

PONTIFÍCIA UNIVERSIDADE CATÓLICA
DO RIO DE JANEIRO



Gabriel Chaves de Melo

**Algoritmos para Reconhecimento de Padrões em
Imagética Motora em uma Interface Cérebro-Máquina**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para
obtenção do título de Mestre pelo Programa de Pós-
Graduação em Engenharia Mecânica da PUC-Rio.

Orientador: Marco Antonio Meggiolaro

Rio de Janeiro, maio de 2018

Gabriel Chaves de Melo

**Algoritmos para Reconhecimento de Padrões em Imagética
Motora em uma Interface Cérebro-Máquina**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do título de Mestre pelo Programa de Pós-Graduação em Engenharia Mecânica da PUC-Rio.

Orientador: Marco Antonio Meggiolaro.

Marco Antonio Meggiolaro
Orientador
PUC-Rio

Elisabeth Costa Monteiro
PUC-Rio

Carlos Julio Tierra Criollo
UFRJ

Marcio da Silveira Carvalho
Coordenador Setorial do Centro Técnico Científico - PUC-Rio

Rio de Janeiro, 09 de maio de 2018

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Gabriel Chaves de Melo

Gabriel graduou-se em Engenharia Mecânica pela Universidade Federal de Minas Gerais em 2015. No ano de 2016 iniciou o Mestrado no Departamento de Engenharia Mecânica da PUC-Rio. Seu principal interesse é na área de tecnologia assistiva.

À minha querida avó Regina

Agradecimentos

Pai, Mãe, irmãos e irmãs

Toda minha grande família, especialmente minha avó Zinda que me acolheu com tanto carinho no Rio de Janeiro

Ana Luísa, por tudo que é na minha vida

Amizades de Belo Horizonte e novas amizades do Rio de Janeiro

Victor Campos, pelo apoio e colaboração indispensáveis

Gabriel, Rossi, Bruna, Túlio e Felipe pelo apoio na realização do trabalho

Meu orientador, professor Marco Antonio Meggiolaro, pela confiança e pelos ensinamentos

Sistema Colégio Militar, UFMG e PUC-Rio, pela excelente formação acadêmica no decorrer da minha vida

Sumário

Lista de Figuras	8
Lista de Tabelas	11
Lista de Abreviaturas	13
Lista de Símbolos	15
1 Introdução	19
2 Fundamentos Teóricos	25
2.1. Interface Cérebro-Máquina	25
2.2. Tipos de Interfaces	26
2.2.1. Dependente e Independente	26
2.2.2. Síncrona e Assíncrona	26
2.2.3. Invasiva e Não Invasiva	26
2.3. Principais Aspectos de uma ICM	27
2.3.1. Aquisição de Sinais e Sinais de Controle	27
2.3.2. Pré-processamento	30
2.3.3. Extração de Características	33
2.3.4. Classificação	34
2.3.5. Controle	35
3 Técnicas Matemáticas Utilizadas nos Algoritmos	37
3.1. Pré-processamento – Filtro Espacial	37
3.1.1. <i>Common Spatial Patterns</i>	37
3.1.2. Superfície Esférica Laplaciana	39
3.1.3. Visualização dos Filtros Espaciais	43
3.2. Extração de Características	44
3.2.1. Transformada de Fourier	44

3.2.2. Transformada de Wavelet	45
3.2.3. Áreas no Domínio do Tempo	47
3.2.4. Variância no Domínio do Tempo	48
3.3. Classificação – <i>Fisher Linear Discriminant</i>	48
4 Método Proposto	50
4.1. Banco de Dados	50
4.2. Sistema de Posicionamento dos Eletrodos	52
4.3. Método de Três Etapas	54
4.3.1. Etapa 1 – Teste das Características	54
4.3.2. Etapa 2 – Seleção de Canais de Características	57
4.3.3. Etapa 3 – Redução de Canais do Filtro Espacial	59
4.4. Resultados e Discussão	60
4.4.1. Resultados da Etapa 1	61
4.4.2. Resultados da Etapa 2	67
4.4.3. Resultados da Etapa 3	72
4.4.4. Resultados de Validação	74
4.5. Método de Duas Etapas	75
4.5.1. Etapa 1 – Teste das Características v2	75
4.6. Resultados e Discussão	76
4.6.1. Resultados da Etapa 1	76
4.6.2. Resultados da Etapa 2	79
4.6.3. Resultados de Validação	82
5 Aquisição de Dados para Análise <i>Offline</i>	84
5.1. Composição do Banco de Dados	84
5.2. Seleção de Características	87
5.2.1. Resultados e Discussão	88
5.3. Intervalo de Tempo Processado	90
5.4. Detecção de Um Único MI	92
6 Análise em Tempo Real	95
6.1. O Sistema	95
6.2. Primeiro Teste Experimental	99

6.3. Resultados e Discussão	101
6.4. Segundo Teste Experimental	104
6.5. Resultados e Discussão	105
7 Conclusão	109
Apêndice A	114
a. Superfície Esférica Laplaciana – Interpretação física (Carvalhaes e De Barros, 2015)	114
b. Superfície Esférica Laplaciana – Cálculo (Carvalhaes e De Barros, 2015; Carvalhaes e Suppes, 2011)	117
Apêndice B	121
Bibliografia	124
Anexo I	131

Lista de Figuras

Figura 1 - (A) Controle de um indivíduo sobre o ambiente em condições normais; (B) ICM como forma alternativa para o indivíduo exercer controle sobre o ambiente quando a conexão do cérebro com o corpo é interrompida.	20
Figura 2 - Modelo esquemático de uma ICM adaptado de Yuan e He (2014).....	25
Figura 3 - Sistema de coordenadas esféricas.	41
Figura 4 - Distribuição espacial dos sinais de EEG sem filtro, filtrado com CSP e filtrado com SL.	44
Figura 5 - Exemplos de janela <i>hamming</i> ao longo de um intervalo de 1s.	45
Figura 6 – Sucessivos filtros de frequência para executar a DWT (adaptado de Badrzadeh et al., (2013)).	46
Figura 7 - Análise em tempo e em frequência com DWT, onde a cada retângulo corresponde um coeficiente.	47
Figura 8 - Sistema 10-20 de posicionamento de eletrodos.	53
Figura 9 - Eletrodos utilizados para compor o banco de dados.	53
Figura 10 - Modelo esquemático do Método de Três Etapas.	54
Figura 11 - Procedimentos da etapa 1.	56
Figura 12 - A) Área motora suplementar (MS), área pré-motora (PM) e área motora primária (M1) (Lent, 2010); B) Homúnculo representado em apenas um hemisfério no corte transversal da área M1 (Squire et al., 2008).....	58
Figura 13 - Canais de características (preenchidos de acordo com a Figura 15) e os demais canais utilizados apenas para o filtro espacial (sem preenchimento).	58
Figura 14 - Configurações selecionadas para cada técnica e para cada pessoa.	64
Figura 15 - Cores e posições dos canais.	67
Figura 16 - Configurações vencedoras da etapa 2.	68
Figura 17 - Incidência de cada canal nas configurações vencedoras da etapa 2. ...	69
Figura 18 - Incidência de cada linha de posição nas configurações vencedoras da etapa 2.	70
Figura 19 - Melhores sete canais.	70

Figura 20 - Incidência de cada canal nos melhores grupos com sete canais da etapa 2.....	71
Figura 21 - Incidência de cada linha de posição nos melhores grupos com sete canais da etapa 2.....	71
Figura 22 - Melhores taxas de acerto para cada quantidade de canais características variando de 39 a 1.....	72
Figura 23 - Taxas de acertos obtidas durante execução da etapa 3.....	73
Figura 24 - Configurações selecionadas de forma definitiva na versão 1 da etapa 1 e configurações selecionadas depois de combinar as melhores da FFT v2 e DWT 2 com sete e 39 canais separadamente na versão 2 da etapa 1.....	79
Figura 25 - Melhor configuração obtida com a etapa 2 do Método de Duas Etapas.....	80
Figura 26 - Incidência de cada canal nas configurações vencedoras da etapa 2..	81
Figura 27 - Incidência de linha de posição nas configurações vencedoras da etapa 2.....	81
Figura 28 - Resultados da etapa 2 do Método de Duas Etapas.....	82
Figura 29 - Eletrodos utilizados no Emotiv e suas respectivas posições no sistema 10-20.....	86
Figura 30 - Taxas de acertos com diferentes intervalos de tempo processados de cada vez.....	91
Figura 31 - Taxas de acertos com diferentes intervalos de tempo processados de cada vez, após seleção de características para cada caso.....	92
Figura 32 - Resultados quando foram classificados um MI e a atividade espontânea (sem MI).....	94
Figura 33 - Raspberry Pi, o microcontrolador utilizado para teste em tempo real.....	96
Figura 34 - Representação da distribuição dos pinos GPIO do Raspberry Pi.....	96
Figura 35 - Aparelho de EEG utilizado, Emotiv EPOC.....	97
Figura 36 - Eletrodos do Emotiv vistos em detalhe.....	98
Figura 37 - Sistema utilizado para os testes em tempo real.....	99
Figura 38 - Resultados do primeiro teste em tempo real. No eixo horizontal, os valores indicam a posição do ponto em uma unidade arbitrária.....	102

Figura 39 - Resultados do segundo teste em tempo real (Abordagem 1). No eixo horizontal, os valores indicam a posição do ponto em uma unidade arbitrária.	107
Figura 40 - Sistema de coordenadas esféricas	119

Lista de Tabelas

Tabela 1 - Quantidade de amostras de 1 s do conjunto de ajuste de parâmetros...	52
Tabela 2 - Quantidade de amostras de 1 s dos conjuntos de testes e validação (ambos têm o mesmo tamanho).....	52
Tabela 3 – Combinações possíveis de cada técnica na etapa 1.	55
Tabela 4 - Taxa de acertos com dados de teste.....	60
Tabela 5 - Taxa de acertos com dados de validação.....	61
Tabela 6 – Melhores desempenhos da DWT 2.....	61
Tabela 7 - Melhores desempenhos da DWT 3.	62
Tabela 8 - Melhores desempenhos da DWT 3a.....	62
Tabela 9 - Melhores desempenhos da FFT.....	63
Tabela 10 - Melhores desempenhos da ADT.	63
Tabela 11 - Melhores desempenhos da VDT.	64
Tabela 12 - Configurações selecionadas de forma definitiva na etapa 1.....	65
Tabela 13 - Resultados obtidos com os 39 canais de características.	65
Tabela 14 - Situações em que a etapa 3 previu melhora nos resultados.....	73
Tabela 15 - Validação com configurações obtidas na etapa 1.....	74
Tabela 16 - Validação com as configurações obtidas por meio das três etapas.	75
Tabela 17 - Buscas realizadas com a FFT v2 na segunda versão do método.....	76
Tabela 18 - Buscas realizadas com a DWT 2 na segunda versão do método.....	76
Tabela 19 - Detalhes das configurações selecionadas da FFT v2.	77
Tabela 20 - Detalhes das configurações selecionadas da DWT 2.	78
Tabela 21 - Configurações selecionadas de forma definitiva na etapa 1.....	79
Tabela 22 - Resultados de validação das configurações vencedoras da etapa 1 e das melhores configurações da etapa 2.....	83
Tabela 23 - Equipamentos utilizados para compor banco de dados.....	85
Tabela 24 - Buscas realizadas com a FFT v2 para análises com banco de dados do Emotiv.	88
Tabela 25 - Resultados da seleção de características com dados medidos pelo Emotiv.	89

Tabela 26 - Resultados com dados de validação.....	90
Tabela 27 - Detalhes do Raspberry Pi.	96
Tabela 28 - Resultados da segunda análise <i>offline</i>	100
Tabela 29 - Resultados da terceira análise <i>offline</i>	100
Tabela 30 - Tempo gasto em cada etapa do experimento.....	101
Tabela 31 - Resultados das análises anteriores com as configurações com melhor desempenho de cada análise e com a configuração selecionada para o teste em tempo real.	105

Lista de Abreviaturas

ADT	Áreas no Domínio do Tempo
CSP	<i>Common Spatial Patterns</i>
db	<i>Daubechies</i>
DWT	Transformada Discreta de Wavelet
DWT 2	Segundo nível de detalhes da DWT
DWT 3	Terceiro nível de detalhes da DWT
DWT 3a	Terceiro nível de aproximação da DWT
ECoG	Eletrocorticografia
EEG	Eletroencefalografia
ERD	Dessincronização Relacionada a Eventos
ERP	Potenciais Relacionados a Eventos
ERS	Sincronização Relacionada a Eventos
FFT	Características obtidas com Transformada de Fourier
FFT v2	Segunda Versão da FFT
FLD	Discriminante Linear de Fisher
fMIR	Ressonância Magnética Funcional
fNIRS	Espectometria Funcional Próxima do Infravermelho
GPIO	Pinos de entrada e saída do microcontrolador Raspberry Pi
ICM	Interface Cérebro-Máquina
M1	Córtex Motor Primário
MD	Mão direita
ME	Mão esquerda
MEG	Magnetoencefalografia
MI	Movimentos Motores Imaginários
MS	Área Motora Suplementar
P	Pés
PET	Tomografia por Emissão de Pósitrons
PM	Área Pré-Motora
SCP	Potenciais Corticais Lentos

SL	Superfície Laplaciana
SMR	Ritmo Sensório Motor
SSVEP	Potenciais Visuais Evocados em Regime Estacionário
VDT	Variância no Domínio do Tempo
VEP	Potenciais Visuais Evocados

Lista de Símbolos

V	Potenciais elétricos medidos em um instante de tempo
x, y, z	Coordenadas do espaço tridimensional
j_z	Densidade de corrente na direção z
ρ	Resistividade
V_H e V_F	Potenciais elétricos referentes às classes ‘H’ e ‘F’
R_H e R_F	Covariâncias espaciais normalizadas das classes ‘H’ e ‘F’
R'	Covariância espacial composta
U_0	Matriz de autovetores
Σ	Matriz de autovalores
P	Matriz de branqueamento
S_H	Matriz de covariância média branqueada
U	Matriz de autovetores
Σ_H e Σ_F	Matriz de autovalores das classes ‘H’ e ‘F’
I	Matriz identidade
W	Matriz de projeção do CSP
Z	Matriz com dados de EEG filtrados por CSP
h	Distância entre pontos vizinhos na discretização da SL
λ	Parâmetro de regularização das splines
N	Quantidade de canais de medição do EEG
V_i	Potencial em um canal i
\mathbf{r}_i	Vetor posição de um eletrodo
r	Raio da esfera que representa a cabeça humana
f^*	Função spline
m	Flexibilidade da spline
J_m	Medida da rugosidade de f^*
\mathbf{c} e \mathbf{d}	Coefficientes que expandem a função f^*
g_m	Função definida em função dos polinômios de Legendre
P_l	Polinômio de Legendre de grau l

T e K	Matrizes envolvidas no cálculo da superfície Laplaciana
Q_1, Q_2 e R	Matrizes obtidas com a fatoração QR
L	Matriz de transformação linear da superfície Laplaciana
H	Função <i>hamming</i>
n	Amostra de um sinal discreto
N'	Tamanho de um intervalo de um sinal discreto
f	Valor de frequência
F	Sinal discreto em frequência
γ	Elemento do vetor de características
f_s	Frequência de amostragem de um sinal
$coef_\sigma$	Coefficientes da DWT
t	Instante de tempo
N_v	Quantidade de volumes da DWT que são somados
S'	Sinal discreto no tempo
δ_η	Vetor de características
m_i	Vetor médio das amostras de vetores de características
S_i e S_w	Matrizes envolvidas no cálculo do FLD
w	Vetor de projeção do FLD
Y	Conjunto de pontos projetados por w
N^*	Quantidade de pontos de Y
μ	Limiar do FLD
τ_1 e τ_2	Conjuntos referentes às classes 1 e 2
p	Quantidade de pontos em um intervalo de tempo

Resumo

Chaves de Melo, Gabriel. **Algoritmos para Reconhecimento de Padrões em Imagética Motora em uma Interface Cérebro-Máquina**. Rio de Janeiro, 2018. Dissertação de Mestrado - Departamento de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro.

Uma interface cérebro-máquina (ICM) é um sistema que permite a um indivíduo, entre outras coisas, controlar um dispositivo robótico por meio de sinais oriundos da atividade cerebral. Entre os diversos métodos para registrar os sinais cerebrais, destaca-se a eletroencefalografia (EEG), principalmente por ter uma rápida resposta temporal e não oferecer riscos ao usuário, além de o equipamento ter um baixo custo relativo e ser portátil. Muitas situações podem fazer com que uma pessoa perca o controle motor sobre o corpo, mesmo preservando todas as funções do cérebro, como doenças degenerativas, lesões medulares, entre outras. Para essas pessoas, uma ICM pode representar a única possibilidade de interação consciente com o mundo externo. Todavia, muitas são as limitações que impossibilitam o uso das ICMs da forma desejada, entre as quais estão as dificuldades de se desenvolver algoritmos capazes de fornecer uma alta confiabilidade em relação ao reconhecimento de padrões dos sinais registrados com EEG. A escolha pelas melhores posições dos eletrodos e as melhores características a serem extraídas do sinal é bastante complexa, pois é altamente condicionada à variabilidade interpessoal dos sinais. Neste trabalho um método é proposto para escolher os melhores eletrodos e as melhores características para pessoas distintas e é testado com um banco de dados contendo registros de sete pessoas. Posteriormente dados são extraídos com um equipamento próprio e uma versão adaptada do método é aplicada visando uma atividade em tempo real. Os resultados mostraram que o método é eficaz para a maior parte das pessoas e a atividade em tempo real forneceu resultados promissores. Foi possível analisar diversos aspectos do algoritmo e da variabilidade inter e intrapessoal dos sinais e foi visto que é possível, mesmo com um equipamento limitado, obter bons resultados mediante análises recorrentes para uma mesma pessoa.

Palavras-chave

Interface Cérebro-Máquina, EEG, Reconhecimento de Padrões, Movimentos Imaginários

Abstract

Chaves de Melo, Gabriel. **Algorithms for Motor Imagery Pattern Recognition in a Brain-Machine Interface**. Rio de Janeiro, 2018. MSc Dissertation – Mechanical Engineering Department, Pontifical Catholic University of Rio de Janeiro.

A brain-machine interface (BMI) system allows a person to control robotic devices with brain signals. Among many existing methods for signal acquisition, electroencephalography is the most often used for BCI purposes. Its high temporal resolution, safety to use, portability and low cost are the main reasons for being the most used method. Many situations can affect a person's capability of controlling their body, although brain functions remain healthy. For those people in the extreme case, where there is no motor control, a BCI can be the only way to interact with the external world. Nevertheless, it is still necessary to overcome many obstacles for making the use of BCI systems to become practical, and the most important one is the difficulty to design reliable algorithms for pattern recognition using EEG signals. Inter-subject variability related to the EEG channels and features of the signal are the biggest challenges in the way of making BCI systems a useful technology for restoring function to disabled people. In this paper, a method for selecting subject-specific channels and features is proposed and validated with data from seven subjects. Later in the work data is acquired with different EEG equipment and an adapted version of the proposed method is applied aiming online activities. Results showed that the method was efficient for most people and online activities had promising results. It was possible to analyze important aspects concerning the algorithm and inter and intra-subject variability of EEG signals. Also, results showed that it is possible to achieve good results when multiple analyses are performed with the same subject, even with EEG equipment with well known limitations concerning signal quality.

Key Words

Brain-Machine Interface, EEG, Pattern Recognition, Motor Imagery

1

Introdução

Interface é um elemento que proporciona uma ligação entre dois sistemas não diretamente conectados. Nas diversas atividades que requerem interação entre máquinas e seres humanos, das mais simples às mais complexas, existe uma interface que rege essa relação, permitindo ao indivíduo exercer algum controle sobre a máquina. Botões, alavancas, pedais e microfones são exemplos de artefatos usados em interfaces muito comuns no cotidiano da população. Por meio desses mecanismos, o ser humano pode controlar em diferentes níveis uma máquina e o ambiente que o cerca, além de poder se comunicar com facilidade, superando consideráveis barreiras físicas.

Existem casos em que a única atividade que um indivíduo é capaz de executar voluntariamente é exercida pelo cérebro. Ou seja, o cérebro tem suas funções preservadas, porém não exerce controle consciente sobre corpo. Nessa situação, uma forma de o indivíduo se conectar com o mundo exterior é com o uso de interfaces cérebro-máquina (ICM), que captam, registram e analisam os sinais oriundos da atividade cerebral da pessoa e os transformam em comandos para uma máquina. A Figura 1 ilustra de forma esquemática uma situação normal, onde o cérebro envia comandos para o corpo, que por sua vez interage com o ambiente, e uma situação em que a pessoa necessita de uma interface cérebro-máquina, pois não tem controle consciente sobre o corpo, já que os sinais cerebrais não chegam aos seus destinos para executar movimentos com o corpo.

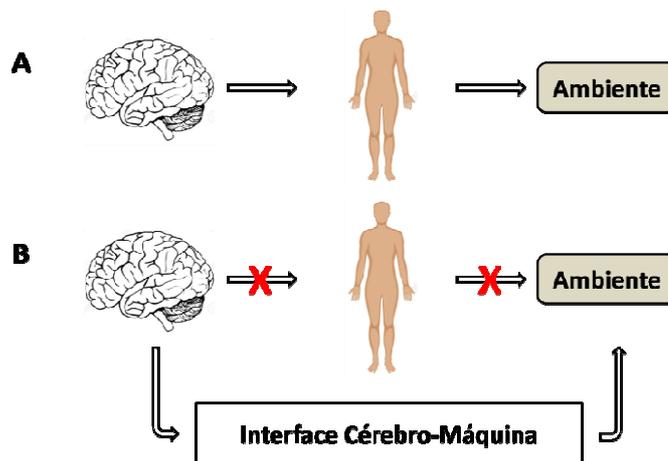


Figura 1 - (A) Controle de um indivíduo sobre o ambiente em condições normais; (B) ICM como forma alternativa para o indivíduo exercer controle sobre o ambiente quando a conexão do cérebro com o corpo é interrompida.

Birbaumer (2006) retrata a perspectiva em relação ao futuro das ICMs por parte dos pioneiros em registro de sinais cerebrais, Hans Berger e Grey Walter, onde eles especulavam sobre a possibilidade de se ler pensamentos a partir da eletroencefalografia (EEG). No entanto, nas décadas que se sucederam pouco se concretizou nesse sentido e o uso de EEG foi direcionado majoritariamente para o estudo de doenças neurológicas e para pesquisas buscando compreender as funções do cérebro. A aplicação de EEG para decifrar pensamentos, permitindo que um indivíduo se comunique ou controle dispositivos somente com atividade cerebral, se deu mais no campo da ficção e da fantasia do que no meio científico (Wolpaw et al., 2002).

Wolpaw et al. (2002) citam razões pelas quais o desenvolvimento da análise dos sinais de EEG não se deu da forma desejada: 1) complexidade do cérebro e de seu mecanismo de funcionamento, o que tornava aparentemente quase remota a possibilidade de reconhecer uma mensagem ou um comando com uma confiabilidade razoável; 2) limitação tecnológica para tornar viável a análise em tempo real de sinais de EEG; 3) muito pouco interesse na capacidade limitada que as ICMs da primeira geração eram capazes de oferecer. Contudo, no mesmo trabalho os autores salientam que na época de sua publicação (2002) esses desafios já estavam sendo contornados de forma cada vez mais eficaz, proporcionando um novo cenário para o futuro na área das interfaces cérebro-máquina para comunicação e controle. Um ano mais tarde, em outro trabalho, Pfurtscheller et al. (2003) reportaram experiências de sucesso com interfaces que

utilizavam movimentos motores imaginários para executar comandos e apresentaram resultados promissores na identificação de movimentos por meio da análise de sinais de EEG.

Ramadan e Vasilakos (2017) esclarecem que nas últimas duas décadas (1997-2017) houve mudanças significativas na área de interface cérebro-máquina, de modo que a quantidade de grupos voltados para pesquisas relacionadas ao tema aumentou consideravelmente em todo o mundo, assim como a quantidade de empresas que desenvolvem produtos voltados para esse fim. As razões para tal são os avanços dos computadores e softwares, além da maior aceitação social em relação aos equipamentos e tecnologias com fins assistivos. Segundo estes autores, o crescente interesse das empresas em produzir equipamentos para ICMs também é responsável por estimular trabalhos de pesquisadores na área.

Projetar uma interface é uma tarefa complexa que exige conhecimentos nas áreas de engenharia, ciência da computação, processamento de sinal, neurociência e psicologia (Lotte et al., 2015). Apesar dos avanços, Lotte et al. (2015) esclarecem que ainda são muitos os desafios que existem para tornar as interfaces adequadas para o usuário final. Alguns destes desafios são a pouca confiabilidade e robustez dos sistemas, de modo que raras são as interfaces capazes de fornecer uma taxa de acertos em relação aos comandos emitidos pelos usuários que permita sua utilização em situações práticas. Além disso, os mesmos pesquisadores informam que um sistema que funciona bem para um indivíduo muitas vezes não é passível de ser usado corretamente por outros. Sendo assim, o uso atual de ICMs para comunicação e controle fora do campo de pesquisas se restringe a aplicações com menores riscos para o usuário, como o uso em ambientes virtuais. Outras aplicações, como acionamento de próteses, órteses, controle de cadeira de rodas e outras similares dificilmente são encontradas fora do ambiente de pesquisa.

Além dos equipamentos físicos necessários para se construir um sistema de ICM, é preciso desenvolver um programa computacional responsável por registrar os sinais cerebrais e transformá-los em sinais de comandos para uma máquina. É no desenvolvimento desse programa que se concentram as maiores dificuldades para a criação de sistemas eficientes. Os algoritmos que compõe o programa geralmente são responsáveis por três tarefas essenciais: pré-processamento do sinal, identificação de características relevantes do sinal, e a classificação dessas características, para determinar a qual grupo de pensamento o sinal registrado

corresponde. Ou seja, o programa registra o sinal durante um intervalo de tempo, pré-processa, extrai as características importantes e classifica o sinal como pertencente ou não a certos grupos de pensamentos pré-determinados. Por fim, o programa envia um comando para o equipamento, que por sua vez executará uma ação de acordo com o grupo ao qual o sinal foi alocado.

Tratando-se de interfaces que utilizam sinais de EEG, como é o caso do presente trabalho, alguns aspectos específicos são responsáveis por grandes dificuldades no desenvolvimento de algoritmos que forneçam uma alta confiabilidade aos sistemas. Entre elas está a grande variabilidade, em pessoas distintas, relacionada a padrões espaciais e características espectro-temporais dos sinais do cérebro (Blankertz et al., 2007). Isso significa, por exemplo, que o sinal correspondente a um determinado pensamento registrado ao longo de toda região do couro cabeludo vai apresentar uma distribuição espacial diferente e características diferentes no domínio do tempo e frequência quando pessoas diferentes são analisadas. A consequência imediata disso é que uma ICM não pode ser utilizada por mais de um indivíduo com as mesmas configurações sem incorrer em prejuízo no desempenho do algoritmo da interface.

Para contornar o problema relativo à variabilidade espectro-temporal, alguns pesquisadores utilizam dados de usuários diferentes para criar classificadores mais genéricos, como fizeram Cheng et al. (2017) e Atyabi et al. (2013). No trabalho de Lana et al. (2015), os autores utilizam em pessoas distintas um mesmo método estatístico para detectar características bem conhecidas dos sinais de EEG de interesse e identificar a ocorrência ou não de certo pensamento. Essas abordagens apresentam bons resultados, porém grande parte das pesquisas foca em algoritmos capazes de se adaptar aos novos usuários. Uma vantagem desses algoritmos adaptativos é que eles podem reduzir a fase de treinamento da pessoa. Essa fase é o período em que o usuário aprende a emitir os sinais corretos para o funcionamento do sistema, o que pode levar meses ou até mesmo nunca acontecer. Em contrapartida, costuma ser necessário um reajuste recorrente dos parâmetros do algoritmo para que ele possa ser utilizado pelo indivíduo, o que torna o uso pouco prático em muitos casos. Muitos pesquisadores, como Galán et al. (2008) e Rodriguez-Bermudez et al. (2013), desenvolvem métodos automáticos para selecionar as melhores características do sinal de cada pessoa ou, como é o

caso de Ron-Angevin et al. (2015), fazem uma seleção manual após uma análise prévia.

No que diz respeito às especificidades espaciais de cada indivíduo, uma possível abordagem é utilizar todos os canais disponíveis para gerar características, porém isso pode incorrer em características corrompidas por ruídos ou características irrelevantes para os propósitos da interface (Lal et al., 2004). Ao invés disso, frequentemente são propostos métodos computacionais para selecionar os melhores canais (eletrodos) para cada usuário. Alguns exemplos são técnicas de identificação de padrões usadas por Wang et al. (2005) e Arvaneh et al. (2011), de algoritmos genéticos usadas por Kee et al. (2015) e He et al. (2013) e outras técnicas matemáticas, como as utilizadas por Lal et al. (2004) e Qiu et al. (2016).

Neste trabalho é desenvolvido um método capaz de selecionar, a partir de um conjunto amplo e abrangente, as melhores características e canais para diferentes pessoas, visando melhorar a taxa de acertos do algoritmo de reconhecimento de padrões baseado em sinais de EEG. A sequência lógica que é proposta como base fundamental para o método pode ser aplicada para quaisquer conjuntos iniciais de características e canais. Portanto, para verificar a eficácia da proposta, utilizam-se inicialmente os subconjuntos disponíveis em maior conformidade com a literatura para gerar os resultados tidos como referência. Em seguida, a metodologia proposta é aplicada para selecionar a melhor configuração da interface para cada indivíduo e os resultados de ambas as situações são comparados. Para essas análises foi utilizado um banco de dados disponível publicamente, contendo registros de sete pessoas. Depois, com um equipamento de EEG foram registrados sinais de cinco pessoas voluntárias para novas análises visando à aplicação dos algoritmos a uma situação em tempo real.

Os principais objetivos do trabalho são: (1) propor uma metodologia para encontrar características e grupos de canais otimizados para cada indivíduo, a fim de garantir maior precisão no reconhecimento de padrões de pensamento relativos a movimentos imaginários; (2) analisar técnicas comumente utilizadas nos algoritmos de ICM em diferentes pessoas e as especificidades de cada indivíduo e entender a relação entre diferentes partes do algoritmo de uma interface cérebro-máquina e como elas podem afetar o desempenho da classificação.

No âmbito mais prático, o trabalho apresenta um sistema para processamento de sinais de EEG em tempo real utilizando equipamentos portáteis e de baixo custo. O objetivo (3), então, é investigar a capacidade desses equipamentos para uma atividade em tempo real e fazer novas análises referentes ao uso de uma ICM.

O trabalho é dividido em sete capítulos, onde o capítulo 1 é a introdução; o capítulo 2 contém os principais fundamentos teóricos necessários para compreensão do trabalho; o capítulo 3 fornece detalhes das técnicas matemáticas utilizadas nos algoritmos; o capítulo 4 apresenta e valida, com o banco de dados disponível publicamente, o método proposto e uma segunda versão do mesmo; o capítulo 5, visando uma atividade futura em tempo real, apresenta e valida uma adaptação do método utilizando um banco de dados cuja construção faz parte do presente trabalho; o capítulo 6 apresenta um sistema para testes em tempo real e analisa o desempenho do sistema e dos algoritmos nessa condição; o capítulo 7, que é a conclusão, sumariza os principais aspectos do trabalho. No Anexo I, com o intuito de auxiliar na compreensão do trabalho, é apresentado um fluxograma explicativo da estrutura e sequência do trabalho nos capítulos 4, 5 e 6, que tratam da metodologia, resultados e discussão.

2 Fundamentos Teóricos

2.1. Interface Cérebro-Máquina

Diversos problemas podem interromper as vias neuromusculares através das quais o cérebro se comunica com o ambiente externo. Doenças degenerativas, acidente vascular cerebral e lesões medulares são alguns exemplos. As pessoas mais afetadas podem ficar sem nenhum controle muscular remanescente, impossibilitadas de interagirem com outras pessoas e o meio em que vivem (Wolpaw et al., 2002). Uma interface cérebro-máquina pode ajudar essas pessoas que têm pouco ou nenhum controle muscular, ao proporcionar alguma autonomia com formas alternativas de comunicação e controle motor (Kumar e Sahin, 2014).

A ICM é um sistema que permite um ser humano interagir com o meio à sua volta através de sinais de controle gerados no cérebro, sem necessitar da ação de nervos ou músculos periféricos (Nicolas-Alonso e Gomez-Gil, 2012). A interface reconhece a intenção do indivíduo através desses sinais cerebrais. Ao detectar essas atividades em tempo real, a interface é capaz de traduzi-las em uma ação que reflete a intenção do usuário (Yuan e He, 2014; Cincotti et al., 2008). A Figura 2 mostra o esquema básico de uma interface cérebro-máquina.

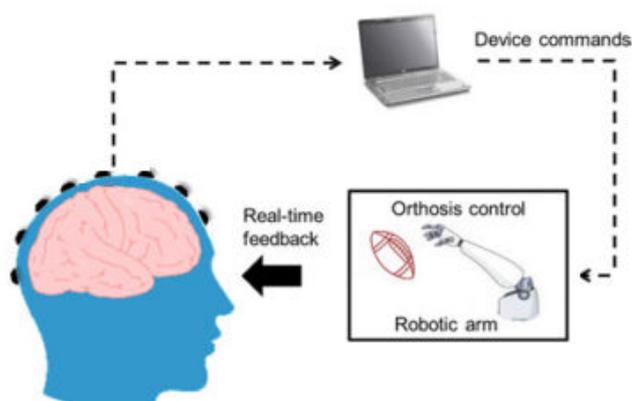


Figura 2 - Modelo esquemático de uma ICM adaptado de Yuan e He (2014).

2.2. Tipos de Interfaces

Existem algumas formas de se classificar as interfaces em função de suas características. As mais usuais são descritas no trabalho e permitem um entendimento acerca de pontos importantes do sistema.

