos os voluntários




Figura B.14: Coeficiente de Correlação Médio para movimentos ascendentes em função da frequência para todos os voluntários .

B.3 Treinamento movimento Descendente Imaginário




Figura B.15: Resposta da estimação de acordo à variação dos parâmetros *lag* de Δ_t nas fases de validação e treinamento para movimentos descendentes imaginários.





Figura B.16: Resposta da estimação de acordo à variação de Δ_t nas fases de validação e treinamento para todos os voluntários.



Validação

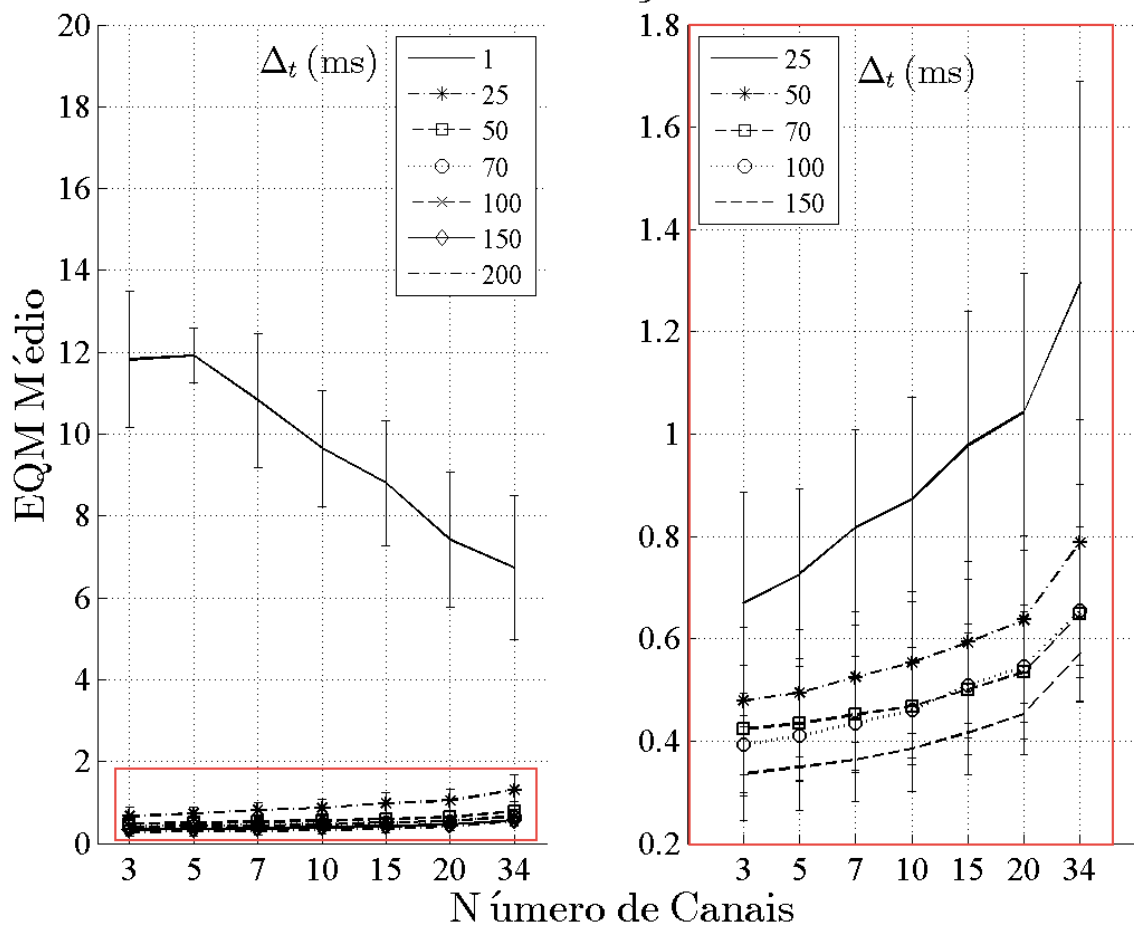


Figura B.17: Resposta do Erro Quadrático Médio de acordo ao número de canais nas fases de validação e treinamento para movimentos descendentes imaginários.




Figura B.18: Resposta do Erro Quadrático Médio de acordo à frequência nas fases de validação e treinamento para movimentos descendentes.




Figura B.19: Coeficiente de Correlação Médio para movimentos descendentes em função do parâmetro Δ_t para todos os voluntários .




Figura B.20: Coeficiente do Erro Quadrático Médio para movimentos descendentes em função do número de canais para todos os voluntários




Figura B.21: Coeficiente de Correlação Médio para movimentos descendentes em função da frequência para todos os voluntários .

Apêndice C

Biologia do Cérebro

No corpo humano, o cérebro é a máquina que controla consciente e inconscientemente as funcionalidade do nosso organismo. Coberto com uma certa camada de mistério o seu funcionamento tem sido decodificado e entendido ao longo de décadas, graças, aos avanços técnicos e médicos que permitiram descobrir como são integradas atividades corporais, cognitivas, sociais e psicológicas com o sistema nervoso, e interpretá-las desde um ponto de vista biológico.

De fato têm sido desmentidos diversos mitos associados com o cérebro, acrescentados mais que tudo pelo desconhecimento de como é que ele funciona; daí a importância de poder explicar o que acontece internamente, e falar da interação entre as redes neurais que compõem o cérebro, de como existe uma propagação da informação através da eletricidade, do pensamento, de como funciona o aprendizado, a memória, das regiões cerebrais e como participam nas diversas funções do corpo humano como: caminhar, comer, respirar, resolver um problema matemático e regular a temperatura do corpo (que, as vezes, acontecem ao mesmo tempo). Estes descobrimentos permitiram criar um mapa do funcionamento cerebral, permitindo saber o que está acontecendo com o ele, interpretar padrões de comportamento e até desvariamentos que antigamente estavam relacionados com assuntos espirituais e associá-los com possíveis dolências do organismo.

Contudo, é a técnica e as inovações o que tem permitido a criação de equipamentos que ajudaram aos cientistas nas interpretações das atividades do cérebro, como no caso do uso massivo do *EEG* (Eleetroencefalograma) que, sendo apoiado por ferramentas matemáticas tem levado um alto grau de conhecimento sobre seu comportamento, criando a Ciência Neural. Este anexo está dedicado a explorar a morfologia e os aspectos biológicos concernentes ao funcionamento do cérebro para logo no capítulo posterior abordá-los para a descrição das ferramentas tecnológicas e teóricas que levaram aos resultados apresentados neste documento, e em trabalhos em geral relacionados com o uso de sinais cerebrais em sistemas *BCI* (*Brain Computer Interface*) ou *BMI* (*Brain Machine Interface*).

C.1 A teoria do Movimento

Pons [3] comentava no seu livro, *Wearable Robots: Biomechatronic Exoskeletons* a importância da *Bio-imitação* no desenvolvimento de sistemas robóticos que imitam o comportamento do ser humano e de animais. A *Bio-imitação* quer dizer a cópia de parâmetros biológicos com o objetivo de conseguir maximizar as qualidades específicas de um ser vivo. Por exemplo, imitar o desenho das asas de um pássaro para obter as melhores capacidades de voo em um protótipo voador. É de supor, que a morfologia de um espécime está sujeita a um modelamento ao longo das gerações, que melhora as qualidades do indivíduo que se adapta a diversas situações de seu entorno. Estas adaptações não são unicamente externas, também existe um uso eficiente dos recursos energéticos. Assim de um corpo modelado pelas circunstâncias ambientais e um consumo moderado da energia supõem-se o êxito de uma espécie para sua sobrevivência.

