

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

JULIET SÁNCHEZ GALEGO

**AQUISIÇÃO E PROCESSAMENTO DE BIOSINAIS DE
ELETROMIOGRAFIA DE SUPERFÍCIE E
ELETROENCEFALOGRAFIA PARA CARACTERIZAÇÃO DE
COMANDOS VERBAIS OU INTENÇÃO DE FALA
MEDIANTE SEU PROCESSAMENTO MATEMÁTICO EM
PACIENTES COM DISARTRIA**

Porto Alegre

(2016)

JULIET SÁNCHEZ GALEGO

**AQUISIÇÃO E PROCESSAMENTO DE BIOSINAIS DE
ELETROMIOGRAFIA DE SUPERFÍCIE E
ELETROENCEFALOGRAFIA PARA CARACTERIZAÇÃO DE
COMANDOS VERBAIS OU INTENÇÃO DE FALA
MEDIANTE SEU PROCESSAMENTO MATEMÁTICO EM
PACIENTES COM DISARTRIA**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, da Universidade Federal do Rio Grande do Sul, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Engenharia de Controle e Automação - Instrumentação.

ORIENTADOR: Prof. Dr. Alexandre Balbinot

Porto Alegre

(2016)
JULIET SÁNCHEZ GALEGO

**AQUISIÇÃO E PROCESSAMENTO DE BIOSINAIS DE
ELETROMIOGRAFIA DE SUPERFÍCIE E
ELETROENCEFALOGRAFIA PARA CARACTERIZAÇÃO DE
COMANDOS VERBAIS OU INTENÇÃO DE FALA
MEDIANTE SEU PROCESSAMENTO MATEMÁTICO EM
PACIENTES COM DISARTRIA**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Elétrica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: _____

Prof. Dr. Alexandre Balbinot, UFRGS
Doutor pela UFRGS – Porto Alegre, Brasil

Banca Examinadora:

Prof. Dr. Léia Bernardi Bagesteiro, UFABC
Doutora pela University of Surrey – Surrey, Inglaterra

Prof. Dr. Altamiro Amadeu Susin, UFRGS
Doutor pela Institut National Polytechnique de Grenoble – Grenoble, França

Prof. Dr. Alexandre Simões Dias, HCPA
Doutor pela Universidade Federal de Rio Grande do Sul – Porto Alegre, Brasil

Prof. Dr. Alexandre Rosa Franco, PUCRS
Doutor pela University of New Mexico – New Mexico, Estados Unidos

Coordenador do PPGEE: _____

Prof. Dr. Luís Fernando Alves Pereira

Porto Alegre, Abril de 2016.

DEDICATÓRIA

Dedico principalmente este trabalho a minha mãe, pela sua luta constante e apoio. Por me ajudar a sair de todos os meus "fracasos" e por me celebrar e me louvar nas minhas conquistas, sem a sua dedicação, nada teria sido possível, muito obrigada mamãe.

A meu parceiro na vida Omar e meu colega de profissão, para você eu dedico esta pesquisa, seu apoio exclusivo, a sua preocupação em todos os meus resultados e acima de tudo por seu amor e compreensão em todos os momentos.

AGRADECIMENTOS

Quero agradecer a meu Professor orientador Alexandre Balbinot, sem cujos conselhos e sugestões em todo o meu tempo como uma estudante no Programa de Pós-Graduação em Engenharia Elétrica – PPGEE, não teria concluído este trabalho. Por sua paciência e orientação constante que demonstrou sempre na revisão deste documento.

Ao Programa de Pós-Graduação em Engenharia Elétrica, PPGEE, pela oportunidade de realização de trabalhos em minha área de pesquisa.

Aos colegas do PPGEE pelo seu auxílio nas tarefas desenvolvidas durante o curso e apoio na revisão deste trabalho, em especial aos colegas do Laboratório de Instrumentação Eletro-Eletrônica – IEE.

Ao Doutor Alexandre Simões Dias, Chefe do Serviço de Fisioterapia - Hospital de Clínicas de Porto Alegre – HCPA, por abrir as portas de seu departamento para o Laboratório IEE, por meio deste trabalho.

Meus agradecimentos à Fisioterapeuta Daniele Rossato, do Serviço de Fisioterapia – HCPA, pela sua dedicação, no atendimento com as coletas dos voluntários com Disartria pós AVC.

Aos professores da UFRGS por ter contribuído cada um em seu momento como complemento na minha formação como Mestre em Engenharia Elétrica.

Finalmente quero agradecer a cada uma das pessoas que me passaram sabedoria, força e positividade; a todos em geral:

Obrigada

RESUMO

Sistemas para assistência de pessoas com sequelas de Acidente Vascular Cerebral (AVC) como, por exemplo, a Disartria apresenta interesse crescente devido ao aumento da parcela da população com esses distúrbios. Este trabalho propõe a aquisição e o processamento dos biosinais de Eletromiografia de Superfície (sEMG) no músculos do rosto ligados ao processo da fala e de Eletroencefalografia (EEG), sincronizados no tempo mediante um arquivo de áudio. Para isso realizaram-se coletas em voluntários saudáveis no Laboratório IEE e com voluntários com Disartria, previamente diagnosticados com AVC, no departamento de Fisioterapia do Hospital de Clínicas de Porto Alegre. O objetivo principal é classificar esses biosinais frente a comandos verbais estabelecidos, mediante o método computacional *Support Vector Machine* (SVM) para o sinal de sEMG e *Naive Bayes* (NB) para o sinal de EEG, visando o futuro estudo e classificação do grau de Disartria do paciente. Estes métodos foram comparados com o *Linear Discriminant Analysis* (LDA), que foi implementado para os sinais de sEMG e EEG. As características extraídas do sinal de sEMG foram: desvio padrão, média aritmética, *skewness*, *kurtosis* e RMS; para o sinal de EEG as características extraídas na frequência foram: Mínimo, Máximo, Média e Desvio padrão e *Skewness* e *Kurtosis*, no domínio do tempo. Como parte do pré-processamento também foi empregado o filtro espacial *Common Spatial Pattern* (CSP) de forma a aumentar a atividade discriminativa entre as classes de movimento no sinal de EEG. Foi avaliado através de um Projeto de Experimentos Fatorial, a natureza das coletas, o sujeito, o método computacional, o estado do sujeito e a banda de frequência filtrada para EEG. Os comandos verbais definidos: “Direita”, “Esquerda”, “Para Frente” e “Para Trás”, possibilitaram a identificação de tarefas mentais em sujeitos saudáveis e com Disartria, atingindo-se *Accuracy* de 77,6% - 80,8%.

Palavras-chave: Eletromiografia. Eletroencefalografia. Tecnologia Assistiva. Redes Bayesianas. *Support Vector Machine*.

ABSTRACT

Assistive technology for people with Cerebrovascular Accident (CVA) aftereffects, such as Dysarthria, is gaining interest due to the increasing proportion of the population with these disorders. This work proposes the acquisition and processing of Surface Electromyography (sEMG) signal from the speech process face muscles and Electroencephalography (EEG) signal, synchronized in time by an audio file. For that reason assays were carried out with healthy volunteers at IEE Laboratory and with dysarthric volunteers, previously diagnosed with CVA, at the physiotherapy department of the Porto Alegre University Hospital. The main objective is to classify these biosignals in front of verbal commands established, by computational method of Support Vector Machine (SVM) for the sEMG and Naive Bayes (NB) for EEG, regarding the future study and classification of patient degree of Dysarthria. These methods were compared with Linear Discriminant Analysis (LDA), who was implemented for sEMG and EEG. The extracted features of sEMG signal were: standard deviation, arithmetic mean, skewness, kurtosis and RMS; for EEG signal extracted features in frequency domain were: minimum, maximum, average and standard deviation, skewness and kurtosis, were used for time domain extraction. As part of pre-processing, Common Spatial Pattern (CSP) filter was also employed, in order to increase the discriminating activity between motion classes in the EEG signal. Data were evaluated in a factorial experiment project, with nature of assays, subject, computational method, subject health state and specifically for EEG were evaluated frequency band filtered. Defined verbal commands, "Right", "Left", "Forward" and "Back", allowed the identification of mental tasks in healthy subjects and dysarthric subjects, reaching Accuracy of 77.6% - 80.8%.

Keywords: Electromyography. Electroencephalography. Assistive technology. Bayesian Networks. Support Vector Machines.

SUMÁRIO

1	INTRODUÇÃO.....	17
1.1	JUSTIFICATIVA	18
1.2	OBJETIVOS	19
2	A LINGUAGEM HUMANA.....	20
2.1	FONÉTICA E A ARTICULAÇÃO TEMPOROMANDIBULAR: SUA INFLUÊNCIA NA AÇÃO DA FALA	20
2.2	OS MÚSCULOS FACIAIS ENVOLVIDOS NO MOVIMENTO MANDIBULAR E NA FALA	23
2.3	A ARTICULAÇÃO DA FALA E SUA CONEXÃO COM O CÉREBRO HUMANO	26
2.4	O ACIDENTE VASCULAR CEREBRAL	30
2.5	A DISARTRIA	31
3	CARACTERÍSTICAS BÁSICAS SOBRE OS BIOSINAIS DE ELETROMIOGRAFIA E ELETROENCEFALOGRAFIA.....	32
3.1	CONCEITOS BÁSICOS SOBRE BIOSINAIS DE SEMG E DE EEG.....	32
3.2	<i>SUPPORT VECTOR MACHINE</i> E INTERFACE HOMEM-COMPUTADOR	36
3.3	REDES BAYESIANAS E INTERFACE HOMEM-COMPUTADOR.....	41
3.4	DISCRIMINANTE LINEAR DE FISHER E INTERFACE HOMEM-COMPUTADOR.....	43
3.5	MÉTODO DA TRANSFORMADA DISCRETA <i>WAVELET</i> (DWT) PARA EXTRAÇÃO DE CARACTERÍSTICAS NO SEMG	44
3.6	ÍNDICE DE LATERALIZAÇÃO NO SINAL DE EEG	46
3.7	FILTRO ESPACIAL CSP PARA EEG.....	47
3.8	MÉTODO DO PERIODOGRAMA MODIFICADO DE WELCH PARA EXTRAÇÃO DE CARACTERÍSTICAS NO EEG	51
4	METODOLOGIA EXPERIMENTAL.....	53
4.1	METODOLOGIA USADA E DESCRIÇÃO DA AMOSTRA.....	54
4.1.1	Técnicas e procedimentos de coleta de dados	55
4.1.2	Interface para captura e sincronismo dos sinais	57
4.2	POSICIONAMENTO DOS ELETRODOS PARA CAPTAÇÃO DE SEMG E DE EEG	60
4.3	PROCESSAMENTO DOS SINAIS DE SEMG E DE EEG	61
4.3.1	NORMALIZAÇÃO E FILTRAGEM DOS SINAIS DE SEMG E DE EEG	62
4.3.2	SEGMENTAÇÃO DOS SINAIS DE SEMG E DE EEG	68
4.4	EXTRAÇÃO DAS CARACTERÍSTICAS DE SEMG E DE EEG	73
4.4.1	EXTRAÇÃO DE CARACTERÍSTICAS PELO MÉTODO DA TRANSFORMADA DISCRETA <i>WAVELET</i> (DWT) PARA SEMG.....	75
4.4.2	EXTRAÇÃO DE CARACTERÍSTICAS PARA SINAL DE EEG	79
4.4.2.1	Procedimento de obtenção da Energia Média do sinal de EEG.....	80
4.4.2.2	Procedimento para obtenção do Índice de Lateralização do sinal de EEG	81

4.4.2.3	Procedimento para obtenção do Periodograma de Welch e extração de Características do EEG.....	82
4.5	IMPLEMENTAÇÃO DO MÉTODO <i>SUPPORT VECTOR MACHINE</i> DO SINAL DE SEMG	85
4.6	IMPLEMENTAÇÃO DO MÉTODO <i>NAIVE BAYES</i> DO SINAL DE EEG.....	86
4.7	MATRIZ DE CONFUSÃO	87
4.8	OBTENÇÃO DA <i>ACCURACY</i> E CLASSIFICAÇÃO FINAL.....	89
4.9	EXPERIMENTO PROJETADO PARA AVALIAÇÃO DOS MÉTODOS MATEMÁTICOS	89
5	RESULTADOS E DISCUSSÕES	94
5.1	RESULTADOS DA ANÁLISE DE ENERGIA MÉDIA DO SINAL DE EEG.....	100
5.2	RESULTADOS DA ANÁLISE DO ÍNDICE DE LATERALIZAÇÃO DO SINAL DE EEG	104
5.3	RESULTADOS DO PROJETO DE EXPERIMENTOS PARA SINAL DO SEMG	106
5.4	RESULTADOS DOS PROJETOS DE EXPERIMENTOS PARA O SINAL DO EEG.....	111
5.5	RESULTADOS DA CLASSIFICAÇÃO COM SINAIS DE SEMG E EEG	119
5.6	DISCUSSÃO E COMPARAÇÃO COM OUTROS TRABALHOS	120
6	CONCLUSÕES	122
7	PROPOSTA PARA TRABALHOS FUTUROS.....	124
	REFERÊNCIAS	126
	ANEXOS	140
	ANEXO A - PRINCIPAIS MÚSCULOS SUPERFICIAIS DA BOCA QUE INFLUENCIAM NA FALA. .	140
	ANEXO B - DOMÍNIO DISARTRIA DA ESCALA DE AVC.....	141
	ANEXO C - TERMO DE COMPROMISSO LIVRE E ESCLARECIDO.....	142
	ANEXO D - SINAIS DE SEMG OBTIDAS PARA OS QUATRO COMANDOS VERBAIS	145
	ANEXO E - SINAIS DE EEG OBTIDAS PARA OS QUATRO COMANDOS VERBAIS	152

LISTA DE ILUSTRAÇÕES

Figura 1 Principais estruturas internas da Cavidade Oral (adaptado de ADAM, 1997).	21
Figura 2 (a) Movimento de oclusão, (b) Movimento de retensão, (c) Movimento de protusão (adaptado de ALMEIDA, 2011; WU et al., 2014; RABINER & JUANG, 1993)...22	
Figura 3 (a) Músculos faciais vista anterior e (b) Músculos faciais vista lateral (adaptado de ADAM, 1997).	24
Figura 4 Localização dos Lobos do Cérebro Humano (adaptado de ADAM, 1997).	26
Figura 5 Visualização do Córtex motor primário ou área de Brodmann, junto com outras áreas do cérebro que intervierem no processo da fala (adaptado de GUYTON & HALL, 2006; CORTICAL FUNCTIONS REFERENCE, 2012).	28
Figura 6 Representação de Hiperplano de Máquina de Suporte de Vetores (adaptado de DUDA & HART, 2000).	38
Figura 7 Função de escala à esquerda e Função Wavelet a direita para tipo Daubechies N = 8.	46
Figura 8 Fluxograma com descrição passo a passo do algoritmo para obtenção e aplicação do filtro CSP.	50
Figura 9 Diagrama de Bloco do Sistema Experimental Proposto.	53
Figura 10 Foto de um dos ensaios realizados com voluntários saudáveis.	55
Figura 11 Foto de um dos ensaios com voluntários com Disartria pós AVC.	56
Figura 12 Tela do código implementado no Simulink versão R2010b para captura dos sinais de sEMG, EEG e Áudio.	57
Figura 13 Exemplo dos sinais captados sincronizados (comando “Para frente”, falado): (a) Sinal de áudio, (b) Sinal de sEMG e (c) Sinal de EEG.	59
Figura 14 Imagem (a) Posicionamento dos eletrodos de sEMG na face e (b) Posição dos eletrodos de EEG segundo o Sistema 10-20 da touca EMOTIV. Figura (b) adaptada de (EKANAYAKE, 2011).	60
Figura 15 Fluxograma primário para processamento dos sinais na preparação para a classificação.	61
Figura 16 Pre-processamento do sinal de sEMG: (a) Sinal bruto, (b) Sinal sem a componente offset ou sinal DC, (c) Sinal filtrado em frequência e (d) Sinal normalizado pronto para Segmentação.	63
Figura 17 Diagrama de Blocos da função de filtragem, remoção de offset e normalização.	64
Figura 18 Espectro do sinal de sEMG (a) antes da filtragem e (b) depois da filtragem.	65
Figura 19 Pre-processamento do sinal de EEG, (a) Sinal bruto, (b) Sinal sem a componente DC, (c) Sinal filtrado em frequência e (d) Sinal normalizado pronto para Segmentação.	66
Figura 20 Espectro do sinal de EEG (a) antes da filtragem e (b) depois da filtragem.	67
Figura 21 Diagrama de Blocos da função de segmentação.	68
Figura 22 Diagrama de Blocos da função do método da potência.	69
Figura 23 Segmentação para sujeito saudável, (a) Sinal de Áudio, (b) segmento do sinal de sEMG com marca em vermelho do intervalo temporal selecionado e (c) primeiro intervalo segmentado ou trilha de 10 s, contendo o possível MUAP.	70

Figura 24	Segmentação para sujeito saudável, (a) Sinal de Áudio, (b) segmento do sinal de EEG com marca em vermelho do intervalo temporal selecionado e (c) primeiro intervalo segmentado ou trilha de 7 s, contindo o efeito da tarefa mental.	71
Figura 25	Segmentação para paciente disártrico Grau 2, (a) Sinal de Áudio, (b) segmento do sinal de sEMG com marca em vermelho do intervalo temporal selecionado e (c) primeiro intervalo segmentado ou trilha de 10 s, contindo o possível MUAP.....	72
Figura 26	Segmentação para paciente disártrico Grau 2, (a) Sinal de Áudio, (b) segmento do sinal de EEG com marca em vermelho do intervalo temporal selecionado e (c) primeiro intervalo segmentado ou trilha de 7 s, contindo o efeito da tarefa mental.	73
Figura 27	Fluxograma do método computacional para classificação de padrões da fala.	74
Figura 28	Diagrama de Blocos da função para extração de características no sinal de sEMG.	77
Figura 29	Decomposição de segmentos de sEMG pelo método de DWT para (a) um sujeito saudável e para (b) um paciente com Disartria Grau 2.....	78
Figura 30	Diagrama em bloco da recomposição dos canais de EEG e filtragem CSP.....	79
Figura 31	Diagrama de blocos do algoritmo de cálculo da Energia Média para cada classe... 80	
Figura 32	Curvas de Energia Média no tempo para o canal do lóbulo Esquerdo P7 (em cor azul) e lóbulo Direito P8 (em cor verde). Teste pensado de sujeito saudável, filtragem banda μ , (a) para trilha de comando “Direita” e (b) para trilha de comando “Esquerda”.....	81
Figura 33	Diagrama de blocos do algoritmo de cálculo do Índice de Lateralidade.....	81
Figura 34	Índice de Lateralização para canais de EEG estudados para comando lateral “Direita” em sujeito saudável, com filtragem nas bandas μ e β	82
Figura 35	Diagrama de blocos do algoritmo de segmentação pelo método do Periodograma de Welch.....	82
Figura 36	Diagrama de blocos do algoritmo de implementação do classificador SVM para processamento do sinal de sEMG.....	85
Figura 37	Diagrama de blocos do algoritmo de implementação do classificador NB para processamento do sinal de EEG.	86
Figura 38	Fluxograma do algoritmo de obtenção das matrizes de confusão.	88
Figura 39	Sinais de ativação para sEMG para os 7 músculos (canais) medidos na face de um voluntário saudável (na ordem descendente: Masseter Direito, Zigomático Direito, Depressores Direitos, Platisma, Masseter Esquerdo, Zigomático Esquerdo, Depressores Esquerdos). Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	94
Figura 40	Sinais de ativação do sinal de sEMG para os 7 músculos (canais) medidos na face de um voluntário com Disatria (na ordem descendente: Masseter Direito, Zigomático Direito, Depressores Direitos, Platisma, Masseter Esquerdo, Zigomático Esquerdo, Depressores Esquerdos). Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	95
Figura 41	Sinais de ativação do sinal de EEG para os 2 canais medidos no escalpo de um voluntário saudável. Ativação ante (a) Comando ‘Direita’ e (b) Comando ‘Esquerda’, para (parte superior) os canais P7 – P8 e para (parte inferior) os canais FC5 – FC6. Sinal de ativação (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’, para (parte superior) os canais FC5 – P7 e para (parte inferior) os canais FC6 – P8. Em cores se diferencia os canais de lóbulos opostos analisados em cada caso.	96

Figura 42	Sinais de ativação do sinal de EEG para os 2 canais medidos no escalpo de um voluntário com Disatria. Ativação ante (a) Comando ‘Direita’ e (b) Comando ‘Esquerda’, para (parte superior) os canais P7 – P8 e para (parte inferior) os canais FC5 – FC6. Sinais de ativação (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’, para (parte superior) os canais FC5 – P7 e para (parte inferior) os canais FC6 – P8. Em cores se diferencia os canais de lóbulos opostos analisados em cada caso.	97
Figura 43	Curvas de Energia Média no tempo para o canal do lóbulo Esquerdo P7 (em cor azul) e lóbulo Direito P8 (em cor verde). Teste pensado de sujeito saudável, filtragem banda μ , (a) para trilha de comando “Direita” e (b) para trilha de comando “Esquerda”.	98
Figura 44	Curvas de Energia Média no tempo para o canal do lóbulo Frontal FC6 (em cor azul) e lóbulo Parietal P8 (em cor verde). Teste pensado de um sujeito saudável, com filtragem na banda μ , (a) para trilha de comando “Para Frente” e (b) para trilha de comando “Para Trás”.	99
Figura 45	Curvas de Energia Média no tempo para o canal do lóbulo Esquerdo FC5 (em cor azul) e lóbulo Direito FC6 (em cor verde). Teste pensado de um sujeito doente, com filtragem na banda μ , (a) para trilha de comando “Direita” e (b) para trilha de comando “Esquerda”.	100
Figura 46	Curvas de Energia Média no tempo para o canal do lóbulo Frontal FC6 (em cor azul) e lóbulo Parietal P8 (em cor verde). Teste pensado de um sujeito doente, com filtragem na banda μ , (a) para trilha de comando “Para Frente” e (b) para trilha de comando “Para Trás”.	101
Figura 47	Índice de Lateralização para canais de EEG estudados para comando lateral “Direita” em sujeito saudável, com filtragem nas bandas μ e β .	102
Figura 48	Índice de Lateralização para canais de EEG estudados para comando lateral “Direita” em sujeito com Disartria, com filtragem nas bandas μ e β .	103
Figura 49	Índice de Lateralização para canais de EEG estudados para comando frontal “Para Frente” em sujeito saudável, com filtragem nas bandas μ e β .	103
Figura 50	Índice de Lateralização para canais de EEG estudados para comando frontal “Para Frente” em sujeito com Disartria, com filtragem nas bandas μ e β .	104
Figura 51	Histograma com tendência de distribuição normal para dados de sEMG nos 14 voluntários.	105
Figura 52	Curvas de interações entre o fator Dataset e o fator Método para o sinal de sEMG.	109
Figura 53	Curvas de interações entre o fator Dataset e o fator Comando para o sinal de sEMG.	110
Figura 54	Histograma com tendência de distribuição normal para dados de EEG nos 14 voluntários.	111
Figura 55	Curvas de interações entre o fator Dataset e o fator Método para o sinal de EEG.	113
Figura 56	Curvas de interações entre o fator Comando e o fator Método para o sinal de EEG.	114
Figura 57	Curvas de interações entre o fator Comando e o fator Dataset para o sinal de EEG.	115
Figura 58	Gráfico de interações entre o fator Dataset e o fator Natureza para sinal de EEG.	117
Figura 59	Curvas de interações entre o fator Comando e o fator Método para o sinal de EEG.	118
Figura 60	Curvas de interações entre o fator Dataset e o fator Banda para o sinal de EEG.	119
Figura 61	Resultado em barras representando a classificação com sinal de EEG (método NB) e EEG + sEMG (método NB + SVM).	120

Figura 78	Curvas do sinal de EEG do Dataset 4 para os quatro comandos verbais. Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	153
Figura 79	Curvas do sinal de EEG do Dataset 5 para os quatro comandos verbais. Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	154
Figura 80	Curvas do sinal de EEG do Dataset 6 para os quatro comandos verbais. Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	154
Figura 81	Curvas do sinal de EEG do Dataset 7 para os quatro comandos verbais. Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	155
Figura 82	Curvas do sinal de EEG do Dataset 8 para os quatro comandos verbais. Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	155
Figura 83	Curvas do sinal de EEG do Dataset 9 para os quatro comandos verbais. Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	156
Figura 84	Curvas do sinal de EEG do Dataset 11 para os quatro comandos verbais. Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	156
Figura 85	Curvas do sinal de EEG do Dataset 12 para os quatro comandos verbais. Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	157
Figura 86	Curvas do sinal de EEG do Dataset 13 para os quatro comandos verbais. Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	157
Figura 87	Curvas do sinal de EEG do Dataset 14 para os quatro comandos verbais. Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.....	158

LISTA DE TABELAS

Tabela 1. Resumo da revisão bibliográfica realizada na área de Classificadores baseados em Métodos Matemáticos aplicados ao EEG e ao sEMG.	33
Tabela 2. Características de ambos os grupos de voluntários participantes nos ensaios.	54
Tabela 3 Matriz de Confusão para os classificadores.	87
Tabela 4. Tabela de Cruzamento para Projeto de Experimentos com o sinal de sEMG.	92
Tabela 5. Tabela de Cruzamento para o primeiro Projeto de Experimentos com o sinal de EEG.	92
Tabela 6. Tabela de Cruzamento para o segundo Projeto de Experimentos com o sinal de EEG.	93
Tabela 7. Resultado do Projeto de Experimentos da variável de resposta TxC para os fatores controláveis de interesse e as suas interações no sinal de sEMG.	108
Tabela 8. Resultado do Projeto de Experimentos da variável de resposta TxC para os fatores controláveis Dataset, Método, Comando e as suas interações no sinal de EEG.	112
Tabela 9. Resultado do Projeto de Experimentos da variável de resposta TxC para os fatores controláveis Dataset, Natureza, Banda e as suas interações no sinal de EEG.	116
Tabela 10. Características dos principais Músculos Superficiais da boca que influenciam na fala (adaptado de TORTORA & GRABOWSKI, 2003).	140
Tabela 11. Escala de AVC do Domínio Disartria.	141

LISTA DE ABREVIATURAS

sEMG: Eletromiografia de Superfície

EEG: Eletroencefalografia

SVM: Máquina de Vetores de Suporte

SNC: Sistema Nervoso Central

LDA: *Linear Discriminant Analysis*

AVC: Acidente Vascular Cerebral

CSA: Comunicação Suplementar e/ou Alternativa

NB: *Naive Bayes*

ATM: Articulação Temporomandibular

DTM: Disfunções Temporomandibulares

MUAP: *Motor Unit Action Potential*

BCI: *Brain Computer Interface*

SCP: *Slow Cortical Potential*

SMR: Ritmo sensório-motor

ERP: *Event Related Potentials*

FCM: *Fuzzy C-means*

GA: *Genetic Algorithm*

ANN: *Artificial Neural Networks*

HMM: *Hidden Markov Models*

MRA: *Multiresolution Analysis*

GMM: *Gaussian Mixture Model*

BSC: *Bayesian classifier*

KNN: *K-Nearest-Neighbor*

ERD: Desincronização relacionado ao evento

ERS: Sincronização relacionada ao evento

RBF: *Radial Basis Function*

RB: Redes Bayesianas

IL: Índice de Lateralização

CSP: Common Spatial Patterns

FIR: Resposta finita ao impulso

DWT: Transformada Discreta *Wavelet*

VN: Verdadeiro Negativo

FP: Falso Positivo

FN: Falso Negativo

VP: Verdadeiro Positivo

TxC: *Accuracy*

Err: *Error Rate*

Sx: Sensitivity

Sc: *Specificity*

NIH: *National Institute of Health*

TCLE: Termo de Consentimento Livre Esclarecido

ANOVA: Análise de Variância

1 INTRODUÇÃO

A produção de um movimento pelo corpo humano implica a entrada em ação, em uma determinada ordem, de diferentes estruturas do sistema motor organizadas de forma hierárquica. O movimento pretendido envolve rotinas neurais associadas ao conjunto de padrões musculares adequados (GUYTON & HALL, 2006). Os movimentos, os gestos e a linguagem caracterizam a humanidade do homem, ou seja, são cadeias simbólicas com raízes na mesma estrutura. O impacto do simbólico no indivíduo propicia à fala e o desenvolvimento da linguagem oral e corporal (TAKAI, 2012).

Atualmente na Fonoaudiologia utilizam-se recursos que proporcionam maior autonomia para indivíduos que possuem limitações significativas de linguagem oral, como a Comunicação Suplementar e/ou Alternativa (CSA). Embora seja uma área do conhecimento ainda em consolidação no Brasil, observa-se um aumento na inclusão de estudos com foco no adulto e no idoso (CESA & MOTA, 2015).

É importante também ressaltar que existem pessoas com deficiência na fala que também apresentam deficiências psicomotoras, como por exemplo, a Tetraplegia¹, a Tetraparesia², Amputação³, Paralisia Cerebral⁴ ou o AVC agudo⁵, criando-lhes um limite maior em sua autonomia e comunicação na sua vida (TAKSANDE & PADOLE, 2014; WILLIAMS *et al.*, 2014).

Pessoas com deficiências psicomotoras e da fala, como a Disartria pós AVC, apresentam limitações significativas em sua autonomia. A Disartria é definida como uma dificuldade motora, causada por danos neurológicos, sendo caracterizados pela fala lenta, imprecisa e/ou movimentos descoordenados da musculatura da fala (YANO *et al.*, 2015). O

¹ Tetraplegia: perda total das funções motoras dos membros inferiores e superiores.

² Tetraparesia: perda parcial das funções motoras dos membros inferiores e superiores.

³ Amputação: perda total/parcial de um determinado membro ou segmento de membro.

⁴ Paralisia Cerebral: lesão de uma ou mais áreas do sistema nervoso central, tendo como consequência alterações psicomotoras, podendo ou não causar deficiência mental.

⁵ Acidente Vascular Cerebral: comprometimento súbito da função cerebral resultante de alterações na irrigação sanguínea do cérebro, causando lesão celular e danos nas funções neurológicas.

AVC é a terceira causa de morte no mundo, segundo dados da Organização Mundial de Saúde; estando associado a uma das causas mais comuns de mortes e de deficiências motoras e cognitivas em adultos (ALWAN A., 2014), sendo as doenças cardiovasculares as de maior coeficiente de mortalidade no estado de Rio Grande do Sul (66,7% - 71,4%) e no município de Porto Alegre (72,4% - 82,4%) (DATASUS, 2015). Em função disso, estudos envolvendo o uso de biosinais apresentam importância, pois tem como alvo o desenvolvimento de sistemas de tecnologia assistiva para incluir pacientes com este tipo de desordem ou doença. Vêm contribuindo para isso os paradigmas linguísticos que, embora com diferentes referências, desenvolvem meios teórico-metodológicos para explicar o funcionamento da linguagem no cérebro (LEONOR SCLIAR-CABRAL, 2009).

Sendo assim, evidencia-se a importância do estudo e da caracterização dos sinais de Eletroencefalografia (EEG) e de Eletromiografia de Superfície (sEMG) para possibilitar o desenvolvimento de sistemas não invasivos para portadores de deficiência na fala.

1.1 JUSTIFICATIVA

O movimento mandibular é um processo complexo que envolve o sistema muscular do rosto, o trato vocal e o Sistema Nervoso Central (SNC), relacionando-se à conformação das estruturas e movimentos desenvolvidos para viabilizar as diversas posturas articulatórias próprias para cada som (GUYTON & HALL, 2006, BEM & FRANCIS, 2000, MA *et al.*, 2014).

A Disartria pós AVC representa um fator negativo para o desenvolvimento motor nos pacientes que apresentam esta disfunção. A obtenção de padrões para a classificação de sinais de sEMG ou de EEG em pacientes com diferentes tipos de sequelas como a Disartria pós AVC, torna-se complexa devido à mobilidade reduzida dos mesmos. Portanto, o uso de sinais musculares da face, sincronizados com os sinais cerebrais nestes pacientes, pode ser uma

ferramenta empregada como entrada para um sistema de classificação de dados e sua saída pode ser utilizada para controlar dispositivos ou permitir a melhoria da comunicação verbal destes pacientes com o ambiente.

1.2 OBJETIVOS

O objetivo principal deste trabalho é desenvolver um sistema experimental para adquirir, extrair e classificar sinais de sEMG dos músculos da face que estão relacionados ao processo da fala com determinados comandos verbais, assim como, adquirir conjuntamente sinais de EEG relacionados aos eventos estudados com os mesmos comandos. Propiciando uma contribuição no desenvolvimento de sistemas de tecnologia assistiva para uma maior autonomia em pessoas com limitações psicomotoras como Disartria pós AVC.

Os objetivos secundários deste trabalho são:

- Avaliar os biosinais de sEMG e de EEG, em pessoas saudáveis e em pacientes com Disartria buscando padrões da fala para estabelecê-los como referência;
- Verificar a sincronização dos sinais (sEMG e EEG) no momento da aquisição, criando as bases para seu posterior processamento;
- Avaliar os métodos computacionais Máquina de Vetores de Suporte (SVM) no processamento de sEMG e o classificador *Naive Bayes* (NB) para o processamento de sinais de EEG;
- Gerar base de dados com voluntários saudáveis e pacientes com Disartria possibilitando diversos estudos futuros do grupo de pesquisa e classificação do grau de Disartria do paciente.

2 A LINGUAGEM HUMANA

O estudo nas áreas das Neurociências e da Linguagem gerou novas perspectivas de pesquisa e possibilidades de compreensão do mecanismo da linguagem humana. Por exemplo, a área da Psicolinguística elaborou técnicas e possibilitou que métodos não invasivos de análise da atividade cerebral fossem inseridos em linhas de pesquisa com o objetivo de estudar o comportamento de fenômenos linguísticos no cérebro humano (MARCO *et al.*, 2011; DOMINGOS, 1998).

A intenção de falar está integralmente ligada ao Sistema Nervoso Central (SNC), à parte motora e às estruturas periféricas, além da inter-relação das partes. O processo da linguagem é bastante complexo e envolve uma rede de neurônios distribuída entre diferentes regiões cerebrais. O neurônio é considerado a unidade básica da estrutura do cérebro e do sistema nervoso. Todas as ações executadas são ordenadas pelo SNC, incluindo a execução da fala, que envolve a respiração, a laringe e os músculos faciais e mastigatórios, além de exigir o papel de outras estruturas cerebrais. Desta forma, a fala é definida como um sistema convencional de símbolos combinados de modo sistemático e orientados para armazenar e trocar informações (GUYTON & HALL, 2006).

2.1 FONÉTICA E A ARTICULAÇÃO TEMPOROMANDIBULAR: SUA INFLUÊNCIA NA AÇÃO DA FALA

A fonética é a ciência que estuda os sons da linguagem humana. Cabe à Fonética descrever os sons da linguagem e analisar suas particularidades articulatórias, acústicas e perceptivas. É na fonética que se estuda, se analisa e se classifica a produção e a percepção dos sons da fala. A fonética está dividida na Fonética Acústica e Fonética Articulatória (MCMICKEN *et al.*, 2014; MILLER & LOWIT, 2014).

A Fonética acústica procura examinar as propriedades físicas das ondas sonoras produzidas pelos órgãos fonadores (pulmões, traquéia e músculos peitorais), as cavidades e músculos respiratórios de maneira geral (CHIEN *et al.*, 2015). À Fonética articulatória estuda a forma de articulação dos sons, divide-se em partes articulatórias (boca, língua e dentes) e parte ressonante (nariz, fossas nasais e faringe), dentro destas estruturas pode também estar à caixa torácica que também pode funcionar como cavidade ressonante (STEFANI, 2008, WANG & XU, 2010, BRESOLIN *et al.*, 2008).

As estruturas osteomusculoarticulares responsáveis pela morfofuncionalidade da boca se organizam para a ejeção, que se cumpre pelo ajustamento das paredes bucais e projeção posterior da língua (BERRY *et al.*, 2014, SHELLIKERI *et al.*, 2014). A Figura 1 apresenta as principais estruturas da cavidade oral relacionadas com a fonética e a articulação.

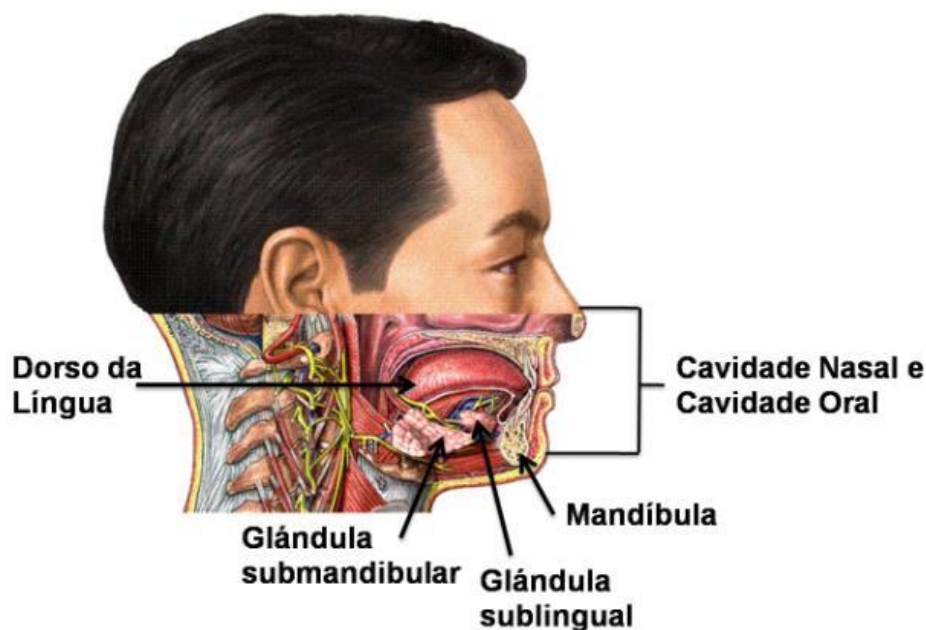


Figura 1 Principais estruturas internas da Cavidade Oral (adaptado de ADAM, 1997).

Para que haja liberdade nos movimentos mandibulares deve haver equilíbrio entre as estruturas ósseas e dentárias, tonicidade da musculatura, equilíbrio oclusal e saúde das estruturas que compõe a Articulação Temporomandibular (ATM) (VASCONCELOS *et al.*,

2002). Anatomicamente, a estrutura que liga a mandíbula ao crânio recebe o nome de Articulação Temporomandibular (ATM), a qual é considerada uma articulação composta por um conjunto de estruturas anatômicas, que com a participação dos grupos musculares, permite à mandíbula executar os diversos movimentos funcionais (AHMED *et al.*, 2013; YU & LIU, 2014). A ATM está diretamente relacionada com os movimentos mandibulares de oclusão, de retrusão e de protusão como se pode observar na Figura 2.

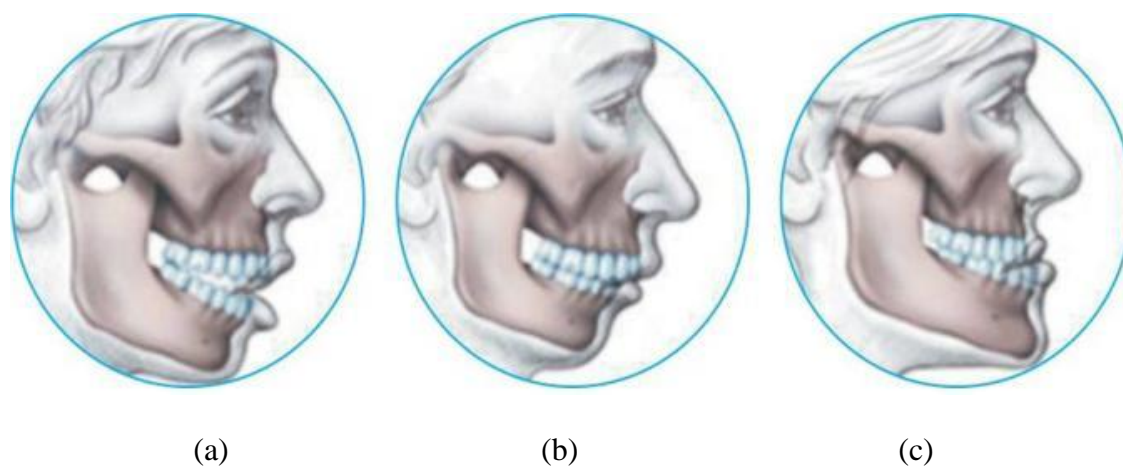


Figura 2 (a) Movimento de oclusão, (b) Movimento de retrusão, (c) Movimento de protusão (adaptado de ALMEIDA, 2011; WU *et al.*, 2014; RABINER & JUANG, 1993).

As Disfunções Temporomandibulares (DTM), também podem propiciar problemas na fala e podem ser acarretadas pelo excesso de demanda de adaptações funcionais, ultrapassando a tolerância funcional da ATM. Devido a isso, diversos distúrbios funcionais degenerativos podem ser desencadeados, acompanhados de sintomatologia dolorosa que modificam as condições musculares e articulares, assim evidenciam algumas pesquisas (AQUEVEQUE *et al.*, 2013; ABDOLALI *et al.*, 2014). Sistemas para a medição das DTM são cada vez mais elaborados, utilizando aparelhos que medem objetivamente os movimentos mandibulares durante a fala, auxiliando o diagnóstico e as condutas terapêuticas (KALANI, MOGHIMI & AKBARZADEH, 2015; MCLOUGHLIN, 2014; LIN *et al.*, 2013).

2.2 OS MÚSCULOS FACIAIS ENVOLVIDOS NO MOVIMENTO MANDIBULAR E NA FALA

O esqueleto protege os órgãos internos e fornece pontos de apoio para a fixação dos músculos. O esqueleto da face forma a parte anterior do crânio contendo as órbitas, cavidades nasais, maxila e mandíbula (KUMAR & RAKESH, 2011). As maxilas contribuem para a maior porção da parte superior do esqueleto da face. A mandíbula forma o esqueleto do maxilar inferior, que é móvel porque se articula com a base do crânio nas Articulações Temporo-Mandibulares (ATM) (TORTORA & GRABOWSKI, 2003).

Os músculos da face geralmente chamados de músculos superficiais estão situados no tecido subcutâneo, localizados logo abaixo do tecido epitelial e estão intimamente relacionados com a pele da face e do pescoço. Existem diversos tipos de músculos faciais que ajudam no movimento das diferentes partes do rosto (GRUEBLER & SUZUKI, 2014; WU *et al.*, 2014). Porém, é importante ressaltar que o interesse deste trabalho são os principais músculos do rosto que apresentam relação direta no processo da fala.

Músculos da expressão facial são considerados músculos da mímica facial e suas contrações produzem variações na forma dos orifícios do corpo e sulcos da pele, alterando a fisionomia da face. A expressão das emoções movimenta determinados músculos do rosto. Esta área foi inicialmente estudada pelo cientista Charles Robert Darwin em 1872, ao publicar seu livro: “A Expressão das Emoções no Homem e nos Animais”, com uma série de estudos sobre este vasto universo das emoções humanas e como elas se manifestam no corpo. Seguidamente, no ano de 1978, com a pesquisa das diferentes técnicas para a medição dos movimentos faciais pelos Psicólogos Paul Ekman e Wallace Friesen (EKMAN & FRIESEN, 1976; CASTILHO & MARTINS, 2012; RUSSELL *et al.*, 2003), se evidenciou a possibilidade da comunicação interpessoal mediante os movimentos faciais. Outros trabalhos constataram

que os músculos faciais se movem comandados por uma via motora voluntária e uma involuntária (WU *et al.*, 2013; BORUAH *et al.*, 2015). Suas funções são indicadas pelos seus próprios nomes, que revelam o movimento que fazem. É bom lembrar que esses músculos da expressão facial ou músculos mímicos, também são chamados dérmicos, pois não são fixados ao esqueleto nas suas duas partes (LOIZIDES *et al.*, 2008), pois apenas uma parte é fixada no esqueleto, enquanto a outra se prende nas camadas mais profundas da pele. Os feixes de fibras de um músculo são muitas vezes unidos aos de outro e nos locais de inserção é comum estarem entrelaçados (BUI *et al.*, 2003; SANTOS & PETRIU, 2013). Cabe destacar que existem músculos associados aos movimentos mandibulares e aos movimentos do pescoço, mas que também apresentam relação com o processo da fala, como é o caso dos músculos Masseter e Platíma (NG *et al.*, 2007; GOLDSTEIN *et al.*, 2004). Os principais músculos ligados à fala são apresentados na Figura 3 (a origem e a função desses músculos são apresentadas no Anexo A).

