

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

JULIANO COSTA MACHADO

**Pré-processamento, extração de características e  
classificação offline de sinais eletroencefalográficos para uso em  
sistemas BCI**

Porto Alegre

2012

Juliano Costa Machado

**Pré-processamento, extração de características e  
classificação offline de sinais eletroencefalográficos para uso em  
sistemas BCI**

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

Área de concentração: Controle e Automação - Instrumentação e Processamento de Sinais.

ORIENTADOR: Dr. Alexandre Balbinot

Porto Alegre

2012

Juliano Costa Machado

**Pré-processamento, extração de características e  
classificação offline de sinais eletroencefalográficos para uso em  
sistemas BCI**

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

Orientador: \_\_\_\_\_

Prof. Dr. Alexandre Balbinot, UFRGS

Doutor pela Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil

Banca Examinadora:

Prof. Dr. Henrique Takachi Moriya, Dept<sup>o</sup> Eng<sup>a</sup> de Telecomunicações e Controle, USP

Doutor pela Universidade de São Paulo, São Paulo, Brasil.

Prof. Dr. Herbert Martins Gomes, PROMEC, UFRGS

Doutor pela Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil.

Prof. Dr. Altamiro Amadeu Susin, PPGEE, UFRGS

Doutor pelo Instituto Politécnico Nacional de Grenoble, Grenoble, França

Coordenador do PPGEE: \_\_\_\_\_

Prof. Dr. João Manoel Gomes da Silva Jr.

Porto Alegre, Novembro de 2012.

## **DEDICATÓRIA**

Dedico este trabalho a minha família que sempre deu suporte aos meus projetos de vida.

Dedico a Natália, que me acompanhou durante todo o desenvolvimento deste trabalho e sempre foi uma fonte de inspiração.

## **AGRADECIMENTOS**

Agradeço ao meu orientador, Alexandre Balbinot, pela oportunidade da realização deste trabalho. Agradeço também todos os colegas do Laboratório de Instrumentação Eletrônica e Biomédica.

Agradeço também as amigas Larissa e Bruna Gabriela pela ajuda na confecção deste trabalho. Agradeço aos colegas e professores do PPGEE que de alguma forma ajudaram.

## RESUMO

O uso de sistemas denominados *Brain Computer Interface*, ou simplesmente BCI, para controle de dispositivos tem gerado cada vez mais trabalhos de análise de sinais de EEG, principalmente devido ao fato do desenvolvimento tecnológico dos sistemas de processamento de dados, trazendo novas perspectiva de desenvolvimento de equipamentos que auxiliem pessoas com debilidades motoras. Neste trabalho é abordado o comportamento dos classificadores LDA (Discriminante Linear de Fisher) e o classificador *Naive Bayes* para classificação de movimento de mão direita e mão esquerda a partir da aquisição de sinais eletroencefalográficos. Para análise destes classificadores foram utilizadas como características de entrada a energia de trechos do sinal filtrados por um passa banda com frequências dentro dos ritmos sensório-motor e também foram utilizadas componentes de energia espectral através do periodograma modificado de Welch. Como forma de pré-processamento também é apresentado o filtro espacial *Common Spatial Pattern* (CSP) de forma a aumentar a atividade discriminativa entre as classes de movimento. Foram obtidas taxas de acerto de até 70% para a base de dados geradas neste trabalho e de até 88% utilizando a base de dados do *BCI Competition II*, taxas de acertos compatíveis com outros trabalhos na área.

Palavras-chave: *Brain Computer Interface* (BCI), Eletroencefalograma (EEG), *Naive Bayes*, Discriminante Linear de Fisher, *Common Spatial Pattern* (CSP), Periodograma de Welch.

## **ABSTRACT**

Brain Computer Interface (BCI) systems usage for controlling devices has increasingly generated research on EEG signals analysis, mainly because the technological development of data processing systems has been offering a new perspective on developing equipment to assist people with motor disability. This study aims to examine the behavior of both Fisher's Linear Discriminant (LDA) and Naive Bayes classifiers in determining both the right and left hand movement through electroencephalographic signals. To accomplish this, we considered as input feature the energy of the signal trials filtered by a band pass with sensorimotor rhythm frequencies; spectral power components from the Welch modified periodogram were also used. As a preprocessing form, the Common Spatial Pattern (CSP) filter was used to increase the discriminative activity between classes of movement. The database created from this study reached hit rates of up to 70% while the BCI Competition II reached hit rates up to 88%, which is consistent with the literature.

**Keywords:** Brain Computer Interface (BCI), Electroencephalogram (EEG), Naive Bayes, Fisher's Linear Discriminant, Common Spatial Pattern (CSP), Welch periodogram.

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>17</b>
<b>1.1 OBJETIVOS</b> .....	<b>17</b>
<b>1.2 JUSTIFICATIVAS</b> .....	<b>18</b>
<b>2 REVISÃO BIBLIOGRÁFICA</b> .....	<b>20</b>
<b>2.1 ANATOMIA DO CÉREBRO HUMANO</b> .....	<b>20</b>
<b>2.1.1 Córtex Motor</b> .....	<b>23</b>
<b>2.2 O SINAL DE EEG</b> .....	<b>25</b>
<b>2.2.1 Ritmos Sensorio-motores e Potenciais Relacionados a Eventos</b> .....	<b>26</b>
<b>2.3 INTERFACE CÉREBRO-COMPUTADOR (BCI)</b> .....	<b>28</b>
<b>2.3.1 Aquisição do sinal e conversão A/D</b> .....	<b>31</b>
<b>2.4 PERIODOGRAMA MODIFICADO DE WELCH</b> .....	<b>32</b>
<b>2.5 PRÉ PROCESSAMENTO</b> .....	<b>38</b>
<b>2.5.1 Filtro Espacial CSP (<i>Common Spatial Pattern</i>)</b> .....	<b>38</b>
<b>2.6 CLASSIFICADORES</b> .....	<b>43</b>
<b>2.6.1 <i>Naive Bayes</i> (NB)</b> .....	<b>43</b>
<b>2.6.2 Discriminante Linear de Fisher (LDA)</b> .....	<b>44</b>
<b>3 METODOLOGIA EXPERIMENTAL</b> .....	<b>46</b>
<b>3.1 PLATAFORMA EXPERIMENTAL</b> .....	<b>48</b>
<b>3.1.1 Geração de Estímulos e Aquisição de Dados</b> .....	<b>48</b>
<b>3.2 PRÉ-PROCESSAMENTO DO BIO-SINAL DE EEG</b> .....	<b>53</b>

3.2.1 Filtro Espacial (CSP) .....	54
3.3 CLASSIFICAÇÃO DO SINAL DE EEG .....	56
3.3.1 Escolha das características.....	56
3.3.2 Extração de características .....	59
3.3.2.1 Sinal Filtrado pelo filtro CSP .....	59
3.3.2.2 Periodograma de Welch .....	59
3.3.3 Classificador <i>Naive Bayes</i> .....	60
3.3.4 Classificador LDA .....	61
3.4 O EXPERIMENTO DA UNIVERSIDADE DE GRAZ.....	61
4 RESULTADOS E DISCUSSÕES.....	63
4.1 ANÁLISE ENERGIA DO SINAL .....	63
4.1.1 Experimento proposto .....	63
4.1.1.1 Índice de Lateralização .....	70
4.1.2 Experimento BCI Competition II.....	71
4.2 ANÁLISE PERIODOGRAMA DE WELCH.....	74
4.2.1 Experimento Proposto .....	75
4.2.2 <i>BCI Competition II</i> .....	78
4.3 ANÁLISE FILTRO ESPACIAL .....	80
4.3.1 Experimento Proposto .....	81
4.3.2 Experimento <i>BCI Competition II</i> .....	84
4.4 RESULTADOS DE CLASSIFICAÇÃO UTILIZANDO A ENERGIA DO SINAL .....	86
4.4.1 Utilizando Filtros CSP e a energia do sinal de EEG para o experimento proposto.....	86
4.4.1.1 Utilizando o classificador LDA.....	87
4.4.1.2 Utilizando o classificador <i>Naive Bayes</i> .....	89

4.4.1.3 Discussão sobre os resultados utilizando filtros CSP a energia do sinal como característica de entrada para o experimento proposto .....	90
4.4.2 Utilizando Filtros CSP e a energia do sinal de EEG para o experimento <i>BCI Competition II</i> .....	92
4.4.3 Discussão dos resultados dos classificadores utilizando a energia como característica de entrada para os 2 experimentos .....	94
4.4.4 Utilizando componentes espectrais como característica de entrada .....	95
4.4.5 Utilizando componentes espectrais para o experimento BCI .....	97
5 CONCLUSÕES .....	99
6 TRABALHOS FUTUROS .....	101
REFERÊNCIAS.....	102
ANEXO A – GRÁFICOS DE ENERGIA PARA AS SESSÕES S1, S2 E S4.....	106

## LISTA DE ILUSTRAÇÕES

Figura 1: Sistema Nervoso Central. Adaptado de (TORTORA, 2000).....	20
Figura 2: Vista lateral do encéfalo (TORTORA, 2000).....	22
Figura 3: (a) Vista superior do cérebro e (b) detalhe do cérebro (TORTORA, 2000). ....	22
Figura 4: Vista lateral direita do cérebro (TORTORA, 2000). ....	23
Figura 5: Localização do Córtex Motor. Adaptado de (BEAR, CONNORS e PARADISO, 2007). ....	24
Figura 6: Representação do córtex motor. (TORTORA, 2000). ....	25
Figura 7: Partes de um típico Sistema BCI. Adaptado de (WOLPAW, BIRBAUMER, <i>et al.</i> , 2002). ....	29
Figura 8: Sistema 10-20 de eletrodos. Extraído de (SANEI e CHAMBERS, 2007). ....	32
Figura 9: Efeito do Filtro Espacial CSP em uma variável bi-dimensional. Adaptado de (BLANKERTZ, TOMIOKA, <i>et al.</i> , 2008). ....	42
Figura 10: Diagrama em blocos do algoritmo LDA (DUDA, HART e STORK, 2000). ....	45
Figura 11: Diagrama de blocos do aparato experimental. ....	46
Figura 12: Imagem do experimento proposto.....	47
Figura 13: Temporização de uma trilha.....	49
Figura 14: Fluxograma dos <i>softwares</i> de aquisição e controle do experimento: (a) fluxograma de execução do <i>software main.vi</i> e (b) fluxograma de execução do <i>software</i> <i>estímulos.vi</i> . ....	52
Figura 15: Fluxograma de separação do dados em trilhas e classes de movimento.....	53

Figura 16: Fluxograma do algoritmo que implementa o filtro $W$ da Eq. (12). .....	56
Figura 17: Janelamento pelo método de Welch para um trecho de 2s com sobreposição de 50% entre as janelas.....	58
Figura 18: Temporização das trilhas do experimento <i>BCI Competition II</i> . Adaptado de (BCI Competition II, 2003). .....	62
Figura 19: Energia média relativa dos canais Fp1 e F3 durante a sessão S3 (banda $\mu$ ). .....	64
Figura 20: Energia média relativa dos canais C3 e P3 durante a sessão S3 (banda $\mu$ ). .....	65
Figura 21: Energia média relativa dos canais Fp2 e F4 durante a sessão S3 (banda $\mu$ ). .....	65
Figura 22: Energia média relativa dos canais C4 e P4 durante a sessão S3 (banda $\mu$ ). .....	66
Figura 23: Energia dos canais Fp1 e F3 durante a sessão S4 (banda $\beta$ ). .....	67
Figura 24: Energia dos canais C3 e P3 durante a sessão S4 (banda $\beta$ ). .....	68
Figura 25: Energia dos canais Fp2 e F4 durante a sessão S4 (banda $\beta$ ). .....	68
Figura 26: Energia dos canais C4 e P4 durante a sessão S4 (banda $\beta$ ). .....	69
Figura 27: Índice lateralização médio e relativo para os canais C3 e C4 para as 4 sessões. ....	70
Figura 28: Energia do canal Cz do experimento <i>BCI Competition II</i> (banda $\mu$ ). .....	71
Figura 29: Energia dos canais C3 e C4 do experimento <i>BCI Competition II</i> (banda $\mu$ ). .....	72
Figura 30: Energia dos canais C3 e C4 do experimento <i>BCI Competition II</i> (banda $\beta$ ). .....	73
.Figura 31: $IL$ normalizado do experimento <i>BCI Competition II</i> (banda $\mu$ e $\beta$ ). .....	73
Figura 32: Energia média do experimento proposto no domínio frequência para os canais Fp1 e F3. ....	75
Figura 33: Energia média do experimento proposto no domínio frequência para os canais C3 e P3. ....	76
Figura 34: Energia média do experimento proposto no domínio frequência para os canais Fp2 e F4. ....	76

Figura 35: Energia média do experimento proposto no domínio frequência para os canais C4 e P4. ....	77
Figura 36: <i>IL</i> do experimento proposto no domínio frequência para todas sessões.....	78
Figura 37: Energia média do <i>BCI Competition II</i> no domínio frequência para os canais C3 e C4.....	79
Figura 38: Energia média do <i>BCI Competition II</i> no domínio frequência para o canal Cz.....	79
Figura 39: <i>IL</i> do <i>BCI Competition II</i> no domínio frequência.....	80
Figura 40: Energia média do experimento proposto no domínio frequência para os canais CSP1 e CSP2. ....	81
Figura 41: Energia média do experimento proposto no domínio frequência para os canais CSP3 e CSP4. ....	82
Figura 42: Energia média do experimento proposto no domínio frequência para os canais C3 e C4 (ritmo $\mu$ apenas). ....	82
Figura 43: Energia média do experimento proposto no domínio frequência para os canais CSP1 e CSP3. ....	85
Figura 44: Energia média relativa dos canais Fp1 e F3 durante a sessão S1 (banda $\mu$ ). ....	107
Figura 45: Energia média relativa dos canais C3 e P3 durante a sessão S1 (banda $\mu$ ). ....	107
Figura 46: Energia média relativa dos canais Fp2 e F4 durante a sessão S1 (banda $\mu$ ). ....	108
Figura 47: Energia média relativa dos canais C4 e P4 durante a sessão S1 (banda $\mu$ ). ....	108
Figura 48: Energia média relativa dos canais Fp1 e F3 durante a sessão S2 (banda $\mu$ ). ....	109
Figura 49: Energia média relativa dos canais C3 e P3 durante a sessão S2 (banda $\mu$ ). ....	109
Figura 50: Energia média relativa dos canais Fp2 e F4 durante a sessão S2 (banda $\mu$ ). ....	110
Figura 51: Energia média relativa dos canais C4 e P4 durante a sessão S2 (banda $\mu$ ). ....	110
Figura 52: Energia média relativa dos canais Fp1 e F3 durante a sessão S4 (banda $\mu$ ). ....	111
Figura 53: Energia média relativa dos canais C3 e P3 durante a sessão S4 (banda $\mu$ ). ....	111

Figura 54: Energia média relativa dos canais Fp2 e F4 durante a sessão S4 (banda  $\mu$ ). ..... 112

Figura 55: Energia média relativa dos canais C4 e P4 durante a sessão S4 (banda  $\mu$ ). ..... 112

## LISTA DE TABELAS

Tabela 1: Comparação das Janelas mais utilizadas. ....	34
Tabela 2: Codificação digital dos trechos da trilha. ....	51
Tabela 3: Sessões do experimento proposto. ....	64
Tabela 4: Instantes de tempo do janelamento para extração da energia do sinal para o experimento proposto .....	71
Tabela 5: Instantes de tempo do janelamento para extração da energia do sinal para o experimento <i>BCI Competition II</i> . ....	74
Tabela 6: Comparativo da energia proporcional entre classes com e sem o filtro CSP. ....	84
Tabela 7: Comparativo da energia proporcional entre classes com e sem o filtro CSP para o experimento <i>BCI Competition II</i> . ....	86
Tabela 8: Taxas de acerto média com o classificador LDA utilizando os canais C3 e C4 para estimar $W$ e os 2 canais CSP resultantes. ....	87
Tabela 9: Taxas de acerto média com o classificador LDA utilizando os canais C3, C4, P3 e P4 para estimar $W$ e utilizando os 2 melhores canais CSP. ....	88
Tabela 10: Taxas de acerto média com o classificador LDA utilizando os canais C3, C4, P3 e P4 para estimar $W$ e utilizando todos canais CSP. ....	88
Tabela 11: Taxas de acerto média com o classificador <i>Naive Bayes</i> utilizando os canais C3 e C4 para estimar $W$ e os 2 canais CSP resultantes. ....	89
Tabela 12: Taxas de acerto média com o classificador <i>Naive Bayes</i> utilizando os canais C3, C4, P3 e P4 para estimar $W$ e utilizando os 2 melhores canais CSP. ....	89
Tabela 13: Taxas de acerto média com o classificador <i>Naive Bayes</i> utilizando os canais C3, C4, P3 e P4 para estimar $W$ e utilizando todos canais CSP. ....	90

Tabela 14: Taxas de acerto média utilizando os canais C3 e C4 para classificação. ....	92
Tabela 15: Taxas de classificação para o experimento <i>BCI Competition II</i> .....	93
Tabela 16: Taxas de acerto média utilizando componentes espectrais de 2 canais (C3 e C4) para o experimento proposto. ....	95
Tabela 17: Taxas de acerto média utilizando componentes espectrais de 4 canais (C3, C4, P3 e P4) para o experimento proposto. ....	96
Tabela 18: Taxas de acerto utilizando componentes espectrais para o experimento <i>BCI Competition II</i> . ....	97

## **LISTA DE ABREVIATURAS**

A/D: Analógico/Digital

BCI: *Brain Computer Interface*

CSP: *Common Spatial Pattern*

DFT: *Discrete Fourier Transform*

EEG: Eletroencefalograma

ERD: *Event Related Desynchronization*

ERS: *Event Related Synchronization*

IL: Índice de Lateralização

LDA: *Linear Discriminant Analysis*

NB: *Naive Bayes*

SNC: Sistema Nervoso Central

SNP: Sistema Nervoso Periférico

TTL: *Transistor-Transistor Logic*

## 1 INTRODUÇÃO

Sistemas baseados em uma Interface Cérebro-Computador (sigla BCI de *Brain Computer Interface*) utilizam sinais cerebrais extraídos de forma não invasiva, com o uso de eletrodos de superfície (geralmente toucas de eletrodos), ou de forma invasiva, com o uso de eletrodos implantados diretamente no córtex cerebral. O sistema mais estudado, por não necessitar de uma equipe médica, além de permitir uma grande variabilidade de indivíduos, é o método não invasivo (GRAIMANN, ALLISON e PFURTSCHELLER, 2011) (CARRA, 2012). Existem muitas aplicações desenvolvidas dentro das áreas da Engenharia de Reabilitação, com o foco no desenvolvimento de sistemas integrados ao ser humano para acionar próteses, por exemplo, ou outros sistemas que facilitem sua interação com o ambiente (BASHASHATI, FATOURECHI, *et al.*, 2007), facilitando e permitindo a difusão da Tecnologia Assistiva.

### 1.1 OBJETIVOS

Compreender o comportamento do sinal de EEG, analisando suas características no tempo e na frequência de forma a achar maneiras funcionais de aquisição, pré-processamento e processamento, de forma a extrair características que sejam úteis para um classificador diferenciar intenções mentais do usuário de um sistema BCI.

A necessidade de se compreender melhor os sinais provenientes do cérebro durante o movimento de um membro, ou durante a imaginação deste movimento, possibilita o desenvolvimento de métodos alternativos para que pessoas com severas deficiências motoras possam interagir apenas com estímulos cerebrais voluntários. Sistemas BCI podem ser

utilizados não somente dentro do campo da Engenharia de Reabilitação, com a possibilidade, por exemplo, de projetos de próteses acionadas por sinais cerebrais, como na área de Tecnologia Assistiva, onde se busca a possibilidade de facilitar a interação de deficientes com o ambiente. As tentativas de compreender o funcionamento deste tipo de sinal já gerou inúmeros trabalhos sobre formas de processá-los (BASHASHATI, FATOURECHI, *et al.*, 2007) e classificá-los (LOTTE, CONGEDO, *et al.*, 2007). Esse trabalho tem como principais objetivos:

- Desenvolver uma plataforma experimental BCI e criar uma base de dados de sinais de EEG durante o movimento de mãos;
- Utilizar técnicas de extração de características, tal como componentes espectrais e energia do sinal dentro de faixas de frequência específicas;
- Testar e comparar o comportamento dos classificadores *Naive Bayes* e o Discriminante Linear de Fisher com as diferentes características extraídas.

Portanto o foco deste trabalho está na parte inicial do sistema BCI, verificando se através de métodos de pré processamento é possível melhorar a qualidade das características específicas de cada usuário.

## **1.2 JUSTIFICATIVAS**

Com o conhecimento de diferentes ferramentas matemáticas para extração de características e classificação de sinais de EEG é possível que sistemas BCI se torne um meio real para recuperar, mesmo que parcialmente, pacientes com amputações ou dar uma melhor forma de interação a pacientes com paralisias parciais ou totais.

Portanto o que justifica este trabalho é que com a melhor compreensão das ferramentas de análise no tempo, em frequência e de classificação, é possível tornar o sinal de EEG em um acionador de comandos, onde o acionamento é feito de acordo com a vontade do usuário. Este trabalho é uma parte de uma linha de pesquisa sobre análise e classificação de sinais biológicos (FAVIEIRO e BALBINOT, 2011) (FAVIEIRO e BALBINOT, 2012) e mais recentemente trabalhos dentro da área BCI (CARRA, 2012) (CARRA e BALBINOT, 2012) desenvolvidos dentro do Laboratório de Instrumentação Eletro Eletrônica e Biomédica (IEE & Bio) da UFRGS.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 ANATOMIA DO CÉREBRO HUMANO

O encéfalo (estrutura formada pelo cérebro) faz parte do conjunto conhecido como Sistema Nervoso Central (SNC), que também é composto pela medula espinhal. Este conjunto é responsável pela tradução do estímulo recebido pelo Sistema Nervoso Periférico (SNP), através de neurônios sensitivos, e também é responsável pela resposta deste estímulo através dos neurônios motores, que são ligados ao SNC através de nervos cranianos e nervos espinhais (TORTORA, 2000) conforme apresenta a Figura 1.

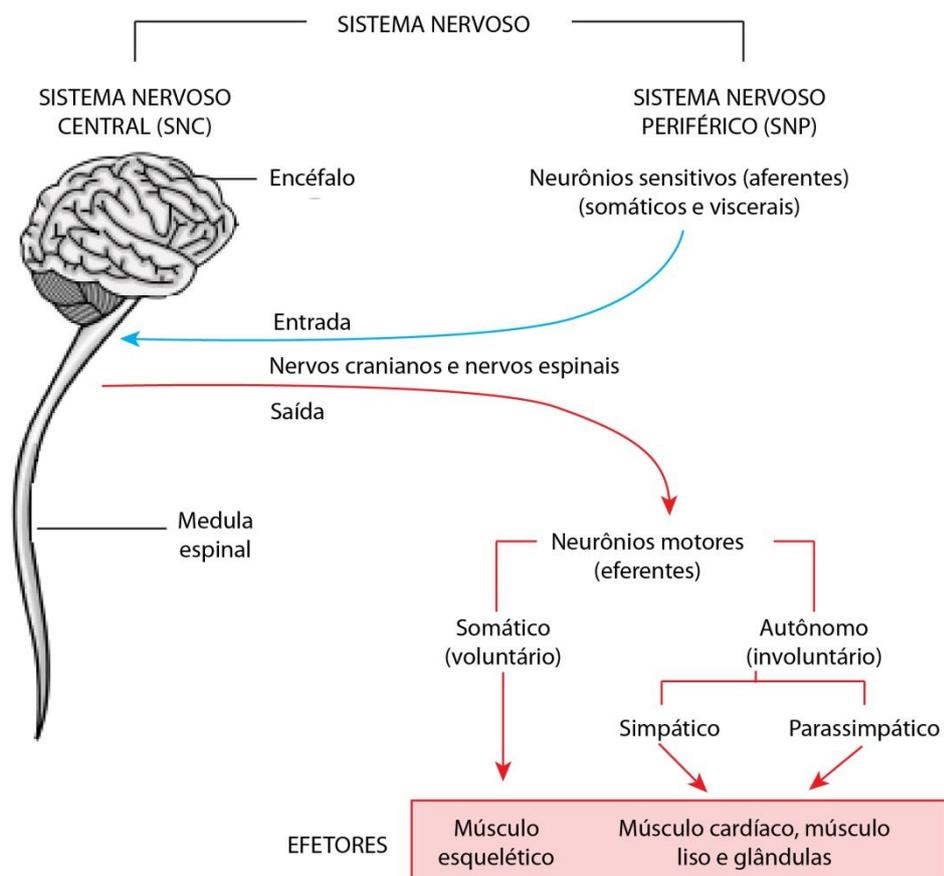


Figura 1: Sistema Nervoso Central. Adaptado de (TORTORA, 2000).

Os neurônios motores são responsáveis por transmitir até os músculos o sinal de resposta do SNC. Se o músculo é utilizado para movimento voluntário (como das pernas e braços, por exemplo) o neurônio motor é chamado de Somático. Se o movimento for involuntário (como os batimentos cardíacos), o neurônio motor é denominado Autônomo.

A medula espinhal é responsável por receber sinais do SNP e transmitir ao encéfalo, assim como transmitir os sinais de resposta para os neurônios motores (TORTORA, 2000). Portanto, observe que o “processamento” da informação de entrada e saída é feita pelo encéfalo, sendo o SNP os “sensores” que enviam a informação ao encéfalo, e os neurônios motores os “acionadores” que recebem o sinal do encéfalo.

O encéfalo (ver Figura 2) é uma estrutura composta de diversas partes, sendo suas principais:

- Tronco Encefálico: é a ligação do cérebro com a medula espinhal. Fazem parte do tronco encefálico o bulbo, a ponte e o mesencéfalo;
- Diencefalo: localizado logo acima do Tronco Encefálico e é composto pelo tálamo e o hipotálamo;
- Telencefalo: é a parte que ocupa a maior parte do crânio e possui dois hemisférios, o esquerdo e o direito;
- Cerebelo: localizado sob o telencefalo e acima do tronco encefálico.

O cérebro é a estrutura formada pelo diencefalo e o telencefalo e tem na sua superfície uma área enrugada e cinzenta denominada córtex cerebral (SOBOTTA, 2006). Esse enrugamento se dá pelo fato do córtex crescer mais rapidamente que a massa branca do interior do cérebro. Essas dobras dão origem a fendas profundas, chamadas de fissuras, sendo

as fissuras rasas chamadas de sulcos. A fissura longitudinal do cérebro o separa em dois hemisférios, o direito e o esquerdo (TORTORA, 2000), conforme mostra a Figura 3.

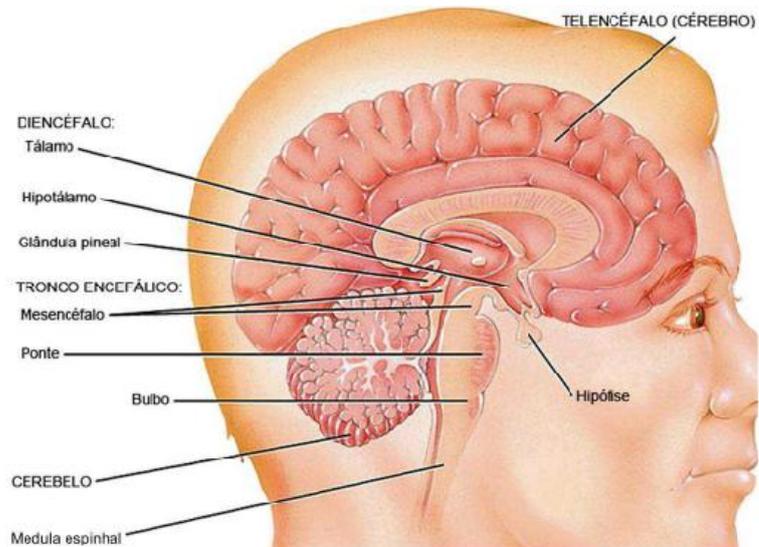


Figura 2: Vista lateral do encéfalo (TORTORA, 2000).