2.2.1. Dependente e Independente

A dependência se refere ao controle motor do indivíduo. Em uma ICM dependente, é necessário algum controle do sistema neuromuscular para estimular o sinal cerebral desejado. Por exemplo, em algumas interfaces dependentes o usuário precisa direcionar o olhar para um determinado local, o que requer controle dos movimentos dos olhos e do pescoço. Uma ICM independente, por outro lado, requer apenas a execução de um pensamento para gerar o sinal de controle (Wolpaw et al., 2002).

2.2.2. Síncrona e Assíncrona

Millán e Mourino (2003) esclarecem que um sistema de interface cérebro-máquina é dito síncrono quando os comandos para alterar de uma atividade mental para outra são reconhecidos somente em janelas bem definidas de tempo. Um sistema assíncrono permite que o usuário decida iniciar ou encerrar uma atividade mental voluntariamente a qualquer momento, de modo que os comandos não são sincronizados com nenhuma atividade do sistema.

2.2.3. Invasiva e Não Invasiva

Essa classificação diz respeito à forma como é medido o sinal. Uma interface invasiva faz a aquisição de sinais a partir de sensores implantados no córtex do indivíduo através de procedimento cirúrgico. Quando o sensor é posicionado no couro cabeludo e não é necessária uma cirurgia, a interface é não-invasiva. Ramadan e Vasilakos (2017) relatam que, geralmente, métodos invasivos fornecem sinais com alta resolução espacial e temporal, de modo que a interface possua alta confiabilidade, precisão e rápida resposta. Contudo, uma vez colocados os sensores, eles não podem ser reposicionados, podem ter seu desempenho comprometido pela formação de tecidos cicatrizantes e,

evidentemente, o método possui o inconveniente de necessitar de procedimento cirúrgico com os riscos inerentes a esse tipo de procedimento. Métodos não-invasivos possuem inúmeras vantagens em termos práticos, mas a qualidade do sinal dificilmente se aproxima dos métodos invasivos em mais de um aspecto simultaneamente. Por exemplo, há métodos com boa resolução espacial, mas resposta temporal lenta e vice-versa. Lebedev e Nicoletis (2017) chamam a atenção para o aspecto da segurança dos métodos não invasivos e colocam esse fator como a principal causa da recorrente preferência por esse tipo de interface em aplicações clínicas, mas ressaltam que sistemas de ICM não invasivos têm seu desempenho comprometido em função dos sinais com qualidade inferior.

2.3. Principais Aspectos de uma ICM

O sistema que compõe a ICM executa os procedimentos de reconhecimento de padrões de pensamento e atuação de um dispositivo por meio de cinco principais etapas: aquisição de sinais, pré-processamento, extração de características, classificação e controle (Khalid et al., 2009).

2.3.1. Aquisição de Sinais e Sinais de Controle

Existem diversas formas de se medir os sinais provenientes da atividade elétrica cerebral. Os principais métodos invasivos são Eletrocorticografia (ECoG), que mede os sinais diretamente no córtex motor e medições intracorticais, cujos sensores são posicionados em estruturas subcorticais (em outras palavras, “dentro” do cérebro). Ambos os métodos medem diretamente sinais eletrofisiológicos (Nicolas-Alonso e Gomez-Gil, 2012; Yuan e He, 2014; Ramadan e Vasilakos, 2017).

Entre os métodos não-invasivos, os mais conhecidos são tomografia por emissão de pósitrons (PET, do inglês *positron emission tomography*) magnetoencefalografia (MEG), ressonância magnética funcional (fMRI, do inglês *functional magnetic resonance imaging*), eletroencefalografia e espectroscopia funcional próxima do infravermelho (fNIRS, do inglês *functional near-infrared spectroscopy*). O PET, fMRI e fNIRS medem respostas metabólicas, MEG e EEG medem sinais eletrofisiológicos por meio do campo magnético e do campo elétrico, respectivamente. Devido ao baixo custo relativo, segurança, portabilidade

e praticidade para aplicações em ICM, EEG é o método mais utilizado. Além disso, possui elevada resolução temporal, na ordem de milisegundos, permitindo ao sistema fornecer repostas rápidas (Wolpaw et al., 2002; Nicolas-Alonso e Gomez-Gil, 2012; Yuan e He, 2014; Naseer e Hong, 2015; Lotte et al., 2015; Ramadan e Vasilakos, 2017).

EEG consiste no registro feito no couro cabeludo da atividade elétrica do cérebro, causada pelo disparo de neurônios que geram diferenças de potenciais na ordem de microvolts (Baillet et al., 2001; Lotte et al., 2015; Ramadan e Vasilakos, 2017). O sistema é composto por eletrodos, amplificador, conversor analógico/digital e um dispositivo de gravação. Os eletrodos adquirem o sinal, o amplificador processa o sinal analógico para que o conversor possa digitalizar o sinal de forma mais precisa e o dispositivo de gravação registra os dados (Nicolas-Alonso e Gomez-Gil, 2012).

Devido à alta impedância no contato entre a pele e o eletrodo, geralmente faz-se necessário um gel ou uma solução salina para um registro mais adequado. Sendo assim, o uso de EEG não é recomendado para períodos ininterruptos muito longos, já que essas substâncias podem secar, comprometendo a qualidade do sinal medido. O EEG é composto por um ou mais canais, sendo cada um responsável pela medição da diferença de potencial elétrico entre o eletrodo ao qual está conectado e um eletrodo de referência. Quando se diz que os canais são monopolares, isso significa que eles possuem o mesmo eletrodo de referência, já canais bipolares possuem eletrodos de referência diferentes. Em alguns casos se faz ainda a média dos potenciais de todos os canais para ser subtraída de cada canal isoladamente. Para evitar interferências de linhas de energia externas, existe o eletrodo terra, que pode ser posicionado em qualquer parte do corpo (Teplan, 2002; Lotte et al., 2015).

Diversos comportamentos dos sinais de EEG já foram observados, bem como a relação deles com os eventos que os originam. São os chamados sinais de controle da interface. Os mais conhecidos são apresentados na sequência.

Potenciais Evocados:

Esses potenciais ocorrem a partir de algum estímulo externo, portanto são geralmente utilizados em interfaces dependentes. Os principais são os potenciais visuais evocados (VEP, do inglês *visual evoked potentials*), os potenciais visuais evocados em regime estacionário (SSVEP, do inglês *steady state visual evoked*

potentials) e o chamado P300. O primeiro ocorre quando o indivíduo percebe algum estímulo visual repentino, o que provoca um aumento considerável na amplitude do potencial medido no córtex visual. O segundo é similar, porém diz respeito a um estímulo constante, como uma letra na tela de um computador piscando a uma frequência específica. Nesse caso deve-se analisar a resposta em frequência e será observada uma elevação na amplitude do sinal na frequência do estímulo. Por fim, o P300 é caracterizado por um pico positivo 300ms após o estímulo, não necessariamente visual. Esses sinais possuem características que favorecem a classificação, porém requerem atenção permanente do usuário aos estímulos e com o tempo os potenciais podem se tornar menos perceptíveis pelo fato de os estímulos se tornarem menos inesperados para o usuário (Wolpaw et al., 2002; Nicolas-Alonso e Gomez-Gil, 2012; Ramadan e Vasilakos, 2017).

Potenciais Relacionados a Eventos:

Diversos tipos de eventos (executar uma tarefa mental, por exemplo) podem provocar alterações na atividade de populações neuronais com comportamento síncrono em fase. Essas alterações provocam mudanças previsíveis no sinal de EEG e são chamadas de potenciais relacionados a eventos (ERP, do inglês *event related potentials*) (Pfurtscheller e Silva, 1999).

Potenciais Corticais Lentos:

Esses potenciais (SCP, do inglês *slow cortical potentials*) ocorrem a uma frequência menor que 1 Hz. São alterações nos potenciais que ocorrem de 0,5 s a 10 s após um estímulo. Um indivíduo pode gerar SCP voluntariamente após um período de treinamento adequado. Esse sinal de controle foi bastante utilizado nas primeiras gerações de interface (Wolpaw et al., 2002; Nicolas-Alonso e Gomez-Gil, 2012; Ramadan e Vasilakos, 2017).

Sincronização/Dessincronização Relacionada a Eventos:

Esse sinal pode ser comparado ao ERP, pois também ocorre durante a realização de uma atividade mental em instantes de tempo geralmente bem definidos. No entanto, o presente sinal de controle (ERS e ERD, do inglês *event related synchronization* e *event related desynchronization*) tem relação com alterações nos níveis de energia em bandas de frequência específicas. O ERS e ERD podem ser vistos como comportamentos gerados a partir de mudanças em um ou mais parâmetros que controlam oscilações em redes neuronais. Geralmente, quando uma área do córtex é ativada, ocorre uma dessincronização, o

que causa a redução da amplitude do sinal na frequência característica da atividade mental. Quando uma área está em atividade espontânea, costuma ocorrer uma sincronização, refletindo em um aumento na amplitude do sinal (Pfurtscheller e Silva, 1999; Pfurtscheller, 2001).

Ritmo Sensório Motor:

O ritmo sensório motor (SMR, do inglês *sensorimotor rhythm*) é um caso particular de ERD e ERS. Quando no domínio da frequência, os sinais de EEG podem ser divididos nas bandas Delta (0-4 Hz), Teta (4-8 Hz), Alfa (8-12 Hz) e Beta (>12 Hz). Sinais da banda Alfa, quando medidos na região do córtex motor e quando associados ao movimento motor real ou imaginário de um indivíduo, recebem o nome de ritmos Mu ou ritmo sensório motor. A presença de ERD na banda Mu indica que a região do córtex está ativa, o que por sua vez indica que há movimento (real ou imaginário) em execução. A situação é inversa quando se observa ERS nessa banda. O sinal na banda Mu costuma estar relacionado a mudanças nos sinais da banda beta entre 18 e 26 Hz (Wolpaw et al., 2002; Nicolas-Alonso e Gomez-Gil, 2012; Ramadan e Vasilakos, 2017).

2.3.2. Pré-processamento

O pré-processamento tem como principal objetivo deixar o sinal o mais próximo possível do sinal emitido pela fonte de interesse e pode variar em função do método de aquisição do sinal. No caso de EEG (caso abordado no trabalho), isso geralmente consiste em um filtro de frequência para selecionar o sinal nas bandas de interesse e também evitar ruídos provenientes de fontes externas de energia, um filtro espacial devido à baixa resolução espacial de EEG, e remoção de artefatos para eliminar sinais oriundos dos olhos e dos músculos.

Os artefatos oculares, por exemplo, podem ter influência nos sinais de EEG a ponto de comprometerem a análise de certos sinais de controle, como relata Lana et al. (2015). Existem diversas técnicas para remover artefatos, mas existem casos em que isso não necessariamente leva a melhorias consideráveis na classificação final do sinal, como demonstrado por Barbosa et al. (2010). O filtro espacial, tema recorrente de muitas pesquisas da área, como são os casos dos trabalhos de Babiloni et al. (2001), Falzon et al. (2012), Vidaurre et al. (2016) e

Yong et al. (2008), é uma importante etapa, pois diz respeito a uma das maiores limitações no uso de EEG, que é a baixa resolução espacial.

Isso significa que um sinal medido em determinado local do couro cabeludo corresponde a uma sobreposição de sinais provenientes de diferentes regiões do córtex. O principal fator responsável por isso é o volume condutor entre o cérebro (fonte do sinal) e o couro cabeludo (região dos sensores). Isso é particularmente ruim no caso de interface cérebro-máquina, pois muitas vezes o sinal de interesse é fraco e provém de uma região bem específica do córtex, enquanto sinais gerados em outras regiões do córtex possuem maior intensidade. Isso representa um desafio maior para a visualização do sinal de interesse. Os problemas são potencializados quando se trata de interfaces que classificam sinais em uma única tentativa (Blankertz et al., 2008). A utilização de uma grande quantidade de eletrodos pode ser uma alternativa para contornar o problema, porém muitas vezes não é suficiente para resolvê-lo completamente (Nunez et al., 1994). Sendo assim, o sinal medido em cada canal, que na realidade é uma mistura de sinais atenuados de mais de uma região do cérebro, deve passar por um processo de filtragem no domínio do espaço. Isso faz com que os sinais sobrepostos sejam isolados uns dos outros (Wu et al., 2015).

Uma das técnicas de filtro espacial que pode ser utilizada nas interfaces cérebro-máquinas é o *common spatial patterns* (CSP). A idéia principal é usar uma transformação linear para projetar dados de EEG de múltiplos canais em subespaços de baixa dimensão com uma matriz de projeção, onde cada linha consiste em pesos para os canais. Essa transformação pode maximizar a variância entre matrizes com sinais de duas classes distintas. O método se baseia na diagonalização simultânea das matrizes de covariância de ambas as classes (Wang et al., 2005). CSP é um método amplamente utilizado em sistemas de interfaces cérebro-máquina no pré-processamento de sinais de EEG (Yong et al., 2008).

Apesar da sua utilidade no pré-processamento, o algoritmo CSP é sensível a *outliers* porque envolve a estimativa das matrizes de covariância. As estimativas clássicas de covariância de amostras são altamente não robustas e têm um ponto de ruptura igual à zero. Os valores atípicos não só afetam as variâncias e a estrutura de correlação das matrizes de covariância, mas também o número de condição das matrizes, que pode crescer até valores muito grandes (o maior autovalor se torna muito grande). *Outliers* podem mudar os autovetores ordenados

e alterar drasticamente o subespaço gerado pelos autovetores. Tal perturbação na orientação dos autovetores tem um impacto sobre as direções de projeção estimadas pelo algoritmo CSP. Não apenas a estimativa das matrizes de covariância, mas também as estimativas de variância das amostras utilizadas na extração das características dos sinais de EEG projetados também são facilmente afetadas por até mesmo um único *outlier* (Yong et al., 2008).

Outra técnica bastante utilizada é a Superfície Laplaciana (SL). O modelo de Superfície Laplaciana para EEG tem se mostrado uma importante ferramenta para análise de EEG. Basicamente o método estima a densidade de corrente radial que entra ou sai do couro cabeludo logo abaixo do eletrodo. A melhora na resolução espacial fornecida por essa técnica independe de quaisquer suposições acerca dos geradores do cérebro, como quantidade de dipolos e suas posições (Carvalhaes e Suppes, 2011). Uma demonstração da interpretação física da superfície Laplaciana é fornecida por Carvalhaes e De Barros (2015), onde os autores deduzem a equação (1).

$$\frac{\partial^2 V}{\partial x^2} + \frac{\partial^2 V}{\partial y^2} = \rho \frac{\partial j_z}{\partial z} \quad (1)$$

Nessa equação, V é a distribuição de potenciais na superfície definida no plano xy , ρ é a resistividade e j_z é a densidade de corrente na direção perpendicular ao plano xy . A equação mostra o quanto a componente normal da corrente varia na direção perpendicular à superfície. No caso do couro cabeludo, isso está associado à presença de uma fonte de corrente dentro do crânio. Para mais detalhes, consultar Apêndice A. O lado esquerdo da equação é definido como a Superfície Laplaciana de V . Ou seja,

$$Lap_s(V) = \frac{\partial^2 V}{\partial x^2} + \frac{\partial^2 V}{\partial y^2} \quad (2)$$

São muitas as maneiras pelas quais esses filtros podem ser calculados. Existem ainda diversas variações dentro de cada técnica. Vidaurre et al. (2016), por exemplo, propõem um método que combina características de ambos os filtros visando obter vantagens específicas de cada um deles.

2.3.3. Extração de Características

Essa é uma etapa de extrema relevância, pois consiste no momento do processamento que talvez seja o mais importante (Falzon et al., 2012), cujo objetivo fundamental é representar o sinal da melhor maneira para facilitar o trabalho de classificação. Para executar essa tarefa, é preciso antes decidir quais são as informações da amostra mais relevantes para que o algoritmo identifique corretamente os padrões de cada classe. Com isso em vista, é importante ter conhecimento dos principais aspectos que diferenciam o sinal de uma classe do sinal da outra.

No caso de EEG, uma das grandes dificuldades para criar algoritmos de reconhecimento de padrões de pensamento passa exatamente por saber selecionar as informações mais apropriadas do sinal, para que ele seja corretamente classificado. Tendo conhecimento do sinal de controle adotado na interface, é possível direcionar os esforços dessa etapa de maneira mais específica para certos aspectos conhecidos do sinal. No entanto, isso não é suficiente para contornar os desafios existentes. Uma das causas dessa dificuldade é o problema da resolução espacial, que ainda não foi superado de maneira satisfatória nos estudos da área, impossibilitando uma leitura mais fiel do sinal gerado no cérebro. Além disso, conforme descrito no primeiro capítulo deste trabalho, já foi constatado na literatura que existe uma variabilidade muito grande entre as características espectro-temporais e de distribuição espacial dos sinais de pessoas distintas referentes ao mesmo pensamento (Blankertz et al., 2007). Isso faz com que uma determinada técnica de extração de características que propicia uma boa classificação do sinal para uma pessoa seja completamente inadequada para os sinais de outra pessoa. Cabe ressaltar que os sinais de EEG em uma ICM costumam ser relativos a vários canais, portanto a escolha daqueles que serão utilizados para extração de características faz parte desse processo. Vidaurre et al. (2016), na tentativa de se classificar dois movimentos imaginários, obtiveram taxas de acertos superiores a 90% e inferiores a 50% para diferentes participantes. Entre 12 sujeitos analisados por Ron-Angevin et al. (2015), seis foram descartados na sessão preliminar de ajuste de parâmetros por não terem atingido 70% de acertos. Ao analisar resultados de quatro indivíduos, Rodriguez-Bermudez et al. (2013) encontraram uma diferença entre o melhor e o pior que chegou a 15

pontos percentuais. Além da conhecida variabilidade interpessoal dos sinais, a capacidade que um indivíduo tem de executar a tarefa mental exigida é diferente para cada pessoa, o que também dificulta a obtenção das características. No trabalho de Filho et al. (2009), alguns sujeitos tiveram que realizar mais sessões experimentais do que outros para produzirem um sinal de EEG de movimento imaginário que fosse detectável, mostrando que a capacidade da pessoa em executar o pensamento solicitado ou a clareza com que a tarefa mental é explicada para a pessoa também interfere na detecção da atividade mental. Isso ilustra ainda que, para uma ICM eficaz, é necessária uma adaptação mútua entre o algoritmo e o usuário.

Dessa forma, o método de escolha das características que serão extraídas dos sinais torna-se um desafio importante no desenvolvimento de uma interface cérebro-máquina. Isso inclui diversos fatores que podem variar em função da abordagem. Por exemplo, tentativas de encontrar características genéricas que atendam a grandes grupos de pessoas pode ser um caminho, enquanto outro possível seria o desenvolvimento de um método adaptativo que se adéqua totalmente ao indivíduo. A abordagem que parece mais promissora é a combinação dessas duas.

2.3.4. Classificação

As características geradas para representar o sinal são utilizadas como entrada para um classificador, que tem como função identificar a qual classe pertence o sinal em questão. Ou seja, é nesse momento que o algoritmo diz que o sinal emitido se refere a um ou outro padrão de pensamento. Para escolher uma técnica de classificação, alguns fatores devem ser levados em conta, como a quantidade de classes existentes e se os dados são linearmente separáveis ou não, pois existem classificadores que separam de forma linear e não linear. Para aplicações em interfaces cérebro-máquina, análise de discriminantes lineares é o método mais utilizado, mas outros como *support vector machines* e redes neurais artificiais são também encontrados em diversos trabalhos (Nicolas-Alonso e Gomez-Gil, 2012).

Uma das dificuldades em se aplicar técnicas estatísticas para reconhecimento de padrões é a grande quantidade de dimensões envolvidas em

muitos problemas. No entanto, é possível reduzir um espaço de d dimensões para apenas uma dimensão ao projetar os dados sobre uma linha. Ao mover essa linha pelo espaço, pode ser encontrada uma orientação em que as projeções fiquem bem separadas em suas respectivas classes. Encontrar essa orientação é exatamente o objetivo do discriminante de Fisher (Duda et al., 2001), técnica de classificação adotada no trabalho.

O discriminante linear de Fisher (FLD, do inglês *Fisher linear discriminant*), consiste basicamente em uma soma ponderada das características, que é obtida com o produto entre o vetor de características e o vetor de projeção. Uma importante vantagem é o pequeno esforço computacional exigido para determinar o vetor de projeção e para efetuar a classificação. Contudo, o FLD considera que as classes são linearmente separáveis e o método só permite separar o sinal em duas classes.

O projeto do classificador baseado nessa abordagem envolve a definição do vetor que caracteriza a reta, a definição do limiar que delimita cada região da reta e a identificação de cada região, para saber a que classe de pensamento pertence cada uma. Alguns trabalhos na área de ICM que utilizam abordagens dessa natureza para projetar o classificador foram realizados por Wolpaw e McFarland (2004), Ron-Angevin et al. (2015), Blankertz et al. (2007), Rodríguez-Bermúdez et al. (2013), Guger et al. (2003) e Wang et al. (2005).

2.3.5. Controle

As interfaces podem ser utilizadas com diversos fins, seja para comunicação, controle ou muitas outras aplicações que vão além (Blankertz et al., 2016). O presente trabalho tem como foco as interfaces voltadas para controle. A parte final do sistema consiste em acionar alguns LEDs por meio de um microcontrolador, onde é realizado o processamento dos dados em tempo real, associado a um eletroencefalograma sem fios, que registra e envia em tempo real os dados para o microcontrolador. Controle de robôs (Millan et al., 2004; Cincotti et al., 2008; Bell et al., 2008; Barbosa et al., 2010; Ron-Angevin et al., 2015; Kim et al., 2015), órteses robóticas (Pfurtscheller et al., 2010; Ortner et al., 2011), próteses robóticas (Muller e Pfurtscheller, 2008) e cadeira de rodas motorizadas (Galan et al., 2008; Choi, 2012; Barbosa et al., 2013) são comumente o foco desse

tipo de ICM. Essas aplicações ainda encontram muitas limitações para serem utilizadas de forma prática pelos usuários finais, entre as quais estão: falta de ergonomia dos equipamentos para aquisição de sinais, dificuldade das interfaces em fornecer múltiplos comandos em um curto intervalo de tempo com a precisão necessária e o esforço e controle mental exigidos do usuário.

3

Técnicas Matemáticas Utilizadas nos Algoritmos

No presente trabalho são desenvolvidos algoritmos para reconhecimento de padrões de pensamentos em uma interface cérebro-máquina independente, assíncrona, não-invasiva e que utiliza sinais de EEG. São apresentadas neste capítulo as técnicas utilizadas em cada etapa dos algoritmos. Cabe ressaltar que, entre os tipos de ICM apresentados, esse é o que representa o maior desafio para obtenção de resultados precisos.

3.1. Pré-processamento – Filtro Espacial

Nos tópicos 3.1.1 e 3.1.2, os dois filtros espaciais utilizados no trabalho são abordados com mais detalhes.

3.1.1. *Common Spatial Patterns*

Neste trabalho o cálculo do filtro CSP foi de acordo com o exposto por Wang et al. (2005) e Müller-Gerking et al. (1999), conforme descrito na sequência.

Sejam V_H e V_F matrizes com dados pré-processados de EEG, cada uma correspondente a dados de uma classe de pensamento em um intervalo de tempo no qual uma tentativa de classificação é realizada. Cada linha das matrizes corresponde a um canal de medição e cada coluna a uma amostra no tempo. A covariância espacial normalizada pode ser representada por

$$R_H = \frac{V_H V_H^T}{\text{trace}(V_H V_H^T)} \quad \text{e} \quad R_F = \frac{V_F V_F^T}{\text{trace}(V_F V_F^T)} \quad (3)$$

A operação $\text{trace}(A)$ calcula a soma dos elementos da diagonal de A . As covariâncias normalizadas médias \bar{R}_H e \bar{R}_F são calculadas através da média entre todas as tentativas de cada grupo. A covariância espacial composta R' pode ser fatorada como

$$R' = \bar{R}_H + \bar{R}_F = U_0 \Sigma U_0^T \quad (4)$$

onde U_0 é a matriz dos autovetores e Σ é a matriz diagonal com os autovalores. A matriz de branqueamento

$$P = \Sigma^{-1/2} U_0^T \quad (5)$$

transforma as matrizes de covariâncias médias em

$$S_H = P \bar{R}_H P^T \quad \text{e} \quad S_F = P \bar{R}_F P^T \quad (6)$$

S_H e S_F compartilham os mesmos autovetores e a soma dos autovalores correspondentes é sempre igual a um.

$$S_H = U \Sigma_H U^T \quad S_F = U \Sigma_F U^T \quad \Sigma_H + \Sigma_F = I \quad (7)$$

Os autovetores com os maiores autovalores para S_H possuem os menores autovalores para S_F e vice-versa.

A projeção de EEG branqueado em U fornece vetores que são ótimos para discriminar entre duas classes. A matriz de projeção W é denotada por

$$W = U^T P \quad (8)$$

Com a matriz de projeção W , o sinal de EEG original V pode ser transformado em componentes não correlacionados

$$Z = W V \quad (9)$$

onde Z pode ser visto como os componentes da fonte do sinal medido, incluindo componentes comuns e específicos de atividades diferentes. O sinal de EEG original pode ser reconstruído através de

$$V = W^{-1} Z \quad (10)$$

As colunas de W^{-1} são padrões espaciais, que podem ser considerados a distribuição de vetores da fonte do sinal de EEG. A primeira e a última coluna de W^{-1} são os mais importantes padrões espaciais que explicam a maior variância de uma atividade e a menor variância da outra atividade.

3.1.2. Superfície Esférica Laplaciana

Para calcular a superfície Laplaciana, muitos pesquisadores utilizam o método de diferenças finitas proposto por Hjorth (1975) e conhecido como método de Hjorth. Esse método assume que a superfície é plana, o espaçamento entre eletrodos é uniforme e eles estão dispostos em uma malha quadrada. A superfície Laplaciana para um nó central (i, j) pode ser aproximada conforme equação (11).

$$\begin{aligned} Lap_s(V)_{(i,j)} &= \frac{\partial^2 V}{\partial x^2} + \frac{\partial^2 V}{\partial y^2} \\ &\approx \frac{V_{(i-1,j)} + V_{(i+1,j)} + V_{(i,j-1)} + V_{(i,j+1)} - 4V_{(i,j)}}{h^2} \end{aligned} \quad (11)$$

onde h é a distância entre dois eletrodos vizinhos. Uma limitação do método de Hjorth é que a segunda derivada espacial é derivada de uma grade de diferenciação discreta, impedindo estimativas não somente na borda da montagem do EEG, mas em qualquer local fora da posição dos eletrodos, já que as estimativas dependem da quantidade e localização dos vizinhos mais próximos. Estes efeitos adversos são agravados pelas características da montagem do eletroencefalograma, como a densidade de eletrodos e a uniformidade de espaçamento (Kayser e Tenke, 2015).

Outra forma de estimar a superfície Laplaciana é através de interpolação ou suavização com *splines* esféricas. Esse método possui as vantagens de não necessitar de uma malha, trabalhar com distâncias arbitrárias entre os eletrodos e poder fornecer estimativas da distribuição Laplaciana em toda a superfície da cabeça (Carvalhaes e Suppes, 2011).

Spline é um tipo de curva muito utilizada para fazer interpolação ou suavização de dados. Dentro do contexto do trabalho, o objetivo é fazer uma suavização com *splines* esféricas para que uma superfície esférica represente a distribuição de potencial no couro cabeludo de forma contínua e suave. Feito isso, é possível achar o Laplaciano dessa superfície, pois ele representa os dados de EEG filtrados no espaço. Na sequência, os cálculos e as explicações são reproduzidos a partir dos trabalhos de Carvalhaes e Suppes (2011) e Carvalhaes e De Barros (2015). Para mais detalhes, consultar as referências citadas e o Apêndice A.

A função *spline* é a solução única para o problema de achar uma função f^* que minimize a equação

$$SS(f^*, \lambda) = \frac{1}{N} \sum (V_i - f^*(\mathbf{r}_i))^2 + \lambda J_m[f^*(\mathbf{r})] \quad (12)$$

onde N é a quantidade de canais, V_i são os potenciais medidos, \mathbf{r}_i são as posições dos eletrodos, λ é o parâmetro de regularização, $J_m[f^*]$ é a medida da rugosidade de f^* em termos de sua derivada parcial de m -ésima ordem (Wahba, 1990 *apud* Carvalhaes e De Barros, 2015) e m , que aparece apenas como um índice na equação (12), é na realidade a flexibilidade do ajuste. Se $\lambda = 0$, então ocorre uma interpolação ($f^*(\mathbf{r}_i) = V_i$), se $\lambda > 0$ ocorre uma suavização dos dados.

A função que minimiza $SS(f^*, \lambda)$, já com o formato apropriado para os objetivos deste trabalho (Wahba, 1981 *apud* Carvalhaes e Suppes, 2011), tem a forma

$$f^*(\mathbf{r}) = \sum_{i=1}^N c_i g_m(\mathbf{r}, \mathbf{r}_i) + \mathbf{d} \quad (13)$$

onde

$$g_m(\mathbf{r}, \mathbf{r}_i) = \frac{1}{4\pi} \sum_{l=1}^{\infty} \frac{2l+1}{l^m(l+1)^m} P_l(\hat{\mathbf{r}} \cdot \hat{\mathbf{r}}_i) \quad (14)$$

e P_l são funções polinomiais de Legendre com uma variável e de grau l . Sua fórmula é dada por

$$P_l(a) = \frac{1}{2^l l!} \frac{d^l}{da^l} [(a^2 - 1)^l] \quad (15)$$

Devido a uma singularidade, é definido que $P_l(1) = 1$. Para calcular os demais valores do polinômio, a equação (16) pode ser utilizada (Meziani, 2017).

$$P_l(a) = \frac{1}{2^l} \sum_{l_0=0}^{l/2} \frac{-1^{l_0} (2l - l_0)!}{l_0! (l - l_0)! (l - 2l_0)!} a^{l-2l_0} \quad (16)$$

Através de notação matricial, as variáveis c_i e d_i , que são os coeficientes que expandem a função $f^*(\mathbf{r})$, equação (13), podem ser expressas como solução do sistema linear

$$\begin{pmatrix} \mathbf{K} + N\lambda \mathbf{I} & \mathbf{T} \\ \mathbf{T}^T & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{c} \\ \mathbf{d} \end{pmatrix} = \begin{pmatrix} \mathbf{V} \\ \mathbf{0} \end{pmatrix} \quad (17)$$

onde $\mathbf{T}_{N \times 1}$ e $\mathbf{K}_{N \times N}$ são dados por

$$(\mathbf{T})_i = 1 \quad (18)$$

$$(\mathbf{K})_{ij} = g_m(\mathbf{r}_i, \mathbf{r}_j) \quad (19)$$

O vetor $\mathbf{V} = (V_1, \dots, V_N)^T$ corresponde aos potenciais medidos em um instante de tempo. O sistema da equação (17) tem a solução formal (Wahba, 1990 *apud* Carvalhaes e De Barros, 2015)

$$\mathbf{c} = \mathbf{Q}_2 [\mathbf{Q}_2^T (\mathbf{K} + N\lambda \mathbf{I}) \mathbf{Q}_2]^{-1} \mathbf{Q}_2^T \mathbf{V} \quad (20)$$

$$\mathbf{R}\mathbf{d} = \mathbf{Q}_1^T (\mathbf{V} - \mathbf{K}\mathbf{c} - N\lambda \mathbf{c}) \quad (21)$$

onde $\mathbf{Q}_1_{N \times M}$, $\mathbf{Q}_2_{N \times (N-M)}$ e $\mathbf{R}_{M \times M}$ são matrizes obtidas a partir da decomposição QR de $\mathbf{T}_{N \times M}$ (equação (22)), que também inclui a matriz nula $\mathbf{O}_{(N-M) \times M}$. No caso de superfície esférica, tem-se que $M = 1$.

$$\mathbf{T} = (\mathbf{Q}_1 \quad \mathbf{Q}_2) \begin{pmatrix} \mathbf{R} \\ \mathbf{O} \end{pmatrix} \quad (22)$$

Para passar do sistema de coordenadas cartesianas para coordenadas esféricas, foi utilizada a convenção mostrada na Figura 3, em que $\theta \in [0, \pi]$ e é medido a partir do eixo z de cima para baixo e $\varphi \in [0, 2\pi]$ e é medido a partir do eixo x no sentido anti-horário.

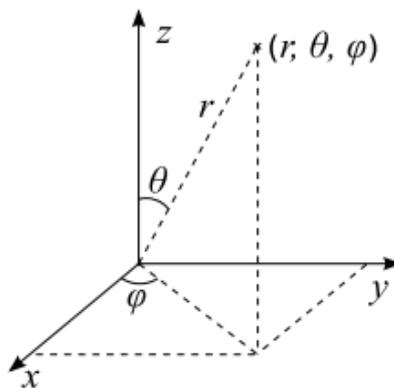


Figura 3 - Sistema de coordenadas esféricas.