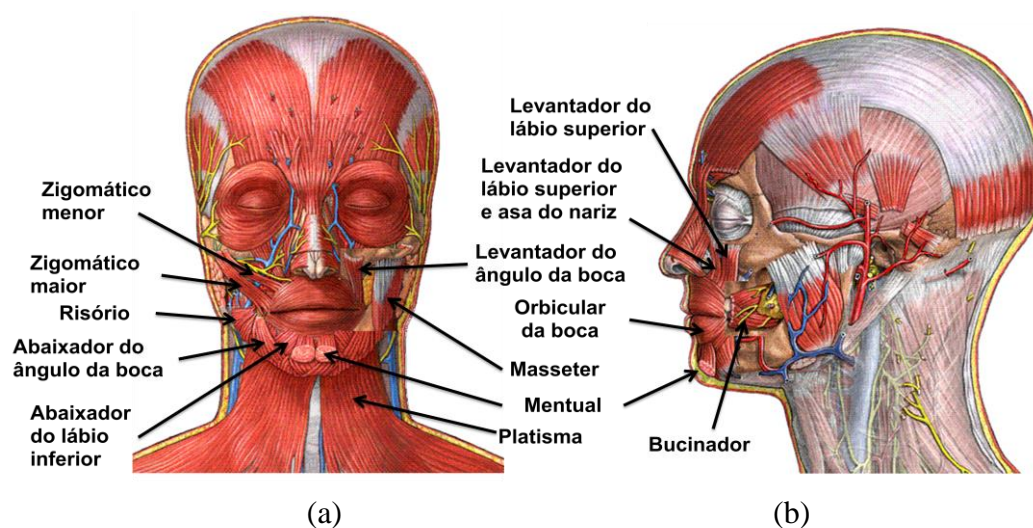


Figura 3 (a) Músculos faciais vista anterior e (b) Músculos faciais vista lateral (adaptado de ADAM, 1997).

A seguir são apresentados os principais músculos da face de interesse deste trabalho:

- **Zigomático Maior:** localizado na bochecha, é mais largo que o Zigomático Menor e age juntamente com o músculo Zigomático Menor. Estende-se do osso Zigomático e se insere no ângulo da boca onde se funde as fibras dos músculos Levantador do Ângulo da Boca e Orbicular da Boca. É responsável por tracionar o ângulo da boca para cima e para trás (por exemplo, no sorriso) e é de grande importância para o movimento labial (BURROWS *et al.*, 2014);
- **Abaixador do Ângulo da Boca:** o músculo Abaixador do Ângulo da Boca é um músculo plano e delgado localizado sobre o músculo Abaixador do Lábio Inferior. Deprime o ângulo da boca (típica expressão de tristeza) e suas fibras é a continuação do músculo Platisma (SEIKEL *et al.*, 2015);
- **Abaixador do Lábio Inferior:** músculo curto e quadrangular, situado no queixo. Repuxa o lábio inferior diretamente para baixo e lateralmente (SEIKEL *et al.*, 2015);
- **Masseter:** é considerado, o músculo mais evidente, largo e retangular, sendo o mais potente da deglutição e mastigação. O mesmo é dividido em superficial e profundo e embora não esteja perto da região dos lábios, não significa que esses músculos sejam utilizados apenas para a mastigação. Ele é utilizado para quaisquer funções que necessitem de elevação ou abaixamento da mandíbula, inclusive a fala. É um músculo que apresenta quatro propriedades: excitabilidade elétrica, contratilidade, extensibilidade, elasticidade, além de contribuir à homeostase do sistema (JIRAKITTAYAKORN *et al.*, 2014, NG *et al.*, 2007);
- **Platisma:** é um músculo que se encontra na área do pescoço. O mesmo não influencia diretamente na produção da fala, mas vibra quando às cordas vocais são ativadas. Torna-se de grande interesse para este trabalho devido à captação

do sinal produzido pela vibração na intenção do paciente em falar (WILLIAMS & KIRSCH, 2008; WILLIAMS & KIRSCH, 2015).

2.3 A ARTICULAÇÃO DA FALA E SUA CONEXÃO COM O CÉREBRO HUMANO

O córtex cerebral é dividido em áreas denominadas lobos cerebrais, cada uma com funções diferenciadas e especializadas. Os sinais produzidos pela ativação cerebral segundo o estímulo são captados nas áreas do Cérebro apresentadas na Figura 4.




Figura 4 Localização dos Lobos do Cérebro Humano (adaptado de ADAM, 1997).

A atividade cognitiva inicial responsável pela realização de uma tarefa motora, planejamento de uma ação, seja de imaginação de movimento de um membro ou o movimento físico do mesmo, ocorre no Lobo Frontal (BENEVIDES *et al.*, 2010). O Lobo Parietal (constituído por duas subdivisões, a anterior e a posterior), tem a função de possibilitar a percepção de sensações como o tato, a dor e o calor (GUYTON & HALL, 2006). O Lobo Occipital possui várias subáreas que processam os dados visuais recebidos do exterior. Localizados na parte inferior do cérebro, define uma das funções essenciais para uma vida autônoma de uma pessoa que é a visão. Sua função também inclui a capacidade de compreender e diferenciar entre formas diferentes, a geometria de formas (CLARKE & MIKLOSSY, 1990). O Lobo Temporal, localizado nas partes laterais de cada hemisfério do

cérebro humano possui a função principal de processar os estímulos auditivos. Além de ser a estrutura central responsável pelo gerenciamento da memória. O Lobo Temporal relaciona-se com a audição, com o olfato, com funções psíquicas e a linguagem compreensiva (SEIKEL *et al.*, 2015). O Cerebelo, órgão do sistema nervoso, repousa sobre a fossa cerebelar do osso Occipital e está separado do Lobo Occipital por uma prega da Dura-máter denominada Tenda do Cerebelo. Do ponto de vista fisiológico, o Cerebelo difere principalmente do cérebro porque funciona sempre em nível involuntário e inconsciente, sendo sua função exclusivamente motora (equilíbrio e coordenação) (SEIKEL *et al.*, 2015).

Por sua vez, as contrações musculares para produzir a fala são controladas por impulsos nervosos que são originadas nas áreas motoras do Cérebro ao nível do Tronco Cerebral e da Medula Espinhal, e então são direcionados para os músculos relacionados ao processo da fala, através de vários nervos que se situam na base do Crânio ou da Medula Espinhal (GUYTON & HALL, 2006). A fala depende da integridade do Córtex Motor suplementar e primário, dos Tratos Piramidais e Extrapiramidais, dos Núcleos Subcorticais, do Tronco Cerebral, do Cerebelo, assim como, dos Nervos Cranianos. A Figura 5 apresenta o Córtex Motor Primário ou área de Brodmann, considerada como uma das principais áreas do Cérebro responsáveis pela função motora e execução de movimentos nos músculos (GUYTON & HALL, 2006; BINDER *et al.*, 1997).

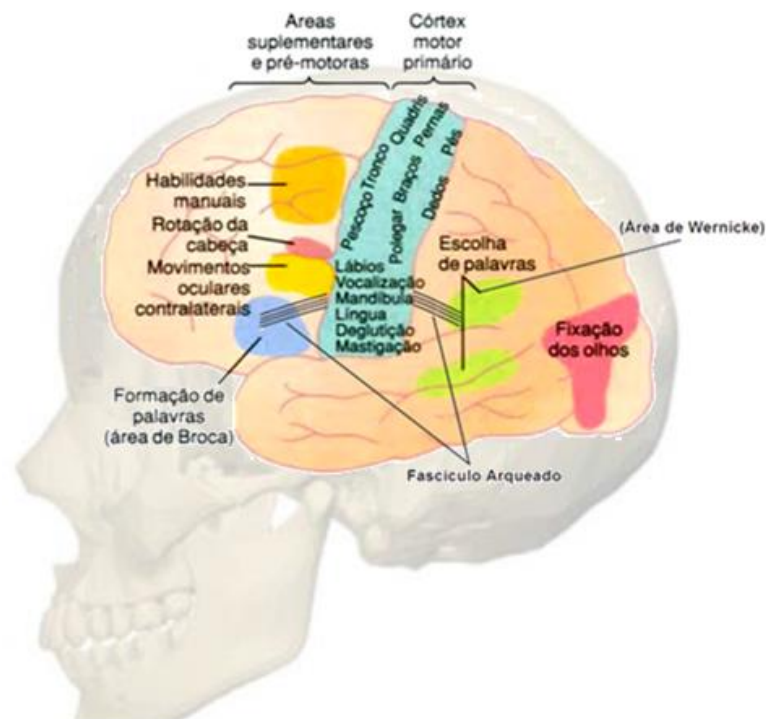


Figura 5 Visualização do Córtex motor primário ou área de Brodmann, junto com outras áreas do cérebro que intervierem no processo da fala (adaptado de GUYTON & HALL, 2006; CORTICAL FUNCTIONS REFERENCE, 2012).

A Área de Broca ocupa a circunvolução frontal inferior (*pars opercularis* assim como um pequeno segmento posterior da *pars triangularis*), no hemisfério dominante. Constitui o componente sintático-articulatório da linguagem e têm também áreas motoras da fala nas circunvoluções frontais inferiores bilateralmente. Esta área é a responsável por gerar sinais para a musculatura (dependente do córtex motor) produzir sons significativos. É importante ressaltar, que o paciente com lesões nesta região tem dificuldade na produção/articulação das palavras (KUMAR, 2015; FRIEDERICI, 2009).

A Área de Wernicke, também ligadas ao processo da fala, se localiza no segmento posterior do *gyrus* temporal superior, na sua face dorsal, logo atrás da circunvolução de Heschl e adiante do *gyrus angularis*. Este constitui o componente léxico-semântico da linguagem (FRIEDERICI, 2009).

Por último, o Fascículo Arqueado constitui um feixe de fibras que liga as áreas de Wernicke e Broca. As lesões do fascículo arqueado produzem uma afasia de condução, com

áreas de Wernicke e Broca intacta, o paciente consegue articular corretamente as palavras, mas é incapaz de repetir uma palavra. Curiosamente a dificuldade de repetição é maior para palavras menores, estando relativamente preservada a capacidade de repetição de números (MURDOCH, 1997; JÜRGENS, 2002).

A natureza dos rápidos movimentos musculares do rosto, produzidos naturalmente durante a fala sugere a necessidade de mecanismos significativos de ajustes motores em mínimos intervalos de tempo, ou seja, a ocorrência de impulsos nervosos, diretamente dependentes do controle neural (MOON, *et al.*, 2005).

O impulso nervoso é a transmissão de um sinal codificado de um estímulo dado ao longo da membrana do neurônio, partindo de seu ponto de aplicação. Dois tipos de fenômenos são envolvidos no processamento do impulso nervoso: os elétricos e os químicos. Os eventos elétricos propagam o sinal dentro de um neurônio, e os eventos químicos transmitem o sinal de um neurônio ao outro ou para uma célula muscular (CANTOR, 1995).

Portanto, os neurotransmissores possibilitam que os impulsos nervosos de uma célula influenciem os impulsos nervosos de outra, permitindo assim às células do Cérebro interagir. O corpo humano desenvolveu um grande número desses mensageiros químicos para facilitar a comunicação interna e a transmissão de sinais dentro do Cérebro. Quando tudo funciona adequadamente, as comunicações internas acontecem sem tomar consciência delas. O sistema nervoso controla e coordena as funções corporais, permitindo que o corpo responda, intercedendo com o meio ambiente. Porém, quando existe alguma limitação psicomotora, por exemplo, um Acidente Vascular Cerebral (AVC), os impulsos nervosos não atingem devidamente os músculos relacionados com o movimento desejado, limitando a movimentação muscular e podendo atrofiar o processo da fala (YANG & YEO, 2015).

2.4 O ACIDENTE VASCULAR CEREBRAL

A ênfase no estudo da Engenharia de Reabilitação aumenta a cada ano, dado que os Acidentes Vasculares Cerebrais aumentam no mundo inteiro, segundo os dados da Organização Mundial de Saúde (NEAGOE, 2013). O AVC é uma alteração da circulação cerebral que ocasiona um déficit transitório ou definitivo no funcionamento de uma ou mais partes do cérebro, podendo ser por meio isquêmico ou hemorrágico e resultando em perda da função neurológica (TOWNSEND *et al*, 2013). Essa patologia cerebrovascular atinge com maior incidência pessoas a partir dos 55 anos de vida (KILGORE *et al*, 2014). A avaliação da independência funcional destes pacientes deve contemplar a análise das atividades de vida diária geralmente afetada após o AVC. Esta avaliação é usada para adequar a intervenção terapêutica às condições reais do paciente, comparar os resultados em diferentes momentos da intervenção, melhorar os procedimentos e determinar as necessidades de cada pessoa (EL-TAMAWY *et al*, 2014). O AVC pode limitar de modo significativo o desempenho funcional, com consequências negativas nas relações pessoais, familiares, sociais e, na qualidade de vida. Essa limitação, nem sempre se deve ao déficit neurológico em si. Como por exemplo, complicações psiquiátricas têm sido indicadas como fatores determinantes da incapacitação do paciente após o AVC (DE MENESES *et al*, 2014). Pessoas que sofrem o AVC podem experimentar como consequência uma paralisia facial, na qual a pessoa perde a possibilidade da comunicação, mas também se pode comprometer a articulação de sons e em função disso limitar a fala, assim como, afetar a Articulação Temporomandibular (ATM). É importante ressaltar que a impossibilidade de um indivíduo de se comunicar de forma eficiente limita a sua integração com seu próximo e com a sociedade.

2.5 A DISARTRIA

A articulação da fala é acionada pela combinação de vários movimentos dos lábios, da língua, do palato mole, da faringe e da laringe. Em alguns pacientes com doença cerebrovascular, a função motora da língua poderá ser afetada, causando a Disartia (YANO *et al.*, 2015). Disartria pode ser definida como uma dificuldade motora na fala, causada por danos neurológicos, sendo caracterizada pela fala lenta, fraca, imprecisa e/ou por movimentos não coordenados da musculatura da fala. Ainda, pode envolver a respiração, a fonação, a ressonância ou a articulação oral (YORKSTON, 1996). A Disartria pode ser decorrente de tumores do sistema nervoso central, de lesões vasculares cerebrais ou de um traumatismo crânio-encefálico, bem como de doenças progressivas neuromusculares ou que atingem o sistema extrapiramidal. Além disso, pode ser originada de doenças infecciosas, metabólicas, tóxicas ou degenerativas do sistema nervoso ou do sistema muscular (SELLARS *et al.*, 2005; RIBEIRO & ORTIZ, 2009).

3 CARACTERÍSTICAS BÁSICAS SOBRE OS BIOSINAIS DE ELETROMIOGRAFIA E ELETROENCEFALOGRAFIA

Os biosinais são sinais de origem biológica e produzidos por todos os seres vivos partindo desde o nível celular. Estes sinais podem ter origem elétrica, mecânica ou química. As principais unidades geradoras dos sinais bioelétricos são as células nervosas e musculares, com seus potenciais de ação, entretanto, estas não funcionam em grandes agrupamentos (BEM *et al.*, 2000). A caracterização destes sinais pode mostrar informações vitais relativas às funções normais e patológicas do corpo ou também para modelar a fisiologia de sistemas biológicos (BOUTANI & OHSUGA, 2013; IBÁÑEZ *et al.*, 2014). Os músculos do rosto ao se movimentar, mediante o processo da fala, geram sinais bioelétricos que podem ser registrados, resultando na captação de sinais de Eletromiografia de Superfície (sEMG) ou/e sinal de Eletroencefalografia (EEG) (HAMEDÍ *et al.*, 2011; THULKAR *et al.*, 2015).

3.1 CONCEITOS BÁSICOS SOBRE BIOSINAIS DE SEMG E DE EEG

Sistemas *Brain Computer Interface* (BCI) possibilitam a comunicação dos pacientes com severidades motoras com o ambiente. Normalmente sistemas BCI são classificados como invasivos ou não invasivos. Um sistema invasivo registra a atividade cerebral mediante o uso de micro-eletrodos implantados no córtex cerebral, enquanto um sistema não invasivo emprega eletrodos tipicamente posicionados no escalpo para o registro não invasivo do sinal de EEG (SOLHJOO, *et al.*, 2005).

Para os sistemas não invasivos normalmente são captados: os potenciais corticais lentos (SCP) de EEG, as oscilações de EEG e de sEMG (principalmente o ritmo sensório-motor (SMR)) e Eventos Relacionados a Potenciais elétricos (ERP: *Event Related Potentials*) (SOLHJOO, *et al.*, 2005). Tipicamente sistemas BCI necessitam do desenvolvimento de métodos de reconstrução do sinal de interesse, de extração e de classificação.

Em função disso, a Tabela 1 apresenta, de forma resumida, os resultados da revisão bibliográfica executada neste trabalho. Foram revisados um total de 138 artigos relacionados ao Processamento de Sinais de EEG e de sEMG (*search words: sEMG, EEG, signal processing, classification method*). Destes, 50 artigos usaram sEMG, 62 usaram EEG e 26 a combinação de ambos. As Bases de Dados acessadas foram a SCOPUS, *Web of Science* e a IEEE.

Tabela 1. Resumo da revisão bibliográfica realizada na área de Classificadores baseados em Métodos Matemáticos aplicados ao EEG e ao sEMG.

Artigos Métodos Matemáticos para Classificação	2014-2015								
	SCO*			ISI†			IEEE‡		
	sEMG	EEG	sEMG e EEG	sEMG	EEG	sEMG e EEG	sEMG	EEG	sEMG e EEG
Support Vector Machines (SVM)	10	2	1	6	1	2	2	0	2
Fuzzy C-means (FCM)	0	0	0	0	0	0	0	2	0
Genetic Algorithm (GA)	0	1	0	1	3	0	1	0	0
Artificial Neural Networks (ANN)	1	3	1	0	2	0	2	6	4
Hidden Markov Models (HMM)	0	2	0	0	1	0	0	2	4
Linear Discriminant Analysis (LDA)	14	10	1	5	4	2	1	5	1
Multiresolution analysis (MRA)	0	0	0	0	0	0	1	0	0
Gaussian mixture models (GMMs)	2	0	0	0	0	0	0	0	0
Bayesian classifier (BSC)	0	5	2	0	2	1	1	3	5
K-Nearest-Neighbor (KNN)	1	2	0	0	0	0	2	0	0
Fuzzy Logic	1	2	0	0	1	0	0	2	0
Sub-Total	29	27	5	12	14	5	9	21	16
Total							50	62	26

*Scopus (SCO): The mayor competitor of ISI (www.info.scopus.com), sponsored by Elsevier.

†Web of Science (ISI): Edited by the Institute for Scientific Information and distributed by Thomson Reuters (<http://isiwebofknowledge.com/>).

‡Database of (IEEE) Institute of Electrical and Electronics Engineers (<http://ieeexplore.ieee.org/Xplore/home.jsp>).

Como mostrado na Tabela 1, os principais métodos de classificação, nos artigos avaliados, foram: *Artificial Neural Networks (ANNs)*, *Linear Discriminant Analysis (LDA)*, *Support Vector Machines (SVM)* e *Bayesian Classifier (BSC)* (HUSSAIN *et al.*, 2009; SANEI & CHAMBERS, 2013). Destes métodos os escolhidos para o processamento dos

sinais de interesse, neste trabalho, foram a *Support Vector Machines* (SVM) para os sinais de sEMG e Redes Bayesianas (RB) para os sinais de EEG. Estes métodos foram selecionados devido aos bons resultados apresentados com esses biosinais e devido à experiência do Grupo de Pesquisa do IEE, no uso dessas técnicas em diversas aplicações na área da Engenharia Biomédica (BEMUDEZ, 2013; CARRA & BALBINOT, 2012; DE PAULI NILSON & BALBINOT, 2014; MACHADO & BALBINOT, 2014). Além disso, a grande contribuição deste trabalho é a metodologia empregada com os pacientes com Disartria e, em função disso, optou-se por métodos matemáticos já consagrados na literatura.

A sEMG pode ser definida como a técnica que registra os potenciais elétricos da membrana do músculo em resposta à ativação fisiológica dos músculos esqueléticos. A excitação elétrica do músculo esquelético é iniciada e regulada pelo sistema nervoso central e periférico (GUYTON & HALL, 2006). O sinal de sEMG é a atividade elétrica durante a contração e o repouso muscular, constituindo uma avaliação eletrofisiológica que mensura a atividade musculoesquelética no nível da pele mediante a colocação de eletrodos de superfície.

A sEMG fornece referências instrumentais, ao verificar os potenciais elétricos de grupos musculares no momento da fala, tornando possível monitorar alguns aspectos da fala tanto em indivíduos saudáveis quanto em indivíduos com Disartria (BERRY *et al.*, 2014). É possível medir a atividade muscular durante o processo da fala, da deglutição, da mastigação, entre outros processos fisiológicos (BERRY *et al.*, 2014).

No trabalho de (FIORUCCI *et al.*, 2009), eletrodos de superfície foram posicionados nos músculos bilaterais: Masseter, Temporal Anterior, Digástrico Anterior e Esternocleidomastóideo para o estudo funcional, de diagnóstico e para terapia ortodôntica. Estudos com respiradores orais, padrões faciais, desordens de ATM e desordens que afetam o sistema estomatognático têm sido feitos associados à sEMG (VASCONCELOS *et al.*, 2002).

Pode-se verificar que para a produção da fala, além dos desenvolvimentos cognitivos e fonológicos adequados, deve-se analisar o sistema neurológico, assim como, todas as estruturas envolvidas na produção deste ato motor comandadas pelo sistema nervoso central e periférico, que é totalmente íntegro para que a fala seja produzida de maneira correta. O uso da sEMG configura-se, assim, como uma possibilidade de avaliação instrumental complementar (ALBRECHT, 2010).

Com relação ao reconhecimento de padrões da fala são usados diferentes métodos, onde a classificação dos sinais é desenvolvida mediante o processamento da sEMG. Um exemplo destes métodos é no reconhecimento de voz, onde o sinal de sEMG é captado por oito canais colocando eletrodos superficiais em oito músculos da face e do pescoço, aplicando Análise Discriminante Linear (LDA), como classificador, atingindo uma *Accuracy* de 92,2% (LYU *et al.*, 2014).

O movimento facial desempenha um papel importante na interação homem-computador para a reabilitação das pessoas com deficiência. A terapia muscular facial com o exercício regular dos músculos faciais tem apresentado bons resultados no auxílio da recuperação muscular. Um sistema pode identificar uma série de padrões nos sinais de sEMG dos músculos faciais, analisar o sinal e comandar um pequeno robô móvel para realizar tarefas específicas, assim como, outras atividades de controle (MOHAMAD *et al.*, 2012). Recentemente sistemas de sEMG faciais foram desenvolvidos para o controle de computadores e cadeiras de rodas, bem como, para estudos de polissonografia como indicativos de relaxamento muscular e de movimentos oculares (ANH-DAO *et al.*, 2013).

O sinal de EEG é um registro gráfico da atividade gerada pelas células do cérebro (neurônios) e o equipamento de EEG consiste basicamente de um sistema condicionador de sinais para captura destes biosinais.

Os padrões cerebrais têm formas de ondas sinusoidais típicas e geralmente são medidos na faixa de 0,5 a 100 μ V. Na realização de movimentos reais ou imaginários ocorre tipicamente uma diminuição na atividade dos ritmos μ (8 – 12 Hz) e β (18 – 25 Hz) na região do córtex sensório-motor, em particular no lado contralateral ao movimento (QIU *et al.*, 2015). No processamento cognitivo e sensório-motor ocorrem mudanças no sinal de EEG em forma de desincronização relacionado ao evento (ERD) ou sincronização relacionada ao evento (ERS). Ambos os fenômenos acontecem no tempo, mas não na fase e são específicos em bandas de frequência dos ritmos μ e β . O ERD é interpretado como uma correlação da área cortical ativada com um aumento da excitabilidade. O ERS pode ser interpretado, sob certas condições, como uma correlação de uma área cortical desativada. O mapeamento espacial do ERD e/ou ERS é utilizado para estudar a dinâmica dos padrões de ativação corticais (PFURTSCHELLER, 2001).

3.2 SUPPORT VECTOR MACHINE E INTERFACE HOMEM-COMPUTADOR

Support Vector Machine (SVM) tipicamente é utilizada para classificar dados. Considera como entrada um conjunto de dados e prediz, para cada entrada dada, qual de duas possíveis classes a entrada faz parte, o que faz da SVM um classificador linear binário não probabilístico. Um modelo SVM é uma representação de pontos no espaço, mapeados de maneira que os pontos de cada categoria sejam divididos por um espaço claro que seja tão amplo quanto possível. O objetivo na formação de uma SVM é encontrar o hiperplano de separação com a maior margem entre as classes (CHRISTIANINI & SHAW-TAYLOR, 2000). A questão da generalização pode ser mais bem avaliada para o caso de duas classes. Assumindo que as amostras de treinamento das duas classes são linearmente separáveis, a função de decisão mais adequada é aquela para a qual a distância entre os conjuntos das

amostras de treinamento é maximizada. Neste contexto, a função de decisão que maximiza esta separação é denominada de ótima (ABE, 2005).

Para exemplificar, considere um conjunto com M amostras de treinamento x_i ($i=1, \dots, M$), em um problema que consiste de duas classes linearmente separáveis (ω_1 e ω_2). Cada amostra fica associada a um rótulo: $y_i = 1$ se $x_i \in \omega_1$, $y_i = -1$ se $x_i \in \omega_2$. A forma geral de uma função linear de decisão pode ser dada pela Equação (1):

$$D(x) = \mathbf{w}^T \mathbf{x} + \mathbf{b} \quad (1)$$

onde \mathbf{x} é um vetor m -dimensional representando o padrão a ser classificado, \mathbf{w} também é um vetor m -dimensional (pesos) e \mathbf{b} o termo independente. Neste exemplo, se supõe que as amostras são linearmente separáveis, então não ocorrerá a situação em que $\mathbf{w}x_i + \mathbf{b} = 0$.

Desta forma, o critério para classificação pode ser escrito pela Equação (2):

$$\mathbf{w}x_i + \mathbf{b} > a \text{ para } x_i \in \omega_1 (y_i = 1)$$

$$\mathbf{w}x_i + \mathbf{b} < -a \text{ para } x_i \in \omega_2 (y_i = -1) \quad (2)$$

para $a > 0$. Dividindo ambos os membros da desigualdade por a , o critério para classificação fica como a Equação (3):

$$\mathbf{w}^T \mathbf{x} + \mathbf{b} \begin{cases} \geq 1 \text{ para } y_i = 1 \\ \leq -1 \text{ para } y_i = -1 \end{cases} \quad (3)$$

Deste modo, ambas as condições podem ser combinadas em uma única equação:

$$y_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) \geq 1 \text{ para } i=1,2, \dots, M \quad (4)$$

sendo M o número de amostras disponíveis. O Hiperplano da Equação (5), representado na Figura 6 forma uma superfície de separação entre as duas classes:

$$D(x) = \mathbf{w}^T \mathbf{x} + \mathbf{b} = c \text{ para } -1 < c < 1 \quad (5)$$




Figura 6 Representação de Hiperplano de Máquina de Suporte de Vetores (adaptado de DUDA & HART, 2000).

Para $c = 0$, a Equação (5) define um hiperplano situado à meia distância entre os dois hiperplanos extremos ($c = 1$ e $c = -1$). A distância entre estes dois hiperplanos extremos é denominada de “margem”, representada por ρ na Figura 6. Supondo a existência de pelo menos uma amostra x para a qual $D(x) = 1$, e pelo menos uma outra amostra para a qual $D(x) = -1$, então o hiperplano $D(x) = 0$ representa a melhor superfície de separação entre estas amostras, no sentido de que maximiza o poder de generalização do classificador. A distância $d(x)$ de uma amostra x a um plano qualquer $D(x)$ é dada pela Equação (6):

$$d(x) = \frac{|D(x)|}{\|w\|} \quad (6)$$

O hiperplano ótimo será, portanto, aquele para o qual esta distância é máxima. Esta condição pode-se obter minimizando $\|w\|$, ou equivalentemente, minimizando a Equação (7):

$$Q(w) = \frac{1}{2} \|w\|^2 = \frac{1}{2} w^T w \quad (7)$$

com respeito aos parâmetros da função $D(x)$, w e b . Para satisfazer a convenção adotada com relação ao rótulo de cada amostra (y_i), a restrição da Equação (4) deve ser imposta. Tal

restrição é imposta de maneira a assegurar que não ocorram amostras de treinamento na região de separação entre as duas classes (entre as margens). A inclusão das restrições da Equação (4) no problema de minimização da Equação (7) pode ser resolvida por meio da técnica dos multiplicadores de Lagrange (α). Esta abordagem pode ser expressa para minimizar a Equação (8).

$$Q(\mathbf{w}, \mathbf{b}, \alpha) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^M \alpha_i \{y_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) - 1\} \quad (8)$$

com relação a \mathbf{w} , \mathbf{b} e maximizar com relação a α_i , sendo $\alpha = (\alpha_1, \dots, \alpha_M)$ os multiplicadores de Lagrange, um vetor de dimensão M , com $\alpha_i \geq 0$. Deste modo, obtém-se a forma dual na Equação (9), expressa em termos de α somente (HAMEL, 2011; ABE, 2005):

$$Q(\alpha) = \sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i,j=1}^M \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \quad (9)$$

A solução deste problema permite expressar \mathbf{w} em termos de α resultando em uma nova forma para a função de decisão da Equação (1):

$$D(\mathbf{x}) = \sum_{i \in S} \alpha_i y_i \mathbf{x}_i^T \mathbf{x} + \mathbf{b} \quad (10)$$

onde S é o conjunto de índices dos vetores de suporte, isto é, as amostras de treinamento para as quais $\alpha_i > 0$. A formulação acima apresenta solução somente no caso de as amostras \mathbf{x}_i pertencentes às duas classes serem linearmente separáveis. Em situações reais, entretanto, os dados frequentemente não são linearmente separáveis. Para estender a formulação acima para conjuntos de dados não linearmente separáveis, permite-se que alguns dados possam violar a restrição da Equação (4), por meio da introdução do conceito de variável de folga (*slack variable*) representada por ξ_i ($\xi_i \geq 0$). Tais variáveis relaxam as restrições impostas ao problema de otimização. Neste caso, a restrição expressa na Equação (4) torna-se:

$$y_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) \geq 1 - \xi_i \quad (11)$$

Esta abordagem é conhecida como SVMs com margens suaves (*soft-margin*) (HAMEL, 2009; ABE, 2005). Para o caso de $\theta < \xi_i < I$ a correspondente amostra x_i não terá margem máxima, mas será rotulada corretamente. No caso de $\xi_i \geq I$, a amostra x_i será rotulada erroneamente. Para levar em consideração o termo ξ_i , minimizando assim o erro sobre os dados de treinamento, a Equação (7) é reformulada como:

$$Q(\mathbf{w}, \mathbf{b}, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^M \xi_i \quad (12)$$

A constante C , conhecida como “parâmetro de margem”, estabelece o equilíbrio entre a maximização da margem e a minimização dos erros. O procedimento, neste caso, é semelhante ao desenvolvido para o caso de margens rígidas, resultando em uma função de decisão semelhante à anterior (Equação (10)), com a única diferença de $C \geq \alpha_i \geq \theta$ para $i=1, \dots, M$ (HAMEL, 2009; ABE, 2005). As SVM lineares são eficazes na classificação de conjuntos de dados linearmente separáveis, contaminados com a presença de alguns ruídos. Entretanto, em situações reais ocorre com bastante frequência classes não linearmente separáveis. A solução mais simples nestes casos consistiria na adoção de polinômios de grau mais elevado. Entretanto, esta abordagem apresenta o risco de excesso de ajuste (*overfitting*), e a conseqüente redução no poder de generalização do classificador (DUDA *et al.*, 2000). Uma opção mais eficiente consiste em mapear os dados para um espaço de dimensão mais alta, no qual os dados tornam-se linearmente separáveis (HAMEL, 2009; CRISTIANINI & SHAWE-TAYLOR, 2000).

Função de mapeamento *Kernel* ou núcleo de produto interno é uma técnica matemática que permite à SVM separar linearmente as amostras de classes diferentes, sem que estas sejam linearmente separáveis em sua dimensão original. Dependendo de como o *Kernel* é gerado, pode-se construir máquinas de aprendizagem com superfícies de decisão não-lineares. Entre estas funções *Kernel* estão: a função Linear, a função Quadrática, a função

Polinomial e a Função de Base Radial (RBF: *Radial Basis Function*), representada pela Equação (13), as quais são bem sucedidas em muitas aplicações, recomendando-se para EMG a RBF (CHRISTIANINI & SHAW-TAYLOR, 2000; CHAGAS, 2009; WEI & HU, 2011).

$$H(x, x_i) = \exp(-\gamma \|x - x_i\|^2) \quad (13)$$

onde γ é um parâmetro de controle. Então a regra de classificação está dada por Equação (14):

$$\begin{aligned} D(x_i) &> 0 & x_i \in w_1 \\ D(x_i) &< 0 & x_i \in w_2 \end{aligned} \quad (14)$$

Se $D(x_i) = 0$, então x_i está sobre o hiperplano separador e não é classificado. Quando as amostras de treinamento são linearmente separáveis, a região $\{x_i > D(x) > -1\}$ é a região de generalização. A maximização da margem permite aumentar a capacidade de generalização do classificador, vantagem que possuem as SVM com respeito a outros classificadores (ABE, 2005; ANDREOLA & HAERTEL, 2010).

3.3 REDES BAYESIANAS E INTERFACE HOMEM-COMPUTADOR

Uma técnica computacional utilizada para modelar com facilidade de interpretação a incerteza através de probabilidades são as Redes Bayesianas (RB) (FREITAS *et al.*, 2012; DAYAN & ABBOTT, 2000). As RB são modelos matemáticos baseados em nós e arcos que representam, respectivamente, as variáveis de um universo $U = (A_1, A_2, \dots, A_n)$ e as dependências entre estas. O modelo matemático utilizado na representação das RB possibilita lidar com incertezas através de técnicas probabilísticas. A medicina, por exemplo, é uma área em que a utilização de redes probabilísticas vem sendo difundida. Estas são empregadas na modelagem de incertezas para emitir diagnósticos (FERNANDES *et al.*, 2013). As redes Bayesianas são diagramas com a função de organizar o conhecimento sobre uma determinada área através de um mapeamento entre causas e efeitos. São largamente utilizadas em situações

onde não se conhece totalmente o escopo do problema, ou seja, quando há um conhecimento incerto sobre as variáveis do domínio (FERNANDES *et al.*, 2013).

Em 1762, o Reverendo Thomas Bayes demonstrou um procedimento importante para calcular a probabilidade de um evento, dado que outro tenha ocorrido. O teorema de Bayes tem importância fundamental, pois fornece a base para uma abordagem da inferência estatística. O método consiste na partição do espaço amostral em diversos subconjuntos cujas probabilidades sejam conhecidas e, em seguida, aplicar a seguinte Equação (15):

$$P(A_i/B) = \frac{P(B/A_i) \cdot P(A_i)}{\sum P(B/A_j) \cdot P(A_j)} \quad (15)$$

onde A_i é o evento cuja probabilidade se quer calcular dado que o evento B tenha ocorrido. A_j representa genericamente uma das "fatias" da partição do espaço amostral (A_i é uma dessas fatias). A interpretação da probabilidade como o grau de certeza em um determinado evento é chamada "ênfoque Bayesiano" (FERNANDES *et al.*, 2013).

Nessas redes, pode-se calcular a probabilidade de um evento ocorrer condicionado à ocorrência de outro. Elas representam a incerteza tomando por base a teoria da probabilidade. A questão de construção de redes Bayesianas envolve dois aspectos: a construção da estrutura da rede e a definição das probabilidades associadas. O teorema de Bayes permite então calcular a probabilidade *a posteriori*, baseada na probabilidade *a priori* dos dados observados na hipótese e dos dados totais, assim como apresenta a Equação (16).

$$P(b_i/A) = \frac{P(A/b_i) \times P(b_i)}{P(A)} \quad (16)$$

Em função do custo computacional neste trabalho se trabalhou com o classificador *Naive Bayes* (NB), o qual considera todos os eventos independentes entre si. Outros pesquisadores tem atingido bons resultados na classificação além da sua simples implementação (DUDA & HART, 2000). A probabilidade conjunta pode ser obtida pela Equação (17) e a saída do classificador NB pode ser dada pela Equação (18).

$$P(\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n | \mathbf{b}_j) = \prod_i P(\mathbf{a}_i | \mathbf{b}_j) \quad (17)$$

$$\mathbf{b}_{MAP} = \underset{\mathbf{b}_j \in B}{\operatorname{argmax}} \{P(\mathbf{b}_j) \times \prod_i P(\mathbf{a}_i | \mathbf{b}_j)\} \quad (18)$$

onde \mathbf{b}_{MAP} representa a máxima probabilidade *a posteriori* calculada dentro do espaço de hipótese B . Somente é necessário estimar a distribuição de probabilidade de cada atributo para cada classe, além de não precisar realizar o cálculo de $P(A)$ no caso do número de observações de cada classe ser igual (MACHADO *et al.*, 2012).

3.4 DISCRIMINANTE LINEAR DE FISHER E INTERFACE HOMEM-COMPUTADOR

Utilizou-se um classificador LDA, visando a comparação dos resultados dos classificadores de SVM e NB para os sinais de sEMG e EEG, respectivamente. O objetivo principal do LDA é projetar os dados em um hiperplano dentro do espaço de características, orientando o hiperplano resultante da projeção com a melhor discriminação das classes na reta do hiperplano mesmo (DUDA & HART, 2000). Discriminante linear é uma combinação dos componentes do espaço $\mathbf{x} \in \mathbb{R}^D$ de características que pode ser dado por a Equação (19):

$$\mathbf{g}(\mathbf{x}) = \mathbf{w}^T \cdot \mathbf{x} + \mathbf{w}_0 \quad (19)$$

onde $\mathbf{w} \in \mathbb{R}^D$ é o vetor dos pesos, \mathbf{w}_0 é uma constante e D é a dimensão do vetor de características, de forma que um classificador linear para duas classes C_1 e C_2 é implementado pela seguinte regra de decisão representados em (20):

$$\begin{aligned} C_1 \text{ se } \mathbf{g}(\mathbf{x}) > 0 \\ C_2 \text{ se } \mathbf{g}(\mathbf{x}) < 0 \end{aligned} \quad (20)$$

Ou seja, a classe C_1 será escolhida caso o produto interno dado pela Equação (19) seja maior que $-\mathbf{w}_0$, caso este seja menor que $-\mathbf{w}_0$ a classe C_2 será escolhida. Pela sua parte, a direção do

hiperplano é dada pelo critério de Fisher ou coeficiente de Rayleigh, apresentado na Equação (21):

$$J(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_d \mathbf{w}}{\mathbf{w}^T \mathbf{S}_c \mathbf{w}} \quad (21)$$

onde \mathbf{S}_d representa a atividade discriminativa dos dados e \mathbf{S}_c é a atividade comum, sendo feito o cálculo de \mathbf{w} para maximizar a função $J(\mathbf{w})$ e encontrando um vetor \mathbf{w} que maximize a atividade discriminativa entre as duas classes em relação à atividade comum (DUDA & HART, 2000; ZHAO *et al.*, 2009; KOYAS *et al.*, 2013). O classificador LDA foi implementado pela função *classify* do MatLab. Esta função faz a busca dada pela Equação (19) e encontra o vetor \mathbf{w}_j e a constante w_0 . O número de constantes do vetor \mathbf{w}_j é dado pela quantidade de características utilizadas.

3.5 MÉTODO DA TRANSFORMADA DISCRETA WAVELET (DWT) PARA EXTRAÇÃO DE CARACTERÍSTICAS NO SEMG

Assim como a análise de *Fourier*, a análise de *Wavelet* trata com a expansão de funções em termos de um set de funções básicas. A diferença da análise de *Fourier*, a análise de *Wavelet* expande as funções em termos de *Wavelets*, que são gerados em forma de translações e dilatações de uma função fixa chamada *mother Wavelet*. As *Wavelet* são localizadas no tempo e na frequência permitindo uma melhor conexão entre a função representada e seus coeficientes. Assim é garantida estabilidade numérica na reconstrução e manipulação (LEE & YAMAMOTO, 1994).

Considerando a função complexa ψ que satisfaz as condições da Equação (22) e (23):

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad (22)$$

$$c_\psi = 2\pi \int_{-\infty}^{\infty} \frac{|\Psi(w)|^2}{|w|} dw < \infty \quad (23)$$

onde Ψ é a transformada de Fourier de ψ . A primeira condição (22) implica que a função ψ possui energia finita e a segunda condição, conhecida como condição de admisibilidade, implica que se $\psi(w)$ é suave, $\Psi(0) = 0$. A função ψ é a *mother wavelet* (LEE & YAMAMOTO, 1994).

Dada uma função ψ no set de base ortonormal de funções $L^2(\mathbb{R})$, pode se introduzir a família de funções $\psi_{a,b}$ ($a > 0, b \in \mathbb{R}$), sendo a o parâmetro de escala e b o parâmetro de deslocamento, como apresenta a Equação (24) (CHAN, 2012):

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{(t-b)}{a}\right) \quad (t \in \mathbb{R}) \quad (24)$$

A transformada contínua $F(a,b)$ de uma função f é definida como a Equação (25):

$$F(a,b) = (f, \psi_{a,b}) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{(t-b)}{a}\right) dt \quad (25)$$

De acordo com o teorema de Parseval se obtém a Equação (26) onde a função $\hat{\psi}_{a,b}(w)$ está dada na Equação (27):

$$(f, \psi_{a,b}) = \frac{1}{2\pi} (\hat{f}, \hat{\psi}_{a,b}) \quad (26)$$

$$\hat{\psi}_{a,b}(w) = \sqrt{a} e^{-iwb} \hat{\psi}(aw) \quad (27)$$

No domínio discreto, os parâmetros de escala e deslocamento são discretizados como: $a = a_0^m$ e $b = nb_0$, assim como, as *wavelets* de análise são discretizadas como a Equação (28):

$$\psi_{m,n}(t) = a_0^{\frac{-m}{2}} \psi\left(\frac{(t-nb_0)}{a_0^m}\right) \quad (28)$$

onde m e n são valores inteiros. A transformada discreta de *wavelet* e sua inversa são apresentadas na Equação (29) e (30):

$$S_{m,n} = \int_{-\infty}^{\infty} \psi'_{m,n}(t) s(t) dt \quad (29)$$

$$s(t) = k_{\psi} \sum_m \sum_n S_{m,n} \psi_{m,n}(t) \quad (30)$$

onde k_ψ é um valor constante para a normalização. Ingrid Daubechies construiu uma *wavelet*, na qual a ψ era estruturada compactamente. Para segurar isto foi escolhida uma função ϕ com estrutura compacta (PHINYOMARK *et al.*, 2011).

A função $\phi(t)$ dada na Equação (31) é uma solução da equação funcional.

$$\phi(t) = \sum_{k=-\infty}^{\infty} a_k \sqrt{2} \phi(2t - k) \quad (31)$$

Esta função é contínua, estruturada compacta e satisfaz $\int \phi(t) dt$ para o inteiro N . A estrutura da $\phi(t)$ é $[0, 2N-1]$. No caso da aplicação deste trabalho se escolhe uma função ψ tipo Daubechies pela sua semelhança com os sinais de sEMG (PHINYOMARK *et al.*, 2011; GALLEGO DUQUE *et al.*, 2014). Um exemplo de função de escala ϕ e função wavelet ψ para Daubechies $N = 8$ é dado apenas para mostrar esta semelhança na Figura 7.




Figura 7 Função de escala à esquerda e Função Wavelet a direita para tipo Daubechies $N = 8$.

3.6 ÍNDICE DE LATERALIZAÇÃO NO SINAL DE EEG

O Índice de Lateralização (IL) apresentado na Equação (32) e (33) é usado para expressar os valores da energia dos canais do sinal de EEG contralaterais no tempo, além de ser usado na frequência para observar quais as componentes de frequência com maior discriminação entre as classes.

$$IL_{Lateral} = \frac{[(E_{Padrão Esquerda}^{Canal Esquerdo} - E_{Padrão Esquerda}^{Canal Direito}) + (E_{Padrão Direito}^{Canal Direito} - E_{Padrão Direito}^{Canal Esquerdo})]}{2} \quad (32)$$

$$IL_{Frontal} = \frac{[(E_{Padrão Para Frente}^{Canal Frontal} - E_{Padrão Para Frente}^{Canal Parietal}) + (E_{Padrão Para Trás}^{Canal Parietal} - E_{Padrão Para Trás}^{Canal Frontal})]}{2} \quad (33)$$

onde E representa a Energia do canal captado ante o comando verbal correspondente. Pela sua parte são construídos dois tipos de IL , o lateral que quantifica a atividade das tarefas mentais laterais: “Direita” e “Esquerda”, e o frontal o qual quantifica a atividade para as tarefas frontais: “Para Frente” e “Para Trás“. Este parâmetro representa a contralateralidade da atividade de uma tarefa mental (NAM *et al.*, 2011). IL é usado para quantificar o efeito da dessincronização (ERD/ERS) relacionada a eventos (LEMM *et al.*, 2009). Embora o IL nunca tenha sido usado para mesurar os efeitos do que seria equivalente à contralateralidade nas tarefas mentais frontais, existe a hipótese que as atividades corticais produto destas tarefas produz um efeito similar e é usado neste trabalho para a classificação (DOYLE *et al.*, 2005).