Quando é analisado o movimento do corpo humano, pode-se apreciar esta necessidade do corpo de poupar a maior quantidade de energia efetuando a menor quantidade de movimentos e com a maior precisão, deixando de lado ações desnecessárias. Por exemplo um braço humano com graus de liberdade redundantes favorecem o movimento e o ajuste dele para alcançar um objeto. O movimento pode ser visto como uma trajetória reta, sem efetuar movimentações absurdas ao redor dele (a menos que tenha outro objeto obstruindo) efetuando assim a melhor rota. Riehle [163] observou que o sistema motor tem que ser ajustado segundo no contexto em que ele se encontra, tendo em conta as propriedades dos elementos entorno dele e as condições ambientais. A situação do movimento envolve problemas que são resolvidos imediatamente através do racionamento, porém, comenta a autora, existem problemas essenciais que também devem ser resolvidos: atenção, intenção, estimações de restrições temporais e espaciais, antecipação, motivação, julgamento, decisão e preparação do movimento.

O processo é monitorado continuamente pelo cérebro, observando o entorno, lendo as informações, retendo as mais importantes e escolhendo a resposta motora mais adequada. Isto quer dizer que se tem a integração de múltiplas áreas do cérebro que são ativadas, realizando um processo cognitivo que envolve o uso dos neurônios, sensores visuais, táteis, e ativação motora, em um *feedback* contínuo que termina efetuando a tarefa, dando um passo para outras atividades que puderam ser realizadas voluntariamente ou processadas internamente sem requer nossa atenção.

Outra teoria aponta como o movimento desenvolvido cotidianamente é o resultado do treinamento. Na situação de uma tarefa de apanhar um objeto com a mão, a visão é usada pelo cérebro para fornecer os dados de entrada suficientes para controlar o movimento. Em [164] é assumido que o cérebro converte a informação

visual da localização do objetivo em comandos de ativação muscular através do laço de realimentação descrito na Figura C.1. O modelo apresenta o termo *Modelo Interno* [165],[166], que são mecanismos neurais que podem imitar as características de entrada e saída do sistema Musculoesquelético adquirindo sua dinâmica inversa a través de aprendizado motor. Isto é, uma repetição constante dos movimentos levam a melhorar as condições de movimentação, efetuando ao final trajetórias direitas e com um erro de locação decrescente. Se houver uma mudança na adaptação (a aplicação de um campo de força), as trajetórias do movimento são distorcidas com um aumento do erro na localização.

Em condições normais a dinâmica inversa calcula os comandos motores com a compensação apropriada usando os sensores do sistema, neste caso a visão e a propriocepção (capacidade de reconhecer a localização espacial do corpo). Se as condições são alteradas, os comandos motores não são mais úteis nas novas circunstâncias, não podem compensar a força e levam ao erro nas trajetórias do movimento. Para corrigir isto, o sistema muda a dinâmica aprendida tendo em conta as novas condições através de múltiplas repetições, mudando os comandos motores até diminuir o erro. Segundo os estudos neurofisiológicos de Scott [164], os modelos internos, estão localizados em todas as regiões cerebrais, alguns deles sendo armazenados no córtex cerebral.

Segundo Mial e Wolpert [167], estes modelos internos podem ser classificados em grupos conceptualmente distintos: o primeiro, é uma representação do aparato motor, conhecido também como modelo direto, este modelo, tem como propósito representar o comportamento normal do sistema motor em resposta aos comandos motores, permitindo por exemplo, estimar o comportamento futuro. O segundo, se encarrega de modelar o comportamento do ambiente, este modelo encapsula conhecimento das propriedades físicas e consegue prever o comportamento do mundo externo. E finalmente, o terceiro grupo de modelos internos são conhecidos como os modelos inversos, os quais tem conhecimento sobre o comportamento do sistema motor, permitindo estabelecer que tipo de entradas podem levar a um modelo a produzir um estado (posição/velocidade) específico.

Os modelos internos ajudam ao cérebro a prever as consequências de um comando motor tomando em conta as interações com o ambiente e a própria complexidade do movimento [168]. Por exemplo o comportamento motor adotado posteriormente a um treinamento exaustivo é consequência de um modelo preditivo exato que concebe tanto o próprio corpo como também os mecanismos externos que interatuam com ele. Assim, como consequência direta do treino constante os modelos diretos são alterados de acordo com a experiência, atualizados através da comparação do comportamento do comando motor atual com o estimado.

Ao conseguir aprender a estimar o estado, as predições permitem ao cérebro a

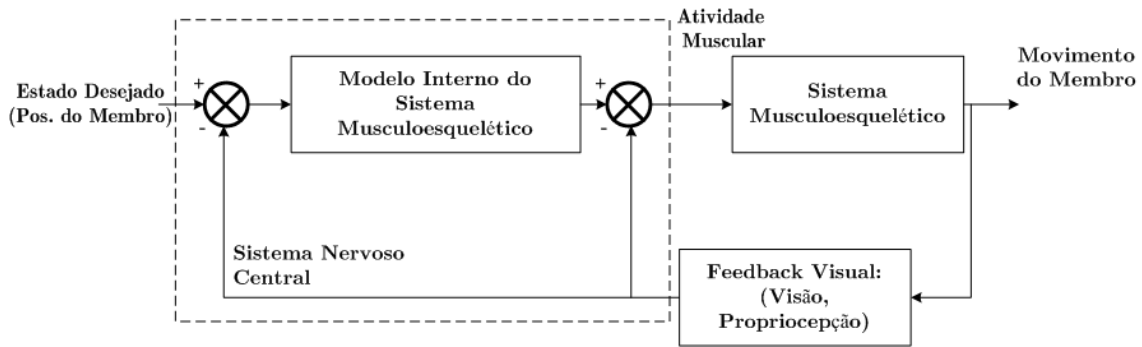


Figura C.1: Controle do movimento do Braço segundo a teoria dos Modelos Internos [164]

filtrar informação sensorial, atenuando informação inessária ou ressaltando aquela que seja de maior proveito para o controle. Este evento, por exemplo permite ao sistema determinar si o movimento do corpo ha sido gerado por nosso corpo ou por um agente externo, ao comparar as prediões sensoriais com a realimentação atual, assim de houver alguma discrepância, o corpo atribui o movimento a um elemento não gerado por ele mesmo [168].

Assim as habilidades para gerar um comportamento motor preciso e apropriado sem importar as condições ambientais são devidas á capacidade do corpo de escolher múltiplos controladores, cada um adequado para diferentes contextos. Estes controladores são aprendidos analisando diferentes modelos internos em uma circunstancia ambiental, se a predição de um determinado modelo se aproxima à realimentação sensorial, então esse controlador será considerado para determinar os subseqüentes comandos motores quando a condição ambiental se repita [169].