A solução para a superfície Laplaciana de $f^*(\mathbf{r})$ é, então, dada por

$$Lap_S(f^*(\mathbf{r})) = -\frac{1}{r^2} \sum_{i=1}^N c_i g_{m-1}(\mathbf{r}, \mathbf{r}_i), \quad m > 1 \quad (23)$$

A equação (23) permite calcular o potencial em qualquer ponto \mathbf{r} arbitrário definido na superfície esférica, a partir dos potenciais medidos em N canais em um dado instante de tempo. No entanto, a fatoração QR permite que se transformem todos os N potenciais medidos através de uma transformação linear, que determina os novos valores em cada posição dos N canais de uma só vez. Para tanto, define-se a matriz \mathbf{C} como

$$\mathbf{c} = \mathbf{C}\mathbf{V} \quad (24)$$

Da equação (20), conclui-se que

$$\mathbf{C} = \mathbf{Q}_2 [\mathbf{Q}_2^T (\mathbf{K} + N\lambda \mathbf{I}) \mathbf{Q}_2]^{-1} \mathbf{Q}_2^T \quad (25)$$

Tem-se também a matriz $\tilde{\mathbf{K}}$, em que til indica que foi aplicado o operador laplaciano, onde

$$(\tilde{\mathbf{K}})_{ij} = -\frac{g_m(\mathbf{r}_j, \mathbf{r}_i)}{r^2} \quad (26)$$

Após alguns procedimentos detalhados no trabalho de Carvalhaes e Suppes (2011), chega-se a

$$\mathbf{L} = \tilde{\mathbf{K}}\mathbf{C} \quad (27)$$

A superfície Laplaciana é dada então por

$$Lap_S(\mathbf{V}) = \mathbf{L}\mathbf{V} \quad (28)$$

Como se vê, $\mathbf{L}_{N \times N}$ não depende dos potenciais medidos. Dessa forma, essa matriz de transformação precisa ser calculada apenas uma vez e depois pode ser aplicada a cada amostra do sinal.

É necessário definir valores para λ , l , r e m . Kayser e Tenke (2015) sugerem valores para esses parâmetros. Para a flexibilidade m , recomenda-se valores de 2 a 6 e, para l , valores acima de 20. Contudo, testes preliminares realizados neste trabalho com os algoritmos mostraram que $m = 5$ e $m = 6$

forneem resultados quase sempre piores que os demais valores, portanto no trabalho m variou de 2 a 4. Também foi visto que $l > 15$ não gerou melhora nos resultados, portanto foi definido $l = 15$. Para λ , os autores ressaltam que o valor ótimo é vinculado ao valor de m e citam o valor 10^{-5} quando $m = 4$, portanto foi definido $\lambda = 10^{-5}$. O raio da cabeça, designado por r , não provocou diferenças consideráveis quando testado com valores entre 0,08 e 0,20. Com isso, foi estabelecido $r = 0,15$ m.

3.1.3. Visualização dos Filtros Espaciais

Com os gráficos da Figura 4 é possível observar como os filtros afetam a distribuição espacial dos potenciais. Os círculos representam os eletrodos projetados em um plano e as cores se referem aos valores dos potenciais, onde os valores máximos e mínimos de cada gráfico assumem as cores amarela e azul indicadas na barra de cores à direita. Os valores utilizados são sinais de EEG registrados em 59 canais e correspondem a médias calculadas ao longo de 4 s nos quais uma pessoa foi orientada a imaginar o movimento da mão esquerda. No caso da SL, um padrão de distribuição ao longo do espaço pode ser notado, onde os maiores potenciais se concentram próximos à linha central quando considerada a direção do eixo x e com uma distribuição suave ao longo da superfície. No caso dos valores sem filtro e com filtro CSP, os potenciais não mostram claramente uma distribuição padronizada. No primeiro caso parece não haver grandes disparidades entre eletrodos próximos entre si, enquanto no caso do CSP podem ser vistos eletrodos relativamente próximos com potenciais perto do máximo e mínimo.

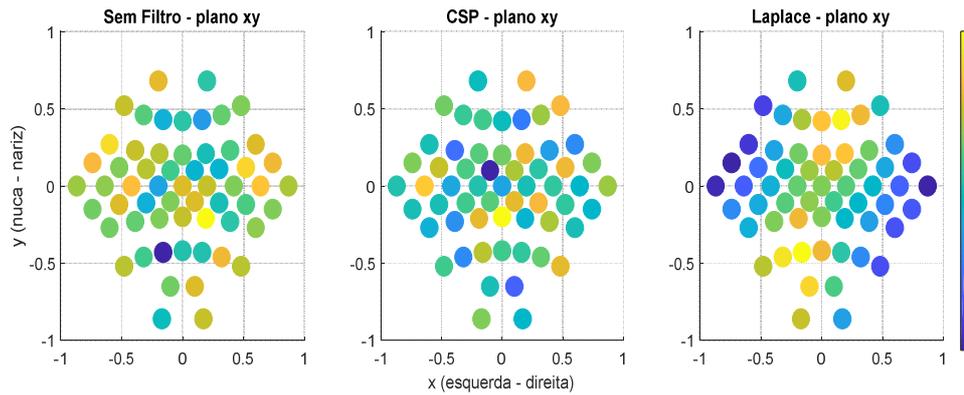


Figura 4 - Distribuição espacial dos sinais de EEG sem filtro, filtrado com CSP e filtrado com SL.

3.2. Extração de Características

As técnicas utilizadas para gerar os elementos do vetor de características do sinal são apresentadas nas seções 3.2.1 a 3.2.4.

3.2.1. Transformada de Fourier

A transformada de Fourier consiste em passar o sinal que está no domínio do tempo para o domínio da frequência. Considerando os sinais de controle ERD/ERS e SMR (seções 3.1.4 e 3.1.5), essa técnica é uma proposta interessante para gerar características relevantes. A transformação foi realizada por meio da transformada rápida de Fourier (no caso do Matlab, a função chama-se *fft*). Janelas podem ser usadas para tornar o sinal no tempo mais adequado à transformação. Neste trabalho foi utilizada a janela *hamming*, equação (29), com esse fim.

$$H[n] = 0,54 - 0,46 \cos(2\pi n/N') \quad (29)$$

O uso de colchetes indica que são pontos discretos, onde n é uma amostra variando de $n = 0$ a $n = N'$, que é o tamanho total do intervalo (Smith, 1997). Os pontos do sinal devem ser multiplicados um a um pelos pontos correspondentes da janela. No algoritmo desenvolvido, a possibilidade de se dividir o intervalo de tempo em dois segmentos de mesmo tamanho para gerar dois espectros separados foi considerada, pois isso contempla um pouco da natureza não estacionária do sinal. Em alguns casos a janela *hamming* pode fornecer melhores resultados se ela

for maior que a janela de tempo e isso foi investigado no trabalho. A Figura 5 ilustra os casos utilizados, onde as figuras na parte superior correspondem aos casos em que o intervalo de tempo inteiro foi utilizado para gerar apenas um espectro, na parte inferior o intervalo de tempo foi dividido em dois, para gerar dois espectros. À esquerda, as janelas *hamming* têm tamanhos iguais aos intervalos de tempo, à direita elas são um pouco maiores que os intervalos de tempo.

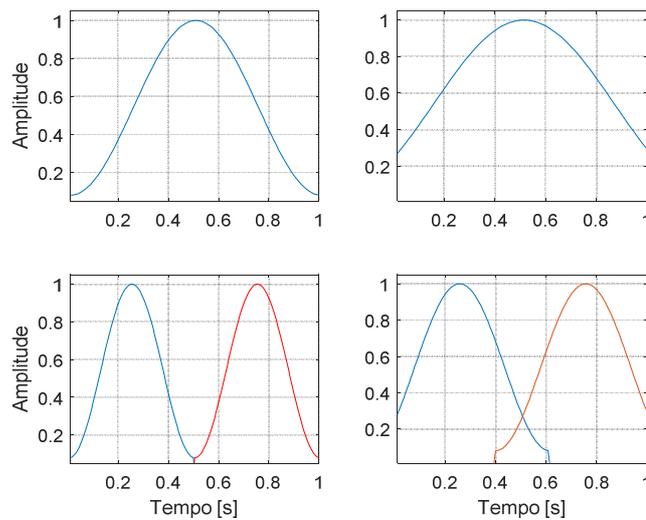


Figura 5 - Exemplos de janela *hamming* ao longo de um intervalo de 1s.

As características utilizadas foram áreas calculadas ao longo do espectro nas bandas de frequência desejadas. Se a banda de interesse vai de f_i a f_f e corresponde às amostras n_i a n_f do sinal em frequência designado pela variável $F[n]$, então a característica γ é calculada conforme a equação (30).

$$\gamma = \sum_{n=n_i}^{n_f} F[n] \times \left(\frac{f_f - f_i}{n_f - n_i} \right) \quad (30)$$

3.2.2. Transformada de Wavelet

A transformada de Wavelet, assim como a transformada de Fourier, passa o sinal para o domínio da frequência, porém preserva algumas informações temporais. Isso permite que seja feita uma análise do sinal no domínio do tempo e da frequência simultaneamente (Badrzadeh et al., 2013). Essa transformada pode ser entendida como uma extensão da transformada de Fourier, em que se trabalha na base de múltiplas escalas (Hazarika, 1997). Neste trabalho foi utilizada a

transformada discreta de Wavelet (DWT, do inglês *discrete Wavelet transform*), calculada com a função *wavedec* no Matlab. O processo consiste em filtrar sucessivamente o sinal para retirar as componentes de diferentes escalas de frequência ao longo do intervalo de tempo, como ilustra a Figura 6.

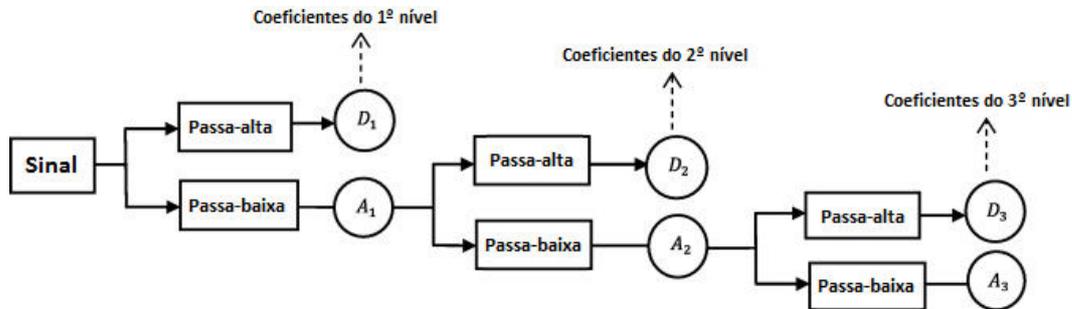


Figura 6 – Sucessivos filtros de frequência para executar a DWT (adaptado de Badrzadeh et al., (2013)).

Se um sinal é digitalizado a uma frequência f_s , primeiramente as componentes do sinal com frequências entre $f_s/4$ e $f_s/2$ são retiradas na forma de coeficientes de detalhes, onde cada coeficiente corresponde a um intervalo de tempo. O restante dos coeficientes correspondem às componentes de 0 Hz a $f_s/4$ e são chamados de coeficientes de aproximação. Em seguida, o sinal abaixo de $f_s/4$ pode ser novamente filtrado para retirar as componentes com frequências entre $f_s/8$ e $f_s/4$, formando novos grupos de coeficientes de detalhes e de aproximação. O processo pode seguir até atingir o nível desejado. A cada nível, a quantidade de coeficientes gerados é menor, bem como o intervalo de frequência correspondente. Sendo assim, cada coeficiente de detalhe do primeiro nível contempla uma faixa de frequência muito grande e um intervalo de tempo muito pequeno e essa relação vai se invertendo a cada nível. A Figura 7 ilustra essa relação.

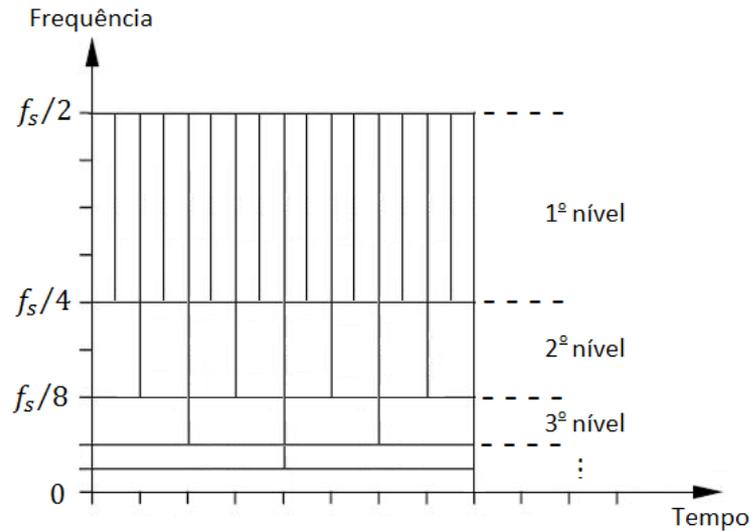


Figura 7 - Análise em tempo e em frequência com DWT, onde a cada retângulo corresponde um coeficiente.

Considerando que cada coeficiente está associado a um intervalo de tempo Δt e um de frequência Δf bem definidos (Figura 7), ele pode ser visto como um paralelepípedo onde as dimensões são exatamente Δt , Δf e o valor do coeficiente. Uma característica γ é calculada como a soma de volumes de paralelepípedos adjacentes em um mesmo nível, conforme equação (31). A quantidade de volumes a serem somados é dada por N_v , enquanto Δt e Δf são constantes dentro de um mesmo nível. Além disso, o produto $\Delta t \times \Delta f$ é igual para todos os níveis, exceto quando se trata dos coeficientes de aproximação. Na equação (31), $coef_\sigma$ é o valor do coeficiente.

$$\gamma = \sum_{\sigma=1}^{N_v} coef_\sigma \times \Delta t \times \Delta f \quad (31)$$

3.2.3. Áreas no Domínio do Tempo

Com essas características pretende-se extrair informações do sinal no domínio do tempo. Sinais como ERP (seção 3.1.2) talvez possam ser detectados com essa análise. O procedimento consiste em calcular a área abaixo do sinal em um intervalo específico de tempo. Se o intervalo de tempo vai de t_i a t_f e corresponde às amostras n_i a n_f do sinal no tempo designado pela variável $S'[n]$, então a característica γ é calculada conforme a equação (32).

$$\gamma = \sum_{n=n_i}^{n_f} |S'[n]| \times \left(\frac{t_f - t_i}{n_f - n_i} \right) \quad (32)$$

3.2.4. Variância no Domínio do Tempo

A utilização dessa técnica ocorre em função do uso do filtro espacial CSP, já que ele consiste em aumentar a variância no tempo de uma classe ao mesmo tempo em que diminui a variância da outra classe. O cálculo da característica γ é dado pela equação (32), em que o intervalo de tempo vai de t_i a t_f e corresponde às amostras n_i a n_f do sinal no tempo designado pela variável $S'[n]$. A média das amostras dentro do intervalo analisado é designada por \bar{S}' .

$$\gamma = \log \left(\frac{1}{(n_f - n_i) - 1} \sum_{n=n_i}^{n_f} (S'[n] - \bar{S}')^2 \right) \quad (33)$$

3.3. Classificação – Fisher Linear Discriminant

O discriminante, que consiste em um vetor de projeção que multiplica o vetor de características, pode ser calculado conforme procedimento descrito por Duda et al. (2001). Os principais cálculos do procedimento são reproduzidos nesse tópico e, ao final, um método para definir o valor do limiar que separa as classes é proposto. Para maiores detalhes a respeito do cálculo do FLD, ver Apêndice B.

Primeiramente deve-se determinar o vetor médio de cada classe. Seja \mathbf{m}_i a média das amostras da classe i (onde $i = 1$ ou $i = 2$), δ_η o vetor de características e N_i o total de vetores de características da classe i , então

$$\mathbf{m}_i = \frac{1}{N_i} \sum_{\eta=1}^{N_i} \delta_\eta \quad (34)$$

Em seguida, as matrizes de dispersão \mathbf{S}_i de cada classe e a matriz \mathbf{S}_W devem ser definidas como mostram as equações (35) e (36).

$$\mathbf{S}_i = \sum_{\eta=1}^{N_i} (\delta_\eta - \mathbf{m}_i)(\delta_\eta - \mathbf{m}_i)^T \quad (35)$$

$$\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2 \quad (36)$$

Com isso, o vetor coluna de projeção pode ser determinado por meio da equação (37).

$$\mathbf{w} = \mathbf{S}_W^{-1}(\mathbf{m}_1 - \mathbf{m}_2) \quad (37)$$

Por fim, só resta calcular o limiar que será usado para definir se o ponto projetado pertence a uma classe ou à outra. No procedimento executado, todos os vetores de características utilizados para gerar \mathbf{w} são projetados com o próprio \mathbf{w} , criando um vetor \mathbf{Y} com os pontos projetados correspondentes a cada vetor de características. Nesse caso, a classe a que pertence cada ponto é conhecida. Vários valores de limiar μ_β igualmente espaçados entre o ponto mínimo e máximo de \mathbf{Y} são testados. Aquele que fornece a melhor separação entre as duas classes é escolhido como o limiar do discriminante. O conjunto de valores μ_β é definido pela equação (38), onde $N^* = N_1 + N_2$ é a quantidade total de vetores de características projetados por \mathbf{w} .

$$\mu_\beta = \min(\mathbf{Y}) + \beta \times \left(\frac{\max(\mathbf{Y}) - \min(\mathbf{Y})}{N^*} \right), \quad \forall \beta \in \{1, 2, \dots, N^*\} \quad (38)$$

A classificação é então realizada por meio das equações (39) e (40), em que μ é o limiar escolhido, $\boldsymbol{\delta}$ é um vetor coluna de características e $\boldsymbol{\tau}_1$ e $\boldsymbol{\tau}_2$ são os conjuntos referentes às classes 1 e 2.

$$\text{Se } \mathbf{w}^T \boldsymbol{\delta} > \mu, \quad \text{então } \boldsymbol{\delta} \in \boldsymbol{\tau}_1 \quad (39)$$

$$\text{Se } \mathbf{w}^T \boldsymbol{\delta} < \mu, \quad \text{então } \boldsymbol{\delta} \in \boldsymbol{\tau}_2 \quad (40)$$

4

Método Proposto

No primeiro momento, a proposta é aplicar um método para selecionar configurações específicas do algoritmo para cada indivíduo, permitindo analisar alguns aspectos fundamentais do algoritmo de reconhecimento de padrões de sinais de EEG relativos a movimentos motores imaginários (MI). Esses aspectos são: filtro espacial, extração de características e conjunto de eletrodos utilizados. Foi desenvolvida, então, uma estratégia a qual foi atribuído o nome “Método de Três Etapas”, por ser composta de três etapas seqüenciais (tópico 4.3). Em função dos resultados obtidos, outra versão do método foi proposta (tópico 4.5). Os métodos permitem, além de avaliar os aspectos mencionados do algoritmo, analisar a variabilidade entre os sinais de pessoas diferentes. Para desenvolver os algoritmos e validar os métodos, foram utilizados dados de EEG disponíveis publicamente (Muller et al., 2008). O tópico 4.1 contém mais informações sobre o banco de dados.

4.1. Banco de Dados

O referido banco de dados contém sinais de EEG de sete pessoas e foram medidos a partir de 59 canais. As pessoas são representadas no decorrer do texto pelas letras A a G. Contudo, as pessoas C, D e E são fictícias, pois os dados foram gerados artificialmente. Os dados de cada pessoa são divididos em dois grupos, sendo um de ajuste de parâmetros do algoritmo (conjunto de ajuste de parâmetros), para criar o classificador e o filtro espacial, e outro para avaliação do algoritmo. Este ainda foi subdividido em duas outras partes, sendo uma (conjunto de testes) utilizada para aplicar os métodos desenvolvidos e outra (conjunto de validação) utilizada para validar os resultados fornecidos pelos métodos.

Cada indivíduo foi orientado a escolher dois entre três movimentos imaginários: movimento dos pés, da mão esquerda e da mão direita. Os dados utilizados para o conjunto de ajuste de parâmetros foram obtidos da seguinte forma: o participante permanecia sentado olhando para uma tela de computador

enquanto era registrada a atividade espontânea de EEG. Durante 2 s não havia nada na tela, depois surgia uma cruz ao centro. Após mais 2 s apenas com essa cruz, uma seta também surgia na tela (apontando para um dos lados ou para baixo) indicando qual MI deveria ser executado. Depois de 4 s a seta desaparecia junto com a cruz e o participante deveria interromper o MI em execução e voltar para a atividade espontânea. Isso se repetiu diversas vezes, variando a direção das setas sem nenhuma sequência específica. O conjunto de dados fornecido para avaliar o algoritmo foi obtido da seguinte forma: um estímulo auditivo indicava o MI a ser executado e a palavra *stop* era pronunciada para indicar a interrupção da atividade mental. A duração de cada atividade pôde variar entre 1,5 e 8 s. Períodos em que nenhum MI foi indicado também tiveram duração entre 1,5 e 8 s. A sequência das atividades mentais indicadas e os intervalos de duração não seguiram nenhum critério específico.

A separação dos dados em três conjuntos tem o objetivo de simular uma situação real em que a ICM seria utilizada. O usuário do sistema deve fornecer alguns dados antes do uso, para que o classificador da ICM possa ser ajustado para essa pessoa e, em alguns casos, o filtro espacial também é construído a partir desses dados. Esses são os chamados dados de ajuste de parâmetros. Mas considerando que a proposta consiste em fazer análises para selecionar as melhores características e os melhores canais, outro conjunto de dados deve ser disponibilizado para realizar essas análises. A esse conjunto foi dado o nome conjunto de testes. Após as análises, o usuário pode, finalmente, utilizar a ICM configurada de acordo com o método proposto. Para simular o momento do uso da interface com as configurações desejadas, foi utilizado o conjunto de validação. Os resultados apresentados ao longo da aplicação dos métodos propostos são obtidos com dados do conjunto de testes, em outros casos, quando apenas algumas configurações específicas de maior interesse são avaliadas após a aplicação dos métodos, eles são obtidos com o conjunto de validação. Todos os momentos em que o conjunto de validação é utilizado são explicitamente comentados no texto.

As Tabelas 1 e 2 informam o tamanho, em segundos, dos conjuntos de ajuste de parâmetros, validação e testes. Para compor os conjuntos, foram considerados apenas os intervalos contínuos e não sobrepostos correspondentes a 1 s. Isto é, se no banco de dados existe um trecho de 1,4 s de um pensamento MI_1 , seguido por 0,9 s de outro pensamento MI_2 , 3,2 s de um pensamento MI_3 e 1,1 s

de MI_1 novamente, então no conjunto correspondente haverá, seguindo a mesma sequência: 1 s de MI_1 , 0 s de MI_2 , 3 s de MI_3 e 1 s de MI_1 .

Tabela 1 - Quantidade de amostras de 1 s do conjunto de ajuste de parâmetros.

Dados	Mão esquerda	Mão direita ou pés	Nenhum pensamento	Total
A - G	300	300	300	900

Tabela 2 - Quantidade de amostras de 1 s dos conjuntos de testes e validação (ambos têm o mesmo tamanho).

Dados	Mão esquerda	Mão direita ou pés	Nenhum pensamento	Total
A	192	198	195	585
B	214	201	195	610
C	200	187	195	582
D	195	182	195	572
E	192	186	195	573
F	182	193	195	570
G	210	208	195	613

4.2. Sistema de Posicionamento dos Eletrodos

Com o objetivo de padronizar a aquisição de dados de EEG, há mais de cinco décadas é utilizado um sistema de posicionamento de eletrodos chamado de 10-20, onde cerca de 20 posições são definidas. Posteriormente, o sistema foi expandido para configurações com cerca de 80 e 320 posições, com os sistemas 10-10 e 10-5 (Jurcak et al., 2007). O posicionamento é definido a partir de marcos anatômicos na cabeça. São eles: *nasion* (Nz), *inion* (Iz) e os pontos pré-auriculares da esquerda e direita (LPA e RPA). Os números 10, 20 e 5 se referem à porcentagem das distâncias definidas entre as marcas. A Figura 8 ilustra os pontos básicos do sistema. A nomenclatura dos pontos para os sistemas estendidos a partir do sistema 10-20 utiliza um critério semelhante ao de pontos cardeais, isto é: as posições entre os eletrodos designados por F e por C, por exemplo, recebem a designação FC (Oostenveld e Praamstra, 2001).

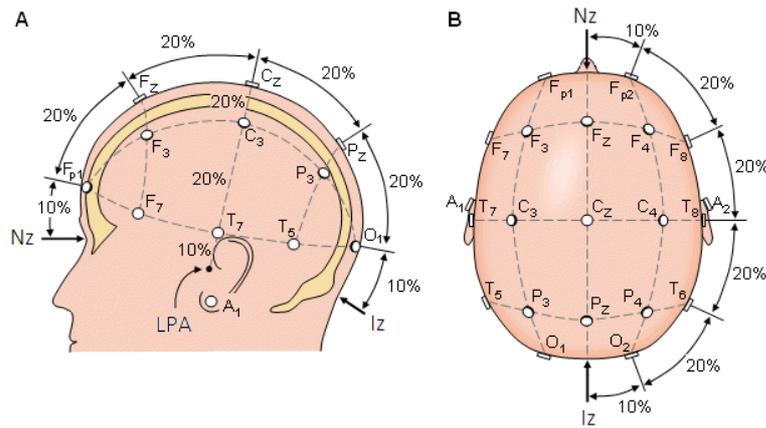


Figura 8 - Sistema 10-20 de posicionamento de eletrodos.

As letras que são usadas para indicar a posição estão relacionadas com a região do córtex imediatamente abaixo, como região frontal (F), parietal (P), occipital (O) e temporal (T). A letra C é utilizada em referência à linha central. Para indicar a posição no sentido LPA-RPA, os números ímpares são usados no hemisfério esquerdo e os pares no hemisfério direito, onde quanto maior o número, mais afastado da linha central está o eletrodo. A linha central *nasion-ion*, por sua vez, é indicada pela letra minúscula 'z'. Os 59 eletrodos utilizados para compor o banco de dados foram posicionados de acordo com esse padrão. As posições utilizadas estão representadas na Figura 9.

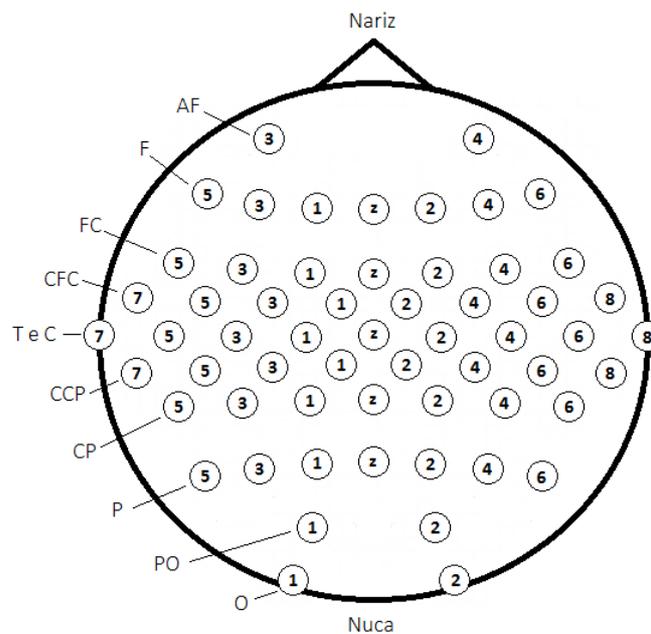


Figura 9 - Eletrodos utilizados para compor o banco de dados.

4.3. Método de Três Etapas

Cada etapa possui objetivos específicos e foi nomeada em função disso. O método foi aplicado separadamente para os dados de cada pessoa. No decorrer do tópico, as etapas são descritas em detalhes. A classificação se deu entre os dois movimentos imaginários escolhidos por cada pessoa. Ou seja, o algoritmo separa os sinais de EEG em duas classes. A Figura 10 mostra um modelo esquemático do método que será descrito em detalhes na sequência.

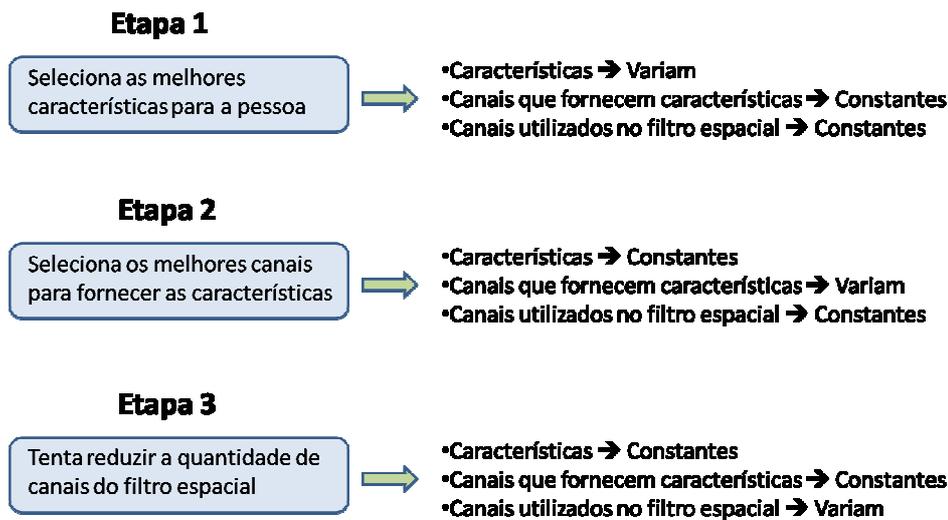


Figura 10 - Modelo esquemático do Método de Três Etapas.

4.3.1. Etapa 1 – Teste das Características

O objetivo dessa etapa é avaliar a eficácia de diferentes tipos de características combinadas com diferentes filtros espaciais e encontrar a forma mais adequada para extrair as características do sinal de cada pessoa. As características foram geradas a partir de cinco conjuntos de informações obtidas em intervalos de 1 s dos sinais de EEG:

1. Coeficientes de detalhes do 2º nível da DWT
2. Coeficientes de detalhes do 3º nível da DWT
3. Coeficientes de aproximação do 3º nível da DWT
4. Espectro de frequência através da transformada rápida de Fourier
5. Sinal no domínio do tempo

Para os conjuntos de 1 a 3 foi utilizada a equação (31) para gerar características. As técnicas utilizadas para gerar essas características foram chamadas de DWT 2, DWT 3 e DWT 3a, respectivamente. Para o conjunto 4 foi

utilizada a equação (30) e a técnica foi chamada de FFT. Para o conjunto 5, as equações (32) e (33) geraram diferentes características e as técnicas foram chamadas de ADT e VDT, respectivamente. Os nomes das técnicas são relacionados às técnicas matemáticas descritas no item 3.3. Assim, foram testadas seis técnicas de extração de características. Cada técnica foi testada em cinco condições diferentes de pré-processamento no domínio do espaço: Superfície Laplaciana com $m = 2$, $m = 3$ e $m = 4$, CSP e sem filtro espacial. Além disso, a quantidade de características a serem extraídas por canal pode variar também, bem como a wavelet mãe quando a DWT foi utilizada. A Tabela 3 ilustra as combinações possíveis, onde db2 e db6 são as wavelets mãe *daubechies* 2 e *daubechies* 6, respectivamente, e ‘db’ seguido por qualquer outro número inteiro obedece a mesma lógica.

Tabela 3 – Combinações possíveis de cada técnica na etapa 1.

Técnica	Características por canal	Wavelet mãe	Filtro espacial	Total de combinações
DWT 2	1 a 5	db2 a db6	Laplace, $m = 2$ Laplace, $m = 3$ Laplace, $m = 4$ CSP Sem filtro	125
DWT 3				125
DWT 3a				125
FFT	1 a 6	-		30
ADT	1 a 8	-		40
VDT	1	-		5

Nessa etapa, sete canais foram escolhidos para fornecerem as características: Cz, C1, C2, C3, C4, C5 e C6. Eles foram selecionados por serem aqueles mais diretamente relacionados ao córtex motor primário (vide Figuras 9 e 12). Todos os 59 canais disponíveis foram utilizados para gerar o filtro espacial. Os procedimentos a serem executados nessa etapa, também representados de maneira esquemática na Figura 11, são:

- Dada uma técnica, experimentar cada condição de pré-processamento e, para cada combinação, experimentar diferentes quantidades de características em cada canal. No caso das características obtidas com DWT, a wavelet mãe também deve variar.
- Gerar um ranking separado para cada técnica em função das taxas de acertos obtidas com as diferentes combinações do item ‘a’. A configuração com maior taxa de acertos dentro de cada técnica é selecionada para os próximos passos.

- c. Eliminar todas as configurações em que a taxa de acertos for menor que 60%, mesmo que seja uma das selecionadas para os próximos passos.
- d. Com as configurações selecionadas e não eliminadas de cada técnica, fazer novo teste combinando de todas as formas possíveis os pré-processamentos, as técnicas de extração de características e as respectivas quantidades de características por canal (e as wavelets, no caso da DWT) de todas as configurações presentes.
- e. Novamente os resultados são ordenados em função das taxas de acertos e a configuração com melhor desempenho é selecionada de forma definitiva para ser utilizada nas etapas seguintes do método, lembrando que a quantidade de características indicada é relativa a cada canal.

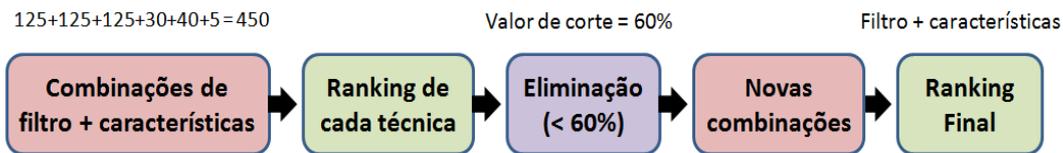


Figura 11 - Procedimentos da etapa 1.

Um exemplo fictício pode contribuir no entendimento dos procedimentos. Para tanto, pode-se imaginar a situação a seguir: extrair três características com a FFT utilizando filtro espacial de Laplace com $m = 4$ foi a configuração selecionada da técnica FFT e obteve mais de 60% de acertos; extrair duas características com ADT sem filtro espacial foi a configuração selecionada da técnica ADT e obteve mais de 60% de acertos; as demais técnicas obtiveram somente acertos inferiores a 60%. Nesse caso, a parte final consiste em considerar todas as combinações possíveis entre zero e 3 características da FFT, zero e 2 características de ADT, filtro de Laplace com $m = 4$ e nenhum filtro espacial. A configuração com a maior taxa de acertos é selecionada definitivamente para as etapas 2 e 3.