3.7 FILTRO ESPACIAL CSP PARA EEG

Foi usado o método de Filtro de Padrões Espaciais (CSP: *Common Spatial Patterns*) para acrescentar as diferenças das características entre os padrões (“Esquerda” – “Direita”) e entre os padrões (“Para Frente” – “Para Trás”). Este filtro foi proposto para a análise de EEG por KOLES *et al.*, (1991) e empregado com eficácia por outros pesquisadores para maximizar a atividade discriminativa (ERD/ERS) (MÜLLER-GERKING *et al.*, 1999; RAMOSER *et al.*, 2000; PFURTSCHELLER *et al.*, 2003; MACHADO & BALBINOT, 2014; STOCK, 2015). No processamento é achado um subespaço linear para o qual a variância de uma classe projetada é maximizada enquanto a variância da outra é minimizada. Mais específico, os filtros espaciais ótimos são determinados mediante uma diagonalização de duas matrizes de covariância derivadas de duas classes de sinais de EEG (LEE *et al.*, 2004). Por isso, precisa-se de um algoritmo que calcule uma matriz que diagonalize simultaneamente duas matrizes de covariância, tal como mostrado na Equação (34) e (35):

$$W^T \cdot \Sigma^{(+)} \cdot W = \Lambda^{(+)} \quad (34)$$

$$\mathbf{W}^T \cdot \boldsymbol{\Sigma}^{(-)} \cdot \mathbf{W} = \boldsymbol{\Lambda}^{(-)} \quad (35)$$

onde $\boldsymbol{\Sigma}^{(c)}$ é o estimador da matriz de covariância na condição (c) do sinal $\mathbf{x}(t)$. A matriz \mathbf{W} é calculada de forma que a sua matriz identidade é expressa como a Equação (36):

$$\boldsymbol{\Lambda}^{(+)} + \boldsymbol{\Lambda}^{(-)} = \mathbf{I} \quad (36)$$

Valores associados à matriz diagonal $\boldsymbol{\Lambda}^{(c)} \in \mathbb{R}^{c \times c}$ são as variâncias dos novos canais, sendo que se um canal j tem alta variância na condição $\boldsymbol{\Lambda}^{(+)}$ possui baixa variância na condição $\boldsymbol{\Lambda}^{(-)}$ e vice-versa. Para projetar a matriz \mathbf{W} com estas características deve-se decompor a matriz composta de variâncias em seus respectivos autovalores como mostram as Equações (37) e (38):

$$\boldsymbol{\Sigma} = \boldsymbol{\Sigma}^{(+)} + \boldsymbol{\Sigma}^{(-)} \quad (37)$$

$$\boldsymbol{\Sigma} = \mathbf{B} \cdot \boldsymbol{\lambda} \cdot \mathbf{B}' \quad (38)$$

Tendo-se a nova base de autovetores em \mathbf{B} , os quais são vetores ortogonais e $\boldsymbol{\lambda}$ é a matriz diagonal de autovalores. Logo depois, realiza-se uma operação para branqueamento (*Whitening Transformation*) em \mathbf{B} como apresenta as Equações (39) e (40):

$$\mathbf{P} = \boldsymbol{\lambda}^{-\frac{1}{2}} \cdot \mathbf{B} \quad (39)$$

$$\mathbf{P} \cdot \boldsymbol{\Sigma} \cdot \mathbf{P}' = \mathbf{I} \quad (40)$$

A matriz \mathbf{P} equaliza todas as variâncias da matriz composta $\boldsymbol{\Sigma}$, fazendo todos os valores iguais a 1 e descorrelaciona os sinais deixando as suas covariâncias iguais a 0. Transformando as matrizes de covariâncias, se ontem $\mathbf{S}^{(+)}$ e $\mathbf{S}^{(-)}$ que compartilham os mesmos autovetores, como apresentado nas Equações (41) e (42):

$$\mathbf{S}^{(+)} = \mathbf{P} \cdot \boldsymbol{\Sigma}^{(+)} \cdot \mathbf{P}' \quad (41)$$

$$\mathbf{S}^{(-)} = \mathbf{P} \cdot \boldsymbol{\Sigma}^{(-)} \cdot \mathbf{P}' \quad (42)$$

Sendo a somatória dos autovalores de $\mathbf{S}^{(+)}$ e $\mathbf{S}^{(-)}$ igual a 1, representado pela matriz identidade, como expresso na Equação (43):

$$\mathbf{S}^{(+)} + \mathbf{S}^{(-)} = \mathbf{P} \cdot \mathbf{\Sigma} \cdot \mathbf{P}^T = \mathbf{I} \quad (43)$$

Pela sua parte $\mathbf{S}^{(+)}$ e $\mathbf{S}^{(-)}$ podem se relacionar com a matriz \mathbf{U} dos autovetores ortonormais comuns, como mostram as Equações (44) e (45):

$$\mathbf{S}^{(+)} = \mathbf{U} \cdot \mathbf{\Lambda}^{(+)} \cdot \mathbf{U}^T \quad (44)$$

$$\mathbf{S}^{(-)} = \mathbf{U} \cdot \mathbf{\Lambda}^{(-)} \cdot \mathbf{U}^T \quad (45)$$

$\mathbf{\Lambda}^{(+)}$ e $\mathbf{\Lambda}^{(-)}$ são matrizes diagonais de autovalores, onde $\Lambda_j^{(+)}$ e $\Lambda_j^{(-)}$, $j = 1, 2, \dots, C$, determinam quais as colunas \mathbf{w}_j da \mathbf{W} que discriminam mais as duas classes. O filtro espacial \mathbf{W} projeta o sinal $\mathbf{x}(t)$ do espaço original para um novo espaço $\mathbf{x}_{CSP}(t)$ dado pela projeção da matriz \mathbf{P} por \mathbf{U}' , assim como, apresentado na Equação (46):

$$\mathbf{W} = (\mathbf{U}' \cdot \mathbf{P})' \quad (46)$$

Colunas \mathbf{w}_j com melhor discriminação serão os valores $\Lambda_j^{(c)}$ mais perto de 1 para cada classe (BLANKERTZ *et al.*, 2008).

Aplicando o estimador de covariância para cada uma das trilhas (*trials*) e condições ou padrões do sistema tem-se a Equação (47):

$$\mathbf{\Sigma}^{(c)} = \frac{1}{N} \sum_{n=1}^N \frac{\mathbf{X}_{(c)}^n \cdot \mathbf{X}_{(c)}^{n'}}{\text{trace}(\mathbf{X}_{(c)}^n \cdot \mathbf{X}_{(c)}^{n'})} \quad (47)$$

Define-se o traço (*trace*) como a soma dos valores da diagonal do produto. Inicia-se assim o algoritmo empregado e apresentado na Figura 8, para cada par de padrões ou condições a classificar, os quais são \mathbf{X}_D (“Direita”) e \mathbf{X}_E (“Esquerda”) para a obtenção dos filtros para paradigmas laterais; e por fim, \mathbf{X}_{PF} (“Para Frente”) e \mathbf{X}_{PT} (“Para Trás”) para a obtenção dos filtros para paradigmas frontais.

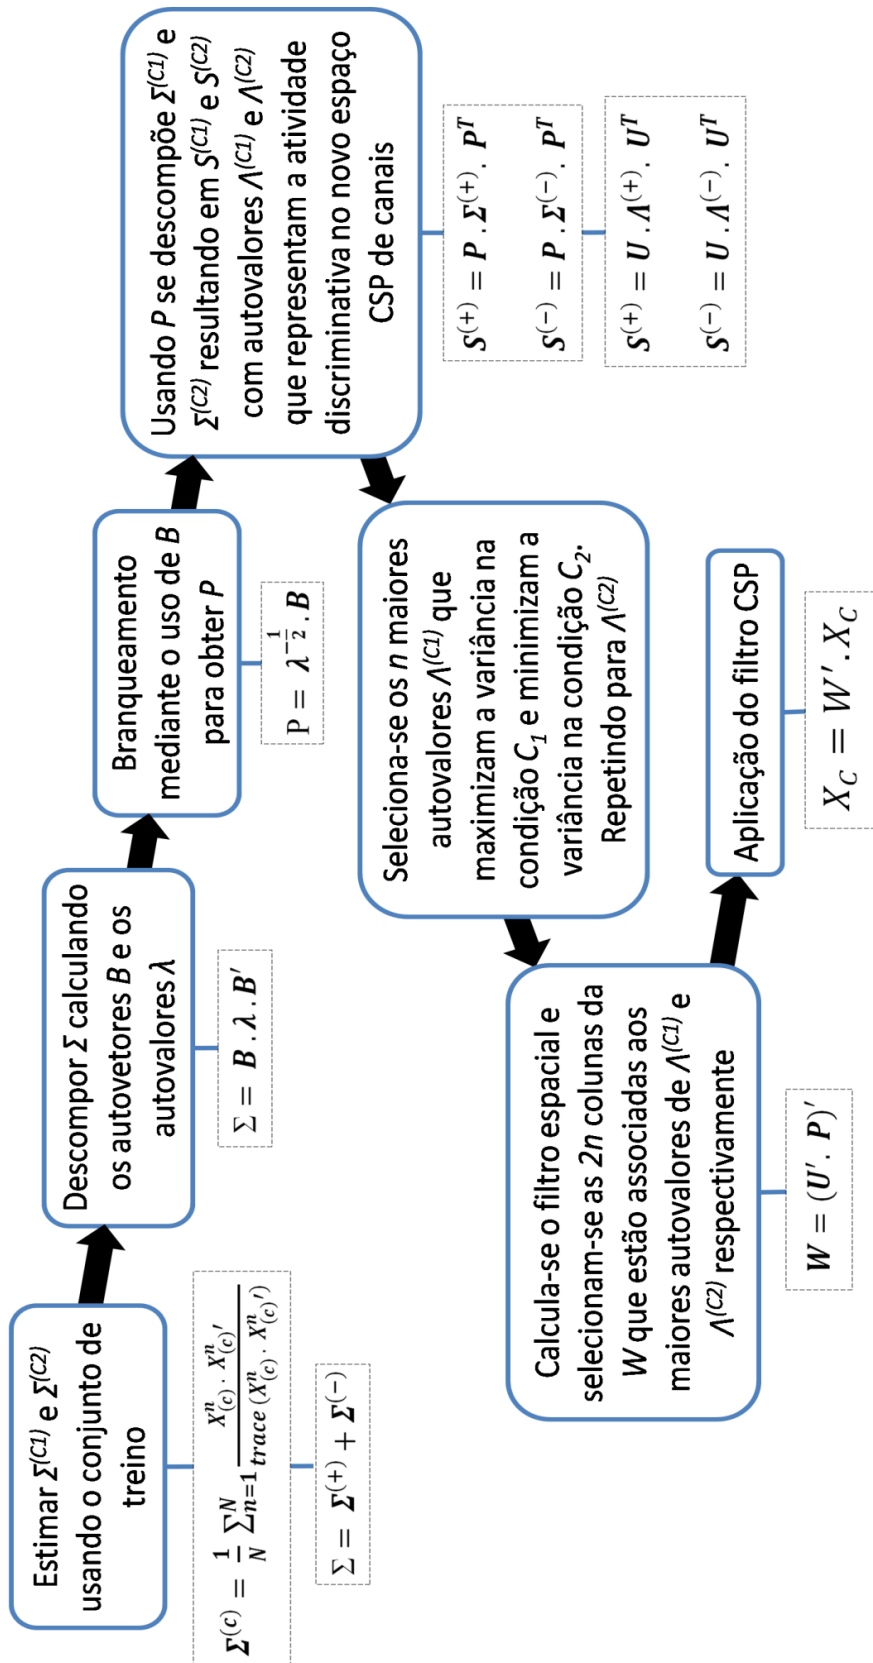


Figura 8 Fluxograma com descrição passo a passo do algoritmo para obtenção e aplicação do filtro CSP.

3.8 MÉTODO DO PERIODOGRAMA MODIFICADO DE WELCH PARA EXTRAÇÃO DE CARACTERÍSTICAS NO EEG

Como analisado no Capítulo 2.3, as características dos movimentos faciais gerados pelas tarefas verbais, influenciam as componentes de frequência do ritmo sensório-motor. Por isso, uma forma para caracterizar a ativação cortical produto destas tarefas é a estimação das componentes de frequência. Neste trabalho é usado o Periodograma Modificado de *Welch* como estimador espectral.

No ano 1967, Welch propôs modificações ao método de Bartlett (BARTLETT & KENDALL, 1946), dentre as quais estavam o solapamento de segmentos de dados, conhecido como *overlap*. Supondo que entre duas sequências consecutivas um deslocamento de D pontos e cada sequência possui L pontos de comprimento, a sequência i -ésima é determinada pela Equação (48):

$$x_i(n) = x(n + iD) \quad n = 0, 1, \dots, L - 1 \quad (48)$$

O solapamento entre duas sequências consecutivas $x_i(n)$ e $x_{i+1}(n)$ é $L - D$ pontos, e se K sequências cobrem o comprimento de N pontos, então:

$$N = L + D(K - 1) \quad (49)$$

Para um 50% de solapamento entre as sequências se podem formar K sequências de comprimento $2L$, onde K é representado pela Equação (50):

$$K = \frac{N}{L} - 1 \quad (50)$$

Desta forma é melhorada a resolução mantendo a variância. Foi introduzido também o janelamento de cada sequência $x_i(n)$ com uma janela geral $w(n)$. Assim é obtido um periodograma modificado por cada sequência. O estimador de Welch é a média dos periodogramas modificados e sua expressão é apresentada pela Equação (51):

$$\hat{S}_W(e^{jw}) = \frac{1}{KLU} \sum_{i=0}^{K-1} \left| \sum_{n=0}^{L-1} w(n)x(n + iD)e^{-jnw} \right|^2 \quad (51)$$

onde U está dada pela Equação (52):

$$U = \frac{1}{L} \sum_{n=0}^{L-1} |w(n)|^2 \quad (52)$$

A resolução na frequência vai depender muito da forma da janela no tempo do sinal. Os principais efeitos de se aplicar uma janela ao sinal é a perda de resolução no domínio frequência (OPPENHEIM, SCHAEFER e BUCK, 1998). A resolução é influenciada diretamente pelo lóbulo principal e o “vazamento” (*leakage*, proveniente da transformada de Fourier da janela) adiciona uma tendência ao estimador nas frequências adjacentes à frequência de interesse (STOICA e MOSES, 2005).

Na prática, o erro aleatório definido pela Equação (54) pode ser reduzido dividindo o sinal janelado em diversos subtrechos de tamanho n_d logo ter calculado o estimador da densidade espectral de potência como na Equação (53):

$$\hat{G}_{xx}(f) = \frac{2}{n_d T_d} \sum_{i=1}^{n_d} |X_i(f, T_d)|^2 \quad (53)$$

$$\varepsilon_R[\hat{G}_{xx}(f)] = \frac{\sigma[\hat{G}_{xx}(f)]}{\hat{G}_{xx}(f)} = \frac{\sqrt{2n}}{n} = \sqrt{\frac{2}{n}} \quad (54)$$

O método do periodograma de *Welch* permite que as janelas segmentadas se sobreponham em até 50% do seu tamanho, permitindo um número maior de janelas, visando obter um valor menor do erro aleatório, como apresentado na Equação (54) (STOICA e MOSES, 2005).

Os métodos matemáticos apresentados no Capítulo 3 representam a base do processamento e classificação dos sinais de sEMG e EEG usados no trabalho. No Capítulo 4 é descrita a Metodologia empregada para a realização das coletas de dados, assim como, a implementação de cada um dos métodos descritos no Capítulo 3.

4 METODOLOGIA EXPERIMENTAL

A Figura 9 apresenta o diagrama de blocos do sistema experimental desenvolvido. O primeiro bloco representa o posicionamento dos eletrodos de sEMG, nos músculos da face, e a touca utilizada para a captura do sinal de EEG com eletrodos posicionados no escalpo de acordo com o Sistema Internacional 10-20. O sujeito é estimulado por comandos de áudio determinando que o mesmo fale ou tente falar em um intervalo de 10 segundos, as seguintes palavras: Direita, Esquerda, Para Trás e Para Frente. A touca de eletrodos envia os sinais de EEG via Bluetooth à porta USB do computador e os sinais de sEMG são condicionados pelo eletromiógrafo, digitalizados pela placa A/D e são enviados ao computador pela porta USB. A placa de áudio do computador é usada para estimulação sonora do sujeito e aquisição do som provocado quando na repetição dos comandos verbais.

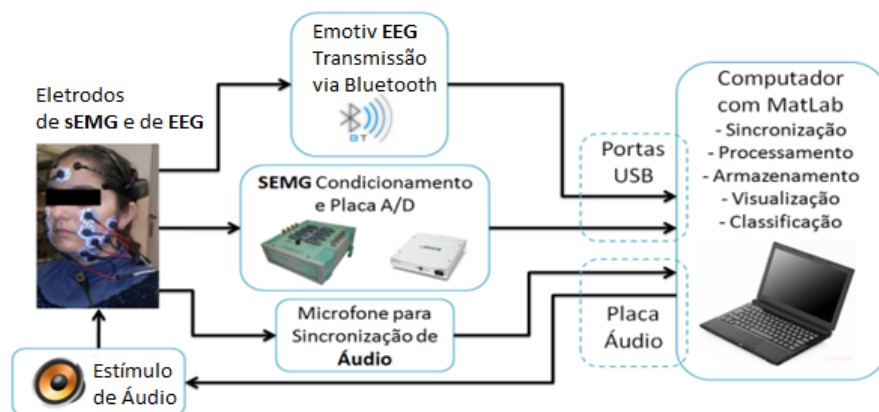


Figura 9 Diagrama de Bloco do Sistema Experimental Proposto.

Os biosinais são armazenados em três arquivos para cada ensaio, contendo um arquivo de sEMG com 7 canais, de EEG com 14 canais e de Áudio com 2 canais. São utilizados na captura dos biosinais a touca EEG Emotiv EPOC/EPOC+ (14 canais), o eletromiógrafo EMG 830C, Brasil Systems (de até oito canais), uma placa A/D NI-USB-6289, da National Instruments (de até 32 canais), eletrodos descartáveis para sEMG (modelo MSGST-06, marca Solidor - tamanho 44x32 mm) e um microfone de lapela 3,5 mm Stéreo Profissional.

4.1 METODOLOGIA USADA E DESCRIÇÃO DA AMOSTRA

Neste trabalho foram selecionados dois grupos de estudo. O primeiro grupo tem características: sujeitos saudáveis, entre 22 e 35 anos, de ambos os sexos, como apresentado na Tabela 2. O segundo grupo é composto por sujeitos com sequelas de AVC, com idades entre 59 anos e 75 anos, do sexo masculino como apresentado na Tabela 2. Os ensaios com voluntários saudáveis foram realizados no Laboratório de Instrumentação Eletro-Eletrônica (IEE) da Universidade Federal de Rio Grande do Sul (UFRGS). Os ensaios no Hospital de Clínicas de Porto Alegre (HCPA) foram realizados com o grupo de pacientes disártricos pós AVC agudo, internados na Unidade de AVC, onde a Disartria foi classificada através do domínio Disartria da Escala de AVC do *National Institute of Health Stroke Scale* (NIH) (Anexo B), validado para seu uso no Brasil.

Tabela 2. Características de ambos os grupos de voluntários participantes nos ensaios.

Código	Idade	Sexo	Estado	Tipo de AVC	Lado Atingido	Tempo Tratamento	Grau de Disartria
01	32	M	Saudável	-----	-----	-----	0 (Normal)
02	28	F	Saudável	-----	-----	-----	0 (Normal)
03	33	F	Saudável	-----	-----	-----	0 (Normal)
04	35	M	Saudável	-----	-----	-----	0 (Normal)
05	22	F	Saudável	-----	-----	-----	0 (Normal)
06	30	M	Saudável	-----	-----	-----	0 (Normal)
07	29	F	Saudável	-----	-----	-----	0 (Normal)
08	62	M	Disartria	AVC Isquêmico com Transformação Hemorrágica	Esquerdo (Núcleos da base)	9 dias	1 (Leve a Moderada)
09	68	M	Disartria	AVC Isquêmico	Direito (Artéria Cerebral Média)	12 dias	1 (Leve a Moderada)
10	70	M	Disartria	AVC Isquêmico	Direito (Artéria Cerebral Posterior)	11 dias	1 (Leve a Moderada)
11	62	M	Disartria	AVC Isquêmico	Direito (Artéria Cerebral Média)	7 dias	1 (Leve a Moderada)
12	59	M	Disartria	AVC Isquêmico	Esquerdo (Fossa posterior)	16 dias	1 (Leve a Moderada)
13	75	M	Disartria	AVC Isquêmico	Esquerdo (Núcleo caudado, cápsula interna)	7 dias	1 (Leve a Moderada)
14	71	M	Disartria	AVC Isquêmico	Esquerdo (Artéria Cerebral Média)	7 dias	2 (Grave)

O consentimento informado foi obtido dos voluntários envolvidos através da assinatura do Termo de Consentimento Livre Esclarecido (TCLE), o qual foi devidamente explicado pelo pesquisador mediante dúvidas e questionamentos (Anexo C). O Projeto com identificação: “Aquisição e Processamento de Biosinais de Eletromiografia de Superfície e Eletroencefalografia para Caracterização de Comandos Verbais ou Intenção de Fala mediante seu Processamento Matemático” foi aprovado pelo Comitê de Ética do HCPA com número CAAE: 47633915.7.0000.5327.

4.1.1 TÉCNICAS E PROCEDIMENTOS DE COLETA DE DADOS

Primeiramente se realiza a calibração do sistema de aquisição de dados, fazendo testes preliminares para verificar o bom funcionamento. Logo depois são colocados os eletrodos de sEMG, a touca de EEG e também um pequeno microfone é posicionado perto da boca do sujeito para captar o áudio que permite o sincronismo dos sinais de interesse. O sujeito escuta uma gravação onde é explicado o teste antes de iniciar a captação dos sinais, tal como apresentado na Figura 10, para as coletas realizadas em voluntários saudáveis e na Figura 11 para pacientes disártricos.




Figura 10 Foto de um dos ensaios realizados com voluntários saudáveis.



Figura 11 Foto de um dos ensaios com voluntários com Disartria pós AVC.

As coletas foram divididas em duas partes:

- na primeira parte o sujeito tinha que repetir em alta voz cada padrão e pensar em realizar o movimento segundo o padrão, com três repetições sequenciais para cada padrão, com um intervalo de 10 segundos entre cada repetição. Este ciclo é repetido duas vezes para cada padrão. Logo, os arquivos das aquisições são armazenados no computador. O tempo para esta primeira etapa do teste é de 20 minutos para cada sujeito;
- na segunda parte do teste, o sujeito tinha somente que pensar em realizar o movimento correspondente ao padrão, com três repetições sequenciais para cada padrão e igualmente com um intervalo de 10 segundos entre cada repetição. Este ciclo é repetido duas vezes. Os arquivos das aquisições são armazenados no computador. O tempo para esta segunda etapa do teste é de 20 minutos também para cada paciente.

Cada coleta apresenta tempo total de 40 minutos para cada sujeito, mais 10 minutos de preparação do sujeito para a realização do teste. Estabelecendo um total de 50 minutos do tempo de duração para cada sujeito.

4.1.2 INTERFACE PARA CAPTURA E SINCRONISMO DOS SINAIS

Como interface para realizar a aquisição dos dados é utilizada a ferramenta Simulink do MatLab versão R2010b, onde são capturados os três sinais para permitir sincronizar no tempo os biosinais com o sinal de Áudio como mostrado na Figura 12.

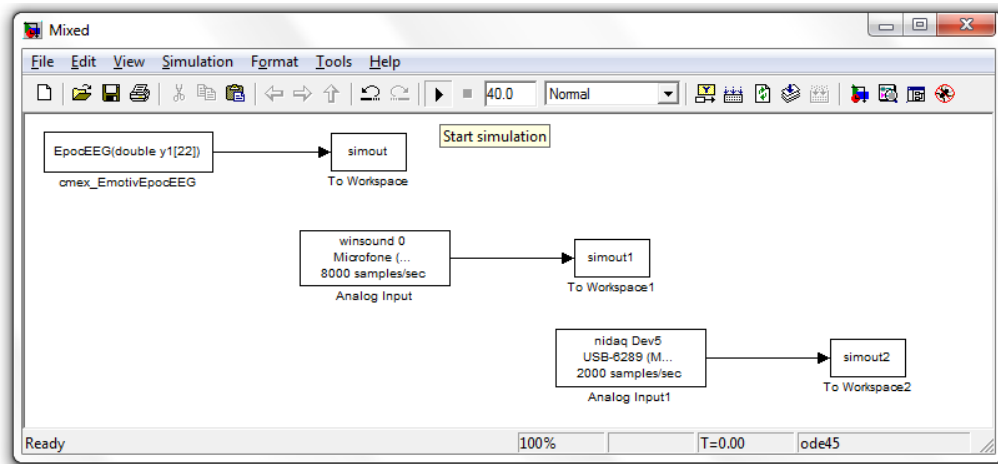


Figura 12 Tela do código implementado no Simulink versão R2010b para captura dos sinais de sEMG, EEG e Áudio.

Em um intervalo de 40 segundos são gravados três arquivos usando a interface do Simulink. Estes arquivos correspondem aos três elementos de entrada:

1. Bloco EmotivEpodEEG: para o sinal que aparece na porta serial da touca EEG Emotiv. Este sinal chega via receptor de Bluetooth pela porta COM 1, USB 2.0 do computador e é interligado com o MatLab vR2010b mediante um software fornecido pelo fabricante da touca EEG Emotiv, que atua como servidor para estabelecer a comunicação entre as partes. Este elemento possui uma frequência de amostragem de 128 Hz e sua função é adquirir os 14 canais de EEG da touca EEG Emotiv;

2. NIDAQ Dev5 USB-6289: para gerenciar a placa A/D cujo sinal é disponibilizado em uma porta USB 2.0. O *driver* fornecido pelo fabricante (National Instruments) da placa permite o reconhecimento da mesma pelo software MatLab vR2010b, em especial pelo Simulink. A frequência usada para amostragem foi de 2000 Hz para um total de 7 canais a serem capturados;
3. Bloco Winsound: o áudio é adquirido via a placa de áudio do computador com um microfone comercial. Este permite a digitalização deste sinal sonoro para ser usado posteriormente na sincronização dos sinais fisiológicos e a sua segmentação. A amostragem ocorre a 8000 Hz e são amostrados 2 canais.

Logo depois dos 40 segundos, estes sinais são gravados no Workspace do MatLab vR2010b para seu processamento pelas outras funções implementadas.

A Figura 13 apresenta, como exemplo, parte da sincronização dos biosinais de sEMG (Figura 13 (b)) e EEG (Figura 13 (c)) e o sinal de áudio gerado no momento da repetição de cada comando (“Direita”, “Esquerda”, “Para Frente”, “Para Trás”), mostrado na Figura 13 (a).

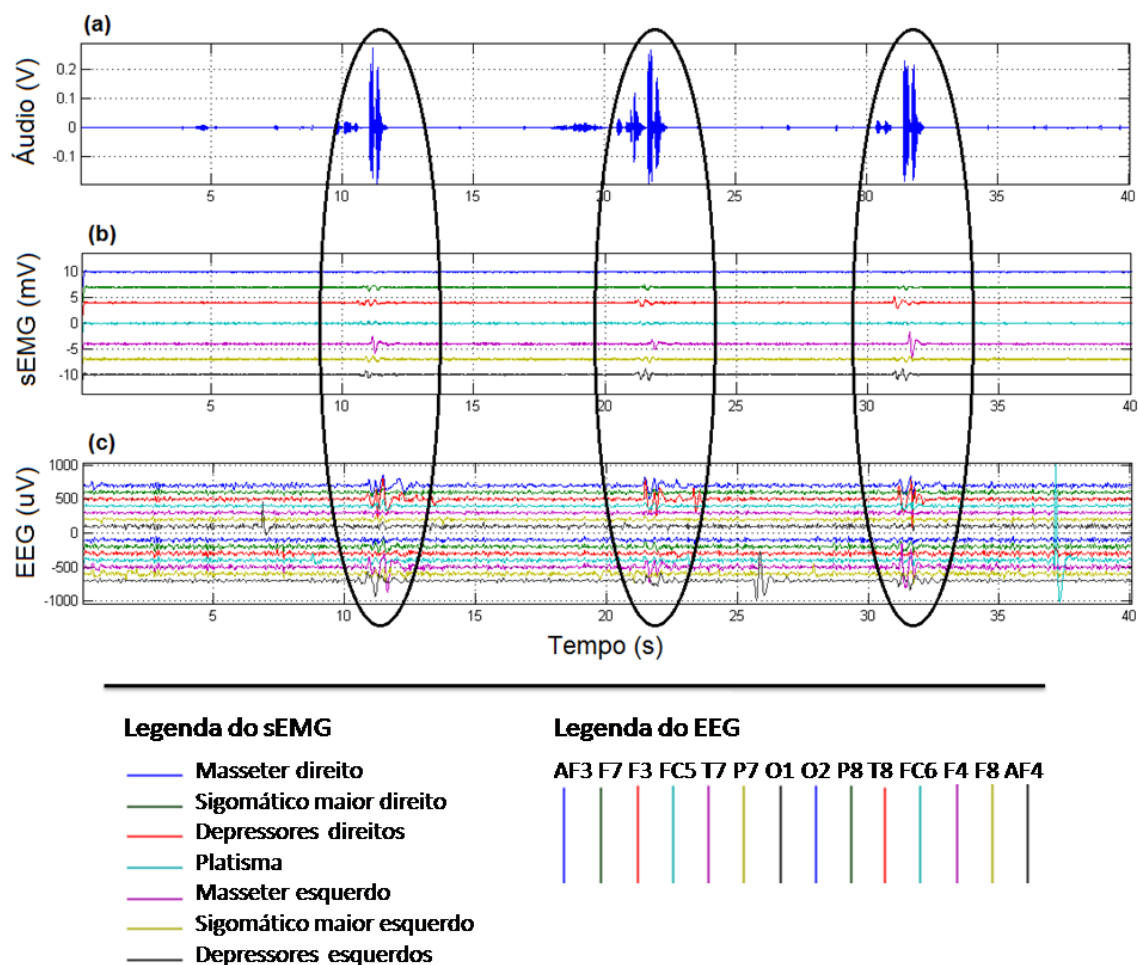


Figura 13 Exemplo dos sinais captados sincronizados (comando “Para frente”, falado): (a) Sinal de áudio, (b) Sinal de sEMG e (c) Sinal de EEG.

Os intervalos de interesse das três repetições do comando representado na Figura 13 são destacados mediante elipses. Alterações visíveis nos canais de EEG podem evidenciar artefatos musculares da face na área pré-frontal, os quais foram estudados em outro trabalho (GALEGO *et al.*, 2015) e que não são fonte de investigação no presente trabalho, assim como, métodos para minimização de artefatos não foram implementados. O sinal de áudio da Figura 13 (a) é usado para a segmentação dos sinais de sEMG e de EEG. Estimam-se 10 segundos para realizar a segmentação partindo do sinal de áudio, o qual delimita o momento médio no caso do sEMG para efetuar a segmentação e no caso do EEG o início para segmentar o sinal. A seguir serão apresentados detalhes dos blocos principais deste aparato experimental proposto.

4.2 POSICIONAMENTO DOS ELETRODOS PARA CAPTAÇÃO DE sEMG E DE EEG

Os sinais de sEMG foram captados pelos eletrodos posicionados nos músculos da face: Masseter (EM bilateral), Zigomático maior (ES bilateral), Platisma (EP), os Depressores (ED bilateral, incluindo o Depressor do lábio inferior e o Depressor do ângulo da boca) e a Referência (ER colocado na frente) segundo apresentado na Figura 14 (a). Os sinais de EEG foram captados pelos eletrodos posicionados no escalpo de acordo com o Sistema Internacional 10-20: canais frontais (AF3, AF4, F3, F4, F7, F8) e fronto-central (FC5, FC6) área occipital (O1, O2), parietal (P7, P8), com P3, P4 como referências e temporais (T7, T8), como representados na Figura 14 (b).

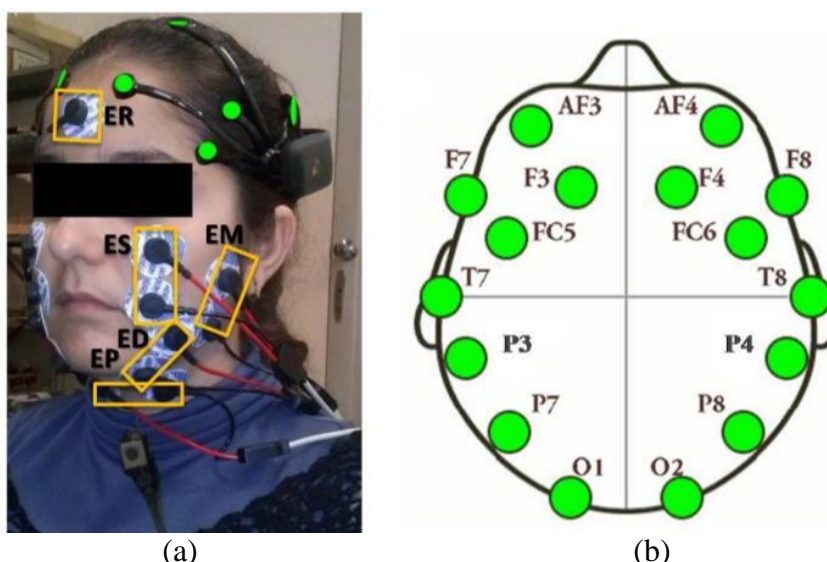


Figura 14 Imagem (a) Posicionamento dos eletrodos de sEMG na face e (b) Posição dos eletrodos de EEG segundo o Sistema 10-20 da touca EMOTIV. Figura (b) adaptada de (EKANAYAKE, 2011).

Para a fixação dos eletrodos de EMG e o posicionamento da touca com eletrodos de EEG foram seguidos os procedimentos tradicionais de limpeza da pele e as recomendações dos fabricantes dos produtos utilizados.

4.3 PROCESSAMENTO DOS SINAIS DE sEMG E DE EEG

Após a aquisição dos biosinais (sEMG e EEG), estes são primeiramente filtrados e normalizados, seguindo a mesma metodologia, mas se diferenciando nas faixas de frequência usadas, assim como apresenta a Figura 15.

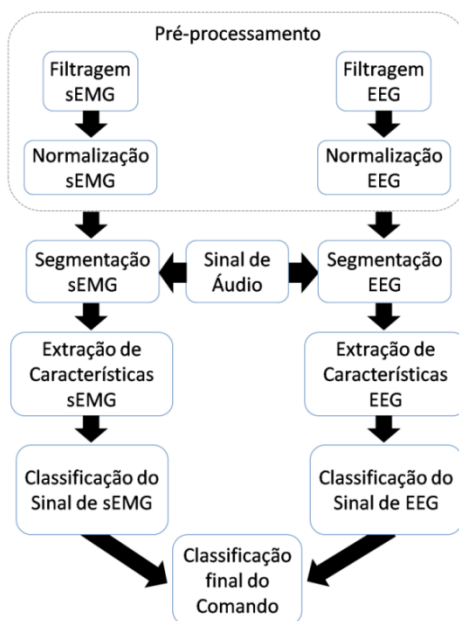


Figura 15 Fluxograma primário para processamento dos sinais na preparação para a classificação.

Logo após o procedimento de filtragem, ambos os sinais foram normalizados na amplitude, deixando-os no intervalo de $-1 \text{ V/V} - 1 \text{ V/V}$. Para a segmentação foi escolhido o sinal de áudio para ter uma referência de tempo, devido a que a atividade dos músculos da face (sEMG) acontece desde segundos antes da maior amplitude no sinal de áudio e termina segundos depois. Pela sua parte, a atividade cortical referente ao comando verbal (EEG) é gerada segundos depois do comando verbal (NAM *et al.*, 2011), usando o pico do sinal de áudio como momento de início da tarefa mental. A seguir, foram extraídas as características dos sinais usando para sinal de EEG um filtro espacial CSP, visando à melhora da discriminação entre classes e o método do Periodograma Modificado de *Welch* para estimação espectral. Do EEG foram extraídas características espectrais e temporais. Para o sinal sEMG

foi implementada a Transformada Discreta *Wavelet* (DWT) para sua decomposição em frequência, aumentando o espaço de vetores para a extração das características temporais. Por fim, são realizadas as classificações empregando classificador SVM implementado para o sinal sEMG e classificador NB para o sinal EEG. Logo após o procedimento de classificação realiza-se a classificação final usando os resultados das *Accuracy* atingidas nas classificações anteriores. A seguir são descritos os principais blocos do processamento e classificação dos sinais.

4.3.1 NORMALIZAÇÃO E FILTRAGEM DOS SINAIS DE SEMG E DE EEG

A filtragem digital é realizada mediante a criação de filtros de resposta finita ao impulso (FIR) para cada tipo de sinal, pois cada um possui faixas de frequências diferentes. Para obter zero defasagem é usada a função *filtfilt* do MatLab vR2010b para coeficientes gerados por aproximação *Butterworth* de 4ª Ordem, a qual é usada pela resposta maximamente plana na banda passante, obtendo resultados como o da Figura 16 (c). Esta função processa os dados em direção para frente e logo depois à inversa, obtendo zero distorção de fase e magnitude (OPPENHEIM *et al.*, 1989). Junto com a filtragem é minimizado um possível *offset* do sinal, (ou sinal DC), para re-estabelecer a linha base do registro, afetado por outros sinais de muita baixa frequência (Figura 16 (b)). Por isso, realizou-se o cálculo da média de cada sinal para logo depois subtrair o mesmo dos sinais ponto a ponto, assim como mostrado na Equação (55):

$$x_i(n) = x_i(n) - \frac{\sum_{i=1}^N x_i(n)}{N} \quad (55)$$

onde $x_i(n)$ representa o sinal a ser minimizado o *offset*, n o n -ésimo valor da amostra e N o total de amostras do sinal. Em seguida os sinais são normalizados seguindo o procedimento da Equação (56):

$$x_i(\mathbf{n}) = \frac{x_i(\mathbf{n})}{\max|x(\mathbf{n})|} \quad (56)$$

tendo em conta uma saída entre -1 e 1 , para todos os sinais como apresentado na Figura 16

(d).

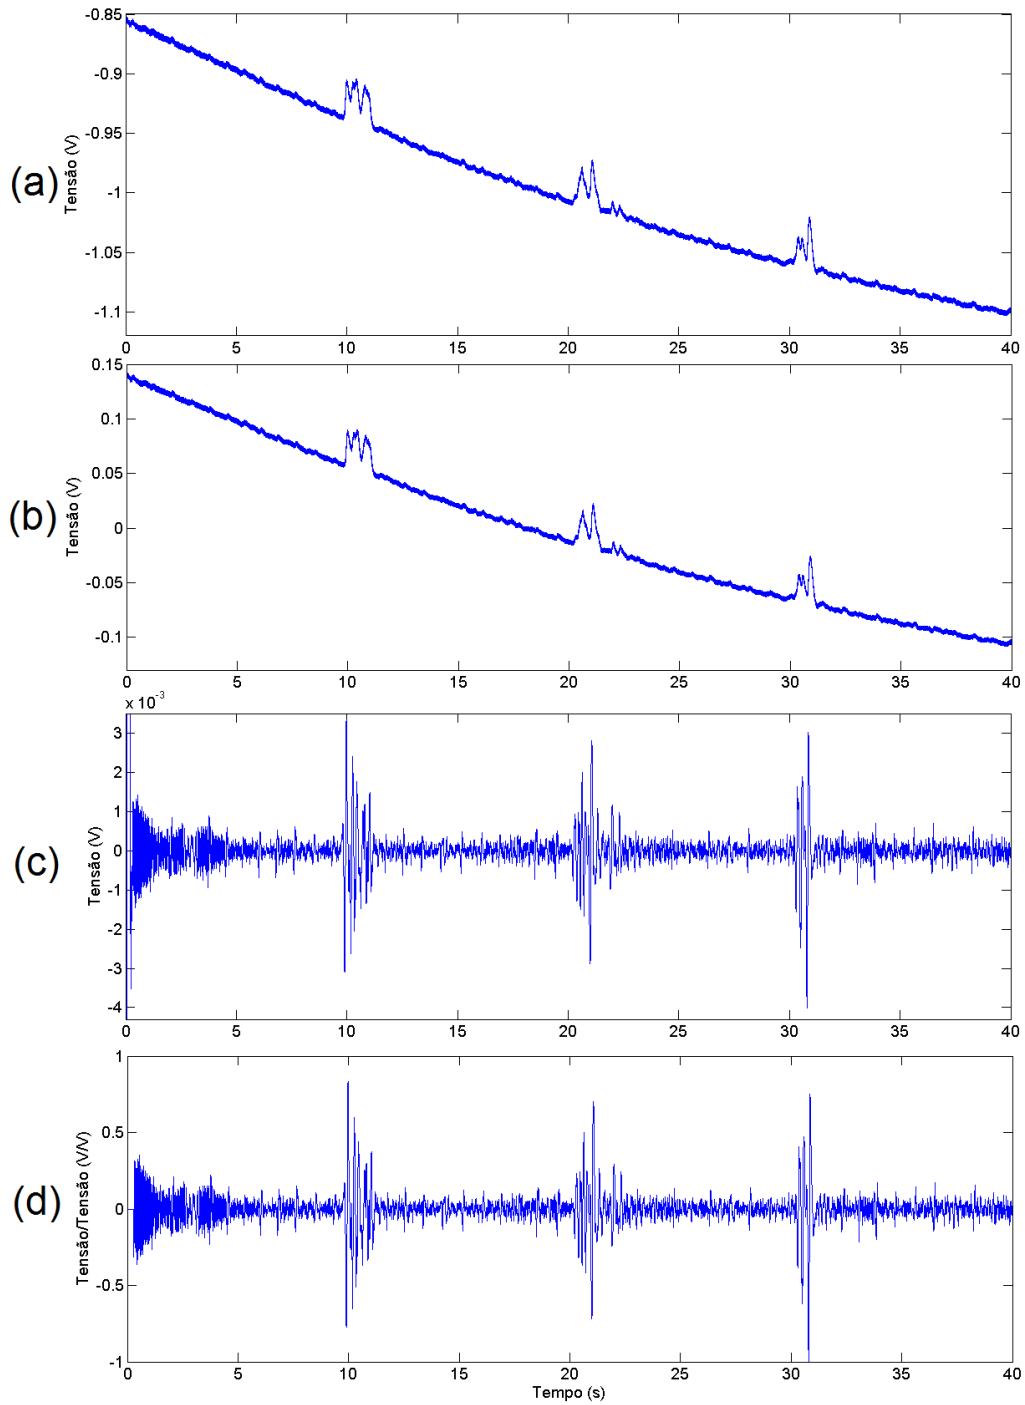


Figura 16 Pre-processamento do sinal de sEMG: (a) Sinal bruto, (b) Sinal sem a componente *offset* ou sinal DC, (c) Sinal filtrado em frequência e (d) Sinal normalizado pronto para Segmentação.

O Diagrama de blocos da Figura 17 apresenta a implementação da função para filtragem dos sinais, normalização e remoção da componente *offset*.

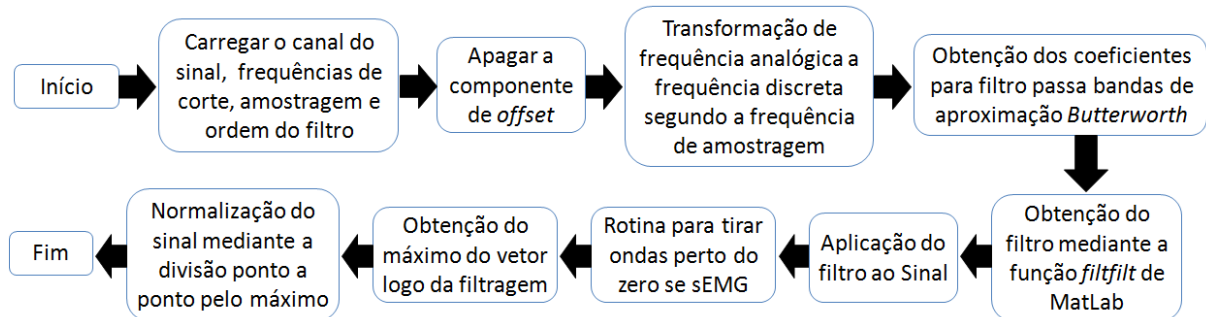


Figura 17 Diagrama de Blocos da função de filtragem, remoção de offset e normalização.