As teorias mencionadas explicam o movimento desde um ponto de vista cognitivo. Na secção seguinte serão abordados os aspectos teóricos da biologia neural envolvida no movimento do corpo.

C.2 O Sistema Nervoso Periférico

O Sistema Nervoso, possui uma simetria bilateral na sua estrutura cobrindo o corpo e conectando-o com o cérebro. Ele está dividido em Sistema Nervoso Central e Sistema nervoso Periférico. O Sistema Nervoso Periférico é composto por nervos que surgem do cérebro (nervos cranianos) e da médula espinal (nervos espinhais), e transporta a informação proveniente dos órgãos e receptores sensoriais localizados ao longo do corpo, como também transporta informação proveniente do Sistema Nervoso Central aos músculos e glândulas.

Esta estrutura de comunicação pode-se subdividir funcionalmente no *Sistema*

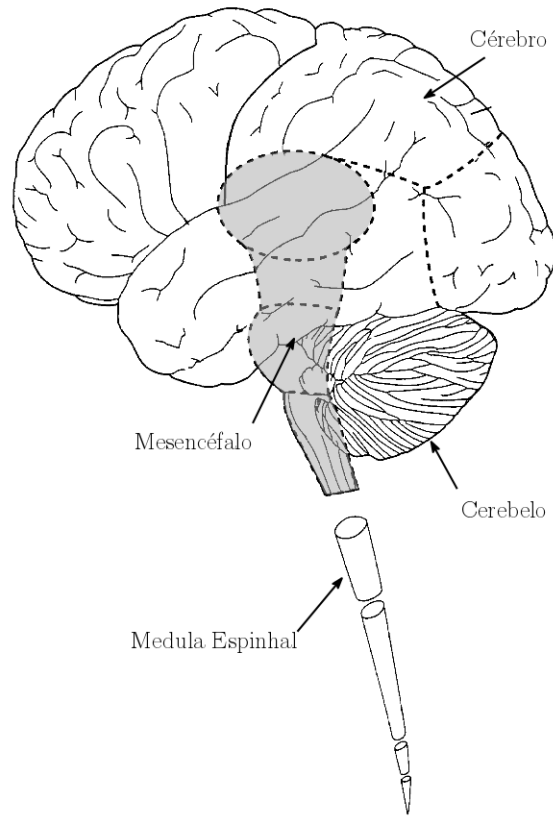


Figura C.2: Esquema do Sistema Nervoso Central. Imagem extraída de [1]

Nervoso Somático, que são as estruturas neurais que conformam tanto o Sistema Nervoso Central como o Periférico encarregadas de transportar informação aferente (sensorial) de forma consciente e inconsciente, como também informação eferente (motora) que controla o movimento voluntário; o Sistema Nervoso autônomo encarregado das funções vitais do corpo que são não conscientes ou feitas de maneira autônoma. O Sistema Nervoso possui vias para transportar as informações até o cérebro e vice-versa, por exemplo. informações visuais são transportadas pelas vias sensoriais associadas a visão, entretanto as ordens neurais para a ativação motora são transportadas através das vias motoras, outras vias exclusivas para temperatura ou dor complementam a estrutura.

C.3 O Sistema Nervoso Central

O cérebro faz parte do Sistema Nervoso Central apresentado na Figura C.2, este sistema encontra-se conectado com o Sistema Nervoso Periférico, e composto por múltiplas partes, onde destacam-se [1],[2]:

- **A medula espinhal:** O centro de transporte, a via da informação entre o corpo e o cérebro, é a encarregada de receber todas as informações provenientes

do Sistema Nervoso Periférico, por exemplo informações do sentido do tato, a dor nas extremidades (aférente); mais também comunica os comandos de movimento provenientes do cérebro até as extremidades e glândulas (eferente).

- **O cerebello:** Encarregado da dinâmica do corpo humano, modula a força e a amplitude dos movimentos, coordenação dos movimentos oculares, balanço, aprendizado motor.
- **O Mesencéfalo:** controla as funções motoras, como o movimentos dos olhos e a coordenação.
- **O cérebro:** Parte central do Sistema Nervoso, encontra-se dividido em camadas, a externa denominada *córtex cerebral* e três internas: os *gânglios basais*, o *hipocampo* e a *amígdala*. Os sinais elétricos usados nos sistemas *BCI* são captados no Córtex, que se encontra dividido em quatro lobos: frontal, parietal, temporal e occipital. As camadas internas do cérebro, estão encarregadas de aspectos como a memória, as respostas endócrinas e os estados emocionais.

C.3.1 O Córtex Cerebral

O Córtex Cerebral é a camada externa do cérebro, também conhecida como massa cinzenta. O córtex encontra-se distribuído ao longo de quatro lobos ver Figura C.3., cada lobo está encarregado de diferentes funções cognitivas sendo elas:

- **Lobo Frontal:** encarregado do planejamento das ações futuras como também do controle do movimento.
- **Lobo Parietal:** Trabalha a sensação somática, relacionada aos sentidos e ao espaço extra sensorial.
- **Lobo Temporal:** encarregado da audição, mais internamente da memória e emoções.
- **Lobo Occipital:** Encarregado da visão.

Destaca-se dos lobos as formações irregulares denominadas circunvoluções ou *giros*, as quais são separadas por fissuras ou *sulcos*, sendo as mais importantes o *Sulco Central* que divide o *Giro Pré-central*, (também conhecido como *Córtex Motor*, encarregado das funções motoras), do *Giro Pós-central* (também conhecido como *Sistema Somato sensitivo*), encarregado das funções sensitivas, codifica os estímulos captados por receptores em todo o corpo; e o *Sulco Lateral* que separa o lobo frontal do lobo temporal.




Figura C.3: Localização dos Giros Pré-Central e Pós-Central no Cérebro e regiões cerebrais. Imagem feita pelo autor.

C.3.2 O Córtex Motor

O Córtex Motor é a área do cérebro responsável pelo controle do movimento voluntário e possivelmente da imagética motora. O córtex trabalha de forma contralateral, isto é, o hemisfério direito do cérebro controla os movimentos dos membros do lado esquerdo do corpo. Esta mesma lógica é aplicada no hemisfério esquerdo do córtex que controla o movimento dos membros do lado direito.

Cada membro possui uma região do córtex dedicada ao controle do seu movimento, porém estas áreas não estão uniformemente distribuídas. Na Figura C.4 se ilustra um mapa de regiões corticais que é conhecido como o *homúnculo* (do latim pequeno homem), este digrama descreve a quantidade de tecido cerebral no córtex dedicado para a supervisão do movimento de cada membro. Por exemplo, pôde-se ver na figura como a área de representação da mão possui um tamanho maior em relação à área do pé. Isso quer dizer que existe atividade cognitiva em uma área do córtex maior em comparação com o outro membro, mas esta diferença não é casual, As regiões relacionadas a cada membro são proporcionais à habilidade, precisão e controle requerido para o movimento [2].

Esta regionalização permite teorizar que existe um número de neurônios integrados relacionados com a ativação de músculos específicos, que processam a intenção cinemática e a transformam em movimento[170]. Este processo é entendido como variações da atividade elétrica em um grupo de neurônios, cuja energia oscila em diferentes frequências e amplitudes. Estes grupos trabalham em estruturas distribuídas que variam em intensidade, sincronização, duração e retardo, controlando cada função do córtex [171].