Para variar as quantidades de características por canal dentro de cada técnica, os seguintes critérios foram utilizados:

DWT 2, DWT 3, DWT 3a:

Se no nível desejado existem n_{coef} coeficientes e deseja-se n_{car} características, a quantidade de volumes adjacentes N_v a serem somados na equação (31) corresponde à parte inteira da divisão $n_{coef} \div n_{car}$ e eles são somados na sequência temporal.

FFT:

O espectro é dividido em três intervalos que correspondem aos intervalos 0-8 Hz, 8-13 Hz e 13-30 Hz. A segunda e terceira bandas estão associadas à imaginação de movimentos, enquanto a primeira complementa os sinais de maior interesse no EEG, que são aqueles com frequências abaixo de 30 Hz. Quando apenas uma característica é desejada, a segunda banda é a escolhida, seguida pela terceira e primeira banda para os casos em que duas e três características são desejadas, respectivamente. Se a quantidade desejada é entre quatro e seis, o intervalo de tempo é dividido ao meio e dois espectros de frequência são calculados. As três áreas do primeiro intervalo são automaticamente incluídas e da quarta à sexta característica a ordem das bandas do segundo intervalo a serem incluídas é a mesma já mencionada. Em todos os casos a janela *hamming* conta com 25 pontos a mais em cada extremidade da janela de tempo considerada, a fim de evitar excessiva atenuação do sinal no início e fim dos intervalos considerados.

ADT:

O intervalo de tempo é dividido pela quantidade de características desejadas e assim se obtêm os intervalos utilizados para calcular as características com a equação (32).

VDT:

Como a quantidade foi fixa e igual a 1, então a equação (33) foi aplicada a todo o intervalo correspondente a 1s.

4.3.2. Etapa 2 – Seleção de Canais de Características

São chamados “canais de características” os eletrodos de onde são extraídas as características. Um conjunto inicial de 39 canais foi definido, levando-se em conta o córtex cerebral ilustrado na Figura 12 e o posicionamento dos eletrodos, de modo a incluir todos os principais eletrodos capazes de medir a atividade cerebral relacionada aos movimentos imaginários.

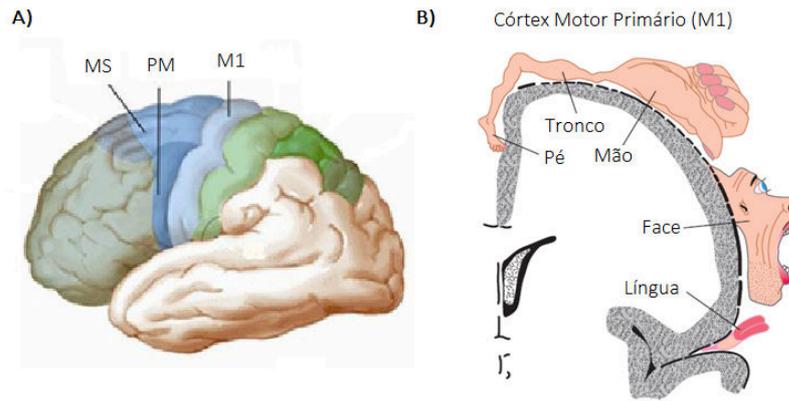


Figura 12 - A) Área motora suplementar (MS), área pré-motora (PM) e área motora primária (M1) (Lent, 2010); B) Homúnculo representado em apenas um hemisfério no corte transversal da área M1 (Squire et al., 2008).

Para gerar o filtro espacial, todos os 59 eletrodos disponíveis foram utilizados. Na Figura 13, os 39 eletrodos selecionados para fornecer características podem ser vistos (coloridos), bem como os demais utilizados somente para o filtro espacial (sem preenchimento).

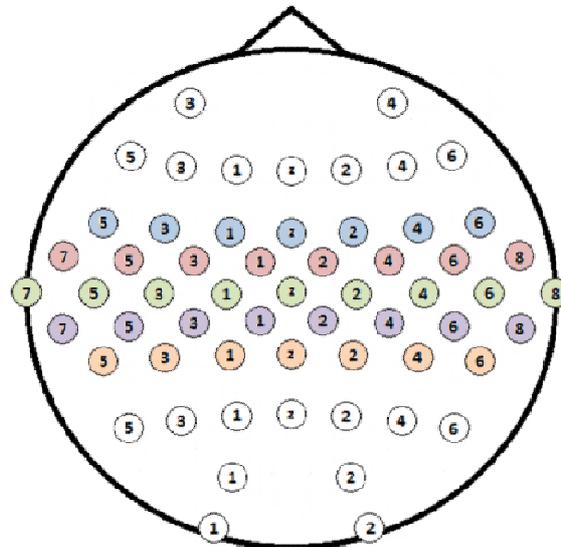


Figura 13 - Canais de características (preenchidos de acordo com a Figura 15) e os demais canais utilizados apenas para o filtro espacial (sem preenchimento).

O processo de seleção dos canais se deu por meio de um procedimento que elimina, um a um, os eletrodos menos importantes para fornecer características para a classificação do sinal. A partir do conjunto inicial de 39 canais de características, um canal é retirado e o algoritmo é testado, em seguida o canal

retorna ao conjunto, outro canal é retirado e o algoritmo testado. Isso é feito com cada eletrodo do conjunto inicial, então o grupo de 38 canais com a maior taxa de acertos passa a ser o novo conjunto de testes, agora com um canal a menos que o conjunto inicial. Por exemplo, se ao retirar o canal C6 a taxa de acertos foi a maior entre todas as tentativas, então C6 é excluído permanentemente, dando origem ao novo conjunto de testes. O procedimento é repetido até restar apenas um canal.

Todas as tentativas têm suas taxas de acertos armazenadas para análises posteriores. A tentativa que fornece a maior taxa de acerto é considerada o conjunto vencedor da etapa. Em caso de igual desempenho, a tentativa com menor quantidade de canais é considerada a vencedora. Ou seja, após essa busca, é possível obter o melhor grupo de canais de características para as características selecionadas na etapa 1.

4.3.3. Etapa 3 – Redução de Canais do Filtro Espacial

Nessa etapa são avaliados os eletrodos que são utilizados exclusivamente para construir o filtro espacial. Isso significa que os canais de características, embora sejam utilizados para construir o filtro espacial, são ignorados nessa etapa. Parte-se do pressuposto de que os eletrodos mais distantes dos canais de características são menos importantes para filtrar os sinais. Sendo assim, foi definido um critério para eliminar um a um os canais exclusivos do filtro espacial. O procedimento inicia com todos os eletrodos disponíveis e a partir disso o processo de redução de canais é aplicado.

O processo começa com a definição de um ponto geométrico central entre os canais de características. Esse ponto foi determinado a partir das posições consideradas para o cálculo da superfície Laplaciana, onde a cada eletrodo foi atribuída uma posição em coordenadas esféricas. Em seguida, a distância de cada eletrodo em relação ao ponto central é calculada. Após testar a interface na configuração inicial, o eletrodo mais distante é eliminado e um novo teste é feito. Isso se repete até restar apenas os canais de características. Também nessa etapa as taxas de acertos são armazenadas para análises posteriores.

4.4. Resultados e Discussão

Com o intuito de se ter um parâmetro para avaliar a metodologia proposta, foram obtidos alguns resultados sem a aplicação da mesma, ou seja, a escolha dos canais e das características foi feita somente a partir de informações encontradas na literatura e não a partir do método apresentado. Embora não haja na literatura um consenso referente à melhor maneira de extrair características, ou ainda as melhores posições para colocação dos eletrodos, é possível notar que, na ausência de métodos adaptativos, é comum a escolha pelos canais na linha central (acima do córtex motor) e por características relacionadas ao ritmo sensorio motor. Exemplos disso são os trabalhos de Millan et al. (2004), Ron-Angevin et al. (2015), Galán et al. (2008) e Wolpaw e McFarland (2004). Sendo assim, a técnica FFT é utilizada para calcular as características nas bandas alfa e beta e as taxas de acertos são calculadas. Separadamente, em outro teste, os níveis dois e três da DWT geram características (bandas 12,5 a 25 Hz e 6,25 a 12,5 Hz, respectivamente). Em todos esses casos foi utilizada Superfície Laplaciana com $m = 4$ como filtro espacial. Além dos canais da linha central, foram testados também os 39 canais selecionados para a etapa 2, a fim de permitir mais comparações. Os resultados são tomados como referência para algumas avaliações no decorrer do trabalho. As Tabelas 4 e 5 mostram as taxas de acertos para os dados de cada pessoa de A a G com dados dos conjuntos de teste e de validação, respectivamente. Nota-se que os valores foram muito baixos, sendo que em alguns casos o valor foi próximo a 50%, o que significa que praticamente não houve classificação. O melhor resultado para cada pessoa está em negrito.

Tabela 4 - Taxa de acertos com dados de teste.

		A	B	C	D	E	F	G
7 canais	FFT	57,95%	49,88%	48,32%	57,03%	67,20%	53,60%	60,34%
	DWT	54,87%	48,19%	52,20%	52,52%	68,78%	52,80%	59,86%
39 canais	FFT	59,23%	55,18%	50,16%	60,48%	65,34%	52,53%	64,18%
	DWT	56,67%	50,60%	51,42%	54,64%	70,63%	53,87%	60,34%

Tabela 5 - Taxa de acertos com dados de validação.

		A	B	C	D	E	F	G
7 canais	FFT	57,69%	51,81%	49,58%	58,36%	70,63%	56,80%	61,48%
	DWT	53,59%	50,36%	52,71%	51,99%	69,58%	57,60%	64,59%
39 canais	FFT	60,51%	51,08%	50,52%	64,19%	68,25%	54,93%	62,68%
	DWT	58,72%	51,02%	51,94%	53,05%	71,69%	58,40%	60,29%

4.4.1. Resultados da Etapa 1

Primeiramente são apresentados os resultados da fase preliminar da etapa 1, onde cada técnica é testada de forma isolada. As Tabelas 6 a 11 correspondem cada uma a uma técnica e nelas estão as configurações com melhor desempenho da técnica para cada banco de dados (A a G). Em vermelho estão as taxas de acertos abaixo de 60%, pois correspondem a configurações eliminadas.

DWT 2:

Tabela 6 – Melhores desempenhos da DWT 2.

Dados	Filtro espacial	Wavelet mãe	Características por canal	Taxa de acertos
A	Sem filtro	db5	5	62,82%
B	Laplace, $m = 2$	db5	1	58,80%
C	Laplace, $m = 3$	db4	1	86,05%
D	Laplace, $m = 3$	db5	1	77,19%
E	Laplace, $m = 2$	db3	1	84,92%
F	Laplace, $m = 2$	db5	1	59,47%
G	Sem filtro	db6	2	72,12%

DWT 3:**Tabela 7 - Melhores desempenhos da DWT 3.**

Dados	Filtro espacial	Wavelet mãe	Características por canal	Taxa de acertos
A	Sem filtro	db3	2	60,70%
B	Laplace, $m = 2$	db2	1	59,76%
C	Laplace, $m = 2$	db5	1	82,43%
D	Sem filtro	db3	2	66,31%
E	Laplace, $m = 2$	db3	1	74,87%
F	Sem filtro	db5	2	58,40%
G	CSP	db3	2	71,39%

DWT 3a:**Tabela 8 - Melhores desempenhos da DWT 3a.**

Dados	Filtro espacial	Wavelet mãe	Características por canal	Taxa de acertos
A	Sem filtro	db4	4	55,13%
B	CSP	db4	3	49,16%
C	Laplace, $m = 4$	db6	4	54,01%
D	CSP	db2	1	51,72%
E	CSP	db5	2	60,85%
F	CSP	db5	5	53,60%
G	Laplace, $m = 2$	db4	4	53,13%

FFT:

Tabela 9 - Melhores desempenhos da FFT.

Dados	Filtro espacial	Características por canal	Taxa de acertos
A	Sem filtro	5	64,36%
B	Laplace, $m = 2$	3	63,61%
C	Sem filtro	2	85,53%
D	Sem filtro	1	79,31%
E	Laplace, $m = 2$	5	84,66%
F	Laplace, $m = 4$	3	55,47%
G	Laplace, $m = 2$	2	71,15%

ADT:

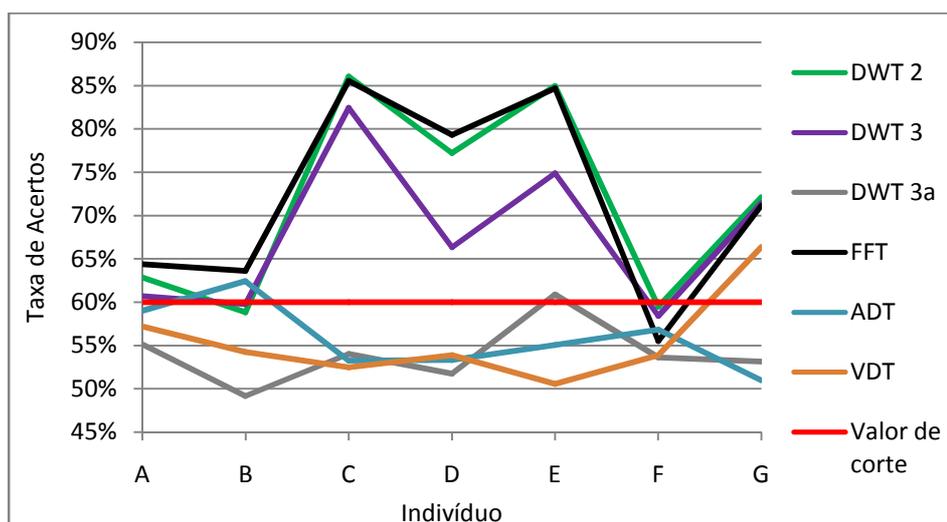
Tabela 10 - Melhores desempenhos da ADT.

Dados	Filtro espacial	Características por canal	Taxa de acertos
A	Sem filtro	5	58,97%
B	Laplace, $m = 2$	1	62,41%
C	CSP	2	53,23%
D	Sem filtro	5	53,32%
E	Laplace, $m = 2$	6	55,03%
F	CSP	3	56,80%
G	Sem filtro	2	50,96%

VDT:**Tabela 11 - Melhores desempenhos da VDT.**

Dados	Filtro espacial	Características por canal	Taxa de acertos
A	CSP	1	57,18%
B	Laplace, $m = 2$	1	54,22%
C	CSP	1	52,45%
D	Laplace, $m = 3$	1	53,85%
E	Laplace, $m = 2$	1	50,53%
F	CSP	1	53,87%
G	Sem filtro	1	66,35%

Pelas Tabelas 6 a 11 se vê que as técnicas que analisam frequências nas bandas alfa e beta apresentaram resultados superiores às outras. A Figura 14 sumariza os resultados mostrados nas Tabelas 6 a 11, onde cada linha da figura corresponde a uma tabela, exceto a linha vermelha que representa o valor de corte igual a 60%. Os valores no eixo vertical são as taxas de acertos e no horizontal são os bancos de dados, cada um de uma pessoa diferente. É possível ver a superioridade da DWT 2 (que corresponde à banda de 12,5 a 25 Hz) e da FFT em relação às demais técnicas.

**Figura 14 - Configurações selecionadas para cada técnica e para cada pessoa.**

Na fase final da Etapa 1, as configurações selecionadas e não eliminadas de cada banco de dados são combinadas para chegar a uma configuração única de

características para cada pessoa. A Tabela 12 contém as configurações selecionadas de forma definitiva para as próximas etapas.

Tabela 12 - Configurações selecionadas de forma definitiva na etapa 1.

Dados	Filtro espacial	Técnicas	Características por canal	Taxa de acertos
A	Sem filtro	FFT	5	64,36%
B	Laplace, $m = 2$	ADT	1	63,86%
		FFT	3	
C	Laplace, $m = 3$	DWT 2, db4	1	86,05%
D	Laplace, $m = 3$	DWT 2, db5	1	84,88%
		FFT	1	
E	Laplace, $m = 2$	DWT 2, db5	1	88,62%
		FFT	5	
F	Laplace, $m = 2$	DWT 2, db5	1	59,47%
G	Laplace, $m = 2$	FFT	2	71,15%

Como era de se esperar, os resultados da etapa 1 mostram uma melhora substancial em relação aos resultados apresentados antes do procedimento usando os mesmos dados (conjunto de testes) e comparando com as mesmas quantidades de canais utilizados. As características selecionadas na etapa 1 foram utilizadas também nos 39 canais e as taxas de acertos com todos os 39 eletrodos fornecendo características encontram-se na Tabela 13. Nesse caso, as características selecionadas com os sete canais também se mostraram mais eficazes em seis, dos sete casos. A exceção foi a pessoa C, porém os resultados nesse caso foram todos muito próximos de 50%. Além disso, os dados de B e F ainda obtiveram acertos inferiores a 60%.

Tabela 13 - Resultados obtidos com os 39 canais de características.

A	B	C	D	E	F	G
62,31%	58,80%	51,68%	67,11%	81,22%	59,20%	72,36%

Esses resultados mostram a variabilidade dos sinais de EEG das pessoas em questão. As configurações selecionadas não se repetiram para nenhum indivíduo e as taxas de acertos variaram entre 59,47% e 88,62%. No entanto, algumas tendências nos resultados dos diferentes bancos de dados podem ser observadas.

Por exemplo, dois aspectos sugerem que a FFT foi superior às demais técnicas. Primeiro, ao analisar as configurações selecionadas de cada técnica, a FFT obteve uma média de 72,01% e apenas um resultado eliminado (abaixo de 60%), enquanto a segunda e terceira melhores médias foram 71,62% e 67,69% para DWT 2 e DWT 3, respectivamente e com dois resultados abaixo de 60% para cada. Segundo, nas técnicas de extração de características das configurações selecionadas de forma definitiva, a FFT esteve presente em cinco casos contra quatro da DWT 2 e um da ADT.

No tratamento no domínio do espaço, apenas para a pessoa A não foi utilizado um filtro espacial entre as configurações selecionadas de forma definitiva. Interessante observar que para essa pessoa o filtro só foi utilizado na técnica VDT, onde o filtro CSP foi selecionado. Como o CSP se baseia exatamente nas variâncias das classes, era esperado que ele fosse mais eficiente com a técnica VDT. O filtro CSP não esteve presente entre as configurações selecionadas de forma definitiva, enquanto Laplace foi selecionado nos seis casos além de A, sendo quatro vezes com $m = 2$ e duas vezes com $m = 3$. A ineficiência do filtro CSP possivelmente tem relação com a presença de artefatos no sinal analisado, pois como explicado no item 3.2.2, o cálculo do filtro é altamente sensível à presença de *outliers*.

É interessante observar que, para os dados de B, D e E, a combinação de mais de uma técnica promoveu melhora nos resultados. Quando cada técnica é testada isoladamente, o discriminante de Fisher encontra a direção no espaço n -dimensional que melhor separa os vetores de características da respectiva técnica. As direções para dois tipos de características diferentes, que podem inclusive formar vetores de características em espaços com dimensões distintas, não possuem necessariamente nenhuma relação, mesmo se tratando do mesmo sinal de origem. Todavia, a etapa 1 mostrou que em três dos sete casos a estratégia de combinar técnicas de características contribuiu na busca por classificações mais precisas.

Na tentativa de reduzir o universo de buscas em versões futuras do método, é razoável considerar o filtro de Laplace como a técnica mais importante para o tratamento no domínio do espaço e a FFT e DWT 2 como técnicas mais importantes para extração de características. Além disso, nas configurações selecionadas de forma definitiva pode ser visto que poucas características por

técnica foram utilizadas, de maneira geral. No caso da DWT 2, foi utilizada somente uma característica por canal, para a FFT foram cinco no caso de A e E e três ou menos nos demais. A técnica ADT, que apareceu somente uma vez, forneceu uma característica por canal.

4.4.2. Resultados da Etapa 2

Para facilitar a visualização dos resultados dessa etapa, nas Figuras 16 a 21 foram atribuídas cores relacionadas à posição dos canais, conforme mostra a Figura 15.

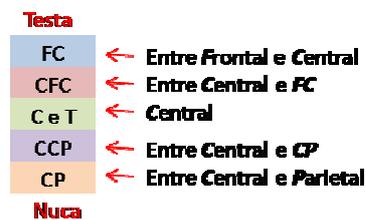


Figura 15 - Cores e posições dos canais.

Após realizar a etapa 2, é possível ver o melhor grupo de canais de características com qualquer quantidade de canais entre um e 39, de acordo com a metodologia proposta. São apresentados, para cada indivíduo, os resultados com a maior taxa de acertos e o melhor resultado quando apenas sete canais são utilizados para fornecer características. Este último foi representado para fins de comparação com os sete canais escolhidos arbitrariamente para executar a etapa 1. A Figura 16 informa a letra correspondente à pessoa, as partes do corpo cujos movimentos foram imaginados (onde ME e MD significam mão esquerda e direita, respectivamente, e P significa pés), a taxa de acertos da configuração vencedora e os canais pertencentes à configuração, onde a cor representa as letras (Figura 15) e o número da posição está escrito na célula. Nessa figura e na Figura 19, a posição de cada uma das três colunas que contém os nomes dos canais indica se eles estão posicionados no hemisfério esquerdo, direito ou na linha central da cabeça.

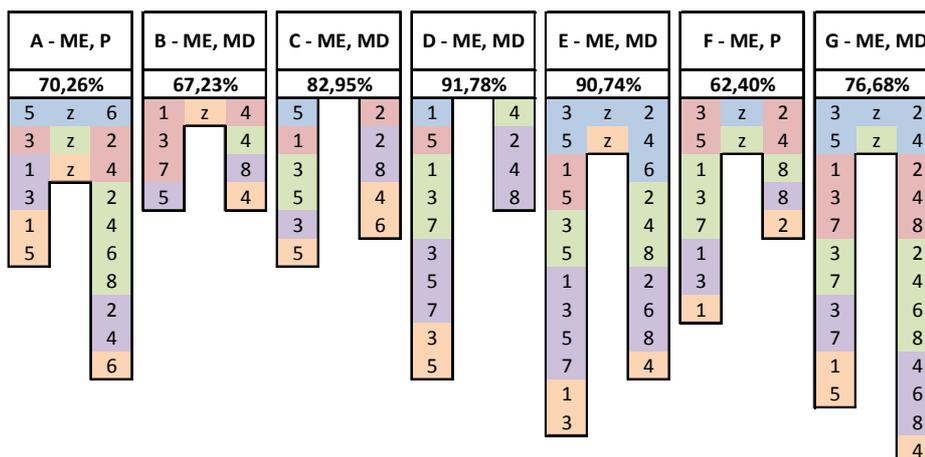


Figura 16 - Configurações vencedoras da etapa 2.

A melhor configuração obtida para cada pessoa previu melhoras em relação aos resultados da etapa 1, com aumentos entre 2,12 e 6,90 pontos percentuais para todas as pessoas, exceto pessoa C, onde houve uma piora de 3,10 pontos percentuais. A quantidade de canais utilizados variou de nove (pessoa B) a 26 (pessoa G).

A Figura 17 mostra a incidência de cada canal nas configurações vencedoras. Como pode ser visto, nenhum canal esteve presente em todas as melhores configurações. Contudo, os canais CCP3 e CCP8 estiveram em seis, dos sete casos, seguidos por C3 e C4, que estiveram em cinco, dos sete casos. Tendo em vista que em nenhum caso os MIs escolhidos foram referentes ao mesmo lado do corpo e, entre os quatro canais mencionados, existem dois para cada hemisfério e as posições são bem próximas do córtex motor primário (vide Figura 12), esse resultado se mostra coerente. O canal CFC6 foi o único que não apareceu entre as melhores configurações.

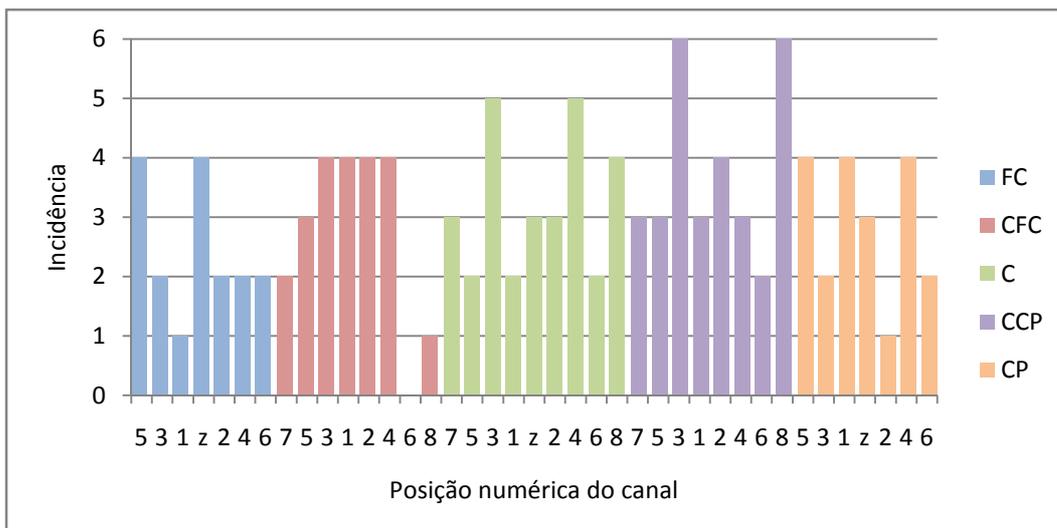


Figura 17 - Incidência de cada canal nas configurações vencedoras da etapa 2.

O gráfico da Figura 18 mostra a incidência relativa dos canais de cada linha de posição determinada pelas letras FC a CP. Isto é, ela mostra a incidência de cada linha nas configurações vencedoras, porém considerando que algumas têm maior probabilidade inicial, pois têm mais eletrodos. Dessa forma, a quantidade total de eletrodos presentes de cada linha foi dividida pela quantidade de vezes que ela poderia ter aparecido. A linha central, por exemplo, possui nove eletrodos, portanto ela poderia ter aparecido nove vezes para cada um dos sete indivíduos, totalizando 63 possibilidades. Como ela esteve presente 29 vezes, o valor representado é a razão, em porcentagem, entre 29 e 63. A expectativa era de que a linha central fosse mais importante, porém os valores mostram que a linha CCP foi superior. As duas linhas mais frontais tiveram as menores incidências, sendo que a mais frontal entre elas obteve o pior resultado. Uma possível causa para isso é a presença de artefatos provenientes dos olhos nessa região.

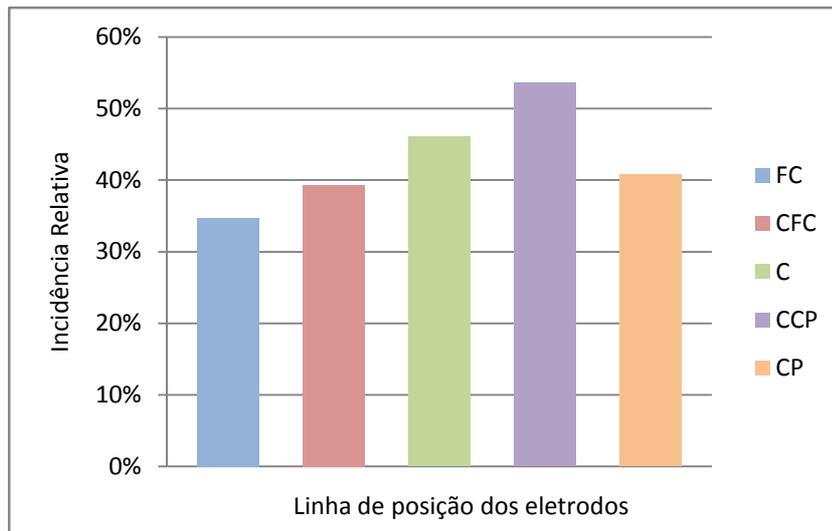


Figura 18 - Incidência de cada linha de posição nas configurações vencedoras da etapa 2.

A Figura 19 mostra o melhor grupo com apenas sete canais obtidos com a etapa 2. O grupo com os melhores sete canais de cada pessoa foi obtido para fins de comparação com os resultados da etapa 1 e com os resultados antes dos procedimentos.

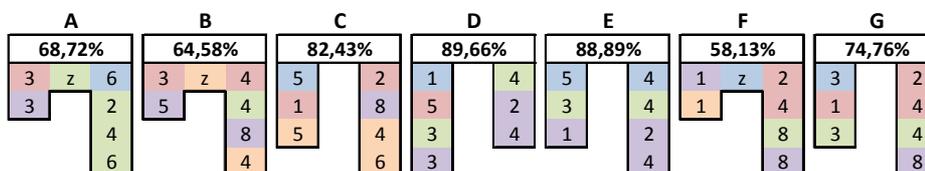


Figura 19 - Melhores sete canais.

Quando comparados aos sete canais da etapa 1, os aumentos ficaram entre 0,27 e 4,78 pontos percentuais, exceto para C novamente e F, onde houve pioras de 3,62 e 1,34 pontos percentuais. Quando comparados aos resultados antes dos procedimentos com dados de teste, o menor aumento foi de 4,53 (pessoa F), seguido por 10,77 (pessoa A) e chegando a 32,63 pontos percentuais (pessoa D). A incidência de cada canal é mostrada na Figura 20. Dessa vez, C4 foi o que esteve mais presente, seguido por CCP8, depois C3, CFC2 e CFC4.

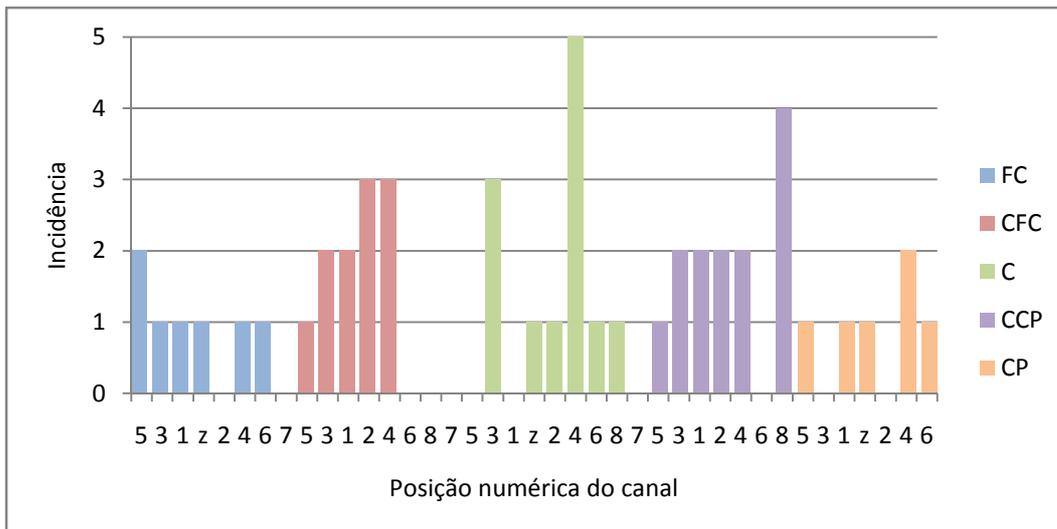


Figura 20 - Incidência de cada canal nos melhores grupos com sete canais da etapa 2.

A Figura 21 mostra a incidência relativa de cada linha de posição. Nesse caso, a diferença para o gráfico da Figura 18 ocorreu nas linhas das regiões mais frontais, pois as linhas FC e CFC foram superiores à linha CP, sendo que CFC foi superior também à linha central. Partindo da hipótese já mencionada de que a região mais frontal entre as selecionadas é mais suscetível aos artefatos oculares, esse resultado pode ser indício da relevância dessa região quando não corrompida por esse problema. Ou seja, os canais dessa região que foram menos afetados pelos artefatos são importantes para a classificação dos MIs.

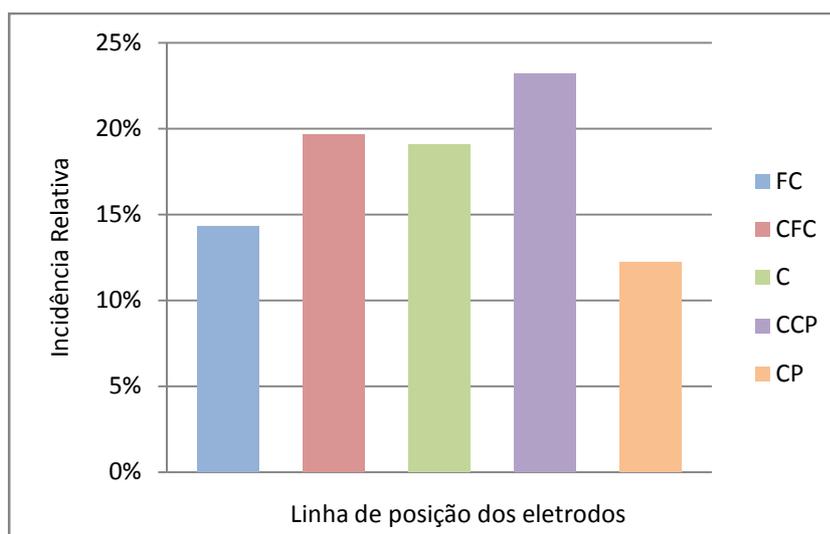


Figura 21 - Incidência de cada linha de posição nos melhores grupos com sete canais da etapa 2.

A Figura 22 mostra o resultado para o melhor grupo de canais de características com quantidades variando de 39 canais a um. O eixo vertical corresponde à taxa de acertos e o horizontal à quantidade de canais que forneceram características. A imagem mostra que nos dois extremos, à esquerda e à direita, as taxas de acertos tendem a diminuir. Isso sugere que, para as características selecionadas na etapa 1, uma grande quantidade de canais inclui nos vetores de características informações que dificultam a classificação do sinal registrado. Pequenas quantidades, inferiores a sete, perdem informações importantes para a classificação. Na figura ainda é possível notar a superioridade dos resultados das pessoas E e D em relação às demais, seguidos pelos resultados de C e G. Nenhum resultado acima de 75% foi obtido com A, B e F, revelando assim uma dificuldade consideravelmente maior para o reconhecimento de padrões nesses casos com as técnicas utilizadas.