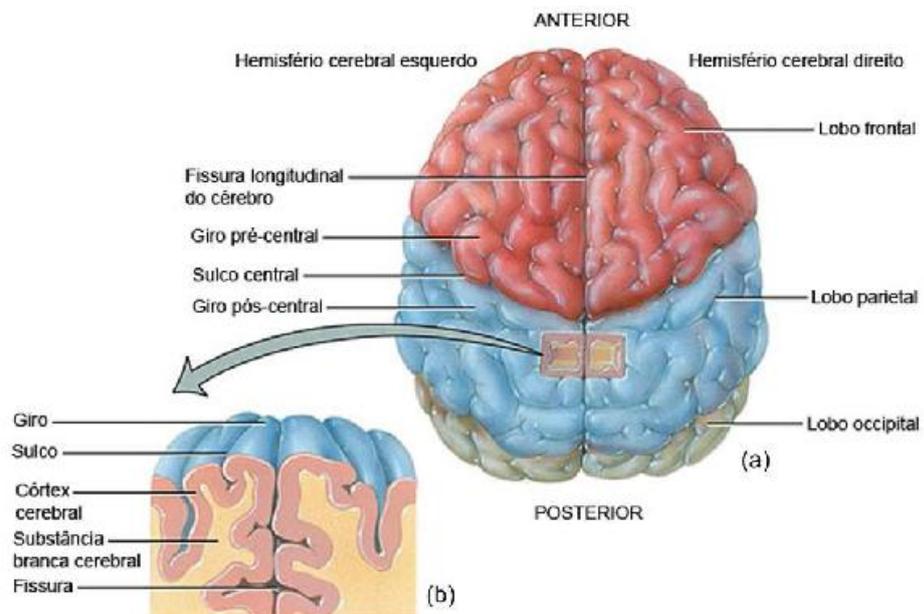


Figura 3: (a) Vista superior do cérebro e (b) detalhe do cérebro (TORTORA, 2000).

Cada hemisfério cerebral pode ser dividido em 4 lobos principais, chamados de lobo frontal, parietal, temporal e occipital. O sulco central divide os lobos central e parietal. Localizado imediatamente anterior ao sulco central está o giro pré-central, onde fica localizada a área motora primária do cérebro (TORTORA, 2000). A localização dos lobos pode ser vista na Figura 4.

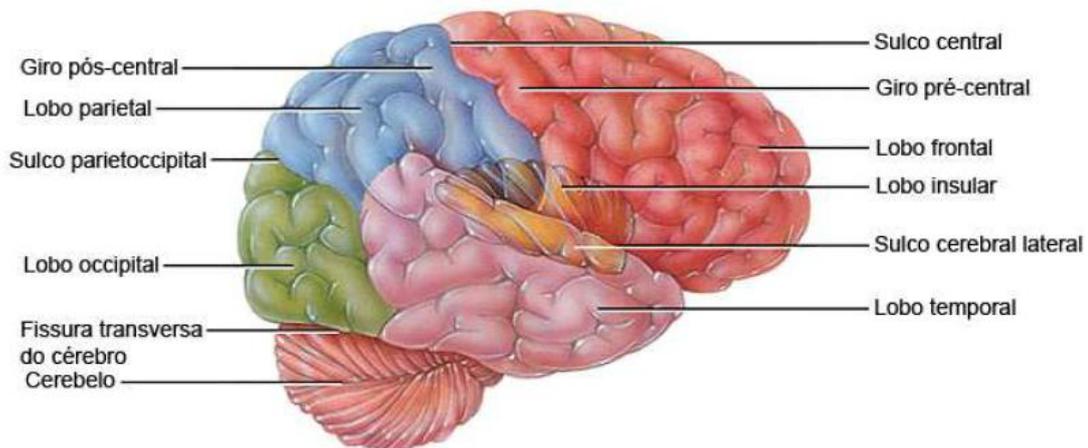


Figura 4: Vista lateral direita do cérebro (TORTORA, 2000).

### 2.1.1 Córtex Motor

O córtex motor é uma região limitada do córtex na região do lobo frontal, indicadas pelas áreas 4 e 6 na Figura 5, e é responsável pelo controle dos movimentos (BEAR, CONNORS e PARADISO, 2007). A área 4 fica anterior ao sulco central e a área 6 anterior a área 4, conforme Figura 5.

Demonstrações do neuro-cirurgião canadense Wilder Penfield mostraram que estas áreas estão diretamente ligadas ao movimento. Ao aplicar pequenos choques elétricos nessas regiões do córtex é possível observar movimentos em músculos na região contralateral, ou

seja, para ativar um músculo do lado direito, deve-se estimular o córtex motor no hemisfério esquerdo (BEAR, CONNORS e PARADISO, 2007).

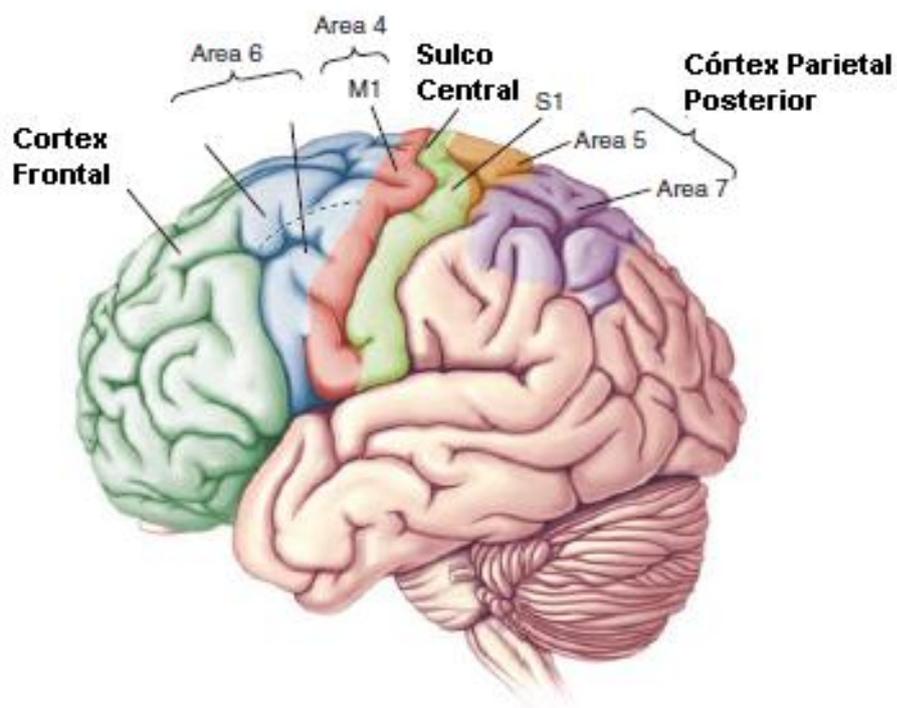


Figura 5: Localização do Córtex Motor. Adaptado de (BEAR, CONNORS e PARADISO, 2007).

O córtex motor tem uma assimetria, como pode-se ver na Figura 6, onde existem regiões muito grandes representando pequenas porções do corpo, como os dedos das mãos, onde o ser humano tem muita sensibilidade. Por outro lado, regiões menores controlam partes com menor sensibilidade, como pernas e braços (TORTORA, 2000). Também pode-se observar que a região que controla o movimento das mãos está localizada em uma região mais afastada do sulco central, ao contrário da região que controla os pés ou as pernas, que está localizada na região do sulco central. Essa posição mais afastada permite fazer uma distinção espacial clara entre os lados contralateral e ipsilateral do movimento das mãos, ao contrário

do movimento de pernas que estão muito próximos, não permitindo ter uma clara distinção entre o movimento da perna direita e esquerda.

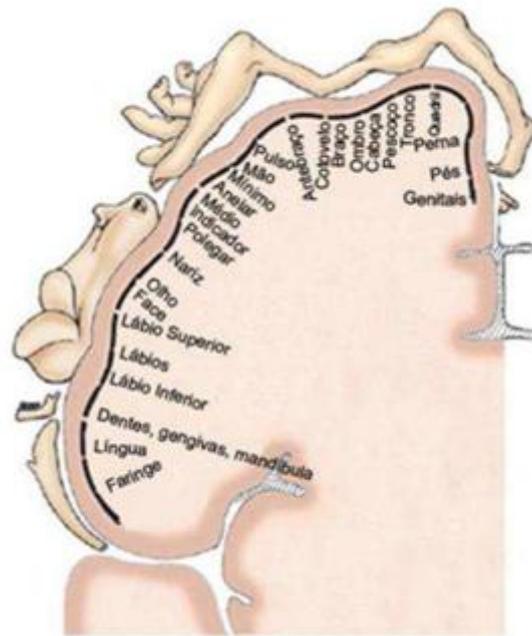


Figura 6: Representação do córtex motor. (TORTORA, 2000).

## 2.2 O SINAL DE EEG

As células do cérebro geram atividade elétrica como resultado de milhões de potenciais de ação (ou impulsos nervosos) de neurônios individuais. Esses potenciais elétricos são denominados ondas cerebrais e indicam a atividade do córtex cerebral (SOBOTTA, 2006).

Os sinais de EEG capturados do escalpo, com frequências geralmente não superiores a 100Hz, é uma medida da atividade elétrica durante a excitação (geração de um potencial de ação ou condução de um estímulo nervoso) de um grupo de neurônios no córtex cerebral. Essa atividade neuronal pode ser capturada, no escalpo, através do campo elétrico gerado

pelos neurônios (SANEI e CHAMBERS, 2007). Através do sinal de EEG medido no escalpo, é possível, dentre outras possibilidades, o diagnóstico de doenças neurológicas e o reconhecimento da intenção de movimento de uma pessoa (WOLPAW, BIRBAUMER, *et al.*, 2002) (PFURTSCHELLER e SILVA, 1999) (CARRA, 2012) (CARRA e BALBINOT, 2012).

Dentro da análise do espectro do sinal de EEG é possível observar variações de energia em diferentes bandas de frequência. Essas variações são devido a mudanças do estado cerebral de um indivíduo. Os padrões de energia em determinadas faixas de frequências podem mudar de forma acentuada de uma pessoa acordada e a mesma pessoa em sono profundo, por exemplo (KROPOTOV, 2009).

Os sinais de EEG são compostos por componentes bem localizadas e componentes não localizadas espacialmente. Componentes não localizadas são geralmente geradas em grandes áreas do córtex. Por outro lado, componentes localizadas podem ser consideradas atividades intrínsecas de certas regiões do córtex. Exemplos de componentes bem localizadas são os ritmos sensório-motores, chamados de ondas  $\alpha$  e ondas  $\beta$  (PFURTSCHELLER, NEUPER, *et al.*, 1997). Durante a execução de um movimento esses dois tipos de sinais podem ser utilizados para reconhecer o movimento ou intenção de movimento: as ondas alfa ( $\alpha$ ), que ficam na faixa de 8Hz a 12Hz e também são comumente chamadas de ritmos- $\mu$ , e ondas (ou ritmo) beta ( $\beta$ ), que se situam na faixa de 13Hz a 26Hz (DORNHEGE, MILLÁN, *et al.*, 2007).

### **2.2.1 Ritmos Sensório-motores e Potenciais Relacionados a Eventos**

Os ritmos sensório-motores podem sofrer modulações em sua amplitude durante o movimento de algum membro do corpo, chamados de dessincronização relacionadas a

eventos (ERD de *Event Related Desynchronization*) e sincronização relacionada a evento (ERS de *Event Related Synchronization*) (PFURTSCHELLER e SILVA, 1999). A ocorrência desse fenômeno é devido ao fato de que quando áreas bem localizadas do cérebro são ativadas (córtex central, no caso dos ritmos sensório-motores), ocorre uma dessincronização (ERD) dentro dos ritmos  $\mu$  e  $\beta$ . Por outro lado, quando essas regiões não estão ativas, ocorre um aumento da energia (ERS) dos ritmos  $\mu$  e  $\beta$  (PFURTSCHELLER e NEUPER, 1994).

Sabe-se que durante o planejamento do movimento tipicamente ocorre uma forte dessincronização (ERD) dos ritmos sensório-motores (8Hz a 26Hz), sendo que a dessincronização do lado contralateral ao movimento é mais acentuada na faixa da banda  $\alpha$  (8 a 12Hz) (PFURTSCHELLER e SILVA, 1999). Na finalização do movimento, tipicamente ocorre um aumento da energia devido a sincronização (ERS), principalmente na faixa de frequência das ondas  $\beta$  (13Hz a 26Hz) (DOYLE, YARROW e BROWN, 2005) (NAM, JEON, *et al.*, 2011).

Estudos mostraram que a atividade neuronal do movimento é lateralizada. Isso significa que o movimento da mão, por exemplo, gera um ERD no lado contralateral (contrário) ao movimento durante o planejamento e execução do mesmo e um ERS no lado ipsilateral (mesmo lado) ao movimento em torno de 1s a 2s após o término do movimento (PFURTSCHELLER e SILVA, 1999) (DOYLE, YARROW e BROWN, 2005) (NAM, JEON, *et al.*, 2011), sendo que o ERD pode ocorrer nos lados ipsilateral e contralateral durante o movimento, mas com o lado ipsilateral sempre mantendo uma energia relativa mais alta que o contralateral (NAM, JEON, *et al.*, 2011).

É importante observar que devido a complexidade do cérebro os efeitos dos ritmos sensório-motor podem ocorrer de forma mais proeminente em apenas um dos hemisférios, assim como em alguns indivíduos podem nem chegar a ocorrer ou ocorrer em bandas de frequências diferentes, assim como em localizações do córtex diferentes do córtex central, existindo portanto uma grande variabilidade de comportamento de indivíduo para indivíduo (PFURTSCHELLER e NEUPER, 1994) (TAN e NIJHOLT, 2010) (GRAIMANN, ALLISON e PFURTSCHELLER, 2011). O ideal, para cada usuário de um sistema BCI, seria a realização de exames mais complexos e custosos, como por exemplo ressonância funcional, para verificar as áreas mais sensíveis ao tipo de fenômeno de interesse.

### **2.3 INTERFACE CÉREBRO-COMPUTADOR (BCI)**

Praticamente toda forma de comunicação e interação do ser humano com o ambiente depende da ação do sistema nervoso central e periférico, além dos músculos. Essas ações são disparadas pela intenção do sujeito (sinal gerado no sistema nervoso central), o que desencadeia processos de transmissão de sinais neurológicos, através do sistema nervoso periférico, enviando sinais aos músculos, que entram em atividade para realizar determinada ação, seja de interação com o ambiente ou de comunicação. A atividade resultante dessas ações é frequentemente chamada de saída motora (ou saída eferente) e depende tanto da intenção do usuário (gerado pelo sistema nervoso central e distribuído pelo sistema nervoso periférico) quanto pelo movimento muscular (que é resultado da chegada do sinal neurológico ao músculo) (GRAIMANN, ALLISON e PFURTSCHELLER, 2011).

Um sistema BCI se propõe a capturar diretamente do sistema nervoso central, através de medições invasivas e/ou não invasivas, a intenção do sujeito. Dessa forma, pode-se criar

próteses e equipamentos (como uma cadeira de rodas) para pessoas com problemas motores devido a traumas (amputação de membros ou paralisia devido a rompimento de nervos) ou devido a doenças degenerativas do sistema muscular, onde a pessoa ainda possui plena consciência de suas ações. Um sistema BCI seria então responsável por traduzir a intenção do usuário, através da medição de seu sinal de EEG, por exemplo, para a ação correspondente a esta intenção.

Uma interface BCI necessita então, como qualquer sistema de comunicação ou controle, uma entrada (a atividade neurofisiológica que gera o EEG), uma saída (comandos para dispositivos) e componentes que traduzam a entrada para saída através das características do sinal. Na Figura 7 pode-se ver um diagrama mostrando as principais partes de um típico sistema BCI (WOLPAW, BIRBAUMER, *et al.*, 2002).

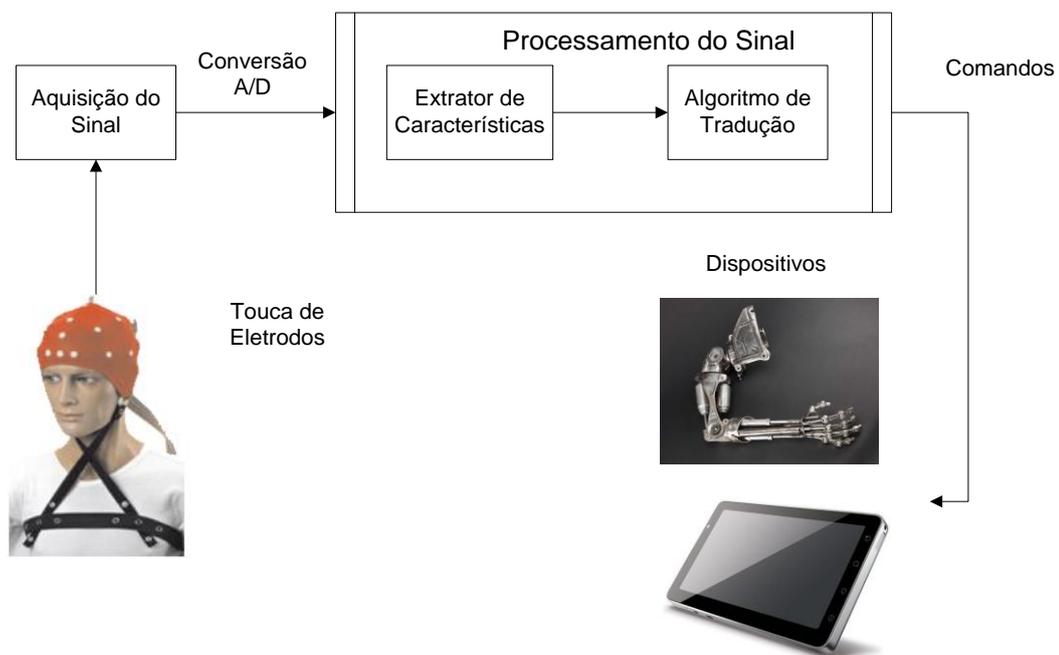


Figura 7: Partes de um típico Sistema BCI. Adaptado de (WOLPAW, BIRBAUMER, *et al.*, 2002).

**Mas somente medir o sinal de EEG não é o suficiente, pois o sistema BCI não consegue classificar os “pensamentos” em geral. Um sistema BCI consegue apenas reconhecer padrões da atividade cerebral que estão associados a alguma tarefa ou evento. Portanto o sujeito que utiliza este tipo de sistema precisa criar ou estar exposto a estratégias mentais para criar esses padrões.** As estratégias mentais mais utilizadas são a atenção seletiva, onde o usuário deve concentrar sua atenção em algum objeto ou símbolo, como uma letra do alfabeto, por exemplo, de forma a observar diferentes padrões cerebrais para diferentes tipos de objeto ou símbolos e a imaginação de movimento, onde o usuário deve imaginar o movimento de algum membro do corpo e portanto gerar os diferentes padrões mentais para diferentes movimentos de membros do corpo humano (GRAIMANN, ALLISON e PFURTSCHELLER, 2011).

O uso da imaginação de movimento utiliza os ritmos sensório-motores como característica de entrada e é largamente utilizado, devido a diferença de energia do ritmo durante o ERD no lado contralateral e ERS no lado ipsilateral, tornando essa distinção útil para classificação do movimento (SANEI e CHAMBERS, 2007).

Qualquer sistema BCI necessita de um período de treinamento do usuário e da análise das características individuais deste usuário. O treinamento vai tornar o uso do sistema como uma habilidade do usuário, fazendo com que ele consiga modular o sinal de forma a atingir seu objetivo (movimentar uma prótese, por exemplo). Para que isso ocorra é necessário que se leve em consideração as características individuais de cada sujeito. Por exemplo, um sujeito pode apresentar atividades motoras em outras regiões do córtex, além da região central, como na região parietal. Além disso, as faixas de frequência dos ritmos sensório-motor podem

também variar de usuário para usuário ou até mesmo de um mesmo usuário de um dia para o outro (DORNHEGE, MILLÁN, *et al.*, 2007).

Para tanto é necessário então inicialmente compreender o sinal de EEG do sujeito em estudo, para analisar as faixas de frequência relevantes e quais os comportamentos característicos do sinal de EEG deste usuário, fazendo com que o algoritmo de tradução da Figura 7 obtenha uma alta taxa de acerto.

### **2.3.1 Aquisição do sinal e conversão A/D**

A entrada do sistema BCI pode ser qualquer medição da atividade neurológica do usuário. Em geral são utilizados sinais de EEG devido a suas vantagens sobre outros métodos de se obter informações do comportamento cerebral, como medições feitas por imagens do cérebro, que demandam grandes equipamentos e alto custo (WOLPAW, BIRBAUMER, *et al.*, 2002).

Portanto a entrada em um sistema BCI necessita de eletrodos para capturar a atividade elétrica cerebral, que podem ser tanto invasivos como não invasivos. Por questões práticas e pela facilidade de estudo em vários indivíduos, os eletrodos não invasivos são os mais utilizados. O uso de eletrodos não invasivos para capturar sinais de EEG respeitam determinados padrões. Um desses padrões é o chamado sistema 10-20, que utiliza 21 eletrodos, onde eles estão separados entre si com uma distância de 10 a 20% da medida do diâmetro da entre nuca e face (JASPER, 1958), conforme Figura 8.

Os eletrodos que cobrem o córtex motor são principalmente os eletrodos centrais, representados pela letra C (C3, Cz e C4). Eletrodos com índice ímpar cobrem o hemisfério esquerdo do crânio e eletrodos com índice par cobrem o hemisfério direito. Para uma maior

resolução pode-se utilizar toucas que utilizam o sistema 10-20 modificado, com um número maior de eletrodos.

A conversão A/D de um sinal de EEG deve ser feita respeitando os critérios de Nyquist. Levando em consideração que o sinal de EEG tem uma banda de no máximo 100Hz, frequências de amostragem acima de 200Hz são recomendadas. No caso dos ritmos sensório-motores, pode-se utilizar frequências mais baixas, pois as frequências de interesse não passam dos 30Hz.

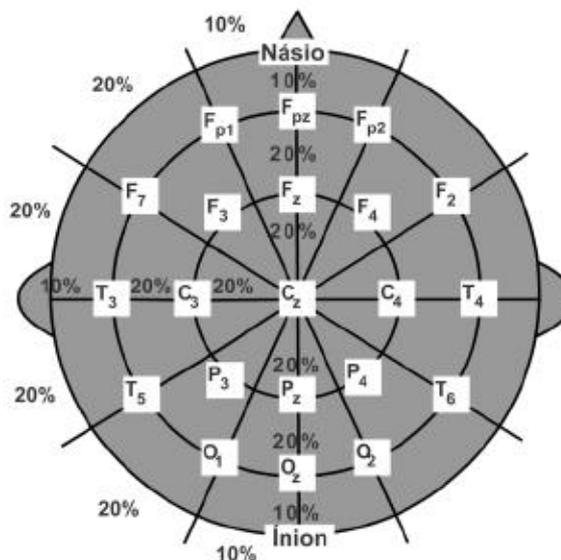


Figura 8: Sistema 10-20 de eletrodos. Extraído de (SANEI e CHAMBERS, 2007).

## 2.4 PERIODOGRAMA MODIFICADO DE WELCH

Como já apresentado anteriormente (sessão 2.2) as características do movimento são refletidas nas componentes de frequência do ritmo sensório-motor, portanto uma forma de se caracterizar a diferença de movimento da mão esquerda e da mão direita é através da

estimação das componentes de frequência do ritmo sensório-motor. Nesta seção será apresentado o periodograma modificado de Welch por ter sido utilizado como estimador espectral neste trabalho.

Uma das primeiras formas de se estimar a densidade espectral de potência de sinais estocásticos (como o sinal de EEG, por exemplo) foi através da transformada de Fourier da função de auto correlação deste sinal (BENDAT e PIERSOL, 1986):

$$S_{xx}(f) = \int_{-\infty}^{\infty} R_{xx}(\tau) e^{-j2\pi f\tau} d\tau \quad (1)$$

onde  $S_{xx}(f)$  é a densidade espectral de energia bilateral e  $R_{xx}(\tau)$  é função de autocorrelação do processo estocástico definido por  $x(t)$  e  $\int_{-\infty}^{\infty} R_{xx}(\tau) < \infty$ .

O outro método utilizado é aplicar diretamente a transformada de Fourier no sinal  $x(t)$  e elevando ao quadrado o módulo de cada componente de frequência (onde considera-se  $\int_{-\infty}^{\infty} x(t) < \infty$ ) (STOICA e MOSES, 2005):

$$S_{xx}(f) = \frac{1}{T} \left| \int_0^T x(t) e^{-j2\pi ft} dt \right|^2 \quad (2)$$

Considerando que o sinal  $x(t)$  será amostrado para um número finito de amostras  $N$ , pode-se reescrever a Eq. (2) para o caso discreto:

$$S_{xx}(k) = \frac{1}{N} \left| \sum_{n=1}^N x(n) e^{-j(2\pi/N)kn} \right|^2 \quad (3)$$

Uma consideração que deve ser levada é a resolução de frequência para cada uma das componentes da DFT (*Discrete Fourier Transform* ou Transformada de Fourier Discreta) calculada pela Eq. (3). A resolução  $\Delta f$  dada pela DFT é dado por:

$$\Delta f = \frac{Fs}{N} \quad (4)$$

onde  $N$  é o tamanho do sinal e  $F_s$  é a frequência de amostragem do sinal.

Porém a resolução em frequência também irá depender muito da forma como o sinal será janelado no tempo. Perda de resolução no domínio frequência e influência dos lóbulos laterais da janela são os principais efeitos de se aplicar uma janela ao sinal (OPPENHEIM, SCHAEFER e BUCK, 1998). A resolução é influenciada diretamente pelo lóbulo principal e o “vazamento” (fenômeno conhecido como *leakage*, proveniente da transformada de Fourier da janela, onde as descontinuidades das bordas contribuem para o espalhamento de frequência fora do lóbulo principal, criando lóbulos secundários de menor energia) adiciona uma tendência ao estimador nas frequências adjacentes à frequência de interesse (STOICA e MOSES, 2005). Na Tabela 1 são apresentadas as janelas mais comuns, tamanho de seu lóbulo principal e atenuação do primeiro lóbulo (a atenuação é relativa ao lóbulo principal e  $M$  é a quantidade de amostras da janela):

Tabela 1: Comparação das Janelas mais utilizadas.

Janela	Largura Lóbulo Principal (rad/s)	Atenuação Relativa Lóbulo secundário (dB)
<b>Retangular</b>	$4\pi/(M + 1)$	-13
<b>Bartlett</b>	$8\pi/M$	-25
<b>Hanning</b>	$8\pi/M$	-31
<b>Hamming</b>	$8\pi/M$	-41

Adaptado de (OPPENHEIM, SCHAEFER e BUCK, 1998).

Observe que a largura do lóbulo principal vai depender inversamente do tamanho da janela (o que é um efeito esperado, visto que uma compressão no espaço das frequências ocasiona uma dilatação no tempo). Portanto, para uma componente  $\Delta f = f_0$  da Equação (4), o próprio lóbulo principal pode se espalhar por valores adjacentes a  $f_0$  de forma significativa. Portanto a escolha certa do tamanho da janela reduz o erro de tendência do estimador (STOICA e MOSES, 2005).

Mas o maior problema do uso do periodograma para estimação da densidade espectral de potência reside no fato que sua variância (ou o estimador do erro aleatório) tem uma magnitude igual a magnitude do valor medido, como será demonstrado a seguir.

Definindo  $\hat{\phi}$  como um estimador para  $\phi$ , pode-se definir o erro aleatório normalizado do estimador como:

$$\varepsilon_R = \frac{\sigma[\hat{\phi}]}{\phi} \quad (5)$$

onde  $\sigma$  é o desvio padrão do estimador.

Considerando o sinal  $x(t)$ , pode-se definir sua densidade espectral de potência bilateral da seguinte forma (BENDAT e PIERSOL, 1986):

$$S_{xx}(f) = \lim_{T \rightarrow \infty} \frac{1}{T} E\{|X(f, T)|^2\} \quad (6)$$

onde  $E\{\cdot\}$  é o operador linear valor esperado e  $X(f, T)$  é a Transformada de Fourier de  $x(t)$ :

$$X(f, T) = \int_0^T x(t) e^{-j2\pi ft} dt \quad (7)$$

Definindo um estimador unilateral  $\hat{G}_{xx}$  (que é igual a  $2 \cdot S_{xx}(f)$ ) onde o tempo  $T$  é finito, obtém-se:

$$\hat{G}_{xx}(f) = \frac{2}{T} |X(f, T)|^2 \quad (8)$$

De forma a determinar a variância desse estimador, observe que  $X(f, T)$  é definido pela série de componentes nas frequências definidas na Eq. (4) e que cada componente  $\Delta f$  calculada pela Eq. (7) é um número complexo, composto por parte real e imaginária. Se o sinal  $x(t)$  for gaussiano, então pelo fato da Transformada de Fourier ser um operador linear, sua parte real e imaginária devem ter distribuições gaussianas independentes. Disso, pode-se afirmar então que:

$$|X(f, T)|^2 = X_R^2(f, T) + X_I^2(f, T) \quad (9)$$

Observe então que  $|X(f, T)|^2$  é a soma de duas variáveis aleatórias independentes e normais elevadas ao quadrado (onde  $X_R(f, T)$  e  $X_I(f, T)$  são as parte real e a parte imaginária da Transformada de Fourier do sinal  $x(t)$  respectivamente), o que por definição é uma variável Chi-Quadrada com dois graus de liberdade (BENDAT e PIERSOL, 1986) (STOICA e MOSES, 2005).