Segundo Ashe [172] ainda existe um debate sobre o que é representado nas leituras do sinal elétrico provenientes do córtex motor. Se elas representam parâmetros cinéticos, relacionados aos músculos e a força, ou parâmetros cinemáticos que tem a ver com aspectos espaciais da saída motora, como a direção, velocidade e posição. Têm se evidencias dos aspectos cinemáticos, contudo, são os efeitos dinâmicos os mais comuns nas pesquisas sobre o uso dos sinais provenientes do córtex motor para aplicações *BCI* e no estudo do córtex no âmbito geral. Pesquisas relatam relações entre as atividades neurais com parâmetros como força muscular [173], velocidade do membro [174], [157], posição do membro [100],[107],[103], e direção do movimento [98].

C.3.3 A Biologia do Movimento

As mensagens neurais para a atividade motora são levadas aos músculos e glândulas [2] após a recepção de um estímulo do sistema sensorial. As mensagens são transportadas através das vias motoras aos terminais neuromusculares localizados nos

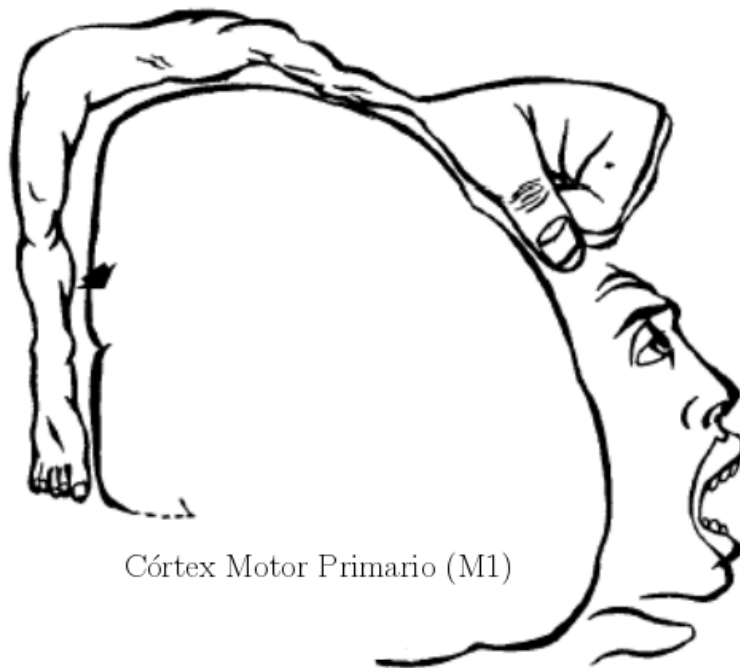


Figura C.4: Secção frontal do Córtex Motor no Hemisfério Direito do cérebro, relacionando cada parte do corpo com o tamanho da região usada para seu controle. Extraído de Noback et al., [2]

músculos da cabeça, corpo e extremidades.

C.4 Descrição da Atividade Neural

Nas seções C.2 e C.3 descreveu-se a biologia do movimento envolvendo o cérebro e toda a rede nervosa que desenvolve o processo. Esta seção descreve desde um ponto de vista neural e fisiológico, os fatores que desencadeiam a atividade elétrica envolvida pelos processos cognitivos associados à execução do movimento e que finalmente são captados pelo EEG. Existe ampla bibliografia que descreve a atividade neural e biológica sendo aqui os livros de Sanei e Chambers [123] e Caccioppo et al. [175] usados como material referencial.

A informação eferente e aferente é transportada pelo Sistema Nervoso através das células nervosas (FiguraC.5), as quais em resposta ao estímulo podem levar informações a distâncias tão longas como um metro. Os neurônios são células nervosas que possuem a mesma estrutura básica, composta pelo axônio, os dendritos e o corpo celular (ou soma). Os estímulos são originados das sinapses ou de atividade química. Os dendritos permitem a comunicação entre as células conectando-se aos terminais axonais de outras células, recebendo os impulsos. O sinal elétrico é integrado próximo ao soma e transmitido pelo axônio.

A tensão elétrica transmitida pelo nervo da ordem dos 60-70 mV com polaridade

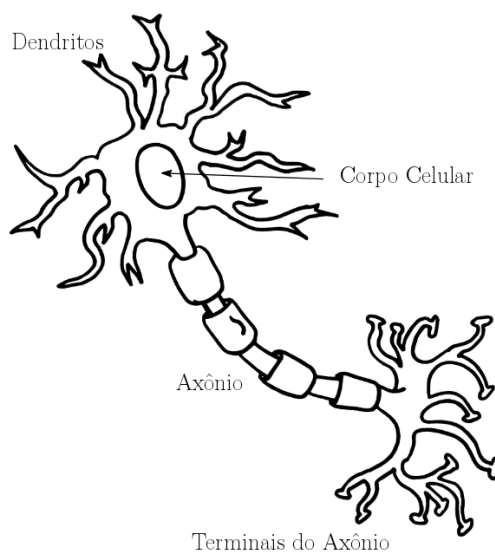


Figura C.5: Ilustração do Neurônio. Imagem extraída e modificada do portal web GettyImages.




Figura C.6: Potencial de Ação da membrana. Adaptado de Sanei e Chambers [123].

negativa, é chamado de Potencial de Ação (PA), Figura C.6, sendo causado por um intercâmbio iônico entre as membranas que gera uma mudança no potencial que é transmitido logo pelo axônio. Um pico elétrico é produzido quando a membrana depolariza, depois torna-se mais negativa, esta ação é chamada de repolarização, e finalmente retorna ao potencial normal. Este período tem uma duração de 5 até 10 ms e apresenta uma variação da tensão elétrica dos -60 mV até 20 mV.

É necessário um estímulo para o PA iniciar (I), levando à abertura de canais e a entrada de íons de Sódio (Na) positivos. Ele pode se originar da atividade química, luz, eletricidade, pressão, contato ou esforço, e deve ser maior que o limiar de disparo de potência. Despolarizações da célula de -70 mV até -55 mV, levam ao início do processo. O pico no PA é causado pela abertura dos canais de Sódio (Na^{\pm}) dependentes de voltagem. A entrada destes íons Na^+ (II) polarizam positivamente a célula (depolarização) atingindo uma tensão de 30 mV aproximadamente; logo os canais de Na^+ são fechados para dar abertura aos canais de K^+ (III), iniciando a repolarização (IV) levando ao potencial de membrana abaixo do potencial de repouso (V) (-90 mV aproximadamente), este ponto é chamado de hiperpolarização. Esta etapa evita que a célula tenha susceptibilidade ao outro estímulo e inicie um novo PA. Os íons de Na^+ são bombeados fora da membrana, trocados por K^+ e ela retorna ao potencial normal (VI) (-70 mV).