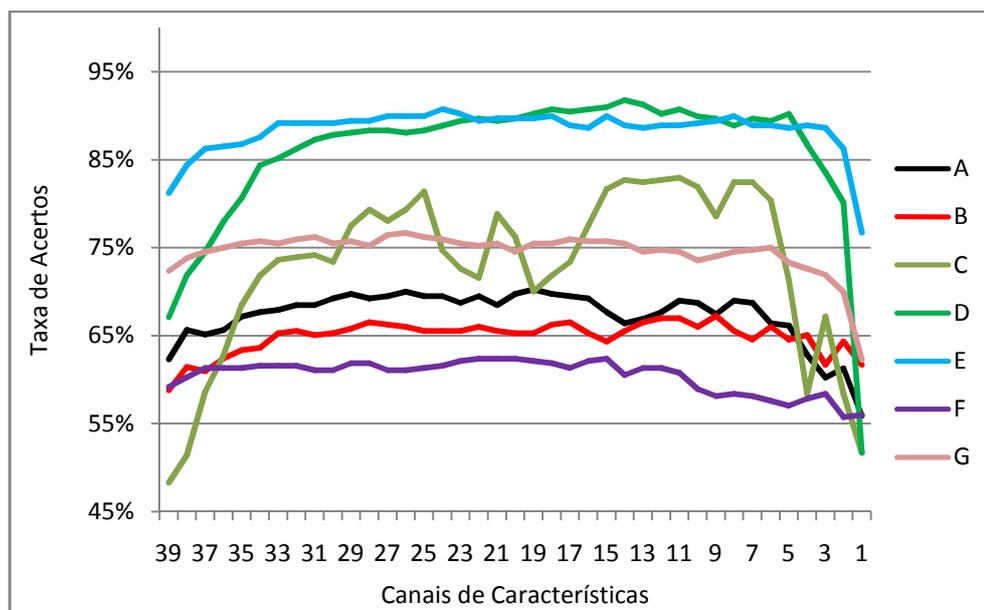


Figura 22 - Melhores taxas de acerto para cada quantidade de canais características variando de 39 a 1.

4.4.3. Resultados da Etapa 3

Os resultados apresentados nesse tópico correspondem às situações que obtiveram as melhores taxas de acertos na etapa 2. Isto é, a eliminação de canais que são utilizados exclusivamente para o filtro espacial foi aplicada para os canais de características ilustrados na Figura 16. A Figura 23 foi dividida em duas partes com o intuito de facilitar a visualização dos resultados, que poderia ser

prejudicada pela quantidade de linhas sobrepostas. Não foi aplicada a etapa 3 para os dados da pessoa A, pois não foi utilizado filtro espacial nesse caso.

Pode ser visto na figura que as taxas de acertos variaram de forma imprevisível e bastante particular para cada banco de dados. A expectativa era de que os resultados piorassem, pois como descrito por Babiloni et al. (2001), a Superfície Laplaciana de dados eletroencefalográficos eleva a resolução espacial em função da quantidade de eletrodos utilizados. No entanto, para os indivíduos B, F e G houve melhora em relação ao resultado da etapa 2 com quantidades específicas de canais. Esse comportamento irregular das curvas pode ser atribuído à maneira como o filtro é projetado, pois inclui uma suavização dos dados com *splines* esféricas. Portanto, a forma com que o sinal de um eletrodo afeta essa suavização está relacionada ao cálculo das *splines*.

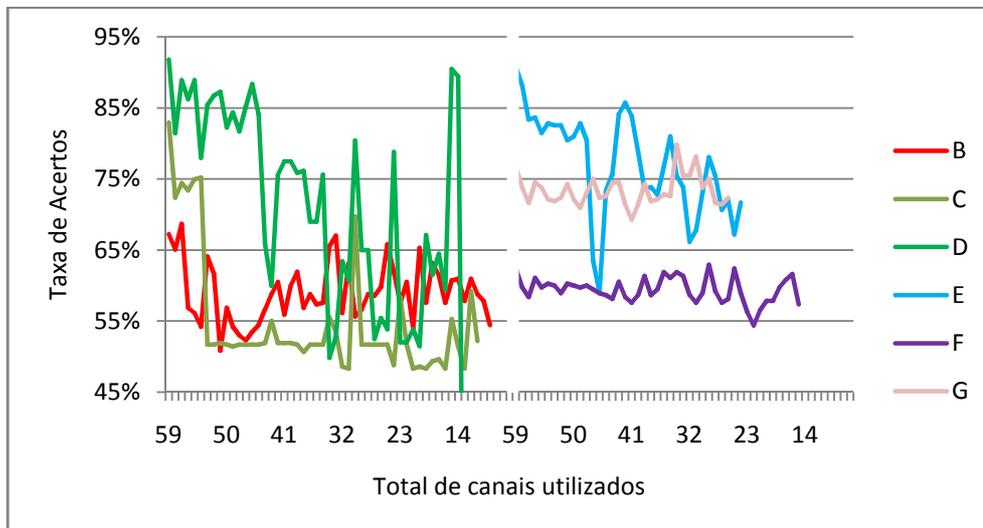


Figura 23 - Taxas de acertos obtidas durante execução da etapa 3.

Os casos em que a etapa 3 previu melhora nos resultados estão na Tabela 14. Na tabela, o traço horizontal indica que não houve previsão de melhora e o total de canais inclui tanto os de características, quanto os exclusivos do filtro espacial. Somente está representada a melhor configuração de cada pessoa.

Tabela 14 - Situações em que a etapa 3 previu melhora nos resultados.

	A	B	C	D	E	F	G
Total de canais	-	57	-	-	-	29	34
Taxa de acertos	-	68,67%	-	-	-	62,93%	79,81%

Uma importante observação em relação ao comportamento inesperado das curvas de acertos é que esses resultados não validam, tampouco rejeitam a premissa inicial de que eletrodos mais distantes dos canais de características são menos importantes no filtro espacial. Isso ocorre porque a distância dos eletrodos foi calculada em relação a um ponto médio entre os canais de características, de forma que um eletrodo exclusivo do filtro espacial pode estar muito distante desse ponto médio, mas extremamente próximo de um ou mais canais de características.

4.4.4. Resultados de Validação

A Tabela 15 mostra os resultados para as configurações em que não houve nenhum processo de seleção de canais. Ou seja, são os 39 canais de características da etapa 2 e os sete canais utilizados na etapa 1. Em ambos os casos, o único procedimento executado foi o teste das características da etapa 1, já que os canais foram escolhidos arbitrariamente em função de informações da literatura. Nesse caso, quando comparados aos resultados antes da etapa 1, as taxas de acertos foram melhores para todas as pessoas. No entanto, alguns resultados foram abaixo de 60% (pessoas B e F). Isso significa que, embora tenham melhorado, continuam com resultado pouco significativo para validar o método nesses casos.

Tabela 15 - Validação com configurações obtidas na etapa 1.

	A	B	C	D	E	F	G
7 canais	61,54%	52,57%	83,98%	81,70%	79,63%	59,20%	73,21%
39 canais	61,78%	54,70%	52,32%	68,44%	77,78%	59,13%	73,68%

A Tabela 16 mostra os resultados de validação após executar todos os procedimentos do Método de Três Etapas. Nesses casos, a etapa 3 previu melhora para as pessoas B, F e G. Portanto, nessas situações não são utilizados todos os 59 canais para gerar o filtro espacial. No caso dos sete melhores canais, a etapa 3 não foi aplicada. A seleção de canais provocou melhora nos resultados com todos os bancos de dados exceto C, como o método já havia previsto. Com os dados de C, D e E os resultados para os sete melhores canais foram superiores aos resultados do melhor grupo, porém isso não constitui grande surpresa, já que as diferenças entre os resultados previstos para o melhor grupo e os melhores sete foram pequenas diante da variação dos resultados quando são utilizados os dados de

teste e de validação. Em termos gerais, a seleção de canais se mostrou útil para melhorar a classificação.

Tabela 16 - Validação com as configurações obtidas por meio das três etapas.

	A	B	C	D	E	F	G
Melhor	64,62%	59,52%	79,07%	85,15%	84,92%	62,40%	80,86%
Melhores sete	64,62%	58,31%	79,59%	86,21%	86,77%	56,00%	76,79%

4.5. Método de Duas Etapas

Uma segunda versão do Método de Três Etapas foi proposta e batizada de Método de Duas Etapas, pois não conta com a etapa 3 do método anterior, além de contar com uma nova versão da etapa 1. O objetivo é refinar as buscas, concentrando os esforços nos procedimentos mais eficientes. A etapa 2 permaneceu a mesma da primeira versão, portanto não é detalhada nesse tópico. Os resultados da etapa 2, porém, estão devidamente representados.

4.5.1. Etapa 1 – Teste das Características v2

O final “v2” que aparece no título e após algumas palavras no texto subsequente indica que se refere à segunda versão. Nesse caso, uma nova versão da FFT, chamada de FFT v2, e a DWT 2 com menos opções de busca foram utilizadas para gerar as características. A FFT v2 permitiu variar o tamanho da janela *hamming* utilizada, a quantidade de características e quantidade de janelas em que o intervalo de 1 s foi dividido. As Tabelas 17 e 18 mostram o novo cenário da etapa 1, onde p é a quantidade de pontos da janela de tempo considerada. Além disso, essa etapa foi calculada com os mesmos sete canais de características da primeira versão e também com os 39 canais da etapa 2. No pré-processamento, somente a SL com flexibilidade igual a dois ou três foi considerada e também a não utilização de filtro espacial.

Tabela 17 - Buscas realizadas com a FFT v2 na segunda versão do método.

Técnica	Características por canal	Tamanho da janela <i>hamming</i>	Janelas de tempo	Filtro espacial	Total de possibilidades
FFT v2	1 a 9	1,0xp 1,2xp 1,4xp 1,6xp 1,8xp 2,0xp	1 a 2	Sem filtro Laplace, $m = 2$ Laplace, $m = 3$	324

Tabela 18 - Buscas realizadas com a DWT 2 na segunda versão do método.

Técnica	Características por canal	<i>Wavelets</i>	Filtro espacial	Total de possibilidades
DWT 2	1 a 2	3 a 7	Sem filtro Laplace, $m = 2$ Laplace, $m = 3$	54

As mesmas equações continuaram a ser utilizadas para calcular as características. No entanto, ao variar a quantidade de características na FFT v2 a lógica foi diferente da apresentada na primeira versão, a saber: quando somente uma janela de tempo é utilizada, a quantidade de pontos do espectro de frequência é dividida pela quantidade desejada de características e, analogamente ao caso da ADT na primeira versão, as áreas são calculadas. Quando o intervalo de tempo é dividido em dois e a quantidade de características é par, cada espectro fornece metade das características, que são calculadas da mesma forma que no caso anterior. Para quantidades ímpares faz-se o cálculo para a quantidade par imediatamente anterior e acrescenta-se a soma das áreas totais de cada espectro.

4.6. Resultados e Discussão

4.6.1. Resultados da Etapa 1

Na Tabela 19 podem ser vistos os detalhes das configurações selecionadas da FFT v2 com sete canais e com 39 canais, onde p é a quantidade de pontos da janela de tempo considerada. A divisão do intervalo de tempo em duas janelas só foi utilizada nas configurações selecionadas das pessoas C e G com sete canais e

B e F com 39 canais. O tamanho da janela *hamming* variou bastante, dificultando a escolha de um intervalo menor de buscas para uma futura versão dessa etapa. A menor quantidade de características foi igual a quatro e ocorreu somente para a pessoa E, tanto com sete, quanto com 39 canais. Os dados de A não utilizaram filtro espacial em nenhum dos dois casos e o mesmo ocorreu com D com 39 canais. Quando o filtro SL foi utilizado, a flexibilidade m não apresentou nenhum valor mais recorrente de forma significativa. Foi observada uma superioridade dos resultados quando sete canais de características foram utilizados, onde apenas o resultado do indivíduo A foi inferior quando comparado ao resultado com 39 canais.

Tabela 19 - Detalhes das configurações selecionadas da FFT v2.

	Dados	Filtro espacial	Janelas de tempo	Tamanho da janela <i>hamming</i>	Características por canal	Melhor resultado
7 canais	A	Sem filtro	1	$2xp$	7	65,38%
	B	SL, $m = 2$	1	$1,4xp$	9	65,78%
	C	SL, $m = 3$	2	$1,2xp$	9	68,48%
	D	SL, $m = 2$	1	$1,4xp$	8	89,66%
	E	SL, $m = 2$	1	$1,6xp$	4	86,51%
	F	SL, $m = 3$	1	$1,4xp$	9	62,40%
	G	SL, $m = 2$	2	$2xp$	7	70,67%
39 canais	A	Sem filtro	1	$2xp$	7	69,23%
	B	SL, $m = 3$	2	$1,4xp$	5	63,61%
	C	SL, $m = 3$	1	$1,2xp$	7	66,41%
	D	Sem filtro	1	$1,4xp$	8	67,64%
	E	SL, $m = 2$	1	$1,8xp$	4	83,86%
	F	SL, $m = 3$	2	$1xp$	7	59,73%
	G	SL, $m = 2$	1	$1,8xp$	5	67,55%

Na Tabela 20 estão as configurações selecionadas da DWT 2. Parecido com o que ocorreu no caso da FFT v2, os dados de A não utilizaram filtro espacial com sete canais e o mesmo também ocorreu com os dados de G com sete e 39 canais. Dessa vez, os resultados com 39 canais foram superiores, com exceção dos dados de C e E. Todas as *wavelets* apareceram pelo menos uma vez. Em três, dos 14 casos possíveis, duas características por canal foram utilizadas, todas com sete canais sendo utilizados e correspondentes às pessoas A, F e G.

Tabela 20 - Detalhes das configurações selecionadas da DWT 2.

	Dados	Filtro espacial	Wavelet	Características por canal	Melhor resultado
7 canais	A	Sem filtro	db3	2	61,03%
	B	SL, $m = 2$	db5	1	58,80%
	C	SL, $m = 3$	db4	1	86,05%
	D	SL, $m = 3$	db5	1	77,19%
	E	SL, $m = 2$	db3	1	84,92%
	F	SL, $m = 2$	db7	2	60,00%
	G	Sem filtro	db6	2	72,12%
39 canais	A	SL, $m = 2$	db6	1	63,59%
	B	SL, $m = 2$	db3	1	60,72%
	C	SL, $m = 2$	db3	1	84,24%
	D	SL, $m = 3$	db5	1	83,55%
	E	SL, $m = 2$	db5	1	83,86%
	F	SL, $m = 2$	db7	1	62,67%
	G	Sem filtro	db3	1	73,56%

No geral, as duas técnicas tiveram um desempenho parecido, com resultados melhores para os dados de C, D e E. Cabe ressaltar, ainda, que a FFT v2 foi superior a FFT da primeira versão em cinco casos.

A Figura 24 mostra as configurações selecionadas de forma definitiva na etapa 1 da primeira versão, as configurações selecionadas depois de combinar as melhores da FFT v2 e DWT 2 com sete e 39 canais separadamente na etapa 1 da segunda versão. Os resultados foram próximos uns dos outros, porém na segunda versão foi possível obter resultados melhores para cinco casos, onde as exceções foram os indivíduos C (resultado igual) e E. Embora não possa ser visto por meio da figura, novamente a combinação de duas técnicas se mostrou eficaz para melhorar a classificação, dessa vez para os dados de A e G com sete canais e E com 39 canais.

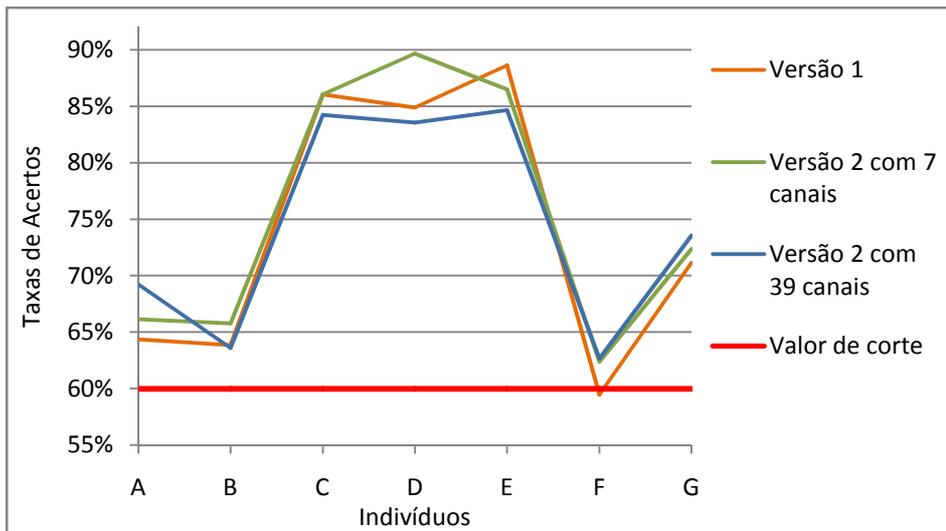


Figura 24 - Configurações selecionadas de forma definitiva na versão 1 da etapa 1 e configurações selecionadas depois de combinar as melhores da FFT v2 e DWT 2 com sete e 39 canais separadamente na versão 2 da etapa 1.

Para a execução da etapa 2, somente o melhor resultado da etapa 1 foi escolhido. Ou seja, para cada indivíduo, escolheu-se o melhor resultado entre as configurações selecionadas com sete canais e 39 canais. A Tabela 21 mostra as configurações selecionadas de forma definitiva que são utilizadas na etapa 2. Como pode ser observado, nenhuma das configurações combinando mais de uma técnica foi escolhida para a etapa 2.

Tabela 21 - Configurações selecionadas de forma definitiva na etapa 1.

Canais	Dados	Filtro espacial	Técnica	Características por canal	Melhor resultado
39	A	Sem filtro	FFT	7	69,23%
7	B	SL, $m = 2$	FFT	9	65,78%
7	C	SL, $m = 3$	DWT 2	1	86,05%
7	D	SL, $m = 2$	FFT	8	89,66%
7	E	SL, $m = 2$	FFT	4	86,51%
39	F	SL, $m = 2$	DWT 2	1	62,67%
39	G	Sem filtro	DWT 2	1	73,56%

4.6.2. Resultados da Etapa 2

Na Figura 25 estão os resultados com os melhores grupos de canais de características obtidos com a etapa 2 do Método de Duas Etapas. Assim como ocorreu na etapa 2 do Método de Três Etapas, todos os resultados melhoraram

com a etapa 2, exceto os resultados de C. A quantidade de canais utilizados variou de quatro (pessoa D) a 33 (pessoa G). Quando comparados aos resultados da etapa 2 da primeira versão, os resultados atuais foram superiores em quatro casos (A, B, D e F), igual em um caso (C, pois o resultado da etapa 1 foi o mesmo nos dois métodos) e inferiores em dois casos (E e G). O resultado que chamou mais atenção foi o de D, pois obteve a maior taxa de acertos com a menor quantidade de canais. Isso mostra que poucos canais podem conter informações suficientes para classificações precisas, desde que escolhidos corretamente e com as características adequadas. Na figura, os canais com número em *itálico*, sublinhado e em **negrito** são aqueles que também estiveram presentes na melhor configuração da mesma pessoa na primeira versão. Assim, pode-se notar que as configurações de canais não se repetiram em relação à primeira versão, exceto para C, cujas características extraídas foram idênticas às da primeira versão. Com isso, é possível perceber a relação de interdependência entre os canais escolhidos e as características extraídas.

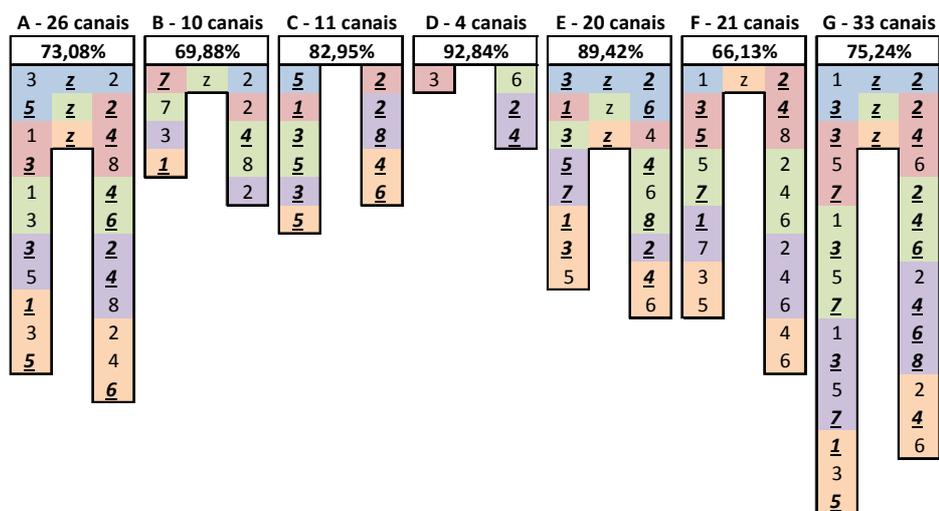


Figura 25 - Melhor configuração obtida com a etapa 2 do Método de Duas Etapas.

A Figura 26 mostra a incidência de cada canal nas melhores configurações. O canal CCP2 foi o único que esteve presente na melhor configuração de todas as pessoas. O canal FC4 não fez parte de nenhuma melhor configuração, assim como o CFC6 na primeira versão. Os dois canais são muito próximos entre si, como mostra a Figura 13.

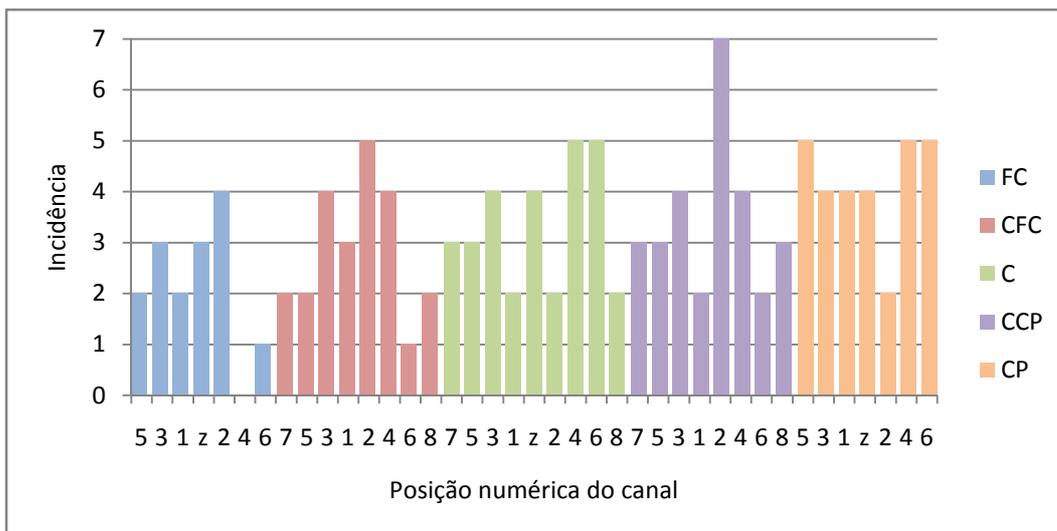


Figura 26 - Incidência de cada canal nas configurações vencedoras da etapa 2.

A Figura 27 mostra a incidência relativa de cada linha de posição. A principal diferença para a primeira versão foi em relação à linha CP, que agora foi superior às demais. As duas linhas mais frontais continuaram com menor incidência relativa. Tomando por base esses resultados e os análogos da primeira versão, conclui-se que, embora algumas regiões se mostrem mais importantes para gerar as características em questão, todas demonstraram relevância quando os resultados das sete pessoas são levados em consideração, pois seja na primeira ou segunda versão, cada indivíduo contou com pelo menos um eletrodo de cada região.

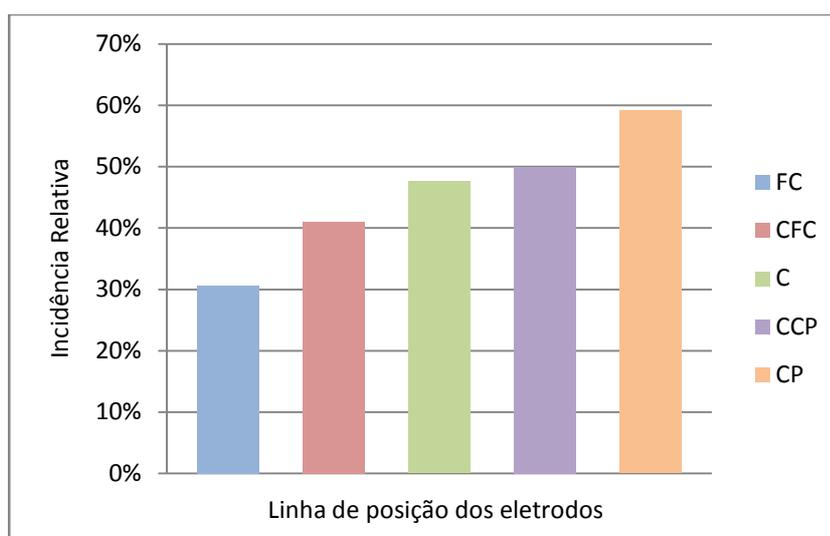


Figura 27 - Incidência de linha de posição nas configurações vencedoras da etapa 2.

A Figura 28 mostra os melhores resultados com cada quantidade de canais variando de 39 a 1. As curvas foram parecidas com as observadas na Figura 22 (primeira versão do método), com uma diferença mais nítida na curva do indivíduo D, onde houve uma tendência de crescimento a partir do início do processo, com 39 canais, até quase o fim, com quatro canais, a partir de onde os acertos caíram rapidamente. Outro ponto interessante nessa curva, que também foi percebido na curva de C, é que ela teve uma variação global (diferença entre a maior e menor taxa de acertos) muito grande, com o valor de 39,79 pontos percentuais, seguido por C com 34,63 pontos percentuais. As demais curvas tiveram variação entre 6,13 e 15,61 pontos percentuais. As curvas mostram a sensibilidade do algoritmo de classificação em relação à escolha dos canais de características que são utilizados, mesmo dentro de uma região restrita do couro cabeludo.

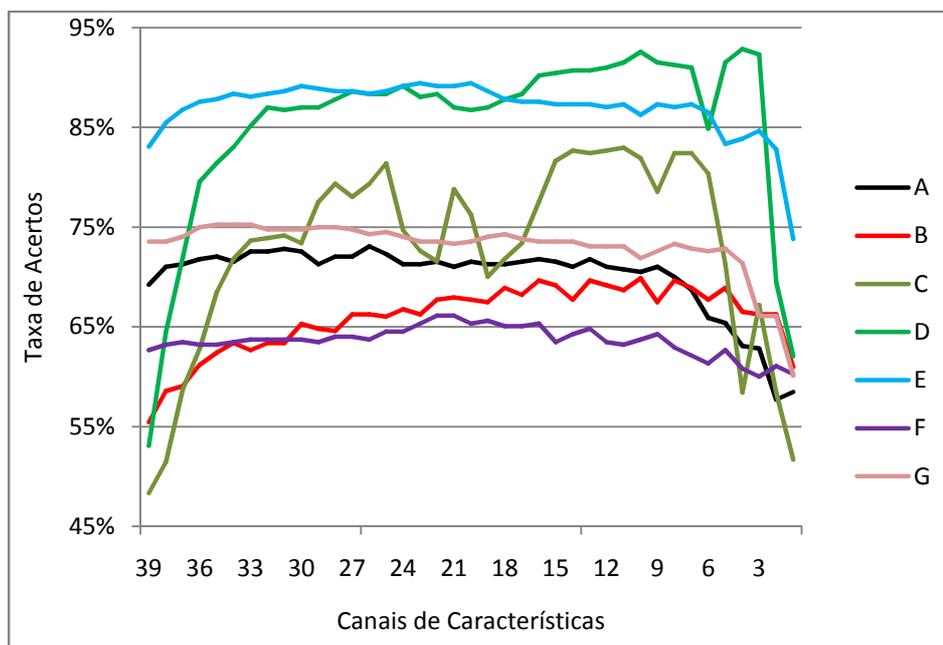


Figura 28 - Resultados da etapa 2 do Método de Duas Etapas.

4.6.3. Resultados de Validação

Os dados de validação foram utilizados para simular o melhor grupo de canais de características de cada pessoa e as configurações de características obtidas na etapa 1. Os resultados estão na Tabela 22. Curiosamente, para B e E os resultados para os melhores grupos de canais foram inferiores aos resultados com os canais da etapa 1, diferente do que foi previsto nas duas etapas do método.

Com os dados de C a mesma situação ocorreu, porém a etapa 2 já havia indicado esse cenário. O Método de Duas Etapas obteve resultados muito próximos daqueles obtidos com o Método de Três Etapas, sem incorrer em melhoras ou piores consideráveis.

Tabela 22 - Resultados de validação das configurações vencedoras da etapa 1 e das melhores configurações da etapa 2.

	A	B	C	D	E	F	G
Etapa 1	67,69%	57,59%	83,98%	89,66%	82,01%	59,47%	72,49%
Melhor grupo	70,51%	56,87%	79,07%	93,37%	78,84%	60,80%	73,44%

5

Aquisição de Dados para Análise *Offline*

Neste capítulo, um equipamento de EEG é utilizado para registrar sinais de movimentos imaginários de cinco pessoas e, baseado nas análises anteriores, métodos de seleção de características e de canais são aplicados para classificar os sinais registrados e analisar o desempenho das técnicas propostas com sinais obtidos a partir de um equipamento comercial de baixo custo. Um dos objetivos desse experimento é verificar a viabilidade de um sistema de ICM utilizando o equipamento em questão associado a um microcontrolador que será apresentado posteriormente.

Todas as atividades envolvendo testes com seres humanos foram devidamente aprovadas pelo comitê de ética em pesquisa da PUC-Rio e os voluntários assinaram um termo de consentimento livre e esclarecido, também aprovado pelo mesmo comitê de ética.

5.1. Composição do Banco de Dados

Nessa etapa são utilizados o Emotiv EPOC Headset (adquirido em 2011) para aquisição do sinal, o algoritmo disponibilizado publicamente em código aberto chamado de Emokit (**Emokit, 2010**) para leitura e registro do sinal, e um notebook para as análises *offline* com o *software* Matlab. A Tabela 23 contém os detalhes dos equipamentos utilizados.

Tabela 23 - Equipamentos utilizados para compor banco de dados.

Equipamento	Função	Dados técnicos
Eletroencefalograma	Medição dos sinais	<ul style="list-style-type: none"> • Nome: Emotiv EPOC Headset (2010) • 14 eletrodos para registro, mais CMS e DRL (referência e terra). • Frequência de amostragem de 128 Hz. • Sinais na banda de 0,2 a 45 Hz. • Wireless (transmissão via bluetooth)
Notebook	Leitura e registro dos sinais	<ul style="list-style-type: none"> • Nome: Toshiba Satellite M645 • Processador de 2,53 GHz • Memória RAM de 4 GB

O Emotiv, nome comercial do eletroencefalograma utilizado, é um aparelho voltado para uso recreativo e também para pesquisa. É um equipamento de baixo custo quando comparado a eletroencefalogramas para aplicações clínicas ou até mesmo outros eletroencefalogramas também voltados para fins recreativos e de pesquisa com quantidade de eletrodos parecida. A maior vantagem do Emotiv é a praticidade, pois o equipamento é pequeno, não possui fios visíveis (a transmissão do sinal acontece via *bluetooth*) e utiliza feltros umedecidos com solução salina para fazer o contato elétrico entre o sensor e o couro cabeludo. Grande parte dos outros equipamentos utiliza um gel com essa finalidade, gerando maior desconforto para o usuário. Contudo, a qualidade do sinal medido por esse aparelho é inferior a de equipamentos clínicos ou outros que utilizam gel. No trabalho de Duvinage et al. (2013), a performance desse equipamento em aplicações baseadas em P300 (tópico 3.1.1) é investigada. Os pesquisadores relatam que o Emotiv fornece sinais com uma qualidade razoável, porém não adequada para aplicações que exigem uma alta confiabilidade, como controle de dispositivos robóticos. Para uso recreativo, como videogames, para comunicação ou para uso de computadores, o equipamento pode ser útil para pessoas com limitações motoras. Barham et al. (2017) mostram que o Emotiv fornece sinais comparáveis aos de um equipamento de qualidade reconhecida somente quando submetido a certas modificações. Outra questão importante para o presente trabalho é o posicionamento dos eletrodos do Emotiv, pois ele apresenta maior densidade na região frontal e nenhum eletrodo na região do córtex motor. Isso é particularmente ruim para a aplicação desejada, pois os pensamentos utilizados

são referentes a movimentos motores imaginários. Os 14 eletrodos do equipamento e suas posições no sistema 10-20 são representados na Figura 29.

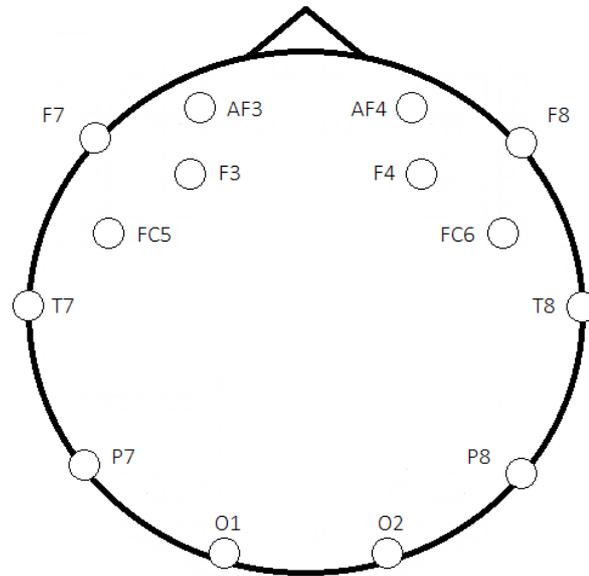


Figura 29 - Eletrodos utilizados no Emotiv e suas respectivas posições no sistema 10-20.