Os registros de sinais de sEMG são filtrados na faixa de frequência de 10 – 150 Hz, onde se encontra a maior concentração de energia dos sinais de interesse deste trabalho. Logo da aplicação do filtro, uma rotina na função de filtragem zera as primeiras amostras do sinal de sEMG, pois produto do transiente da ligação da placa de aquisição aparecem alterações não desejadas no início do sinal. Em seguida é realizada a normalização dos sinais estudados, assim como representado na Figura 17. A normalização para ambos os sinais é realizada dividindo ponto a ponto os valores do sinal pelo valor máximo do canal em questão, como apresentado na Equação (56). Como observado na Figura 16 (b), o sinal é levado em amplitude até a média do mesmo e logo da filtragem se observam na curva (Figura 16 (c)) a ativação produto da repetição dos três comandos verbais. Um gráfico com o espectro de um sinal (sEMG) antes e depois da filtragem é apresentado na Figura 18 (a) e 18 (b) apenas como exemplo.




Figura 18 Espectro do sinal de sEMG (a) antes da filtragem e (b) depois da filtragem.

Observa-se uma região de maior energia nas baixas frequências dada pela velocidade de reação dos músculos ativados pelo comando verbal. Estes comandos verbais produzem ativação nos sinais de EEG e estes são processados com os mesmos blocos de sEMG de filtragem e normalização. No sinal de EEG a faixa de frequência varia dado pela ativação dos ritmos μ e β , os quais intervêm no fenômeno de ERS/EDR. Em função disso, o sinal é filtrado na faixa de 8 – 12 Hz e de 18 – 26 Hz, que correspondem respectivamente aos ritmos μ e β . Filtros passa bandas foram implementados para este fim e a ação de filtrar somente na faixa de μ , somente na faixa de β ou nas duas as faixas é analisada e discutida no Capítulo 5. Um registro de sinal de EEG é apresentado na Figura 19 como exemplo.

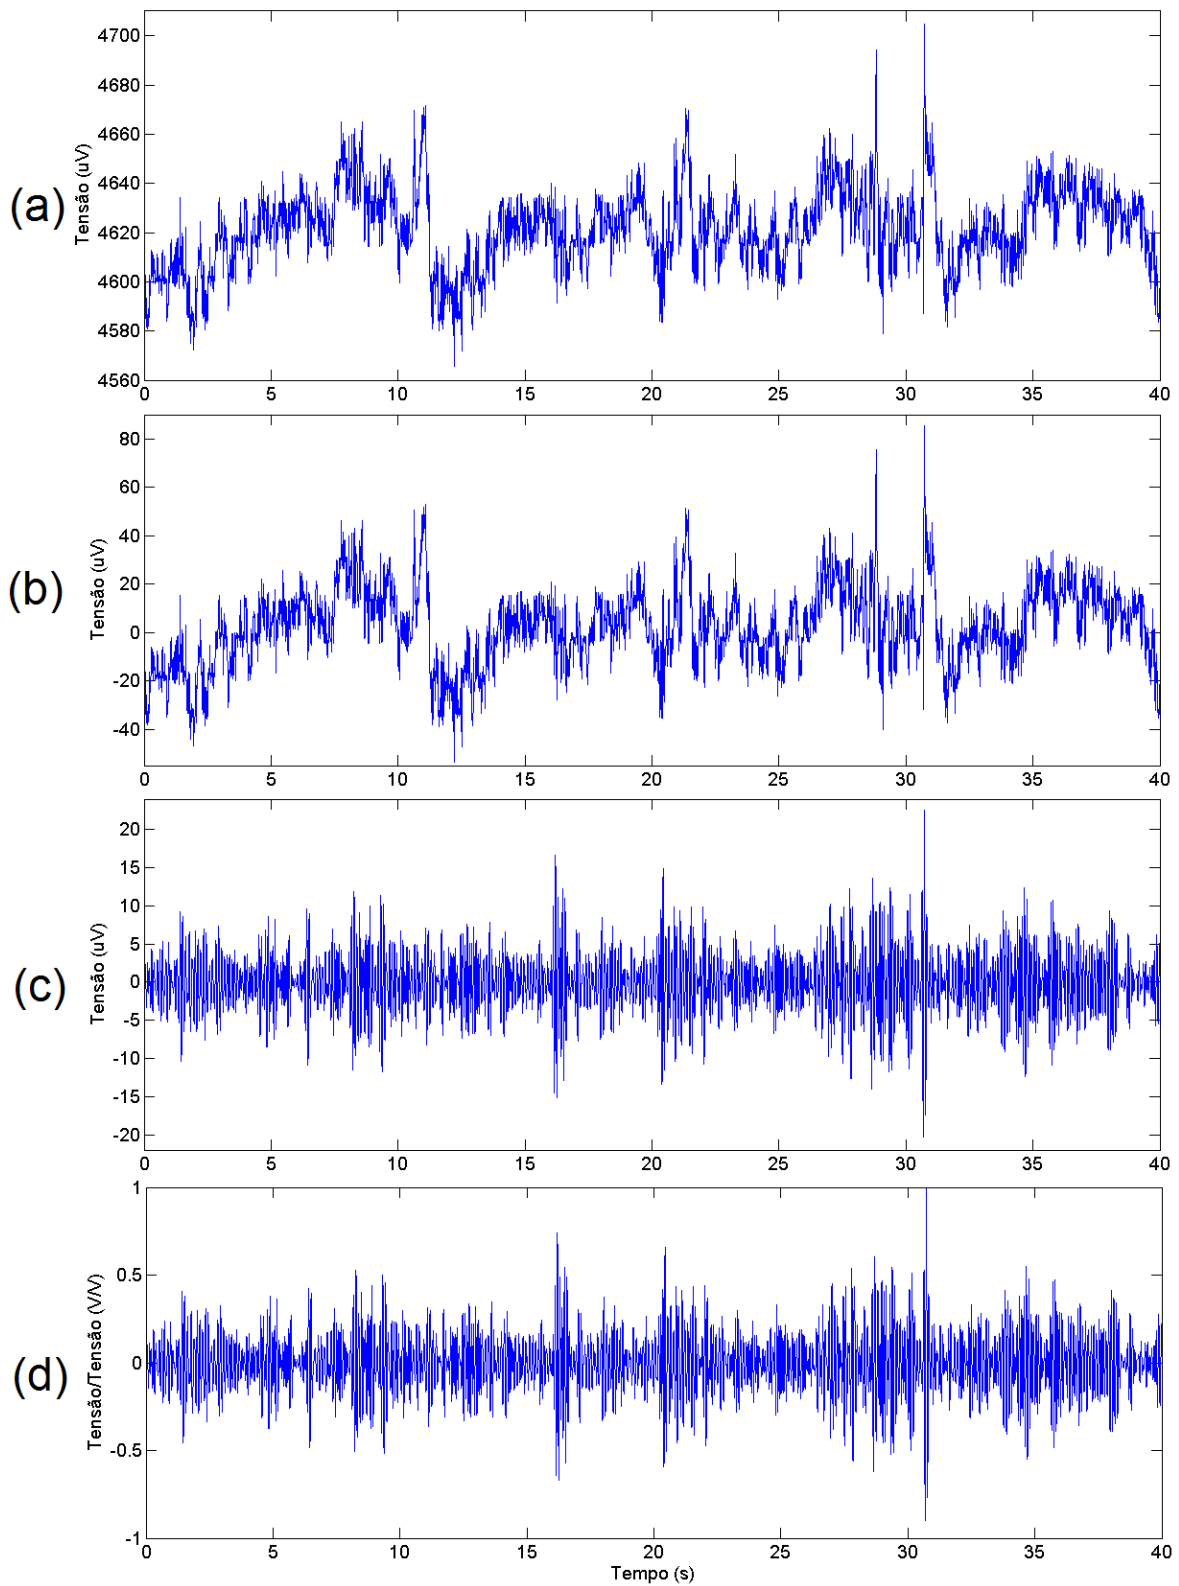


Figura 19 Pre-processamento do sinal de EEG, (a) Sinal bruto, (b) Sinal sem a componente DC, (c) Sinal filtrado em frequência e (d) Sinal normalizado pronto para Segmentação.

Na Figura 19 (a) e (b) se observa no sinal bruto a ausência de linha base do sinal, a qual é reconstruída logo da filtragem. Neste ponto o sinal de EEG é mais parecido com o sinal senoidal de frequência que varia com a ativação cortical do cérebro. No caso dos comandos verbais, estes produzem uma contralateralização entre os lóbulos cerebrais que são usados posteriormente no trabalho para a classificação. Os sinais podem ter a influencia de artefatos, e outros tipos de interferências, mas este tipo de abordagem, assim como, procedimentos para sua minimização não são parte do escopo deste trabalho. Como exemplo, a Figura 20 apresenta o espectro de um sinal de EEG antes e depois da filtragem e normalização. É importante ressaltar, que neste trabalho, nenhum método matemático para minimização de artefatos em sinais de EEG foi desenvolvido.




Figura 20 Espectro do sinal de EEG (a) antes da filtragem e (b) depois da filtragem.

Como observado na Figura 20, o ritmo μ possui maior energia que o β . Estimulado pelas diferenças encontradas entre os ritmos propõe-se sua avaliação no projeto de

experimentos apresentado no Capítulo 5, visando observar as diferenças nos resultados de classificação. O sinal de áudio é filtrado também com o objetivo de mitigar ruídos que possam dificultar a segmentação dos registros mediante o uso deste sinal de referência.

4.3.2 SEGMENTAÇÃO DOS SINAIS DE sEMG E DE EEG

Após a etapa de filtragem e de normalização dos sinais de sEMG e de EEG e considerando-se que os sinais foram sincronizados no momento da aquisição, a próxima etapa do processamento dos biosinais foi a segmentação dos mesmos considerando-se o sinal de áudio captado como referência. Os picos no sinal de áudio permitiram escolher uma janela de tempo de ± 5 s, para realizar a segmentação do sEMG e uma janela de 7 s, para o sinal do EEG. Partindo do fato de que quando um comando verbal é gerado alguns músculos da face são ativados e áreas do córtex motor também, se pode empregar o sinal de áudio para realizar a segmentação nos momentos de maior energia de cada sinal. O diagrama de blocos da Figura 21 mostra cada um dos pasos da etapa de segmentação para ambos os sinais de interesse neste trabalho.

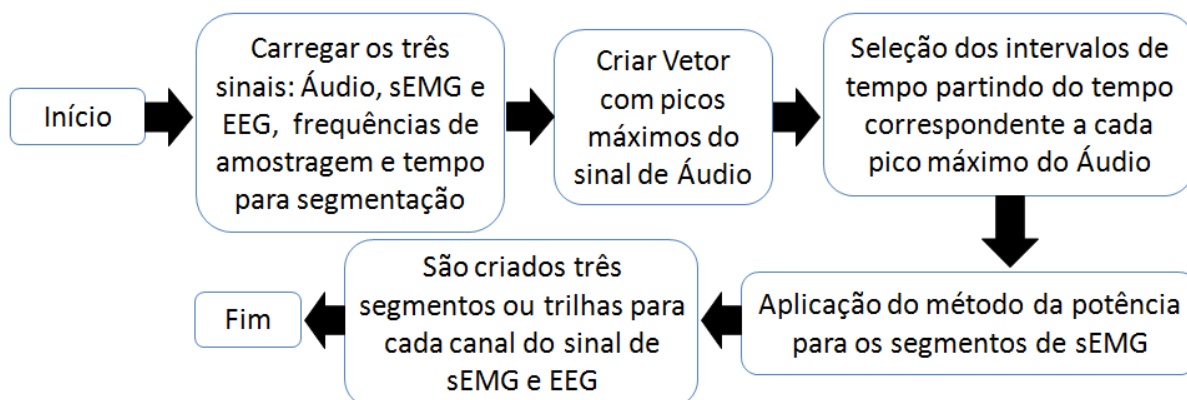


Figura 21 Diagrama de Blocos da função de segmentação.

Como apresentado na Figura 21, primeiramente foram carregados os sinais e os valores de frequência de amostragem e tempo para segmentar no intervalo dos sinais de

estudo. Com o sinal de áudio foram selecionados os picos máximos do sinal, usando um limiar obtido de forma experimental com valor 5 vezes maior à média deste sinal (calculada ponto a ponto e tendo em conta o *silêncio* do sinal). Logo após a determinação desses picos ou marcadores temporais, foi escolhido intervalos de ± 5 s de cada pico para o sinal de sEMG, e escolhido intervalos de 7 s depois de cada pico para o sinal de EEG, pois considera-se, neste trabalho, que a atividade cortical de interesse somente é disparada depois de ter sido executado o comando verbal. Visando obter os segmentos do sinal de sEMG com a maior concentração de energia é aplicado um método baseado na análise da energia do sinal no domínio do tempo. Este método é nomeado neste trabalho como método da potência e seu diagrama de blocos encontra-se na Figura 22.

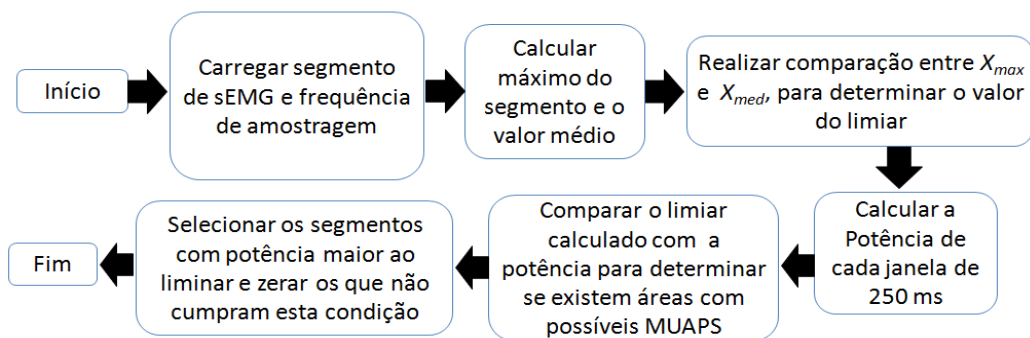


Figura 22 Diagrama de Blocos da função do método da potência.

O sinal é segmentado em trechos de 250 ms como estudado por outros pesquisadores (KAUR *et al.*, 2009; BEMUDEZ, 2013), para a comparação com o limiar (*Threshold*) estabelecido, da potência de cada janela. O limiar foi obtido sob o critério da comparação entre o valor máximo (X_{max}) e o valor médio (X_{med}) do segmento. Se o valor máximo for maior ou igual que 30 vezes o valor médio, o limiar é obtido como a Equação (57), caso contrário o limiar é calculado pela Equação (58):

$$Th = 5 \times X_{med} \quad (57)$$

$$Th = \frac{X_{max}}{5} \quad (58)$$

onde Th é o limiar calculado e é usado para comparar seu valor com a Potência, calculada na Equação (59):

$$Potência = \frac{\sum_{i=1}^N x(n)^2}{N} \quad (59)$$

de cada janela temporal de 250 ms obtida.

As janelas com menor energia são zeradas e as de energia maior que o limiar são somadas no segmento de saída resultante do método. Obtém-se assim, segmentos de sinal de sEMG com possíveis MUAPs para o processamento posterior, tais como o mostrado apenas como exemplo na Figura 23 para um sujeito saudável.




Figura 23 Segmentação para sujeito saudável, (a) Sinal de Áudio, (b) segmento do sinal de sEMG com marca em vermelho do intervalo temporal seleccionado e (c) primeiro intervalo segmentado ou trilha de 10 s, contindo o possível MUAP.

No caso do sinal de EEG, o intervalo escolhido experimentalmente foi de 7 s, a partir do pico máximo do sinal de áudio. Gráficos da segmentação são apresentados na Figura 24. É importante observar que com relação aos pacientes com Disartria estes sinais poderão ou não estar presentes dependendo do tipo de desordem ocasionada pelo AVC. Na Figura 25 é apresentada a segmentação do sinal de sEMG de um sujeito disártrico e na Figura 26 a segmentação do sinal do EEG. *Um paciente com Disartria pode apresentar disfasia que impeda a execução do comando verbal, ação que vai depender do grau de Disartria do sujeito* (Anexo B).




Figura 24 Segmentação para sujeito saudável, (a) Sinal de Áudio, (b) segmento do sinal de EEG com marca em vermelho do intervalo temporal selecionado e (c) primeiro intervalo segmentado ou trilha de 7 s, contendo o efeito da tarefa mental.

Nos segmentos selecionados, denominados trilhas, são extraídas as características como explicado no próximo capítulo para ambos os sinais de estudo.

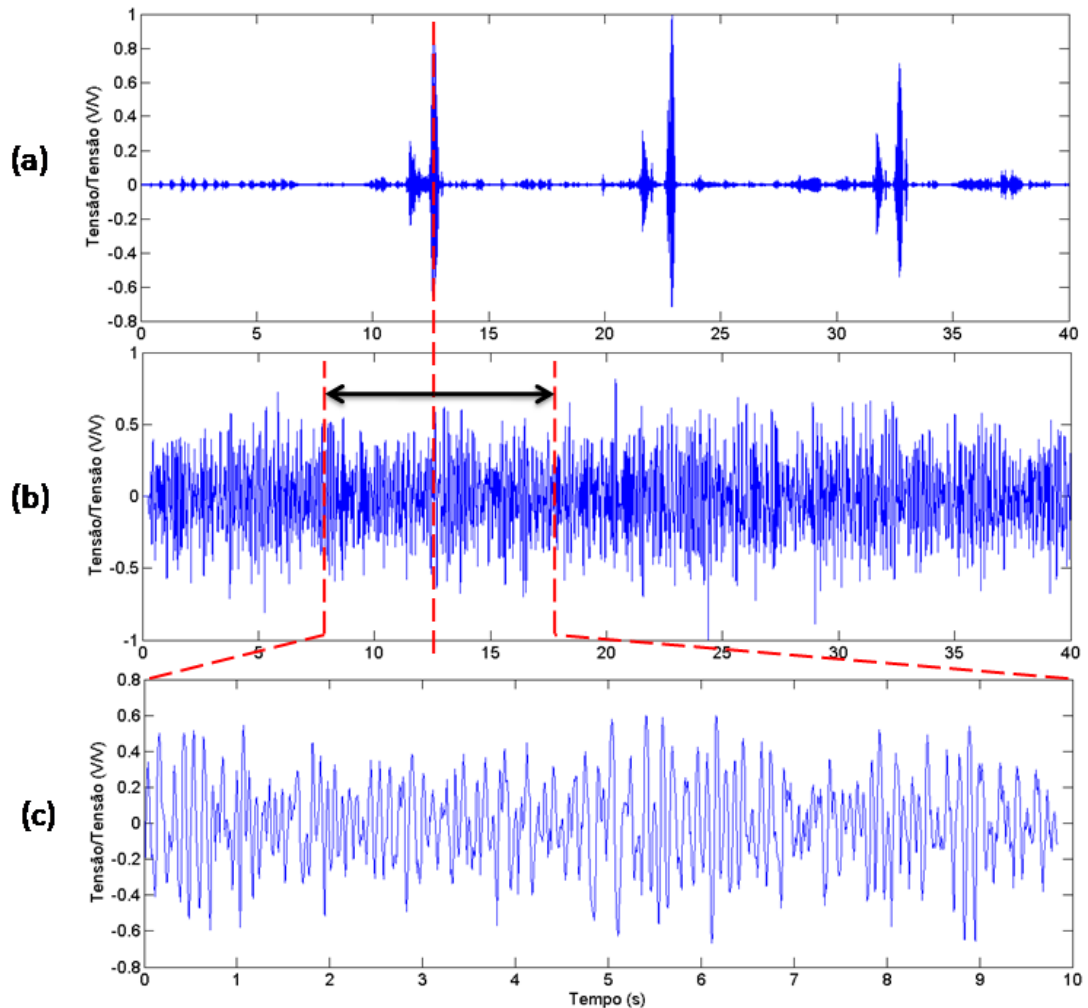


Figura 25 Segmentação para paciente disártrico Grau 2, (a) Sinal de Áudio, (b) segmento do sinal de sEMG com marca em vermelho do intervalo temporal selecionado e (c) primeiro intervalo segmentado ou trilha de 10 s, contendo o possível MUAP.

Como mostrado na Figura 25 (b), o sinal de sEMG nos sujeitos com Disartria é caracterizado por contrações dos músculos constantes que impedem a visualização e definição de intervalos de energia correspondentes à ativação muscular da face. Na Figura 25 (c) se observa como o método da potência usado não logra discriminar intervalos menores de sEMG com possíveis MUAPS, o que está condicionado pela fala errática do sujeito que possui uma seqüela pós AVC de Disartria Grau 2 (ver Anexo B).




Figura 26 Segmentação para paciente disártrico Grau 2, (a) Sinal de Áudio, (b) segmento do sinal de EEG com marca em vermelho do intervalo temporal selecionado e (c) primeiro intervalo segmentado ou trilha de 7 s, contendo o efeito da tarefa mental.

Como mostrado na Figura 26, o comportamento do paciente para o sinal de EEG é semelhante ao do sujeito saudável, o que pode estar relacionado com que a seqüela estudada tem seu principal efeito na transmissão da informação dos centros sensório-motores do cérebro aos músculos e canais de transmissão do movimento facial (ver Capítulo 2.3), porém a ativação cortical relacionada a tarefa motora pode se manter dentro dos parâmetros normais.

4.4 EXTRAÇÃO DAS CARACTERÍSTICAS DE SEMG E DE EEG

Um fluxograma apresenta o algoritmo do método desenvolvido na Figura 27. Logo após a aquisição dos biosinais são gerados arquivos com os dados dos sinais de Áudio, sEMG e EEG, como abordado no Capítulo 4.1, e em seguida são processados como abordado no Capítulo 4.3.

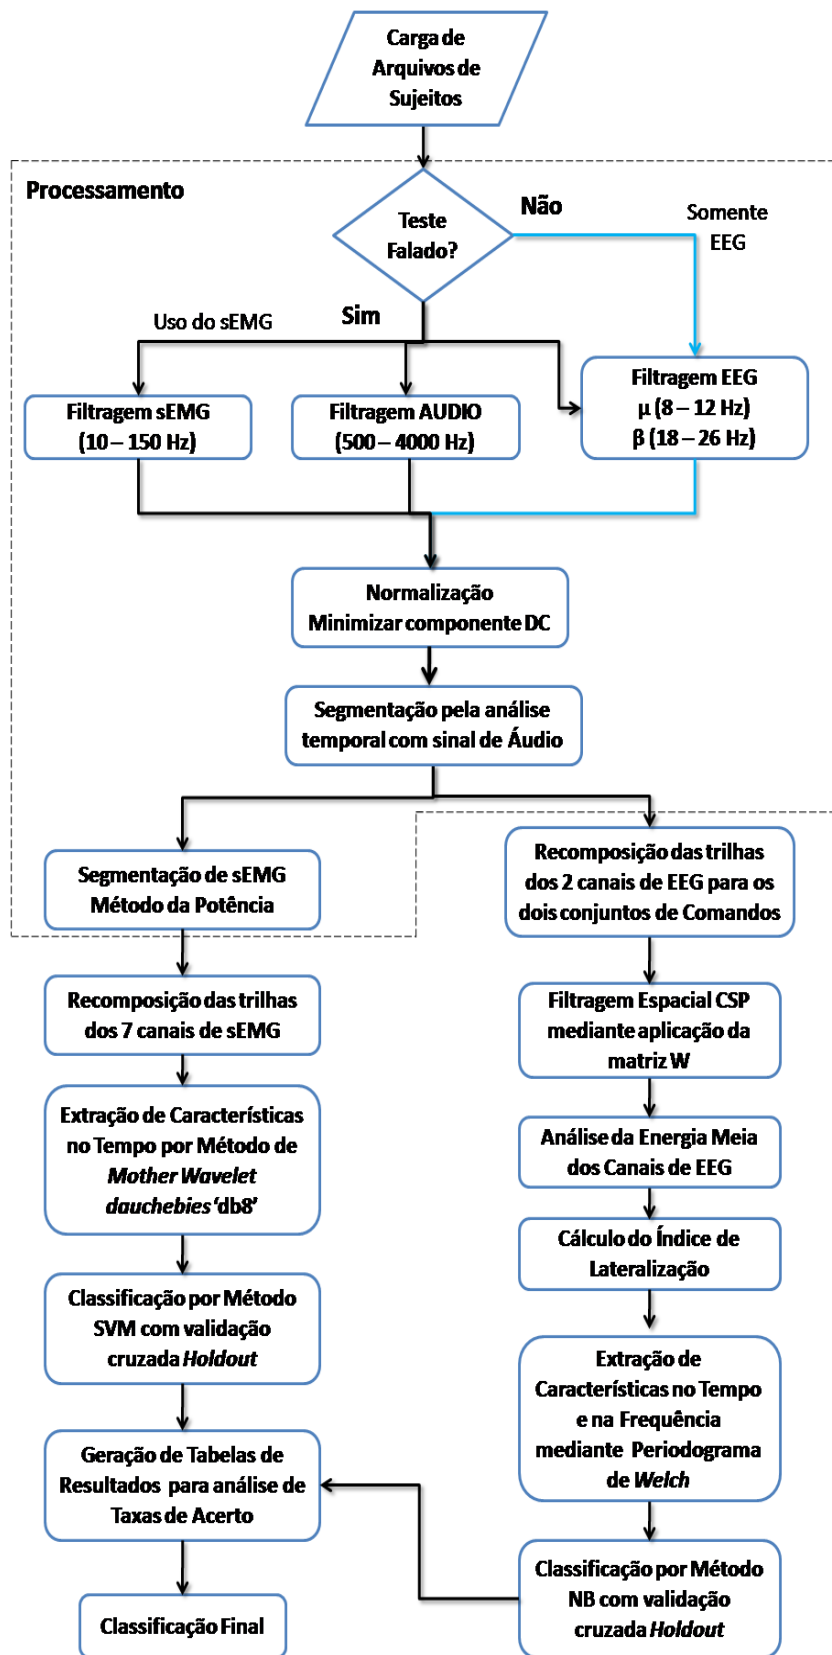


Figura 27 Fluxograma do método computacional para classificação de padrões da fala.

Se o *Dataset* do teste carregado for falado se realizará o processamento do sinal de sEMG e será empregado para a classificação final, caso contrário, somente será empregado o sinal de EEG. Devido à diferença entre as abordagens do procedimento para extração de características do sinal de sEMG e do sinal de EEG, estes foram divididos em sub-capítulos para poder realizar uma melhor descrição.

4.4.1 EXTRAÇÃO DE CARACTERÍSTICAS PELO MÉTODO DA TRANSFORMADA DISCRETA WAVELET (DWT) PARA SEMG

Logo após o sinal de sEMG ter sido segmentado, estes são recompostos nos sete canais usados na classificação, visando a sua manipulação. Portanto cada canal terá três segmentos ou trilhas do sinal de sEMG. A Transformada Discreta *Wavelet* (DWT) realiza a decomposição dos sinais de sEMG nas frequências que a compõem, permitindo uma análise em vários níveis de decomposição e é um procedimento utilizado para sinais não estacionários, como os sinais de origem biológica que mudam suas propriedades consideravelmente com o passar do tempo (GOKGOZ & SUBASI, 2015; ZHANG, *et al.*, 2010; DE PAULI NILSON & BALBINOT, 2014). Como abordado no Capítulo 3.5, a análise *Wavelet* consiste em adotar uma função base (*mother wavelet*) e representar o sinal original como uma combinação linear de decomposições sobre a função base (LUCAS *et al.*, 2008; MAHAPHONCHAIKUL *et al.*, 2010, SUBASI, 2015; PHINYOMARK *et al.*, 2011; BERMUDEZ, 2013).

As trilhas dos 7 canais de sEMG são recompostas para permitir a extração das características temporais pelo método de *Transformada Discreta Wavelet* (DWT), para uma *mother wavelet* com *Daubechies* de ordem 8 (PHINYOMARK *et al.*, 2011; BERMUDEZ, 2013; CHAGAS, 2009), com decomposição de 4 níveis de frequências, sendo esta *mother*

wavelet a mais parecida com a forma do potencial muscular ou MUAP (GALLEGO DUQUE *et al.*, 2014).

Características no domínio do tempo são geralmente usadas para detectar a contração muscular e outra atividade muscular (DAUD *et al.*, 2013). São extraídas as características temporais: média aritmética, desvio padrão (*Std*), *skewness* (*Skew*), *kurtosis* (*Kurt*) e RMS (essas características foram selecionadas devido a diversos outros estudos com o principal objetivo de permitir uma geração de características similares para comparações futuras entre diversos trabalhos). A média aritmética é usada para medir a tendência central de um conjunto de dados, como apresentado na Equação (60), por isso é usada como característica do sinal de sEMG, para caracterizar o quanto centrados estão os valores do segmento de dados analisados (PHINYOMARK *et al.*, 2010). O desvio padrão mede a distribuição dos dados a partir da média aritmética e no processamento de sinais, como a Equação (61). Este representa o ruído e outras interferências, pelo que pode ser usado como característica discriminando entre as classes de como agrupados estão os dados em relação à sua média (DAUD *et al.*, 2013). O *skewness* representa a assimetria de uma distribuição estatística, na qual a curva aparece distorcida ou enviesada, seja para a esquerda ou para a direita, como mostra a Equação (62). A assimetria pode ser quantificada para definir quanto o conjunto de dados difere de uma distribuição normal (MCNEESE, 2010). O objetivo da *kurtosis* é testar a normalidade, como uma medida de desvios da normalidade como apresenta a Equação (63). Esta pode ser definida formalmente como o quarto momento da população padronizada sobre a média. Esta característica é uma medida do “achatamento” da distribuição, tendo a distribuição normal uma *kurtosis* de 3. Kurtosis e *skewness*, são usados por diversos pesquisadores obtendo bons resultados na classificação de sEMG (NAZARPOUR *et al.*, 2005). RMS é outra característica popular na análise do sinal de sEMG, calculada como mostra a Equação (64). Alguns

pesquisadores destacam seu resultado de desempenho em classificação de sEMG frente ao uso de centroide de frequência, entre outras características (MAHAPHONCHAIKUL *et al.*, 2010; PHINYOMARK *et al.*, 2009).

$$Média = \frac{\sum_{n=1}^N X_n}{N} \quad (60)$$

$$Std = \sqrt{\frac{\sum_{n=1}^N (X_n - Média)^2}{N-1}} \quad (61)$$

$$Skew = \frac{\sum_{n=1}^N (X_n - Média)^3}{(N-1) \times Std^3} \quad (62)$$

$$Kurt = \frac{\sum_{n=1}^N (X_n - Média)^4}{(N-1) \times Std^4} \quad (63)$$

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N X_n^2} \quad (64)$$

O diagrama de blocos da Figura 28 mostra o algoritmo usado na implementação da função para extração das características do sinal de sEMG.

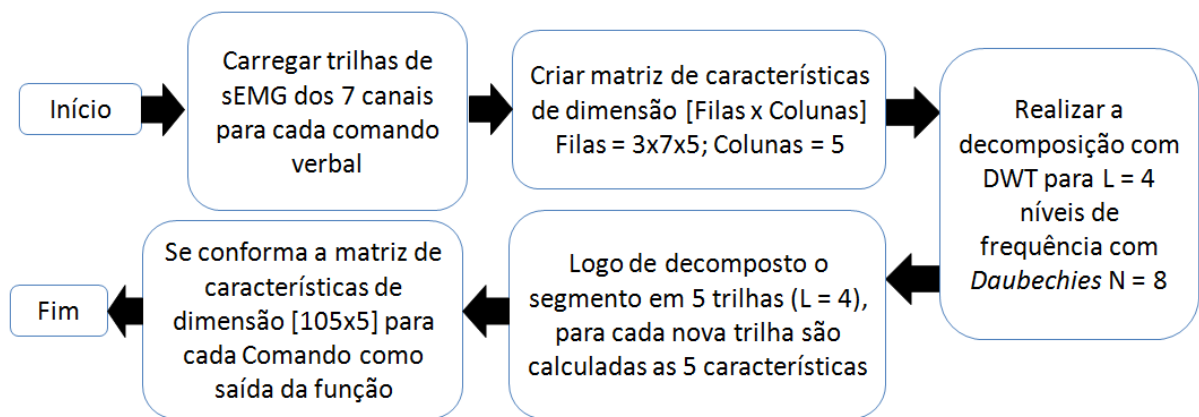


Figura 28 Diagrama de Blocos da função para extração de características no sinal de sEMG.

Como se observa no diagrama da Figura 28, uma matriz de características foi criada com as dimensões de Filas x Colunas. As filas são de valor 3x7x5, ou seja: 3 segmentos, 7 canais e 5 novas trilhas produto da decomposição Wavelet de 4 níveis de frequência. As colunas estão formadas pelas 5 características extraídas do sinal. Ao realizar a decomposição

de $L = 4$ níveis, o sinal é segmentado em 5 novas trilhas de frequências diferentes, assim como, mostrado na Figura 29 (a) para um sujeito saudável e na Figura 29 (b) para um paciente.




Figura 29 Decomposição de segmentos de sEMG pelo método de DWT para (a) um sujeito saudável e para (b) um paciente com Disartria Grau 2.

Na Figura 29 se observa como os segmentos produto da decomposição possuem faixas de frequências diferentes, o que garante o aumento do espaço de vetores e a riqueza do sinal para a classificação. Logo depois de aplicar a transformada, segundo a Figura 28, são calculadas as cinco características para estes novos segmentos, obtendo à saída um vetor de características de dimensão $[105 \times 5]$ para cada comando verbal.

4.4.2 EXTRAÇÃO DE CARACTERÍSTICAS PARA SINAL DE EEG

Para realizar a extração das características do sinal de EEG, como apresentado no fluxograma da Figura 27, é necessário primeiro recompor as trilhas dos canais para os dois conjuntos de comandos verbais, realizar uma filtragem espacial CSP para aumentar a atividade discriminadora das classes, calcular a Energia Média dos canais de EEG, calcular o Índice de Lateralização e logo depois extrair as características no tempo e na frequência mediante o método do Periodograma de *Welch*. Todos estes procedimentos são abordados na continuação deste capítulo.

Para lograr o aumento da atividade discriminadora entre classes, foram selecionados os canais FC5, FC6, P7 e P8, canais de maior ativação cortical devido às tarefas mentais executadas. Para as tarefas mentais laterais: “Direita” e “Esquerda”, foram selecionados os canais FC5 e P7 pelo lóbulo Esquerdo e FC6 e P8 pelo lóbulo Direito. Para as tarefas frontais: “Para Frente” e “Para Trás“, foram selecionados os canais FC5 e FC6 pelo lóbulo frontal e P7 e P8 pelo lóbulo parietal. O diagrama de blocos da Figura 30 mostra o algoritmo para recompor as trilhas dos canais selecionados e realizar a filtragem espacial do sinal de EEG.

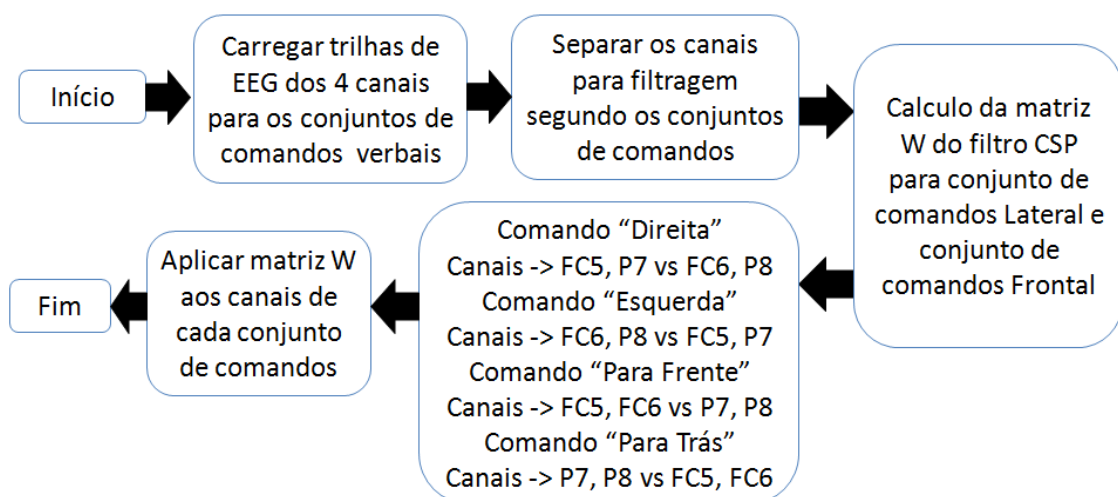


Figura 30 Diagrama em bloco da recomposição dos canais de EEG e filtragem CSP.

Na Figura 30, as matrizes W dos filtros CSP foram calculadas para cada conjunto de canais, visando o aumento da atividade discriminadora entre os canais opostos, como visto no Capítulo 3.7. Logo as matrizes W foram aplicadas aos canais dos respectivos conjuntos para lograr uma maior separação de classes posteriormente.

4.4.2.1 PROCEDIMENTO DE OBTENÇÃO DA ENERGIA MÉDIA DO SINAL DE EEG

Como apresentado no Capítulo 3.1, os efeitos ERD/ERS podem ocorrer durante o planejamento do movimento e/ou durante o mesmo. Por isso, a Energia Média destes canais é analisada visando determinar o momento de maior variação de energia entre os canais contralaterais. A energia média de cada canal é calculada como mostrado na Equação (65) e como apresentado no diagrama de blocos da Figura 31.

$$Energia_{C_j}^{(c)} = \frac{1}{M} \sum_{i=0}^M C_{ji}^{(c)2} \quad (65)$$

$C_j^{(c)}$ representa o canal j do sinal de EEG na condição (c) e M é o número de trilhas (*segmentos*) a serem processadas.




Figura 31 Diagrama de blocos do algoritmo de cálculo da Energia Média para cada classe.

No diagrama da Figura 31, logo após carregar as trilhas de EEG correspondente a cada classe, são obtidos os valores de Energia média para cada classe. Um filtro de média móvel é utilizado para melhorar a visualização para a determinação do momento do ERD/ERS. A Figura 32 mostra apenas como exemplo as curvas de Energia média calculadas para o canal

FC5 do lóbulo Esquerdo e o canal FC6 do lóbulo Direito, para Comando verbal “Direita” em Figura 32 (a), e Comando verbal “Esquerda” em Figura 32 (b).




Figura 32 Curvas de Energia Média no tempo para o canal do lóbulo Esquerdo FC5 (em cor azul) e lóbulo Direito FC6 (em cor verde). Teste pensado de sujeito saudável, filtragem banda μ , (a) para trilha de comando “Direita”, (b) para trilha de comando “Esquerda”.

4.4.2.2 PROCEDIMENTO PARA OBTENÇÃO DO ÍNDICE DE LATERALIZAÇÃO DO SINAL DE EEG

Como visto no Capítulo 3.6, o IL fornece a quantificação da contralateralidade nas tarefas mentais estudadas. Usando as Equações (32) e (33). Para altos valores de IL é obtida uma alta contralateralidade no sinal. Este índice é usado depois na estimação espectral para a geração do vetor de características para a classificação, pois logo após se ordenar os valores de IL decendentemente estes ajudam a realizar a classificação com os melhores dados de frequência. A Figura 33 apresenta o diagrama em blocos do algoritmo para o cálculo do IL .

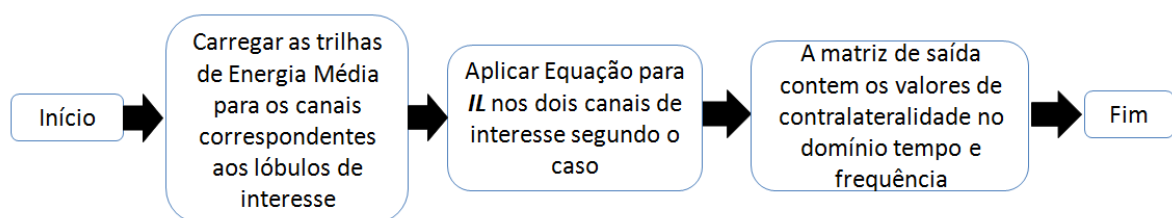


Figura 33 Diagrama de blocos do algoritmo de cálculo do Índice de Lateralidade.

Também o *IL* da energia média no domínio da frequência é analisado para as trilhas de EEG, como apresenta apenas como exemplo a Figura 34.




Figura 34 Índice de Lateralização para canais de EEG estudados para comando lateral “Direita” em sujeito saudável, com filtragem nas bandas μ e β .

4.4.2.3 PROCEDIMENTO PARA OBTENÇÃO DO PERIODOGRAMA DE WELCH E EXTRAÇÃO DE CARACTERÍSTICAS DO EEG

Uma segunda segmentação dos sinais mediante a análise do Periodograma de *Welch* é realizada ao sinal de EEG, visando a extração de características de origem espectral. Para a classificação do sinal de EEG são escolhidas características temporais e componentes espectrais, método também empregado por outros pesquisadores (GÜNES *et al.*, 2011; MACHADO *et al.*, 2012; MACHADO & BALBINOT, 2014). O procedimento do método do Periodograma de Welch é mostrado no diagrama de blocos da Figura 35.

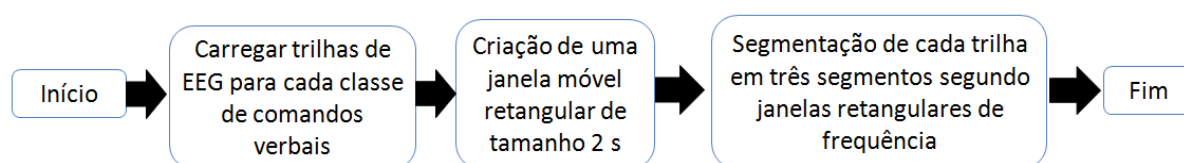


Figura 35 Diagrama de blocos do algoritmo de segmentação pelo método do Periodograma de Welch.

Para realizar a segmentação são obtidas três janelas de 2 s, iniciando no segundo 1 e terminando no segundo 7. Foram utilizados 65 pontos para o método *Welch*, permitindo a sobreposição das janelas em até 50% de seu tamanho, acrescentando o número de janelas resultantes, o qual diminui o erro aleatório (STOICA & MOSES, 2005). Como saída do método os valores do estimador espectral são denominados $\widehat{Gxx}(F)$, assim como, as trilhas segmentadas no tempo são denominadas pelo estimador temporal $\widehat{Txx}(t)$. Para obter as trilhas divididas em janelas de componentes temporais e espectrais é realizada a extração de características para o novo espaço de características.

Como características temporais foram extraídas: *skewness* (*Skew*) e *kurtosis* (*Kurt*). O *skewness* representa a assimetria de uma distribuição estatística, o qual é um aspecto interessante a caracterizar em um sinal de tipo estocástico como o EEG, no qual a curva da distribuição parece distorcida, seja para a esquerda ou para a direita, como mostra a Equação (66). O objetivo da *kurtosis* é analisar a normalidade, como uma medida de desvios da normalidade como apresentado na Equação (67):

$$\mathbf{Skew} = \frac{\sum_{n=1}^N (Txx(n) - Média)^3}{(N-1) \times Std^3} \quad (66)$$

$$\mathbf{Kurt} = \frac{\sum_{n=1}^N (Txx(n) - Média)^4}{(N-1) \times Std^4} \quad (67)$$

Autores recomendam o uso de características dos domínios do tempo e da frequência (GÜNES *et al.*, 2011). Por isso também foram escolhidas as características espectrais: Mínimo, Máximo, Média e Desvio padrão; representadas pelas Equações (68), (69), (70) e (71), respectivamente.

$$\mathbf{Mín} = \min |Gxx(n)| \quad (68)$$

$$\mathbf{Máx} = \max |Gxx(n)| \quad (69)$$

$$\mathbf{Média} = \frac{\sum_{n=1}^N Gxx(n)}{N} \quad (70)$$

$$Std = \sqrt{\frac{\sum_{n=1}^N (Gxx(n) - Média)^2}{N-1}} \quad (71)$$

O Mínimo e Máximo do sinal expressam os momentos de menor e maior contralateralidade, respectivamente. A média aritmética é usada para medir a tendência central de um conjunto de dados. O desvio padrão mede a distribuição dos dados a partir da média aritmética e no processamento de sinais representa o ruído e outras interferências, pelo que pode ser usado como característica discriminando entre as classes por quão agrupados estão os dados em relação à média (DAUD *et al.*, 2013).

Para obtenção das características espectrais são selecionadas as frequências mais influentes. Para lograr isto é calculado o índice **IL** para todas as trilhas, como mostrado na Figura 33, visando a escolha dos 15 pontos de frequência com maior índice **IL**. Logo depois, o vetor das características é processado pela Equação (72):

$$Característica_{Final} = \log(Caract) \quad (72)$$

para normalizar a distribuição visando a adequada classificação.

Após a etapa de normalização são gerados os vetores de saída para a classificação, tendo em conta o efeito da contralateralidade acrescentado pelo filtro CSP. É conformado então um vetor de saída para cada comando de tamanho [24x1], 12 valores para um lóbulo e os outros 12 para o lóbulo oposto, visando a utilização das características de cada padrão, segundo seu efeito nos sinais das regiões dos lóbulos em ativação. Conforma-se finalmente uma matriz de treino de [24x6], sendo 24 observações divididas em 2 repetições do padrão para 2 canais com uma janela de Welch de 3 janelas, para a captação do padrão em um lóbulo e seu oposto, ou seja, $24 = 2 \times 2 \times 3 \times 2$, e 6 colunas de características: 4 características espectrais e 2 características temporais. Em fim gera-se também uma matriz de teste do mesmo tamanho que a do treino, para poder continuar com o método de classificação.