Depois de dois segundos o nervo é susceptível a um novo estímulo que da origem a um novo PA. A direção da corrente elétrica é dependente da excitação. Quando um PA se aproxima do neurônio resultado de uma atividade aferente aos dendritos próximos ao corpo celular, apresenta-se uma despolarização deles e tornam-se mais eletronegativos em comparação ao soma, resultando numa diferença de potencial que origina uma corrente elétrica desde o soma até os dendritos emergindo uma polaridade negativa na superfície. Caso contrário se o soma é excitado, o fluxo elétrico terá a direção contrária.

C.4.1 Geração do *EEG*

O *EEG* é um ferramenta fundamental para o estudo dos processos cognitivos [177]. Ele pode captar a dinâmica da cognição, ações motoras, perceptuais, linguísticas e emocionais que podem ser analisados no instante em que acontecem. Por tanto o *EEG* é útil para aplicações em tempo real. As variações temporais do *EEG* são na ordem de milissegundos, e podem ser captadas por *Sistemas de Adquisição de Dados* (DAQ no inglês) de alta resolução.

Os processos cognitivos captados pelo *EEG* são compilações de oscilações de potenciais elétricos da ordem de microvolts (μV) que acontecem no cérebro a nível celular, produto das sinapses, em resposta a potenciais excitatórios ou inibitórios




Figura C.7: Movimentação da Corrente elétrica causado pela inibição e excitação do neurônio. Adaptado de Olejniczak [176].

acontecidos nos neurônios piramidais localizados no córtex. Estas sinapses são respostas ao estímulos ou ordens de controle para extremidades e órgãos entre outras funções biológicas. O cérebro sempre está trabalhando, portanto sua atividade elétrica é permanente e diversa, variando constantemente sua oscilação e a amplitude, produto da atividade que o corpo esteja realizando, porém, segundo o sinal é possível determinar diferentes estados mentais, como sono profundo, alta concentração, movimento, desordens mentais entre outros [123].

O *EEG* é captado por sensores não invasivos localizados em torno do crânio chamados electrodos, cada electrodo capta a média das sinapses de em torno de 100 milhões até 1 bilhão de neurônios [178] do córtex, cujos dendritos estão orientados paralelamente entre eles e perpendicular á superfície, facilitando a captação do sinal[179]. A atividade registrada na realidade é o somatório de diferentes potencias que acontecem ao mesmo tempo num volume de neurônios. Este volume de sinais é suficientemente elevado para atingir os sensores localizados na superfície, ainda tendo o osso do crânio e a pele que atuam como resistores conseguindo alterar o sinal original atenuando a amplitude.

Os sinais podem ser avaliados no domínio do tempo ou da frequência. Com o primeiro é possível determinar variações de potencial quando um evento cognitivo acontecer (*ERP*), entanto no domínio da frequência podem ser analisados as oscilações em diferentes bandas que proporcionam maiores informações sobre o comportamento da onda. Pode-se ver por exemplo que ações motoras geram variações na banda alfa (18-26 Hz) conhecida como Mu (μ) [180]. Os sistemas *BCI* trabalham com estes tipos de variações identificando eventos relacionados com a atividade

executada.

C.4.2 Atividades rítmicas do *EEG*

Tem-se diferentes teorias indicando as possíveis causas das diversas oscilações que podem ser encontradas no *EEG* quando se faz um análise dos ritmos (variações do sinal em certas bandas de frequência) predominantes no seu comportamento. Têm-se evidência que estes ritmos podem ser causados pelas interações entre as redes corticais e do tálamo que se encontra mais profundamente no cérebro. Segundo Steriade [181] pesquisas efetuadas em animais, mostraram que no tálamo surgem as oscilações denominadas alfa (α) e beta (β), delimitadas na banda dos 1.5 até 12.5 Hz que ativam a atividade no córtex, também é responsável pela geração das ondas delta (δ) (1-4 Hz). As interações entre o córtex e o tálamo durante o processamento da informação podem gerar oscilações de alta frequência (13-30 Hz). Outras teorias, apontam ao número de neurônios que são ativados, sendo as altas frequências resultado da ativação de regiões neurais pequenas, enquanto as baixas frequências são originadas de ativações que envolvem maior número de neurônios [182]. Centenas de pesquisadores evidenciam a correlação das oscilações neurais do cérebro com múltiplas funções cognitivas que incluem processamento sensorial [183], percepção [184], processos cognitivos [185] e movimento [186].

A pesar de tudo, existem ainda dúvidas acerca da origem destes sinais e seu significado fisiológico [123], porém não deixam de ser uma fonte de informação que permite a cientistas entender as complicadas regras de funcionamento do cérebro.

Os ritmos *EEG* são altamente complexos e possuem um comportamento aleatório e não estacionário (Figura C.8). Estes ritmos são distintos entre indivíduos, e também mudam ao longo da vida, variando tanto a intensidade como a banda predominante de acordo com a idade. Os ritmos *EEG* se encontram divididos em cinco grandes grupos: *alfa*, *beta*, *delta*, *gamma* e *teta*, nominados segundo eram descobertos, cada ritmo trabalha uma banda da frequência, e muda em amplitude, reduzindo-se na medida que a frequência do sinal aumenta de 10 até 100 μV [179]. Abaixo, estes ritmos são descritos em maior detalhe, apresentando algumas características:

- **Ritmo Alfa**

Atividade *EEG* mais prominente se encontra na faixa dos 8-13 Hz. Ela é a frequência dominante nos adultos [187], possui uma amplitude entre 10 e 45 μV , é visível facilmente em períodos de repouso com olhos fechados. Na abertura dos olhos, ela tende a diminuir, como também em atividades de concentração mental e alerta. Recentes pesquisas, relatam a diferenciação na




Figura C.8: Descrição dos ritmos EEG segundo a frequência. Adaptado de Sanei e Chambers [123]

resposta de alfa em diferentes sub bandas: o baixo alfa (8-10 Hz), o qual apresenta dessincronizações em tarefas cognitivas, o alto alfa (10-12 Hz) dessincroniza quando existem processamentos de informações sensoriais e semânticas, incremento do desempenho da memória semântica, e a expectativa a um determinado estímulo [179]. Em conjunto com o ritmo alfa, se encontra o ritmo Mu (8-15 Hz) ou (9-13)Hz, dependendo do autor, que é o nome para a frequência *alfa* que é gerada no córtex motor e na área somato sensorial, este ritmo pode ser dessincronizado com o movimento ou planejamento da mão, dedos [162] e extremidades, movimento visualizado [188], e imaginação motora [189].

• Ritmo Beta

São oscilações de baixa tensão na banda dos 13-30 Hz. É um ritmo que tende a se incrementar durante a sonolência, sonos curtos, e ativação mental (demanda de alta atenção ou vigilância) [190]. Nos adultos o *Beta* apresenta amplitudes entre os 10-20 μV . É possível que o *Beta* incremente durante atividades excitatórias e alta atenção [179]. Também se encontra associado com funções no córtex reagindo a movimentos e tato, sendo atenuada pelos movimentos voluntários, e inibições durante a imaginação motora. Outros estudos apresentam evidência do ritmo *Beta* na manutenção da força de saída em estado estável, por exemplo, para conservar a postura do corpo através de controle visual. Isto contrasta com provas que apresentam um incremento na atividade

desta banda em atividades de manter a postura após o movimento. Possivelmente *Beta* está relacionado com processo de *feedback* motor usado para recalcular as saídas ao músculo [191], segundo foi visto na secção C.1.