Embora o Emotiv possua 14 canais de medição, o canal AF3 não foi registrado pelos algoritmos utilizados, portanto foi desconsiderado nos testes, que contaram apenas com dados dos 13 canais restantes.

A atividade de extração de dados ocorreu em um ambiente fechado e silencioso. O voluntário permanecia sentado em uma cadeira sem nenhuma distração visual. Após o aparelho de EEG ser devidamente posicionado na cabeça do voluntário, o condutor do experimento dava um comando oral para que a pessoa começasse a emitir o pensamento indicado, até que um novo comando oral indicasse o fim do registro daquele pensamento. Similar ao banco de dados utilizado no desenvolvimento dos métodos dos tópicos anteriores, dois MIs (um relacionado ao braço esquerdo e outro ao braço direito) foram utilizados. O movimento imaginário sugerido foi o braço sair da posição de apoio nas pernas, esticar completamente para a lateral e retornar, repetitivamente. A escolha por esses MIs ocorreu em função da preferência dos participantes, que julgaram essas atividades mentais como mais fáceis de serem executadas do que outros MIs. O pensamento onde nenhum MI é executado (atividade espontânea) também foi registrado. O procedimento consistiu em registrar aproximadamente 60 s do MI mão esquerda, 60 s do MI mão direita e 60 s sem MI e repetir essa sequência até

totalizar 21 registros de cerca de 60 s, o que corresponde a sete registros de cada pensamento.

Cinco participantes, denominados por Sujeito 1, Sujeito 2, Sujeito 3, Sujeito 4 e Sujeito 5, foram voluntários para terem seus sinais registrados. Durante a execução dos testes, todas as pessoas relataram em algum momento sentir cansaço mental, solicitando intervalos de descanso maiores entre alguns registros. Além disso, os Sujeitos 1, 2 e 5 disseram ter sentido sono na segunda metade dos registros. É importante ressaltar que nenhum dos voluntários teve qualquer experiência prévia em experimentos dessa natureza e não passou por nenhum período de treinamento antes do registro dos dados. Durante os testes, o condutor da pesquisa manteve a responsabilidade de fiscalizar o voluntário para que nenhum movimento real indesejado ocorresse e todos os voluntários, ao final dos registros, foram inquiridos a respeito disso, onde todos disseram não ter realizado nenhum movimento voluntário consciente durante os registros. O banco de dados consiste, então, nos sinais de EEG de MI do braço esquerdo, braço direito e de nenhum MI, todos registrados de cinco pessoas diferentes.

Ao fim do procedimento, a mesma quantidade de segundos foi utilizada para os três estados mentais de cada pessoa. Além disso, os dados de cada pessoa foram divididos em três conjuntos de aproximadamente mesmo tamanho, onde um é o conjunto de ajuste de parâmetros, outro é o conjunto de testes e o último é o conjunto de validação, similar ao que foi descrito no tópico 4.1.

5.2. Seleção de Características

São apenas 13 canais disponíveis para registro dos sinais e apenas quatro em regiões próximas ao córtex motor, que são T7, T8, FC5 e FC6. Sendo assim, essa etapa contou com todos os canais fornecendo características. Tendo em vista o objetivo de utilizar o equipamento para uma interface cérebro-máquina em tempo real com processamento em uma unidade eletrônica de capacidade de processamento muito inferior a um computador tradicional, foi considerado o custo computacional das técnicas utilizadas. Dessa forma, somente a técnica FFT v2 foi utilizada, mas dessa vez incluindo novamente os filtros CSP e SL com $m = 4$, ambos não utilizados na etapa 1 do Método de Duas Etapas. Além disso, a janela *hamming* pode variar mais o seu tamanho. Outra diferença para os casos

anteriores, é que dessa vez só foram utilizadas as informações de frequência no intervalo de 0-30 Hz, pois em testes preliminares essa banda se mostrou mais eficaz. Os detalhes se encontram na Tabela 24, onde p é a quantidade de pontos no intervalo em que a transformada de Fourier foi calculada. O intervalo de tempo correspondente a uma amostra para classificação é de 1s.

Tabela 24 - Buscas realizadas com a FFT v2 para análises com banco de dados do Emotiv.

Técnica	Características por canal	Tamanho da janela <i>hamming</i>	Janelas de tempo	Filtro espacial	Total de possibilidades
FFT v2	1 a 9	1xp a 2xp com passo de 0,1	1 a 2	Sem filtro CSP Laplace, $m = 2$ Laplace, $m = 3$ Laplace, $m = 4$	990

5.2.1. Resultados e Discussão

Os resultados da seleção de características com os dados de teste estão na Tabela 25, onde p é a quantidade de pontos no intervalo em que a transformada de Fourier foi calculada. Os valores das taxas de acertos ficaram entre 59,44% e 68,62%. Dadas as limitações conhecidas do Emotiv e a ausência de qualquer tipo de treinamento das pessoas voluntárias, esses resultados foram até certo ponto satisfatórios, pois para os dois primeiros sujeitos os acertos chegaram próximos a 70%. Ainda cabe lembrar que a técnica DWT 2, que se mostrou útil nos casos anteriores, não foi utilizada devido ao seu custo computacional maior aliado à perspectiva do uso do algoritmo também em tempo real em uma unidade de processamento muito inferior a um computador.

Tabela 25 - Resultados da seleção de características com dados medidos pelo Emotiv.

Indivíduos	Filtro espacial	Janelas de tempo	Tamanho da janela <i>hamming</i>	Características por canal	Taxa de acertos
Sujeito 1	SL, $m = 2$	1	1,4	2	67,75%
Sujeito 2	SL, $m = 3$	2	1,1	5	68,62%
Sujeito 3	SL, $m = 4$	2	2	4	60,92%
Sujeito 4	Sem filtro	2	1	3	59,44%
Sujeito 5	SL, $m = 4$	1	1,4	1	63,79%

Os dados de validação foram utilizados para testar as configurações selecionadas e para testar características típicas da literatura, como descrito no item 4.4. A Tabela 26 mostra os resultados com os dados de validação. Na linha referente às características típicas da literatura, o melhor resultado entre a FFT e DWT é representado. Embora a DWT não tenha sido considerada na seleção de características, foi utilizada para também representar, junto com a FFT, resultados obtidos por meio de técnicas selecionadas em função de informações da literatura, isto é, sem a aplicação do método proposto. Como já descrito anteriormente (tópico 4.4), isso é feito com o objetivo de avaliar a eficácia do método de seleção de características proposto no trabalho. Como se vê, os resultados após a seleção de características foi superior, apesar de ainda apresentarem taxas modestas quando se considera o uso em um sistema real. O Sujeito 2 apresentou a maior diferença entre o resultado previsto pela seleção de características com dados de teste e o resultado obtido com dados de validação. Curiosamente, ele teve o melhor resultado com dados de teste e o pior com dados de validação. Durante a aquisição de dados dessa pessoa, foi necessário interromper a atividade a pedido do mesmo, em virtude de uma sonolência. Tal situação pode ser uma das causas da grande diferença observada, já que os dados do conjunto de validação são sempre referentes à parcela final dos dados registrados.

Tabela 26 - Resultados com dados de validação.

	Sujeito 1	Sujeito 2	Sujeito 3	Sujeito 4	Sujeito 5
Seleção de caract.	65,22%	51,39%	62,68%	59,15%	61,81%
Literatura	60,87%	50,00%	59,15%	52,11%	50,69%

Na literatura, como discutido no item 2.3.3, diversos trabalhos mostram que uma mesma abordagem produz resultados significativamente diferentes quando testadas em pessoas distintas e podem até mesmo serem ineficazes para certas pessoas. Com isso, os valores modestos das taxas de acertos podem ter como causa diversos fatores, entre os quais está a maior limitação imposta à seleção de características nos testes deste capítulo e a variabilidade interpessoal dos sinais de EEG. Contudo, é importante ressaltar que as limitações do equipamento de EEG utilizado também contribuem para esses resultados, com destaque para o posicionamento dos eletrodos, que enfatiza a área frontal (mais suscetível aos artefatos oculares) e não contempla a região do córtex motor.

A seleção de canais, conforme etapa 2 dos métodos propostos anteriormente, foi aplicada em cada banco de dados, porém não houve nenhuma previsão de melhora com nenhum grupo diferente dos 13 canais disponíveis. Dada a quantidade e posicionamento dos eletrodos não favoráveis à aplicação desejada (item 5.1) isso era esperado.

5.3. Intervalo de Tempo Processado

Aumentar o intervalo de tempo correspondente a uma amostra pode influenciar na classificação de forma positiva, pois a transformada de Fourier com mais pontos fornece um espectro de frequência mais detalhado do intervalo analisado. Sendo assim, foram feitas duas outras tentativas com os sinais dos cinco sujeitos, uma delas processando 1,5 s de cada vez e outra processando 2 s de cada vez. As mesmas configurações da Tabela 25 (obtidas com 1 s sendo processado de cada vez) foram utilizadas para processar 1,5 s e 2 s de cada vez. Depois, dois novos processos de seleção de características foram executados, um processando 1,5 s de cada vez e outro processando 2 s. Os resultados podem ser vistos nas Figuras 30 e 31, onde os números 1 a 5 na metade esquerda do eixo

horizontal correspondem aos dados de teste de cada sujeito e, à direita, correspondem aos dados de validação.

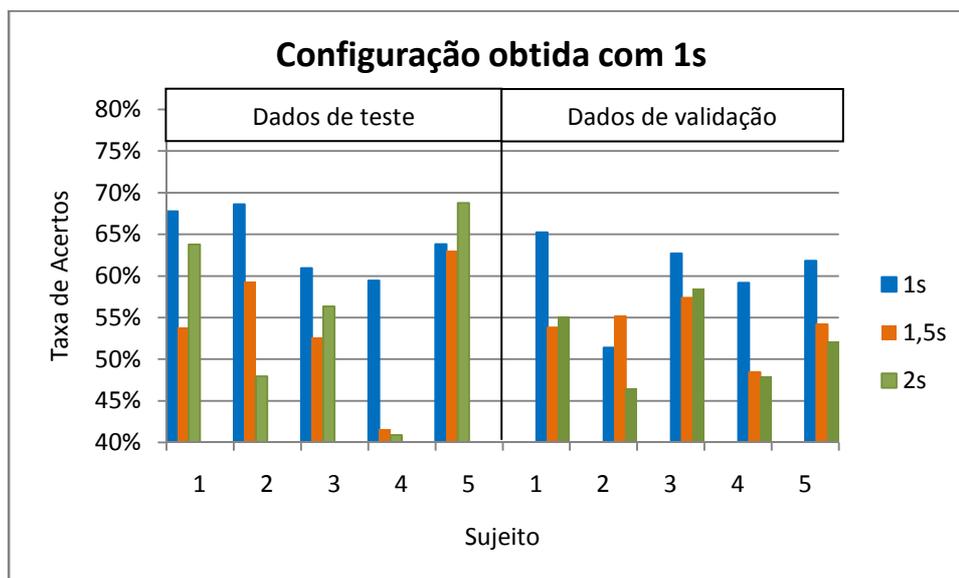


Figura 30 - Taxas de acertos com diferentes intervalos de tempo processados de cada vez.

Analisando a Figura 30, percebe-se que somente para o Sujeito 5 com dados de teste e o Sujeito 2 com dados de validação o aumento no intervalo de tempo foi capaz de elevar a taxa de acertos. No segundo caso, porém, os acertos não ultrapassaram 55%. Pode ser visto também que os testes com 1,5 s e 2 s não mostraram superioridade um em relação ao outro. Comparando somente as duas condições, cada uma foi superior em cinco casos. Nos resultados dessa figura, cabe lembrar, o pré-processamento e as características são os mesmos informados na Tabela 25.

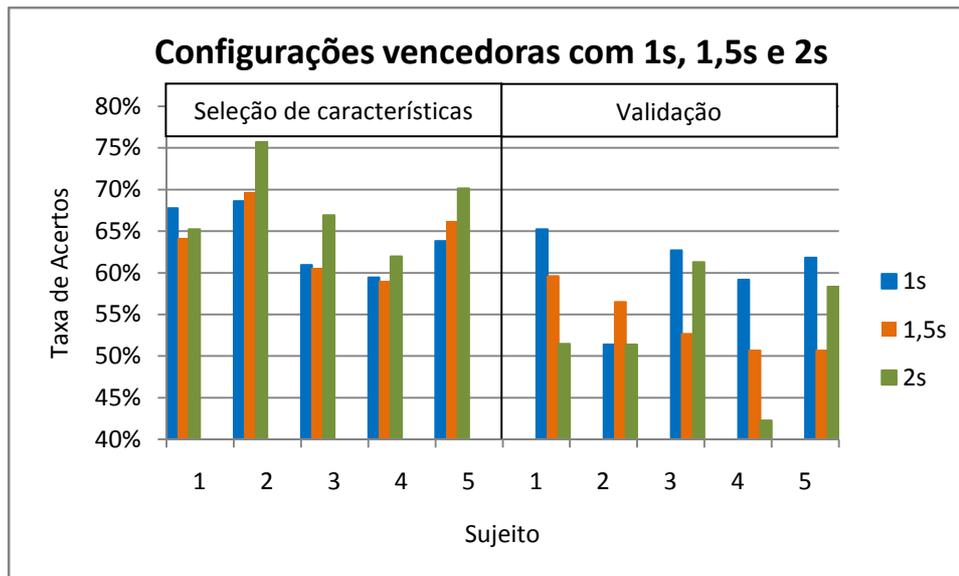


Figura 31 - Taxas de acertos com diferentes intervalos de tempo processados de cada vez, após seleção de características para cada caso.

Para gerar os resultados da Figura 31, foi executada novamente a seleção de características com 1,5 s e 2 s sendo processados de cada vez, conforme já foi explicado. As configurações selecionadas não se repetiram para pessoas diferentes. Para os tempos diferentes com uma mesma pessoa, as configurações selecionadas foram bem parecidas, mas em nenhum caso coincidiu totalmente. Em quatro casos (sujeitos 2 a 5) com dados de teste, os resultados da seleção de características com 2 s obtiveram mais acertos que os resultados com 1 s e 1,5 s. Com 2 s, os resultados chegaram a mais de 70% para os sujeitos 2 e 5. Com os dados de validação, contudo, os resultados com 1 s foram melhores em quatro casos e com 1,5 s foi melhor em um. Como a quantidade de amostras diminuiu com o aumento do intervalo de tempo processado, isso pode ter contribuído para que os resultados com 1,5 s e 2 s obtivessem um pior desempenho com dados de validação, pois pode não ter havido amostras suficientes para evitar o *overfitting*, que ocorre quando o ajuste do sistema (no caso, tanto a escolha das características, quanto o projeto do FLD) se adapta excessivamente às particularidades das amostras, perdendo o poder de generalização.

5.4. Detecção de Um Único MI

Nessa seção, a seleção de características foi aplicada na tentativa de se identificar a ocorrência de um único MI isoladamente. Isto é, em cada teste as

amostras correspondem aos sinais de um único MI e da atividade espontânea (onde nenhum MI é executado). Dessa forma, foram feitos dois testes separados (um para o MI do braço esquerdo e outro para o MI do braço direito) em que a classificação foi realizada entre duas classes possíveis: o MI da vez e a atividade espontânea. Os registros contendo sinais do MI não utilizado no teste são momentaneamente eliminados do banco de dados. A Figura 32 mostra, lado a lado para cada sujeito, a taxa de acertos quando foi considerado o MI braço esquerdo (cor azul) e quando foi considerado o MI braço direito (cor amarela). No eixo horizontal, a metade à esquerda corresponde aos resultados com dados de teste, que são aqueles utilizados para executar a seleção de características, à direita são resultados das configurações selecionadas de cada pessoa com os dados de validação. No geral, os resultados foram próximos aos obtidos ao fazer a classificação entre os dois MIs. Nas duas condições analisadas na Figura 32, é interessante observar que a seleção de características previu um pouco mais de facilidade na detecção do MI braço esquerdo, porém ocorreu o contrário com os dados de validação. O que chama a atenção é o valor obtido com o Sujeito 4 com dados de validação e MI braço esquerdo. A taxa de acertos foi aproximadamente 35%, enquanto a previsão foi um pouco mais de 65%. Ou seja, a região atribuída a cada classe parece ter sido invertida com os dados de validação. Isso levanta uma questão sobre a etapa de aquisição de dados, pois esse resultado pode ser fruto de outra atividade detectada nos sinais de EEG. Por exemplo, o sujeito pode ter executado o movimento imaginário concomitantemente com outra atividade mental durante alguns registros e posteriormente pode ter alterado essa segunda atividade mental. Isso leva ainda à outra questão interessante, que é a maneira com que a seleção de características se adéqua ao sinal de cada pessoa. Se a hipótese anterior for verdadeira, isso significa que a seleção de características se “adaptou” a essa outra atividade mental, em vez de se adaptar ao MI. Com isso, nota-se a importância de se investigar com mais profundidade os sinais de controle que se pretende classificar, a fim de limitar a “adaptação” das características a um universo restrito aos aspectos do sinal de controle mais diretamente relacionados ao pensamento de interesse.

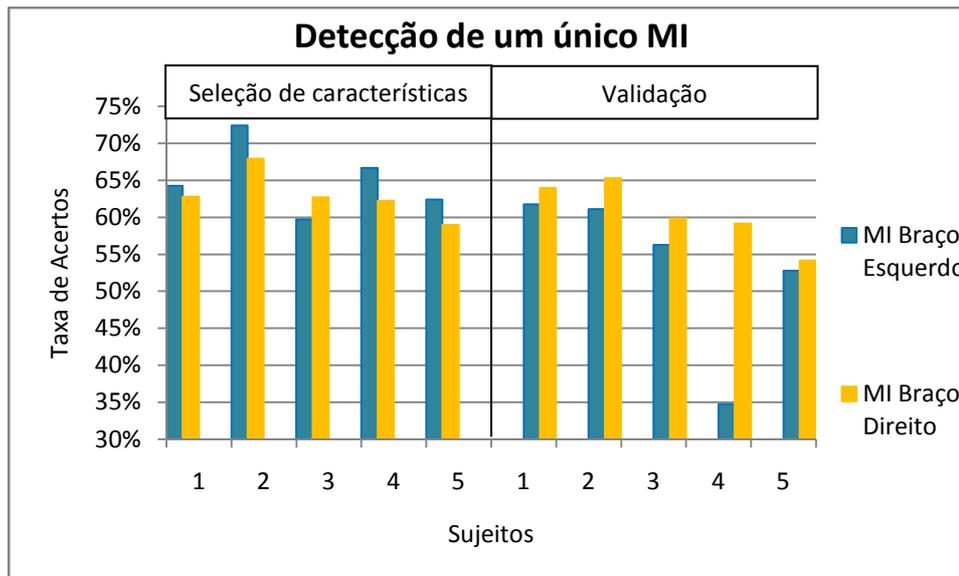


Figura 32 - Resultados quando foram classificados um MI e a atividade espontânea (sem MI).

6 Análise em Tempo Real

A análise em tempo real consiste em testes que envolvem a utilização dos algoritmos desenvolvidos para acionamento de um sistema eletrônico simples. Ou seja, a interface é de fato utilizada em uma atividade real. Todas as atividades envolvendo testes com seres humanos foram devidamente aprovadas pelo comitê de ética em pesquisa da PUC-Rio e os voluntários assinaram um termo de consentimento livre e esclarecido, também aprovado pelo mesmo comitê de ética.

6.1. O Sistema

Todo o processamento dos sinais enquanto a interface é utilizada ocorre em um microcontrolador chamado Raspberry Pi (Figura 33), cujos detalhes técnicos estão na Tabela 27. A grande vantagem desse equipamento, visando o objetivo do presente trabalho, são suas dimensões físicas, que permitem embarcar o sistema com relativa facilidade, tornando o mais propício para o uso em situações práticas. Os pinos GPIO (do inglês, *general purpose input output*) vistos na figura são portas de entrada e saída digitais do Raspberry Pi, para conectá-lo a outros dispositivos eletrônicos de qualquer natureza. Por meio deles, a placa pode transmitir a saída lógica desejada a um circuito do qual ela faz parte e que a transformará em um sinal analógico. A Figura 34 mostra esquematicamente os pinos. Através da nomenclatura indicada e fazendo uso da biblioteca de programação disponível no Raspberry Pi com a finalidade de controlar os pinos, é possível estabelecer esse controle de forma relativamente simples. A linguagem Python foi utilizada para realizar todas as etapas relativas ao processamento, classificação do sinal e envio de comandos para os pinos GPIO. A versão do Emokit que foi utilizada foi também desenvolvida em Python. Como fonte de energia, o Raspberry Pi possui uma entrada similar à de muitos telefones celulares, podendo ser ligado diretamente em uma tomada ou em um carregador de celular portátil. Contudo, é possível utilizar qualquer outra fonte de energia ligada diretamente aos pinos GPIO.

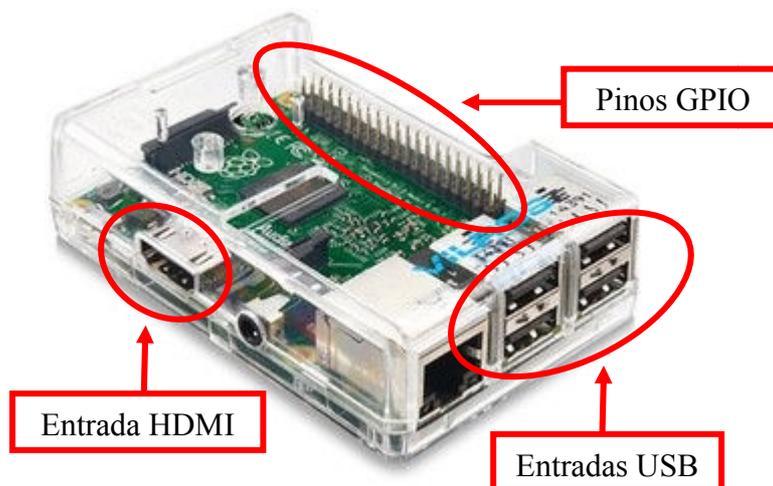


Figura 33 - Raspberry Pi, o microcontrolador utilizado para teste em tempo real.

Raspberry Pi 3 GPIO			
01	3.3v DC Power	⬤ ⬤	DC Power 5v 02
03	GPIO02 (SDA1 , I ² C)	⬤ ⬤	DC Power 5v 04
05	GPIO03 (SCL1 , I ² C)	⬤ ⬤	Ground 06
07	GPIO04 (GPIO_GCLK)	⬤ ⬤	(TXD0) GPIO14 08
09	Ground	⬤ ⬤	(RXD0) GPIO15 10
11	GPIO17 (GPIO_GEN0)	⬤ ⬤	(GPIO_GEN1) GPIO18 12
13	GPIO27 (GPIO_GEN2)	⬤ ⬤	Ground 14
15	GPIO22 (GPIO_GEN3)	⬤ ⬤	(GPIO_GEN4) GPIO23 16
17	3.3v DC Power	⬤ ⬤	(GPIO_GEN5) GPIO24 18
19	GPIO10 (SPI_MOSI)	⬤ ⬤	Ground 20
21	GPIO09 (SPI_MISO)	⬤ ⬤	(GPIO_GEN6) GPIO25 22
23	GPIO11 (SPI_CLK)	⬤ ⬤	(SPI_CE0_N) GPIO08 24
25	Ground	⬤ ⬤	(SPI_CE1_N) GPIO07 26
27	ID_SD (I ² C ID EEPROM)	⬤ ⬤	(I ² C ID EEPROM) ID_SC 28
29	GPIO05	⬤ ⬤	Ground 30
31	GPIO06	⬤ ⬤	GPIO12 32
33	GPIO13	⬤ ⬤	Ground 34
35	GPIO19	⬤ ⬤	GPIO16 36
37	GPIO26	⬤ ⬤	GPIO20 38
39	Ground	⬤ ⬤	GPIO21 40

Figura 34 - Representação da distribuição dos pinos GPIO do Raspberry Pi.

Tabela 27 - Detalhes do Raspberry Pi.

Equipamento	Função	Dados técnicos
Microcontrolador	Registrar e processar o sinal	<ul style="list-style-type: none"> • Nome: Raspberry Pi 3 B • Processador de 1,2 GHz • Memória RAM de 1 GB • Custo aproximado: US\$35,00

O sistema conta ainda com o Emotiv, aparelho de EEG utilizado para as análises do capítulo 5 (Figura 35). O *dongle* ilustrado na imagem é um receptor de *bluetooth* USB que faz parte do Emotiv e recebe em tempo real os dados medidos.



Figura 35 - Aparelho de EEG utilizado, Emotiv EPOC.

Os eletrodos propriamente ditos estão representados na Figura 36 e são encaixados nas extremidades circulares dos braços vistos na Figura 35. A parte que faz contato com o couro cabeludo é o feltro, visto na cor preta. Ele deve ser umedecido com uma solução salina antes do uso, para possibilitar um contato elétrico melhor. O eletrodo em si é a parte na cor dourada, que em alguns casos está parcialmente coberta com uma camada de oxidação. De acordo com a fabricante, em texto publicado *online*, essa camada não prejudica o contato elétrico:

“The green material is (...) a reaction product between the salt water and polymer material on the electrode plate. It is completely harmless and does not cause any contact problems. It is also conductive when wet.” (Emotiv, 2017)



Figura 36 - Eletrodos do Emotiv vistos em detalhe.

O sinal do Emotiv recebido pela unidade de processamento (Raspberry Pi) é criptografado, mas o conjunto de algoritmos Emokit decriptografa o sinal e o registra em tempo real em um arquivo de texto. O programa desenvolvido para viabilizar a interpretação em tempo real conta com uma adaptação no Emokit, que faz com que o sinal, ao ser decriptografado, seja enviado diretamente para o processamento que traduz o sinal de EEG em uma saída para o sistema eletrônico, sem criar de fato um arquivo de texto com as informações.

Após a leitura e o processamento, o algoritmo da ICM emite um comando lógico para os pinos GPIO 17 e 18 (vide Figura 34), que vai depender do comando que o algoritmo selecionou. Com isso, o sinal vai para o circuito e acende o LED indicado pelo algoritmo. O sistema pode ser visto na Figura 37, onde os resistores utilizados são de $1k\Omega$, os LEDs verdes e vermelhos representam cada cor um MI e o LED amarelo é apenas um indicador de que o sistema está ligado.

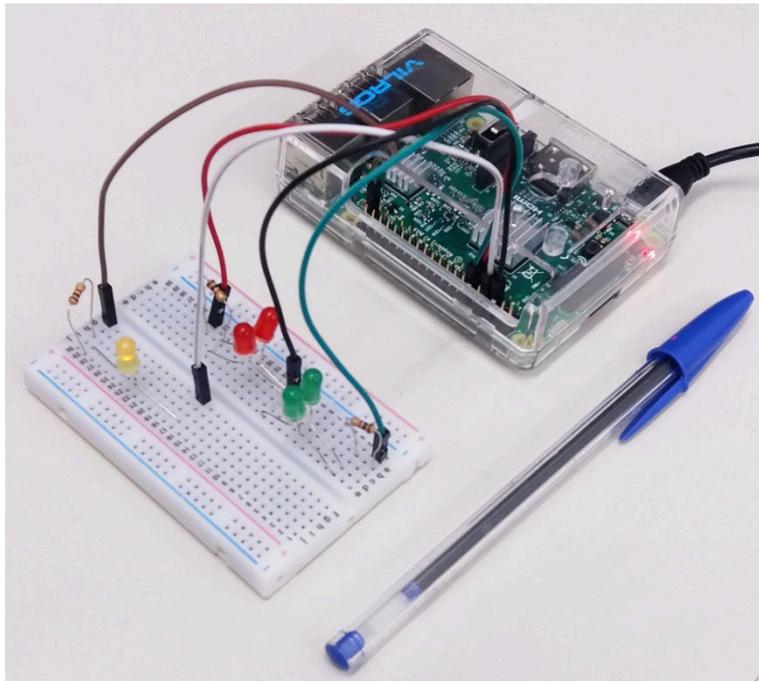


Figura 37 - Sistema utilizado para os testes em tempo real.

6.2. Primeiro Teste Experimental

Com o objetivo de avaliar o desempenho do sistema em tempo real, foi proposta uma tarefa simples, porém suficiente para verificar o funcionamento do sistema. A atividade consiste em executar tarefas mentais associadas aos LEDs do circuito. Ou seja, os sinais de EEG serão interpretados e o resultado da classificação será indicado por meio dos LEDs que forem acionados.

Para usar o equipamento adequadamente, o usuário deve primeiramente fornecer um pequeno banco de dados com sinais dos movimentos imaginários que deverão ser reconhecidos pela interface. Os dados são analisados em um computador, onde a seleção de características descrita no capítulo 5 é executada e a melhor configuração é utilizada no algoritmo da interface que está no Raspberry Pi. Quando há o uso de filtro espacial que requer dados de EEG para ser projetado, ele também é obtido nessa análise *offline*, bem como o vetor de projeção do Discriminante Linear de Fisher e o respectivo valor de limiar que separa as classes de pensamentos. Depois que esses dados são repassados para o microcontrolador, ele está pronto para ser utilizado. Basta, então, executar o programa que faz os procedimentos que vão desde a aquisição do sinal à iluminação dos LEDs.

Antes de dar início aos testes, mais análises *offline* foram realizadas com o Sujeito 1, que foi selecionado para os testes em tempo real. O objetivo é identificar a reincidência de parâmetros selecionados para a melhor configuração, a fim de reduzir o universo de busca, para que o intervalo de tempo entre a coleta dos primeiros dados e os testes em tempo real seja menor. A segunda coleta de dados, feita 50 dias após a primeira (item 5.1), consistiu em registrar sinais de MI da mão esquerda, mão direita e sem MI, seguindo o mesmo protocolo do item 5.1. Contudo, o voluntário executou os MIs direcionando o olhar para o membro em questão, situação que não ocorreu nos testes anteriores. O processamento para fazer a classificação foi executado a cada intervalo de 1 s e depois a cada intervalo de 2 s. Os resultados estão na Tabela 28 e referem-se à classificação entre os dois MIs.

Tabela 28 - Resultados da segunda análise *offline*.

Tempo processado	Filtro espacial	Janelas de tempo	Tamanho da janela <i>hamming</i>	Características por canal	Taxa de acertos
1 s	Sem filtro	1	1,9xp	3	64,03%
2 s	Sem filtro	1	2xp	2	75,00%

A terceira coleta de dados, feita dois dias após a segunda, também registrou sinais referentes aos MIs das mãos. Dessa vez, no entanto, cada MI foi executado por sete minutos consecutivos, diferente do caso anterior, onde eles foram alternados a cada minuto até completar sete minutos de cada. Novamente, o voluntário pôde olhar para o membro enquanto imaginava o movimento. Os resultados estão na Tabela 29 e mostram grande evolução nas taxas de acertos. Nesse caso e no anterior, metade dos dados foi utilizada para ajustar o classificador e metade para fazer as buscas. Não foi feita a validação, pois isso é substituído pelo teste em tempo real nesse capítulo.

Tabela 29 - Resultados da terceira análise *offline*.

Tempo processado	Filtro espacial	Janelas de tempo	Tamanho da janela <i>hamming</i>	Características por canal	Taxa de acertos
1 s	SL, $m = 2$	2	1,4xp	4	85,55%
2 s	Sem filtro	1	1,8xp	2	90,00%

A partir desses resultados, foi definido para os testes em tempo real que as quantidades de características por canal devem variar apenas entre 2 e 4 e o tamanho da *hamming* deve variar entre 1 e 2 vezes o tamanho da janela de tempo, porém com passo de 0,2. No pré-processamento, só devem ser considerados os casos sem filtro e SL com $m = 2$.

Para o primeiro teste em tempo real de fato, realizado três dias após a terceira coleta de dados para análise *offline* (Tabela 29), a extração de dados se deu conforme a última análise *offline*. Todas as etapas do procedimento e a duração aproximada de cada uma estão na Tabela 30.

Tabela 30 - Tempo gasto em cada etapa do experimento.

Etapas	Duração [min]
Setup do Emotiv, computador e Raspberry Pi	15
Registro dos sinais dos MIs para ajuste do sistema	14
Preparação para fazer a busca	1
Busca pela melhor configuração	0,88 (53 s)
Atualização dos algoritmos no Raspberry Pi	3
Testes em tempo real	livre

6.3. Resultados e Discussão

Quando em tempo real, o Sujeito 1 executou alternadamente os dois MIs durante intervalos de tempo variados. O voluntário indicou verbalmente cada vez que alterou o MI em execução. Durante o teste ele não teve contato visual com os LEDs. A busca pela configuração adequada se deu processando intervalos de 2 s. As previsões foram surpreendentemente boas, dados os resultados das análises anteriores, pois quase todas foram acima de 90% e a com melhor desempenho obteve 99,51% de acertos (sem filtro espacial, uma janela de tempo, *hamming* do mesmo tamanho que o intervalo de tempo e três características por canal). Essa configuração foi utilizada para os três testes que foram realizados em tempo real (Figura 38), mesmo o terceiro deles sendo com intervalos de 1 s processados de cada vez. Posteriormente foi feita a busca pela melhor configuração com 1 s sendo processado, e os resultados foram bastante parecidos com os encontrados com 2 s. O melhor resultado foi de 99,76% de acertos e a configuração igual à selecionada com 2 s obteve 98,79%.

Para avaliar o desempenho em tempo real, os LEDs foram filmados durante as atividades e depois foi simulada uma trajetória com os resultados, onde a posição horizontal foi determinada pelos LEDs e a vertical pelo instante de tempo. A Figura 38 mostra as trajetórias para as três atividades realizadas. A primeira delas teve como objetivo principal familiarizar o Sujeito 1 com a atividade. As linhas tracejadas correspondem aos momentos em que houve mudança no MI executado, as linhas vermelhas representam os comandos que foram recebidos pelos LEDs e as azuis representam o MI que estava sendo executado. As duas primeiras imagens foram obtidas quando foram processados intervalos de 2 s, enquanto a última foi obtida quando foram processados intervalos de 1 s. O título de cada imagem informa exatamente o intervalo de tempo processado de cada vez. No eixo horizontal, os valores indicam a posição do ponto em uma unidade arbitrária.