4.5 IMPLEMENTAÇÃO DO MÉTODO *SUPPORT VECTOR MACHINE* DO SINAL DE sEMG

O método utilizado para resolver o problema de classificação foi o de múltiplas classes, com várias classificações binárias, do tipo um contra todos (*one versus all*). A matriz de características é inserida na máquina de vetores de suporte criada com a função *kernel* tipo RBF (*Radial Basis Function*) para seu treinamento como abordado no Capítulo 3.2 com o uso da Equação (13). O método para validação cruzada usado na SVM foi o *Holdout*, tendo em conta três trilhas para treino e três trilhas para teste em cada validação. A Figura 36 apresenta o diagrama de blocos da implementação do classificador SVM.

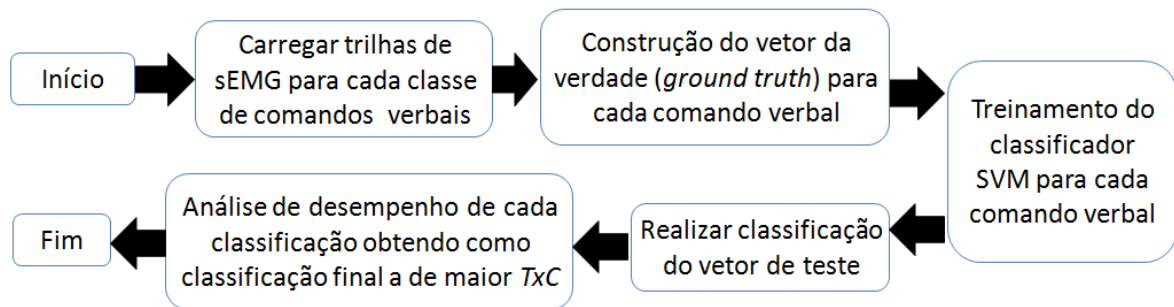


Figura 36 Diagrama de blocos do algoritmo de implementação do classificador SVM para processamento do sinal de sEMG.

Após a carga das trilhas representando cada comando verbal foi criado um vetor para cada comando usando a média aritmética da trilha como comparação para gerar o vetor binário. Este vetor é usado para o treinamento, visando a identificação de trilhas similares às do comando a classificar. Desta maneira são testadas as 9 combinações entre trilhas de treino e trilhas de teste, implementando o método de validação cruzada *Holdout*. Destas combinações são selecionadas as de maiores *Accuracy*¹ para tomada de decisão da

¹ É importante ressaltar que na área da Instrumentação existe o Vocabulário Internacional de Metrologia (VIM) com definições extremamente rigorosas (aceitas mundialmente) para Erro, incerteza, Sensibilidade, entre outros conceitos. Porém, para manter a mesma nomenclatura usada na área de classificadores foi deixado o correspondente termo em inglês para evitar entendimento equivocado sobre o termo em Português e principalmente respeitar a área de medidas onde esses conceitos já foram amplamente discutidos. Resumidamente estes termos não devem ser traduzidos para evitar uma confusão na área de medidas, como por exemplo, o péssimo uso da palavra acurácia que simplesmente não tem significado na área de Instrumentação.

classificação. Tabelas de resultado são geradas para análise de *Accuracy* para serem usadas na classificação final. A SVM utilizada foi implementada utilizando a ferramenta Matlab.

4.6 IMPLEMENTAÇÃO DO MÉTODO *NAIVE BAYES* DO SINAL DE EEG

A quantidade de características fornece o número de distribuições usadas na Equação (18). As combinações da matriz de características gerada para cada um dos quatro comandos alimentam quatro classificadores criados como treino destes. A distribuição usada para a criação dos classificadores NB é de estimação de densidade suavizada tipo *kernel*, de acordo com a abordagem do Capítulo 3.3. A distribuição *kernel* é apropriada para características com uma distribuição contínua. Esta não precisa de uma hipótese forte, como a distribuição normal e pode ser usada no caso em que a distribuição de uma característica seja inclinada ou possua vários picos (MINNIER *et al.*, 2015). Também requer mais tempo de processamento e memória do que a distribuição normal (MURPHY, 2012). A Figura 37 mostra o diagrama em bloco do algoritmo desenvolvido para o método *Naive Bayes*.

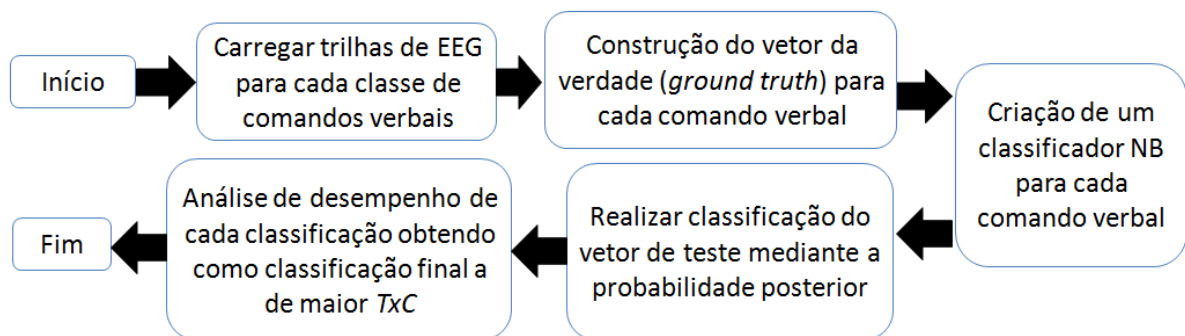


Figura 37 Diagrama de blocos do algoritmo de implementação do classificador NB para processamento do sinal de EEG.

Um vetor binário para cada comando foi criado, tomando valor 1 como as observações correspondentes ao lóbulo da ativação do comando e o valor 0 foi determinado para o lóbulo oposto. O vetor de teste foi conformado dentre as três trilhas de teste, assim como, o vetor de treino foi selecionado das três trilhas de treino. Desta maneira são testadas as 9 combinações

entre trilhas de treino e trilhas de teste, implementando o método de validação cruzada *Holdout*. Destas combinações são selecionadas as maiores *Accuracy* para a tomada de decisão da classificação. Os melhores valores de *Accuracy* coincidem com os melhores valores da probabilidade das distribuições da função tipo *kernel* escolhida no método. O classificador NB foi implementado usando a função *NaiveBayes* do MatLab.

4.7 MATRIZ DE CONFUSÃO

Segundo (CAWLEY, 2006; CHAGAS, 2009) a *Error Rate* é considerada uma medida natural de desempenho de classificação. A matriz de confusão é uma ferramenta que contabiliza os acertos e os erros de cada classe. Nesta matriz as filas apresentam à classe atual e as colunas à classe prevista, uma tabulação cruzada entre a classe prevista pelo modelo e a classe real dos exemplos, tendo como resultado na diagonal principal os acertos de cada classe, assim como, mostrado na Tabela 3.

Tabela 3. Matriz de Confusão para os classificadores.

Matriz de Confusão		Prevista	
		Não	Sim
Real	Não	Verdadeiro Negativo (VN)	Falso Positivo (FP)
	Sim	Falso Negativo (FN)	Verdadeiro Positivo (VP)

Na Tabela 3 entende-se que:

- Verdadeiro Negativo (**VN**): a observação pertence à classe negativa e o classificador prediz que a observação pertence à classe negativa;
- Falso Positivo (**FP**): a observação pertence à classe negativa e o classificador prediz que a observação pertence à classe positiva;

- Falso Negativo (**FN**): a observação pertence à classe positiva e o classificador prediz que a observação pertence à classe negativa;
- Verdadeiro Positivo (**VP**): a observação pertence à classe positiva e o classificador prediz que a observação pertence à classe positiva.

As tabelas de resultados e matrizes de confusão dos classificadores para cada validação cruzada segundo abordado anteriormente nos Capítulos 4.5 e 4.6 foram obtidas seguindo os passos apresentados no fluxograma da Figura 38.

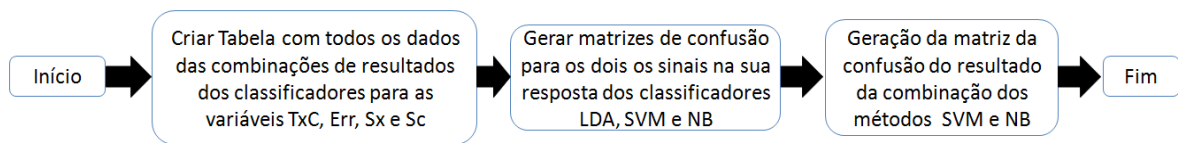


Figura 38 Fluxograma do algoritmo de obtenção das matrizes de confusão.

Estas tabelas utilizam principalmente os dados da Matriz de Confusão fornecida por cada classificação. Com os dados da matriz de confusão foram obtidas as seguintes métricas de avaliação: *Accuracy* (**TxC**), *Error Rate* (**Err**), *Sensibility* (**Sx**) e *Specificity* (**Sc**), usadas neste trabalho e definidas pelas Equações (73) a (76):

$$TxC = \frac{VP+VN}{N} \quad (73)$$

$$Err = \frac{FP+FN}{N} \quad (74)$$

$$Sx = \frac{VP}{VP+FN} \quad (75)$$

$$Sc = \frac{VN}{VN+FP} \quad (76)$$

onde N é a soma de todas as observações para uma classificação como apresentada na Equação (77):

$$N = VP + FP + VN + FN \quad (77)$$

4.8 OBTENÇÃO DA ACCURACY E CLASSIFICAÇÃO FINAL

Considera-se a *Accuracy* como parâmetro para determinar a probabilidade de sucesso em uma classificação. Para as nove combinações de cada ensaio (três trilhas de treino vezes três trilhas de teste) é selecionada a maior taxa de *Accuracy* em cada avaliação (método *Holdout*), como resultado de classificação ante um comando verbal. Este procedimento é usado para o classificador SVM, NB e LDA, para cada *dataset* (sujeito). Quando é realizado o ensaio somente através do pensamento de um dado comando, somente os sinais de EEG são processados, mas quando é realizado ambos os ensaios (comando verbal e comando somente pensado), a classificação do sEMG é complementada com o do EEG, mediante o cálculo das médias das matrizes de confusão para melhorar a *Accuracy*. Desta forma os valores da *Accuracy* da diagonal principal de uma matriz de sinal EEG são acrescentados com os valores da *Accuracy* da diagonal da matriz do sinal sEMG, porém os restantes valores da matriz decrescem pois os valores das taxas de sEMG nesta área da matriz são menores aos da diagonal principal. Todas as métricas foram calculadas e analisadas através de um Projeto de Experimentos.

4.9 EXPERIMENTO PROJETADO PARA AVALIAÇÃO DOS MÉTODOS MATEMÁTICOS

Os dados dos biosinais são parte da realização de um Projeto de Experimentos do Tipo Fatorial, com o objetivo de avaliar possíveis relações entre os diferentes fatores controláveis deste experimento, assim como, avaliar de forma individual se os fatores controláveis alteram de forma significativa a variável de resposta do experimento. Devido a limitações da ferramenta estatística utilizada (MiniTab), o biosinal (EEG e sEMG) não foi considerado como fator controlável e foi necessário dividir a grande base de dados em pequenos Projetos de Experimentos o que possibilitou de forma simplificada e aproximada a análise do sinal de sEMG e do sinal de EEG, com os seguintes fatores controláveis:

1. Projeto de Experimentos para o sinal de sEMG com os seguintes fatores controláveis:
 - Conjunto de dados (Dataset): 7 sujeitos saudáveis e 7 sujeitos com Disartria com 14 níveis;
 - Método Matemático: é o Método matemático utilizado na classificação, LDA e SVM, com 2 níveis;
 - Comando verbal: 16 níveis produto das combinações entre comando Real (“Direita”, “Esquerda”, “Para Frente” e “Para Trás”) e comando Previsto pelo classificador (“Direita”, “Esquerda”, “Para Frente” e “Para Trás”).

2. Projeto de Experimentos para o sinal de EEG com os seguintes Fatores Controláveis:
 - Conjunto de Dados (Dataset): 7 sujeitos saudáveis e 7 sujeitos com Disartria com 14 níveis;
 - Método Matemático, é o Método matemático utilizado na classificação, LDA e NB, com 2 níveis;
 - Comando verbal: 16 níveis produto das combinações entre comando Real (“Direita”, “Esquerda”, “Para Frente” e “Para Trás”) e comando Previsto pelo classificador (“Direita”, “Esquerda”, “Para Frente” e “Para Trás”).

3. Projeto de Experimentos para o sinal de EEG com os seguintes Fatores Controláveis:
 - Conjunto de Dados (Dataset): 7 sujeitos saudáveis e 7 sujeitos com Disartria com 14 níveis;
 - Natureza do teste: se o teste é falado e pensado ou somente pensado com dois níveis;

- Banda de filtragem do sinal de EEG: filtros passa-bandas aplicados aos ritmos μ , β e $\mu+\beta$ com 3 níveis;

Como Variáveis de Resposta são analisadas as métricas derivadas da Matriz de Confusão apresentadas nas Equações (73) a (76): TxC , Err , Sx e Sc . Foram realizadas duas repetições com três execuções do comando verbal para cada voluntário. No momento da classificação são geradas 9 combinações aleatórias entre as trilhas produto da segmentação vezes 4 combinações produto da repetição escolhida para treino e a escolhida para teste, dando uma quantidade de 36 medidas da variável de resposta. Devido à condição inerente dos pacientes, o experimento foi desenvolvido de forma sequencial. É importante ressaltar que devido à quantidade de dados este experimento não foi analisado como apenas um Projeto de Experimentos do Tipo Bloco Aleatorizado e sim como pequenos experimentos individuais (no caso com as trilhas e métricas selecionadas de forma aleatorizada e considerado como três experimentos do Tipo Fatorial Completo). No caso do projeto de experimentos para o sinal de sEMG as 36 repetições vezes os 14 Conjuntos de dados, vezes os dois Métodos, vezes as 16 combinações de Comandos verbais geram um total de 16128 medidas ou valores na Tabela 4 de cruzamento. Para o primeiro projeto de experimentos do sinal de EEG as 36 repetições, vezes os dois tipos de Natureza do teste, vezes as 3 Bandas avaliadas no experimento fornece um novo valor de repetições de 216. Este valor vezes os 14 Conjuntos de dados, vezes os dois Métodos, vezes as 16 combinações de Comandos verbais geram um total de 96768 medidas ou valores na Tabela 5 de cruzamento. No segundo projeto de experimentos do sinal de EEG as 36 repetições, vezes os dois Métodos matemáticos, vezes as 16 combinações de Comandos verbais criam um novo valor de 1152 repetições. Este valor vezes os dois tipos de Natureza do teste, vezes as três Bandas, vezes os 14 Conjunto de dados geram um total de 96768 valores como mostra a Tabela 6 de cruzamento.

Tabela 4. Tabela de Cruzamento para Projeto de Experimentos com o sinal de sEMG.

Sinal de sEMG		Comando Verbal					
		D-D	D-E	D-PF	...	PT-PT	
Método Matemático	LDA	Dataset (Sujeitos)	S1	36 Repetições por Célula			
			S2				
			...				
			S14				
	SVM	Dataset (Sujeitos)	S1				
			S2				
			S14				

Nota: As combinações dos comandos verbais foram representadas da seguinte forma para sua apresentação na Tabela 4: D-D – “Direita - Direita”; D-E – “Direita - Esquerda”; e assim por diante até PT-PT – “Para Trás - Para Trás”.

Tabela 5. Tabela de Cruzamento para o primeiro Projeto de Experimentos com o sinal de EEG.

Sinal de EEG		Comando Verbal					
		D-D	D-E	D-PF	D-PT	...	PT-PT
Método Matemático	LDA	Dataset (Sujeitos)	S1	216 Repetições por Célula			
			S2				
			S3				
			...				
	NB	Dataset (Sujeitos)	S14				
			S1				
			S2				
			S3				
			...				
			S14				

Nota: As combinações dos comandos verbais foram representadas da seguinte forma para sua apresentação na Tabela 5: D-D – “Direita - Direita”; D-E – “Direita - Esquerda”; e assim por diante até PT-PT – “Para Trás - Para Trás”.

Tabela 6. Tabela de Cruzamento para o segundo Projeto de Experimentos com o sinal de EEG.

Sinal de EEG		Banda					
		μ	β	$\mu + \beta$			
Natureza	Falado	Dataset (Sujeitos)	S1	1152 Repetições por Célula			
			S2				
			S3				
			...				
			S14				
			Pensado	Dataset (Sujeitos)	S1		
					S2		
	S3						
	...						
	S14						

A análise dos resultados dos projetos de experimentos para os biosinais estudados é abordada nos Capítulos 5.3 e 5.4.

5 RESULTADOS E DISCUSSÕES

Como resultados foram obtidos diferentes características para os sinais sEMG e de EEG para os comandos verbais estudados (falados e pensado, e somente pensados). Estes foram obtidos pelas etapas de processamento descritas no Capítulo 4. Como exemplo, alguns resultados no formato gráfico são apresentados na Figura 39 para um trecho do sinal de sEMG de um voluntário saudável significativo deste grupo de estudo, e na Figura 40 um trecho do sinal de sEMG para um voluntário com Disatria grau 2 (pior grau que se teve no grupo de estudo), que destacou-se por ter sinais ruidosos em todos os canais menos o do músculo platisma (ativação produto da vibração das cordas vocais). Os sinais de sEMG para o resto dos voluntários participantes dos testes são apresentados no Anexo D. Nos sinais da Figura 39 observa-se que existe uma diferença na ativação dos músculos ocasionada pelos comandos verbais. Estas diferenças são usadas na classificação mediante a extração das características. Variações entre os MUAP (*Motor Unit Action Potential*) para os comandos foram observadas também.

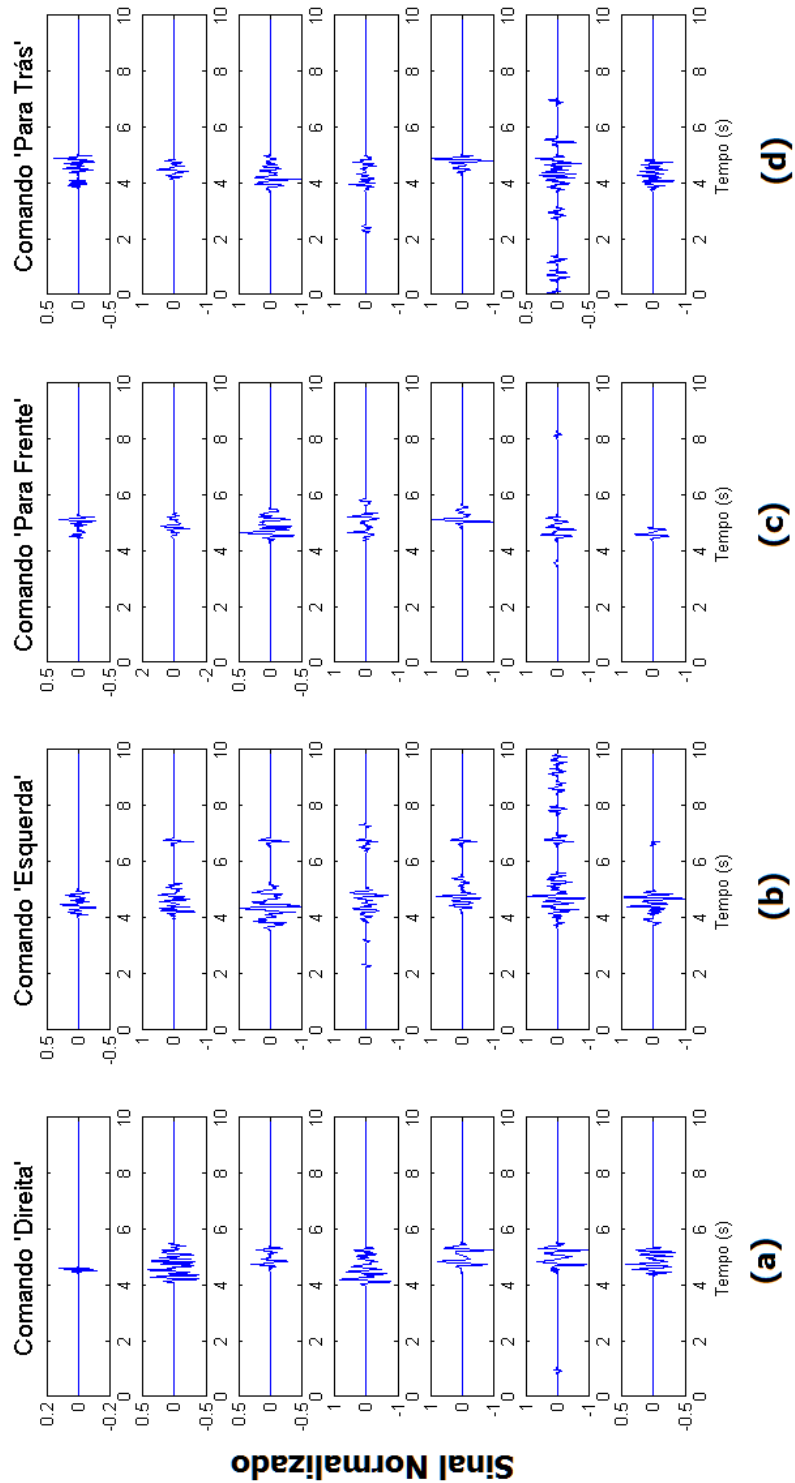


Figura 39 Sinais de ativação para sEMG para os 7 músculos (canais) medidos na face de um voluntário saudável (na ordem decedente: Masseter Direito, Zigomático Direito, Depressores Direitos, Platisma, Masseter Esquerdo, Zigomático Esquerdo, Depressores Esquerdos). Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

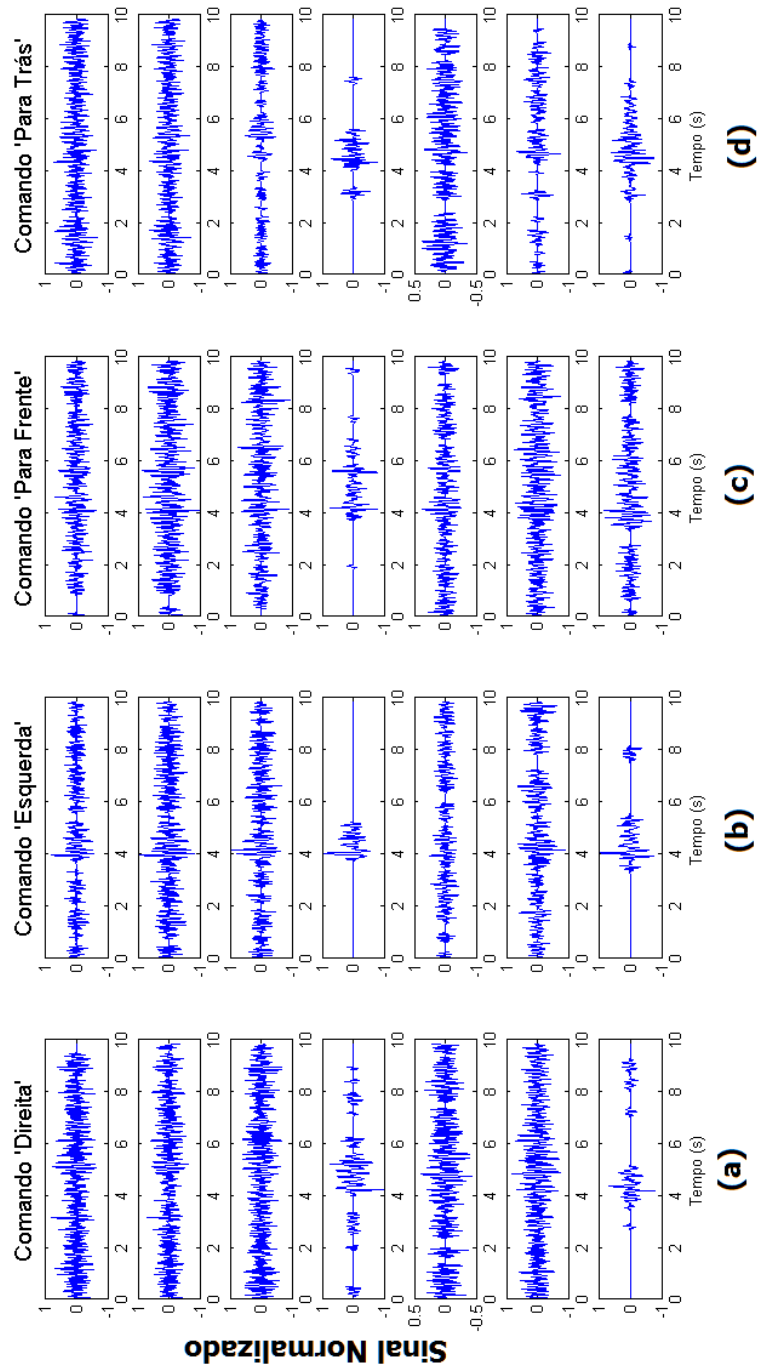


Figura 40 Sinais de ativação do sinal de sEMG para os 7 músculos (canais) medidos na face de um voluntário com Distria (na ordem decendente: Masseter Direito, Zigomático Direito, Depressores Direitos, Platisma, Masseter Esquerdo, Zigomático Esquerdo, Depressores Esquerdos). Sinal de ativação (a) Comando ‘Direita’, (b) Comando ‘Esquerda’, (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’.

Na Figura 40, observa-se uma diferença na ativação dos músculos ocasionada pelos comandos verbais. Estas diferenças são usadas também na classificação mediante a extração de características. A ativação muscular apresenta uma diferença marcante em relação à do voluntário saudável, o qual representa um desafio (diversos trechos dos sinais (ou o todo dependendo de cada paciente) não apresentam uma fácil discriminação entre o comando gerado e o silêncio) – considerando-se que dentre a amostra existem voluntários com grau 2 de Disartria. O nível de ruído na maioria dos pacientes disártricos representa em ocasiões o 100% do sinal. A ativação do músculo Platisma (centro da Figura 40) mostrou-se menos afetada pela disfasia, neste paciente, devido ao músculo estar mais afastado da área mandibular e ser ativado pela vibração das cordas vocais.

Como abordado no Sub-Capítulo 4.4.2.1, a energia média dos canais principais na ativação do córtex motor permitiu a análise da ativação dos lóbulos com a tarefa mental ou comando verbal executado. Por isso, as Figuras 41 e 42 mostram os sinais de EEG dos canais P7 – P8 e FC5 – FC6, na ativação dos lóbulos correspondentes aos comandos executados para estes sinais logo depois de serem processados com filtro CSP. Estes sinais pertencem a dois voluntários somente, o resto destes sinais de EEG são apresentados no Anexo E.

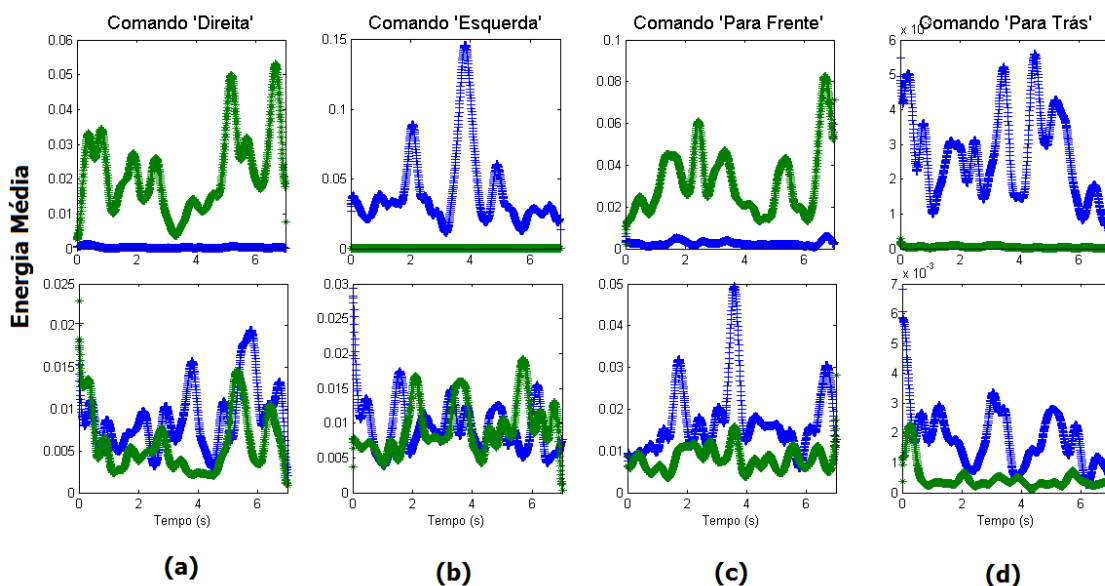


Figura 41 Sinais de ativação do sinal de EEG para os 2 canais medidos no escalpo de um voluntário saudável. Ativação ante (a) Comando ‘Direita’ e (b) Comando ‘Esquerda’, para (parte superior) os canais P7 – P8 e para (parte inferior) os canais FC5 – FC6. Sinal de ativação (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’, para (parte superior) os canais FC5 – P7 e para (parte inferior) os canais FC6 – P8. Em cores se diferencia os canais de lóbulos opostos analisados em cada caso.

Nos sinais da parte superior da Figura 41 se observa uma diferença marcante na ativação entre os canais opostos, o qual pode ser causado por artefatos da ativação muscular perto da região frontal. Na Figura 41 (a) e (b) inferiores são observadas pequenas diferenças na ativação dos canais correspondentes aos comandos ‘Direita’ e ‘Esquerda’, não acontecendo assim na ativação para os comandos ‘Para Frente’ e ‘Para Trás’ na parte inferior da Figura 41 (c) e (d). Encontrou-se que nem sempre os canais estudados apresentaram uma contralateralidade alta quando analisados comandos como ‘Para Frente’ e ‘Para Trás’.

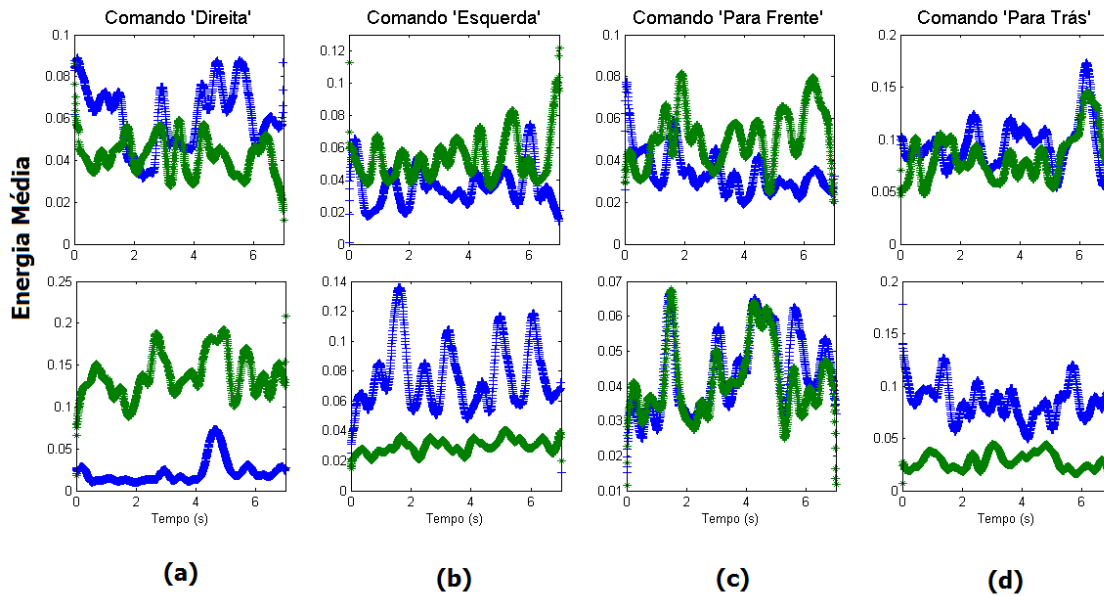


Figura 42 Sinais de ativação do sinal de EEG para os 2 canais medidos no escalpo de um voluntário com Disartria. Ativação ante (a) Comando ‘Direita’ e (b) Comando ‘Esquerda’, para (parte superior) os canais P7 – P8 e para (parte inferior) os canais FC5 – FC6. Sinais de ativação (c) Comando ‘Para Frente’ e (d) Comando ‘Para Trás’, para (parte superior) os canais FC5 – P7 e para (parte inferior) os canais FC6 – P8. Em cores se diferencia os canais de lóbulos opostos analisados em cada caso.

Na Figura 42 se observa variação apreciável na ativação dos canais opostos para todas as condições apresentadas. Este aspecto foi observado na qualidade dos sinais de EEG obtidos dos voluntários com Disartria, o qual pode ser devido ao estado de repouso em que estavam os voluntários no momento das coletas de dados. Para todos os comandos se observam diferenças que permitem a extração de características capazes de realizar a classificação. *É importante observar que para todos os voluntários seria possível analisar graficamente os biosinais, mas é inviável apresentar todos os sinais no formato gráfico neste trabalho devido a quantidade de possibilidades.* Em função disso, optou-se pela análise dos dados da matriz de confusão de cada ensaio e a apresentação dos sinais do restante dos voluntários no Anexo D para sEMG e Anexo E para EEG.

5.1 RESULTADOS DA ANÁLISE DE ENERGIA MÉDIA DO SINAL DE EEG

A Energia média dos sinais de EEG obtidos dos voluntários necessita de uma maior investigação científica, porém apresentam possibilidades interessantes de uso desta técnica como possível interface de comunicação com pacientes com Disartria. A Figura 43 mostra as curvas de Energia média calculadas para o canal FC5 do lóbulo Esquerdo e o canal FC6 do lóbulo Direito, para Comando verbal “Direita” em Figura 43 (a), e Comando verbal “Esquerda” em Figura 43 (b) em um sujeito saudável.




Figura 43 Curvas de Energia Média no tempo para o canal do lóbulo Esquerdo FC5 (em cor azul) e lóbulo Direito FC6 (em cor verde). Teste pensado de sujeito saudável, filtragem banda μ , (a) para trilha de comando “Direita” e (b) para trilha de comando “Esquerda”.

Na Figura 43 se observa o aumento da energia do canal contralateral à tarefa do comando “Direita” FC5, em relação ao FC6 do lóbulo oposto (Figura 43 (a)). Assim acontece também, com o comando “Esquerda”, com a ativação do canal FC6, em relação ao FC5 do lóbulo oposto (Figura 43 (b)). A Figura 44 (a) mostra o comando verbal “Para Frente” e a Figura 44 (b) o comando verbal “Para Trás”.




Figura 44. Curvas de Energia Média no tempo para o canal do lóbulo Frontal FC6 (em cor azul) e lóbulo Parietal P8 (em cor verde). Teste pensado de um sujeito saudável, com filtragem na banda μ , (a) para trilha de comando “Para Frente” e (b) para trilha de comando “Para Trás”.

A Figura 44 mostra o aumento da energia do canal FC6 para o comando “Para Frente”, em relação ao P8 do lóbulo oposto (Figura 44 (a)). Assim acontece também, com o comando “Para Trás”, com a ativação do canal P8, em relação ao FC6 do lóbulo oposto (Figura 44 (b)). Logo são apresentados, apenas como exemplo, os gráficos para um paciente para o comando verbal “Direita” (Figura 45 (a)), comando verbal “Esquerda” (Figura 45 (b)), comando verbal “Para Frente” (Figura 46 (a)) e comando verbal “Para Trás” (Figura 46 (b)).




Figura 45. Curvas de Energia Média no tempo para o canal do lóbulo Esquerdo FC5 (em cor azul) e lóbulo Direito FC6 (em cor verde). Teste pensado de um paciente, com filtragem na banda μ , (a) para trilha de comando “Direita” e (b) para trilha de comando “Esquerda”.

Na Figura 45 se observa o aumento da energia do canal contralateral à tarefa do comando “Direita” FC6, em relação ao FC5 do lóbulo oposto (Figura 45 (a)). Assim acontece também, com o comando “Esquerda”, com a ativação do canal FC5, em relação ao FC6 do lóbulo oposto (Figura 45 (b)). Neste caso, se mostra uma maior ativação na energia que com sujeitos saudáveis.




Figura 46 Curvas de Energia Média no tempo para o canal do lóbulo Frontal FC6 (em cor azul) e lóbulo Parietal P8 (em cor verde). Teste pensado de um paciente, com filtragem na banda μ , (a) para trilha de comando “Para Frente” e (b) para trilha de comando “Para Trás”.

Na Figura 46 se observa o aumento da energia do canal contralateral à tarefa do comando “Para Frente” FC6, em relação ao P8 do lóbulo oposto (Figura 46 (a)). Assim acontece também, com o comando “Para Trás”, com a ativação do canal P8, em relação ao FC6 do lóbulo oposto (Figura 46 (b)). Estas curvas também possuem uma maior ativação que as curvas dos voluntários saudáveis. Outro aspecto a observar é a banda de frequência, pois segundo outros estudos a banda β do EEG é mais afetada por artefatos de origem muscular (PFURTSCHELLER *et al.*, 2006; NEUPER *et al.*, 2006). Neste trabalho foram avaliados em projeto de experimentos, os efeitos que representam a mudança da filtragem na banda μ , banda β e banda $\mu + \beta$.

5.2 RESULTADOS DA ANÁLISE DO ÍNDICE DE LATERALIZAÇÃO DO SINAL DE EEG

Como abordado no Sub-Capítulo 4.4.2.2, o IL é apresentado como uma forma de quantificar a contralateralidade dos sinais de ativação ante os comandos verbais, onde a maior contralateralidade denota o momento (ERS/ERD). A Figura 47 apresenta o IL para um voluntário saudável para o comando “Direita”.




Figura 47 Índice de Lateralização para canais de EEG estudados para comando lateral “Direita” em sujeito saudável, com filtragem nas bandas μ e β .

A Figura 47 mostra uma amplitude para os dois IL menor que a dos dois IL apresentados na Figura 48 para um voluntário com Disartria, o qual pode significar uma diferença a ser estudada para identificação das ativações corticais para pacientes com Disartria pós AVC. Este tipo de técnica merece uma investigação científica com maior número de voluntários (estudo do tipo de AVC, região do cérebro mais afetada e etc), pois é uma técnica simples que apresenta boa possibilidade de uso como possível de interface de comunicação com esse tipo de paciente com determinados graus de Disartria. No projeto de experimentos realizado são avaliados os resultados da matriz de confusão (*Accuracy*) para os voluntários saudáveis e os voluntários com Disartria, pois uma maior contralateralidade nos voluntários com Disartria pode ser evidenciada de forma estatística mediante a análise da variável de

resposta *Accuracy* para o fator Estado do voluntário. Esta análise é apresentada no Capítulo 5.4.




Figura 48 Índice de Lateralização para canais de EEG estudados para comando lateral “Direita” em paciente, com filtragem nas bandas μ e β .

Outra observação da comparação entre as curvas das Figuras 47 e 48 foi a maior ativação do *IL* dos canais FC5 – FC6, em relação à dos canais P7 – P8, o que poderia estar relacionado a características próprias ao tipo de comando usado na tarefa mental. Por isso é apresentado na Figura 49 os *IL* dos canais correspondentes para o comando “Para Frente” em um voluntário saudável e na Figura 50 os *IL* para o comando “Para Frente” em um voluntário com Disartria.




Figura 49 Índice de Lateralização para canais de EEG estudados para comando frontal “Para Frente” em sujeito saudável, com filtragem nas bandas μ e β .

Na Figura 49 se observa uma maior ativação do ritmo β para este comando (Para Frente), em relação ao comando na Figura 48.




Figura 50 Índice de Lateralização para canais de EEG estudados para comando frontal “Para Frente” em sujeito com Disartria, com filtragem nas bandas μ e β .

Também se observa que os sinais do voluntário com Disartria na Figura 50 possuem maior energia que o voluntário saudável na Figura 49.

5.3 RESULTADOS DO PROJETO DE EXPERIMENTOS PARA SINAL DO SEMG

Para a realização do experimento fatorial trabalhou-se com as variáveis de resposta da matriz de confusão conforme exposto no Capítulo 4.7. Primeiramente foi evidenciado que os dados obtidos da variável de resposta TxC e a variável Err seguem uma distribuição normal e são independentes, como representado pela Figura 51.




Figura 51 Histograma com tendência de distribuição normal para dados de sEMG nos 14 voluntários.

Como observado na Figura 51, a variável *TxC* atingiu uma média de 0,7362 ou 73,6%. No caso da variável *Err* atingiu 0,2638 ou 26,4%, sendo este valor o complemento do anterior, como observado na análise das Equações (73) e (74). As variáveis de resposta *Sx* e *Sc* apresentaram uma tendência menos parecida com a normal e foram excluídas na análise de fatores.

Este projeto de experimentos permite avaliar se a variável de resposta *TxC* depende de forma significativa dos fatores controláveis do presente experimento. Os fatores controláveis estudados no caso da classificação do sinal de sEMG foram: *Dataset* (14 Sujeitos), Método Computacional (LDA e SVM), Comando Verbal (16 níveis produto das combinações entre comando Real (“Direita”, “Esquerda”, “Para Frente” e “Para Trás”) e comando Previsto (“Direita”, “Esquerda”, “Para Frente” e “Para Trás”)). A Tabela 7 apresenta o resultado do Projeto de Experimentos para o sinal de sEMG.

Tabela 7. Resultado do Projeto de Experimentos da variável de resposta *TxC* para os fatores controláveis de interesse e as suas interações no sinal de sEMG.

Fonte	Graus de Liberdade	Soma dos Quadrados	Média dos Quadrados	<i>F-Value</i>	<i>P-Value</i>
Método	1	0,04	0,04	3,85	0,050
Dataset	13	66,82	5,14	469,44	0,000
Comando	15	15,52	1,03	94,49	0,000
Método-Dataset	13	0,69	0,05	4,84	0,000
Método-Comando	15	0,26	0,02	1,60	0,065
Dataset-Comando	195	33,43	0,17	15,65	0,000
Método-Dataset-Comando	195	2,07	0,01	0,97	0,603
Erro	15680	171,69	0,01		
Total	16127	290,52			

De acordo com os resultados da Tabela 7, o fator controlável Método não é significativo ($p > 0,05$) na geração da variável de resposta *TxC*, ou seja, o uso dos métodos LDA e SVM empregados na classificação do sinal de sEMG não demonstraram, de forma individualizada, uma diferença estatisticamente significativa entre os seus resultados. Este fato é interessante, pois possibilitaria, nesta análise do fator controlável individualizado, optar pelo método de menor custo computacional (o que não foi considerado no presente trabalho). O fator controlável Dataset resultou significativo ($p < 0,001$), evidenciando, portanto, diferenças notáveis entre os resultados de classificação entre voluntários. O fator Comando resultou em diferença notável ($p < 0,001$). A interação Método – Comando não resultou significativa ($p > 0,05$) ao igual que a interação Método – Dataset – Comando ($p > 0,05$). O resto das interações por serem significativas foi analisado de forma gráfica (para facilitar sua representação neste trabalho em função da grande quantidade de dados) e encontra-se nas Figuras 52 e 53.




Figura 52 Curvas de interações entre o fator *Dataset* e o fator Método para o sinal de sEMG.

De acordo com os resultados do Projeto de Experimentos apresentado na Tabela 7 a interação do fator Método com o fator *Dataset* apresentou resultado significativo, o qual é evidenciado na Figura 52 pelo cruzamento das curvas, onde levemente os voluntários saudáveis (Dataset 1 - 7) apresentaram uma maior *Accuracy* que os voluntários com Disartria (Dataset 8 - 14). Também na Figura 52, se observa que os 14 voluntários, seguem o mesmo comportamento nas curvas dos dois métodos abordados.




Figura 53 Curvas de interações entre o fator Dataset e o fator Comando para o sinal de sEMG.

As curvas da Figura 53 apresentaram os maiores valores de *Accuracy* para os níveis de combinação “Direita – Direita”, “Esquerda – Esquerda”, “Para Frente – Para Frente” e “Para Trás – Para Trás”, coincidindo com as classificações certas dos métodos. Devido ao cruzamento das curvas dos tratamentos, a interação destes fatores é significativa.

5.4 RESULTADOS DOS PROJETOS DE EXPERIMENTOS PARA O SINAL DO EEG

Para a realização dos experimentos fatoriais para o sinal de EEG trabalhou-se também com as variáveis de resposta da matriz de confusão conforme apresentado no Capítulo 4.7. Foi evidenciado que os dados obtidos da variável de resposta *TxC* e a variável *Err* seguem uma distribuição normal e são independentes, como representado na Figura 54.




Figura 54 Histograma com tendência de distribuição normal para dados de EEG nos 14 voluntários.