Considerando a Eq. (5) e sabendo que o valor esperado de uma variável Chi-Quadrada é igual a  $n$ , onde  $n$  são os graus de liberdade da variável e que sua variância é definida por  $2n$ , pode-se então escrever o erro aleatório do estimador espectral como (BENDAT e PIERSOL, 1986):

$$\varepsilon_R[\hat{G}_{xx}(f)] = \frac{\sigma[\hat{G}_{xx}(f)]}{G_{xx}(f)} = \frac{\sqrt{2n}}{n} = \sqrt{\frac{2}{n}} \quad (10)$$

Da Eq. (10) chega-se a conclusão de que com  $n = 2$ , então  $\varepsilon_R = 1$ , o que significa que o desvio padrão do estimador é da mesma magnitude do valor medido, ou seja, está se errando na mesma proporção do valor estimado.

Na prática, o erro aleatório definido pela Eq. (10) pode ser reduzido dividindo o sinal janelado em diversos subtrechos menores de tamanho  $n_d$  e calculando  $\hat{G}_{xx}(f)$  sobre esses trechos menores de tamanho  $T_d$  e logo após fazendo uma média para cada componente de frequência sobre todos os trechos. Dessa forma pode-se definir o estimador da densidade espectral de potência como:

$$\hat{G}_{xx}(f) = \frac{2}{n_d T_d} \sum_{i=1}^{n_d} |X_i(f, T_d)|^2 \quad (11)$$

Um inconveniente da segmentação do sinal em múltiplas janelas é que essa redução de uma janela de tamanho  $T$  para  $n_d$  janelas de tamanho  $T/n_d$  é a perda de resolução em frequência. Como o sinal de EEG só pode ser considerado estacionário em curtos períodos de tempo (em torno de 1 a 2s) (SANEI e CHAMBERS, 2007), isso realmente se torna um problema de ordem experimental. Uma das formas de se resolver este problema é utilizando o periodograma modificado de Welch (STOICA e MOSES, 2005) (WELCH, 1967).

O método de Welch permite que as janelas segmentadas se sobreponham em até 50% do seu tamanho, permitindo um número maior de janelas. Com um número maior de janelas é possível obter um valor menor do erro aleatório dado pela Eq. (10), pois aumenta o número de graus de liberdade. Segundo (STOICA e MOSES, 2005) a dedução da expressão para a variância utilizando o método de Welch é trabalhosa, porém resultados empíricos demonstram que este método reduz a variância, pois para janelas sobrepostas com até 50% da sua largura ainda é mantida uma independência entre as amostras. Sobreposições maiores que 50% fazem as amostras se tornarem cada vez mais dependentes, reduzindo a eficácia do método.

## 2.5 PRÉ PROCESSAMENTO

Um grande problema dos algoritmos de classificação é a grande quantidade de características geradas, comparado à quantidade de dados de treinamento disponíveis. Dentro da área de aprendizagem de máquinas esse problema é conhecido como “*Curse of Dimensionality*”. O grande objetivo do pré-processamento de um sinal de EEG é reduzir o espaço de características selecionando apenas as características mais discriminativas dos estados a serem classificados (DORNHEGE, MILLÁN, *et al.*, 2007).

### 2.5.1 Filtro Espacial CSP (*Common Spatial Pattern*)

Como visto nas sessões 2.1.1 e 2.2.1, o movimento ou imaginação de movimento criam certos padrões espaciais no escalpo, criando uma dessincronização no lado contralateral ao movimento no córtex central e um consequente aumento da energia no lado ipsilateral do mesmo córtex central. Portanto, é possível selecionar canais que melhor discriminam o movimento de mão direita ou esquerda, não sendo necessário utilizar todos os canais, reduzindo o espaço de características.

Pode-se definir a energia de um sinal, filtrado por um passa banda, como sendo igual à variância deste sinal (BENDAT e PIERSOL, 1986) sendo, portanto ideal para capturar o efeito discriminativo do sinal de EEG dentro das bandas  $\alpha$  e  $\beta$  durante o ERD e ERS relacionados ao movimento voluntário de mãos (BLANKERTZ, TOMIOKA, *et al.*, 2008).

A proposta do uso do algoritmo CSP é maximizar a atividade discriminativa entre 2 classes de sinais de EEG multi canal. Pelo fato do escalpo conduzir elementos que não pertencem ao sinal de EEG, como por exemplo, sinais mioelétricos provenientes da atividade

muscular da face, os canais apresentam muita atividade não discriminativa em comum que mascaram a atividade discriminativa do EEG, principalmente pelo fato do sinal proveniente do córtex ser fraco (amplitude na faixa de  $\mu V$ ) em relação a sinais mioelétricos (amplitude na faixa de  $mV$ ) (BLANKERTZ, TOMIOKA, *et al.*, 2008).

A maximização da atividade discriminativa é feita levando o espaço de sensores de uma trilha para um novo espaço através de uma transformação linear que irá maximizar a variância em uma condição, ao mesmo tempo em que minimiza a variância na outra condição. Nesse texto, é importante observar que toda variável maiúscula em negrito representa uma matriz e toda variável minúscula em negrito representa um vetor e um trecho do sinal de EEG recortado de uma trilha, é considerado um sinal filtrado por um filtro passa banda, de tamanho  $T$  e com  $C$  canais, representado como  $\mathbf{X} \in \mathbb{R}^{C \times T}$ , ou como  $\mathbf{x}(t) \in \mathbb{R}^C$  para representar o sinal em um determinado tempo  $t$ . Portanto  $\mathbf{X}$  é uma concatenação de sinais  $\mathbf{x}(t)$ 's sendo escrito como  $\mathbf{X} = [\mathbf{x}(t), \mathbf{x}(t + 1), \dots, \mathbf{x}(t + T - 1)]$ .

O novo espaço de sensores é gerado através de uma decomposição supervisionada do sinal  $\mathbf{x}(t)$  que é parametrizado por uma matriz  $\mathbf{W} \in \mathbb{R}^{C \times C}$  que projeta o sinal para um novo espaço  $\mathbf{x}_{CSP}(t) \in \mathbb{R}^C$  de acordo com a Eq. (12) (BLANKERTZ, TOMIOKA, *et al.*, 2008):

$$\mathbf{x}_{CSP}(t) = \mathbf{W}^T \cdot \mathbf{x}(t) \quad (12)$$

Portanto, observe que cada coluna  $\mathbf{w}_j \in \mathbb{R}^C$  ( $j = 1, \dots, C$ ) é um filtro espacial que recombina linearmente as componentes de todos os canais, criando um novo canal. Veja também que  $\mathbf{A} = (\mathbf{W}^{-1})^T$  é a matriz que leva novamente para o espaço de sensores original dando o padrão espacial do sinal  $\mathbf{x}(t)$  (RAMOSER, MÜLLER-GERKING e PFURTSCHELLER, 2000).

Como citado anteriormente, o objetivo do algoritmo CSP é maximizar a variância de uma classe enquanto minimiza a variância da outra classe levando a um novo espaço de canais onde as variâncias são ótimas pra a discriminação entre 2 classes (RAMOSER, MÜLLER-GERKING e PFURTSCHHELLER, 2000). O método utilizado é o desenvolvimento de um algoritmo que calcule uma matriz que diagonalize simultaneamente duas matrizes de covariância (FUKUNAGA, 1990) conforme a Eq. (13):

$$\mathbf{W}^T \cdot \boldsymbol{\Sigma}^{(+)} \cdot \mathbf{W} = \boldsymbol{\Lambda}^{(+)} \quad (13)$$

$$\mathbf{W}^T \cdot \boldsymbol{\Sigma}^{(-)} \cdot \mathbf{W} = \boldsymbol{\Lambda}^{(-)}, \quad (\boldsymbol{\Lambda}^{(c)} \text{ diagonal}),$$

onde  $\boldsymbol{\Sigma}^{(c)}$  é o estimador da matriz de covariância na condição  $(c)$  do sinal  $\mathbf{x}(\mathbf{t})$  da Eq. (12) e  $\mathbf{W}$  é calculado de forma que:

$$\boldsymbol{\Lambda}^{(+)} + \boldsymbol{\Lambda}^{(-)} = \mathbf{I} \quad (14)$$

onde  $\mathbf{I}$  é a matriz Identidade.

Os valores associados a matriz diagonal  $\boldsymbol{\Lambda}^{(c)} \in \mathbb{R}^{c \times c}$  são as variâncias dos novos canais, sendo que se um canal  $j$  apresentar uma alta variância em sua condição positiva  $\Lambda_j^{(+)}$  ele vai apresentar ao mesmo tempo uma baixa variância na condição negativa  $\Lambda_j^{(-)}$  e vice-versa. Para se projetar tal matriz  $\mathbf{W}$  com essas características, deve-se inicialmente decompor a matriz composta de covariância,  $\boldsymbol{\Sigma} = \boldsymbol{\Sigma}^{(+)} + \boldsymbol{\Sigma}^{(-)}$ , em seus respectivos autovalores e autovetores:

$$\boldsymbol{\Sigma} = \mathbf{B} \cdot \boldsymbol{\lambda} \cdot \mathbf{B}' \quad (15)$$

Então a decomposição dá uma nova base composta pelos autovetores em  $\mathbf{B}$ , que são os vetores ortogonais que descrevem o comportamento da matriz composta de covariância e  $\boldsymbol{\lambda}$  é

a matriz diagonal de autovalores. Aplicando a operação de “branqueamento” (*whitening transformation*) em  $\mathbf{B}$ , encontra-se a matriz  $\mathbf{P}$  (FUKUNAGA, 1990) (DUDA, HART e STORK, 2000):

$$\mathbf{P} = \boldsymbol{\lambda}^{-1/2} \cdot \mathbf{B} \quad (16)$$

Essa transformação faz com que  $\mathbf{P} \cdot \boldsymbol{\Sigma} \cdot \mathbf{P}' = \mathbf{I}$ . Isso significa que a matriz  $\mathbf{P}$  equaliza todas as variâncias da matriz composta  $\boldsymbol{\Sigma}$ , deixando todas iguais a 1, além de descorrelacionar os sinais, fazendo com que suas covariâncias se tornem igual a 0, por isso o nome da operação ser “branqueamento”, pois transforma os sinais correlacionados em sinais descorrelacionados, ou seja, ruído branco (DUDA, HART e STORK, 2000) (LEMM, BLANKERTZ, *et al.*, 2005). O próximo passo é transformar as matrizes de covariância de cada classe da seguinte forma:

$$\begin{aligned} \mathbf{S}^{(+)} &= \mathbf{P} \cdot \boldsymbol{\Sigma}^{(+)} \cdot \mathbf{P}' \\ \mathbf{S}^{(-)} &= \mathbf{P} \cdot \boldsymbol{\Sigma}^{(-)} \cdot \mathbf{P}' \end{aligned} \quad (17)$$

Então  $\mathbf{S}^{(+)}$  e  $\mathbf{S}^{(-)}$  irão compartilhar os mesmos autovetores, pois  $\mathbf{S}^{(+)} + \mathbf{S}^{(-)} = \mathbf{P} \cdot \boldsymbol{\Sigma} \cdot \mathbf{P} = \mathbf{I}$  (BLANKERTZ, TOMIOKA, *et al.*, 2008) e a soma dos autovalores de  $\mathbf{S}^{(+)}$  e  $\mathbf{S}^{(-)}$  é sempre igual a 1, ou seja, se a decomposição de  $\mathbf{S}^{(+)}$  e  $\mathbf{S}^{(-)}$  em termos de autovalores e autovetores for:

$$\begin{aligned} \mathbf{S}^{(+)} &= \mathbf{U} \cdot \boldsymbol{\Lambda}^{(+)} \cdot \mathbf{U}' \\ \mathbf{S}^{(-)} &= \mathbf{U} \cdot \boldsymbol{\Lambda}^{(-)} \cdot \mathbf{U}' \end{aligned} \quad (18)$$

onde  $\boldsymbol{\Lambda}^{(+)}$  e  $\boldsymbol{\Lambda}^{(-)}$  são as matrizes diagonais de autovalores.

Os autovalores  $\Lambda_j^{(+)}$  e  $\Lambda_j^{(-)}$  com  $j = 1, \dots, C$  que compõe a matriz de diagonal de autovalores vão informar quais as colunas  $\mathbf{w}_j$  da matriz  $\mathbf{W}$  da Eq. (12) discriminam mais as duas classes, maximizando a variância em uma das classes ao mesmo tempo que minimiza na

outra. Pelo fato de  $\Lambda_j^{(+)} + \Lambda_j^{(-)} = 1$  um valor de  $\Lambda_j^{(c)}$  perto de 1, indica que o vetor  $w_j$  irá maximizar a variância do sinal na condição (c) enquanto minimiza na outra condição.

O filtro espacial  $\mathbf{W}$  que irá projetar o sinal  $\mathbf{x}(t)$  do espaço de sensores original para o novo espaço  $\mathbf{x}_{CSP}(t)$  será dado então pela projeção da matriz  $\mathbf{P}$  por  $\mathbf{U}'$  (LEMM, BLANKERTZ, *et al.*, 2005) (RAMOSER, MÜLLER-GERKING e PFURTSCHHELLER, 2000):

$$\mathbf{W} = (\mathbf{U}' \cdot \mathbf{P})' \quad (19)$$

As colunas  $\mathbf{w}_j$  que irão fazer a melhor discriminação entre as duas classes serão as que resultam nos valores de  $\Lambda_j^{(c)}$  mais próximo de 1 em cada classe. Como exemplo, na Figura 9 pode-se ver o efeito do filtro CSP em uma variável bi-dimensional. Observe que as variâncias estão ortogonalizadas.

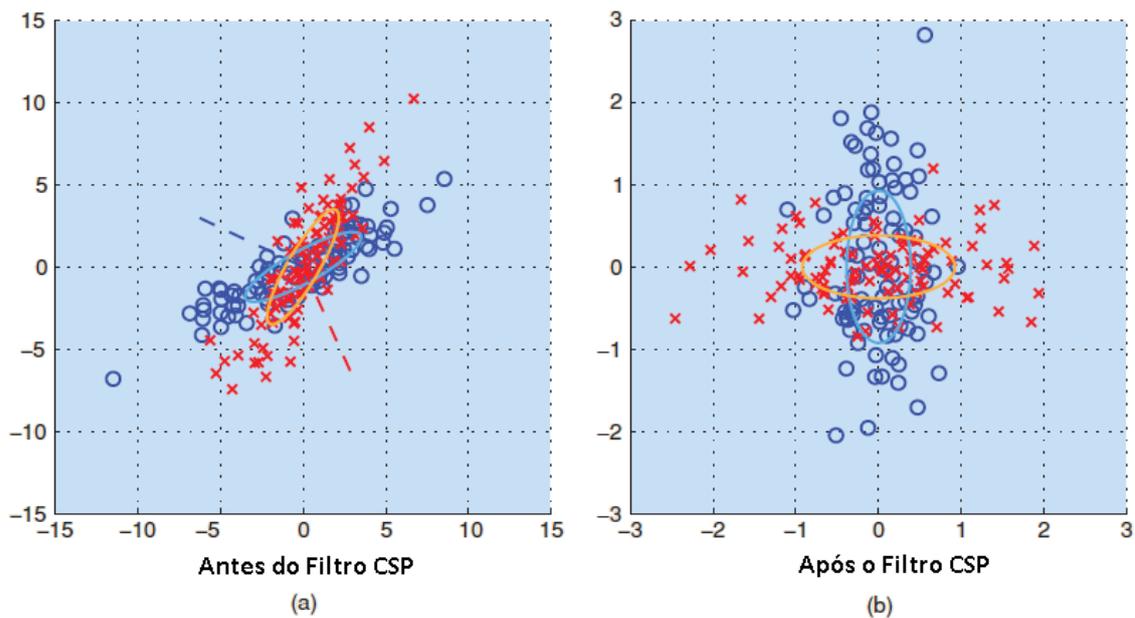


Figura 9: Efeito do Filtro Espacial CSP em uma variável bi-dimensional. Adaptado de (BLANKERTZ, TOMIOKA, *et al.*, 2008).

## 2.6 CLASSIFICADORES

### 2.6.1 Naive Bayes (NB)

O objetivo de um classificador é sempre procurar a melhor hipótese  $H$ , dado um conjunto de dados de treinamento. O teorema de Bayes permite calcular uma probabilidade *a posteriori* (ou a probabilidade de uma hipótese, dado um valor da variável), baseada na probabilidade *a priori* (frequência de cada hipótese), dos dados observados da hipótese em questão e dos dados totais observados, de acordo com (20) (MITCHEL, 1997):

$$P(v_j|A) = \frac{P(A|v_j) \times P(v_j)}{P(A)} \quad (20)$$

Onde  $v_j$  é a hipótese  $j$  no conjunto de hipóteses  $V$ ,  $A$  é o conjunto de atributos  $\langle a_1, a_2, \dots, a_n \rangle$  que descreve os dados. Quando o conjunto  $A$  possui mais de um atributo é necessário então estimar  $P(a_1, a_2, \dots, a_n|v_j)$  para possibilitar o cálculo de  $P(v_j | a_1, a_2, \dots, a_n)$ . O problema é que para estimar  $P(A | v_j)$  é necessário uma quantidade extremamente grande de amostras, além de ser custoso computacionalmente, pois é necessário calcular as probabilidades conjuntas para todas as possibilidades de  $A$  (BENDAT e PIERSOL, 1986) (MITCHEL, 1997). Em função desse problema, é proposto o classificador *Naive Bayes* (NB), que considera que todos os atributos de  $A$  são independentes entre si. A literatura afirma que mesmo quando esses atributos não forem totalmente independentes entre si, é possível obter um bom desempenho na classificação além de possuir uma simples implementação (DUDA, HART e STORK, 2000) (MITCHEL, 1997). Desta forma a probabilidade conjunta é obtida pela Eq. (21):

$$P(a_1, a_2, \dots, a_n | v_j) = \prod_i P(a_i | v_j) \quad (21)$$

e a saída do classificador é dada por:

$$v_{MAP} = \mathop{\text{arg max}}_{v_j \in V} \left\{ P(v_j) \times \prod_i P(a_i | v_j) \right\} \quad (22)$$

Onde  $v_{MAP}$  é a máxima probabilidade *a posteriori* calculada dentro do espaço de hipóteses  $V$ . Observe que é necessário apenas estimar a distribuição de probabilidade de cada atributo para cada classe, além de não precisar realizar o cálculo de  $P(A)$  no caso do número de observações de cada classe ser igual.

### 2.6.2 Discriminante Linear de Fisher (LDA)

O objetivo do Discriminante Linear de Fisher é projetar os dados em um hiperplano dentro do espaço de características, procurando a orientação do hiperplano que vai resultar na projeção com a melhor discriminação das classes nesta reta (FUKUNAGA, 1990) (DUDA, HART e STORK, 2000).

Um discriminante linear que é uma combinação dos componentes do espaço  $\mathbf{x} \in \mathbb{R}^D$  de características pode ser dado por:

$$\mathbf{g}(\mathbf{x}) = \mathbf{w}^T \cdot \mathbf{x} + w_0 \quad (23)$$

onde  $\mathbf{w} \in \mathbb{R}^D$  é o vetor de pesos,  $w_0$  é uma constante e  $D$  é a dimensão do vetor de características. Um classificador linear para duas classes  $v_1$  e  $v_2$  implementa a seguinte regra de decisão:

$$\begin{aligned} &\text{escolhe } v_1 \text{ se } \mathbf{g}(\mathbf{x}) > 0 \\ &\text{escolhe } v_2 \text{ se } \mathbf{g}(\mathbf{x}) < 0 \end{aligned} \quad (24)$$

Isto é, a classe  $v_1$  será a escolhida caso o produto interno dado pela Eq. (23) seja maior que  $-w_0$ , caso seja menor que  $-w_0$  a classe  $v_2$  será a escolhida. A Figura 10 mostra a implementação do algoritmo em blocos. Esta representação demonstra claramente o vetor  $\mathbf{x}$  sendo recombinação com os pesos do classificador dado por  $\mathbf{w}$  e implementando a regra de decisão  $g(\mathbf{x})$  dada pela Eq. (24).

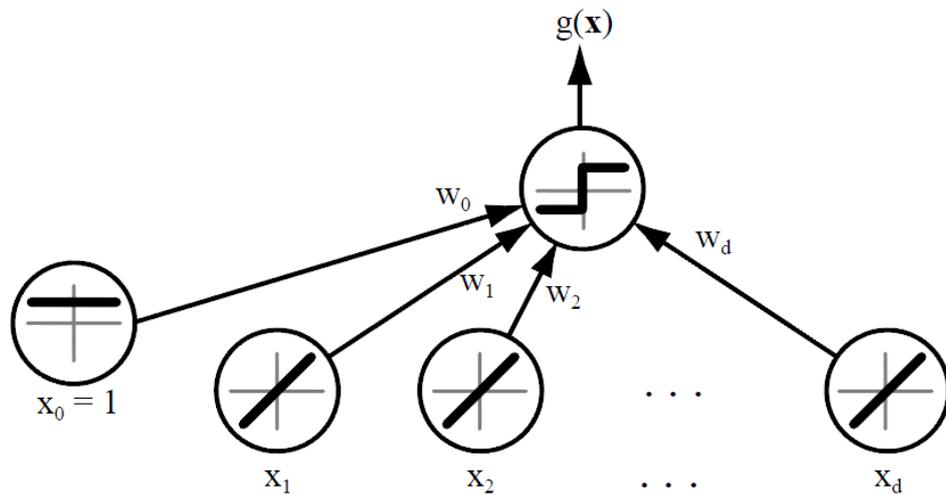


Figura 10: Diagrama em blocos do algoritmo LDA (DUDA, HART e STORK, 2000).

A direção do hiperplano, dado pela norma do vetor de pesos  $\mathbf{w}$  é dada pelo critério de Fisher (também conhecido com coeficiente de Rayleigh):

$$J(\mathbf{w}) = \frac{\mathbf{w}^T S_d \mathbf{w}}{\mathbf{w}^T S_c \mathbf{w}} \quad (25)$$

onde  $S_d$  é a atividade discriminativa dos dados e  $S_c$  é a atividade comum. O cálculo de  $\mathbf{w}$  é feito de forma a maximizar a função  $J(\cdot)$ , encontrando um vetor  $\mathbf{w}$  que maximize a atividade discriminativa entre as 2 classes em relação a atividade comum (FUKUNAGA, 1990) (DUDA, HART e STORK, 2000).

### 3 METODOLOGIA EXPERIMENTAL

O esboço do aparato experimental desenvolvido para a aquisição dos dados, geração de estímulos e processamento do sinal de EEG foi desenvolvido baseado no diagrama de blocos mostrados na Figura 11.

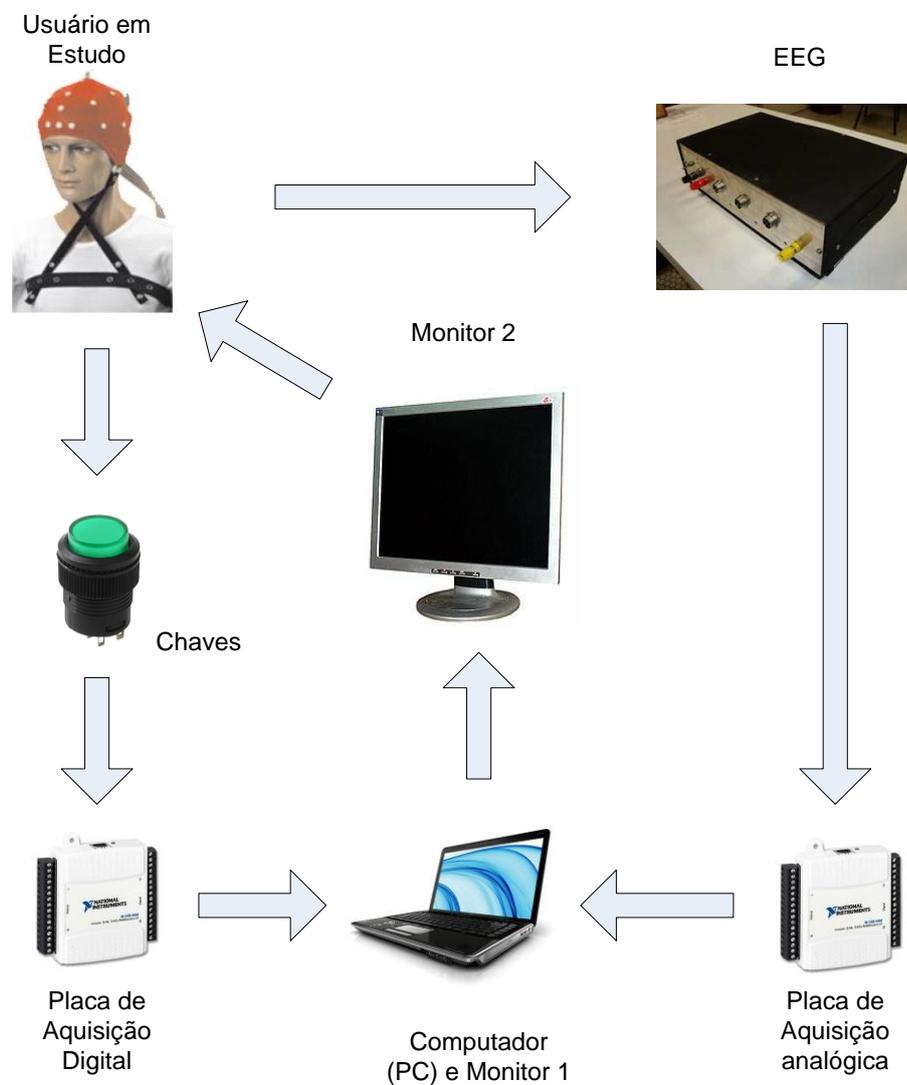


Figura 11: Diagrama de blocos do aparato experimental.

O experimento se baseia em uma geração de estímulos pelo Computador que são mostrados pelo Monitor 2 ao sujeito em estudo, que está confortavelmente sentado em uma cadeira como se pode ver na Figura 12. Os dados são obtidos por meio de uma touca de EEG baseada no sistema 10-20, amplificados e filtrados de forma analógica pelo EEG e convertidos digitalmente para o computador através de uma placa de conversão A/D (Analógico/Digital) comercial da *National Instruments*, modelo NI USB 6008. O usuário tem também duas chaves posicionadas na cadeira, uma no braço direito e outra no braço esquerdo, que são acionadas de acordo com o estímulo apresentado, e seu sinal é lido por outra placa de conversão analógica/digital.



Figura 12: Imagem do experimento proposto.

### 3.1 PLATAFORMA EXPERIMENTAL

#### 3.1.1 Geração de Estímulos e Aquisição de Dados

A geração de estímulos e a aquisição de dados são realizadas pelo computador, mostrado na Figura 11, de forma sincronizada. A aquisição é feita de modo contínuo e logo após as trilhas são recortadas em janelas de 8s, portanto a sincronização da apresentação dos estímulos com a linha do tempo do sinal é feita por *software*. A sequência de estímulos, mostrada na Figura 13, é apresentada da seguinte forma:

- 0s a 1,5s: é apresentada uma tela em branco, chamado período de referência.
- 1,5s a 3s: é apresentado um desenho de cruz na tela, chamado de pré-estímulo.
- 3s a 6s: é apresentado o estímulo. Uma seta azul apontando para direita ou uma seta vermelha apontando para a esquerda.
- 6s a 8s: é apresentada novamente uma tela em branco, chamado de período pós-estímulo.

Este ensaio foi baseado em estudos anteriores (PFURTSCHELLER, NEUPER, *et al.*, 1997) (PFURTSCHELLER e SILVA, 1999) (NAM, JEON, *et al.*, 2011) que demonstra existir uma grande dessincronização bilateral dentro das faixas de frequência das bandas  $\mu$  e  $\beta$  durante a imaginação do movimento, mantendo sempre a energia do lado ipsilateral ao movimento maior que a área contra-lateral ao movimento. Esses estudos demonstraram que a imaginação de movimento por breve períodos (1 a 3s) mostram uma diferença de energia dentro das bandas  $\mu$  e  $\beta$  capazes de distinguir um movimento do outro. A escolha da janela de 8s foi determinada empiricamente através de ensaios experimentais.