- **Ritmo Gama**

Acontece na banda de 36-44 Hz até maiores frequências. Está associada à atenção, excitação, reconhecimento de objetos. Também está ligado à ativação cerebral, no caso da percepção e aprendizado.[179]. Sua amplitude é baixa em comparação ao outras bandas. Responde também à estimulação sensorial, e pode indicar atividade muscular. Atividades de alta frequência (75 Hz) associadas à banda gama apresentam um incremento nas regiões sensoriais e motoras do cérebro [192].

- **Ritmo Teta**

É a classificação das atividades que acontecem na banda dos 4-7 Hz. Ele se apresenta quando emoções são expressadas, também é associado com a concentração intensa, tarefas mentais e concentração [123]. Tende-se a dessincronizar quando a banda *alfa* sincroniza [187].

- **Ritmo Delta**

São as frequências menores que 4 Hz, sendo normal em pessoas maiores de 60 anos e menores de um ano. Também se encontra em fases de sono profundo nos adultos [193], podendo ser confundidos com artefatos relativos ao movimento da cabeça [123] dada a similitude do ritmo com o movimento dos músculos ao ter ambos baixa frequência.

C.5 Electroencefalograma

A captação da atividade elétrica do cérebro envolve o uso de múltiplos eletrodos localizados separadamente e superficialmente ao redor do crânio, e um sistema *DAQ* para a amplificação e digitalização dos dados. O primeiro é necessário dada a baixa amplitude do sinal, e o segundo para facilitar a manipulação e processamento dos dados, sendo mais comuns a filtração do sinal e a eliminação de sinais anormais denominadas artefatos.

O eletrodos são discos metálicos compostos de *Ag* ou liga de *AgCl* de 3 mm de diâmetro, de alta condução e polarização nula. A impedância no contato com a




Figura C.9: Localização dos Eletrodos segundo o Sistema Internacional 10-20. Adaptado do Malmivuo e Plansey [195]

pele deve ser menor a $5k\Omega$, e devem ser monitoradas constantemente (os equipamentos oferecem visualizadores da impedância). Agentes químicos de contato são disponibilizados para reduzi-la caso aumente, e gere uma dificuldade na captação.

Os eletrodos estão organizados em torno da cabeça segundo o padrão denominado 10-20 *International System* (Sistema Internacional) (Figura C.9). O termo 10-20 faz referência à distancia entre eletrodos, distribuídos entre 10% ou 20 % da distância total entre localizações do crânio. Estas porcentagens permitem ter a mesma configuração sem importar o tamanho da cabeça, e garantem uma localização correspondente com as regiões corticais do cérebro [194]. Os pontos de referência usados para posicionar os eletrodos são o *Nasion* (na frente do nariz) e o *Inion* (ponto mais baixo do crânio) e o ponto pré auricular (localizado sobre a orelha). Os eletrodos são classificados segundo a posição em relação à cabeça. A letra F é usada para os pontos localizados na parte *Frontal*, C na parte *Central*, T na parte *Temporal* e os lados, P para a parte *Posterior* e O para os localizados na área *Occipital* (zona inferior da área posterior da cabeça). Sendo a distribuição simétrica, uma numeração é usada para diferenciar os eletrodos do hemisfério direito (ímpar) do esquerdo (par). A letra Z identifica eletrodos localizados no centro da cabeça entre o *Nasion* e o *Inion*.

Alguns artefatos são associados à movimentação da cabeça que levam a mudanças da área de contato, reduzindo o campo estático entre o eletrodo e a cabeça [196]. Por tanto opções de segurança são disponíveis como as tocas elásticas, que facilitam a locação segundo os sistema 10-20. O número de eletrodos pode aumentar segundo

o fabricante e são localizados entre os eletrodos, em espaços equidistantes seguindo a distribuição do padrão [123]. Um maior número deles leva a uma maior resolução espacial melhorando a captação do sinal, tem-se configurações de até 256 canais espalhados na cabeça. A referência do sinal é localizada nos lóbulos das orelhas (A_1 , A_2). Todo sinal captado nos outros canais é a média dos sinais relativas aos referenciais. Os lóbulos são escolhidos por não ter um músculo diretamente associado à parte e receber uma menor quantidade de atividade cerebral do córtex[177].

C.5.1 Preprocessamento do Sinal

Entende-se o preprocessamento como os passos efetuados no sinal prévios à análise do sinal *OFF-LINE*. Estes procedimentos, não envolvem a perda de informação importante mas sim, no melhoramento do sinal para facilitar os passos seguintes no análise a extração de características e a classificação. Sendo o *EEG* um sinal de baixa amplitude, ele precisa ser amplificado através dos equipamentos *DAQ*, digitalizada e finalmente filtrado. Sinais de baixa frequência (0.5 Hz) são eliminados com filtros passa altos, entretanto o ruído de alta frequência é eliminado com filtros passa baixo com um corte que pode ir dos 50 até 70 Hz [123]. O *EEG* possui uma alta resolução com variações de estados da ordem dos milissegundos, porém uma alta frequência de amostragem permite captar essas mudanças. É comum encontrar frequências de amostragem que oscilam entre os 250 até 2000 *amostras/seg.*. Esta frequência deve ser pelo menos o duplo da frequência máxima ao ser analisada, segundo o Teorema de Amostragem de Shannon [197].

Os artefatos mais comuns a serem eliminados são a onda com frequência de 60 Hz (50 Hz segundo a tensão elétrica) própria dos equipamentos elétricos e o ruído dos equipamentos. Movimentos musculares também podem interferir no sinal. O fechamento dos olhos, movimentos da cabeça, respiração e o batimento cardíaco são exemplos de artefatos que devem ser removidos no pós-processamento.

EEGLAB é um pacote de *MATLAB* especializado no análise de sinais *EEG*. Com ele sinais de múltiplos canais podem ser tratados ao mesmo tempo, sua interface é útil na identificação dos artefatos, segmentação do sinal e a eliminação manual de artefatos, ou através de ferramentas matemáticas mais avançadas como o *Independent Component Analysis (ICA)* que separa os múltiplos sinais em componentes que são fontes de variância nos dados. Em um sinal conformado por um somatório de fontes com diferentes pesos, o *ICA* consegue isolá-las, e em seguida por inspeção pode-se eliminar aqueles componentes que estão associados aos artefatos (P. Ex. componentes com picos de alta amplitude são associados a movimentos dos músculos oculares). Depois o sinal sem aquelas perturbações é reconstruído, o sinal resultante mantém as características iniciais sem as variações correspondentes dos

artefatos.

O ruído do sinal também pode ser eliminado via *ICA* mas, por ter variâncias próximas com o *EEG*, pode ser confundido levando à danificação do sinal. O ruído pode ser eliminado por outras alternativas como o *SIGNAL AVERAGING* que é a média do sinal sobre n repetições, supondo que os padrões que são repetitivos possuem distribuições similares. Este procedimento elimina valores que não são constantes prevalecendo aqueles componentes comuns ao longo das repetições. Ao diminuir a influência do ruído tem-se um aumento da relação sinal ruído (*SNR* pelas siglas em inglês).