Na Figura 54 se observa que a variável *TxC* apresentou uma média de 0,5260 (52,6%). A variável *Err* atingiu a média 0,4740 (47,4%), sendo este valor o complemento do anterior, como observado na análise das Equações (73) e (74). As variáveis de resposta *Sx* e *Sc*

apresentaram uma tendência menos parecida com a normal e foram excluídas na análise de fatores. Foram desenvolvidos dois projetos de experimentos que permitem avaliar se a variável de resposta *TxC* depende de forma significativa dos fatores controláveis e as suas interações. Os fatores controláveis estudados no caso da classificação do sinal de EEG foram: *Dataset* (14 Sujeitos), Método Computacional (LDA e NB), Comando Verbal (16 níveis produto das combinações entre comando Real (“Direita”, “Esquerda”, “Para Frente” e “Para Trás”) e comando Previsto (“Direita”, “Esquerda”, “Para Frente” e “Para Trás”)), Natureza do teste (Falado ou somente Pensado) e Banda (ritmo μ , ritmo β ou ritmo $\mu + \beta$). Destes fatores foram escolhidos: *Dataset*, Método e Comando, para a realização do primeiro projeto de experimentos, do qual foi obtida a Tabela 8. Também foram escolhidos os fatores: *Dataset*, Natureza e Banda, para a realização do segundo projeto de experimento, com resultado apresentado na Tabela 9.

Tabela 8. Resultado do Projeto de Experimentos da variável de resposta *TxC* para os fatores controláveis *Dataset*, Método, Comando e as sua interações no sinal de EEG.

Fonte	Grau de Liberdade	Soma de Quadrados	Média dos Quadrados	<i>F-Value</i>	<i>P-Value</i>
Método	1	5,33	5,33	256,53	0,000
<i>Dataset</i>	13	1,62	0,12	6,01	0,000
Comando	15	68,30	4,55	219,25	0,000
Método-<i>Dataset</i>	13	0,95	0,07	3,53	0,000
Método-Comando	15	1,44	0,10	4,63	0,000
<i>Dataset</i>-Comando	195	10,48	0,05	2,59	0,000
Método-<i>Dataset</i>-Comando	195	6,27	0,03	1,55	0,000
Erro	96320	2000,28	0,02		
Total	96767	2094,67			

Os resultados da Tabela 8 mostram que os três fatores controláveis: Método (LDA e NB), *Dataset* (14 voluntários) e Comando (16 combinações) foram significativos ($p < 0,001$), ou seja, estes três fatores mudam a variável de resposta de maneira significativa individualmente. As interações dos fatores: Método – *Dataset*, Método – Comando, *Dataset* – Comando e Método – *Dataset* – Comando, resultaram todos significativos ($p < 0,001$), mudando a variável de resposta em função das interações destes fatores. Todas as interações de dois fatores, por serem significativas foram analisadas de forma gráfica, facilitando sua representação neste trabalho e encontra-se nas Figuras 55, 56 e 57. A interação gráfica dos três fatores não foi possível, pois a ferramenta estatística não permite análise tridimensional gráfico.




Figura 55 Curvas de interações entre o fator *Dataset* e o fator Método para o sinal de EEG.

De acordo com os resultados do Projeto de Experimentos apresentado na Tabela 8 a interação do fator Método com o fator *Dataset* apresentou resultado significativo, onde para todos os *Dataset* o fator Método atingiu valores maiores de *Accuracy* para o nível NB, revelando melhor resultado do método NB.

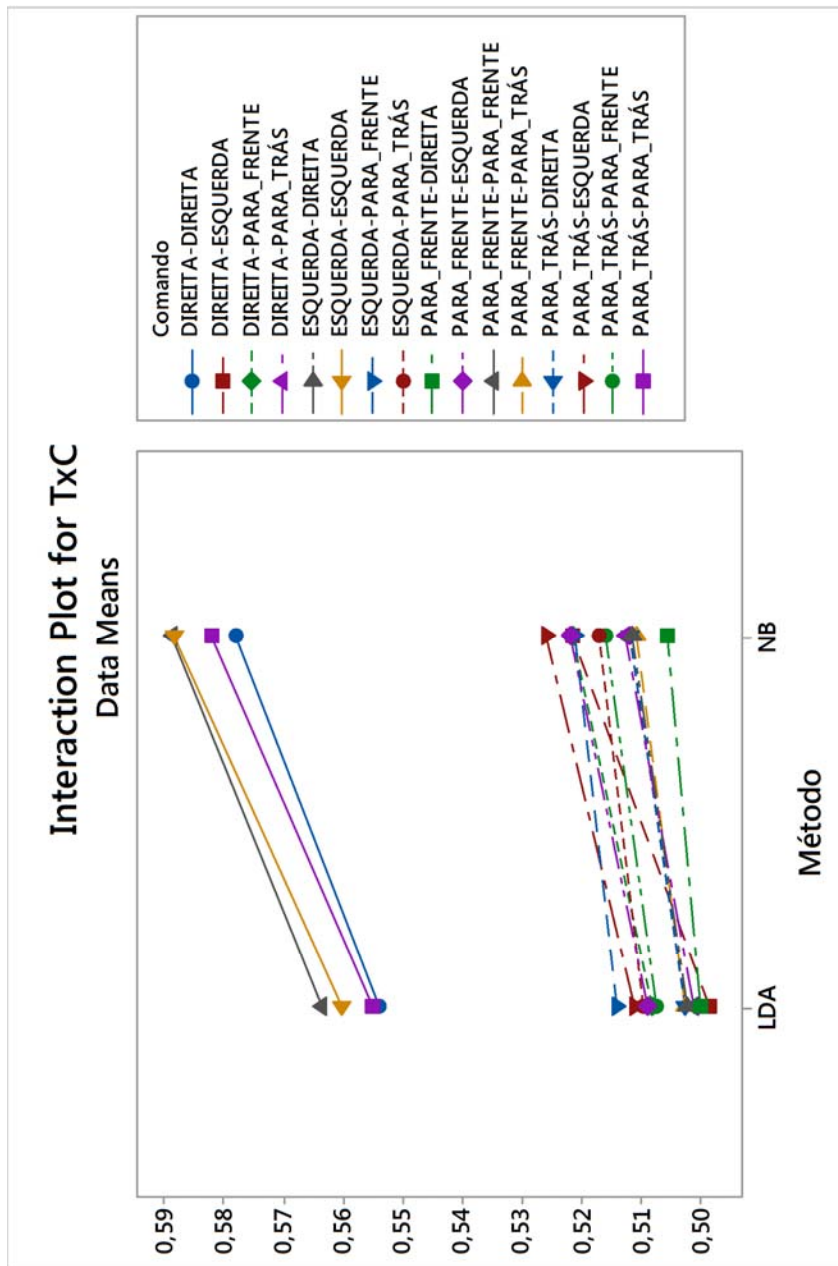


Figura 56 Curvas de interações entre o fator Comando e o fator Método para o sinal de EEG.

A interação do fator Comando com o fator Método apresentou resultado significativo, onde para todos os Comandos o fator Método atingiu valores maiores de *Accuracy* para o nível NB, evidenciando melhor resposta para este método em comparação com o método LDA.

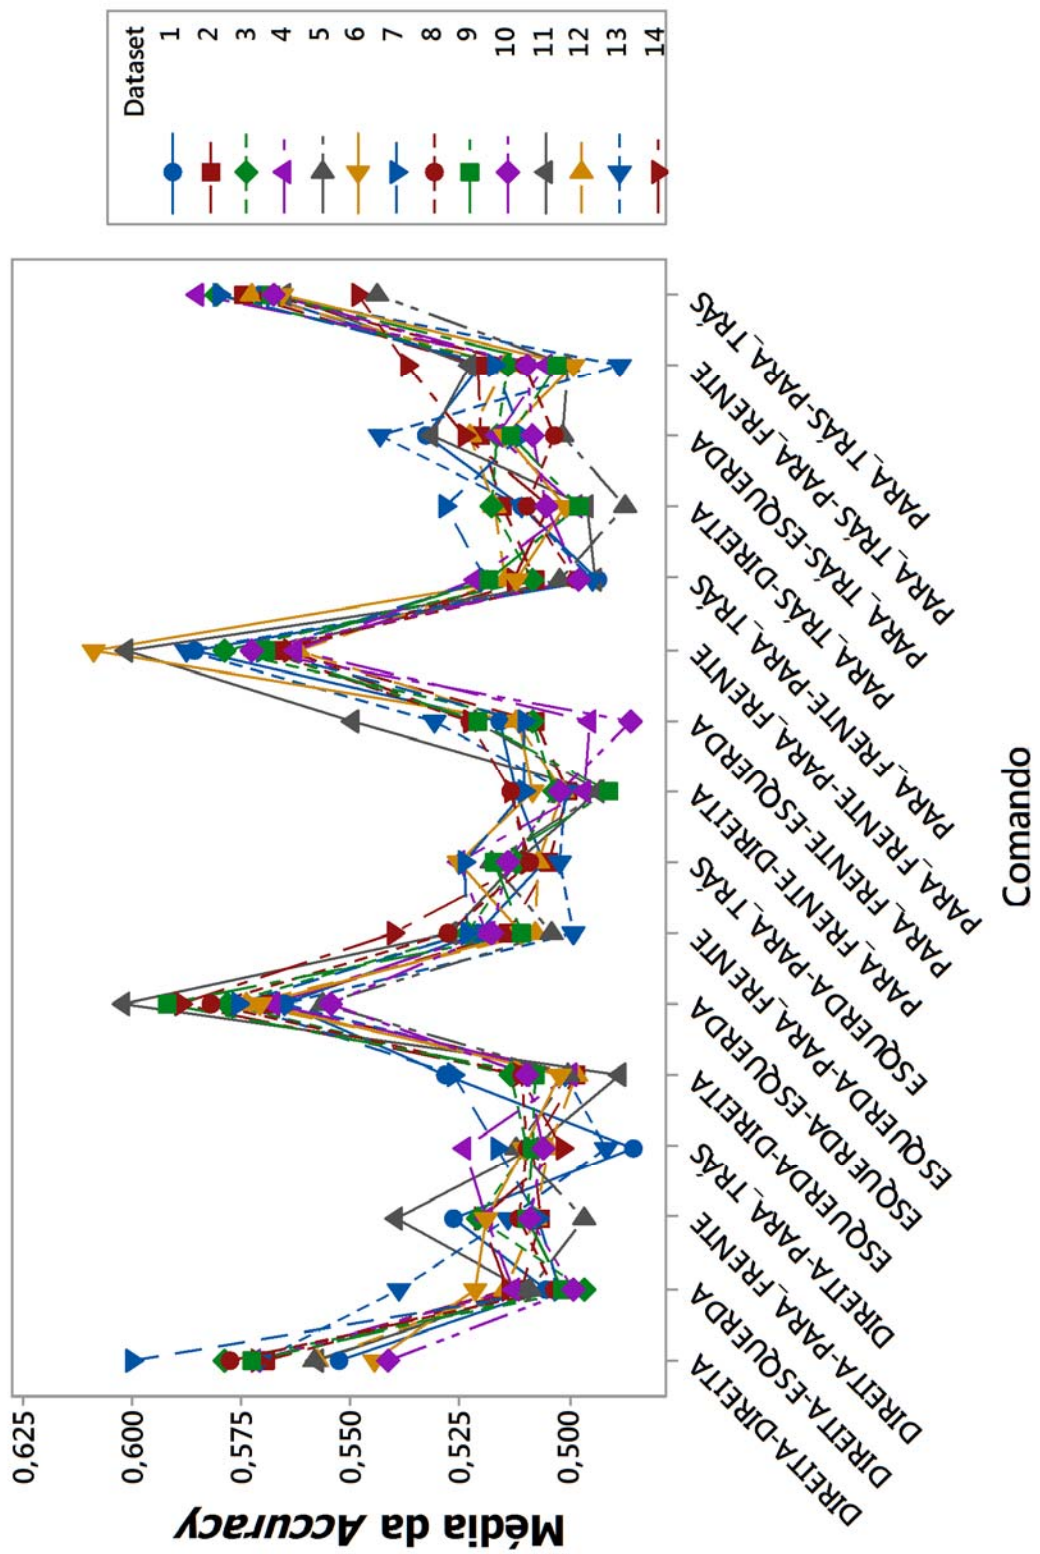


Figura 57 Curvas de interações entre o fator Comando e o fator Dataset para o sinal de EEG.

As curvas da Figura 57 apresentaram os maiores valores de *Accuracy* para os níveis de combinação “Direita – Direita”, “Esquerda – Esquerda”, “Para Frente – Para Frente” e “Para Trás – Para Trás”, coincidindo com as classificações certas dos métodos. Devido ao cruzamento das curvas dos tratamentos, a interação destes fatores é significativa. Os valores médios de *Accuracy* nas curvas da Figura 57 mantem certa estabilidade para todos os *Dataset*.

A Tabela 9 mostra que os fatores controláveis: Natureza (Falado e somente Pensado) e Banda (ritmo μ , ritmo β e ritmo $\mu + \beta$) não foram significativos ($p > 0,05$), ou seja, que não muda a variável de resposta com estes fatores de forma individual.

Tabela 9. Resultado do Projeto de Experimentos da variável de resposta *TxC* para os fatores controláveis *Dataset*, Natureza, Banda e as sua interações no sinal de EEG.

Fonte	Grau de Liberdade	Soma de Quadrados	Média dos Quadrados	<i>F-Value</i>	<i>P-Value</i>
Natureza	1	0,04	0,04	1,65	0,199
<i>Dataset</i>	13	1,62	0,12	5,78	0,000
Banda	2	0,08	0,04	1,79	0,168
Natureza-<i>Dataset</i>	13	2,64	0,20	9,42	0,000
Natureza-Banda	2	0,50	0,25	11,50	0,000
<i>Dataset</i>-Banda	26	3,25	0,13	5,80	0,000
Natureza-<i>Dataset</i>-Banda	26	1,78	0,07	3,18	0,000
Erro	96684	2084,76	0,02		
Total	96767	2094,67			

O fator *Dataset* resultou significativo ($p < 0,001$) nesta análise de variância ao igual que na análise do projeto da Tabela 8. As interações dos fatores: Natureza – *Dataset*, Natureza – Banda, *Dataset* – Banda e Natureza – *Dataset* – Banda, resultaram todos significativos ($p < 0,001$), mudando a variável de resposta em função das interações destes fatores. Estas interações por serem significativas foram analisadas de forma gráfica, encontra-

se nas Figuras 58, 59 e 60. A interação gráfica dos três fatores não foi possível, pois a ferramenta estatística não permite análise tridimensional gráfico.




Figura 58 Gráfico de interações entre o fator *Dataset* e o fator *Natureza* para sinal de EEG.

Como apresentado na Tabela 9, a interação do fator *Natureza* com o fator *Dataset* foi significativo e confirmou-se devido ao cruzamento das curvas dos tratamentos. Para todos os *Dataset* o fator *Natureza* apresentou menor dispersão e maiores valores de *Accuracy* para o nível somente Pensado.




Figura 59 Curvas de interações entre o fator *Comando* e o fator *Método* para o sinal de EEG.

A interação do fator Banda com o fator Natureza foi significativo, evidenciado pelo cruzamento das curvas na Figura 59. Os níveis μ e $\mu + \beta$ do fator Banda demonstraram valores de média de *Accuracy* maiores para os testes de Natureza Falado, enquanto o nível μ apresentou valores maiores de *Accuracy* para os testes de Natureza somente Pensado.




Figura 60 Curvas de interações entre o fator *Dataset* e o fator *Banda* para o sinal de EEG.

Segundo as curvas da Figura 60, a interação dos fatores *Dataset* e Banda foi evidenciada significativa pelo cruzamento das curvas. Observaram-se valores maiores de média de *Accuracy* para o nível β do fator Banda nos níveis do fator *Dataset* (8 - 14) correspondente aos voluntários com Disartria. Os níveis μ e $\mu + \beta$ foram observados estáveis para todos os níveis do fator *Dataset*.

5.5 RESULTADOS DA CLASSIFICAÇÃO COM SINAIS DE SEMG E EEG

Como dito anteriormente no Capítulo 4.8, a proposta de fazer a classificação do sinal de EEG com complementação do sinal de sEMG, consiste principalmente em utilizar as médias entre as classificações de ambos os sinais ante um comando verbal para cada voluntário, visando o aumento da *Accuracy* na diagonal principal das matrizes de confusão geradas para cada voluntário. A Figura 61 apresenta o gráfico de barras para toda a amostra mostrando os as médias de *Accuracy* apenas para o sinal de EEG e usando o sEMG e EEG para melhorar a *Accuracy* no método, ou seja, mediante o uso do método de NB somente e mediante o uso de NB e SVM nos sinais de EEG e sEMG, respectivamente, para cada voluntário.




Figura 61 Resultado em barras representando a classificação com sinal de EEG (método NB) e EEG + sEMG (método NB + SVM).

Logo da aplicação do método SVM como complemento, os resultados da *Accuracy* foram melhorados para os 14 voluntários como apresenta a Figura 61 na ordem dos 10%. O sistema apresentou *Accuracy* entre 65,5% - 70,1% sem a complementação do método SVM e depois de ser inclusa esta mudança, as taxas foram acrescentadas a 77,6% - 80,8%.

5.6 DISCUSSÃO E COMPARAÇÃO COM OUTROS TRABALHOS

Para poder realizar comparações deve-se salientar que na pesquisa bibliográfica feita não foi encontrado nenhum trabalho com perfil similar ao desta pesquisa, porém apenas e feita uma comparação deste trabalho com outros que empregaram técnicas similares. Este trabalho tem as particularidades de trabalhar com dois sinais simultâneos, estudar padrões ou paradigmas pouco acessados como “Para Frente” e “Para Trás”, e realizar o processamento de sinais evocados por estímulos sonoros como a voz humana. No trabalho, foram realizados ensaios com sujeitos saudáveis e com sujeitos com Disartria pós AVC, sendo este um grupo seletivo do qual não foram achados trabalhos relacionados na literatura.

Os comandos verbais foram escolhidos pensando nas principais ações a serem desenvolvidas nos sistemas de tecnologia assistiva, assim como o desenvolvido em (WEI & HU, 2011) onde Sinais de sEMG da face mapeiam cinco comandos de controle para conduzir uma cadeira de rodas simulada, mediante método matemático SVM. Músculos da face também foram usados em (YU *et al.*, 2014) para sujeitos com perda da capacidade de falar na língua cantonesa, e no trabalho de (STEPP *et al.* 2009) foi usado o sinal do sEMG do platísmo, masseter e depressores para captação e classificação de comandos verbais da língua inglesa. Outro trabalho realizou classificação do sinal de sEMG em nove movimentos do segmento braço-mão, mediante o uso de SVM atingindo taxas de 79,4%, que em comparação, o presente trabalho realizou a classificação de quatro comandos verbais mediante sinal de sEMG, obtendo médias de acerto entre 88,8% e 94,2%.

O sistema de EEG empregado neste trabalho, touca EEG Emotiv EPOC/EPOC+ tem sido usado em outras pesquisas como (TAKSANDE & PADOLE, 2014) para sujeitos quadriplégicos, mas nunca foi usado em complementação com sinais de sEMG. Assim como em (CHOWDHURY *et al.*, 2014) onde no controle de um robô usando os mesmos comandos deste trabalho, se atingiu taxas médias de eficiência de 72,6%. Outros pesquisadores (MACHADO *et al.*, 2012; MACHADO & BALBINOT, 2014) têm atingido *Accuracy* para tarefas mentais mediante o uso de método matemático *Naive Bayes*, como as usadas neste trabalho de até 70%, similares às obtidas no sistema deste trabalho sem ajuda do sEMG, porém nesta pesquisa se alcançaram taxas de até 70% sem sEMG e de até 80,8% com EEG + sEMG. Outro trabalho (SONG *et al.*, 2014) emprega os sinais de EEG e sEMG do braço para realizar a movimentação de próteses, porém não emprega sinais faciais.

Considerando outros trabalhos como os abordados no Capítulo 3.1, este trabalho apresenta *Accuracy* dentro da média existente. Além do uso de dois sinais sincronizados como o sEMG e o EEG, tornando-o mais eficiente. Outro aspecto a salientar é que este trabalho avalia fatores como a banda de frequência para filtragem no EEG, compara os métodos de LDA em sEMG com o de SVM e de LDA em EEG com o de NB, obtendo uma grande diferença nos resultados.

6 CONCLUSÕES

O trabalho proposto tinha como objetivo desenvolver um sistema experimental para adquirir, extrair e classificar sinais de sEMG dos músculos da face relacionados ao processo da fala dos comandos verbais estabelecidos, assim como, adquirir conjuntamente sinais de EEG relacionados aos eventos estudados, propiciando uma contribuição no desenvolvimento de sistemas de tecnologia assistiva para uma maior autonomia em pessoas com limitações psicomotoras. O trabalho foi dirigido especialmente a pessoas com sequelas do AVC como Disartria, melhorando com os métodos obtidos a qualidade de vida destes.

Foi elaborado um algoritmo matemático baseado no método *Support Vector Machine* para classificação dos sinais de sEMG e em *Naive Bayes* para classificação dos sinais de EEG. Os comandos verbais definidos: “Direita”, “Esquerda”, “Para Frente” e “Para Trás”, possibilitaram a identificação de tarefas mentais e em sujeitos com Disartria demonstrou ser de muita ajuda o processamento do sinal de EEG, pela qualidade do sinal obtido nestes pacientes.

Realizaram-se coletas em voluntários saudáveis no Laboratório IEE e com voluntários com Disartria no departamento de Fisioterapia do Hospital de Clínicas de Porto Alegre. Foram efetuadas avaliações para o efeito de mudanças no método matemático aplicado, na faixa de frequência filtrada, natureza do ensaio, utilizando como variável de resposta a *Accuracy*.

O método de segmentação foi composto de segmentação por referência de áudio e para sEMG foram segmentadas janelas segundo a energia média nas trilhas analisadas, assim como para EEG foi utilizado o periodograma de *Welch* para segmentar segundo a informação de frequência.

A extração de características foi feita usando o método de *Mother wavelets* para sEMG, dividindo as trilhas em 5 bandas de frequência para serem calculadas as características

escolhidas. No sinal de EEG, o sinal é caracterizado no tempo e na frequência, obtendo-se a matriz de características para a classificação.

Destacaram-se a Banda de frequência μ e $\mu + \beta$ em EEG como as de melhores resultados nos testes realizados de Natureza Falado, sendo na Banda β a de maior valor de *Accuracy* para teste de Natureza somente Pensado. Valores maiores de média de *Accuracy* foram atingidos para o nível β do fator Banda nos níveis do fator *Dataset* correspondente aos voluntários com Disartria, o que pode ser estudado futuramente para a identificação do grau de Disartria.

Foram comparados os métodos de LDA com o SVM para sinal de sEMG, obtendo levemente maior *Accuracy* para SVM. A classificação do sinal de sEMG apresentou menos erro em voluntários saudáveis que em voluntários com Disartria, atingindo taxas maiores nos saudáveis a causa da qualidade do sinal principalmente, pois a disfasia produto da Disartria impede as vezes o controle muscular. Foi avaliado o método LDA e NB para classificação do sinal de EEG, obtendo melhores resultados para NB. Observaram-se maiores taxas em voluntários com Disartria que em saudáveis, o qual pode ser devido à concentração do voluntário encamado na tarefa. Foi implementado um sistema de complementação de método de NB para sinal de EEG e método de SVM para sinal de sEMG, mudando os resultados de *Accuracy* em até um 10% (taxas de 77,6% - 80,8%) em relação ao sistema simples com método de NB em EEG.

7 PROPOSTA PARA TRABALHOS FUTUROS

Como parte dos trabalhos futuros seria interessante realizar ensaios com um número maior de Voluntários (com Disartria e saudáveis), para se realizar uma análise estatística mais robusta dos resultados, podendo avaliar melhor os métodos implementados. Propiciar as mesmas condições ambientais para voluntários com Disartria e Saudáveis no momento da coleta dos dados, assim como garantir a mesma faixa etária nos grupos de estudo, pois depois do processamento dos sinais em ambos os grupos analisados, os sinais de EEG do grupo de voluntários com Disartria apresentaram uma melhor qualidade no sinal e *Accuracy*. Realizar avaliação em um projeto de experimentos com o fator controlável “Canal” para sEMG visando a diminuição de canais na coleta dos dados nos sujeitos, o que melhoraria o conforto do voluntário durante o ensaio.

Outra proposta para trabalhos futuros seria avaliar outras características que poderiam ser extraídas no sinal de sEMG e no sinal EEG para melhorar o desempenho dos métodos de classificação para cada um dos sinais. Incorporando a implementação de algoritmos para seleção das características, como o algoritmo DSLVQ (*Distinction Sensitive Learning Vector Quantization*) que faz a busca pelas componentes específicas de cada usuário. Dessa forma o sistema teria a capacidade de caracterizar mais especificamente os movimentos correspondentes a cada um dos comandos estabelecidos, pois as ativações musculares variam muito de um voluntário ao outro. Aumentar a *Accuracy* acima do máximo obtido no trabalho (80,8%), tendo uma maior capacidade de diferenciar os movimentos do rosto.

Na captação do sinal de sEMG, seria importante ter em conta o *delay* introduzido pelo sistema de aquisição (USB-6289), o qual é robusto, porém possui retardos na faixa dos segundos que influencia no tempo da resposta da classificação.

Outra abordagem necessária a fim de comparação é a classificação dos dados coletados através de outros métodos de inteligência computacional, além do LDA.

Por fim a implementação de um sistema autônomo e assíncrono, capaz de funcionar apenas com a intenção do usuário empregando os comandos verbais estabelecidos neste trabalho. Para isso é necessário o desenvolvimento de uma plataforma de *hardware* capaz de fazer processamento em tempo real. Os algoritmos terão que ser repensados e adaptados para este tipo de sistema autônomo.

REFERÊNCIAS

- ABDOLALI, F.; ZOROOFI, R. A. General multivariate linear modeling of mandible surface using SurfStat. In: IRANIAN CONFERENCE ON BIOMEDICAL ENGINEERING (ICBME), 21., 2014, Tehran, Iran. **Proceedings...** New York: IEEE, 2014.p. 181-185.
- ABE, S. **Support vector machines for pattern classification**. London: Springer, 2005.2 v.
- ADAMS. **Interactive Anatomy**. Ebix Inc. Atlanta, Georgia 30309. Version 0.3.00.05.00, 1997, CD-ROM. Programa de Computador.
- AHMED, W. *et al.* Assisting the autistic with improved facial expression recognition from mixed expressions. In: NATIONAL CONFERENCE ON COMPUTER VISION, PATTERN RECOGNITION, IMAGE PROCESSING AND GRAPHICS (NCVPRIPG), 4., 2013, Jodhpur, India. **Proceedings...** New York: IEEE, 2014.p. 1-4.
- ALBRECHT, B. L. **Controle de uma Cadeira de Rodas motorizada através de Electromiografia em uma plataforma embarcada**. 2010. 137 f. Projeto de diplomação (Graduação em Engenharia da Computação) – Instituto de Informática da Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.
- ALMEIDA N. T. **Ortopedia Funcional: Má Oclusão**. 2011. Disponível em:<<http://www.naiaodonto.com.br/site/ortopedia-funcional>> Acesso em: 05/03/2015
- ALWAN, A. **Global status report on noncommunicable diseases**. 2014. Disponível em:<https://cspinet.org/new/pdf/who-global-status-report-on-ncds-2014__1_.pdf> Acesso em: 20/01/2015
- ANDREOLA, R.; HAERTEL, V. Classificação de Imagens Hiperespectrais Empregando Support Vector Machines. **Boletim de Ciências Geodésicas**, Curitiba, v. 16, n. 2, p. 210-231, 2010.
- ANH-DAO, N. T.*et al.* An Effective Procedure for Reducing EOG and EMG Artefacts from EEG Signals. In: INTERNATIONAL CONFERENCE ON ADVANCED TECHNOLOGIES FOR COMMUNICATIONS (ATC'13), 2013, Hanoi, Vietnam. **Proceedings...** New York: IEEE, 2013. p. 328-32.
- AQUEVEQUE, P.; PINO, E.; LÓPEZ, R. Electrical stimulation device as possible treatment for nocturnal bruxism: Preliminary results. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC), 35., 2013, Osaka, Japan. **Proceedings...** New York: IEEE, 2013. p. 3571-3573.

BADCOCK, N. A. *et al.* **Validation of the Emotiv EPOC® EEG gaming system for measuring research quality auditory ERPs.** *PeerJ*. Sydney: Macquarie University, 2013. v. 1.

BARTLETT, M. S.; KENDALL, D. G. The statistical analysis of variance-heterogeneity and the logarithmic transformation. **Supplement to the Journal of the Royal Statistical Society**, London, v. 8, n. 1, p. 128-138, 1946.

BEMUDEZ, R. **Proposta de um sistema baseado em redes neurais e wavelets para caracterização de movimentos do segmento mão-braço.** 2013. 112p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.

BEN, M. C.; FRANCIS, A. S. Auditory System. In: JOSEPH D. BRONZINO. **The Biomedical Engineering Handbook**. 2nd ed. Boca Raton: Florida, 2000. Chapter 5, p. 82-94.

BENEVIDES, B. A. *et al.* Classificação de Tarefas Mentais em Tempo Real para Aplicação de Controle de Dispositivos Robóticos. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 18., 2010, Bonito, Mato Grosso do Sul. **Anais...** Campinas: São Paulo, 2010, p. 2283-2239.

BERBERIAN, A. P. *et al.* A produção do conhecimento em Fonoaudiologia em Comunicação Suplementar e/ou Alternativa. **Revista CEFAC**, Curitiba, v.11, p. 258-66, maio 2009.

BERRY, J.; NORTH, C.; JOHNSON, M. T. Sensorimotor adaptation of speech using real-time articulatory resynthesis. In: INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH AND SIGNAL PROCESSING (ICASSP), 2014, Florence, Italy. **Proceedings...** New York: IEEE, 2014. p. 3196-3200.

BINDER, J. R. *et al.* Human brain language areas identified by functional magnetic resonance imaging. **The Journal of Neuroscience**, Wisconsin, v. 17, n. 1, p. 353-362. 1997.

BLANKERTZ, B. *et al.* Optimizing Spatial Filters for Robust EEG Single-Trial Analysis. **IEEE Signal Processing Magazine**, Kansas City, v. 25, n. 1, p. 41-56. 2008.

BORNMANN, L. *et al.* Citation counts for research evaluation: standards of good practice for analyzing bibliometric data and presenting and interpreting results. **Ethics in Science and Environmental Politics**, Thessaloniki, Greece, 8, n. 1, p. 93-102. 2008.

BORUAH, D.; SARMA, K. K.; TALUKDAR, A. K. Different Face Regions Detection Based Facial Expression Recognition. In: INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING AND INTEGRATED NETWORKS (SPIN), 2., 2015, Delhi-NCR, India. **Proceedings...** New York: IEEE, 2015.p. 459-464.

BOUTANI, H.; OHSUGA, M. Applicability of the “Emotiv EEG Neuroheadset” as a user-friendly input interface. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC), 35., 2013, Osaka, Japan. **Proceedings...**New York: IEEE, 2013. p. 1346-1349.

BRESOLIN A, A.; NETO, A. D. D.; ALSINA, P. J. Consonantal recognition using SVM and new hierarchical decision structure based in the articulatory phonetics. In: INTERNATIONAL SYMPOSIUM ON MULTIMEDIA, 10., 2008. ISM 2008, Berkeley, California, USA. **Proceedings...**New York: IEEE, 2008. p. 545-550.

BRITO, DE A. V. G. **Estudo da Relação entre a Atividade Eletromiográfica de Músculos da Face e o Movimento Facial durante a Fala**. 2009. 121 f. Dissertação (Mestre em Engenharia Elétrica) – Faculdade de Engenharia Elétrica da Universidade Federal de Minas Gerais, Minas Gerais. 2009.

BUI, T. D.; HEYLEN, D.; NIJHOLT, A. Improvements on a simple muscle-based 3D face for realistic facial expressions. In: INTERNATIONAL CONFERENCE ON COMPUTER ANIMATION AND SOCIAL AGENTS, 16., 2003, New Brunswick, NJ, USA. **Proceedings...**New York: IEEE, 2003. p. 33-40.

BURROWS, A. M. *et al.* **The Anatomical Record**. Of mice, monkeys, and men: Physiological and morphological evidence for evolutionary divergence of function in mimetic musculature. Pittsburgh: WileyPeriodicals, 2014. Disponível em: <<http://onlinelibrary.wiley.com/doi/10.1002/ar.22913/pdf>>. Acesso: 10/03/2015.

CANTOR, R.; CANTOR, S. G. Physiological description of the neuron and the human nervous system. In: INTERNATIONAL FREQUENCY CONTROL SYMPOSIUM, 49., 1995, San Francisco, USA. **Proceedings...**New York: IEEE, 1995. p. 3-9.

CARRA, M.; BALBINOT, A. Development of a brain-computer interface system based on sensori-motor rhythms. In: ISSNIP BIOSIGNALS AND BIROBOTICS CONFERENCE, 2012, Manaus, Brasil. **Proceedings...**New York: IEEE, 2012. p. 21-26.

CASTILHO, F. M.; MARTINS, L. A. C. P. As concepções evolutivas de Darwin sobre a expressão das emoções no homem e nos animais. **Revista da Biologia**, São Paulo, SP Brasil, v. 9, n. 2, p. 12-15. Dez. 2012.

CAWLEY, G. C. Leave-one-out cross-validation based model selection criteria for weighted ls-svms. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 06., 2006, Vancouver. **Proceedings...**New York: IEEE, 2006. p. 1661-1668.

CESA, C. C.; MOTA, H. B. Augmentative and alternative communication: scene of Brazilian journal. **Revista CEFAC**, São Paulo, v. 17, n. 1, p. 264-269. fev. 2015.

CHAGAS, S. L. **Classificação de Sinais de Eletroencefalograma usando Máquinas de Vetores Suporte**. 2009. 85 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Presbiteriana Mackenzie, São Paulo, 2009.

CHAN, Y. T. **Wavelet basics**. Massachusetts, 2012. Disponível em: <https://books.google.com.br/books?id=mQUI_kW5lhIC&printsec=frontcover&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false>. Acesso em: 07/04/2015.

CHIEN, Y. R.; WANG, H. M.; JENG, S. K. An Acoustic-Phonetic Model of F0 Likelihood for Vocal Melody Extraction. Transactions on audio, speech, and language processing. **Journal IEEE/ACM**, New York, v. 23, n.9. p. 1457-1468, Sept. 2015.

CHOWDHURY, P. *et al.* Cognitive efficiency in robot control by Emotiv EPOC. In: INTERNATIONAL CONFERENCE ON INFORMATICS, ELECTRONICS & VISION (ICIEV), 2014, Dhaka, Bangladesh. **Proceedings...**New York: IEEE, 2014. p. 1-6

COLLURA, T. F. History and evolution of electroencephalographic instruments and techniques. **Journal of Clinical Neurophysiology**, New York, v. 10, n. 4, p. 476-504, Oct. 1993.

MANUAL CORTICAL FUNCTIONS REFERENCE. **Trans Cranial Technologies**, Wanchai, Hong Kong, v. 1.0, p. 1-61, 2012.

CRISTIANINI, N.; SHAWE-TAYLOR, J. **An introduction to support vector machines and other kernel-based learning methods**. New York: Cambridge, 2000.

DAUD, W. M. B. W. *et al.* Features extraction of electromyography signals in time domain on biceps Brachii muscle. **International Journal of Modeling and Optimization**, Johor, Malaysia, v. 3, n. 6, p. 515-519, Dec. 2013.

DATASUS, Ministério da Saúde. **Indicadores Regionais, Estaduais e Nacionais**. 2015. Disponível em: www.datasus.gov.br. Acesso em: 23/04/2016.

DAYAN, P.; ABBOTT, L. F. **Theoretical Neuroscience. Computational and Mathematical Modeling of Neural Systems. Neural Decoding**. Cambridge: MIT, 2000. Chapter 3, p. 89-125.

DE BATTISTI, F.; SALINI, S. Robust analysis of bibliometric data. **Statistical Methods & Applications**, Milan, v. 22, n. 2, p. 269-283, 2012. Disponível em: <http://link.springer.com/article/10.1007%2Fs10260-012-0217-0#page-2>. Acesso em: 23/04/2015.

DE MENESES, K. V. P. *et al.* Desempenho ocupacional e satisfação de indivíduos pós-acidente vascular encefálico. **Cadernos de Terapia Ocupacional da UFSCar**, São Carlos, v. 22, n.3, p. 515-520, Nov. 2014.

DE PAULI NILSON, C.; BALBINOT, A. Acquisition, processing of myoelectrics signals and Support-Vector Machine for movement characterization of hand-arm segment. In: BIOSIGNALS AND BIOROBOTICS CONFERENCE (BRC), 5., 2014, Salvador, Brazil. **Proceedings...**New York: IEEE, 2014. p. 1-4.

DOMINGOS, DA S. G. **A Ação Fonoaudiológica nos Pacientes com Disfunção Temporomandibular. Monografia Apresentada no Curso de Metodologia I**. São Paulo: Centro de Especialização em Fonoaudiologia Clínica, 1998. 35 f.

DOYLE, L. M.; YARROW, K.; BROWN, P. Lateralization of event-related beta desynchronization in the EEG during pre-cued reaction time tasks. **Clinical neurophysiology**, London, v. 116, n. 8, p. 1879-1888. Aug. 2005.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Linear Discriminant Functions**. Pattern Classification. 2.ed. New York: Wiley-Interscience, 2000.

EKANAYAKE, H. Research use of EmotivEPOC. **WEB2 PDF**, New York, v. 2013, n. 2, p. 1-59, an. 2013.

EKANAYAKE, H. P300 and Emotiv EPOC: Does Emotiv EPOC capture real EEG?. **WEB2 PDF**, New York, v. 2011, n.2, p. 1-16, Oct. 2011.

EKMAN, P.; FRIESEN, W. V. Measuring facial movement. Environmental psychology and nonverbal behavior. Facial signs of emotional experience. **Journal of personality and Social Psychology**, California, v. 39, n. 6, p. 56-75, 1980.

EL-TAMAWY, M. S. *et al.* Aerobic exercises enhance cognitive functions and brain derived neurotrophic factor in ischemic stroke patients. **Neuro Rehabilitation**, Cairo, v. 34, n. 1, p. 209-213, Jan. 2014.

FERDOUSY, R. *et al.* Electrooculographic and Electromyographic Artifacts Removal from EEG. In: INTERNATIONAL CONFERENCE ON CHEMICAL, BIOLOGICAL AND ENVIRONMENTAL ENGINEERING (ICBEE), 2., 2010, Dhaka, Bangladesh. **Proceedings...** New York: IEEE, 2010. p. 163-167.

FERNANDES, A. M. DA R.; ZAPELINI, C.; COMUNELLO, E. Rede Bayesiana para Auxiliar na Medição da Intensidade da Dor. In: WORKSHOP DE INFORMÁTICA MÉDICA, 13., 2013 Maceió, Alagoas. **Anais...** Porto Alegre: Editora da SBC, 2013. p. 1-10.

FIORUCCI, E. *et al.* Development of an ad hoc measurement station for the human surface electromyography in rest position. In: INTERNATIONAL WORKSHOP ON MEDICAL MEASUREMENTS AND APPLICATIONS, 2009, Cetraro. **Proceedings...** New York: IEEE, 2009. p. 262-267.

FRASER, G. D. *et al.* Automated Biosignal Quality Analysis for Electromyography Using a One-Class Support Vector Machine. **IEEE Transactions on Instrumentation and Measurement**, Ottawa, Canada, v. 63, n. 12, p. 2919-30, Dec. 2014.

FREITAS, D. *et al.* Reconhecimento de contexto em ambientes inteligentes com auxílio de redes Bayesianas. In: ESCOLA REGIONAL DE ALTO DESEMPENHO (ERAD), 12., 2012, Erechim. **Anais...** Erechim RS: Sociedade Brasileira de Computação, 2012. p. 213-216.

FRIEDERICI, A. D. Pathways to language: fiber tracts in the human brain. **Trends in cognitivesciences**, London, v. 13, n. 4, p. 175-181, Apr. 2009.

GALEGO, J. S.; CASAS, O. V.; BALBINOT, A. Análise experimental na captação sincronizada de Eletromiografia de Superfície e Eletroencefalografia para o estabelecimento de padrões da fala. In: CONGRESSO BRASILEIRO DE INTELIGÊNCIA

COMPUTACIONAL (CBIC), 12., 2015, Curitiba. **Anais...** Curitiba: Sociedade Brasileira de Inteligência Computacional, 2015, p. 1-4.

GALLEGRO DUQUE, C. J. *et al.* Discrete wavelet transform and k-nn classification in EMG signals for diagnosis of neuromuscular disorders. In: SYMPOSIUM ON IMAGE, SIGNAL PROCESSING AND ARTIFICIAL VISION (STSIVA), 19., 2014. **Proceedings...**New York: IEEE, 2014. p. 1-5.

GOKGOZ, E.; SUBASI, A. Comparison of decision tree algorithms for EMG signal classification using DWT. **Biomedical Signal Processing and Control**, Oxford, v. 18, p. 138-144, Apr. 2015.

GOLDSTEIN, E. *et al.* Design and implementation of a hands-free electrolarynx device controlled by neck strap muscle electromyographic activity. **IEEE Transactions on Biomedical Engineering**, Cambridge, v. 51, n. 2, p. 325-332. Feb. 2004.

GRIMMES, S.; MARTINSEN, Ø. G. **Bioimpedance and bioelectricity basics. Clinical applications.** London: Great Britain, 2008.

GRUEBLER, A.; SUZUKI, K. Design of a wearable device for reading positive expressions from facial EMG signals. **IEEE Transactions on Affective Computing**, [s. l.], v. 5, n. 3, p. 227-237. July 2014.

GÜNES, S. *et al.* Sleep spindles recognition system based on time and frequency domain features. **Expert Systems with Applications**, New York, v. 38, n. 3, p. 2455–2461, Mar. 2011.

GUYTON, C. A.; HALL, E. J. **Tratadode Fisiología Médica.** 11.ed. Jackson: Elsevier Editora, 2006.

HAMED, M.; REZAZADEH, I. M.; FIROOZABADI, M. Facial gesture recognition using two-channel bio-sensors configuration and fuzzy classifier: A pilot study. In: INTERNATIONAL CONFERENCE ON ELECTRICAL, CONTROL AND COMPUTER ENGINEERING (INECCE), 2011, Pahang. **Proceedings...**New York: IEEE, 2009.p. 338-343.

HAMEL, L. H. **Knowledge discovery with support vector machines.** New York: John Wiley & Sons. 2011.

HUSSAIN, A. *et al.* **Brain Inspired Cognitive Systems 2008.** New York: Springer Science & Business Media, 2009.

IBANEZ, J. *et al.* Upper-limb muscular electrical stimulation driven by EEG-based detections of the intentions to move: A proposed intervention for patients with stroke. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC), 36., 2014, Chicago. **Proceedings...**New York: IEEE, 2014, p. 1646-1649.

JIRAKITTAYAKOM, N.; WONGSAWAT, Y. An EMG Instrument Designed for Bruxism Detection on Masseter Muscle. In: BIOMEDICAL ENGINEERING INTERNATIONAL CONFERENCE (BMEiCON), 7., 2014, Fukuoka, Japan. **Proceedings...**New York: IEEE, 2014, p. 184-188.

JÜRGENS, U. Neural pathways underlying vocal control. **Neuroscience & Biobehavioral Reviews**, Göttingen, v. 26, n. 2, p. 235-58. Mar. 2002.

KALANI, H.; MOGHIMI, S.; AKBARZADEH, A. SEMG-based prediction of masticatory kinematics in rhythmic clenching movements. **Biomedical Signal Processing and Control**, New York, v. 20, p. 24-34, July 2015.

KAUR, G.; ARORA, A. S.; JAIN, V. K. Comparison of the techniques used for segmentation of EMG signals. In: INTERNATIONAL CONFERENCE ON MATHEMATICAL AND COMPUTATIONAL METHODS IN SCIENCE AND ENGINEERING (MACMESE), 2009, Wisconsin. **Proceedings...**New York: IEEE, 2009, p. 124-129.

KHUSHABA, R. N.; SHI, L.; KODAGODA, S. Time-Dependent Spectral Features for Limb Position Invariant Myoelectric Pattern Recognition. In: INTERNATIONAL SYMPOSIUM ON COMMUNICATIONS AND INFORMATION TECHNOLOGIES (ISCIT), 2012, Sydney. **Proceedings...** New York: IEEE, 2012, p. 1015-1020.

KILGORE, T.; SCOTT TOWNSEND, O. I.; ABLES, A. Z. Update on Stroke Management. **American Osteopathic Board of Family Physician**, California, v. 6, n. 1, Nov. 2014.

KOLES, Z.J. The quantitative extraction and topographic mapping of the abnormal components in the clinical EEG. **Electroencephalography and Clinical Neurophysiology**, Salt Lake City, v. 79, p. 440-447, Dec. 1991.

KOYAS, E. *et al.* Detection of intention level in response to task difficulty from EEG signals. In: INTERNATIONAL WORKSHOP ON MACHINE LEARNING FOR SIGNAL PROCESSING, 2013, Southampton. **Proceedings...** New York: IEEE, 2013 p. 1-6.