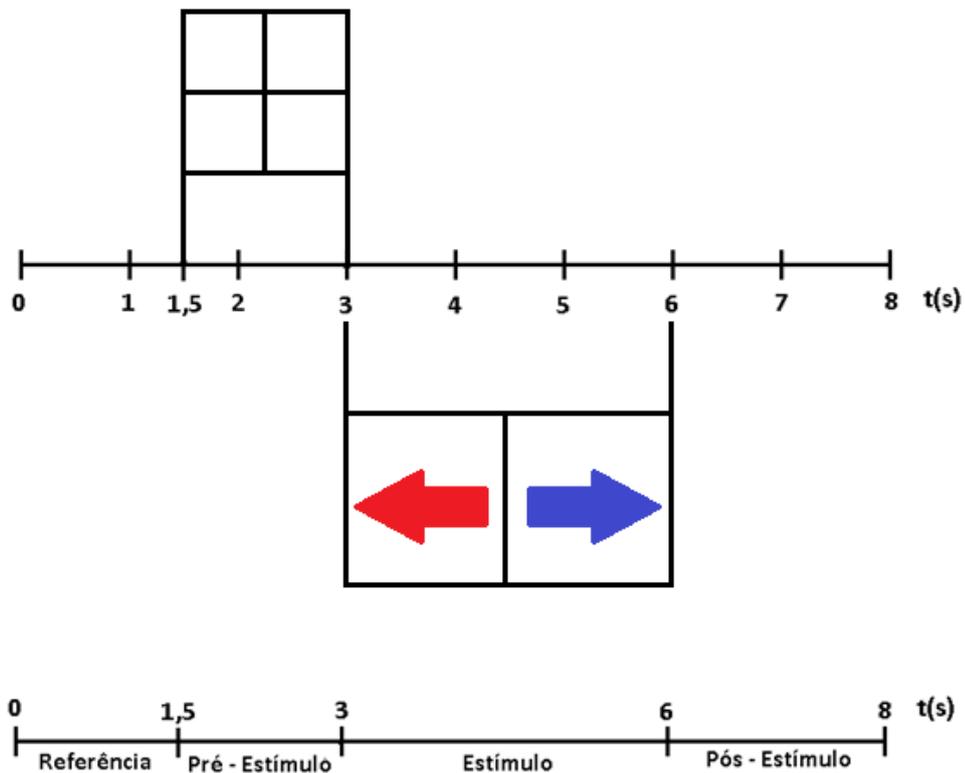


Figura 13: Temporização de uma trilha.

Durante o experimento proposto, o sujeito em estudo é instruído a pressionar chaves mecânicas, instaladas nos braços da cadeira, com a palma da mão de forma que o sujeito movimente a mão e não apenas um dedo (observe que na Figura 6, a área que controla as mãos é muito maior que as áreas que controlam cada um dos dedos). Quando a seta vermelha (que indica movimento de mão esquerda) aparece na tela, o sujeito em estudo deve pressionar o botão, localizado no braço esquerdo da cadeira, com a mão esquerda. Quando surgir a seta azul, deve-se fazer o mesmo procedimento, porém utilizando a mão direita.

Esse experimento é realizado de forma síncrona, ou seja, existe um controle de quando será executado o movimento (SANEI e CHAMBERS, 2007), facilitando a identificação do

efeito ERS/ERD na análise do sinal. O período pós-estímulo é gerado para permitir um tempo de forma que o cérebro retorne ao seu estado normal após a execução do movimento (PFURTSCHELLER e SILVA, 1999).

A placa de conversão A/D comercial utilizada foi configurada para adquirir 8 canais de EEG, Fp1, Fp2, F3, F4, C3, C4, P3 e P4 de acordo com a Figura 8, com frequência de amostragem de 256Hz. Estes canais foram selecionados de forma a cobrir as regiões mais importantes relacionadas ao córtex motor no hemisfério direito (eletrodos com índice par) e hemisfério esquerdo do cérebro (eletrodos com índice ímpar). O eletrodos frontais (Fp1 e Fp2) foram utilizados de forma a desenvolver, futuramente, procedimentos para minimizar os efeitos indesejados dos artefatos.

Para configurar, adquirir e sincronizar os dados foram desenvolvidos dois *softwares* na ferramenta de desenvolvimento *Labview*. Um desses *softwares*, denominado *main.vi* e apresentado no Monitor 1 da Figura 11, é responsável por chamar o outro *software*, denominado *estímulos.vi*, que por sua vez é apresentado no Monitor 2 da Figura 11, e também por gerenciar a aquisição digital-analógica e armazenar estes dados. Esta aquisição precisa ser sincronizada com a apresentação dos estímulos. Portanto, o *software estímulos.vi* é responsável por disparar o processo de aquisição, se comunicando com o *software main.vi*, e a partir deste ponto começa a apresentar um número pré-determinado de trilhas, e o *software main* começa a salvar os dados. A sequência que gera os estímulos é feita de forma aleatória e difere para cada ensaio. Além disso, o *software estímulos* também controla e salva os dados das chaves. O controle das chaves é feito de forma que o sujeito em análise tenha uma janela de 1 segundo após a apresentação do estímulo ( $t = 3s$  a  $t = 4s$  na trilha) para pressionar a

chave, não tendo efeito se pressionada antes ou depois desta janela de tempo. Na Figura 14 é mostrado o fluxograma de funcionamento dos *softwares main e estímulos*.

O sincronismo entre a apresentação do estímulo e a base temporal, onde a primeira amostra representa o tempo 0 e a uma amostra  $n$  representa o tempo  $n \times ts$ , onde  $ts$  é o período de amostragem, foi testada através de uma realimentação na placa de aquisição. A placa de aquisição, além de ter entradas analógicas para conversão A/D, possui entradas e saídas digitais, com níveis TTL de tensão (0V e 5V). A realimentação consistia em ligar 2 saídas digitais em 2 canais analógicos e codificar cada trecho da trilha através das saídas digitais de acordo com a Tabela 2:

Tabela 2: Codificação digital dos trechos da trilha.

Saídas Digitais		
S0	S1	Trecho
0	0	Referência
0	1	Pré-Estímulo
1	0	Estímulo
1	1	Pós-Estímulo

Uma pequena alteração foi feita no *software estímulos.vi*, de forma que ao trocar de trecho na trilha (passando do período de referência para o pré-estímulo, por exemplo), os valores das saídas digitais também se alteram de acordo com a Tabela 2. Essas saídas, que estão conectadas a dois canais analógicos, permanecem em seus estados lógicos durante todo período do trecho observado. Durante período de estímulo, por exemplo, a saída S0 ficará em nível lógico alto (5V) e a saída S1 ficará em nível lógico baixo (0V) durante os 3s de duração. Dessa forma é possível verificar se as transições ocorrem de forma sincronizada com a base temporal da aquisição de dados, verificando os dados obtidos pelos canais analógicos.

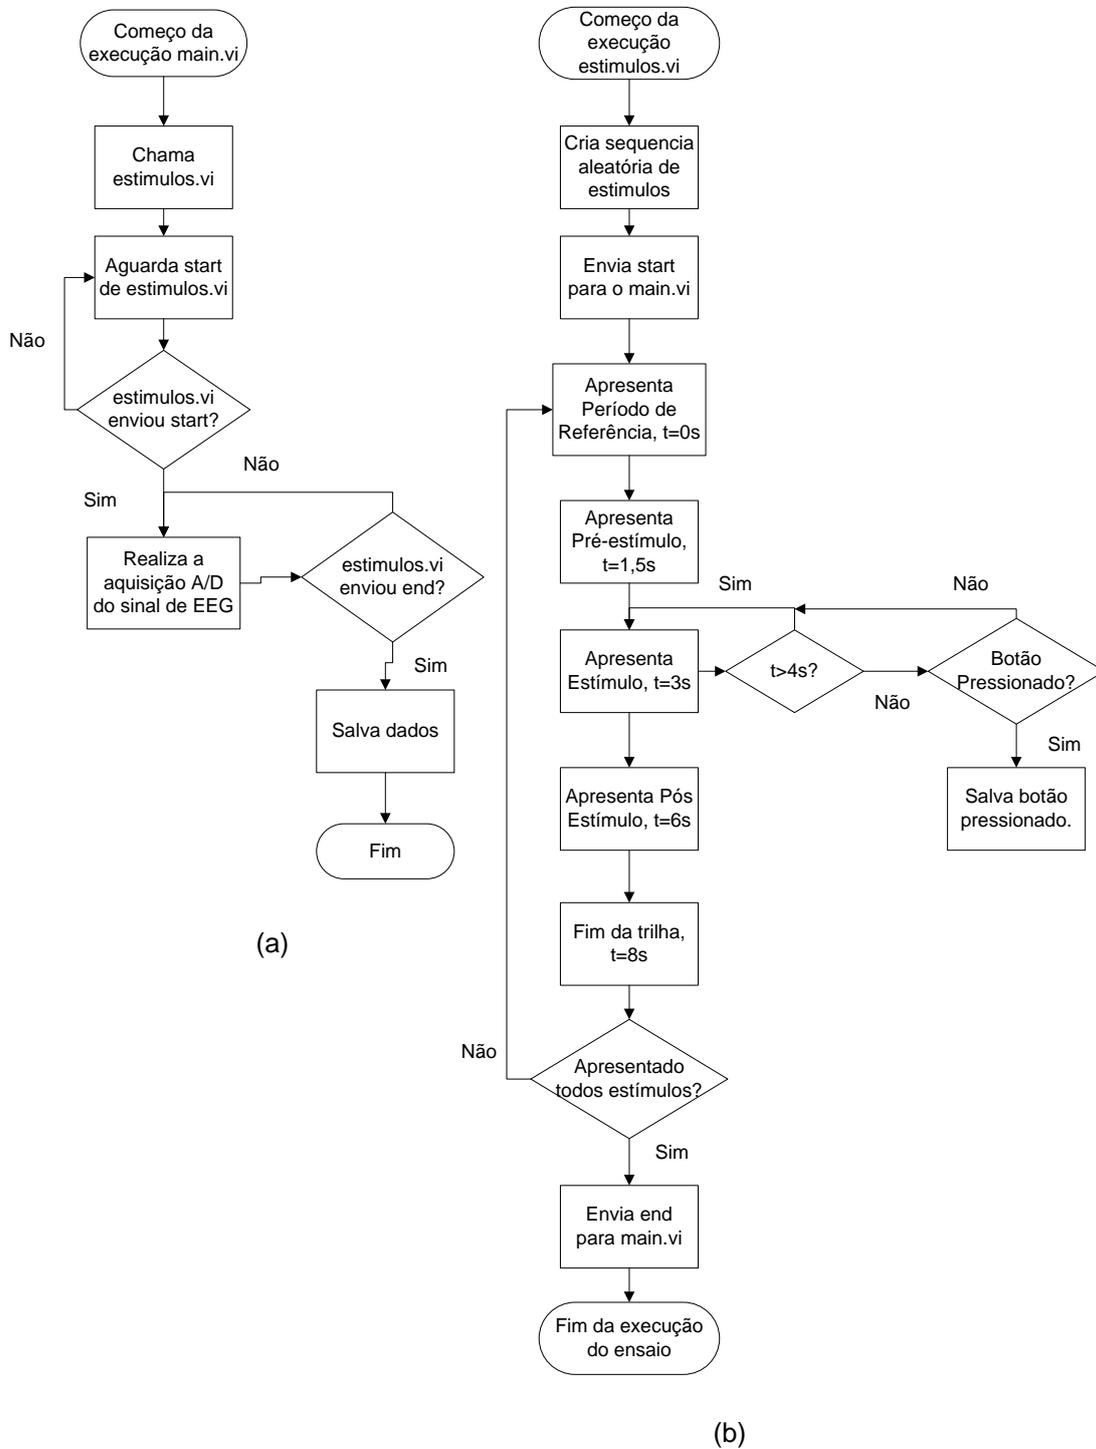


Figura 14: Fluxograma dos *softwares* de aquisição e controle do experimento: (a) fluxograma de execução do *software main.vi* e (b) fluxograma de execução do *software estímulos.vi*.

### 3.2 PRÉ-PROCESSAMENTO DO BIO-SINAL DE EEG

O primeiro passo do pré-processamento do sinal de EEG é a aplicação de um filtro passa banda nos ritmos  $\mu$  e  $\beta$ . Neste trabalho é utilizado um filtro digital Butterworth de 4ª ordem, implementado a partir da função *filtfilt()* no software *Matlab*, de forma a não alterar a fase do sinal.

O passo seguinte é separar os sinais em trilhas, de acordo com cada classe de movimento (direita ou esquerda). Veja que na Figura 14 o *software estimulos.vi* salva os dados de sincronismo e o botão que foi pressionado. Os dados são separados então de acordo com a classe e também de acordo com o botão pressionado. Se de acordo com o arquivo de sincronismo, uma determinada trilha apresentava a seta para esquerda e o individuo pressionava o botão direito primeiro ou não apertasse nenhum botão, este trecho adquirido é descartado de forma automática. O fluxograma da Figura 15 apresenta a lógica desenvolvida para a separação dos dados em trilhas e classes de movimento.

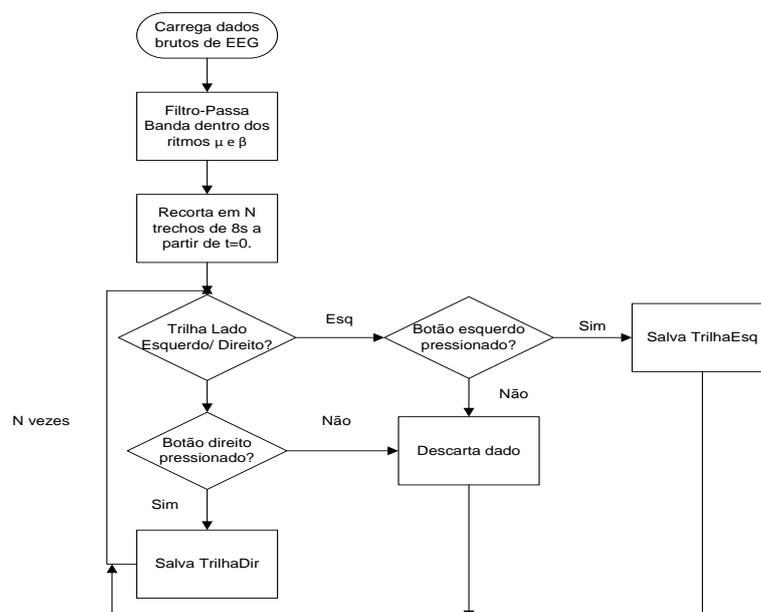


Figura 15: Fluxograma de separação dos dados em trilhas e classes de movimento.

### 3.2.1 Filtro Espacial (CSP)

O primeiro passo para o cálculo do filtro espacial  $\mathbf{W}$  da Eq. (12) é estimar as matrizes de covariância do conjunto de treinamento. Considerando que o sinal  $\mathbf{x}(t)$  é composto por 8 canais de EEG e filtrado por um filtro passa-banda digital utilizando o método de Butterworth de quarta ordem dentro da banda  $\alpha$  e  $\beta$ , um estimador da matriz de covariância para este tipo de sinal, que é geralmente utilizado em estudos de *design* de filtros espaciais CSP (BLANKERTZ, TOMIOKA, *et al.*, 2008) (LEMM, BLANKERTZ, *et al.*, 2005) (RAMOSER, MÜLLER-GERKING e PFURTSCHELLER, 2000), é dado por :

$$\Sigma^{(c)} = \frac{1}{N} \sum_{n=1}^N \frac{\mathbf{X}_{(c)}^n \cdot \mathbf{X}_{(c)}^{n \prime}}{\text{traço}(\mathbf{X}_{(c)}^n \cdot \mathbf{X}_{(c)}^{n \prime})} \quad (26)$$

onde  $N$  é a quantidade de trilhas,  $\Sigma^{(c)}$  é a matriz de covariância na condição  $(c)$ ,  $\mathbf{X}_{(c)}^n$  é um trecho do sinal de EEG na trilha  $n$ , durante o movimento da mão direita ou mão esquerda representado como  $\mathbf{X}_D$  e  $\mathbf{X}_E$  respectivamente e  $\text{traço}(\mathbf{X}_{(c)}^n \cdot \mathbf{X}_{(c)}^{n \prime})$  é a soma dos valores da diagonal do produto  $\mathbf{X}_{(c)}^n \cdot \mathbf{X}_{(c)}^{n \prime}$ .

Como se deseja maximizar a atividade discriminativa entre as duas classes durante o movimento das mãos, janelas de 1s a 2s são aplicadas ao sinal de EEG para posteriormente extrair as componentes espectrais e as variâncias dos canais que melhor discriminam as classes de acordo com os autovalores dados pela Eq. (18). De acordo com estudos, o efeito ERD/ERS ocorre geralmente até 2s após o movimento ter sido executado (PFURTSCHELLER e SILVA, 1999) (NAM, JEON, *et al.*, 2011) (CARRA, 2012), portanto serão utilizados como pontos de começo da janela os tempos  $t = 3s$  a  $t = 4s$ , da trilha representada na Figura 13. Com essas considerações, os passos para o cálculo de  $\mathbf{W}$  são:

1. primeiro estimar  $\Sigma^E$  e  $\Sigma^D$  de acordo com a Eq. (26) utilizando o conjunto de treinamento;
2. encontrar a matriz  $\Sigma = \Sigma^D + \Sigma^E$  e fazer a decomposição de  $\Sigma$  encontrando os autovetores  $B$  e autovalores  $\lambda$  dados pela Eq. (15);
3. logo em seguida é feita a operação de “branqueamento” dada pela Eq. (16), resultando na matriz  $P$ ;
4. utilizando a matriz  $P$ , se decompõe  $\Sigma^E$  e  $\Sigma^D$  de acordo com a Eq. (17), resultando nas matrizes  $S^E$  e  $S^D$  cujos autovalores  $\Lambda^E$  e  $\Lambda^D$  representam a atividade discriminativa no novo espaço CSP de canais;
5. seleciona-se os  $n$  maiores autovalores  $\Lambda^E$ , que vai maximizar a variância na condição movimento de mão esquerda, minimizando a variância na condição movimento de mão direita, repetindo o procedimento para  $\Lambda^D$ ;
6. calcula-se o filtro espacial de acordo com a Eq. (19) e seleciona-se  $2 \cdot n$  colunas da matriz  $W$  que estão associados aos  $n$  maiores autovalores de  $\Lambda^E$  e  $\Lambda^D$  respectivamente.

Na Figura 16 pode-se ver o fluxograma do algoritmo do filtro  $W$ , considerando que o sinal de EEG já está filtrado por um passa banda. Um dos grandes problemas da implementação do filtro CSP é sua grande sensibilidade a artefatos, principalmente proveniente dos músculos. Isso ocorre pelo fato de um artefato muscular causar uma grande variação de energia em uma amostra, contaminando o estimador de variância, levando a uma falsa alta variância (BLANKERTZ, TOMIOKA, *et al.*, 2008).

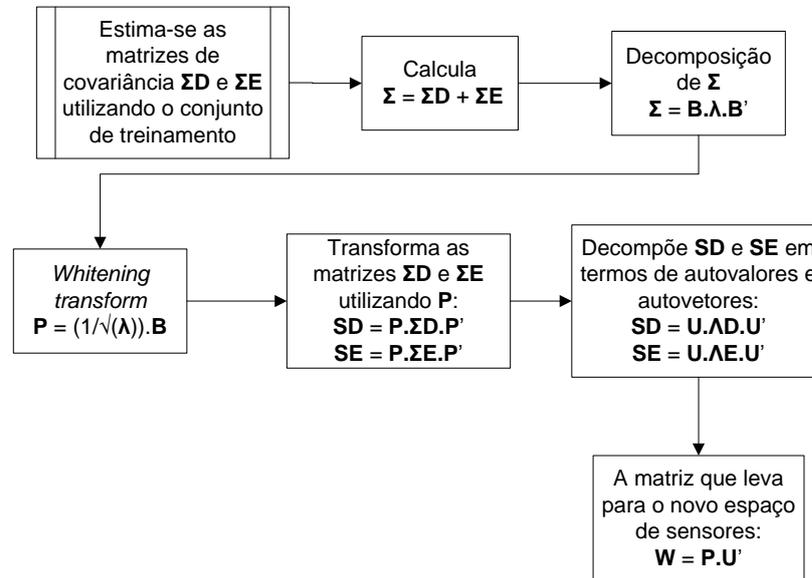


Figura 16: Fluxograma do algoritmo que implementa o filtro  $W$  da Eq. (12).

Todos os cálculos foram realizados utilizando um *script* no *Matlab* e as decomposições de autovalores e autovetores foram feitas utilizando a função  $eig(A)$  que retorna os autovalores e autovetores da matriz  $A$ .

### 3.3 CLASSIFICAÇÃO DO SINAL DE EEG

#### 3.3.1 Escolha das características

Para a correta classificação dos sinais de EEG, deve-se escolher adequadamente as características que permitam identificar e classificar o movimento de mão direita e esquerda. Muitos autores utilizam algoritmos para verificar a relevância de cada característica (BASHASHATI, FATOURECHI, *et al.*, 2007). Neste trabalho, por questões práticas, será utilizado o método manual de escolha de características por um especialista (o operador do sistema). O uso de um especialista para selecionar as melhores características visualmente é uma técnica também empregada e descrita na literatura e muitas vezes leva a taxas de acerto

mais altas que métodos automáticos (CARRA, 2012) (LEMM, BLANKERTZ, *et al.*, 2005) (SANEI e CHAMBERS, 2007).

O primeiro passo para a determinação das componentes espectrais é encontrar o instante inicial de recorte da janela. Da seção 2.2.1, sabe-se que os efeitos ERD/ERS podem ocorrer durante o planejamento do movimento e/ou durante o movimento e que ocorrem principalmente nas bandas  $\mu$  e  $\beta$ , portanto o sinal é filtrado nessas bandas. Após o sinal ser filtrado por um passa banda ele é elevado ao quadrado para obter sua energia e então é tirada a média da energia de todas as trilhas de cada classe, método descrito por (PFURTSCHELLER e SILVA, 1999) e (NAM, JEON, *et al.*, 2011) para se observar a ocorrência de ERD/ERS. A energia média de cada canal é dada por:

$$Energia_{C_j}^{(c)} = \frac{1}{M} \sum_{i=0}^M C_{ji}^{(c)2} \quad (27)$$

onde  $C_j^{(c)}$  é o canal  $j$  do sinal de EEG na condição  $(c)$  e  $M$  é o número de trilhas. Para melhor visualização é feito um filtro média móvel no sinal resultante de forma a suavizar as curvas.

Observando os resultados obtidos com a Eq. (27), é possível observar o instante de tempo onde vai ocorrer o ERD/ERS, determinando assim o instante de tempo inicial a ser janelado. Se espera que os efeitos mais proeminentes ocorram desde o instante do movimento até cerca de 2s após o movimento.

Obtendo o instante inicial do janelamento, se aplica a Eq. (11) dentro de uma janela de tamanho 2s. Para uma janela de 2s com uma sobreposição de 50%, de acordo com o método descrito na sessão 2.4, são utilizadas 3 janelas de 1s, de acordo com a Figura 17. Com janelas de 1s é possível obter uma resolução de 1Hz entre cada componente espectral. Os valores obtidos podem ser observados de forma gráfica e também através do índice de lateralização

(*IL*) (DOYLE, YARROW e BROWN, 2005) (NAM, JEON, *et al.*, 2011), dado por (28), que demonstra a diferença de energia entre os hemisférios direito e esquerdo:

$$\begin{aligned}
 IL = & [(EnergiaCHE_{movimentoesquerdo} - EnergiaCHD_{movimentoesquerdo}) \\
 & + (EnergiaCHD_{movimentodireito} \\
 & - EnergiaCHE_{movimentodireito}) ]/2
 \end{aligned} \tag{28}$$

onde *EnergiaCHE* é a energia dos canais localizados no hemisfério esquerdo e *EnergiaCHD* é a energia dos canais no hemisfério direito.

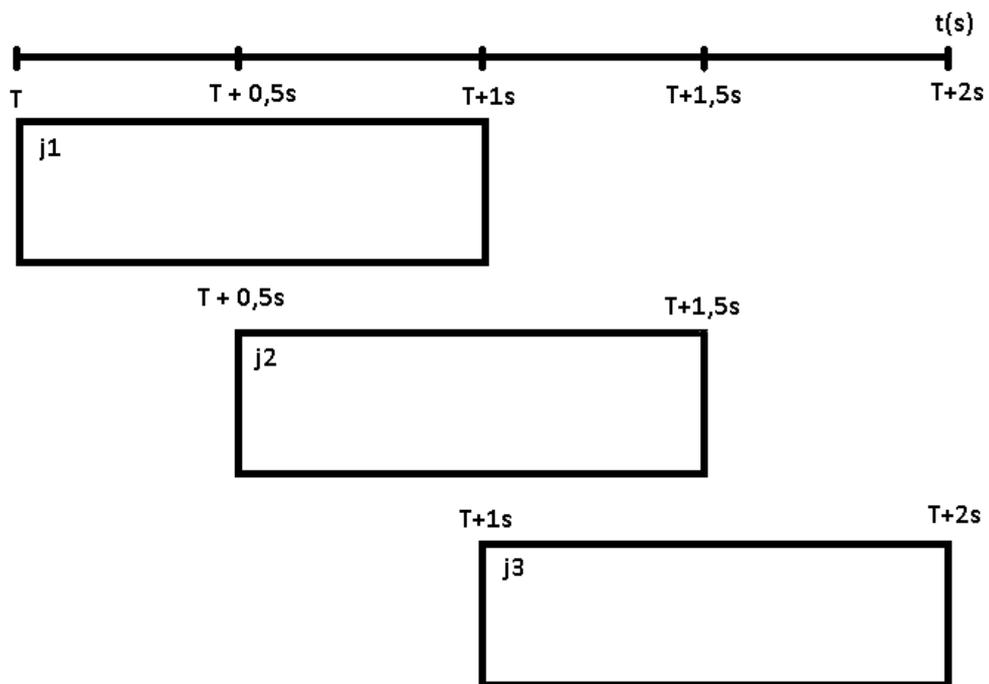


Figura 17: Janelamento pelo método de Welch para um trecho de 2s com sobreposição de 50% entre as janelas.

Altos valores de *IL* mostram uma alta contralateralidade do sinal. Se aplicados para energia de cada componente de frequência dada pela Eq. (11) poderá observar quais as

componentes geram uma discriminação maior entre as classes. Também pode-se aplicar a Eq. (28) para os dados obtidos pela Eq. (27) de forma a se obter o  $IL$  durante o tempo a assim poder verificar em qual instante de tempo ocorrem maiores valores de  $IL$ , indicando assim uma maior atividade discriminativa.

### 3.3.2 Extração de características

#### 3.3.2.1 Sinal Filtrado pelo filtro CSP

A característica extraída utilizando os filtros calculados em 3.2.1 é o logaritmo da energia do sinal projetado pelos filtros com os melhores autovalores para cada classe, de acordo com a Eq. (29):

$$caract_j = \log(\mathbf{w}_j^T \cdot \mathbf{X} \cdot \mathbf{X}' \cdot \mathbf{w}_j) \quad (29)$$

onde  $caract_j$  é o vetor de características utilizado para classificação,  $\mathbf{w}_j$  é o  $j$ -enésimo filtro espacial. A operação  $\log()$  é aplicada afim de tornar as distribuições de energia mais próxima de uma gaussiana (BLANKERTZ, TOMIOKA, *et al.*, 2008). O trecho de sinal de EEG  $X$  a ser utilizado é dado pelas considerações feitas na seção 3.3.1.

#### 3.3.2.2 Periodograma de Welch

Como características a serem utilizadas do sinal de EEG é proposto o uso de componentes espectrais dadas pela Eq. (11), onde foi utilizado por (BHATTACHARYYA, KHASNOBISH, *et al.*, 2011) (HERMAN, PRASAD, *et al.*, 2008) para classificação de sinais de EEG. Portanto, a extração de componentes espectrais de energia é feita de acordo com a Eq. (11). Com o objetivo de se obter uma boa resolução das componentes espectrais o sinal

será janelado utilizado uma janela retangular, que possui o menor lóbulo central de acordo com a Tabela 1.