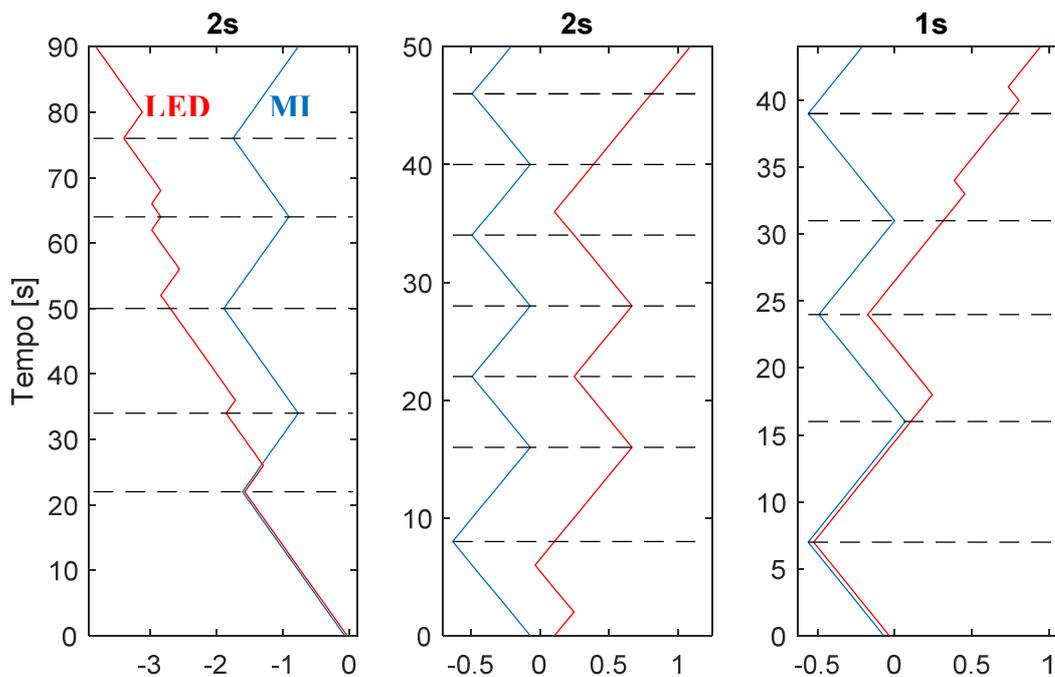


Figura 38 - Resultados do primeiro teste em tempo real. No eixo horizontal, os valores indicam a posição do ponto em uma unidade arbitrária.

A sequência das imagens corresponde à sequência em que os testes foram realizados. Percebe-se que, no primeiro, o resultado apresentou mais erros. Nessa ocasião, houve uma tendência no classificador em selecionar a classe referente ao MI mão esquerda, de forma que quase todos os acertos ocorreram quando o MI correto era de fato este. Quando o MI era referente à mão direita, a taxa de acertos

foi de apenas 35%, enquanto a taxa de acertos total foi de 66,67%. O segundo teste teve um resultado melhor, com dois erros no momento inicial, depois um pequeno atraso para reconhecer o MI mão direita e, no penúltimo trecho, o MI mão esquerda não foi identificado. A taxa de acertos foi de 76%. O terceiro, considerando que apenas 1 s foi processado de cada vez e que foi o último a ser realizado, obteve bons resultados, com um atraso para reconhecer o MI mão esquerda no terceiro trecho, uma dificuldade maior para reconhecer o MI mão esquerda no penúltimo trecho e apenas um comando errado no trecho final, chegando a 75% de acertos.

Apesar das previsões durante a realização das buscas pela melhor configuração terem sido próximas de 100%, era esperado que o desempenho em tempo real fosse muito inferior. Os sinais de EEG registrados para uma análise *offline* exclusivamente podem diferir dos mesmos quando é uma atividade em tempo real. A própria expectativa durante os testes em tempo real foi considerada pelo Sujeito 1 como um fator que afetou a execução dos pensamentos. A alternância entre os movimentos imaginários também foi mencionada no mesmo sentido, pois na sessão de ajustes e buscas cada MI foi executado sem interrupções. É preciso considerar também que os eletrodos do Emotiv alteram seus posicionamentos durante o uso em virtude das hastes flexíveis que os prendem. Ainda, os feltros umedecidos com solução salina secam com o passar do tempo, influenciando na qualidade do sinal.

Pelas análises *offline* no decorrer do trabalho e pelos resultados em tempo real, foi visto que houve uma grande evolução. Possivelmente isso está relacionado à melhora do Sujeito 1 em executar as tarefas mentais exigidas, o que pode ter sido influenciado pela possibilidade do mesmo olhar para o membro enquanto executa o MI. Nota-se que o universo de busca para esse sujeito foi bastante reduzido, mesmo as análises tendo sido realizadas sempre em dias diferentes. Isso sugere que existe a possibilidade de se encontrar uma configuração ótima para uma dada pessoa, após um período de análises e experimentos. Porém, o vetor de projeção do FLD e o valor de limiar continuam sendo calculados da mesma forma, necessitando sempre de novos dados de ajuste de parâmetros. Com isso, o segundo teste experimental investiga a possibilidade de eliminar a necessidade de dados de ajuste após as análises prévias ou pelo menos eliminar as buscas pela melhor configuração. Devido ao bom desempenho

processando apenas 1 s e sua melhor aplicabilidade para situações práticas, no segundo teste somente essa condição foi considerada.

6.4. Segundo Teste Experimental

Duas abordagens são comparadas no segundo teste. Uma consiste em usar os dados coletados no primeiro teste experimental nas três análises *offline* (cada coleta foi realizada em um dia diferente) para fazer a busca pela melhor configuração. A proposta é evitar que dessa vez o Sujeito 1 forneça dados imediatamente antes de usar o sistema em tempo real. A outra abordagem consiste em usar a configuração considerada a melhor em função das análises anteriores e extrair dados somente para gerar o FLD, o que reduz à metade o tempo necessário para registro dos dados.

Abordagem 1 – sem coleta de dados:

O novo banco de dados foi organizado com os dados dos MIs da mão esquerda e da mão direita registrados em três dias distintos. Para cada MI a composição do banco de dados se deu da seguinte forma: a primeira metade dos dados de cada dia é agrupada em sequência, depois a segunda metade dos dados de cada dia é agrupada ao final. O conjunto completo é utilizado para realizar as buscas.

A configuração com melhor desempenho obteve 75,67% de acertos, não utilizou filtro espacial, usou apenas uma janela de tempo, *hamming* 1,8 vezes tamanho da janela de tempo e quatro características por canal. Nessa busca, as possibilidades são as mesmas apresentadas no item 6.2. Teoricamente, a maior probabilidade é de que as únicas componentes em comum entre os sinais de dias diferentes sejam relativas aos MIs. A expectativa com essa abordagem é de que a previsão de acertos seja mais fiel aos resultados em tempo real, já que reduz a possibilidade do algoritmo se adaptar a sinais que não são dos MIs. O experimento foi executado três dias após o primeiro teste em tempo real.

Abordagem 2 – com coleta de dados, mas sem busca pela melhor configuração:

Para seleção dos parâmetros, foram analisados os resultados completos de cada busca realizada para o Sujeito 1, isto é, não somente as configurações com

melhor desempenho. As análises consideradas referem-se aos testes realizados com apenas 1 s sendo processados de cada vez nos itens 5.2.1 (

Tabela 25 25), 6.2 (Tabelas 28 e 29), 6.3 e na Abordagem 1 deste tópico. A principal motivação para essa abordagem é a idéia de que existe pelo menos uma configuração que tem maior chance de ter um bom desempenho com os sinais de uma pessoa.

A configuração selecionada foi sem filtro espacial, uma janela de tempo, *hamming* 1,4 vezes o tamanho da janela de tempo e três características por canal. As taxas de acertos com a configuração com melhor desempenho de cada análise e com a configuração selecionada neste tópico estão na Tabela 31. Pode ser visto que, embora a configuração selecionada não tenha sido a com melhor desempenho nos casos citados, ela obteve resultados próximos, exceto pelo primeiro caso, onde os MIs ainda eram relativos aos braços em vez das mãos.

Tabela 31 - Resultados das análises anteriores com as configurações com melhor desempenho de cada análise e com a configuração selecionada para o teste em tempo real.

	Item 5.2.1	Item 6.2	Item 6.2	Item 6.3	Item 6.4
Melhor desempenho	67,75%	64,03%	85,55%	99,76%	75,67%
Selecionada	60,51%	61,22%	84,36%	98,79%	73,58%

6.5. Resultados e Discussão

Os procedimentos foram um pouco diferentes do primeiro experimento. O voluntário tinha um cronômetro a sua frente durante os testes e foi orientado a alterar o MI em execução a cada intervalo de 10 s em um experimento e a cada 30 s em outro. Sendo assim, duas tentativas foram realizadas com cada abordagem, onde uma contou com mais alternância entre os MIs e outra priorizou a manutenção dos MIs por períodos mais longos. Todas as tentativas tiveram duração de dois minutos. A análise do desempenho foi realizada de maneira similar ao item 6.3.

Os resultados da Abordagem 1 estão representados na Figura 39. O título de cada gráfico se refere ao intervalo de tempo em que o participante manteve o mesmo MI em execução e, no eixo horizontal, os valores indicam a posição do ponto em uma unidade arbitrária. Na situação onde o MI foi alterado a cada 10 s, percebe-se que os acertos foram muito baixos. Houve uma tendência pela classe do MI da mão esquerda, de modo que só foram observados acertos consideráveis quando esse MI foi executado. Quando o MI da mão direita foi executado, somente em duas sequências de 10 s a variação total do movimento foi maior para a direita, sendo que em uma delas, entre 30 s e 40 s, a variação foi 20% do esperado, enquanto na outra, entre 50 s e 60 s, a variação foi 40% do esperado. Acima de 80 s, praticamente só houve comandos para a esquerda, ignorando um intervalo completo que deveria ser para a direita e, no último, quase ocorreu o mesmo, tendo um único comando como exceção. O voluntário relatou maior dificuldade na execução da tarefa, principalmente por ter que prestar atenção constante ao cronômetro e precisar alterar o MI com muita frequência.

Quando o MI foi alterado a cada 30 s, o desempenho foi notadamente melhor. A variação total de cada intervalo na posição horizontal sempre foi no sentido esperado, embora não muito grande na primeira metade do experimento (0-60 s), cuja taxa de acertos foi de 60%. Contudo, nesse mesmo intervalo não foi observada nenhuma tendência na classificação, pois a variação total foi muito próxima do esperado. Na segunda metade (60-120 s) o desempenho foi melhor. As variações em cada sequência de um mesmo MI foram superiores às da primeira metade e a variação total foi parecida. A taxa de acertos no trecho entre 60 e 120 s foi de 75%, valor muito próximo dos 75,67% obtidos na análise *offline*.

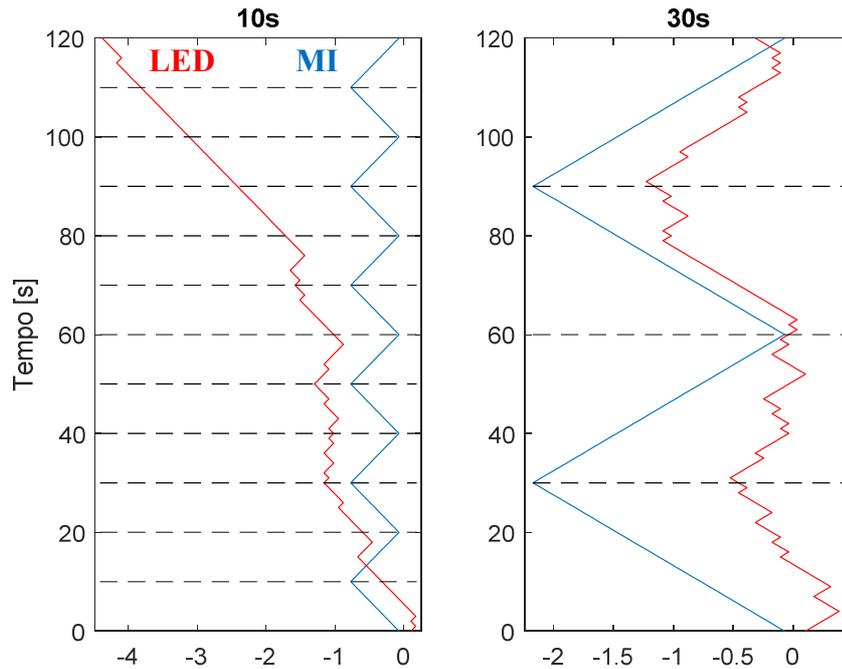


Figura 39 - Resultados do segundo teste em tempo real (Abordagem 1). No eixo horizontal, os valores indicam a posição do ponto em uma unidade arbitrária.

Com esses resultados, é possível ver que o desempenho em tempo real é comprometido quando há a necessidade de variar com muita frequência o MI, mas atende às expectativas quando isso não acontece. Isso pode estar relacionado à maneira com que os dados de ajuste de parâmetros e de busca foram registrados anteriormente, pois não houve períodos de alternância entre os MIs. A capacidade do voluntário provavelmente tem forte impacto nessa situação, pois para executar o MI é necessário certo nível de concentração, o que só ocorreu após alguns segundos com o MI em execução, conforme relato do Sujeito 1. Por fim, a Abordagem 1 foi considerada bem sucedida, já que obteve 67,5% de acertos no total, atendendo à expectativa de que o resultado em tempo real seria mais próximo do resultado *offline* quando comparado aos testes dos itens 6.2 e 6.3. Esse resultado é bastante promissor, pois sugere que um período adequado de treinamento e análises *offline* pode evitar que um algoritmo de ICM requeira reajustes frequentes para um mesmo indivíduo.

Um dia após a execução do experimento da Abordagem 1, foi realizado o experimento da Abordagem 2. Duas tentativas foram realizadas em cada situação (alternando MI a cada 10 s e 30 s), porém em todas elas somente o LED referente

ao MI da mão direita foi aceso. Houve um espaçamento de algumas horas entre as duas tentativas, a fim de evitar que algum fator momentâneo perturbasse os sinais fornecidos pelo Sujeito 1 para gerar o FLD e executar os testes em tempo real. Nesse intervalo, o Emotiv foi retirado e recolocado somente no momento de executar a segunda tentativa. Dada a recorrência da configuração adotada entre as melhores configurações em praticamente todas as análises *offline*, é possível que com mais tentativas, de preferência em dias diferentes, a Abordagem 2 pudesse ter sucesso. No entanto, estudos futuros são necessários para verificar essa hipótese. Com o resultado obtido, a alta sensibilidade do processo de classificação em relação a fatores diversos fica evidente. Percebe-se que há uma grande dependência em relação a fatores de difícil controle, como a forma com que o sujeito executa o pensamento, o que inclui alterações no nível de concentração, presença de outros pensamentos simultâneos, entre outros fatores.

7 Conclusão

O projeto de uma interface cérebro-máquina não invasiva requer muitas etapas, por vezes de naturezas bastante diferentes e quase sempre com considerável complexidade. Deixando de lado a parte relativa ao desenvolvimento de equipamentos, algumas atividades podem ser consideradas como as principais. A aquisição de dados, que envolve o protocolo que rege essa atividade, onde é preciso conhecimentos de neurociências, psicologia e técnicas experimentais, por exemplo, tem um papel determinante no ajuste do sistema e nos resultados, cujas análises são os pilares para o desenvolvimento dos algoritmos. O pré-processamento, por sua vez, está intimamente ligado à aquisição de dados, pois consiste em tratar os sinais que foram registrados para deixá-los mais próximos do sinal emitido pelo cérebro. A presença de artefatos e ruídos, e a resolução espacial são todas afetadas pela etapa anterior e ainda hoje existem muitas limitações referentes à maneira como se deve lidar com essas questões. É possível que, desconsiderando as limitações de *hardware*, esse seja o maior obstáculo no sentido de impedir uma evolução mais rápida no desenvolvimento das interfaces em um âmbito prático. A extração de características e a classificação, muito além de uma atividade de reconhecimento de padrões, por vezes consistem em grandes esforços dedicados a contornar problemas oriundos das etapas anteriores. Com isso, percebe-se que cada etapa previamente mencionada é sozinha um vasto campo de pesquisa.

Com a realização do presente trabalho, foi possível fornecer uma visão geral do que envolve uma ICM não invasiva, com maior enfoque nas etapas do algoritmo relacionadas à filtragem espacial, extração de características e classificação. Assim, algumas das grandes dificuldades no projeto de algoritmos eficientes ficaram evidentes, como a variabilidade inter e intraindividual dos sinais de EEG, por exemplo. Os algoritmos são um dos maiores objetos de atenção das pesquisas que visam tornar viável o uso de sistemas controlados por sinais cerebrais. No trabalho foram abordadas essencialmente as etapas de filtragem

espacial e extração de características, tidas como etapas de grande relevância no algoritmo. Nas análises, mais importante do que o valor das taxas de acertos, a contribuição do trabalho se deu ao abordar questões que afetam consideravelmente o desempenho do algoritmo como um todo, como a seleção de técnicas para extrair características e seleção de canais. Assim, as melhoras ou pioras relativas com os dados de cada pessoa e as diferenças entre os resultados de pessoas distintas foram os objetos principais de análise. Para proporcionar essa visão, foi proposta uma metodologia que envolveu a criação de um método denominado por Método de Três Etapas e, posteriormente, a criação do Método de Duas Etapas após pequenas modificações no primeiro. Os métodos se basearam na variação de diversos parâmetros existentes nos algoritmos, como variáveis dentro das diferentes técnicas utilizadas no pré-processamento e processamento e o grupo de canais utilizados. O objetivo dos métodos foi encontrar configurações ótimas para cada pessoa, no que diz respeito à extração de características e escolha dos canais a serem utilizados.

As técnicas em si não foram abordadas com grande profundidade, mas a variação dos parâmetros considerados mais importantes dentro delas permitiu as análises desejadas. Os sinais de controle, essenciais para projetar técnicas de extração de características, foram apresentados e levados em consideração como base, ainda que não de forma muito profunda, para identificar as características potencialmente mais relevantes do sinal e selecionar as técnicas por meio das quais elas seriam extraídas. A parte prática foi abordada primeiramente do ponto de vista da aquisição do sinal para análises *offline*, onde foi possível perceber a dificuldade na obtenção de sinais com qualidade, seja pelo equipamento, pela habilidade da pessoa ou pela falta de padronização no método, fazendo com que as conclusões obtidas com os resultados sejam muitas vezes reféns de particularidades nessa etapa. Tal situação dificulta a comparação de resultados entre trabalhos da área. Por último, um sistema simples e prático foi projetado para avaliar a utilização do algoritmo em tempo real. A idéia de utilizar equipamentos relativamente baratos e de dimensões reduzidas, como Raspberry Pi em vez de um notebook, tem o intuito de mostrar que um sistema dessa natureza não implica necessariamente em grandes transformações nos equipamentos já existentes, diminuindo possíveis desconfortos que o uso no dia a dia pode acarretar. Os resultados obtidos no trabalho permitiram tirar conclusões acerca de

cada etapa da metodologia. As principais delas são relatadas nos parágrafos seguintes.

O Método de Três Etapas mostrou com a etapa 1 que a escolha por características genéricas para representar sinais de indivíduos diferentes sem nenhum treinamento da parte dos mesmos não é recomendável. Foi visto que a seleção de filtro espacial e de técnicas de extração de características promoveu melhora nos resultados. Além disso, foi observado que as melhores configurações de cada pessoa foram únicas, evidenciando a conhecida variabilidade interpessoal dos sinais de EEG. A etapa 2 apresentou um método para selecionar os melhores grupos de canais de características a partir de um denso conjunto posicionado na região do córtex motor. Essa estratégia se mostrou eficaz na identificação dos canais mais relevantes para a classificação do sinal e mostrou novamente a variabilidade interpessoal, dessa vez relacionada à distribuição espacial dos sinais, já que os melhores grupos também foram únicos para cada indivíduo. Na etapa 3 a relação dos canais utilizados no filtro espacial com a taxa de acertos foi investigada. Com isso, foi visto que em alguns casos a eliminação de um ou mais canais favoreceu a classificação final. Essa constatação encoraja um estudo mais profundo acerca da eficácia dos filtros espaciais em função dos canais utilizados.

Com o Método de Duas Etapas – etapa 1, constatou-se que foi possível reduzir o universo de buscas em relação ao método anterior, dando maior enfoque nas técnicas que se mostraram mais eficazes, assim obtendo resultados ligeiramente melhores, no geral. A etapa 2 evidenciou a relação de interdependência entre os canais selecionados e as características que são extraídas, pois para cada pessoa os grupos de canais variando de um a 39 foram distintos daqueles obtidos no método anterior. Após a aplicação de ambos os métodos, os resultados de validação ficaram entre 59 e 94% para as sete pessoas. No trabalho de Qiu et al. (2016), em que o mesmo banco de dados é utilizado, os acertos para as sete pessoas ficaram entre 63 e 96%, mostrando que o presente trabalho está coerente com dados da literatura.

As análises *offline* com dados extraídos com o Emotiv (capítulo 5) ratificaram as constatações observadas anteriormente. Além disso, revelou algumas dificuldades encontradas para o uso das interfaces em situações práticas, pois utilizou um equipamento com boas características de portabilidade e estética, mas que, em função disso, possui maiores limitações em relação à qualidade do

sinal registrado. A ausência de eletrodos na região do córtex motor também gera consideráveis dificuldades para a aplicação desejada. As taxas de acertos com dados de validação para os cinco participantes ficaram entre 51 e 66%. Os trabalhos de Rodriguez-Bermudez et al. (2013) e Tolic e Jovic (2013) obtiveram, respectivamente, acertos entre 67 e 83% e 67 e 73% ao classificarem os MIs da mão esquerda e mão direita com dados de quatro pessoas. Em ambos os trabalhos, foram utilizados canais associados ao córtex motor para gerar características, de forma que a superioridade desses resultados em relação aos obtidos com o Emotiv no capítulo 5 é consistente com as limitações observadas em relação aos eletrodos desse equipamento.

Ainda no capítulo 5, fica clara também a diferença de desempenho com sinais de pessoas diferentes. É importante levar em consideração que as pessoas podem ter habilidades muito distintas na execução dos movimentos imaginários, de forma que o fraco desempenho na classificação talvez não seja contornado somente com equipamentos melhores, mas com um treinamento adequado do usuário. Algumas outras análises foram feitas variando o intervalo de tempo processado, mas devido ao tamanho limitado do banco de dados, os resultados ficaram comprometidos, dificultando conclusões mais precisas. Quando se tentou classificar apenas um único MI, o resultado de uma das pessoas permitiu realizar considerações importantes relacionadas à seleção de características. O que se viu foi que essa seleção pode ter se “adaptado” de forma tão livre que tenha representado na realidade outra atividade registrada pelo equipamento de EEG. Dessa forma, foi visto que pode ser interessante impor critérios mais rigorosos a essa seleção, em função de um conhecimento mais profundo do sinal de controle que se pretende identificar ou fazer registros em momentos distintos da mesma pessoa, a fim de que somente os sinais de interesse sejam pontos comuns dos diferentes registros.

No capítulo 6, o sistema embarcado atendeu às expectativas no que diz respeito à praticidade do sistema físico como um todo. O funcionamento em tempo real ocorreu de maneira satisfatória, já que a unidade de processamento e o equipamento de EEG trabalharam em perfeita sincronia quando foi necessário classificar sinais a cada 1 s. Com os testes realizados, foi visto que em poucas sessões o Sujeito 1 obteve grande evolução nos resultados e o desempenho em tempo real foi considerado satisfatório, dada a inexperiência do sujeito e as

limitações do equipamento de EEG em relação à qualidade do sinal e aos eletrodos disponíveis. Em um dos testes processando intervalos de apenas 1 s, o sistema acertou 75% dos comandos executados pelo participante, valor equiparável aos resultados já mencionados de Rodriguez-Bermudez et al. (2013) e Tolic e Jovic (2013). Cabe lembrar que, nos testes em tempo real com Emotiv, o participante manteve o olhar direcionado para a mão cujo movimento estava sendo imaginado, o que pode ter contribuído para um sinal mais fácil de ser detectado. Foi visto ainda que é possível reduzir consideravelmente o universo de buscas na seleção de características ao fazer repetidas análises com uma mesma pessoa. A contribuição mais importante, todavia, foi perceber que utilizar bancos de dados registrados em dias distintos para ajustar o sistema pode ser suficiente para garantir uma boa performance em tempo real, sem a necessidade de coletar dados imediatamente antes de cada uso. A análise *offline* nesse caso forneceu inclusive uma perspectiva mais realista de como seria o desempenho em tempo real.

Como sugestão para trabalhos futuros, pode ser incluída no processo uma ou mais técnicas de remoção de artefatos. Para facilitar a classificação dos sinais, é recomendado também que sejam extraídas características específicas para cada canal ou região do couro cabeludo. Isto é, as etapas 1 e 2 dos métodos podem ser fundidas, dando origem a outra mais complexa. Por fim, as técnicas de extração de características utilizadas podem ser investigadas e aprimoradas, visando atender mais corretamente aos sinais de controle adotados. Outros critérios de classificação, bem como outros classificadores também podem ser considerados. Repetidas análises *offline* para as mesmas pessoas também é sugerido, pois podem fornecer conclusões mais precisas em relação às especificidades de cada indivíduo. No aspecto prático, a principal recomendação é referente ao equipamento de EEG. É importante manter a praticidade do Emotiv, porém é sugerido que os eletrodos sejam mais bem posicionados e em quantidades mais apropriadas. Sinais com melhor qualidade também são recomendados.

Apêndice A

a. Superfície Esférica Laplaciana – Interpretação física (Carvalhoes e De Barros, 2015)

EEG no couro cabeludo diz respeito a potenciais em relação a alguma referência, geralmente o valor medido por um eletrodo previamente escolhido. Do ponto de vista físico, porém, o campo elétrico é mais fundamental que o potencial. Para uma partícula q , o campo $E(r)$ na posição r é definido como a razão entre a força elétrica F_E atuando na carga em r e o valor de q . Portanto, o campo é uma quantidade que mede a força por unidade de carga.

$$E(r) \equiv \frac{1}{q} F_E(r) \quad (1)$$

Campos elétricos gerados por cargas pontuais são descritos pela lei de Coulomb. Uma consequência dessa lei é que $E(r)$ é conservativo, isto é, a integral abaixo entre r_A e r_B independe da trajetória na qual é computada.

$$V_{AB} = - \int_{r_A}^{r_B} E(r) \cdot dr \quad (2)$$

O valor V_{AB} corresponde ao trabalho por unidade de carga necessário para levar uma partícula carregada quando ela atravessa o campo $E(r)$ da posição r_A para a posição r_B a uma velocidade constante. Um fato importante é que a independência de V_{AB} em relação à trajetória implica na existência de uma função $V(r)$ tal que

$$V_{AB} \equiv V(r_B) - V(r_A) \quad (3)$$

A função $V(r)$ é chamada de potencial elétrico do campo $E(r)$. Uma relação importante entre o campo e o potencial é dada pelo gradiente:

$$\text{Grad}(V(r)) = \frac{\partial V(r)}{\partial x} \hat{i} + \frac{\partial V(r)}{\partial y} \hat{j} + \frac{\partial V(r)}{\partial z} \hat{k} \quad (4)$$

O gradiente de V é um vetor que aponta na direção onde há maior variação de V e a magnitude do vetor é a taxa de variação. Em outras palavras, a direção perpendicular ao gradiente de V aponta na direção das linhas isopotenciais. A

partir disso é possível provar que a função $V(r)$ se relaciona com o campo $E(r)$ pela expressão

$$E(r) = -\text{Grad}(V(r)) \quad (5)$$

É possível perceber que $V(r)$ não é unicamente definida, como qualquer outra função $V'(r)$ dada por

$$V'(r) \equiv V(r) - V_0 \quad (5)$$

onde V_0 é uma constante arbitrária.

Na prática, observar o campo elétrico é difícil, mas medir o trabalho elétrico em uma partícula de teste, relacionado com a integral de linha entre dois pontos r_A e r_B não. Isto é feito inserindo duas sondas (eletrodos, no caso do EEG) nos pontos r_A e r_B , e criando um circuito paralelo e com alta impedância, de tal forma que apenas uma perturbação mínima seja criada no circuito original. A corrente que surge nesse novo circuito é proporcional à diferença de potencial $V(r_B) - V(r_A)$.

Em um volume condutor, como o cérebro, saber o campo elétrico pode ser muito útil, uma vez que está relacionado com a densidade de corrente j dada por

$$E(r) = \rho j(r) \quad (6)$$

onde $\rho = 1/\sigma$ é a resistividade, que é o inverso da condutividade σ .

O significado físico do Laplaciano advém da lei de Gauss, que em sua forma diferencial é escrita como

$$\text{Div}(E) = 4\pi\rho_Q \quad (7)$$

onde ρ_Q é a densidade de carga. Considerando um campo E representado por

$$E = E_x\hat{i} + E_y\hat{j} + E_z\hat{k} \quad (8)$$

O divergente é dado por

$$\text{Div}(E) = \frac{\partial E_x}{\partial x} + \frac{\partial E_y}{\partial y} + \frac{\partial E_z}{\partial z} \quad (9)$$

Esse divergente pode ser entendido como uma medida local da diferença entre o fluxo de campo que entra e o que sai em um volume infinitesimal em torno do ponto no qual é calculado. Dessa forma, ele é uma medida de fontes (divergente positivo) e “absorvedores” (divergente negativo) do campo elétrico. Assim, a lei de Gauss tem a interpretação física imediata de que as cargas elétricas são fontes de um campo elétrico: se não há cargas elétricas, o divergente do campo é nulo.

Da equação

$$E(r) = -\text{Grad}(V(r)) \quad (10)$$

temos que

$$\text{Div}(E) = -\text{Div}(\text{Grad}(V)) \quad (11)$$

O divergente do gradiente de V é definido com o Laplaciano de V .

$$\text{Lap}(V) \equiv \text{Div}(\text{Grad}(V)) \quad (12)$$

Das equações acima, temos que

$$\text{Lap}(V) = -4\pi\rho_Q \quad (13)$$

O Laplaciano parte do princípio de que as fontes estão todas dentro da cabeça e que não há fontes na superfície onde estão os eletrodos. A partir disso, temos que $\text{Lap}(V) = 0$. Em coordenadas cartesianas, temos

$$\frac{\partial^2 V}{\partial x^2} + \frac{\partial^2 V}{\partial y^2} + \frac{\partial^2 V}{\partial z^2} = 0 \quad (14)$$

Podemos escolher um sistema de coordenadas no qual a superfície do couro cabeludo esteja no plano xy (para pequenas áreas essa suposição é razoável).

Nesse caso, o gradiente de V será nulo em x e y , portanto $E(r) = -\frac{\partial V(r)}{\partial z} \hat{k}$.

Podemos então substituir a segunda derivada de V em z pela primeira derivada de E em z com sinal negativo e reescrever a equação (14) como

$$\frac{\partial^2 V}{\partial x^2} + \frac{\partial^2 V}{\partial y^2} = \frac{\partial E}{\partial z} \quad (15)$$

Tendo em vista que em um condutor vale a relação $E = \rho j$, segue-se que

$$\frac{\partial^2 V}{\partial x^2} + \frac{\partial^2 V}{\partial y^2} = \rho \frac{\partial j_z}{\partial z} \quad (16)$$

O lado esquerdo da equação acima é definido como a *superfície Laplaciana de V* .

Ou seja,

$$\text{Lap}_S(V) = \frac{\partial^2 V}{\partial x^2} + \frac{\partial^2 V}{\partial y^2} \quad (17)$$

Ainda sobre a equação (16), ela mostra o quanto a componente normal da corrente varia na direção perpendicular à superfície. Nesse caso, na ausência de fontes, a mudança de corrente nesta direção significa uma ventilação para fora das linhas de corrente, isto é, uma dispersão das correntes. No caso do couro cabeludo, isso significa que um $\text{Lap}_S(V)$ diferente de zero corresponde a linhas de corrente divergentes (em relação à direção radial) sob o couro cabeludo, o que está associado à presença de uma fonte de corrente dentro do crânio.

b. Superfície Esférica Laplaciana – Cálculo (Carvalhoes e De Barros, 2015; Carvalhoes e Suppes, 2011)

A função *spline* é a solução única para o problema de achar uma função f^* que minimize a equação

$$SS(f^*, \lambda) = \frac{1}{N} \sum (V_i - f(\mathbf{r}_i))^2 + \lambda J_m[f^*(\mathbf{r})] \quad (18)$$

onde N é a quantidade de canais, V_i são os potenciais medidos, \mathbf{r}_i são as posições dos eletrodos, λ é o parâmetro de regularização, $J_m[f^*]$ é a medida da rugosidade de f^* em termos de sua derivada parcial de m -ésima ordem (Wahba, 1990 *apud* Carvalhoes e De Barros, 2015) e m , que aparece apenas como um índice na Equação (18), é na realidade a flexibilidade do ajuste. Se $\lambda = 0$, então ocorre uma interpolação ($f^*(\mathbf{r}_i) = V_i$), se $\lambda > 0$ ocorre uma suavização dos dados.

A função que minimiza $SS(f^*, \lambda)$ tem a forma geral

$$f(\mathbf{r}) = \sum_{i=1}^N c_i \|\mathbf{r} - \mathbf{r}_i\|^{2m-3} + \sum_{l=1}^M d_l \phi_l(\mathbf{r}) \quad (19)$$

onde m e M são inteiros que satisfazem $2m > 3$, $M = \binom{m+2}{3}$ e $M < N$, e $\phi_l(\mathbf{r}) = x^{i-j}y^{j-k}z^k$, onde $l = i + j + k + 1$, $0 \leq i \leq m - 1$, $0 \leq j \leq i$ e $0 \leq k \leq j$.