C.6 Descrição da atividade elétrica

O *EEG* após pré-processamento apresenta múltiplas características no sinal relativas às atividades cognitivas que o cérebro executa. Entre elas, encontra-se a variabilidade da tensão elétrica, fluando entre potenciais positivos e negativos, picos na tensão, e processos de baixa atividade neural. Atividades como a movimentação voluntária, o planejamento, a concentração ativam estas eventos, ocasionando flutuações no potencial elétrico dos neurônios. Estas manifestações podem ser similares para o mesmo evento. Contudo os efeitos do ruído próprio da leitura do *EEG* podem mudar significativamente a variância do sinal, sendo necessário eliminá-lo, mudando a distribuição e conseguindo um sinal que é a manifestação constante entre as repetições, descrevendo-a como o comportamento que tem o cérebro após o estímulo, Assim identificá-los é uma ferramenta útil para a detecção de processos cognitivos associados aos eventos que os desencadeiam.

C.6.1 ERP

Entende-se o *ERP* (*Event Related Potential*) como a resposta dos múltiplos neurônios piramidais localizados no córtex após uma sinapse consequente de uma atividade aferente [120]. Os *ERP* são determinados através da média das repetições, cancelando as pequenas flutuações positivas e negativas causadas pelo ruído, aumentando a *SNR* do sinal resultante. O *ERP* é determinado como o sinal *EEG* no domínio do tempo e é expressado em μV . Os *ERP* fornecem informação de como o cérebro humano processa normalmente a informação. Sua capacidade de extrair morfologias associadas a processos cognitivos permite incluir a determinação da existência de padrões anormais de ordem neurológica ou psiquiátrica [198].

O *ERP* é calculado seguindo a fórmula [120]:

$$ERP_j = \frac{1}{N} \sum_{i=1}^N x_{(i,j)} \quad (C.1)$$

Onde N , é o número total de testes, $x_{(i,j)}$ é a j -ésima amostra do i -ésimo trial.

Na Figura C.10 se ilustra o *ERP* resultante de acordo com o número de repetições (um total de 56 testes). Na medida que aumenta o número de medidas do sinal seu potencial e forma se reduz, contudo depois do teste 31 a variação é menor, implicando que o sinal mais frequente ao longo da prova foi encontrado.

Dado o prevalecimento das morfologias o *ERP* permite a detecção de deflexões de potencial que são características na resposta a um estímulo. Estas deflexões podem ser divididas em duas classes, segundo a direção do desvio: positivas (P) e negativas (N). E são catalogadas segundo o tempo (em milissegundos) em que se apresentam são exemplos a *P100*, *N100*, *P200* e *P300*.

- ***P300***

São denominados *P300* todos aqueles estímulos positivos que acontecem no intervalo 250-400 ms, respondem a estímulos que são seguidos de ações cognitivas motoras [197], e podem variar em amplitude, latência e área de locação [123].

C.6.2 Eventos *time-locked* e *phase-locked*

Quando um estímulo surge o *EEG* apresenta alterações no domínio do tempo e da frequência. Estas alterações podem não ser constantes se o estímulo é apresentado de novo. Um evento é *time-locked* quando apresenta as mesmas alterações (padrões) após se apresentar o estímulo ($t = 0$) em um espaço de tempo similar. Ser *non-time-locked* quer dizer que aquelas alterações se apresentam em tempos distintos para cada momento em que o estímulo se apresente. Um exemplo de *time-locked* é o *ERP* resultante após de N repetições. O sinal manifestado é um conjunto de eventos que se apresentam similarmente em cada iteração.

Um sinal é *phase-locked* unicamente se apresentar o mesmo ângulo de fase após o estímulo. Se o sinal é *non-phase-locked*, a resultante do somatório dos sinais do *ERP* vai tender a zero [177] porque, a cada iteração o *EEG* vai apresentar uma resposta angular distinta o que pode levar a que elas se anulem durante o cálculo da média. Cohen [177] cita que o *ERP* reflete as atividades *phase-locked* e *time-locked* dado que são sinais que conservam sua estrutura ao longo das repetições.

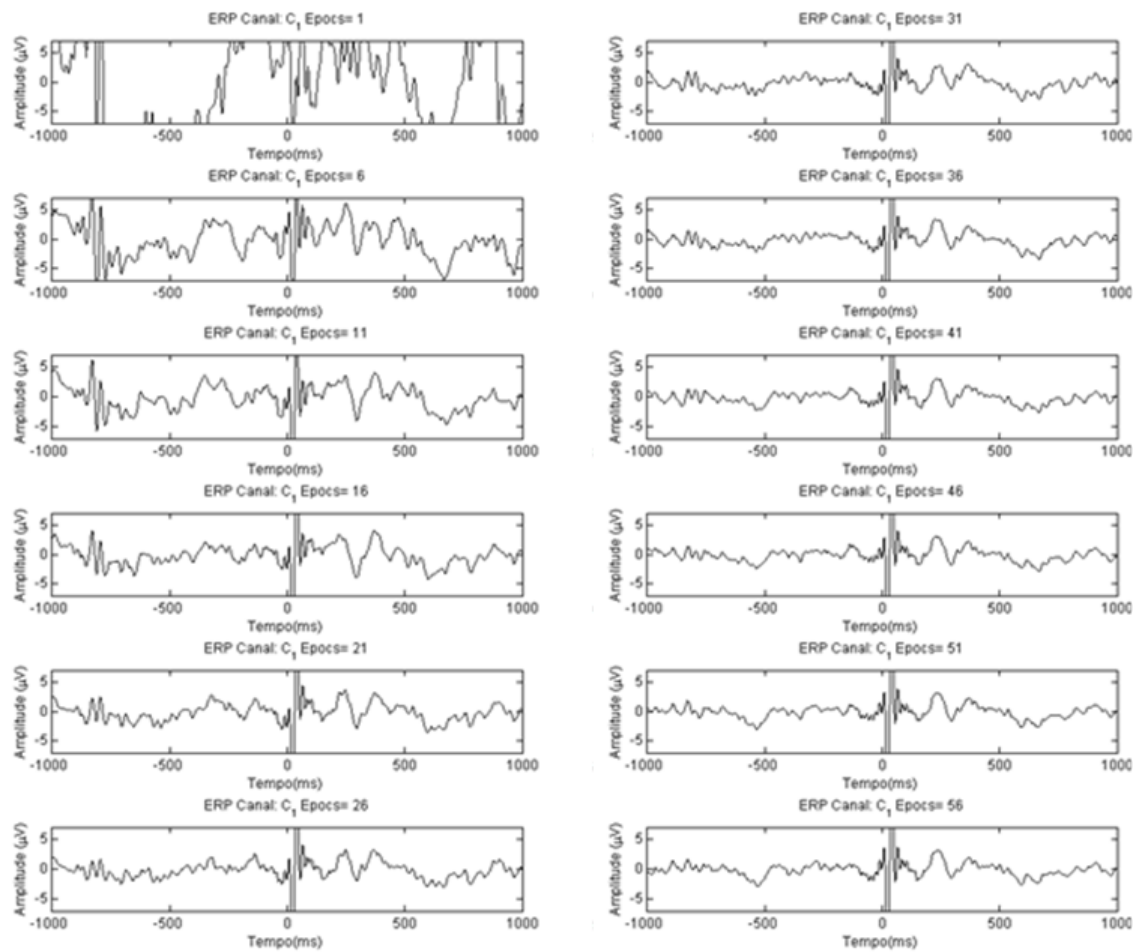


Figura C.10: *ERP* resultante no movimento do braço direito no Canal C_1 . Variando de 1 a 56 repetições. O sinal encontra o padrão característico após de 30 repetições. Fonte Autor.