O tamanho da janela total é de  $2s$  e foi dividida em 3 janelas de  $1s$  com sobreposição de 50% ( $1s$ ) entre cada janela de acordo com a Figura 17. O vetor de características é dado por:

$$\mathbf{caract}_F = \log(\widehat{Gxx}(F)) \quad (30)$$

onde  $\mathbf{caract}_F$  é o vetor de características utilizadas para classificação e  $\widehat{Gxx}(F)$  é o vetor contendo as componentes de frequências estimadas pela Eq. (11). Note que não é necessário utilizar todas as componentes de frequência. As melhores componentes de frequência serão dadas pela Eq. (28). É importante observar que a operação  $\log()$  é aplicada de forma a normalizar a distribuição.

O tempo  $T$  de início do janelamento foi feito de acordo com as considerações feitas na seção 3.3.1. O estimador é calculado pela função  $pwelch()$  do programa *Matlab*.

### 3.3.3 Classificador *Naive Bayes*

O classificador *naive bayes* é implementado utilizando a função *NaiveBayes* do *Matlab*. Essa função implementa a Eq. (22) e faz a modelagem das distribuições. Como as características foram normalizadas através da função  $\log()$ , é utilizada a distribuição normal. Os vetores de características são dados pelas Eqs. (29) e (30) e a quantidade de características fornece o número de distribuições.

### 3.3.4 Classificador LDA

O classificador linear LDA foi implementado pela função *classify* do *Matlab*. Essa função faz a busca dada pela Eq. (25) e encontra o vetor  $w_j$  e a constante  $w_0$ . O número de constantes do vetor  $w_j$  é dado pela quantidade de características utilizadas. É importante ressaltar que em classificadores lineares o uso de uma grande quantidade de características pode ocasionar um *overfit* do classificador, “decorando” os dados de treinamento, degradando sua capacidade de generalização (MITCHEL, 1997).

### 3.4 O EXPERIMENTO DA UNIVERSIDADE DE GRAZ

Um conjunto de sinais também avaliado neste trabalho foi o banco de dados da Universidade de Tecnologia Graz, utilizado no BCI Competition II (BCI Competition II, 2003). Esta base de dados internacional é considerada padrão na área de sistemas BCI em função do seu extenso uso em diversos trabalhos dessa área (BCI Competition II, 2003) (CARRA, 2012) (MING-AI, JING-YU, *et al.*, 2009). Neste experimento, um sujeito saudável (sexo feminino, 25 anos) deve imaginar o movimento da mão direita e esquerda. A sequencia desejada de movimentos (ou estímulos visuais) é gerada por um computador e cada estímulo corresponde a uma trilha do experimento, de um total de 140 trilhas.

A trilha consiste de uma tela em branco em  $t=0s$ ; em  $t=2s$  um estímulo acústico (*beep*) acusa o início da trilha e mostra uma cruz no centro da tela com duração de 1s; em  $t=3s$  aparece uma seta (duração de 6s) indicando qual deve ser o movimento imaginado pelo sujeito em estudo. Durante o período de imaginação do movimento a voluntária visualiza uma realimentação informando se o movimento imaginado está correto ou não.

Os dados, desta base, foram adquiridos com uma frequência de amostragem de 128Hz e foram utilizados os eletrodos C3, C4 e Cz de uma touca seguindo o padrão Sistema 10-20. Todos os sinais foram filtrados por um filtro passa-banda com frequências de corte entre 0,5Hz e 30Hz. Na Figura 18 pode-se visualizar a temporização de uma trilha do experimento.

Essa base de dados é utilizada como comparação aos resultados obtidos no experimento proposto, pois foi feita com um usuário altamente treinado capaz de modular suas ondas de forma a obter uma boa resposta à realimentação do sistema e além disso é gerada em um ambiente controlado.

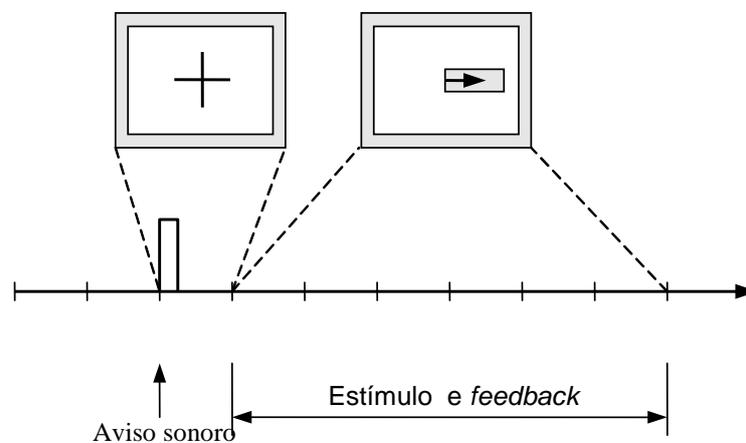


Figura 18: Temporização das trilhas do experimento *BCI Competition II*. Adaptado de (BCI Competition II, 2003).

## 4 RESULTADOS E DISCUSSÕES

Os resultados analisados do experimento proposto são provenientes de um sujeito saudável, do sexo masculino com idade de 21 anos em um ambiente não controlado. Também são apresentados resultados utilizando a base de dados do *BCI Competition II*.

### 4.1 ANÁLISE BASEADA NA ENERGIA DO SINAL

De acordo com a seção 3.3.1 é feita a análise da energia do sinal de acordo com a Eq. (27). Todos os gráficos foram gerados utilizando o *Matlab* e são mostrados em relação a energia média do período de referência, de acordo com a Figura 13 ( $t = 0$  a  $1,5s$ ). Nos gráficos são apresentadas as curvas de cada canal para cada classe de movimento. Com a análise de energia dos sinais e a análise do índice de lateralização (*IL*) durante o tempo é possível identificar o instante de ocorrência do ERD (contralateral) e ERS (ipsilateral) e determinar a partir de que ponto o sinal será janelado para a extração de suas características de forma a obter uma melhor discriminação entre as classes de movimento. Também é realizada uma análise do índice de lateralização da energia média de todas as trilhas do sinal de EEG ao longo do tempo para os dois experimentos.

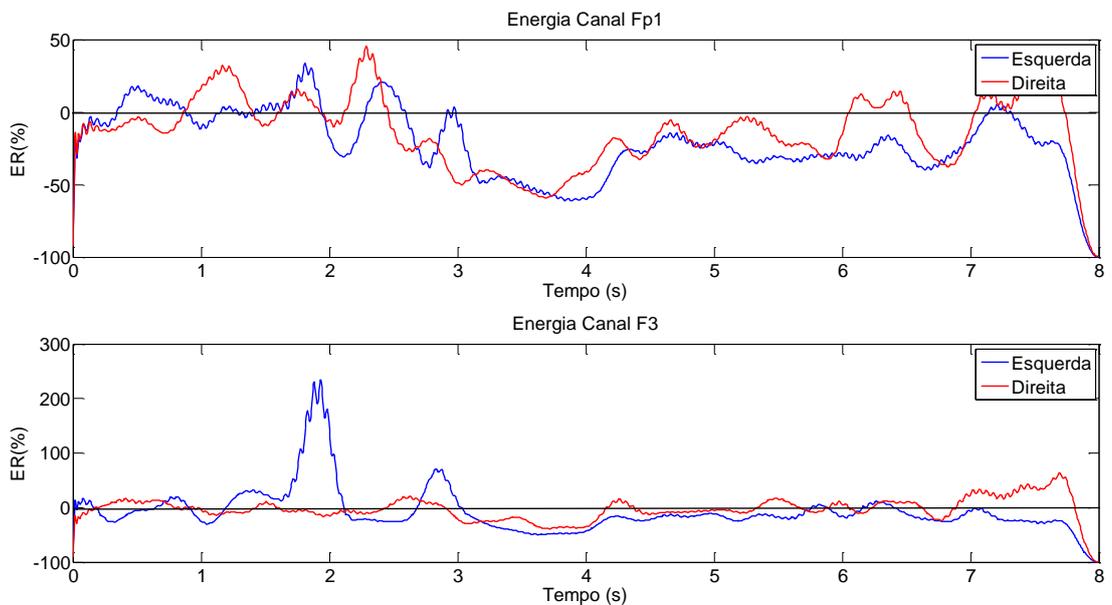
#### 4.1.1 Experimento proposto

Para o experimento proposto foram realizadas 4 sessões de acordo com a Tabela 3, note que a quantidade de trilhas para cada tipo de movimento pode variar pois só foram selecionadas as trilhas onde o sujeito pressionou corretamente os botões de acordo com a metodologia descrita na seção 3.1.1.

Tabela 3: Sessões do experimento proposto.

Sessão	Trilhas Esquerda	Trilhas Direita
<b>S1</b>	99	99
<b>S2</b>	136	139
<b>S3</b>	98	100
<b>S4</b>	137	136

A seguir, da Figura 19 a Figura 22, são apresentados os resultados gráficos da análise da energia média relativa do sinal para os 8 canais sessão S3. Eles foram gerados a partir da Eq. (27) e todos os canais foram filtrados por um passa banda dentro da faixa  $\mu$  (8 a 12Hz) e foi utilizado um filtro média móvel com 63 pontos sobre o sinal médio de forma a suavizar as curvas. As demais sessões encontram-se no Anexo A.

Figura 19: Energia média relativa dos canais Fp1 e F3 durante a sessão S3 (banda  $\mu$ ).

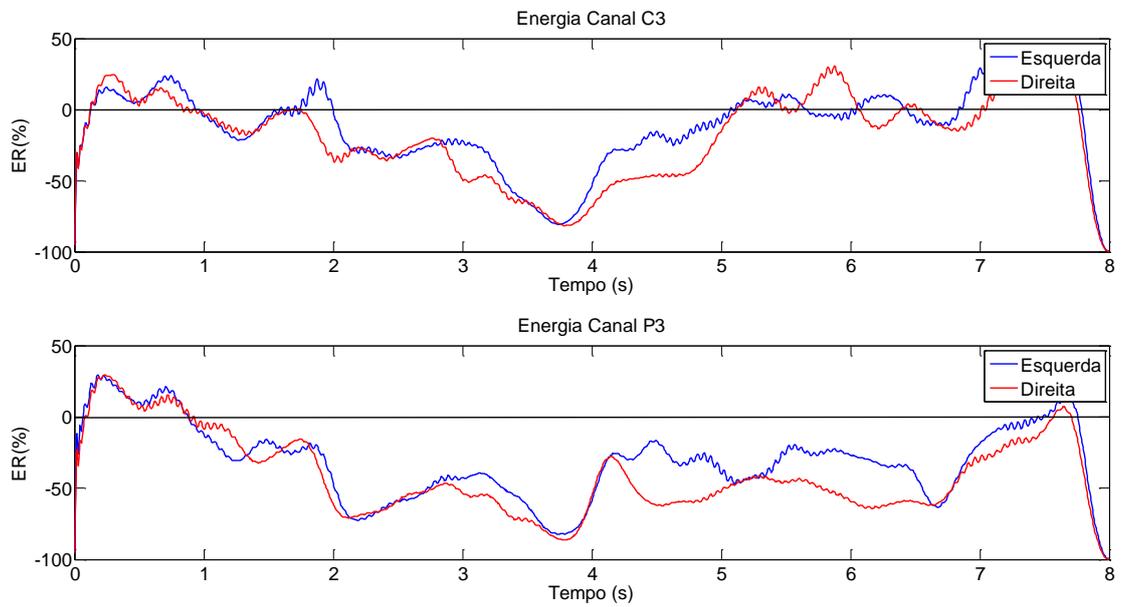


Figura 20: Energia média relativa dos canais C3 e P3 durante a sessão S3 (banda  $\mu$ ).

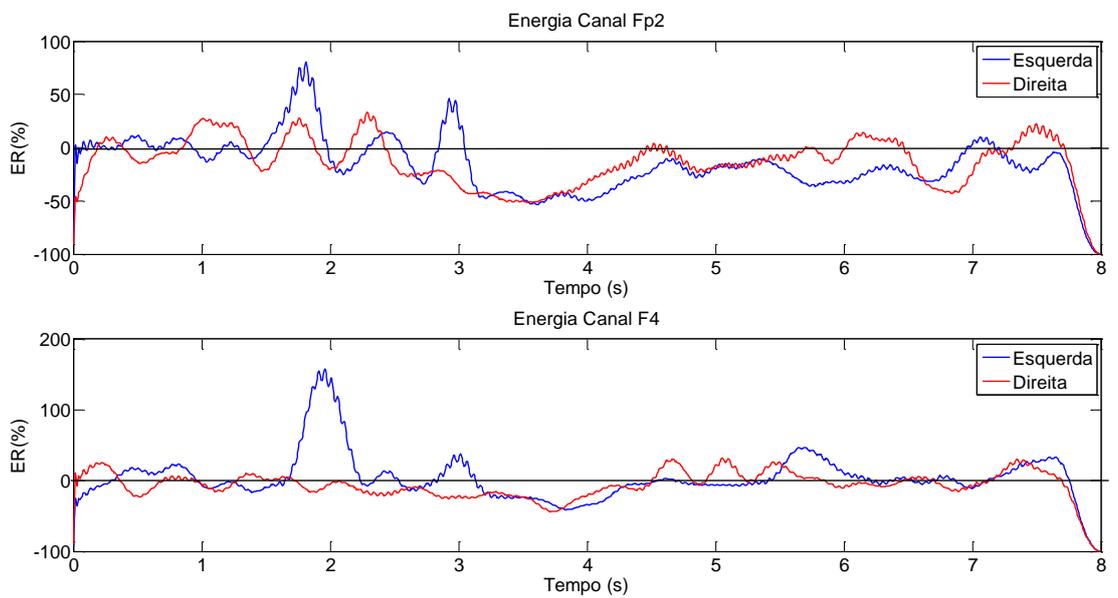


Figura 21: Energia média relativa dos canais Fp2 e F4 durante a sessão S3 (banda  $\mu$ ).

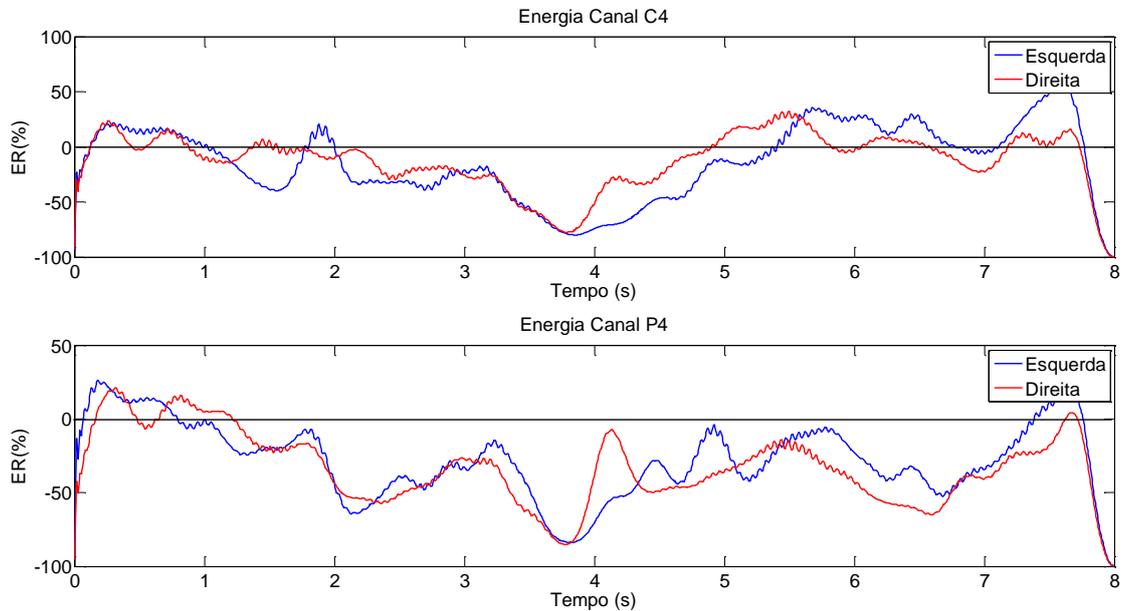


Figura 22: Energia média relativa dos canais C4 e P4 durante a sessão S3 (banda  $\mu$ ).

Os resultados da sessão S3 mostram uma forte dessincronização cerca de 500ms após o surgimento do pré-estímulo em  $t = 1,5s$  (cruz da Figura 13) nos canais C3, P3, C4 e P4 (Figura 20 e Figura 22) para ambos os tipos de movimento. Observações semelhantes podem ser feitas nas outras três sessões, onde os gráficos da energia relativa encontram-se no Anexo A. O efeito do ERD/ERS durante e após o movimento pode ser observado em todos canais que cobrem o córtex motor (C3 e C4), sempre mantendo a energia do lado ipsilateral mais alta que o lado contralateral ao movimento, porém mostrando um ERS mais acentuado no hemisfério esquerdo. Esse efeito também foi observado nos canais que cobrem o córtex parietal, mostrando que este sujeito apresentou, nesses ensaios, atividade motora no córtex parietal. Observe também que em todos casos o ERS do lado ipsilateral ocorre cerca de 800ms após a indicação da seta no tempo  $t = 3s$ , mostrando um efeito discriminativo entre a energia das duas classes. Observe que esses resultados estão de acordo com a teoria exposta

nas seções 2.1.1 e 2.2.1. Portanto, para o janelamento do sinal, tanto para extração das componentes espectrais como para extração da energia do sinal, foram utilizados valores iniciais da janela entre  $t = 3,5s$  a  $t = 4s$  (de  $500ms$  a  $1s$  após o surgimento da seta).

Veja que os canais Fp1, Fp2, F3 e F4 não apresentam nenhuma atividade discriminativa pois são canais altamente suscetíveis a artefatos musculares proveniente dos músculos da face, contaminando o sinal de EEG desses canais. Não foi possível observar nenhuma atividade discriminativa dentro da faixa da banda  $\beta$ , que pelo fato de possuir uma banda de frequência mais elevada, é mais sensível aos artefatos musculares. Pode-se ver, na Figura 23 e na Figura 26, a energia média relativa do sinal filtrado dentro da faixa  $\beta$  (13 a 24Hz) somente da sessão S4.

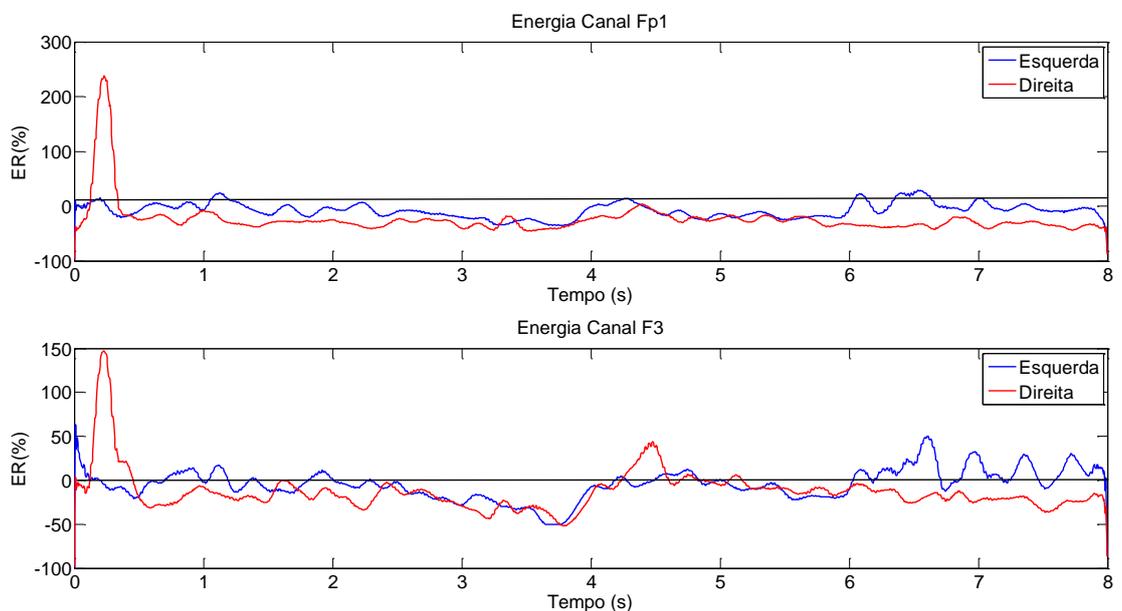


Figura 23: Energia dos canais Fp1 e F3 durante a sessão S4 (banda  $\beta$ ).

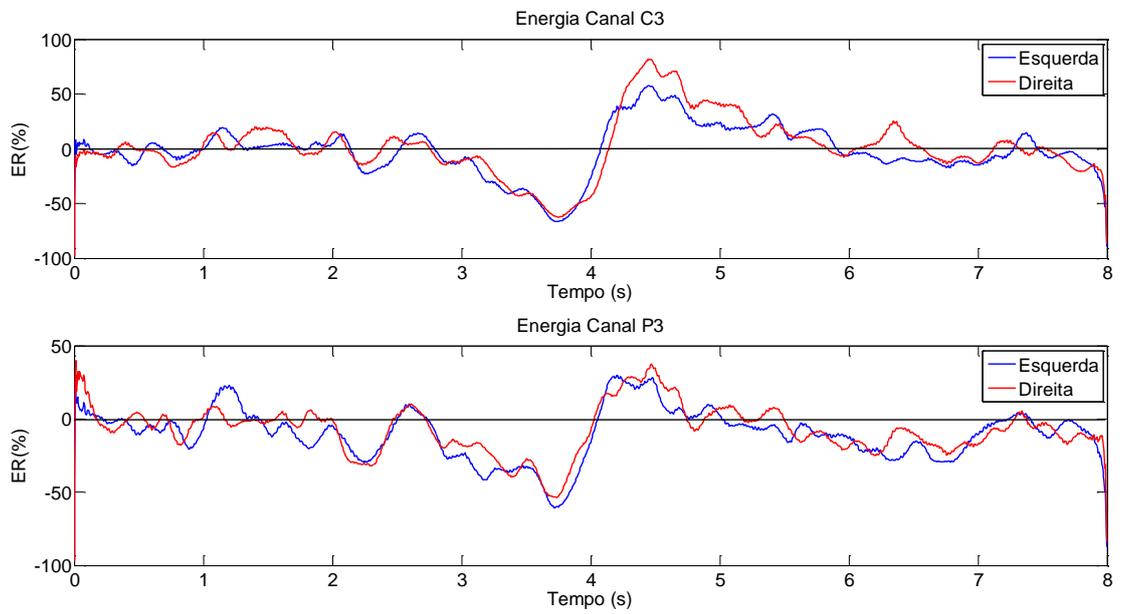


Figura 24: Energia dos canais C3 e P3 durante a sessão S4 (banda  $\beta$ ).

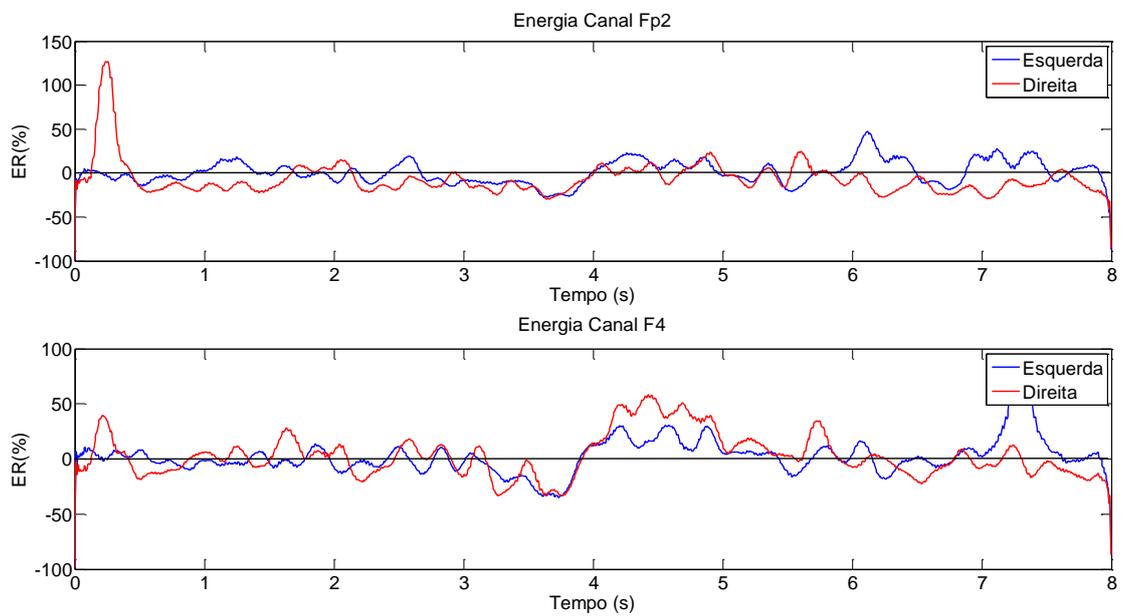


Figura 25: Energia dos canais Fp2 e F4 durante a sessão S4 (banda  $\beta$ ).

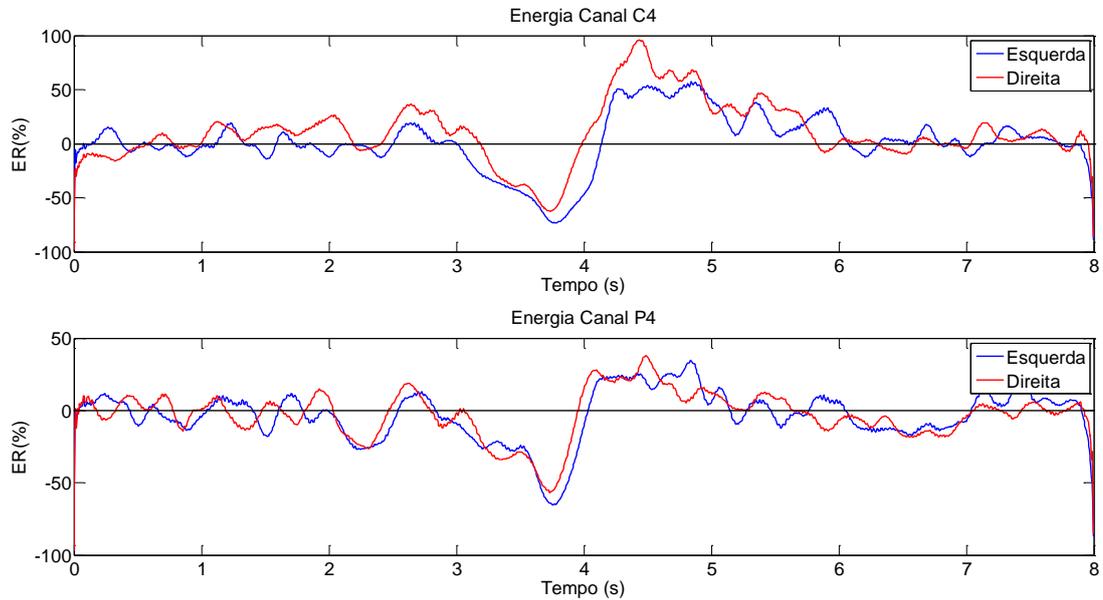


Figura 26: Energia dos canais C4 e P4 durante a sessão S4 (banda  $\beta$ ).

Veja que logo após surgir a seta ocorre um ERD e cerca de 1s depois um ERS nos canais localizados no córtex central (C3 e C4), o que está de acordo com a teoria exposta nas seções 2.1.1 e 2.2.1. O indivíduo também possui uma atividade motora nos canais localizados no córtex parietal. Note que dentro do ritmo  $\beta$ , não existe uma discriminação de energia entre os dois tipos de movimento, sendo que este comportamento foi observado também nas outras sessões. Observe também que os sinais estão altamente contaminados por artefatos, como os sinais de alta amplitude no início das trilhas de Fp1 e Fp2. Portanto os sinais dentro do ritmo  $\beta$  não foram utilizados para a tarefa de classificação, pois não apresentam nenhuma característica discriminativa relevante.

#### 4.1.1.1 Índice de Lateralização

O índice de lateralização (IL) dado pela Eq. (28) foi calculado utilizando apenas os canais centrais (C3 e C4) e os canais parietais (P3 e P4), pois foram os canais que apresentaram atividade motora perceptível neste sujeito e nos ensaios realizados. A Figura 27 apresenta o gráfico do índice de lateralização normalizado em relação à energia média do período de referência ( $t = 0$  a  $t = 1,5s$ ), ao longo do tempo para as 4 sessões.