Usando notação matricial, as variáveis $\mathbf{c} = (c_1, \dots, c_N)^T$ e $\mathbf{d} = (d_1, \dots, d_M)^T$ podem ser expressas como solução do sistema

$$\begin{pmatrix} \mathbf{K} + N\lambda \mathbf{I} & \mathbf{T} \\ \mathbf{T}^T & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{c} \\ \mathbf{d} \end{pmatrix} = \begin{pmatrix} \mathbf{V} \\ \mathbf{0} \end{pmatrix} \quad (20)$$

O vetor coluna \mathbf{c} com N elementos e \mathbf{d} com M elementos são os coeficientes que expandem a função $f^*(\mathbf{r})$. O \mathbf{V} é o vetor coluna com os N potenciais instantâneos nas posições $\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_N$. As matrizes \mathbf{K} e \mathbf{T} têm dimensões $N \times N$ e $N \times M$, respectivamente. Os elementos de \mathbf{K} são dados por $(\mathbf{K})_{ij} = \|\mathbf{r}_i - \mathbf{r}_j\|^{2m-3}$. Os elementos de \mathbf{T} são dados por $(\mathbf{T})_{ij} = \phi_j(\mathbf{r}_i)$.

O sistema possui a solução formal (Wahba, 1990 *apud* Carvalhoes e De Barros, 2015)

$$\mathbf{c} = \mathbf{Q}_2 [\mathbf{Q}_2^T (\mathbf{K} + N\lambda \mathbf{I}) \mathbf{Q}_2]^{-1} \mathbf{Q}_2^T \mathbf{V} \quad (21)$$

$$\mathbf{Rd} = \mathbf{Q}_1^T (\mathbf{V} - \mathbf{Kc} - N\lambda \mathbf{c}) \quad (22)$$

onde \mathbf{Q}_1 $_{N \times M}$, \mathbf{Q}_2 $_{N \times (N-M)}$ e \mathbf{R} $_{M \times M}$ são matrizes obtidas a partir da decomposição QR de \mathbf{T} $_{N \times M}$ (Equação (23)), que também inclui a matriz nula \mathbf{O} $_{(N-M) \times M}$.

$$\mathbf{T} = (\mathbf{Q}_1 \quad \mathbf{Q}_2) \begin{pmatrix} \mathbf{R} \\ \mathbf{O} \end{pmatrix} \quad (23)$$

Os potenciais suavizados V_λ na posição dos eletrodos podem ser representados por

$$\mathbf{V}_\lambda = \mathbf{K}\mathbf{c} + \mathbf{T}\mathbf{d} \quad (24)$$

Definindo $(\tilde{\mathbf{K}})_{ij} = Lap_s(\|\mathbf{r}_i - \mathbf{r}_j\|^{2m-3})$ e $(\tilde{\mathbf{T}})_{ij} = Lap_s(\phi_j(\mathbf{r}_i))$, chega-se a expressão

$$Lap_s(\mathbf{V}) = \tilde{\mathbf{K}}\mathbf{c} + \tilde{\mathbf{T}}\mathbf{d} \quad (25)$$

No entanto, essa abordagem enfrenta alguns problemas quando aplicada a uma superfície quadrática, como é o caso da esférica. Isso ocorre porque, quando $m > 2$, na matriz \mathbf{T} haverá colunas expandidas pelos termos x^2 , y^2 e z^2 ($\phi_l(\mathbf{r}) = x^{i-j}y^{j-k}z^k$), que são linearmente dependentes devido à restrição $x^2 + y^2 + z^2 = 1$ da geometria da superfície.

Para contornar esse problema, foi proposto por Wahba (1990) *apud* Carvalhaes e De Barros (2015) o uso de distâncias geodésicas em vez de euclidianas para a superfície esférica, o que fornece

$$f^*(\mathbf{r}) = \sum_{i=1}^N c_i g_m(\mathbf{r}, \mathbf{r}_i) + \mathbf{d} \quad (26)$$

onde

$$g_m(\mathbf{r}, \mathbf{r}_i) = \frac{1}{4\pi} \sum_{l=1}^{\infty} \frac{2l+1}{l^m(l+1)^m} P_l(\hat{\mathbf{r}} \cdot \hat{\mathbf{r}}_i) \quad m > 1 \quad (27)$$

e P_l são funções polinomiais de Legendre com uma variável e de grau l , dadas por

$$P_l(a) = \frac{1}{2^l l!} \frac{d^l}{da^l} [(a^2 - 1)^l] \quad (28)$$

Devido a uma singularidade, é definido que $P_l(1) = 1$. O acento circunflexo no produto escalar $\hat{\mathbf{r}} \cdot \hat{\mathbf{r}}_i$ indica se tratar de vetores unitários. Os vetores \mathbf{c} e \mathbf{d} continuam sendo determinados pela solução formal da Equação 20.

Em coordenadas esféricas, utilizando a convenção mostrada na Figura 40, em que $\theta \in [0, \pi]$ é medido a partir do eixo z e $\varphi \in [0, 2\pi]$ é medido a partir do eixo x no sentido anti-horário, tem-se

$$\Delta_{sup} f^* = \frac{1}{r^2 \sin \theta} \left[\frac{\partial}{\partial \theta} \left(\sin \theta \frac{\partial f^*}{\partial \theta} \right) + \frac{1}{\sin \theta} \frac{\partial^2 f^*}{\partial \varphi^2} \right] \quad (29)$$

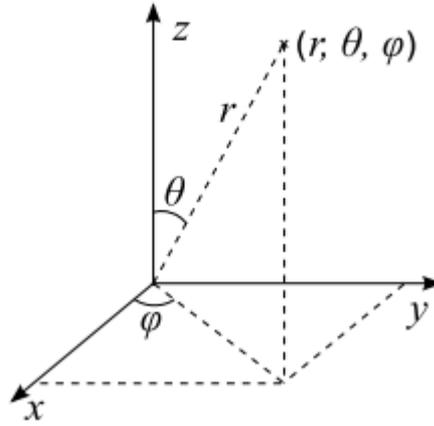


Figura 40 - Sistema de coordenadas esféricas

Como os polinômios de Legendre satisfazem a relação (Jackson, 1999, p.110 *apud* Carvalhaes e De Barros, 2015)

$$\Delta_{sup} P_l(\hat{\mathbf{r}} \cdot \hat{\mathbf{r}}_i) = -\frac{l(l+1)}{r^2} P_l(\hat{\mathbf{r}} \cdot \hat{\mathbf{r}}_i) \quad (30)$$

então a solução para a superfície Laplaciana de $f^*(\mathbf{r})$ é dada por

$$\Delta_{sup} f^*(\mathbf{r}) = -\frac{1}{r^2} \sum_{i=1}^N c_i g_{m-1}(\mathbf{r}, \mathbf{r}_i), \quad m > 1 \quad (31)$$

Tendo em vista que, para *splines* esféricas, $\mathbf{T}_{N \times 1}$, $\tilde{\mathbf{T}}_{N \times 1}$, $\mathbf{K}_{N \times N}$ e $\tilde{\mathbf{K}}_{N \times N}$ são dados por

$$(\mathbf{T})_i = 1 \quad (32)$$

$$(\tilde{\mathbf{T}})_i = 0 \quad (33)$$

$$(\mathbf{K})_{ij} = g_m(\mathbf{r}_i, \mathbf{r}_j) \quad (34)$$

$$(\tilde{\mathbf{K}})_{ij} = -\frac{g_m(\mathbf{r}_j, \mathbf{r}_i)}{r^2} \quad (35)$$

os coeficientes c_i podem ser determinados, bem como o valor do potencial suavizado $\Delta_{sup} f^*(\mathbf{r})$ em um ponto \mathbf{r} arbitrário da superfície Laplaciana.

Para permitir a transformação linear no local dos eletrodos, como demonstrado por Carvalhaes e Suppes (2011), define-se a matriz \mathbf{C} e \mathbf{D} como

$$\mathbf{c} = \mathbf{C}\mathbf{V} \quad (36)$$

$$\mathbf{d} = \mathbf{D}\mathbf{V} \quad (37)$$

Das Equações 21 e 22, conclui-se que

$$\mathbf{C} = \mathbf{Q}_2[\mathbf{Q}_2^T(\mathbf{K} + N\lambda \mathbf{I})\mathbf{Q}_2]^{-1}\mathbf{Q}_2^T \quad (38)$$

$$\mathbf{D} = \mathbf{R}^+\mathbf{Q}_1^T(\mathbf{1} - \mathbf{K}\mathbf{C} - N\lambda\mathbf{C}) \quad (39)$$

onde \mathbf{R}^+ é a pseudo-inversa de \mathbf{R} . A suavização dos dados é dada pela transformação linear

$$\mathbf{V}_\lambda = \mathbf{S}\mathbf{V} \quad (40)$$

onde \mathbf{S} independe dos potenciais e é dada, de acordo com as Equações (24), (36) e (37), por

$$\mathbf{S} = \mathbf{K}\mathbf{C} + \mathbf{T}\mathbf{D} \quad (41)$$

As matrizes \mathbf{C} e \mathbf{D} não são afetadas pela diferenciação no espaço, então, ao aplicar o operador Laplaciano, chega-se a

$$\mathbf{L} = \tilde{\mathbf{K}}\mathbf{C} + \tilde{\mathbf{T}}\mathbf{D} \quad (42)$$

Da Equação (33), conclui-se que

$$\mathbf{L} = \tilde{\mathbf{K}}\mathbf{C} \quad (43)$$

Finalmente, aplicando o operador de Laplace na Equação (40) e usando as relações das Equações (41), (42) e (43), tem-se que a superfície Laplaciana no espaço dos eletrodos é dada por

$$\text{Lap}_S(\mathbf{V}_\lambda) = \mathbf{L}\mathbf{V} \quad (44)$$

Apêndice B

Discriminante Linear de Fisher – (Duda et al., 2001)

Considera-se um conjunto de η amostras $\boldsymbol{\delta}_1, \boldsymbol{\delta}_2, \dots, \boldsymbol{\delta}_\eta$ de d dimensões (isto é, cada $\boldsymbol{\delta}$ é um vetor coluna com d elementos), sendo N_1 a quantidade de amostras no subconjunto D_1 referente à classe τ_1 e N_2 no subconjunto D_2 referente à classe τ_2 . Se for realizada uma combinação linear dos componentes de $\boldsymbol{\delta}$, o resultado será

$$y^* = \mathbf{w}^T \boldsymbol{\delta} \quad (45)$$

Fazendo isso para todas as amostras $\boldsymbol{\delta}_1, \boldsymbol{\delta}_2, \dots, \boldsymbol{\delta}_\eta$, chega-se a um conjunto correspondente com η amostras $y_1^*, y_2^*, \dots, y_\eta^*$, em que cada y^* é um escalar. Esse conjunto pode ser dividido em dois subconjuntos Y_1 e Y_2 , cada um correspondendo a uma classe. Geometricamente, se $\|\mathbf{w}\| = 1$, cada y_i^* é a projeção correspondente de $\boldsymbol{\delta}_i$ em uma linha na direção de \mathbf{w} . O objetivo é que as projeções sejam facilmente separadas nessa linha em função de suas classes τ_1 e τ_2 .

Uma forma de medir a separação das projeções é determinando a distância entre os pontos médios das duas classes. Se \mathbf{m}_i é o vetor correspondente à média das amostras dada por

$$\mathbf{m}_i = \frac{1}{N_i} \sum_{p=1}^{N_i} \boldsymbol{\delta}_p \quad (46)$$

então a média \tilde{m}_i dos pontos projetados das amostras é dada por

$$\tilde{m}_i = \frac{1}{N_i} \sum_{y^* \in Y_i} y^* = \frac{1}{N_i} \sum_{y^* \in Y_i} \mathbf{w}^T \boldsymbol{\delta} = \mathbf{w}^T \mathbf{m}_i \quad (47)$$

Ou seja, é simplesmente a projeção de \mathbf{m}_i . Segue, então, que a distância entre as médias projetadas é

$$|\tilde{m}_1 - \tilde{m}_2| = |\mathbf{w}^T (\mathbf{m}_1 - \mathbf{m}_2)| \quad (48)$$

Para obter uma boa separação das projeções, é necessário que a distância entre as médias seja grande em relação a alguma medida dos desvios-padrão de cada classe. A dispersão dos pontos projetados pertencentes à classe τ_i é utilizada para essa finalidade e é dada por

$$\tilde{s}_i^2 = \sum_{y^* \in Y_i} (y^* - \tilde{m}_i)^2 \quad (49)$$

Dessa forma, $\frac{1}{\eta}(\tilde{s}_1^2 + \tilde{s}_2^2)$ é uma estimativa da variância dos dados agrupados e $\tilde{s}_1^2 + \tilde{s}_2^2$ é chamado de dispersão intraclasse das amostras projetadas. A técnica FLD, que deu origem à generalização conhecida como análise de discriminante linear (LDA, do inglês *linear discriminant analysis*), emprega a função linear $\mathbf{w}^T \boldsymbol{\delta}$ para a qual

$$J(\mathbf{w}) = \frac{|\tilde{m}_1 - \tilde{m}_2|^2}{\tilde{s}_1^2 + \tilde{s}_2^2} \quad (50)$$

é máxima e independente de $\|\mathbf{w}\|$. Enquanto o \mathbf{w} que maximiza $J(\cdot)$ fornece a melhor separação dos dados, é preciso definir também um limiar que funcione como critério de separação entre as classes.

Para obter $J(\cdot)$ como uma função explícita de \mathbf{w} , deve-se definir as matrizes de dispersão \mathbf{S}_i e \mathbf{S}_W como

$$\mathbf{S}_i = \sum_{\boldsymbol{\delta} \in D_i} (\boldsymbol{\delta} - \mathbf{m}_i)(\boldsymbol{\delta} - \mathbf{m}_i)^T \quad (51)$$

$$\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2 \quad (52)$$

Então podemos escrever

$$\begin{aligned} \tilde{s}_i^2 &= \sum_{\boldsymbol{\delta} \in D_i} (\mathbf{w}^T \boldsymbol{\delta} - \mathbf{w}^T \mathbf{m}_i)^2 \\ &= \sum_{\boldsymbol{\delta} \in D_i} \mathbf{w}^T (\boldsymbol{\delta} - \mathbf{m}_i)(\boldsymbol{\delta} - \mathbf{m}_i)^T \mathbf{w} \\ &= \mathbf{w}^T \mathbf{S}_i \mathbf{w} \end{aligned} \quad (53)$$

Conseqüentemente, a soma dessas dispersões pode ser escrita como

$$\tilde{s}_1^2 + \tilde{s}_2^2 = \mathbf{w}^T \mathbf{S}_W \mathbf{w} \quad (54)$$

De forma similar, tem-se para a separação das médias projetadas

$$\begin{aligned} (\tilde{m}_1 - \tilde{m}_2)^2 &= (\mathbf{w}^T \mathbf{m}_1 - \mathbf{w}^T \mathbf{m}_2)^2 \\ &= \mathbf{w}^T (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{w} \\ &= \mathbf{w}^T \mathbf{S}_B \mathbf{w} \end{aligned} \quad (55)$$

onde

$$\mathbf{S}_B = (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^T \quad (56)$$

A matriz \mathbf{S}_W é chamada de matriz de dispersão intraclasse. Ela é proporcional à matriz de covariância das amostras dos dados agrupados de d dimensões. A

matriz \mathbf{S}_B é chamada de matriz de dispersão interclasse. Em termos dessas duas matrizes, a função $J(\cdot)$ pode ser escrita como

$$J(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}} \quad (57)$$

Essa expressão é conhecida como a razão de Rayleigh. Através de multiplicadores de Lagrange, é possível demonstrar que o vetor que maximiza $J(\cdot)$ deve satisfazer

$$\mathbf{S}_B \mathbf{w} = \lambda \mathbf{S}_W \mathbf{w} \quad (58)$$

para uma constante λ , o que é um problema de autovalor. Se \mathbf{S}_W é não singular, o problema convencional de autovalor pode ser obtido da forma

$$\mathbf{S}_W^{-1} \mathbf{S}_B \mathbf{w} = \lambda \mathbf{w} \quad (59)$$

Nesse caso particular, não é necessário resolver o problema para os autovalores e autovetores de $\mathbf{S}_W^{-1} \mathbf{S}_B$ devido ao fato de que $\mathbf{S}_B \mathbf{w}$ está sempre na direção de $\mathbf{m}_1 - \mathbf{m}_2$. Como \mathbf{w} independe de localização no espaço, a solução para \mathbf{w} que otimiza $J(\cdot)$ pode ser imediatamente escrita:

$$\mathbf{w} = \mathbf{S}_W^{-1} (\mathbf{m}_1 - \mathbf{m}_2) \quad (60)$$

Por fim, só resta calcular o limiar que será usado para definir se o ponto projetado pertence a uma classe ou à outra.

Bibliografia

Arvaneh, M., Guan, C., and Ang, K. K., “Optimizing the Channel Selection and Classification Accuracy in EEG-Based BCI,” *IEEE Trans. Biomed. Eng.*, vol. 58, no. 6, pp. 1865–1873, 2011.

Atyabi, A. Luerssen, M. H., and Powers, D. M. W., “PSO-based dimension reduction of EEG recordings: Implications for subject transfer in BCI,” *Neurocomputing*, vol. 119, pp. 319–331, 2013.

Babiloni, F., Cincotti, F., Carducci, F., Rossini, P. M., and Babiloni, C., “Spatial enhancement of EEG data by surface Laplacian estimation: The use of magnetic resonance imaging-based head models,” *Clin. Neurophysiol.*, vol. 112, no. 5, pp. 724–727, 2001.

Badrzadeh, H., Sarukkalige, R., and Jayawardena, A. W., “Impact of multi-resolution analysis of artificial intelligence models inputs on multi-step ahead river flow forecasting,” *J. Hydrol.*, vol. 507, pp. 75–85, 2013.

Baillet, S., Mosher, J. C., and Leahy, R. M., “Electromagnetic brain mapping,” *IEEE Signal Process. Mag.*, vol. 18, no. 6, pp. 14–30, 2001.

Barbosa, A., Achanccaray, D., and Meggiolaro, M., “Activation of a mobile robot through a brain computer interface,” *In proceedings of IEEE Int. Conf. on Robotics and Automation (ICRA)*, pp. 4815–4821, 2010.

Barbosa, A., Freitas, D., Guedes, J., and Meggiolaro, M., “Implementation of a Wheelchair Control Using a Four-Command Brain Computer Interface,” *Cobem*, vol. 6, pp. 5046–5057, 2013.

Barham, M. P., Clark, G. M., Hayden, M. J., Enticott, P. G., Conduit, R., and Lum, J. A. G., “Acquiring research-grade ERPs on a shoestring budget: A comparison of a modified Emotiv and commercial SynAmps EEG system,” *Psychophysiology*, vol. 54, no. 9, pp. 1393–1404, 2017.

Bell, C. J., Shenoy, P., Chalodhorn, R., and Rao, R. P., “Control of a humanoid robot by a noninvasive brain-computer interface in humans,” *J. Neural Eng.*, vol. 5, no. 2 PG-214-220, pp. 214–220, 2008.

Birbaumer, N., “Breaking the silence: Brain-computer interfaces (BCI) for communication and motor control,” *Psychophysiology*, vol. 43, no. 6, pp. 517–532, 2006.

Blankertz, B., Acqualagna, L., Dähne, S., Haufe, S., Schultze-kraft, M., Sturm, I., Ušcumlic, M., Wenzel, M. A., Curio, G., and Müller, K. R., “The Berlin Brain-Computer Interface: Progress Beyond Communication and Control,” *Frontiers in Neuroscience*, vol. 10, 2016.

Blankertz, B., Dornhege, G., Krauledat, M., Müller, K. R., and Curio, G., “The non-invasive Berlin Brain-Computer Interface: Fast acquisition of effective performance in untrained subjects,” *Neuroimage*, vol. 37, no. 2, pp. 539–550, 2007.

Blankertz, B., Tomioka, R., Lemm, S., Kawanabe, M., and Müller, K. R., “Optimizing Spatial Filters for Robust EEG Single-Trial Analysis,” *IEEE Signal Process. Mag.*, vol. XX, pp. 1–12, 2008.

Carvalhoes C. G., and Suppes, P., “A spline framework for estimating the EEG surface laplacian using the Euclidean metric,” *Neural Comput.*, vol. 23, no. 11, pp. 2974–3000, 2011.

Carvalhoes C., and De Barros, J. A., “The surface Laplacian technique in EEG: Theory and methods,” *Int. J. Psychophysiol.*, vol. 97, no. 3, pp. 174–188, 2015.

Cheng, M., Lu, Z., and Wang, H., “Regularized common spatial patterns with subject-to-subject transfer of EEG signals,” *Cogn. Neurodyn.*, vol. 11, no. 2, pp. 173–181, 2017.

Choi, K., “Control of a vehicle with EEG signals in real-time and system evaluation,” *Eur. J. Appl. Physiol.*, vol. 112, no. 2, pp. 755–766, 2012.

Cincotti, F., Mattia, D., Aloise, F., Bufalari, S., Schalk, G., Oriolo, G., Cherubini, A., Marciani, M. G., and Babiloni, F., “Non-invasive brain-computer interface system: Towards its application as assistive technology,” *Brain Res. Bull.*, vol. 75, no. 6, pp. 796–803, 2008.

Duda, R. O., Hart, P. E., and Stork, D. G., “Pattern Classification,” New York: John Wiley, Section. p. 680, 2001.

Duvinage, M., Castermans, T., Petieau, M., Hoellinger, T., Cheron, G., and Dutoit, T., “Performance of the Emotiv Epoc headset for P300-based applications,” *Biomedical Engineering Online*, vol. 12, no. 1, p. 56, 2013.

- Emokit, [online] disponível em <<https://github.com/openyou/emokit>>. Acesso em 16/04/2017.
- Emotiv, [online] disponível em <<https://emotiv.zendesk.com/hc/en-us/articles/204872125-Electrode-Oxidation>>. Acesso em 01/12/2017.
- Falzon, O., Camilleri, K. P., and Muscat, J., “The analytic common spatial patterns method for EEG-based BCI data,” *J. Neural Eng.*, vol. 9, p. 45009, 2012.
- Filho, S. A. S., Tierra-Criollo, C. J., Souza, A. P., Pinto, M. A. S., Lima, M. L. C., and Manzano, G. M., “Magnitude squared of coherence to detect imaginary movement,” *EURASIP J. Adv. Signal Process.*, vol. 2009, 2009.
- Galán, F., Nuttin, M., Lew, E., Ferrez, P. W., Vanacker, G., Philips, J., and Millán, J. del R., “A brain-actuated wheelchair: Asynchronous and non-invasive Brain-computer interfaces for continuous control of robots,” *Clin. Neurophysiol.*, vol. 119, no. 9, pp. 2159–2169, 2008.
- Guger, C., Edlinger, G., Harkam, W., Niedermayer, I., and Pfurtscheller, G., “How many people are able to operate an EEG-based brain-computer interface (BCI)?,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 11, no. 2, pp. 145–147, 2003.
- Hazarika, N., Chen, J. Z., Tsoi, A. C., and Sergejew, A., “Classification of EEG signals using the wavelet transform,” *Proc. 13th Int. Conf. Digit. Signal Process.*, vol. 1, no. 1, pp. 61–72, 1997.
- He, L., Hu, Y., Li, Y., and Li, D., “Channel selection by Rayleigh coefficient maximization based genetic algorithm for classifying single-trial motor imagery EEG,” *Neurocomputing*, vol. 121, pp. 423–433, 2013.
- Hjorth, B., “An on-line transformation of EEG scalp potentials into orthogonal source derivations,” *Electroencephalogr. Clin. Neurophysiol.*, vol. 39, no. 5, pp. 526–530, 1975.
- Jackson, J. D., “Classical Electrodynamics,” 3rd ed. Wiley, New York, 1999.
- Jurcak, V., Tsuzuki, D., and Dan, I., “10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems,” *Neuroimage*, vol. 34, no. 4, pp. 1600–1611, 2007.
- Kayser, J., and Tenke, C. E., “Issues and considerations for using the scalp surface Laplacian in EEG/ERP research: A tutorial review,” *Int. J. Psychophysiol.*, vol. 97, no. 3, pp. 189–209, 2015.

Kee, C., Ponnambalam, S. G., and Loo, C., “Multi-objective genetic algorithm as channel selection method for P300 and motor imagery data set,” *Neurocomputing*, vol. 161, pp. 120–131, 2015.

Khalid, M. B., Rao, N. I., Rizwan-i-Haque, I., Munir, S., and Tahir, F., “Towards a brain computer interface using wavelet transform with averaged and time segmented adapted wavelets,” *2009 2nd Int. Conf. Comput. Control Commun. IC4 2009*, 2009.

Kim, Y. J., Park, S. W., Yeom, H. G., Bang, M. S., Kim, J. S., Chung, C. K., and Kim, S., “A study on a robot arm driven by three-dimensional trajectories predicted from non-invasive neural signals,” *Biomed. Eng. Online*, vol. 14, p. 81, 2015.

Kumar S., and Sahin, F., “A framework for a real time intelligent and interactive Brain Computer Interface,” *Comput. Electr. Eng.*, vol. 43, pp. 193–214, 2014.

Lal, T. N., Schröder, M., Hinterberger, T., Weston, J., Bogdan, M., Birbaumer, N., and Schölkopf, B., “Support Vector Channel Selection in BCI,” *IEEE Trans. Biomed. Eng.*, vol. 51, no. 6, pp. 1003–1010, 2004.

Lana, E. P., Adorno, B. V., and Tierra-Criollo, C. J., “Detection of movement intention using EEG in a human-robot interaction environment,” *Revista Brasileira de Engenharia Biomédica*, vol. 31, no. 4, pp. 285–294, 2015.

Lebedev M. A., and Nicolelis, M. A. L., “Brain-Machine Interfaces: From Basic Science to Neuroprostheses and Neurorehabilitation,” *Physiol. Rev.*, vol. 97, no. 2, pp. 767–837, 2017.

Lent, R., “Cem Bilhões de Neurônios,” Rio de Janeiro: Atheneu, p. 765, 2010.

Lotte, F., Bougrain, L., Clerc, M., “Electroencephalography (EEG)-based Brain-Computer Interfaces,” *Wiley Encycl. Electr. Electron. Eng.*, p. 44, 2015.

Meziani H., [online] disponível em: <<http://www2.fiu.edu/~meziani/NOTE13.pdf>>, acesso em 15/03/2017.

Millán, J. del R., and Mouriño, J., “Asynchronous BCI and local neural classifiers: An overview of the adaptive brain interface project,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 11, no. 2, pp. 159–161, 2003.

Millán, J. del R., Renkens, F., Mouriño, J., and Gerstner, W., “Noninvasive brain-actuated control of a mobile robot by human EEG,” *IEEE Trans. Biomed. Eng.*, vol. 51, no. 6, pp. 1026–1033, 2004.

Müller, K. R., Blankertz, B., Vidaurre, C., Nolte, G., Curio, G., “*BCI Competition IV - dataset I*,” disponível em <<http://www.bbci.de/competition/iv/>>, 2008.

Müller-Gerking, J., Pfurtscheller, G., and Flyvbjerg, H., “Designing optimal spatial filters for single-trial EEG classification in a movement task,” *Clin. Neurophysiol.*, vol. 110, no. 5, pp. 787–798, 1999.

Müller-Putz, G. R., and Pfurtscheller, G., “Control of an electrical prosthesis with an SSVEP-based BCI,” *IEEE Trans. Biomed. Eng.*, vol. 55, no. 1, pp. 361–364, 2008.

Naseer N., and Hong, K.S., “fNIRS-based brain-computer interfaces: a review,” *Front. Hum. Neurosci.*, vol. 9, pp. 1–15, 2015.

Nicolas-Alonso, L. F., and Gomez-Gil, J., “Brain computer interfaces, a review,” *Sensors*, vol. 12, no. 2, pp. 1211–1279, 2012.

Nunez, P. L., Silberstein, R. B., Cadusch, P. J., Wijesinghe, R. S., Westdorp, A. F., and Srinivasan, R., “A theoretical and experimental study of high resolution EEG based on surface Laplacians and cortical imaging,” *Electroencephalogr. Clin. Neurophysiol.*, vol. 90, no. 1, pp. 40–57, 1994.

Oostenveld, R., and Praamstra, P., “The five percent electrode system for high-resolution EEG and ERP measurements,” *Clin. Neurophysiol.*, vol. 112, no. 4, pp. 713–719, 2001.

Ortner, R. Allison, B. Z., Korisek, G., Gaggl, H., and Pfurtscheller, G., “An SSVEP BCI to control a hand orthosis for persons with tetraplegia,” *IEEE Transactions on Neural Systems And Rehabilitation Engineering*, vol. 19, no. 1, pp. 1–5, 2011.

Pfurtscheller G., and da Silva, F. H. L., “Event-related EEG/MEG synchronization and desynchronization: Basic principles,” *Clin. Neurophysiol.*, vol. 110, no. 11, pp. 1842–1857, 1999.

Pfurtscheller, G., “Functional brain imaging based on ERD/ERS,” *Vision Res.*, vol. 41, no. 10–11, pp. 1257–1260, 2001.

Pfurtscheller, G., Neuper, C., Müller, G. R., Obermaier, B., Krausz, G., Schlogl, A., Scherer, R., Graimann, B., Keinrath, C., Skliris, D., Wortz, M., Supp,

G., and Schrank, C., “Graz-BCI: State of the art and clinical applications,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 11, no. 2, pp. 177–180, 2003.

Pfurtscheller, G., Solis-Escalante, T., Ortner, R., Linortner, P., and R. Muller-Putz, G., “Self-paced operation of an SSVEP-based orthosis with and without an imagery-based ‘brain switch’: A feasibility study towards a hybrid BCI,” *IEEE Transactions on Neural Systems And Rehabilitation Engineering*, vol. 18, no. 4, pp. 409–414, 2010.

Qiu, Z., Jin, J., Lam, H., Zhang, Y., and Wang, X., “Improved SFFS method for channel selection in motor imagery based BCI,” *Neurocomputing*, vol. 207, pp. 519–527, 2016.

Ramadan, R. A., and Vasilakos, A. V., “Brain computer interface: control signals review,” *Neurocomputing*, vol. 223, pp. 26–44, 2017.

Rodríguez-Bermúdez, G., García-Laencina, P. J., Roca-González, J., and Roca-Dorda, J., “Efficient feature selection and linear discrimination of EEG signals,” *Neurocomputing*, vol. 115, pp. 161–165, 2013.

Ron-Angevin, R., Debeyre, A., Marquet, Y., Lespinet-Najib, V., and Jean, M. A., “Brain computer interface: comparison of two control modes to drive a virtual robot.” *European Scientific Journal*, 2015.

Sanelli, C., Vidaurre, C., Müller, K. R., and Blankertz, B., “Ensembles of adaptive spatial filters increase BCI performance: an online evaluation,” *Journal of Neural Engineering*, vol. 13, no. 4, 2016.

Smith, S. W., “The Scientist and Engineer’s Guide to Digital Signal Processing,” California: California Technical Pub, p.626, 1997.

Squire, L. R., Bloom, F. E., Spitzer, N. C. , du Lac, S., Ghosh, A., and Berg, D., “Fundamental Neuroscience,” Cambridge: Academic Press, p.1127, 2008.

Teplan, M., “Fundamentals of EEG measurement,” *Meas. Sci. Rev.*, vol. 2, no. 2, pp. 1–11, 2002.

Tolic, M. e Jovic, F. “Classification of Wavelet Transformed EEG Signals With Neural Network for Imagined Mental and Motor Tasks,” *Kinesiology*, vol. 45, no. 1. pp. 130–138, 2013.

Wahba, G., “Spline Interpolation and Smoothing on the Sphere,” *Siam Journal on Scientific and Statistical Computing*, vol. 2, no. 1. pp. 5–16, 1981.

Wahba, G., “Spline Models for Observational Data,” Philadelphia: SIAM, p. 180, 1990.

Wang, Y., Gao, S., and Gao, X., “Common Spatial Pattern Method for Channel Selection in Motor Imagery Based Brain-computer Interface,” *Eng. Med. Biol.*, vol. 5, pp. 5392–5395, 2005.

Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., and Vaughan, T. M., “Brain-computer interfaces for communication and control,” *Clin. Neurophysiol.*, vol. 113, no. 6, pp. 767–91, 2002.

Wolpaw, J. R., and McFarland, D. J., “Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 101, no. 51, pp. 17849–54, 2004.

Wu, W., Chen, Z., Gao, X., Li, Y., Brown, E. N., and Gao, S., “Probabilistic Common Spatial Patterns for Multichannel EEG Analysis,” *IEEE Trans Pattern Anal Mach Intell IEEE Trans Pattern Anal Mach Intell March*, vol. 1, no. 373, pp. 639–653, 2015.

Yong, X., Ward, R. K., and Birch, G. E., “Robust Common Spatial Patterns for EEG signal preprocessing,” *Conf. Proc. IEEE Eng. Med. Biol. Soc.*, vol. 2008, pp. 2087–2090, 2008.

Yuan, H. and He, B., “Brain-Computer Interfaces Using Sensorimotor Rhythms: Current State and Future Perspectives,” *IEEE Trans. Biomed. Eng.*, vol. 61, no. 5, pp. 1425–1435, 2014.

Anexo I

A partir do capítulo 4 do presente trabalho, tem-se o desenvolvimento dos métodos e das atividades práticas, bem como todas as análises inerentes a essas atividades. O desenvolvimento dos métodos foi gradual e pautado nos resultados e discussões das versões mais recentes e também visando às necessidades que adviriam. Desse modo, com o intuito de facilitar a compreensão do trabalho nos capítulos 4, 5 e 6, foi elaborado o fluxograma abaixo.