KÜBLER, A. *et al.* A User Centred Approach for Bringing BCI Controlled Applications to End-Users. In: FAZEL-REZAI, R. BRAIN-COMPUTER INTERFACE SYSTEMS – RECENT PROGRESS AND FUTURE PROSPECTS, 2013, North Dakota. **Proceedings...** New York: IEEE, 2013, p. 2-12.

KUMAR, T. M. Modeling of neural networks based on transient response analysis of EEG signals from Broca's area. In: INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING AND COMMUNICATION ENGINEERING SYSTEMS (SPACES), 2015, Vijayawada, India. **Proceedings...** New York: IEEE, 2015, p. 72-76.

KUMAR, T. S.; RAKESH, P. B. 3D reconstruction of facial structures from 2D images for cosmetic surgery. In: INTERNATIONAL CONFERENCE ON RECENT TRENDS IN INFORMATION TECHNOLOGY (ICRTIT), 2011, Chennai, India. **Proceedings...** New York: IEEE, 2011, p. 743-748.

LEMM, S.; MÜLLER, K. R.; CURIO, G.A generalized framework for quantifying the dynamics of EEG event-related desynchronization. **PLoS Computational Biology**, Minnesota, v. 5, n. 8, p. 1-10, Aug. 2009.

LEE, D. T.; YAMAMOTO, A. Wavelet analysis: theory and applications. **Hewlett Packard Journal**, Boston, v. 45, p. 44-52, Dec. 1994.

LEE, F. *et al.* A Comparative Analysis of Multi-Class EEG Classification for Brain Computer Interface. In: COMPUTER VISION WINTER WORKSHOP, 10., 2004, Graz, Austria. **Proceedings...** Prague: Czech Society for Cybernetics and Informatics, 2004, p. 743-748.

LIN, C. Y.; CHENG, L. C.; SHEN, L. C. Oral mechanism design on face robot for lip-synchronized speech. In: INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION (ICRA), 2013, Karlsruhe, Germany. **Proceedings...**New York: IEEE, 2013, p. 4316-4321.

LOIZIDES, A.; HIMONA, S. L.; CHRYSANTHOU, Y. Visualisation Tool for Representing Synthetic Facial Emotional Expressions. In: VISUALISATION, INTERNATIONAL CONFERENCE, 2008, London. **Proceedings...**New York: IEEE, 2008, p. 135-140.

LUCAS, M. F. *et al.* Multi-channel surface EMG classification using support vector machines and signal-based wavelet optimization. **Biomedical Signal Processing and Control**, New York, v. 3, n. 2, p. 169-174, April 2008.

LYU, M.; XIONG, C.; ZHANG, Q. Electromyography (EMG)-Based Chinese Voice Command Recognition. In: INTERNATIONAL CONFERENCE ON INFORMATION AND AUTOMATION (ICIA), 2014, Hailar, China. **Proceedings...**New York: IEEE, 2014, p. 926-931.

MA, W. *et al.* Using EEG artifacts for BCI applications. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 2014, Beijing. **Proceedings...**New York: IEEE, 2014, p. 3628-3635.

MAHAPHONCHAIKUL, K. *et al.* EMG signal feature extraction based on wavelet transform. In: INTERNATIONAL CONFERENCE ON ELECTRICAL ENGINEERING/ELECTRONICS COMPUTER TELECOMMUNICATIONS AND INFORMATION TECHNOLOGY (ECTI-CON), 7., 2010, Chiang Mai. **Proceedings...**New York: IEEE, 2010, p. 327-331.

MACHADO, J.; BALBINOT, A. Executed Movement Using EEG Signals through a Naive Bayes Classifier. **Micromachines**, Switzerland, v. 5, n. 4, p. 1082-1105. Nov. 2014.

MACHADO, J.; BALBINOT, A.; SCHUCK, A. A study of the Naive Bayes classifier for analyzing imaginary movement EEG signals using the Periodogram as spectral estimator. In: ISSNIP BIOSIGNALS AND BIROBOTICS CONFERENCE (BRC), 2013, Rio de Janeiro. **Proceedings...** New York: IEEE, 2013, p. 1-4.

MARCO, F. M de.; RODRIGUES, K. A.; SAMPAIO, T. O. M. Neurociência e Linguagem: desafios e superações interdisciplinares. In: SCIENTIARUM HISTORIA, 4., 2011, Rio de Janeiro. **Anais...**Rio de Janeiro: CAPES/CnPq, 2011, p. 1-14.

MCLOUGHLIN, I. V. Super-audible voice activity detection. **IEEE/ACM Transactions on Audio, Speech, and Language Processing (TASLP)**, New York, v. 22, n. 9, p. 1424-1433, Sept. 2014.

MCMICKEN, B. *et al.* Cineradiographic examination of articulatory movement of pseudo-tongue, hyoid, and mandible in congenital aglossia. **Communication Disorders Quarterly**, Kansas, v. 36, n. 1, p. 3-11, Nov. 2014.

MCNEESE, W. *et al.* Measuring Skewness: A Forgotten Statistic? **Journal of Statistics Education**, Colorado, v. 19, n. 2, p. 1-18, 2011.

MILLER, N.; LOWIT, A (eds). Motor Speech Disorders: A Cross-language Perspective. **Multilingual Matters**, Florida, v. 12, n. 1, p. 150- 296, 2014.

MINNIER, J, *et al.* Risk classification with an adaptive naive bayes kernel machine model. **Journal of the American Statistical Association**, New York, v. 110, n. 509, p. 393-404. Aug. 2015.

MOHAMAD, A. J. *et al.* Development of EMG measurement system to control mobile robot using frontalis and zygomaticus major muscles. In: EMBS CONFERENCE ON BIOMEDICAL ENGINEERING AND SCIENCES (IECBES), 2012, Langkawi. **Proceedings...**New York: IEEE, 2012, p. 1009-1013.

MONTGOMERY, D. C. **Design and Analysis of Experiments**. 8th ed. New York: John Wiley & Sons, 2013.

MOON, I. *et al.* Wearable EMG-Based HCI for Electric-Powered Wheelchair Users with Motor Disabilities. In: INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION (ICRA), 2005, Barcelona. **Proceedings...**New York: IEEE, 2005, p. 2649-2654.

MOUALEU, A.; GALLAGHER, W.; UEDA, J. Support Vector Machine Classification of Muscle Cocontraction to Improve Physical Human-Robot Interaction. In: INTERNATIONAL CONFERENCE ON INTELLIGENT ROBOTS AND SYSTEMS (IROS), 2014, Chicago. **Proceedings...**New York: IEEE, 2014, p. 2154-2159.

MÜLLER-GERKING, J.; PFURTSCHELLER, G.; FLYVBJERG, H. Designing optimal spatial filters for single-trial EEG classificaton in a movement task. **Clinical Neurophysiology**, Netherlands, v. 110, n. 5, p. 787-798, May 1999.

MULLER-PUTZ, G. R. *et al.* Comparison of DFT and lock-in amplifier features and search for optimal electrode positions in SSVEP-based BCI. **Journal of Neuroscience Methods**, Graz, Austria, v. 168, n. 1, p. 174-81, Feb. 2008.

MURDOCH, B. E. **Desenvolvimento da fala e distúrbios da linguagem: uma abordagem neuroanatômica e neurofisiológica**. Rio de Janeiro: Revinter, 1997.

MURPHY, K. P. **Machine learning: a probabilistic perspective**: Adaptive Computation and Machine Learning series. 1st ed. Cambridge: MIT Press, 2012.

NAM, C. S. *et al.* Movement imagery-related lateralization of event-related (de) synchronization (ERD/ERS): motor-imagery duration effects. **Clinical Neurophysiology**, Netherlands, v. 122, n. 3, p. 567-577, March 2011.

NAM, Y. *et al.* GOM-Face: GKP, EOG, and EMG-Based Multimodal Interface with Application to Humanoid Robot Control. **IEEE Transactions on Biomedical Engineering**, Pohang, Korea, v. 61, n. 2, p. 453-462, Feb. 2014.

NEUPER, C.; WÖRTZ, M.; PFURTSCHELLER, G. ERD/ERS patterns reflecting sensorimotor activation and deactivation. **Progress in brain research**, New Haven, Connecticut. v. 159, n.1, p. 211-222. Dec. 2006.

NG, H. P. *et al.* A study on shape determinative slices for the masseter muscle. In Engineering in Medicine and Biology Society. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE, 29., 2007, Lyon. **Proceedings...**New York: IEEE, 2007, p. 5585-5588.

NG, S.-C.; RAVEENDRAN, P. Enhanced μ Rhythm Extraction Using Blind Source Separation and Wavelet Transform. **IEEE Transactions on Biomedical Engineering**, Lypon, v. 56, n. 8, p. 2024-34, May 2009.

OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R. **Discrete-time signal processing**, [s. l.], v 2. n. 2, p. 1-820, 1989.

PFURTSCHELLER, G. Functional brain imaging based on ERD/ERS. **Vision research**, London, v. 41, n. 10, p. 1257-1260, May 2001.

PFURTSCHELLER, G. *et al.* Mu rhythm (de) synchronization and EEG single-trial classification of different motor imagery tasks. **NeuroImage**, New York, v. 31, n. 1, p. 153-159, May 2006.

PFURTSCHELLER, G. *et al.* 'Thought' – control of functional electrical stimulation to restore hand grasp in a patient with tetraplegia. **Neuroscience Letters**, Connecticut, v. 351, n. 1, p. 33–36. May 2003.

PHINYOMARK, A. *et al.* Evaluation of EMG feature extraction for hand movement recognition based on Euclidean distance and standard deviation. In: INTERNATIONAL CONFERENCE ON ELECTRICAL ENGINEERING/ELECTRONICS COMPUTER TELECOMMUNICATIONS AND INFORMATION TECHNOLOGY (ECTI-CON), 2010, Chiang Mai, Thailand. **Proceedings...**New York: IEEE, 2010, p. 856-860.

PHINYOMARK, A.; LIMSAKUL, C.; PHUKPATTARANONT, P. A novel feature extraction for robust EMG pattern recognition. **Journal of Computing**, Benin, v. 1, n. 1, p. 71-80, Dec. 2009.

PHINYOMARK, A.; LIMSAKUL, C.; PHUKPATTARANONT, P. Application of wavelet analysis in EMG feature extraction for pattern classification. **Measurement Science Review**, Berlin, v. 11, n. 2, p. 45-52. Jan. 2011.

PLENTZ, R. D. **Redes Bayesianas para Análise de Comportamento Aplicadas a Telefonia Celular**. 2003. 57 f. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Santa Catarina, Santa Catarina. 2003.

QIU, S.; YI, W.; QI, H. 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**, New York, v. 24, n. 2, p. 283-289, Sept. 2015.

RABINER, L.; JUANG, B. H. **Fundamentals of speech recognition**. New Jersey: Prentice-Hall, 1993.

RAMOSER, H.; MÜLLER-GERKING, J.; PFURTSCHELLER, G. Optimal spatial filtering of single trial EEG during imagined hand movement. **IEEE Transactions on Rehabilitation Engineering**, New York, v. 8, n. 4, p. 441-446, Dec. 2000.

RIBEIRO, A. F.; ORTIZ, K. Z. Populational profile of dysarthric patients assisted in a tertiary hospital. **Revistada Sociedade Brasileira de Fonoaudiologia**, Salvador, v. 14, n. 3, p. 446-453, maio 2009.

RUSSELL, J. A.; BACHOROWSKI, J. A.; FERNÁNDEZ-DOLS, J. M. Facial and vocal expressions of emotion. **Annual review of psychology**, California, v. 54, n. 1, p. 329-349, Feb. 2003.

SANEI, S.; CHAMBERS, J. A. **EEG signal processing**. New York: John Wiley & Sons, 2013.

SANTOS, P.; PETRIU, E. M. Facial expression cloning with fuzzy set clustering. In: INTERNATIONAL CONFERENCE ON COMPUTATIONAL INTELLIGENCE AND VIRTUAL ENVIRONMENTS FOR MEASUREMENT SYSTEMS AND APPLICATIONS (CIVEMSA), 2013, Milan. **Proceedings...** New York: IEEE, 2013, p. 19-24.

SCLIAR-CABRAL L. **Processamento da leitura: recentes avanços das neurociências**. Linguagem e Cognição: relações interdisciplinares. Porto Alegre: EDIPUCRS, 2009.

SEIKEL, J.; KING, D.; DRUMRIGHT, D. Anatomy & physiology for speech, language, and hearing. **Cengage Learning**, Idaho, v. 1, n.5, p. 361-369, 2015.

SELLARS, C.; HUGHES, T.; LANGHORNE, P. Terapia del habla y del lenguaje para la disartria por daño cerebral no progresivo. **La Biblioteca Cochrane Plus**, Barcelona, v. 1, n.4, p. 1-10, 2006.

SHELLIKERI, S. *et al.* Electrical impedance myography (EIM) in the evaluation of the tongue musculature in amyotrophic lateral sclerosis (ALS). **Muscle & nerve**, New York, v. 52, n. 4, p. 584-591, Oct. 2015.

SOLHJOO, S.; NASRABADI, A.M.; GOLPAYEGANI, M.R.H. Classification of chaotic signals using hmm classifiers: EEG-based mental task classification. In: EUROPEAN SIGNAL PROCESSING CONFERENCE, 13., 2005, Tehran, Iran. **Proceedings...**New York: IEEE, 2005, p. 1-4.

SONG, Y. *et al.* A synchronous and multi-domain feature extraction method of EEG and sEMG in power-assist rehabilitation robot. In: INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION (ICRA), 2014, Hong Kong. **Proceedings...** New York: IEEE, 2014, p. 4940-4945.

STEFANI, F. M. **Estudo eletromiográfico do padrão de contração muscular da face de adultos**. 2008. 105 f. Tese (Doutorado em Ciências) – Faculdade de Medicina, Universidade de São Paulo, São Paulo. 2008.

STEPP, C. E. *et al.* Neck and face surface electromyography for prosthetic voice control after total laryngectomy. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 17, n.2, p. 146-155, Apr. 2009.

STOCK, V. **Classificação de Movimentos Imaginários Através de Redes Bayesianas em Sistema Baseado em Touca EMOTIV**. 2015. 87 f. Trabalho de Conclusão de Curso. (Graduação em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015.

STOICA, P.; MOSES, R. **Spectral Analysis of Signals**. New Jersey: Prentice Hall, 2005.

SUBASI, A. A decision support system for diagnosis of neuromuscular disorders using DWT and evolutionary support vector machines. **Signal, Image and Video Processing**, [s. l.], v. 9, n. 2, p. 399-408, Feb. 2015.

TAKAI, M. Measurement of Motion Quantity from human movement and detection of the sign language word. In: INTERNATIONAL CONFERENCE ON ADVANCED MECHATRONIC SYSTEMS (ICAMEchS), 2012, Tokyo. **Proceedings...**New York: IEEE, 2012, p. 298-303.

TAKSANDE, S.; PADOLE, D. V. Brain Machine Interface System for Person with Quadriplegia Disease. **International Journal of Computer Applications Technology and Research**, Cambridge, v. 3, n. 6, p. 339-344. 2014.

TEPLAN, M. Fundamentals of EEG measurement. **Measurement science review**, Berlin, v. 2, n. 2, p. 1-11, 2002.

THULKAR, D.; BHASKARWAR, T.; HAMDE, S. T. Facial electromyography for characterization of emotions using LabVIEW. In: INTERNATIONAL CONFERENCE ON INDUSTRIAL INSTRUMENTATION AND CONTROL (ICIC), 2015, Maharashtra, India. **Proceedings...** New York: IEEE, 2015, p. 683-686.

TORTORA, G. J.; GRABOWSKI, S. R. **O Sistema Muscular. Corpo Humano: Fundamentos de Anatomia e Fisiologia**. 4. ed. Porto Alegre: Artmed, 2003.

TOWNSEND, A. S.; KILGORE, T.; ABLES, A. Z. **Update on stroke management**. Osteopathic Family Physician. Virginia, 2013. Disponível em: <<http://www.vcom.edu/AR/2015/02%20Research/files/assets/common/downloads/02%20Research.pdf>>. Acesso: 23/05/2015.

VASCONCELOS, B. C. E. *et al.* Meios de Diagnóstico das Desordens Temporomandibulares. **Revista de Cirurgia e Traumatologia Buco-Maxilo-Facial**, Pernambuco, v.1, n. 2, p. 49-57, jan. 2002.

VERNON, S.; JOSHI, S. S. Multidimensional control using a mobile-phone based brain-muscle-computer interface. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, EMBC, 33., 2011, Boston. **Proceedings...**New York: IEEE, 2011, p. 5188-5194.

WANG, L.; WANG, X.; XU, J. Lip detection and tracking using variance based haar-like features and kalman filter. In: INTERNATIONAL CONFERENCE ON FRONTIER OF COMPUTER SCIENCE AND TECHNOLOGY (FCST), 5., 2010, Japan. **Proceedings...**New York: IEEE, 2010, p. 608-612.

WEI, L.; HU, H. A multi-modal human machine interface for controlling an intelligent wheelchair using face movements. In: INTERNATIONAL CONFERENCE ON ROBOTICS AND BIOMIMETICS (ROBIO), 2011, Zhuhai, China. **Proceedings...**New York: IEEE, 2011, p. 2850-2855.

WEI, L.; HU H. EMG and Visual based HMI for hands-free control of an intelligent wheelchair. In: WORLD CONGRESS ON INTELLIGENT CONTROL AND AUTOMATION, 8., 2010, Jinan, China. **Proceedings...**New York: IEEE, 2010, p. 1027-32.

WILLIAMS, G. *et al.* Facilitating communication and computer use with EEG devices for non-vocal quadriplegics. In: INTERNATIONAL CONFERENCE ON INFORMATION AND AUTOMATION FOR SUSTAINABILITY (ICIAfS), 7., 2014, Colombo, Sri Lanka. **Proceedings...**New York: IEEE, 2014, p. 1-5.

WILLIAMS, M. R.; KIRSCH, R. F. Evaluation of head orientation and neck muscle EMG signals as command inputs to a human-computer interface for individuals with high tetraplegia. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, New York, v. 16, n. 5, p. 485-496, Oct. 2008.

WILLIAMS, M. R.; KIRSCH, R. F. Evaluation of head orientation and neck muscle EMG signals as three-dimensional command sources. **Journal of neuroengineering and rehabilitation**, New York, v. 12, n. 1, p. 1-16, Mar. 2015.

WU, J.; LV, G.; FAN, Y. A research on mouth expression animation based on compliant spatial mechanisms model. In: INTERNATIONAL CONFERENCE ON DIGITAL SIGNAL

PROCESSING (DSP), 19., 2014, Hong Kong. **Proceedings...**New York: IEEE, 2014, p. 244-249.

WU, T. F.; HUNG, A.; MITHRARATNE, K. Generating facial expressions using an anatomically accurate biomechanical model. **IEEE Transactions on Visualization and Computer Graphics**, New York, v. 20, n. 11, p. 1519-1529, Nov. 2014.

WU, T. F. *et al.* Estimating muscle activation patterns using a surrogate model of facial biomechanics. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC), 35., 2013, Osaka. **Proceedings...**New York: IEEE, 2013, p. 7172-7175.

YANG, Y.; YEO, C. Conceptual Network Model from Sensory Neurons to Astrocytes of the Human Nervous System. **IEEE Transactions on Biomedical Engineering**, New York, v. 62, n. 7, p. 1843-1852, July 2015.

YANO, J. *et al.* Effect of visual biofeedback of posterior tongue movement on articulation rehabilitation in dysarthria patients. **Journal of oral rehabilitation**, New York, v. 42, n. 8, p. 571-579, Aug. 2015.

YORKSTON, K. M. Treatment Efficacy Dysarthria. **Journal of Speech, Language, and Hearing Research**, New York, v. 39, n. 5, p. 46-57, October 1996.

YU, H.; LIU, H. Regression-based facial expression optimization. **IEEE Transactions on Human-Machine Systems**, New York, v. 44, n. 3, p. 386-394, June 2014.

YU, S.; LEE, T.; NG, M. L. Surface electromyographic activity of non-laryngeal neck muscles in Cantonese tone production. In: INTERNATIONAL SYMPOSIUM ON CHINESE SPOKEN LANGUAGE PROCESSING (ISCSLP), 9., 2014, China. **Proceedings...**New York: IEEE, 2014, p. 304-307.

ZHANG, X.; WANG, Y.; HAN, R. P. Wavelet transform theory and its application in EMG signal processing. In: INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS AND KNOWLEDGE DISCOVERY (FSKD), 20., 2010, China. **Proceedings...**New York: IEEE, 2010, p. 2234-2238.

ZHAO, H. *et al.* Brain-Computer Interface Design Based on Slow Cortical Potentials using Matlab/Simulink. In: INTERNATIONAL CONFERENCE ON MECHATRONICS AND AUTOMATION, 2009, Changchun, China. **Proceedings...**New York: IEEE, 2009, p. 1044-1048.

ANEXOS

ANEXO A - PRINCIPAIS MÚSCULOS SUPERFICIAIS DA BOCA QUE INFLUENCIAM NA FALA.

Tabela 10. Características dos principais Músculos Superficiais da boca que influenciam na fala (adaptado de TORTORA & GRABOWSKI, 2003).

Músculos	Origem	Função
Zigomático menor	Osso zigomático	Levanta o lábio superior.
Zigomático maior	Osso zigomático	Levanta e retrai o ângulo da boca (alegria, sorriso)
Risório	Fáscia do Masseter	Retrai o ângulo da boca lateralmente (riso forçado).
Abaixador do ângulo da boca	Base da mandíbula (região molar ao tubérculo mentoniano)	Abaixa o ângulo da boca (tristeza)
Abaixador do lábio inferior	Base da mandíbula, acima da origem do Depressor do ângulo da boca	Abaixa o lábio inferior
Levantador do lábio superior	Margem infra-orbital	Levanta o lábio superior
Levantador do lábio superior e da asa do nariz.	Processo frontal da maxila	Levanta o lábio superior e a asa do nariz (dilata a narina)
Levantador do ângulo da boca	Fossa canina da maxila	Levanta o ângulo da boca
Orbicular da boca	Quase todo cutâneo; fôveas incisivas da maxila e mandíbula	Comprime os lábios contra os dentes; protusão para a frente dos lábios
Músculo Mental	Fossa incisiva da mandíbula	Eleva e projeta para fora o lábio superior e enrugam a pele do queixo
Bucinator	Maxila e da mandíbula na região molar; ligamento pterigomandibular	Forma as bochechas (as comprime) e atua de forma indireta na mastigação

ANEXO B - DOMÍNIO DISARTRIA DA ESCALA DE AVC.

**Adaptado de NATIONAL INSTITUTE OF HEALTH STROKE SCALE (NIH), 2003;
MANUAL DE ROTINAS PARA ATENÇÃO AO AVC, 2013.**

O rastreamento da disartia será feito através do domínio *Disartria*, da Escala de AVC, onde o paciente deverá ter pontuação 1 ou 2, conforme a tabela.

Tabela 11. Escala de AVC do Domínio Disartria.

Instrução	Definição da escala
<p>Disartria</p> <p>Se acredita que o paciente é normal, uma avaliação mais adequada é obtida, pedindo-se ao paciente que leia ou repita palavras da lista anexa. Se o paciente tem afasia grave, a clareza da articulação da fala espontânea pode ser graduada. Somente se o paciente estiver intubado ou tiver outras barreiras físicas a produção da fala, este item deverá ser considerado não testável (NT). Não diga ao paciente por que ele está sendo testado.</p>	<p>0 = Normal</p> <p>1 = Disartria leve a moderada; paciente arrasta pelo menos algumas palavras, e na pior das hipóteses, pode ser entendido, com alguma dificuldade.</p> <p>2 = Disartria grave; fala do paciente é tão empastada que chega a ser ininteligível, na ausência de disfasia ou com disfasia desproporcional, ou é mudo/anártrico.</p> <p>NT = Intubado ou outra barreira física; explique_____</p>

ANEXO C - TERMO DE COMPROMISSO LIVRE E ESCLARECIDO.

TERMO DE COMPROMISSO LIVRE E ESCLARECIDO – TCLE

Você está convidado a participar da pesquisa “AQUISIÇÃO E PROCESSAMENTO DE BIOSINAIS DE ELETROMIOGRAFIA DE SUPERFÍCIE E ELETROENCEFALOGRAFIA PARA CARACTERIZAÇÃO DE COMANDOS VERBAIS OU INTENÇÃO DE FALA MEDIANTE SEU PROCESSAMENTO MATEMÁTICO”.

O presente trabalho visa o estudo e caracterização dos sinais de Eletroencefalografia (EEG) e de Eletromiografia de Superfície (sEMG), para possibilitar o desenvolvimento de sistemas não invasivos para pacientes portadores de seqüelas de AVC. Serão realizados testes de maneira não invasiva, para avaliar comportamento eletromiográfico dos músculos do rosto que estão relacionados ao processo da fala. Será captado no mesmo tempo, o sinal de eletroencefalografia. A posterior classificação de ambos os sinais permitirá o desenvolvimento de sistemas autônomos para pacientes que apresentem disartria após AVC.

Caso você concorde em participar do estudo, a sua participação consistirá em realizar testes, através da colocação de eletrodos de superfície (não invasivos), nos principais músculos do rosto, para captação do sinal de sEMG. Será igualmente colocada uma touca na cabeça do sujeito para a captação do sinal de EEG. Além da colocação de um pequeno microfone perto da boca do sujeito para gravar o som. O sujeito escutará uma gravação onde será explicado o teste antes de começar a captar os sinais. O teste é dividido em duas partes: na primeira parte o sujeito tem que pensar em realizar o movimento segundo o padrão, com quatro repetições para cada padrão, em um intervalo de 10 segundos entre cada repetição. Este ciclo é

repetido três vezes. Serão armazenados os arquivos das aquisições no computador. O tempo para esta primeira etapa do teste é de 20 minutos para cada paciente. Na segunda parte do teste, o sujeito além de pensar no movimento tentará repetir em alta voz o padrão, com quatro repetições para cada padrão e igualmente com um intervalo de 10 segundos entre cada repetição. Este ciclo é repetido três vezes. Serão armazenados os arquivos das aquisições no computador. O tempo para esta segunda etapa do teste é de 20 minutos para cada paciente. Dando um tempo total de duração dos testes de 40 minutos para cada sujeito, mas 10 minutos de preparação do sujeito para a realização do teste. Estabelecendo um total de 50 minutos do tempo de duração dos testes.

O benefício desse estudo para o paciente é: o conhecimento do comportamento dos sinais de EEG e sEMG no processo da fala frente aos padrões estabelecidos. O estudo contribuirá à criação da base de dados para o desenvolvimento futuro de sistemas autônomos comandados pela fala e/ou pensamento.

Os possíveis desconfortos quanto à pesquisa são considerados mínimos, envolvendo a solicitação para falar os padrões estabelecidos que possam ser cansativos para cada paciente. Caso isso ocorra, serão tomadas as medidas necessárias de conforto e descanso do paciente.

A participação é totalmente voluntária, a decisão de não participação não afetará o seu atendimento no hospital, sendo possível a desistência da participação desse estudo a qualquer momento da pesquisa.

Não é previsto nenhum tipo de pagamento pela participação no estudo e o participante não terá nenhum custo com respeito aos procedimentos envolvidos.

Os pesquisadores se comprometem em manter a confidencialidade dos dados de identificação pessoal dos participantes e os resultados serão divulgados de maneira agrupada, sem identificação dos indivíduos que participaram do estudo.

As dúvidas poderão ser esclarecidas antes e durante o curso da pesquisa, através de contato com o pesquisador responsável, Professor Alexandre Simões, vinculado ao Departamento de Fisioterapia no telefone (51) 9136-5947.

O Comitê de Ética em Pesquisa também poderá ser contatado para esclarecimento de dúvidas no 2º Andar do HCPA, sala 2227, ou através do telefone (51) 3259-7640, das 8h às 17h, de segunda à sexta.

Ao assinar abaixo, você confirma que leu as afirmações contidas nesse termo de consentimento, que foram explicados os procedimentos do estudo, que teve a oportunidade de fazer perguntas, que está satisfeito com as informações fornecidas e que decidiu participar voluntariamente desse estudo. O documento será elaborado em duas vias, sendo uma delas entregue ao participante e outra mantida pelo grupo de pesquisadores.

Nome do Participante _____ Assinatura _____

Nome do Responsável _____ Assinatura _____

Nome do Pesquisador _____ Assinatura _____

Nome do Pesquisador _____ Assinatura _____

Local e Data: _____

ANEXO D - SINAIS DE SEMG OBTIDAS PARA OS QUATRO COMANDOS VERBAIS

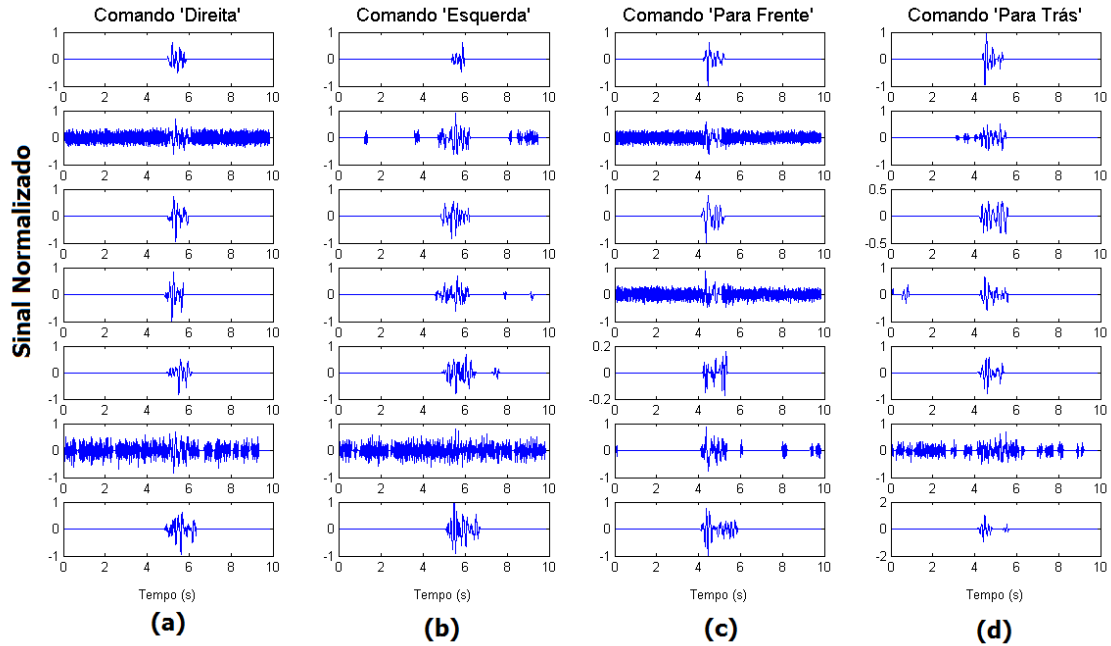


Figura 62 Curvas do sinal de sEMG do Dataset 2 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

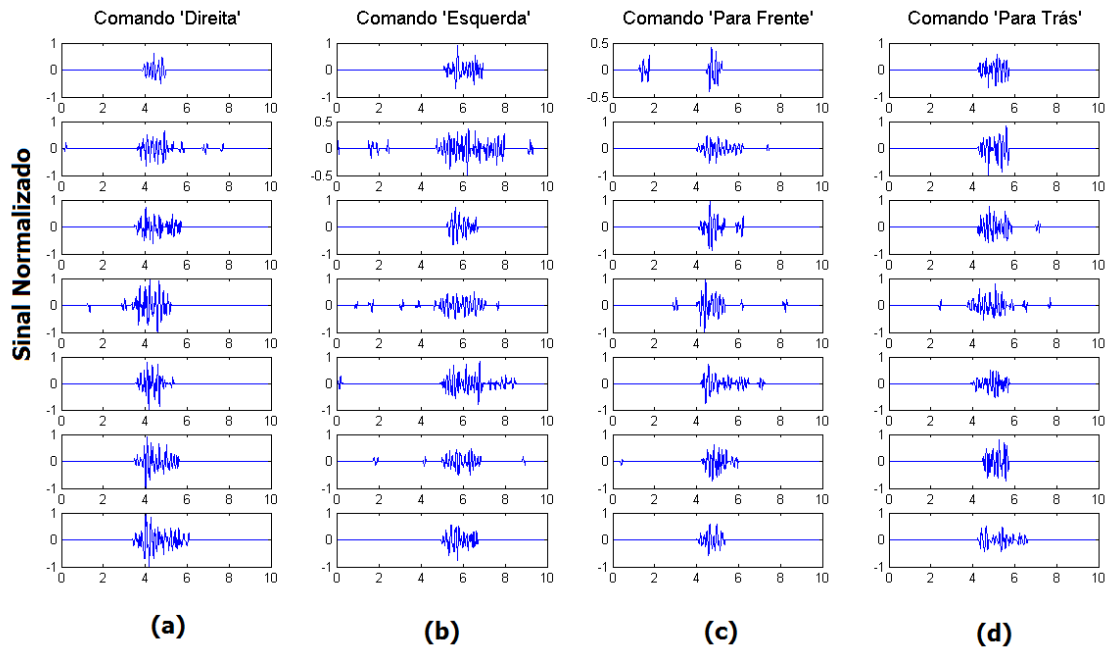


Figura 63 Curvas do sinal de sEMG do Dataset 3 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

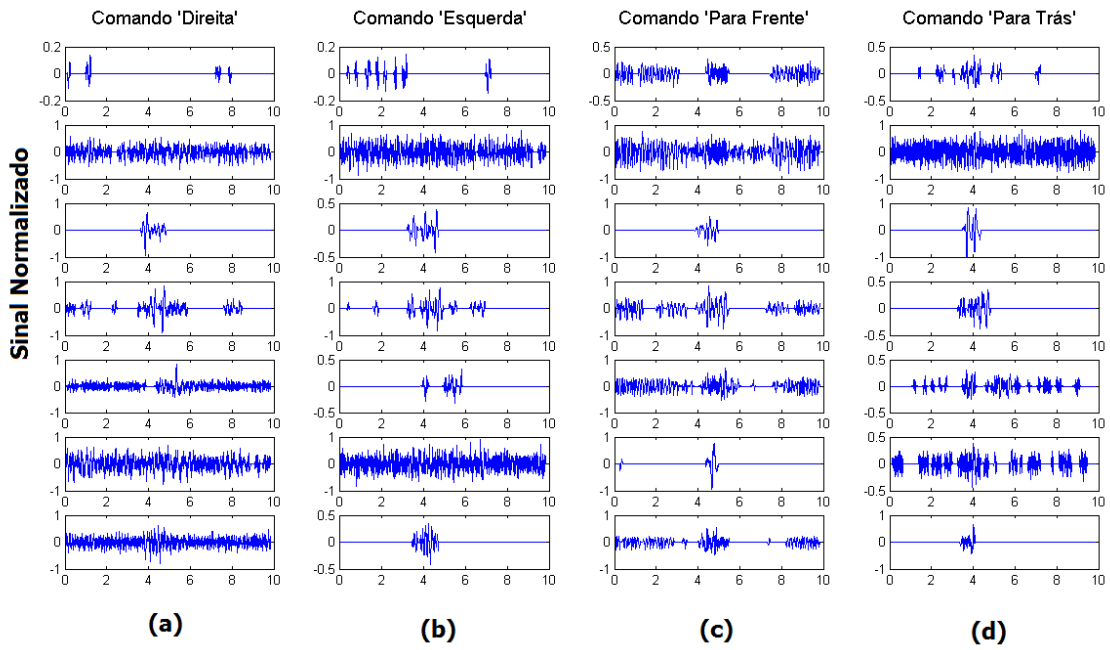


Figura 64 Curvas do sinal de sEMG do Dataset 4 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

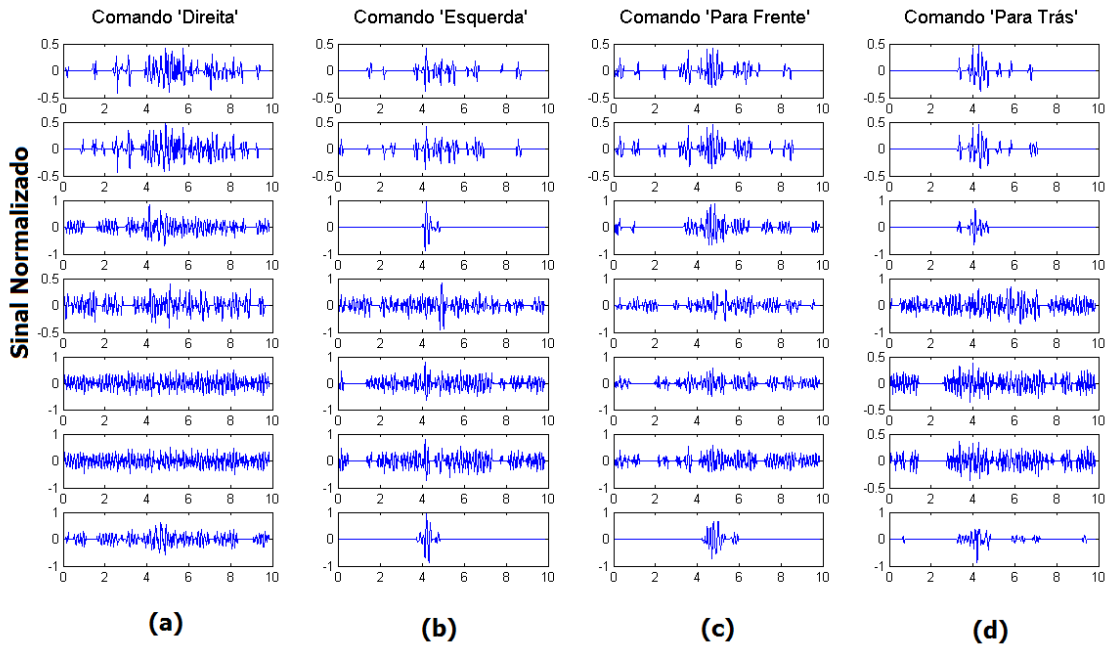


Figura 65 Curvas do sinal de sEMG do Dataset 5 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

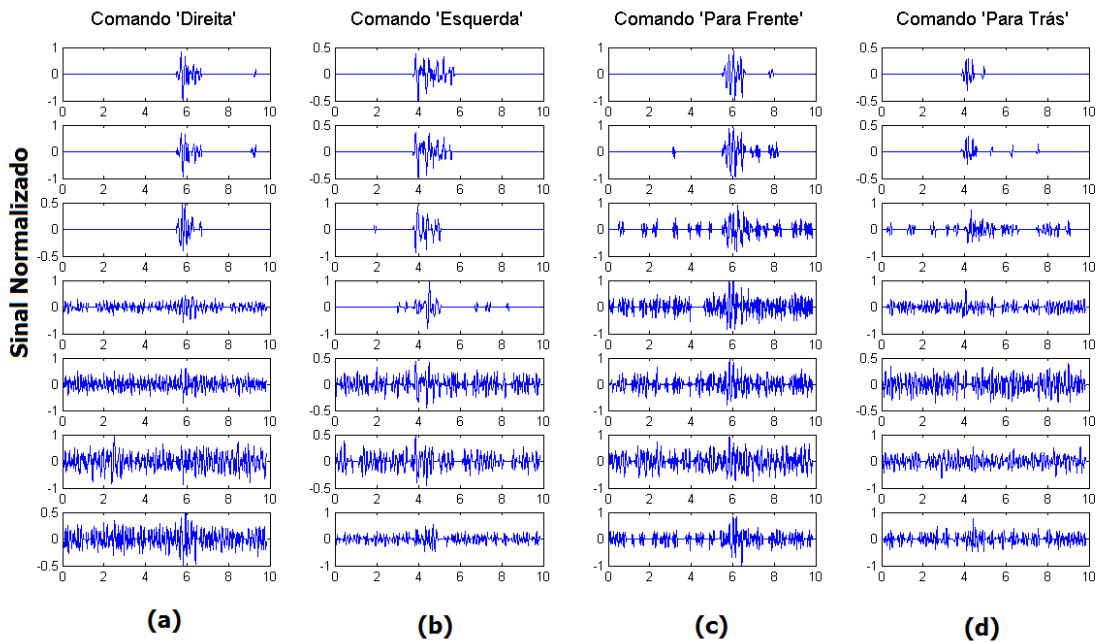


Figura 66 Curvas do sinal de sEMG do Dataset 6 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

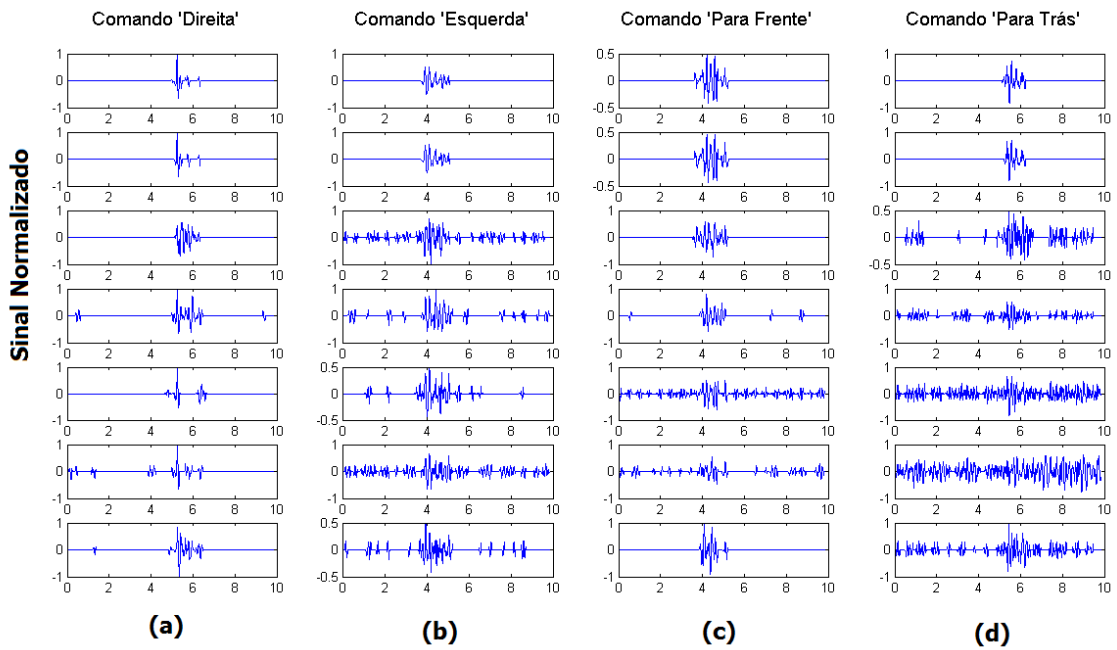


Figura 67 Curvas do sinal de sEMG do Dataset 7 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

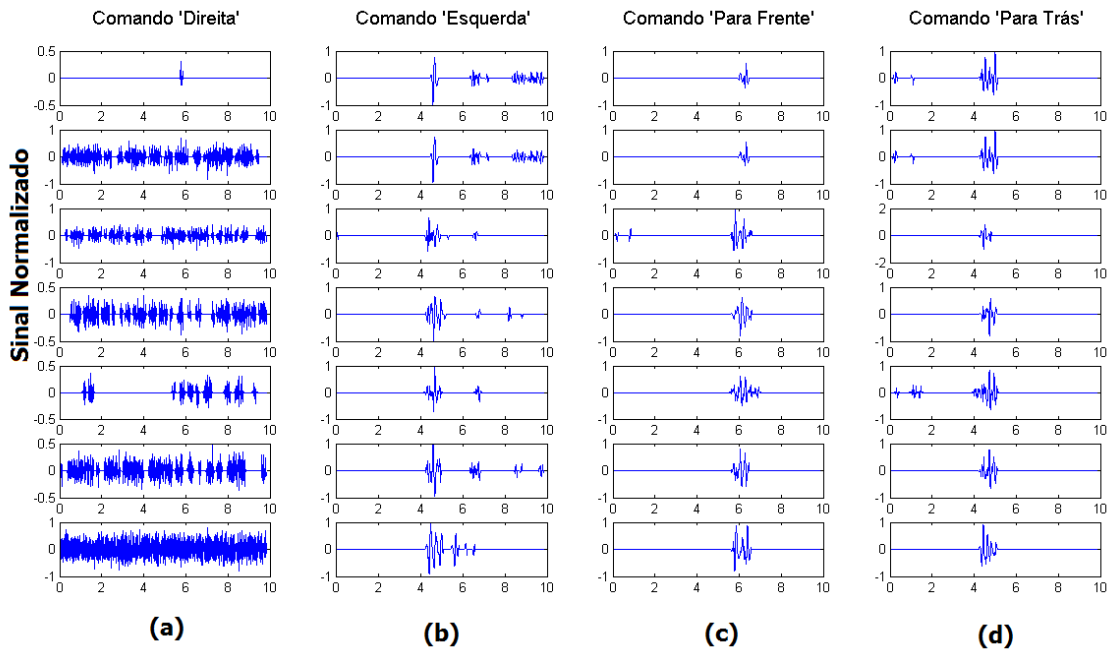


Figura 68 Curvas do sinal de sEMG do Dataset 8 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