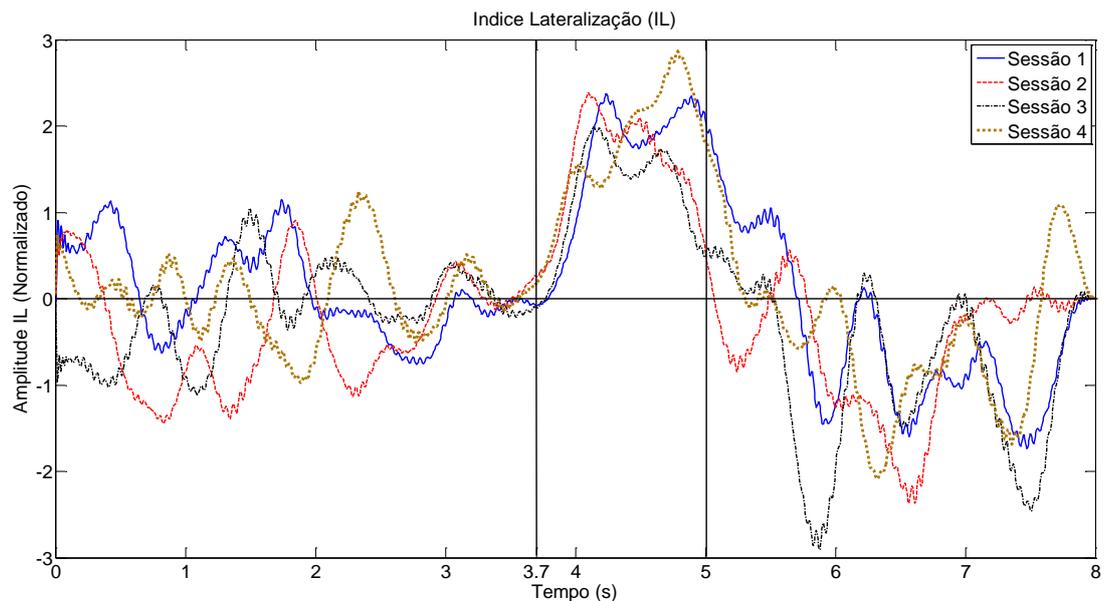


Figura 27: Índice lateralização médio e relativo para os canais C3 e C4 para as 4 sessões.

O gráfico dos índices de lateralização indica uma alta lateralização dos sinais no córtex central em torno de  $500ms$  após o aparecimento da seta até cerca de  $2s$  após o surgimento da seta em  $t = 5s$ , corroborando a escolha anterior para início do janelamento do sinal a partir de  $t = 3,5s$ . Para extração da energia serão utilizadas as janelas indicadas na Tabela 4, onde  $T_1$  indica o início da janela e  $T_2$  indica o fim da janela. Para a extração das componentes

espectrais apenas uma janela de  $t = 3s$  a  $t = 5s$  é utilizada, pois para obter uma resolução de 1Hz utilizando a Eq. (11) é necessário uma janela de no mínimo 2s.

Tabela 4: Instantes de tempo do janelamento para extração da energia do sinal para o experimento proposto

Janela	$T_1$ (s)	$T_2$ (s)
$w_1$	3,5	5,0
$w_2$	3,6	5,0
$w_3$	3,7	5,0
$w_4$	3,8	5,0
$w_5$	3,9	5,0
$w_6$	4,0	5,0

#### 4.1.2 Experimento BCI Competition II

O experimento do *BCI Competition II* possui um arquivo com 280 trilhas, sendo que 140 são para movimentos imaginários da mão direita e 140 para mão esquerda. Eles são sinais filtrados entre 0,5Hz e 30Hz e nesta sessão é apresentada a análise gráfica da energia dos sinais utilizando a metodologia empregada neste trabalho.

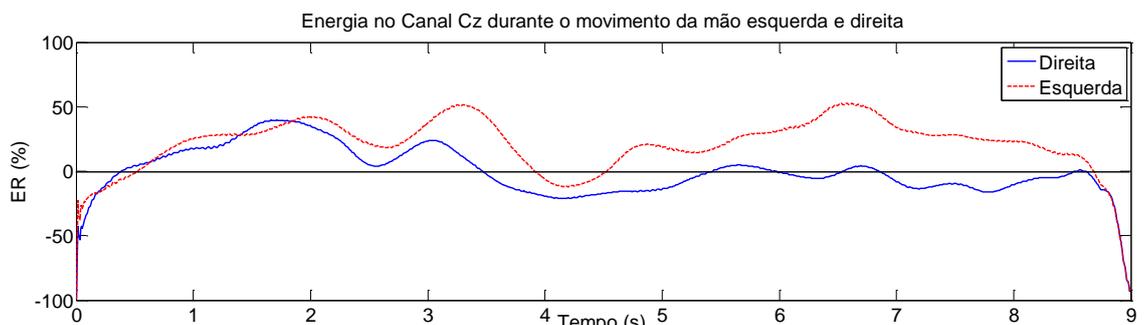


Figura 28: Energia do canal Cz do experimento *BCI Competition II* (banda  $\mu$ ).

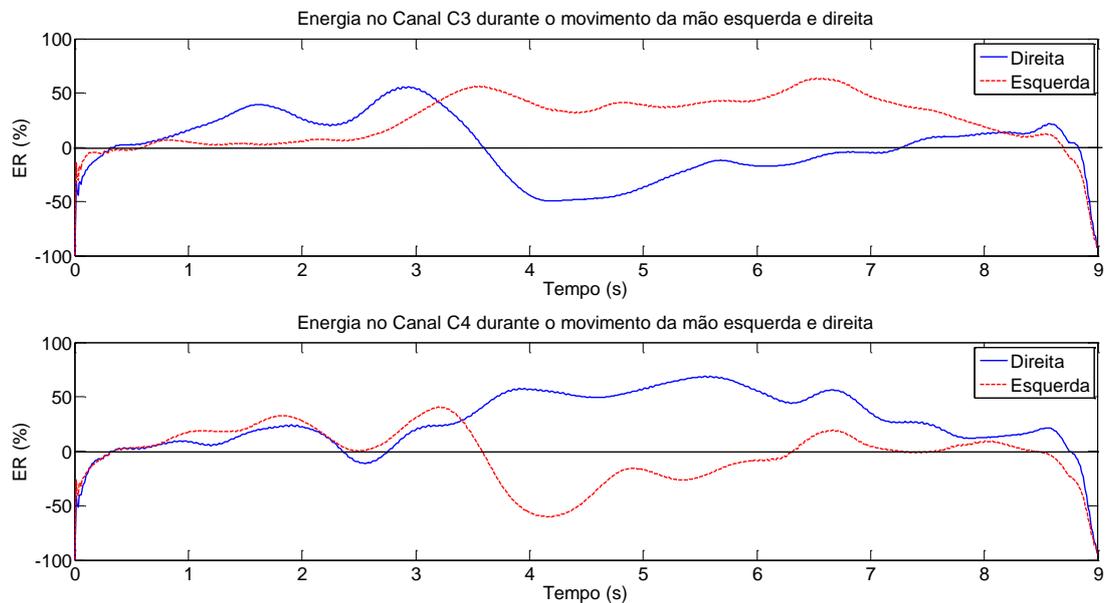


Figura 29: Energia dos canais C3 e C4 do experimento *BCI Competition II* (banda  $\mu$ ).

Neste experimento, o sujeito em estudo possui uma alta atividade discriminativa, tendo um elevado ERD no lado contralateral e um elevado ERS no lado ipsilateral ao movimento, como evidenciam os gráficos dos canais C3 e C4. Veja que no canal Cz não há nenhuma atividade discriminativa entre as 2 classes de movimento, o que está de acordo com a teoria exposta nas seções 2.1.1 e 2.2.1. Também pode-se verificar que o sinal possui atividade discriminativa dentro da banda  $\beta$  de acordo com a Figura 30 (gráficos apenas para C3 e C4)

O instante em torno de  $t = 3,5s$  se mostra o instante de tempo onde a atividade discriminativa começa, sendo portanto o instante inicial de recorte do sinal para classificação e pode-se utilizar o período entre 3,5 e 6 segundos para extração de energia do sinal. Por possuir atividade discriminativa nas bandas  $\mu$  e  $\beta$  o sinal é filtrado por um passa banda entre 8 e 24Hz. Pode-se ver também na Figura 31 o IL normalizado utilizando o valor de pico do sinal, mostrando uma alta lateralização do sinal a partir de  $t = 3,5s$ .

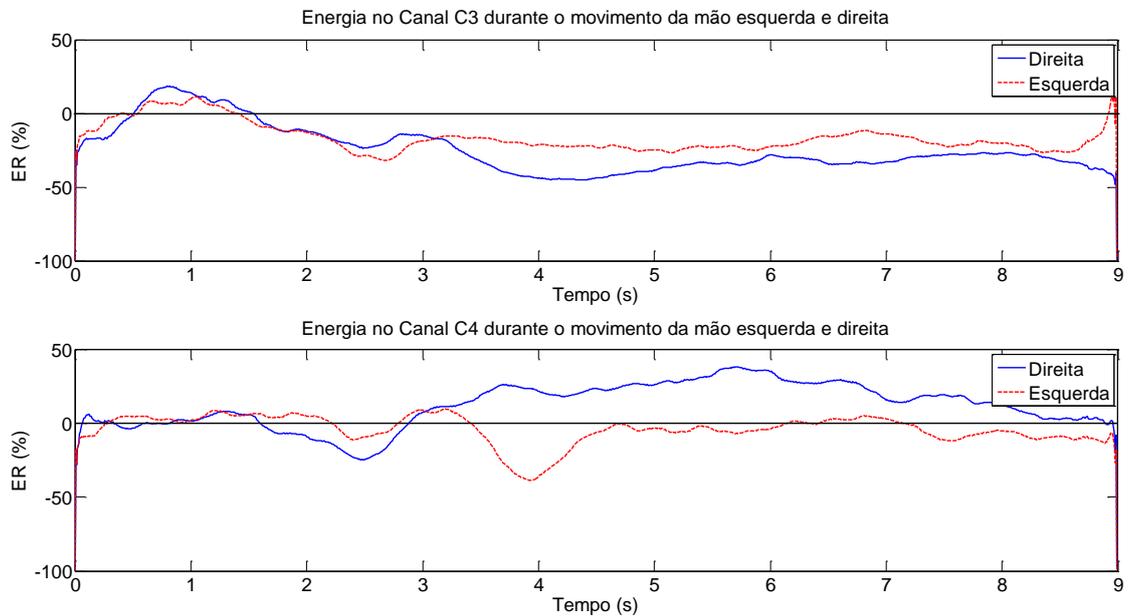


Figura 30: Energia dos canais C3 e C4 do experimento *BCI Competition II* (banda  $\beta$ ).

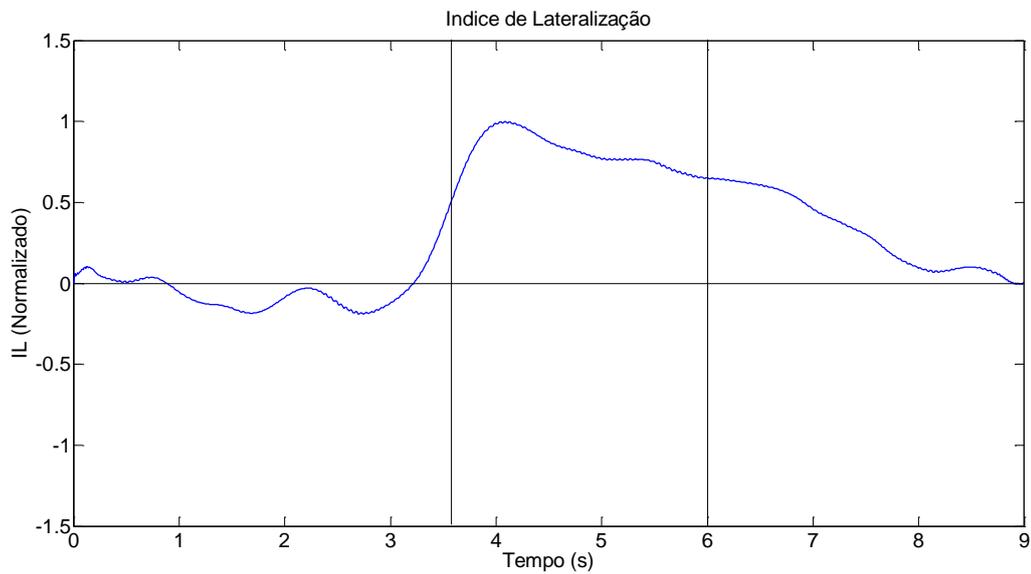


Figura 31: *IL* normalizado do experimento *BCI Competition II* (banda  $\mu$  e  $\beta$ ).

Pelo fato do sujeito em estudo ser treinado e também ter uma realimentação do sistema informando se o movimento foi imaginado corretamente, ele pode modular seu ritmo sensorio

motor de forma a obter uma maior distinção entre os dois tipos de movimentos imaginário. Essa observação vai de encontro com (WOLPAW, BIRBAUMER, *et al.*, 2002) quando afirma que o uso de um sistema BCI é uma habilidade que pode ser aprendida. As janelas utilizadas para extração de energia são dadas pela Tabela 5:

Tabela 5: Instantes de tempo do janelamento para extração da energia do sinal para o experimento *BCI Competition II*.

<b>Janela</b>	<b><math>T_1</math> (s)</b>	<b><math>T_2</math> (s)</b>
$w_1$	3,5	6,0
$w_2$	3,75	6,0
$w_3$	4,0	6,0
$w_4$	4,25	6,0
$w_5$	4,5	6,0
$w_6$	4,75	6,0
$w_7$	5,0	6,0

#### 4.2 ANÁLISE BASEADA NO PERIODOGRAMA DE WELCH

Nesta sessão serão apresentados os gráficos referentes ao periodograma. Também foi avaliado o IL das componentes espectrais para determinar quais componentes de frequência possuem maior discriminação. Os valores de energia em frequência foram todos calculados utilizando a Eq. (11). Para o experimento proposto e o experimento *BCI Competition II* foi utilizada uma janela de 2s para obter uma resolução de pelo menos 1Hz. Para o experimento

proposto a janela utilizada é entre  $t = 3s$  e  $t = 5s$  da sessão S3 (demais sessões em anexo) e para o experimento *BCI Competition II* uma janela entre  $t = 4s$  e  $t = 6s$ . Os sinais foram filtrados por um passa banda entre 8Hz e 24Hz de forma a cobrir todo o ritmo sensório-motor. O IL é calculado de acordo com a Eq. (28).

#### 4.2.1 Experimento Proposto

Da Figura 32 a Figura 35 é apresentada a análise em frequência do experimento proposto, sessão S3, e na Figura 36 é apresentado o IL no domínio frequência e a seguir discussões relacionadas aos resultados:

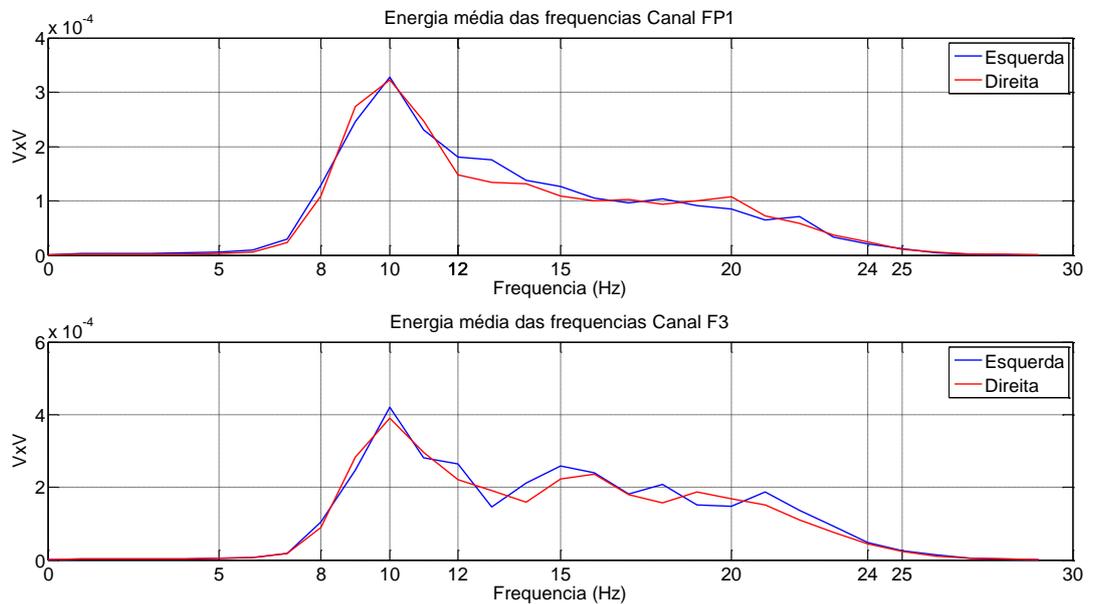


Figura 32: Energia média do experimento proposto no domínio frequência para os canais Fp1 e F3.

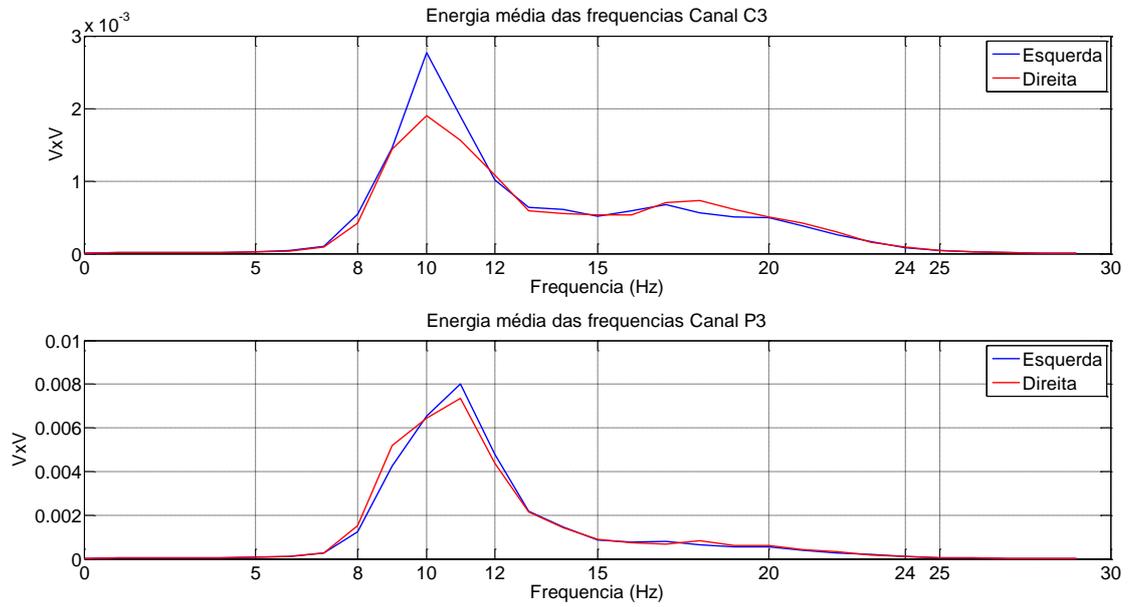


Figura 33: Energia média do experimento proposto no domínio frequência para os canais C3 e P3.

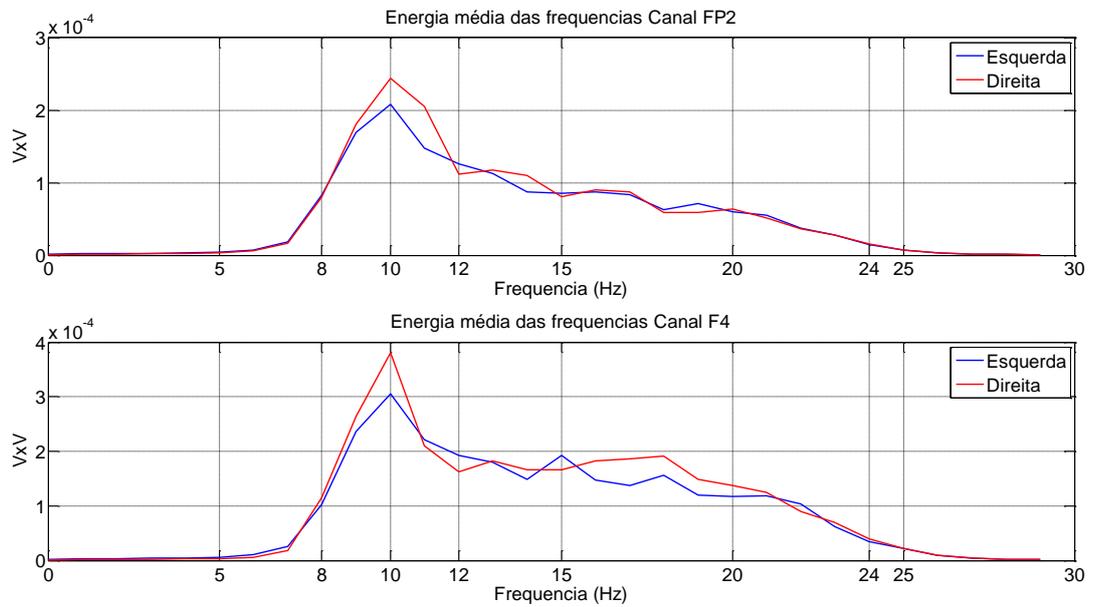


Figura 34: Energia média do experimento proposto no domínio frequência para os canais Fp2 e F4.

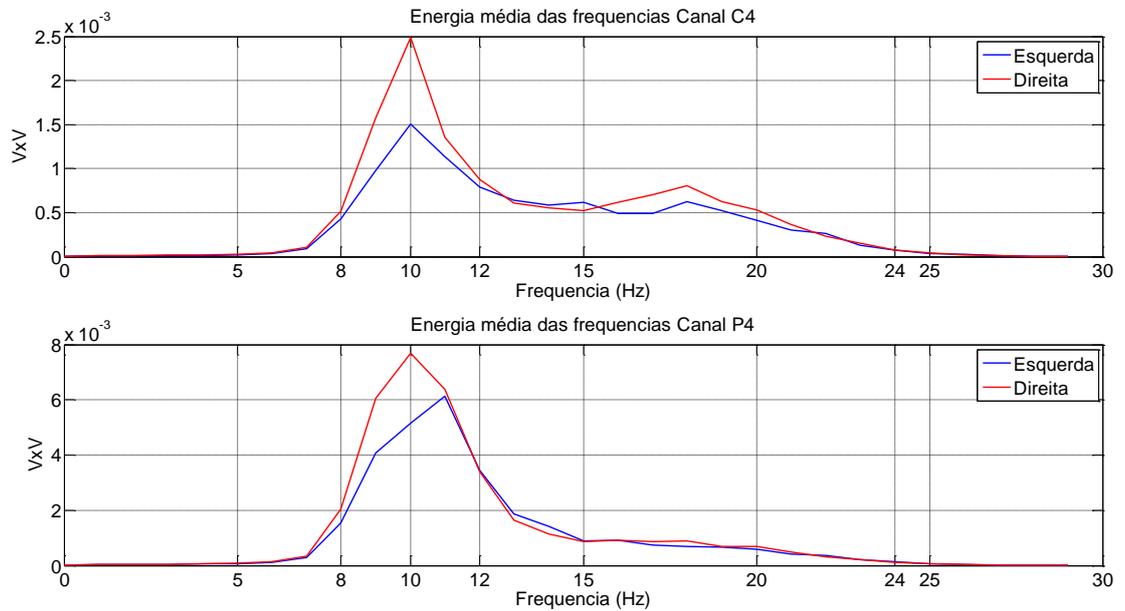


Figura 35: Energia média do experimento proposto no domínio frequência para os canais C4 e P4.

Para os canais Fp1 e F3 (Figura 32) não existe nenhuma atividade discriminativa relevante, demonstrando não haver atividade motora nesses canais. Para os canais Fp2 e F4 (Figura 33) a energia durante o movimento da mão direita é maior que a durante o movimento da mão esquerda, porém ao se analisar a Figura 21 verifica-se que entre o período  $t = 1s$  a  $t = 3s$  existe um grande pico de energia durante o movimento da mão direita e é provavelmente causado por algum tipo de artefato muscular ou interferência nos canais, não estando relacionada a atividade motora. Para os canais C3, P3, C4 e P4 pode-se observar uma clara distinção de energia entre as classes de movimento, dentro do ritmo  $\mu$ , sempre com o lado ipsilateral ao movimento mantendo a energia maior que a energia relativa ao lado contralateral do movimento. Dentro do ritmo  $\beta$  não pode-se observar atividade discriminativa relevante, pois como descrito anteriormente, este usuário não apresenta atividade discriminativa perceptiva dentro do ritmo  $\beta$ .

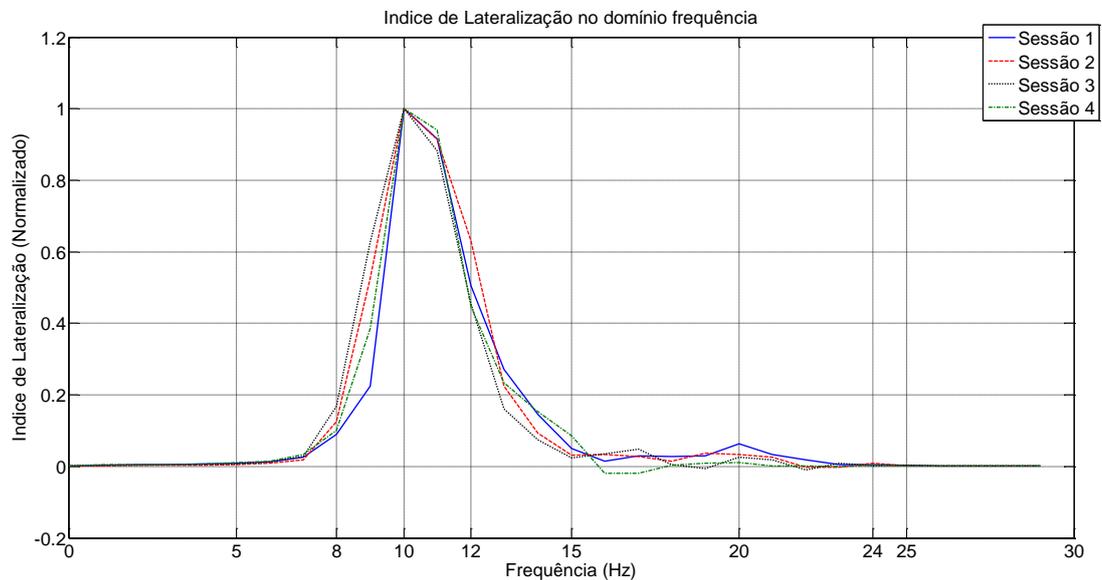


Figura 36: *IL* do experimento proposto no domínio frequência para todas sessões.

O *IL* no domínio frequência, apresentado na Figura 36, calculado utilizando os canais centrais (C3 e C4) e parietais (P3 e P4) e normalizado utilizando o valor de pico, permite verificar uma clara atividade discriminativa entre 8 e 12Hz, corroborando os resultados apresentados anteriormente. Dessa forma, pode-se determinar as componentes espectrais dentro dessa faixa para utilizar como características para classificação, utilizando as componentes de frequência que apresentam o maior valor de *IL*.

#### 4.2.2 *BCI Competition II*

Na Figura 37 e Figura 38 é apresentada a análise gráfica dos três canais utilizados no experimento. Na Figura 39 é apresentado o *IL* do experimento utilizando apenas os canais C3 e C4, pois são os canais que apresentam atividade motora relevante para o movimento das mãos.

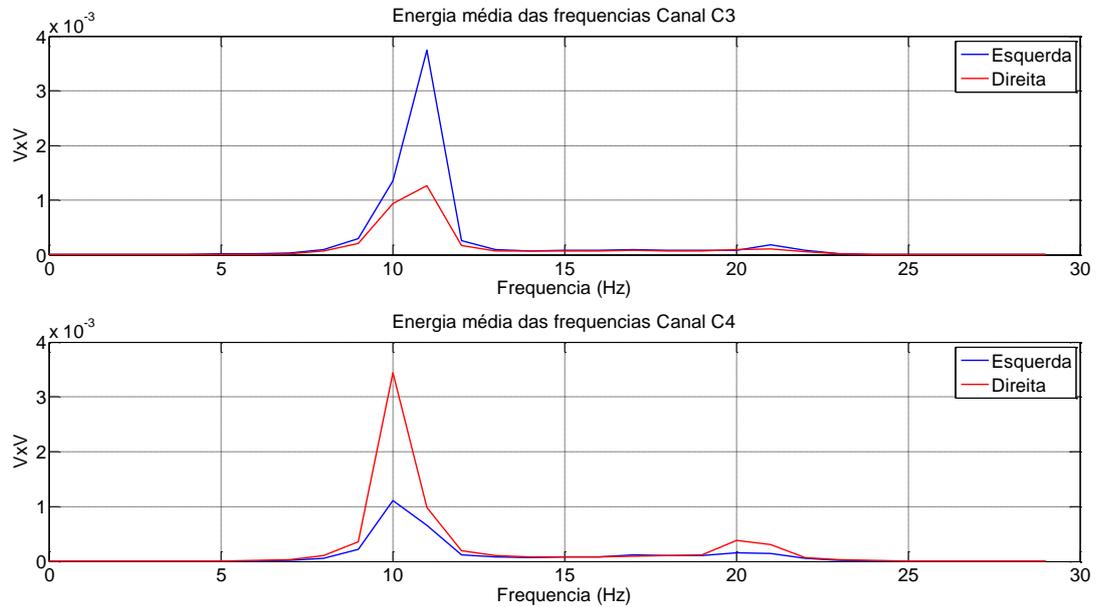


Figura 37: Energia média do *BCI Competition II* no domínio frequência para os canais C3 e C4.