C.6.3 Sincronização/Dessincronização Relacionada a Eventos

A Sincronização ou Dessincronização Relacionada a Eventos (*ERS*, *ERD* pelas siglas em inglês) são entendidas como a relação da mudança da energia média do sinal numa banda específica em relação a um período específico de tempo [199]. Estas comparações descrevem portanto, aumentos (*ERS*) ou diminuições (*ERD*) do potencial elétrico no domínio do tempo relativo ao referencial. O *ERD/ERS* é usado quando existirem eventos que não são visíveis no *ERP*. Segundo Pfurtscheller e Silva [120], certos eventos que são *time-locked*, podem dessincronizar a atividade na banda alfa mais não necessariamente são *phase-locked*, é dizer, quando o *ERP* é calculado, estas oscilações podem se zerar e não ser visíveis no resultado; sendo invisíveis no domínio do tempo, podem ser detectados no domínio da frequência, apresentando-se como uma variação numa banda específica. Para resumir, o *ERD/ERS* permite a detecção da atividade cognitiva relacionada ao evento que consiste em decrementos ou incrementos da potência em uma banda específica da frequência do *EEG*.

Na figura C.11 descreve-se os passos para determinar o ERD/ERS segundo Pfurtscheller, da Silva e Aranibar [120],[200]. Estes passos são: 1) Filtragem do sinal *EEG* após pré-processamento na banda a avaliar; 2) cálculo do quadrado do sinal (potência instantânea) para eliminar sinais negativos e; 3) média dos sinais obtidos (Equação C.2); 4). Estimação da potencia relativa a um intervalo de referência (Equação C.3 e C.4).

$$P_j = \frac{1}{N} \sum_{i=1}^N x_{(i,j)}^2 \quad (\text{C.2})$$

Onde N é o número total de testes, $x_{(i,j)}$ é a j -ésima amostra do i -ésimo trial.

$$ERD_j = \frac{R - A_j}{R} \times 100\% \quad (\text{C.3})$$

$$R = \frac{1}{k} \sum_{j=n_0}^{n_0+k} A_j \quad (\text{C.4})$$

Onde R é a potência média do intervalo de referência, promediado sobre um número k de amostras. E A_j é a potência na j -ésima amostra ou conjunto de amostras.

Os *ERD/ERS* acontecem em todas as bandas (Seção C.4.2), com resultados distintos para cada uma. Segundo Pfurtscheller e Silva [120], as redes neurais podem apresentar diferentes estados de sincronismo (quando n neurônios apresentam um PA ao mesmo tempo), com oscilações em diferentes frequências. Estes potenciais podem refletir mudanças nas atividades das interações locais que acontecem entre

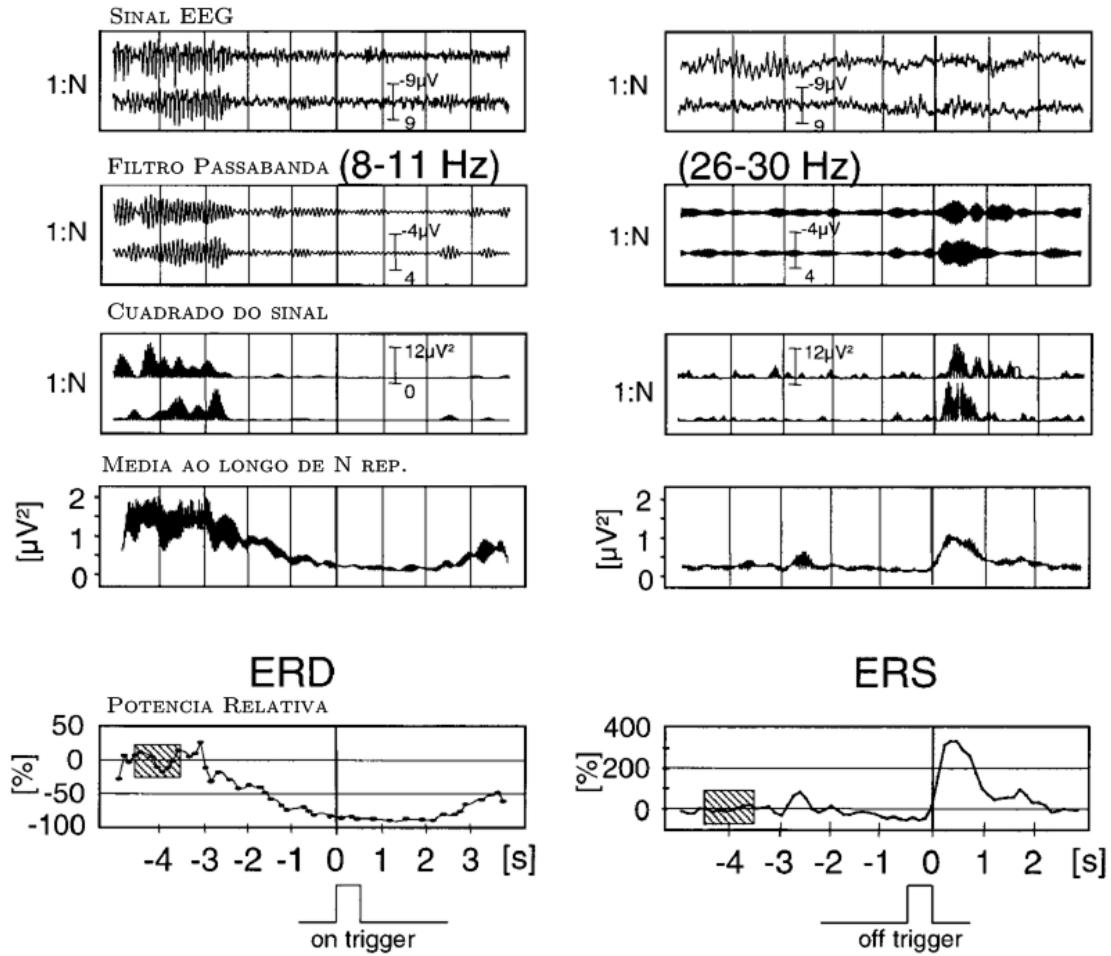


Figura C.11: Passos para a obtenção do ERD/ERS. Adaptado de Pfurstcheller e Silva [120]

neurônios e interneurônios (neurônios pequenos que interconectam outros neurônios do Sistema Nervoso Central) que controlam os componentes de frequência do *EEG* resultante.

OS *ERD/ERS* também são manifestados durante a movimentos reais e imaginários [201], [162]. Podem ser vistos nas bandas Mu e Beta na área Sensoriomotora do cérebro, produzindo padrões úteis para sistemas *BCI*.