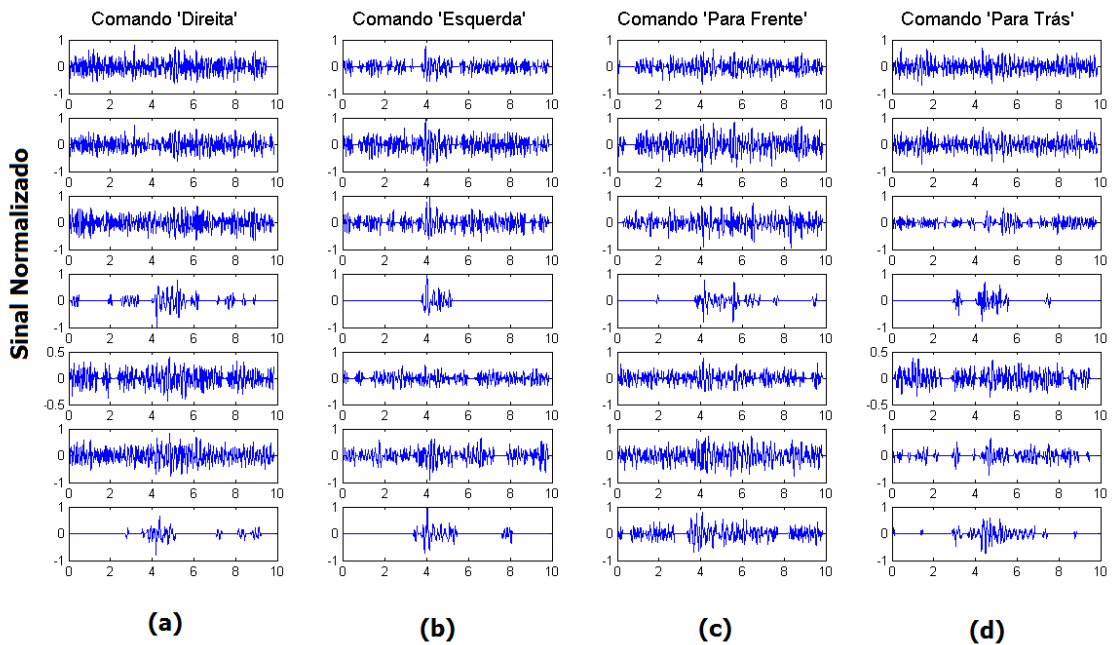


Figura 69 Curvas do sinal de sEMG do Dataset 9 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

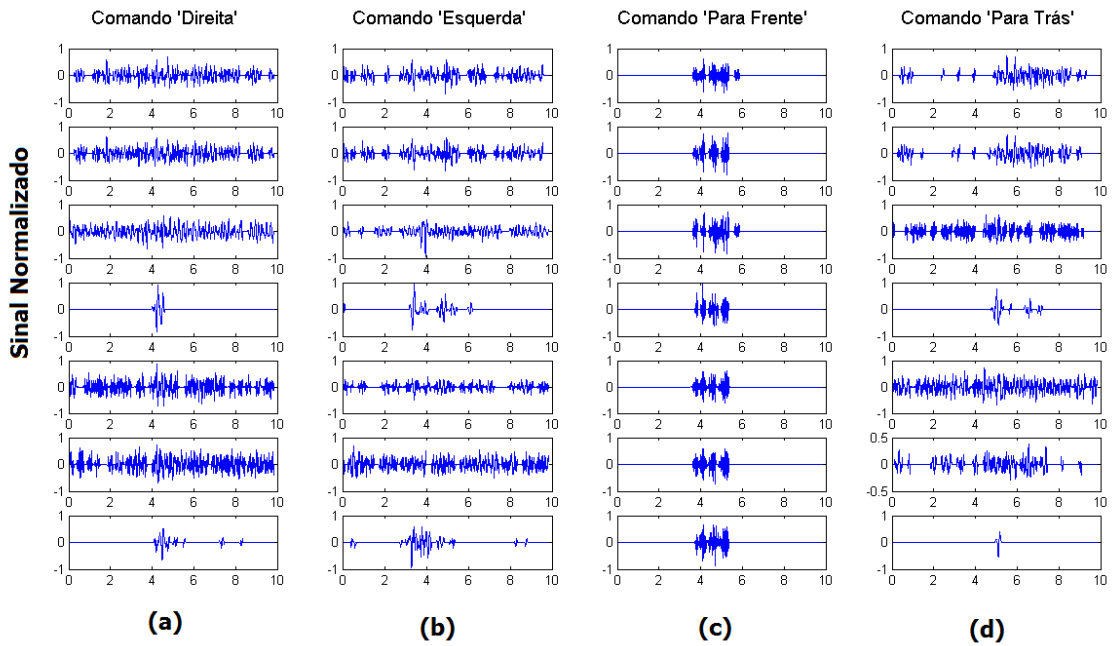


Figura 70 Curvas do sinal de sEMG do Dataset 10 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

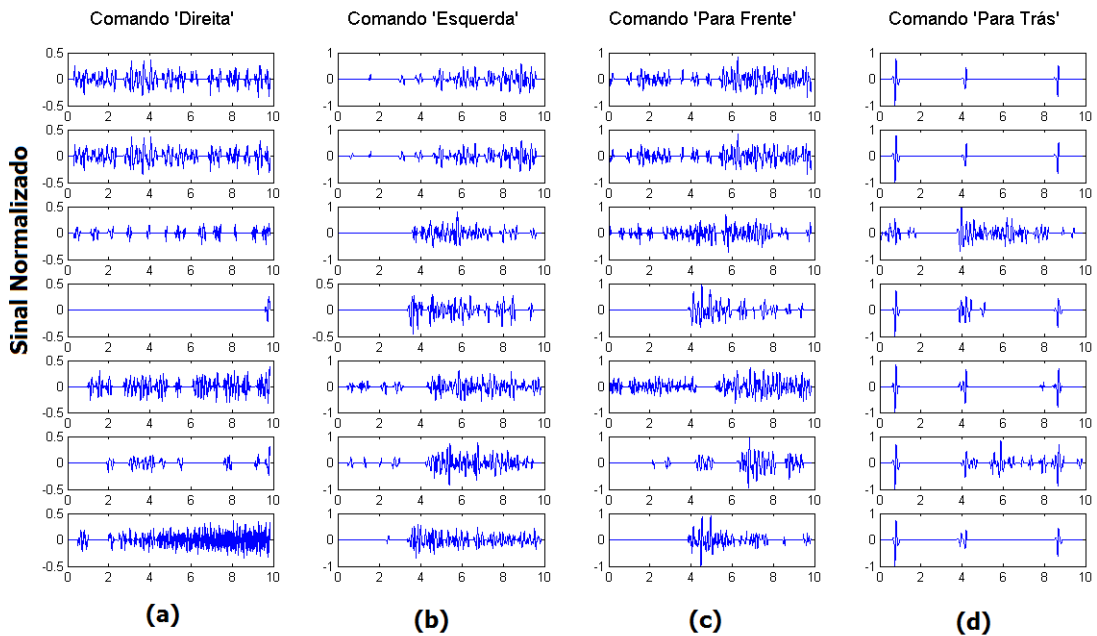


Figura 71 Curvas do sinal de sEMG do Dataset 11 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

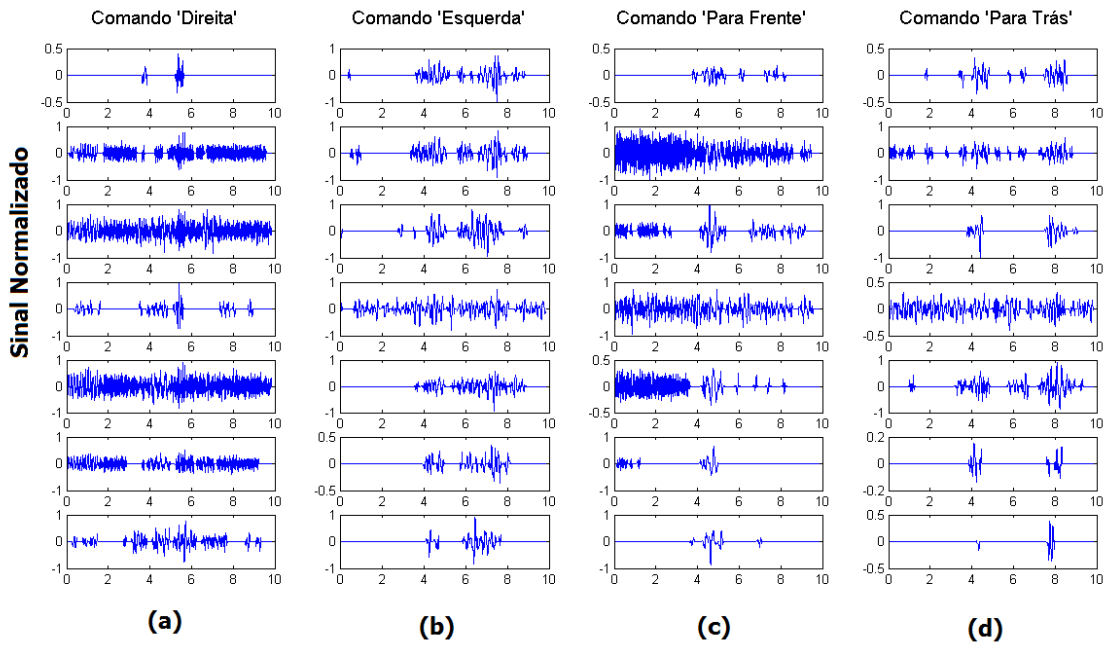


Figura 72 Curvas do sinal de sEMG do Dataset 12 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

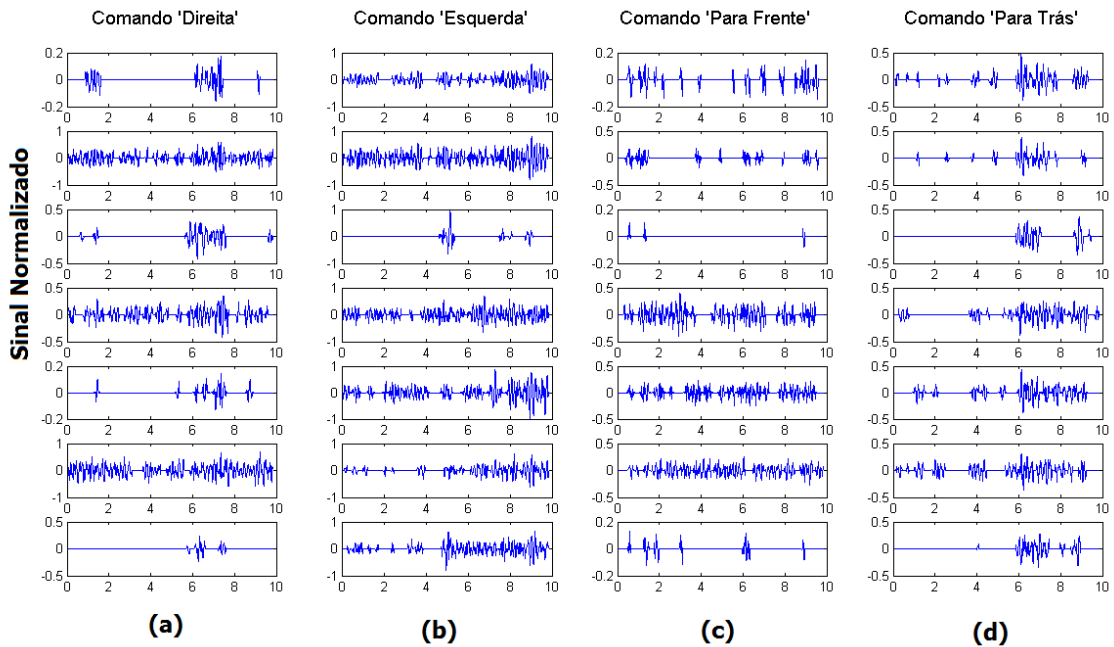


Figura 73 Curvas do sinal de sEMG do Dataset 13 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

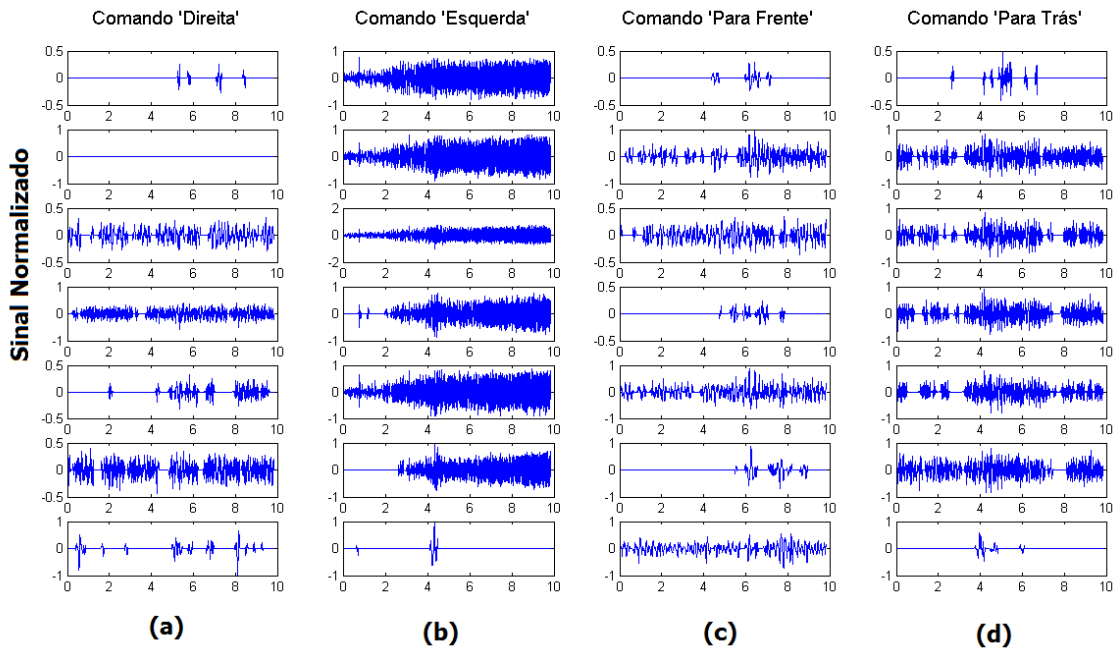


Figura 74 Curvas do sinal de sEMG do Dataset 14 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

ANEXO E - SINAIS DE EEG OBTIDAS PARA OS QUATRO COMANDOS VERBAIS

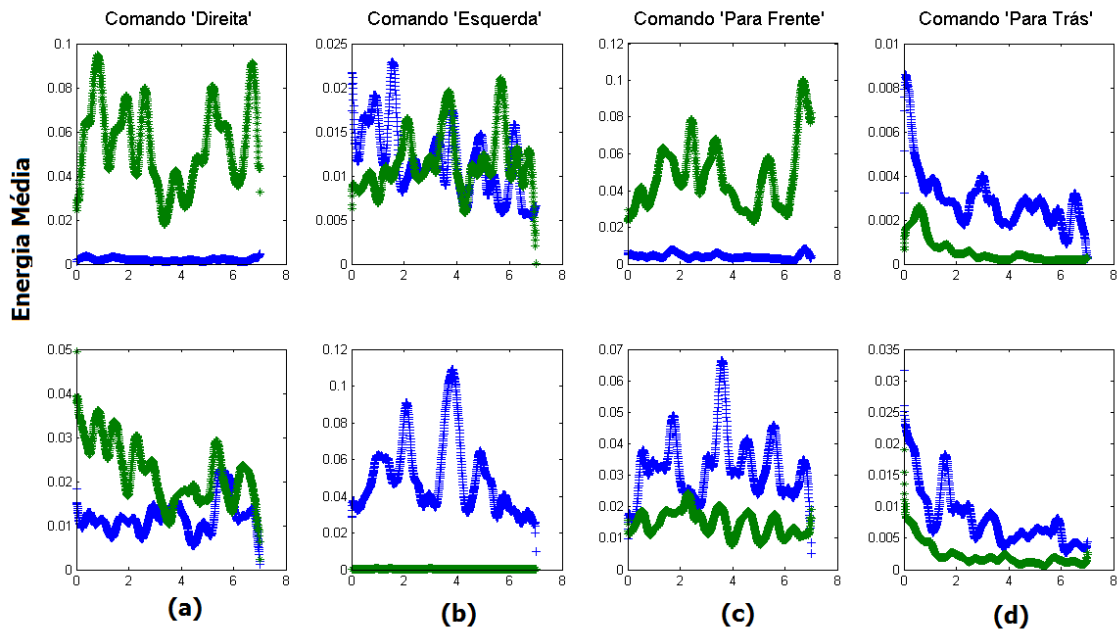


Figura 75 Curvas do sinal de EEG do Dataset 1 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

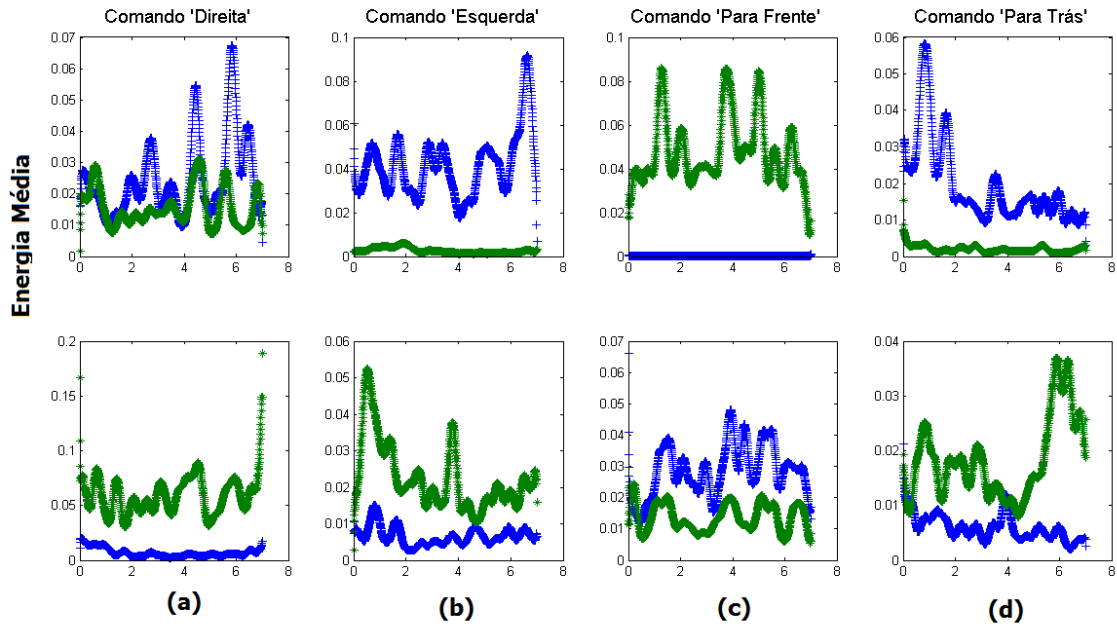


Figura 76 Curvas do sinal de EEG do Dataset 2 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

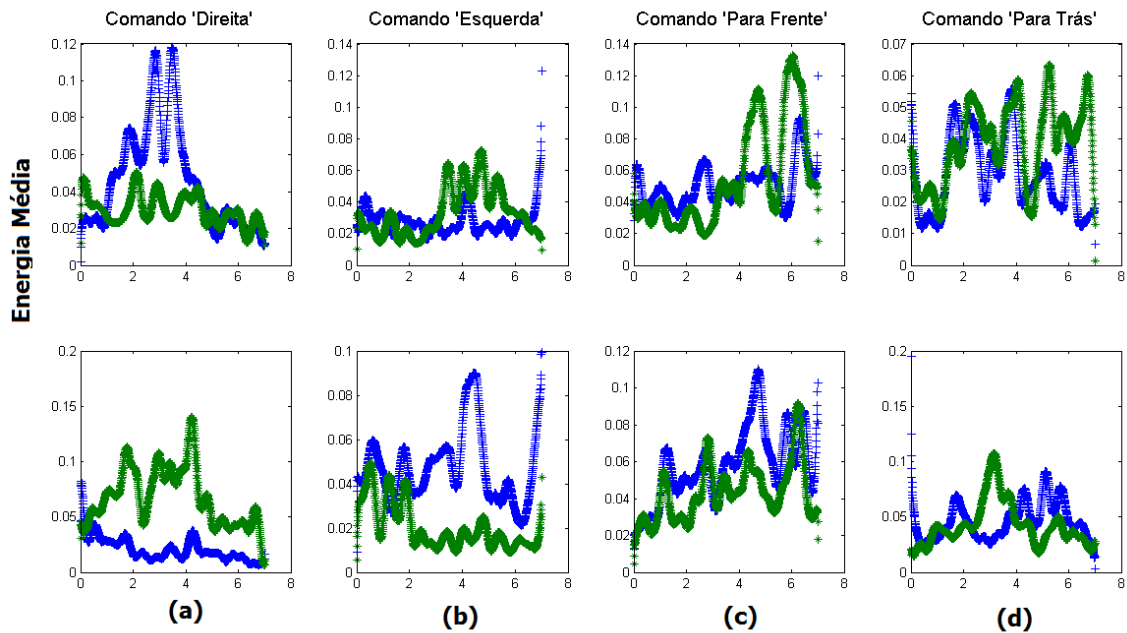


Figura 77 Curvas do sinal de EEG do Dataset 3 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

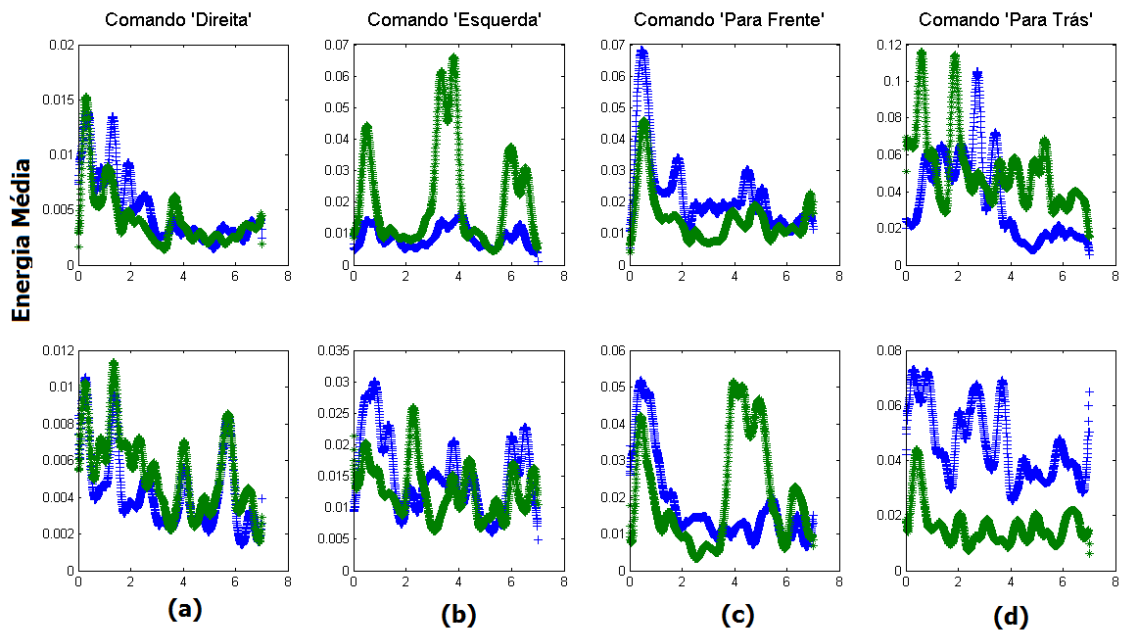


Figura 78 Curvas do sinal de EEG do Dataset 4 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

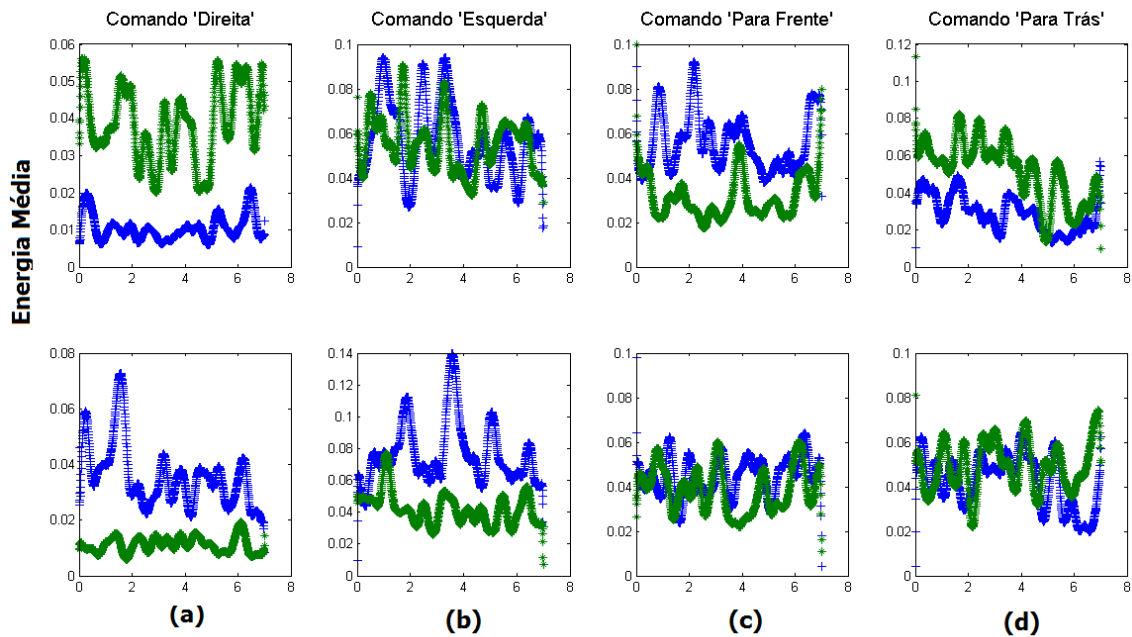


Figura 79 Curvas do sinal de EEG do Dataset 5 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

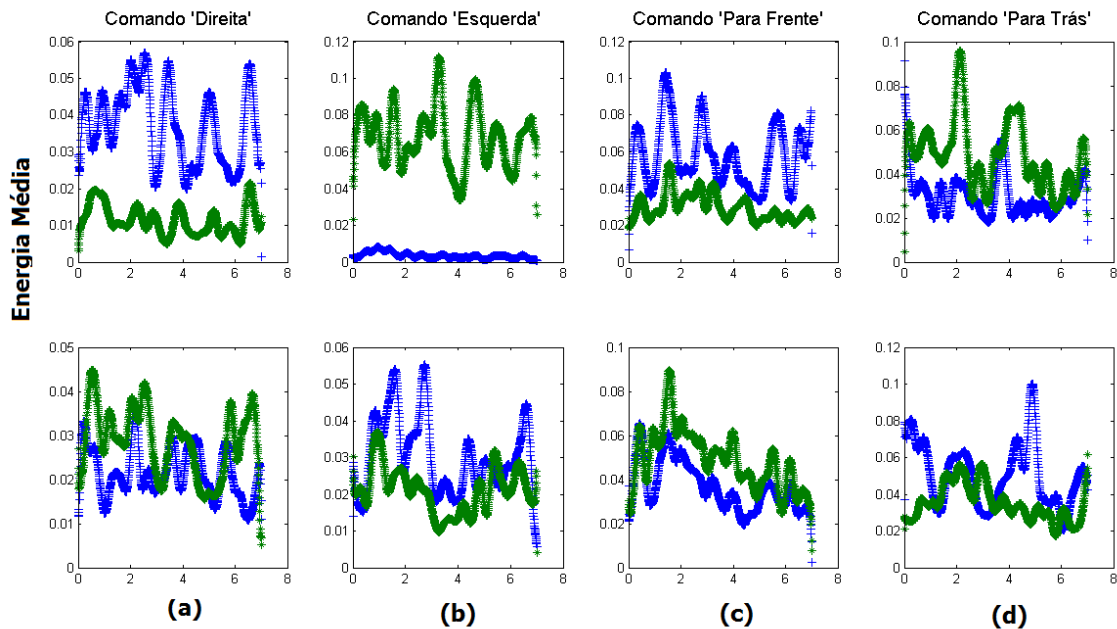


Figura 80 Curvas do sinal de EEG do Dataset 6 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

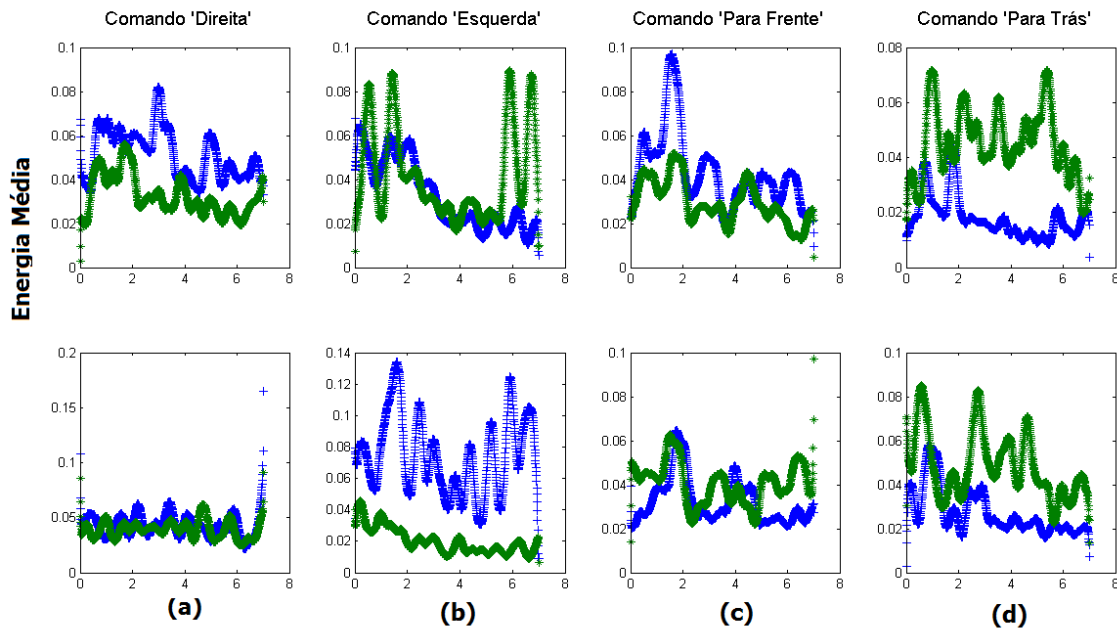


Figura 81 Curvas do sinal de EEG do Dataset 7 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

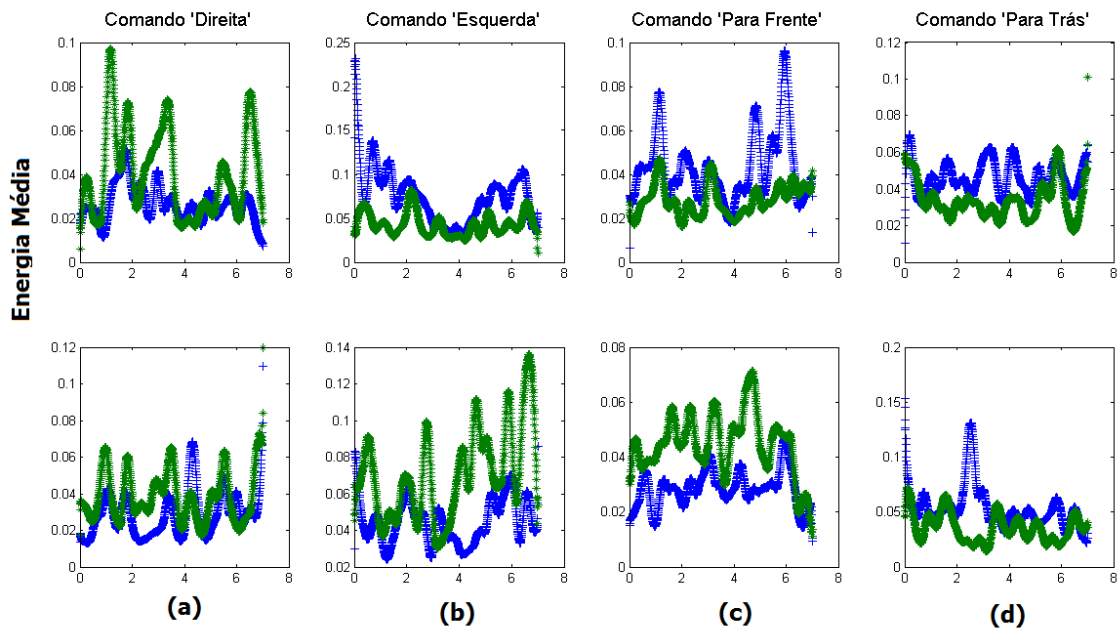


Figura 82 Curvas do sinal de EEG do Dataset 8 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

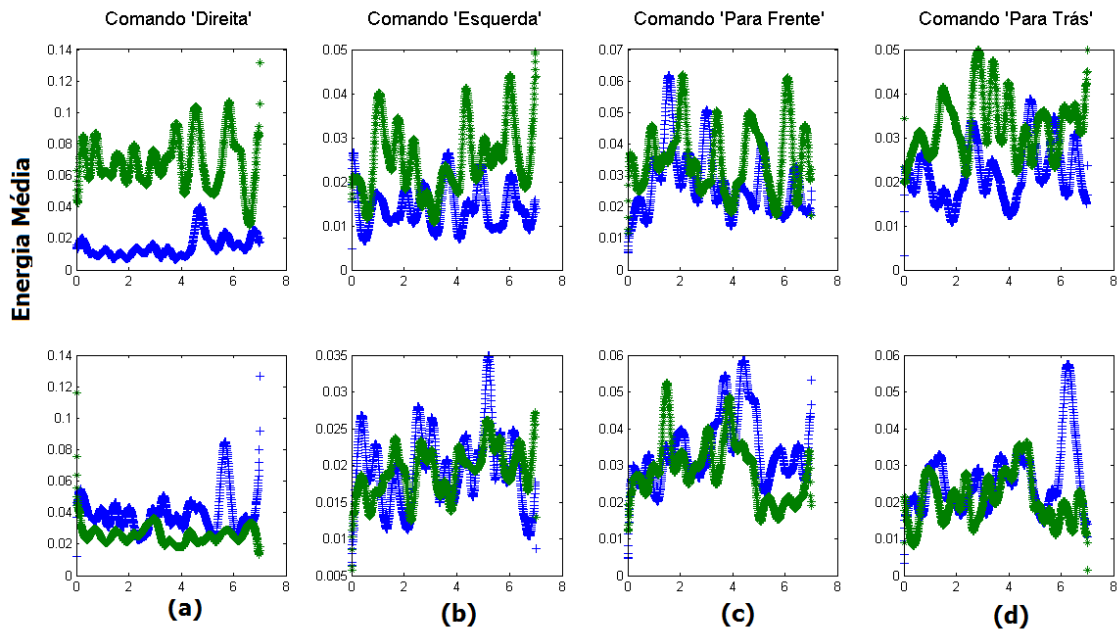


Figura 83 Curvas do sinal de EEG do Dataset 9 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

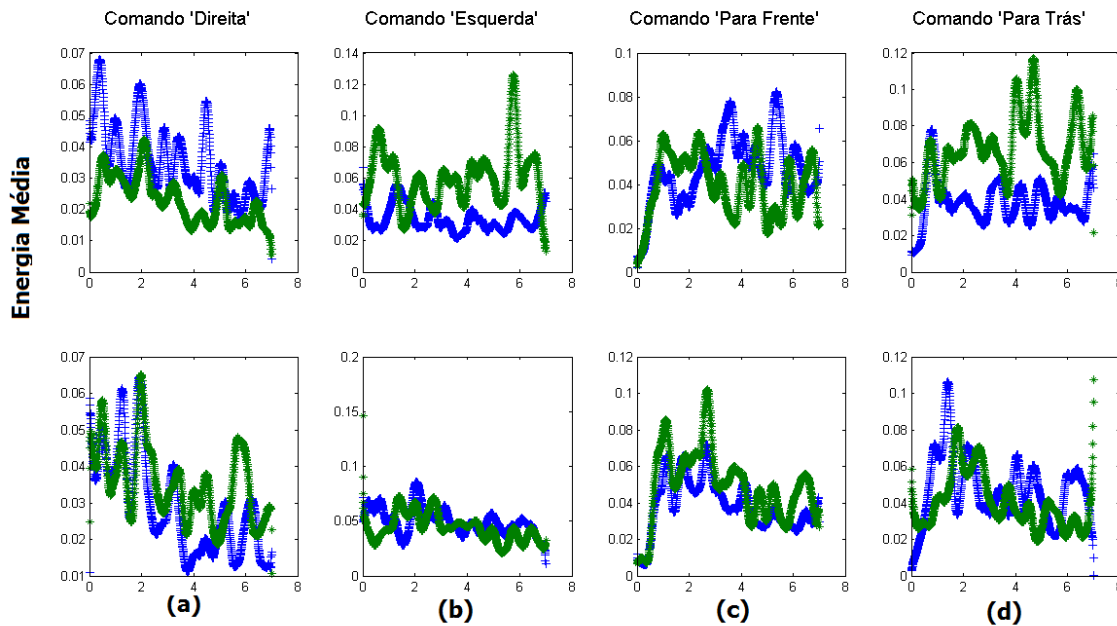


Figura 84 Curvas do sinal de EEG do Dataset 11 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

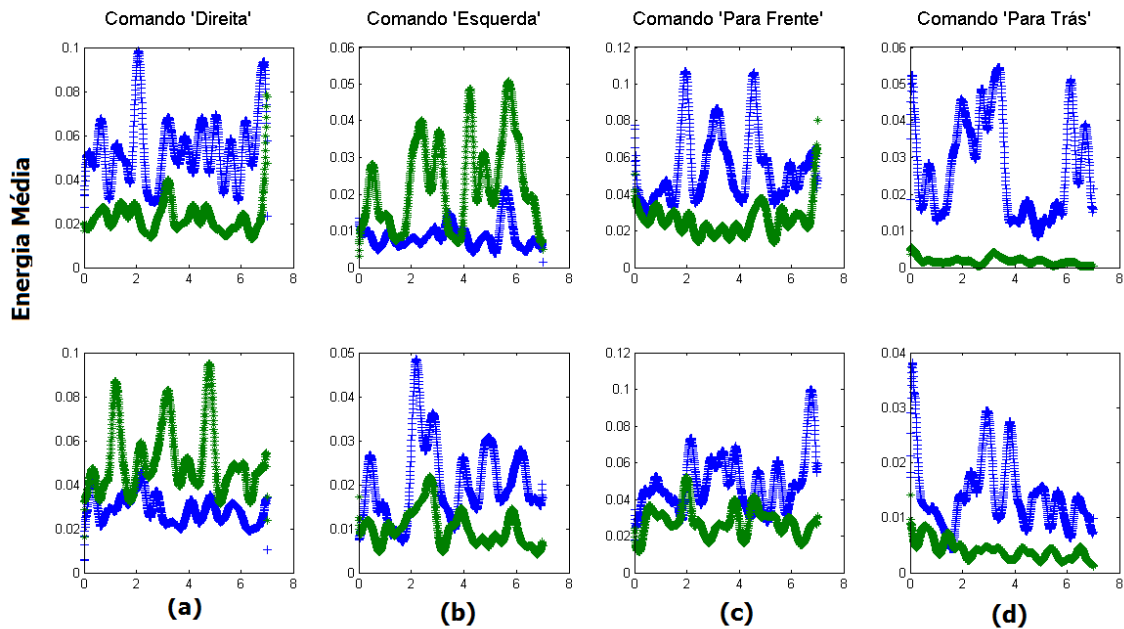


Figura 85 Curvas do sinal de EEG do Dataset 12 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

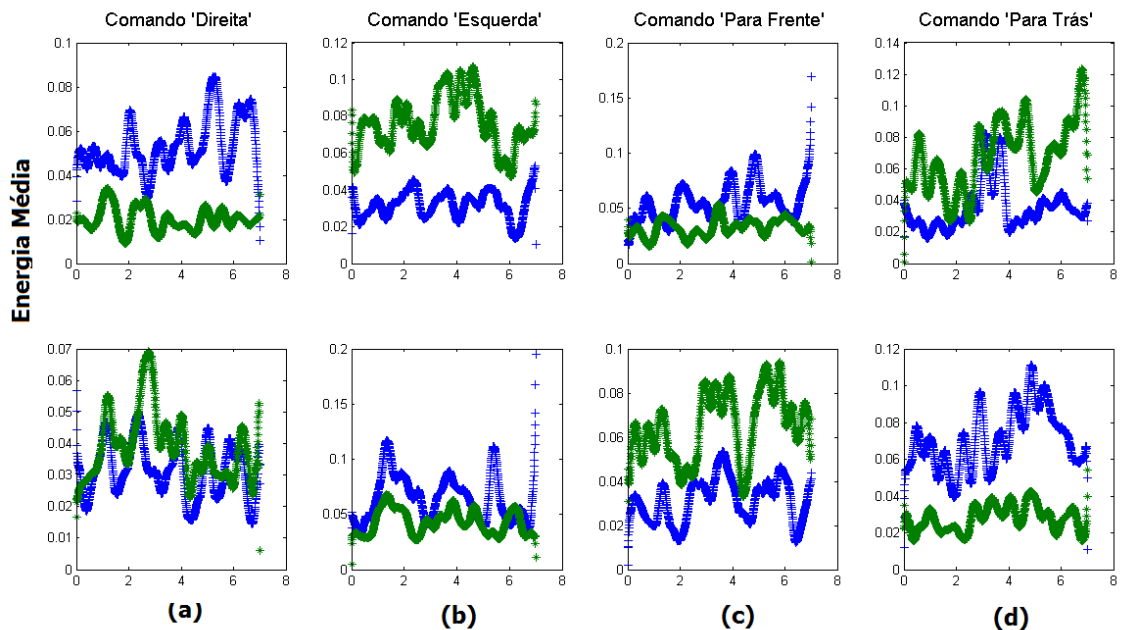


Figura 86 Curvas do sinal de EEG do Dataset 13 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.

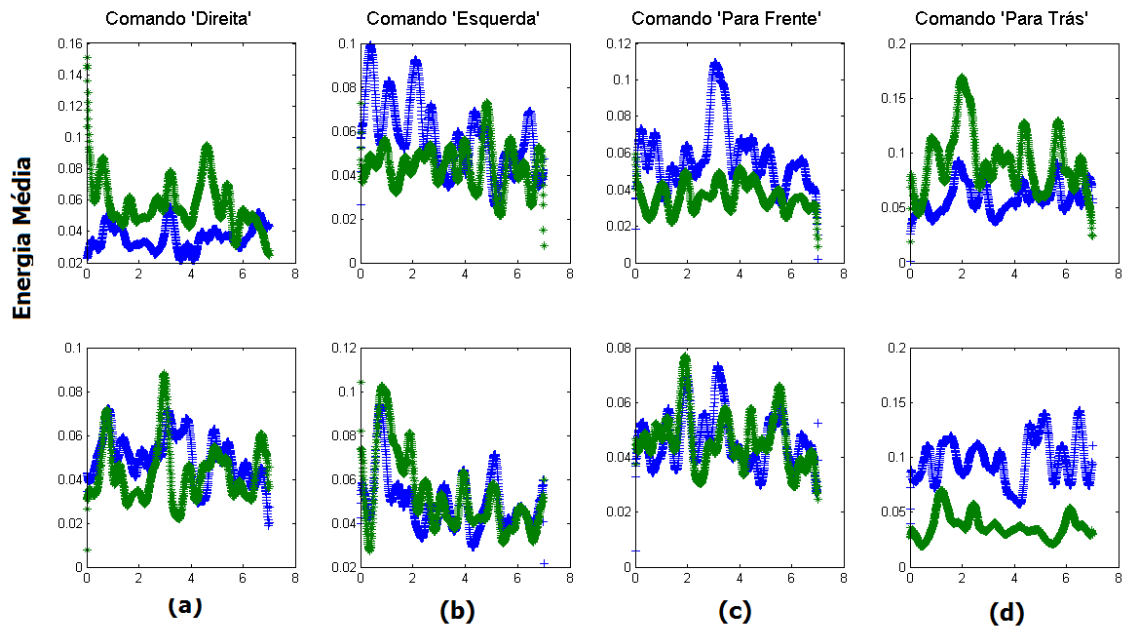


Figura 87 Curvas do sinal de EEG do Dataset 14 para os quatro comandos verbais. Sinal de ativação (a) Comando 'Direita', (b) Comando 'Esquerda', (c) Comando 'Para Frente' e (d) Comando 'Para Trás'.