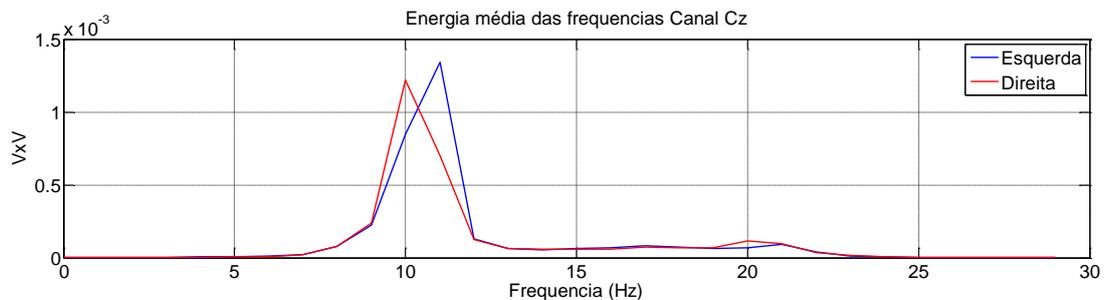


Figura 38: Energia média do *BCI Competition II* no domínio frequência para o canal Cz.

Conforme pode-se verificar na Figura 37, existe uma clara atividade discriminativa a partir de cerca de 10Hz até 12Hz para o canal C3 e a partir de 9Hz até cerca de 11Hz para o canal C4, mostrando uma variabilidade das faixas entre os canais para o sujeito em estudo. Na Figura 39 pode-se verificar o IL, normalizado utilizando o valor de pico, e nota-se uma clara atividade discriminativa a partir de 9Hz até cerca de 12Hz. Também é possível através do gráfico do IL verificar que existe uma atividade discriminativa entre 19Hz e 22Hz. As

componentes utilizadas para a classificação do sinal de EEG foram as componentes que apresentaram o maior valor do IL.

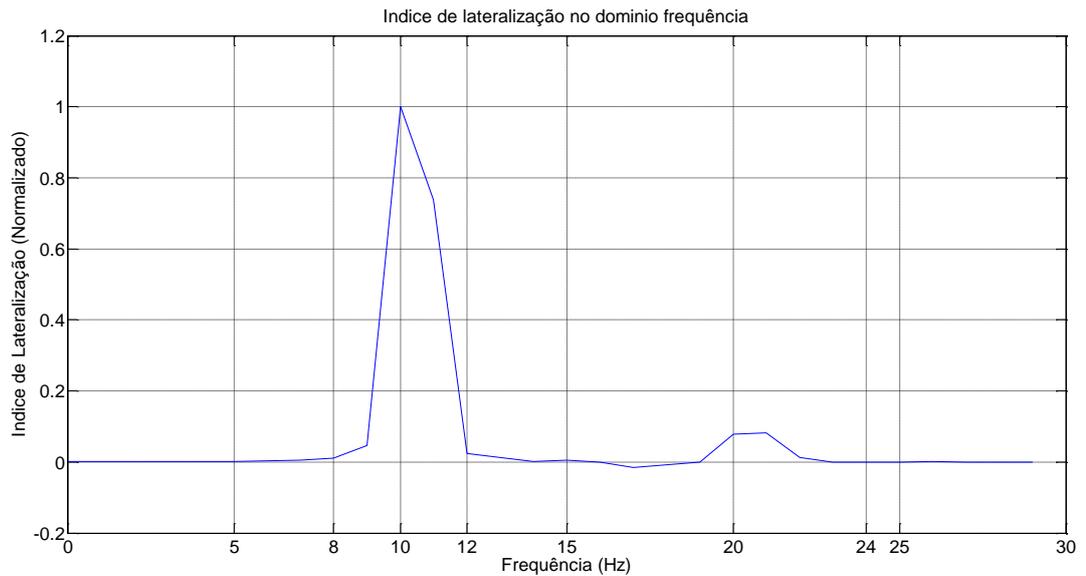


Figura 39: IL do *BCI Competition II* no domínio frequência

### 4.3 ANÁLISE BASEADA NO FILTRO ESPACIAL

Com o objetivo de fazer uma análise do funcionamento do filtro CSP, os coeficientes do filtro espacial são calculados utilizando todo conjunto de dados e também aplicado a todo o conjunto de dados. Os filtros foram calculados utilizando uma janela de 2s a partir de  $t = 3s$  para os dados do experimento proposto e a partir de  $t = 4s$  para o experimento *BCI Competition II*. A escolha dessas janelas se deve ao fato de que nessa sessão foi feita uma avaliação da funcionalidade do filtro, mostrando se o trecho do sinal escolhido cria um novo espaço de canais com atividades discriminativas através da análise espectral do trecho utilizado.

### 4.3.1 Experimento Proposto

Como já descrito anteriormente foram utilizados apenas os canais centrais e parietais para o cálculo dos coeficientes do filtro. Os sinais utilizados para o cálculo foram filtrados dentro do ritmo  $\mu$ . Na Figura 40 e Figura 41 pode-se observar os gráficos da energia das componentes espectrais, calculada pela Eq. (11), da sessão S3. Os canais originais (C3, C4, P3 e P4) foram linearmente combinados, de acordo com a Eq. (19), pelo filtro  $W$  obtido pelos procedimentos descritos na sessão 3.2.1 de forma a criar um novo espaço de canais denominados CSP1, CSP2, CSP3 e CSP4. Como forma de comparação, são apresentados também os gráficos da energia média espectral dos canais C3 e C4, que de acordo com a Figura 20 e Figura 22, são os canais com maior atividade discriminativa dentro da janela estudada.

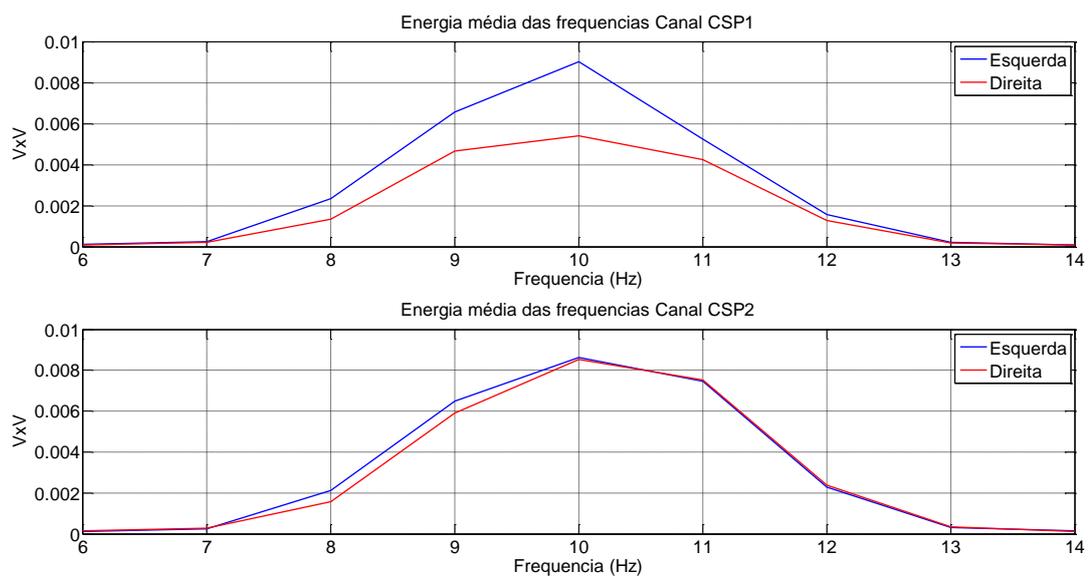


Figura 40: Energia média do experimento proposto no domínio frequência para os canais CSP1 e CSP2.

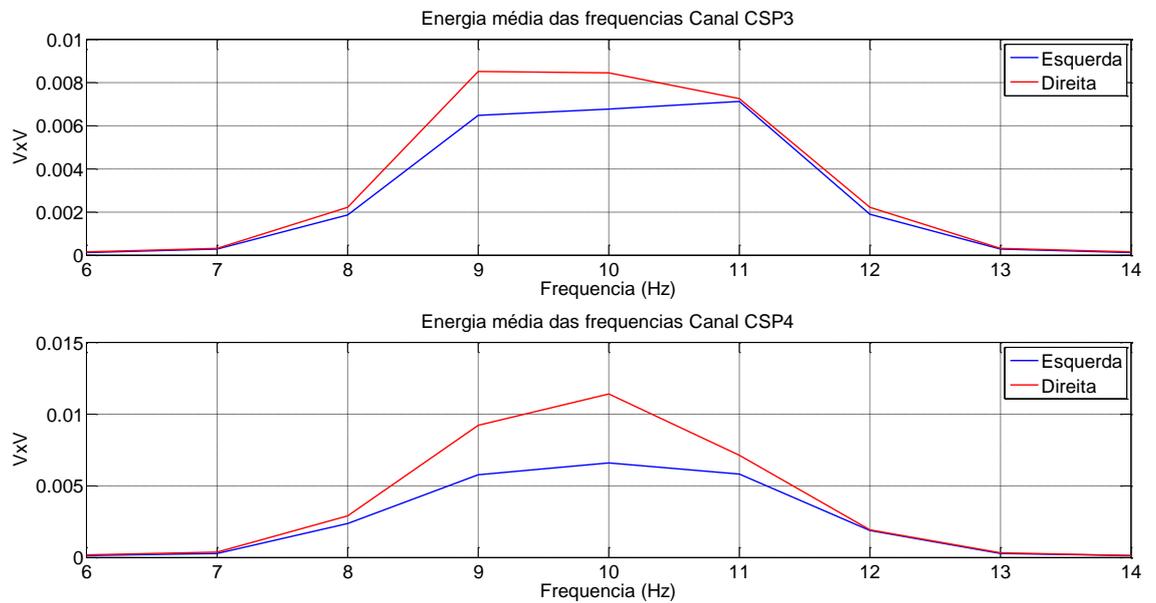


Figura 41: Energia média do experimento proposto no domínio frequência para os canais CSP3 e CSP4.

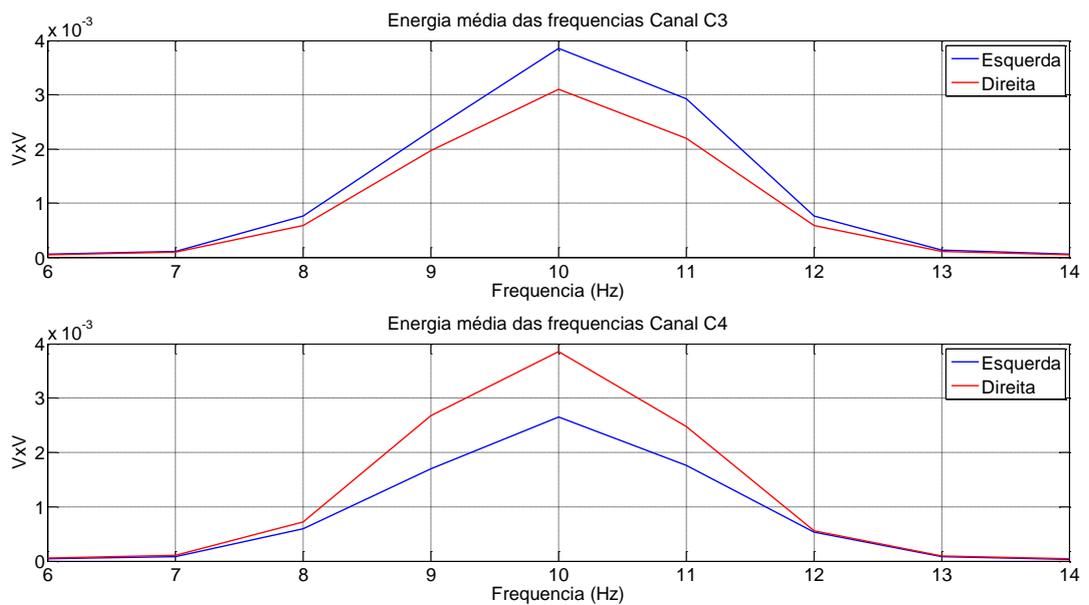


Figura 42: Energia média do experimento proposto no domínio frequência para os canais C3 e C4 (ritmo  $\mu$  apenas).

As matrizes de autovalores,  $\Lambda^{(D)}$  e  $\Lambda^{(E)}$ , encontrados através da Eq. (13) indicam quais canais linearmente combinados apresentam maior atividade discriminativa. Observe que os resultados de  $\Lambda^{(D)}$  e  $\Lambda^{(E)}$  estão de acordo com a Figura 40 e Figura 41, onde se pode verificar que o canal CSP1 (que corresponde a primeira coluna de  $\Lambda^{(c)}$ ), onde para  $\Lambda^{(D)}$  o valor é mínimo e para  $\Lambda^{(E)}$  o valor é máximo, mostrando que energia da classe de movimento esquerda deve ser maior que a da classe de movimento direita. Veja também que  $\Lambda^{(D)} + \Lambda^{(E)} = I$ .

$\Lambda^{(D)}$				$\Lambda^{(E)}$			
0,37	0	0	0	0,63	0	0	0
0	0,47	0	0	0	0,53	0	0
0	0	0,50	0	0	0	0,5	0
0	0	0	0,54	0	0	0	0,46

A primeira e última coluna das matrizes  $\Lambda^{(D)}$  e  $\Lambda^{(E)}$  mostram os filtros que melhor discriminam as 2 classes, o que também está de acordo com os gráficos da Figura 40 e Figura 41. A aplicação do filtro também aumentou a atividade discriminativa entre as 2 classes de movimento. Pode-se verificar esse ganho analisando a energia proporcional entre as 2 classes para um mesmo canal de acordo com a Eq. (31):

$$E_p^{(c)} = \frac{E^{(c)}}{E^{(D)} + E^{(E)}} \quad (31)$$

onde  $E_p^{(c)}$  é a energia proporcional na classe (c),  $E^{(c)}$  é a energia da classe (c) e  $E^{(D)}$  e  $E^{(E)}$  são as energias nas classes de movimento direita e esquerda.

Verificando a energia proporcional da classe direita para a componente de 10Hz, por exemplo, para os canais C4 do espaço original de sensores e para o canal CSP4 para o novo espaço de sensores, obtém-se os resultados indicados na Tabela 6:

Tabela 6: Comparativo da energia proporcional entre classes com e sem o filtro CSP.

	<b>Sem Filtro</b>	<b>Com Filtro</b>
	<b>Canal C4</b>	<b>Canal CSP4</b>
$E_P^{(D)}$	0,59	0,63

A aplicação do filtro aumentou o contraste entre as classes de acordo com os resultados da Tabela 6. Porém é importante ressaltar que os coeficientes foram estimados a partir de todo o conjunto de dados.

#### **4.3.2 Experimento *BCI Competition II***

Para a análise gráfica do efeito dos filtro espacial sobre o conjunto de dados do experimento *BCI Competition II* foram utilizados os 3 canais (C3, Cz e C4) para o cálculo dos coeficientes do filtro espacial. Para a análise foi utilizado todo o conjunto de dados e todos sinais foram filtrados entre 8Hz e 24Hz. Na Figura 43 pode-se ver os canais recombinaados CSP1 e CSP3 calculados a partir da Eq. (12) utilizando os procedimentos descritos na sessão 3.2.1. Apenas estes dois canais são apresentados pois são os únicos a apresentar atividade discriminativa.

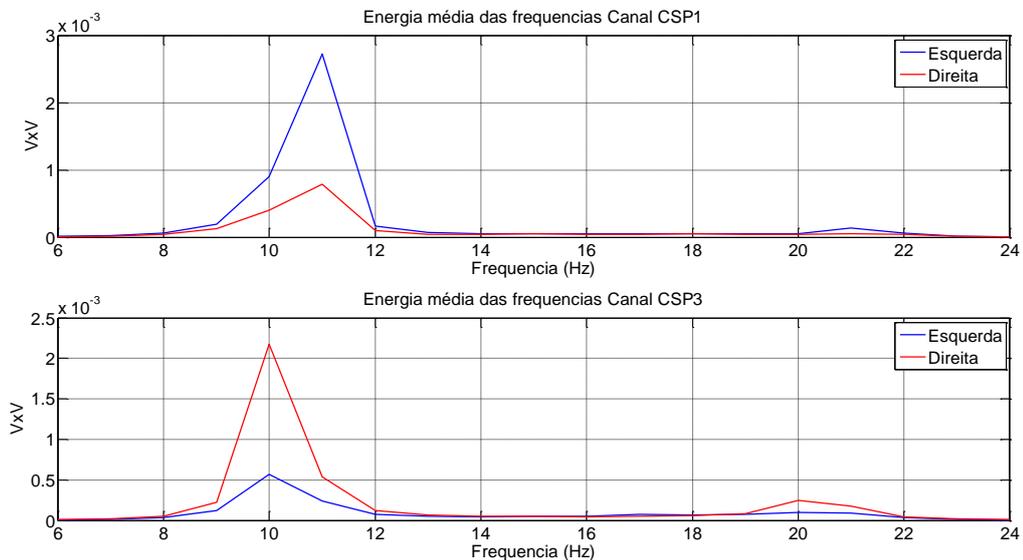


Figura 43: Energia média do experimento proposto no domínio frequência para os canais CSP1 e CSP3.

As matrizes de autovalores,  $\Lambda^{(D)}$  e  $\Lambda^{(E)}$ , encontrados através da Eq. (13) indicam quais os canais linearmente combinados apresentam maior atividade discriminativa. Da mesma forma que na sessão anterior, as matrizes  $\Lambda^{(D)}$  e  $\Lambda^{(E)}$  tiveram valores coerentes com a análise feita na Figura 43.

$$\begin{array}{ccc}
 \Lambda^{(D)} & & \Lambda^{(E)} \\
 \begin{array}{ccc}
 0,31 & 0 & 0 \\
 0 & 0,49 & 0 \\
 0 & 0 & 0,70
 \end{array} & & \begin{array}{ccc}
 0,69 & 0 & 0 \\
 0 & 0,51 & 0 \\
 0 & 0 & 0,30
 \end{array}
 \end{array}$$

Através da Eq. (31) aplicada a classe de movimento esquerda para os canais C3 (onde se pode ver a energia no domínio frequência na Figura 37) e CSP1 nota-se que o filtro aumentou a energia relativa entre as 2 classes para um mesmo canal, aumentando a atividade discriminativa entre as 2 classes.

Tabela 7: Comparativo da energia proporcional entre classes com e sem o filtro CSP para o experimento *BCI Competition II*.

	<b>Sem Filtro Canal C3</b>	<b>Com Filtro Canal CSP1</b>
$E_p^{(D)}$	0,70	0,78

#### 4.4 RESULTADOS DE CLASSIFICAÇÃO UTILIZANDO A ENERGIA DO SINAL

Os resultados apresentados nessa sessão foram obtidos através do procedimento de correlação cruzada, onde é separado 9/10 dos dados para treinamento e 1/10 para classificação. O procedimento de treinamento e classificação é executado 100 vezes, onde em cada execução os conjuntos de treinamento e teste são selecionados de forma aleatória. A taxa de classificação é dada pela média das 100 execuções e também é apresentado o desvio padrão.

##### 4.4.1 Utilizando Filtros CSP e a energia do sinal de EEG para o experimento proposto

Nesta sessão serão apresentados os resultados obtidos com os classificadores LDA e *Naive Bayes* utilizando a energia do sinal como característica de entrada de acordo com a Eq. (29) e com as janelas definidas na Tabela 4.

Para o experimento proposto o filtro espacial será calculado utilizando 4 canais (C3, C4, P3 e P4) e 2 canais (C3 e C4). O uso dos 4 canais para o cálculo do filtro leva a um novo espaço de canais com 4 canais CSP, onde é testado as 2 colunas do filtro  $W$  (Eq. (12)) relacionados com os maiores autovalores de cada classe, de acordo com a Eq. (18) e também utilizando todo o conjunto de canais CSP, ou seja os 4 canais resultantes. Com o uso de 2 canais para o cálculo são obtidos 2 canais CSP que serão utilizados para o cálculo do classificador. Para o experimento *BCI Competition II* serão utilizados os 3 canais para estimar

o filtro  $W$  e os 2 canais resultantes com a melhor distinção entre classes de acordo com a Eq. (18). Na sessão 4.4.1.3 serão discutidos os resultados obtidos para o classificador LDA e NB para o experimento proposto.

#### 4.4.1.1 Utilizando o classificador LDA

Nas Tabela 8 são apresentadas as taxas de acerto do experimento proposto utilizando apenas 2 canais (C3 e C4) para estimar os coeficientes do filtro  $W$  da Eq. (12). Na Tabela 9 são apresentados os resultados utilizando 4 canais para estimar os filtros, mas somente as 2 colunas de  $W$  que maximizam a atividade discriminativa para cada uma das classes é utilizada e na Tabela 10 são utilizados os 4 filtros CSP resultantes. O conjunto de características utilizado para esta análise é o obtido através da Eq. (29).

Tabela 8: Taxas de acerto média com o classificador LDA utilizando os canais C3 e C4 para estimar  $W$  e os 2 canais CSP resultantes.

Janela	Taxa acerto por Sessão (% - Média $\pm$ Desvio Padrão)			
	S1	S2	S3	S4
$w_1$	64,2 $\pm$ 9,87	63,3 $\pm$ 10,1	69,4 $\pm$ 9,37	60,2 $\pm$ 8,55
$w_2$	64,3 $\pm$ 11,3	62,8 $\pm$ 8,91	67,9 $\pm$ 9,67	64,2 $\pm$ 7,47
$w_3$	66,3 $\pm$ 9,33	64,4 $\pm$ 7,42	69,3 $\pm$ 9,30	63,1 $\pm$ 9,67
$w_4$	64,7 $\pm$ 9,64	62,4 $\pm$ 8,92	70,3 $\pm$ 9,70	65,4 $\pm$ 8,86
$w_5$	64,4 $\pm$ 9,60	64,7 $\pm$ 8,85	70,0 $\pm$ 9,03	64,8 $\pm$ 7,63
$w_6$	63,1 $\pm$ 8,52	65,1 $\pm$ 8,66	69,8 $\pm$ 8,97	64,6 $\pm$ 8,55

Tabela 9: Taxas de acerto média com o classificador LDA utilizando os canais C3, C4, P3 e P4 para estimar  $W$  e utilizando os 2 melhores canais CSP.

Janela	Taxa acerto por Sessão (% - Média $\pm$ Desvio Padrão)			
	S1	S2	S3	S4
$w_1$	65,3 $\pm$ 10,1	64,4 $\pm$ 8,14	61,1 $\pm$ 10,2	61,1 $\pm$ 9,12
$w_2$	62,0 $\pm$ 10,3	64,8 $\pm$ 7,89	62,0 $\pm$ 10,4	58,7 $\pm$ 7,67
$w_3$	62,0 $\pm$ 9,51	65,0 $\pm$ 7,64	61,8 $\pm$ 11,0	58,1 $\pm$ 10,3
$w_4$	62,4 $\pm$ 11,0	63,7 $\pm$ 9,24	63,6 $\pm$ 10,9	58,4 $\pm$ 8,87
$w_5$	61,0 $\pm$ 11,2	64,1 $\pm$ 7,90	61,8 $\pm$ 11,5	59,7 $\pm$ 8,43
$w_6$	61,6 $\pm$ 9,92	65,1 $\pm$ 8,46	62,3 $\pm$ 10,2	58,6 $\pm$ 9,55

Tabela 10: Taxas de acerto média com o classificador LDA utilizando os canais C3, C4, P3 e P4 para estimar  $W$  e utilizando todos canais CSP.

Janela	Taxa acerto por Sessão (% - Média $\pm$ Desvio Padrão)			
	S1	S2	S3	S4
$w_1$	66,8 $\pm$ 10,6	68,5 $\pm$ 8,72	69,0 $\pm$ 10,3	64,8 $\pm$ 9,48
$w_2$	66,5 $\pm$ 10,7	67,0 $\pm$ 8,91	69,9 $\pm$ 10,6	64,5 $\pm$ 7,95
$w_3$	65,2 $\pm$ 9,51	66,8 $\pm$ 8,88	70,6 $\pm$ 10,1	65,1 $\pm$ 7,62
$w_4$	66,7 $\pm$ 9,13	66,4 $\pm$ 8,45	68,5 $\pm$ 9,91	66,8 $\pm$ 8,77
$w_5$	64,1 $\pm$ 10,6	67,8 $\pm$ 8,24	69,6 $\pm$ 9,01	65,4 $\pm$ 8,71
$w_6$	64,9 $\pm$ 9,73	66,4 $\pm$ 8,71	68,1 $\pm$ 11,2	67,4 $\pm$ 9,12

#### 4.4.1.2 Utilizando o classificador *Naive Bayes*

Tabela 11: Taxas de acerto média com o classificador *Naive Bayes* utilizando os canais C3 e C4 para estimar  $W$  e os 2 canais CSP resultantes.

Janela	Taxa acerto por Sessão (% - Média $\pm$ Desvio Padrão)			
	S1	S2	S3	S4
$w_1$	58,7 $\pm$ 10,3	61,8 $\pm$ 9,35	65,2 $\pm$ 10,2	58,9 $\pm$ 8,87
$w_2$	58,6 $\pm$ 10,5	61,3 $\pm$ 8,81	65,3 $\pm$ 10,6	59,5 $\pm$ 7,08
$w_3$	59,6 $\pm$ 10,9	62,6 $\pm$ 8,33	64,5 $\pm$ 9,33	58,8 $\pm$ 9,57
$w_4$	58,6 $\pm$ 10,7	61,3 $\pm$ 8,88	67,1 $\pm$ 10,3	61,8 $\pm$ 8,92
$w_5$	59,0 $\pm$ 10,4	63,6 $\pm$ 8,89	64,5 $\pm$ 9,38	61,6 $\pm$ 7,69
$w_6$	59,1 $\pm$ 9,66	62,1 $\pm$ 9,04	64,4 $\pm$ 9,97	60,0 $\pm$ 8,96

Tabela 12: Taxas de acerto média com o classificador *Naive Bayes* utilizando os canais C3, C4, P3 e P4 para estimar  $W$  e utilizando os 2 melhores canais CSP.

Janela	Taxa acerto por Sessão (% - Média $\pm$ Desvio Padrão)			
	S1	S2	S3	S4
$w_1$	66,2 $\pm$ 10,1	62,6 $\pm$ 7,72	59,7 $\pm$ 9,87	60,1 $\pm$ 8,73
$w_2$	62,5 $\pm$ 10,2	62,0 $\pm$ 7,96	60,6 $\pm$ 11,0	58,8 $\pm$ 8,25
$w_3$	61,7 $\pm$ 9,35	63,1 $\pm$ 7,77	60,9 $\pm$ 11,2	56,4 $\pm$ 8,88
$w_4$	62,4 $\pm$ 11,6	62,2 $\pm$ 8,92	64,7 $\pm$ 9,41	55,7 $\pm$ 9,02
$w_5$	61,0 $\pm$ 10,8	62,6 $\pm$ 8,52	62,1 $\pm$ 10,1	57,1 $\pm$ 9,44
$w_6$	61,3 $\pm$ 10,2	63,4 $\pm$ 9,01	63,0 $\pm$ 10,8	56,5 $\pm$ 9,18

Tabela 13: Taxas de acerto média com o classificador *Naive Bayes* utilizando os canais C3, C4, P3 e P4 para estimar  $W$  e utilizando todos canais CSP.

Janela	Taxa acerto por Sessão (% - Média $\pm$ Desvio Padrão)			
	S1	S2	S3	S4
$w_1$	66,1 $\pm$ 10,5	66,2 $\pm$ 9,32	64,3 $\pm$ 9,76	62,9 $\pm$ 9,34
$w_2$	64,4 $\pm$ 10,7	64,6 $\pm$ 8,86	64,6 $\pm$ 10,6	62,4 $\pm$ 8,15
$w_3$	63,6 $\pm$ 9,93	65,2 $\pm$ 8,40	65,2 $\pm$ 10,6	62,1 $\pm$ 8,55
$w_4$	64,6 $\pm$ 11,4	63,5 $\pm$ 8,50	65,0 $\pm$ 9,87	62,0 $\pm$ 9,85
$w_5$	62,6 $\pm$ 10,5	65,1 $\pm$ 8,87	65,0 $\pm$ 10,4	59,7 $\pm$ 9,32
$w_6$	63,1 $\pm$ 10,1	64,0 $\pm$ 8,94	62,6 $\pm$ 9,55	59,5 $\pm$ 9,34

#### 4.4.1.3 Discussão sobre os resultados utilizando filtros CSP a energia do sinal como característica de entrada para o experimento proposto

De forma geral, não houve grandes variações nas taxas de classificação para janelas de tamanho diferentes. Houve uma variabilidade grande entre sessões, onde a sessão S3 se mostrou com o melhor índice de acerto. Devido também ao alto desvio padrão dos resultados não é possível afirmar se o tamanho da janela tem influência, pois as variações entre os tipos de janela são menores que os desvios padrões para cada janela diferente de uma mesma sessão.

O uso de 2 canais (C3 e C4) para estimar os coeficientes do filtro espacial, com o uso dos 2 canais CSP resultantes, levou a taxas de classificação próximas ao uso de 4 canais (C3, C4, P3 e P4) para estimar o uso dos coeficientes do filtro, com o uso dos 4 canais CSP resultantes. O pior resultado foi utilizando apenas 2 canais CSP a partir do cálculo dos

coeficientes utilizando os 4 canais de EEG. Estes resultados dão um bom indicativo de que pode-se utilizar janelas relativamente pequenas, com cerca de 1s, o que é sempre uma vantagem, pois reduz o tempo de processamento, uma preocupação quando o sistema for testado de forma *on-line*.

Estes resultados indicam que o aumento de canais, para estes dados, degradou a taxa de classificação, principalmente para as sessões S3 e S4. A causa provável desta degradação é o fato que apenas 2 canais, C3 e C4, apresentam alta atividade motora. Os estudos que relatam altos índices de acerto utilizando este método geralmente possuem uma quantidade maior de canais, como por exemplo, em (LEMM, BLANKERTZ, *et al.*, 2005) e em (RAMOSER, MÜLLER-GERKING e PFURTSCHHELLER, 2000) onde foram utilizados 55 e 56 canais respectivamente de um sistema 10-20 modificado. Um maior número de canais aumenta a resolução na área motora, dando mais informação discriminativa entre as classes do que apenas 4 canais, o que provavelmente leva a taxas melhores de classificação. Os altos índices de variabilidade em função dos altos desvios-padrão mostra uma dependência do conjunto de treinamento e de teste para a classificação, o que é característico deste tipo de estudo (BLANKERTZ, TOMIOKA, *et al.*, 2008) (RAMOSER, MÜLLER-GERKING e PFURTSCHHELLER, 2000).

Como forma de comparação é apresentada na Tabela 14 a taxa de acerto utilizando apenas os canais C3 e C4 para a sessão S3. Os resultados foram obtidos substituindo a matriz  $W$  pela matriz identidade. O uso do sinal não filtrado apresentou taxas ligeiramente menores que com o uso do filtro utilizando 2 canais de EEG para cálculo do filtro e 2 canais CSP e com o uso de 4 canais de EEG para estimar e 4 canais CSP como característica de entrada,

porém devido a alta variabilidade dos resultados não é possível afirmar que o uso do filtro melhorou significativamente o resultado da classificação. Um estudo com um número maior de sujeitos (treinados e não treinados), além uma quantidade maior de canais cobrindo a região motora e com a remoção de artefatos é necessário para concluir se o uso do filtro aumenta a taxa de acerto do sinal de EEG.

Tabela 14: Taxas de acerto média utilizando os canais C3 e C4 para classificação.

Janela	Taxa acerto sessão S3 (% - Média $\pm$ Desvio Padrão)	
	LDA	<i>Naive Bayes</i>
$w_1$	67,8 $\pm$ 9,75	63,2 $\pm$ 10,5
$w_2$	68,3 $\pm$ 8,85	63,3 $\pm$ 10,0
$w_3$	68,2 $\pm$ 10,4	63,7 $\pm$ 11,5
$w_4$	67,1 $\pm$ 9,65	63,3 $\pm$ 8,68
$w_5$	68,8 $\pm$ 10,2	63,1 $\pm$ 10,7
$w_6$	66,7 $\pm$ 9,65	61,2 $\pm$ 10,1

#### 4.4.2 Utilizando Filtros CSP e a energia do sinal de EEG para o experimento *BCI*

##### *Competition II*

Nessa sessão são apresentados os resultados de classificação do experimento *BCI Competition II* utilizando as janelas descritas na Tabela 5 para o sinal filtrado através da Eq. (12) e utilizando os 2 canais CSP resultantes como característica de entrada dos classificadores. Na Tabela 15 são apresentados os resultados da classificação utilizando os

filtros CSP para os classificadores LDA e NB e sem o uso do filtro para os mesmos classificadores.

Tabela 15: Taxas de classificação para o experimento *BCI Competition II*.

Janela	Taxa acerto por Sessão (% - Média $\pm$ Desvio Padrão)			
	Com filtro		Sem Filtro	
	LDA	NB	LDA	NB
$w_1$	85,4 $\pm$ 6,28	84,2 $\pm$ 7,06	85,5 $\pm$ 6,16	84,2 $\pm$ 7,22
$w_2$	88,0 $\pm$ 5,89	85,3 $\pm$ 6,50	86,1 $\pm$ 6,74	83,3 $\pm$ 7,19
$w_3$	85,5 $\pm$ 6,01	83,4 $\pm$ 6,30	85,0 $\pm$ 7,32	83,4 $\pm$ 7,82
$w_4$	84,0 $\pm$ 6,19	83,2 $\pm$ 7,44	81,9 $\pm$ 7,18	81,5 $\pm$ 7,39
$w_5$	80,9 $\pm$ 6,74	81,1 $\pm$ 7,12	82,1 $\pm$ 6,78	80,8 $\pm$ 6,84
$w_6$	79,5 $\pm$ 7,78	79,4 $\pm$ 8,30	78,2 $\pm$ 8,55	78,3 $\pm$ 8,06
$w_7$	77,2 $\pm$ 7,93	76,7 $\pm$ 7,76	78,8 $\pm$ 7,08	77,5 $\pm$ 7,56

De forma semelhante ao experimento proposto o uso do filtro não aumentou a taxa de classificação. Novamente o classificador LDA demonstrou ter taxas de classificação superiores ao classificador NB. Porém essa análise somente poderá ser confirmada através de uma análise estatística mais robusta, como as metodologias utilizadas na área de Projeto de Experimentos para todos os experimentos (esta tarefa foi deixada como proposta de trabalho futuro). O uso de pequenas janelas degradou de forma significativa a classificação, demonstrando que uma quantidade significativa de dados é necessária para a estimação da energia. Cabe ressaltar que o valor esperado da energia do sinal se aproxima mais do valor

real com o aumento do número de amostras para sua estimação (BENDAT e PIERSOL, 1986), portanto janelas menores apresentam uma variabilidade maior de valores, levando a uma degradação da taxa de classificação. O uso de taxas de amostragens maiores podem levar uma melhor caracterização da energia do sinal em janelas menores.

#### **4.4.3 Discussão dos resultados dos classificadores utilizando a energia como característica de entrada para os 2 experimentos**

A alta diferença entre as taxas de classificação do experimento proposto se deve principalmente:

a) Diferença entre as metodologias utilizadas

No experimento *BCI Competition II* o usuário possui uma realimentação para verificar de forma *online* se a estratégia mental está adequada, o que não ocorre no experimento proposto. O uso de uma realimentação permite que o usuário perceba em tempo real se a estratégia mental utilizada está adequada, permitindo que ele altere, modulando os ritmos sensório-motores de forma significativa. Outra grande diferença na metodologia foi o tipo de ação do usuário, onde no experimento proposto ele deveria movimentar a mão e pressionar um botão e no experimento *BCI Competition II* o usuário deve apenas imaginar o movimento.

b) Ambiente e equipamentos

No experimento *BCI Competition II* a sessão foi realizada em um ambiente controlado (ruído, temperatura, luminosidade) e foram utilizados equipamentos comerciais certificados. No experimento proposto as sessões foram realizadas em um ambiente não controlado. Este tipo de estudo em ambientes não controlados deve ser feitos, pois aproximam mais os dados a

aplicações reais. Além disso, o equipamento utilizado para a aquisição dos dados era um protótipo não comercial desenvolvido dentro do laboratório de pesquisa.

#### **4.4.4 Utilizando componentes espectrais como característica de entrada**

Nesta sessão são apresentados os resultados de classificação utilizando as componentes espectrais para o experimento proposto e para o experimento *BCI Competition II*. As componentes espectrais foram extraídas utilizando a Eq. (11) utilizando a janela descrita na sessão 3.3.2.2. As componentes selecionadas de acordo com os maiores valores obtidos pela Eq. (28) são inseridas dentro do vetor de características dado pela Eq. (30). Como forma de comparação serão utilizadas 2, 4 e 10 componentes espectrais com o uso de 2 canais (C3 e C4) e 4 canais (C3, C4, P3 e P4) para o experimento proposto. Para o experimento *BCI Competition II* foram extraídas 2, 4 e 10 componentes para os canais C3 e C4 apenas. Cabe salientar que a quantidade de características é dada pelo produto da quantidade de componentes espectrais pela quantidade de canais. Nas sessões 4.4.4.1 e 4.4.4.2 são apresentados os resultados e discussões para o experimento proposto e para o experimento *BCI Competition II*.

##### **4.4.4.1 Experimento Proposto**

Na Tabela 16 e na Tabela 17 são apresentados os resultados para as 4 sessões utilizando 2 canais e 4 canais respectivamente.

Tabela 16: Taxas de acerto média utilizando componentes espectrais de 2 canais (C3 e C4) para o experimento proposto.

<b>Componentes Espectrais</b>		
<b>2</b>	<b>4</b>	<b>10</b>

Sessão	LDA	NB	LDA	NB	LDA	NB
<b>S1</b>	62,5 ± 16,6	62,9 ± 17,5	62,5 ± 13,3	65,4 ± 15,3	61,2 ± 16,6	63,5 ± 16,3
<b>S2</b>	60,7 ± 14,9	52,8 ± 12,4	61,6 ± 13,6	55,7 ± 13,9	61,9 ± 14,5	56,1 ± 14,5
<b>S3</b>	60,9 ± 16,0	57,3 ± 15,9	60,6 ± 15,2	56,8 ± 15,2	60,6 ± 13,5	60,3 ± 14,3
<b>S4</b>	62,4 ± 14,0	59,4 ± 13,1	60,9 ± 11,8	58,8 ± 11,9	68,4 ± 11,8	65,4 ± 11,6

Tabela 17: Taxas de acerto média utilizando componentes espectrais de 4 canais (C3, C4, P3 e P4) para o experimento proposto.

Sessão	Componentes Espectrais					
	2		4		10	
	LDA	NB	LDA	NB	LDA	NB
<b>S1</b>	62,6 ± 16,2	64,9 ± 18,4	59,6 ± 16,1	68,4 ± 17,3	54,6 ± 17,2	65,8 ± 13,5
<b>S2</b>	62,6 ± 13,9	50,7 ± 13,4	64,3 ± 12,5	54,1 ± 14,9	59,3 ± 13,6	51,7 ± 14,8
<b>S3</b>	56,1 ± 15,2	55,7 ± 13,3	52,7 ± 15,9	53,8 ± 16,1	45,9 ± 15,6	51,1 ± 15,9
<b>S4</b>	58,9 ± 12,4	51,0 ± 14,1	60,1 ± 12,6	55,4 ± 13,0	60,8 ± 12,7	54,7 ± 11,9

Os resultados obtidos para o experimento proposto utilizando as componentes espectrais demonstraram uma taxa de acerto menor em média do que o uso da energia do sinal com o filtro CSP. Além disso a variabilidade (desvio-padrão) foi maior, demonstrando uma maior irregularidade nas taxas de classificação. Entre sessões o classificador LDA, da mesma forma que com o uso da energia com característica, manteve uma taxa mais alta de acerto, com exceção da sessão S1 utilizando 4 canais de EEG.

A quantidade de canais influenciou principalmente nas taxas de acerto do classificador NB, muito provavelmente pelo fato dos sinais dos canais manterem uma alta dependência, o

que viola o princípio do classificador NB, que considera as características independentes entre si. A quantidade de componentes espectrais não influenciou de forma significativa as taxas de classificação, o que é interessante para uma aplicação online, onde a quantidade de características influencia diretamente na eficiência computacional. A alta variabilidade dos dados mostra que o uso desse tipo de característica, para esse experimento, deixa o classificador muito dependente do conjunto de treinamento utilizado, não generalizando de forma satisfatória a classificação dos dados.

#### 4.4.4.2 Utilizando componentes espectrais para o experimento BCI

A Tabela 18 apresenta os resultados obtidos para o experimento *BCI Competition II* para a classificação utilizando componentes espectrais como característica de entrada:

Tabela 18: Taxas de acerto utilizando componentes espectrais para o experimento *BCI Competition II*.

Componentes Espectrais	Classificadores	
	LDA	NB
2	86,0 ± 6,49	84,8 ± 6,65
4	86,8 ± 6,12	80,0 ± 7,72
10	85,0 ± 6,01	80,4 ± 6,99

Os resultados dos classificadores para o experimento *BCI Competition II* demonstraram taxas de acerto próximas as encontradas com o uso da energia do sinal e com o uso dos filtros CSP, assim como a sua variabilidade. Estes resultados, em comparação aos resultados obtidos para o experimento proposto, indicam que para utilizar componentes espectrais como característica de entrada é necessário o uso de sinais “bem comportados” com

um comportamento mais estacionário, pois geralmente é necessário o uso de janelas maiores para uma boa resolução do espectro de frequência e nesses casos um comportamento não estacionário não é desejável. Observe que comparando os índices de lateralização ao longo do tempo, mostrados na Figura 27 e na Figura 31, o sujeito do experimento proposto consegue manter uma lateralização do movimento durante aproximadamente 1s, entre os tempos  $t = 4$  e  $t = 5$ , enquanto que o usuário do experimento *BCI Competition II* mantém um índice de lateralização relativamente alto durante aproximadamente 4s, entre  $t = 4s$  e  $t = 8s$ , mostrando que essas janelas dentro desse período tendem a manter um comportamento quase estacionário. O problema do uso de janelas muito pequenas é que com a perda de resolução em frequência, começa a se perder informação dentro do ritmo sensorio motor, pois apresenta atividade em bandas de frequência estreitas.

Os resultados do experimento *BCI Competition II* demonstram que o uso de componentes espectrais como características se assemelham ao uso da energia do sinal filtrado por um filtro passa-banda, como o sinal utilizado neste trabalho, o que está de acordo com a teoria (BENDAT e PIERSOL, 1986).

## 5 CONCLUSÕES

Dada as condições deste trabalho, foi possível observar, que utilizando sinais de EEG do sujeito em estudo, taxas de acerto que indicam que o uso do ERD e ERS podem ser adequados para classificação de movimento de mãos. Foi possível confirmar o efeito fisiológico do movimento de mãos no cérebro através de medições não invasivas utilizando 8 canais de EEG para o sujeito em estudo e também na base de dados *BCI Competition II*. O usuário do experimento em estudo apresentou atividade lateralizada ao movimento dentro do ritmo  $\mu$  para os canais localizados nas regiões central e parietal do córtex. O usuário também apresentou atividade para os canais centrais e parietais dentro do ritmo  $\beta$ , porém não apresentava atividade discriminativa relevante dentro desta faixa.

O uso do filtro espacial não aumentou significativamente a taxa de acerto de nenhum classificador. Isso se deve, provavelmente, pelo fato de que não havia uma boa resolução espacial dos sinais adquiridos, sendo que apenas 8 canais estavam disponíveis e desses 8 canais apenas 4 apresentavam atividade relacionada aos ritmos sensório-motor. Além disso, essa técnica é altamente sensível a artefatos para a estimação dos filtros e os sinais não foram tratados de forma a remover os artefatos. Mais estudos com o uso de toucas com uma maior resolução de eletrodos deve ser feita para validar a teoria do filtro CSP.

O uso da energia dos sinal, filtrado ou não pelo filtro CSP, mostrou um bom comportamento nos classificadores, sendo que foi possível manter as taxas de acerto mesmo com janelas pequenas de 1s. O uso das componentes espectrais se mostrou bastante sensível a qualidade do sinal utilizado, sendo portanto uma escolha secundária para uso de característica de classificação. Porém o uso do periodograma se mostrou uma ferramenta útil para

demonstrar quais faixas de frequências são mais relevantes para a classificação. O uso dos dados obtidos pelo periodograma, combinado com outras técnicas de pré processamento, tal qual a análise de componentes principais, permite o desenvolvimento de algoritmos para seleção automático de características.

Os resultados dos classificadores para a base *BCI Competition II* ficaram dentro dos valores encontrados na literatura para esta base de dados (BCI Competition II, 2003). As taxas encontradas para o experimento proposto foram mais baixas devido principalmente a falta de treinamento do usuário e a realimentação durante o experimento, uso de equipamento não certificado e ensaios em um ambiente não controlado. Os resultados das análises demonstram a necessidade do uso de uma realimentação durante o experimento, como o utilizado no experimento *BCI Competition II*, de forma a aumentar a atividade discriminativa entre as duas classes de movimento.

Os classificadores mostraram desempenho semelhantes, com o classificador LDA sempre mantendo, em geral, taxas maiores que o classificador NB. Não é possível confirmar se o uso do classificador LDA é de fato mais robusto que o NB devido a alta variabilidade dos resultados, sendo necessário realizar uma análise estatística mais robusta de todas a base de dados gerada e não a simples comparação múltipla de médias. Além disso, é essencial a criação de um grupo de controle (com uma quantidade relevante de indivíduos treinados) e um grupo com um quantidade relevante de indivíduos não treinados. Com um número maior de ensaios, sujeitos e com um projeto de experimentos robusto, será possível avaliar os resultados encontrados.

## 6 PROPOSTA DE TRABALHOS FUTUROS

Como sugestão para trabalhos futuros fica o desenvolvimento de uma plataforma experimental com realimentação para o usuário e com o uso de equipamentos certificados para uma melhor qualidade do sinal. Também fica como sugestão utilizar os canais frontais Fp1 e Fp2 para remoção de artefatos utilizando técnicas como a análise de componentes independentes (ICA de *Independent Component Analysis*). Também a implementação de algoritmos para seleção das características, tal como o algoritmo DSLVQ (*Distinction Sensitive Learning Vector Quantization*) que faz a busca pelas componentes específicas de cada usuário. Um número maior de usuários é uma proposta que deve ser realizada a fim de generalizar os resultados encontrados utilizando as técnicas apresentadas.

O uso de uma touca do sistema 10-20 adaptado, com uma quantidade maior de eletrodos cobrindo a região central do córtex, cobrindo assim uma quantidade maior de canais com atividade sensório-motora relevante para o desenvolvimento do filtro CSP. Também deve ser implementando um sistema de análise de experimentos para verificar a relevância das diferentes características utilizadas para classificação.

Por fim a implementação de um sistema *online* de forma assíncrona, ou seja, que o sistema funcione apenas com a intenção do usuário, sem um sincronismo com uma trilha. Para isso é necessário o desenvolvimento de uma plataforma de *hardware* capaz de fazer processamento em tempo real.

## REFERÊNCIAS

- BASHASHATI, A. et al. A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. **Journal of Neural Engineering**, Bristol, v. 4, n. 2, p.32-57, Mar. 2007.
- BCI Competition II. 2003. Disponível em: <<http://www.bbc.de/competition/ii/>>. Acesso em: 20 Ago. 2012.
- BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. **Neuroscience: Exploring The Brain**. 3rd. ed. Philadelphia: Lippincott Williams & Wilkins, 2007.
- BENDAT, J. S.; PIERSOL, A. G. **Random Data: Analysis and Measurement Procedures**. 2nd. ed. New York: John Wiley & Sons, 1986.
- BHATTACHARYYA, S. et al. Performance Analysis of Left/Right Hand Movement Classification from EEG Signal by Intelligent Algorithms. In: SYMPOSIUM ON COMPUTATIONAL INTELLIGENCE, COGNITIVE ALGORITHMS, MIND, AND BRAIN, 2011, Paris. **Proceedings ...** New York: IEEE, 2011. p. 1-8.
- BLANKERTZ, B. et al. Optimizing Spatial Filters for Robust EEG Single-Trial Analysis. **IEEE Signal Processing Magazine**, New York, v. 25, n. 1, p. 41-56, Jan. 2008.
- CARRA, Michel. **Desenvolvimento de uma interface cérebro computador baseada em ritmos sensório motores para controle de dispositivos**. 2012.195 f. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal do Rio Grande do Sul, Porto Alegre, Mar. 2012.
- CARRA, M.; BALBINOT, A. Development of a brain-computer interface system based on sensorimotor rhythms. In: ISSNIP BIOSIGNALS AND BIROBOTICS CONFERENCE, 2012, Manaus. **Proceedings ...** New York: IEEE. 2012. p. 21-26.
- DORNHEGE, G. et al. **Toward Brain-Computer Interfacing**. Massachusetts: Bradford Books, 2007.
- DOYLE, L. M. F.; YARROW, K.; BROWN, P. Lateralization of event-related beta desynchronization in the EEG during pre-cued reaction time tasks. **Clinical Neurophysiology**, Amsterdam, n. 116, p. 1879-1888, Aug. 2005.
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2nd. ed. New York: John Wiley & Sons, 2000.

FAVIEIRO, G. W.; BALBINOT, A. Adaptive neuro-fuzzy logic analysis based on myoelectric signals for multifunction prosthesis control. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 33., 2011, Boston. **Proceedings ...** New York: IEEE, 2011. p. 7888-7891.

FAVIEIRO, G. W.; BALBINOT, A. Proposal of a Neuro Fuzzy System for Myoelectric Signal Analysis from Hand-Arm Segment. In: NAIK, G. R. **Computational Intelligence in Electromyography Analysis - A Perspective on Current Applications and Future Challenges**. New York : InTech, 2012. Cap. 14, p. 337-362.

FUKUNAGA, K. **Introduction to Statistical Pattern Recognition**. New York: Academic Press, 1990.

GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. Brain-Computer Interfaces: A Gentle Introduction. In: BERNHARD GRAIMANN, B. A. G. P. **Brain-Computer Interfaces: Revolutionizing Human-Computer Interaction**. 1. ed. Heidelberg: Springer, 2011. Cap. 1, p. 1-28.

HERMAN, P. et al. Comparative Analysis of Spectral Approaches to Feature Extraction for EEG-Based Motor Imagery Classification. **IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING**, New York, v. 16, n. 4, p. 317-326, Aug. 2008.

JASPER, H. The ten-twenty electrode system of the International Federation. **Electroencephalography and Clinical Neurophysiology**, Amsterdam, v. 10, p. 371-375, 1958.

KROPOTOV, J. D. **Quantitative EEG, Event-Related Potentials and Neurotherapy**. 1st. ed., San Diego: Elsevier, 2009.

LEMM, S. et al. Spatio-Spectral Filters for Improving the Classification of Single Trial EEG. **IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING**, New York, v. 52, n. 9, p. 1541-1548, Sept. 2005.

LOTTE, F. et al. A review of classification algorithms for EEG-based brain-computer interfaces. **Journal of Neural Engineering**, Bristol, p.1-13, Jan. 2007.

MING-AI, L. et al. An Improved CSP Algorithm and Application in Motor Imagery Recognition. In: INTERNATIONAL CONFERENCE ON NATURAL COMPUTATION, 5., 2009, Tianjin. **Proceedings ...** Los Alamitos: IEEE Computer Society, 2009. p. 114-117.

MITCHEL, T. **Machine Learning** Columbus: McGraw-Hill, 1997.

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

NUNEZ, P. L. Physiological Foundations of Quantitative EEG Analysis. In: TONG, S.; THAKOR, N. V. **Quantitative EEG analysis methods and clinical applications**. 1st. ed. Norwood: Artech House, 2009. Cap. 1, p. 1-22.

OPPENHEIM, A. V.; SCHAEFER, R. W.; BUCK, J. R. **Discrete-time Signal Processing**. 2nd. ed. New Jersey: Prentice Hall, 1998.

PFURTSCHELLER, G. et al. EEG-based discrimination between imagination of right and left hand movement. **Electroencephalography and clinical Neurophysiology**, Amsterdam, n. 103, p. 642-651, 1997.

PFURTSCHELLER, G.; NEUPER, C. Event-related synchronization of mu rhythm in the EEG over the cortical hand area in man. **Neuroscience Letters**, Amsterdam, v. 174, p. 93-96, June 1994.

PFURTSCHELLER, G.; SILVA, F. H. L. D. Event-related EEG/MEG synchronization and desynchronization: basic principles. **Clinical Neurophysiology**, Amsterdam, p. 1842-1857, May 1999.

RAMOSER, H.; MÜLLER-GERKING, J.; PFURTSCHELLER, G. Optimal Spatial Filtering of Single Trial EEG During Imagined Hand Movement. **IEEE Transactions on Rehabilitation Engineering**, New York, v. 8, n. 4, p. 441-446, Dec. 2000.

SANEI, S.; CHAMBERS, J. A. **EEG Signal Processing**. Chichester: John Wiley & Sons, 2007.

SOBOTTA, J. **Atlas de Anatomia Humana**. 22. ed. Rio de Janeiro: Guanabara Koogan, 2006.

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

TAN, D.; NIJHOLT, A. Brain-Computer Interfaces and Human-Computer Interaction. In: TAN, D.; NIJHOLT, A. **Brain-Computer Interfaces**. Londres: Springer, 2010. p. 3-19.

TORTORA, G. J. **Corpo Humano: Fundamentos de Anatomia e Fisiologia**. 4. ed. Porto Alegre: Artmed, 2000.

WELCH, P. D. The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms. **IEEE**

**Transactions on Audio and Electroacoustics**, New York, v. AU-15, n. 2, p. 70-73, June 1967.

WOLPAW, J. R. et al. Brain–computer interfaces for communication and control. **Clinical Neurophysiology**, Amsterdam, p. 767-791, Mar. 2002.

**Anexo A – Gráficos de Energia para as sessões S1, S2 e S4.**

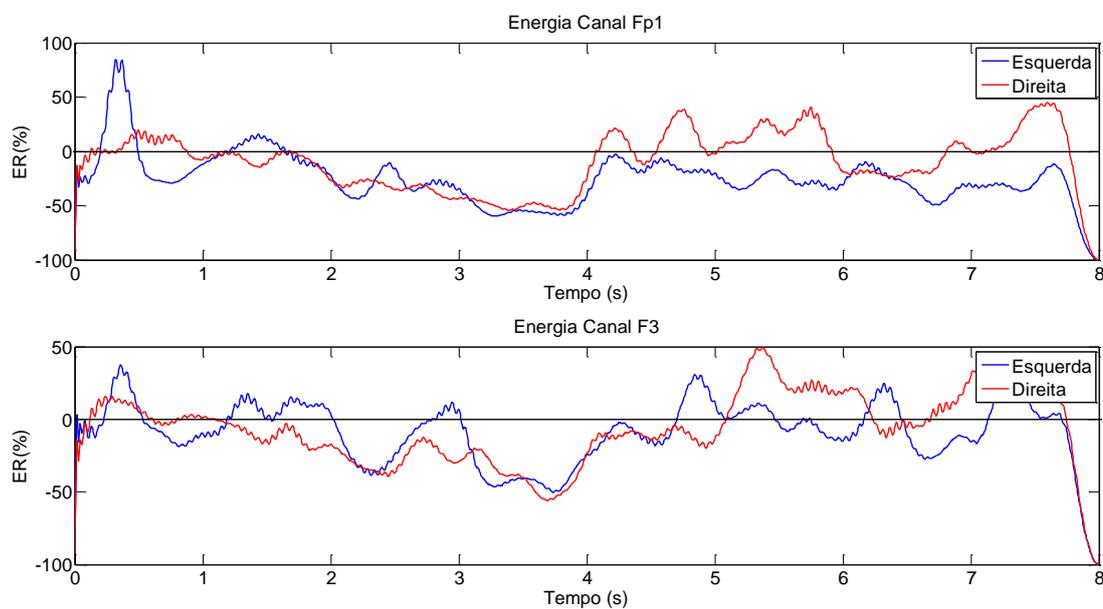


Figura 44: Energia média relativa dos canais Fp1 e F3 durante a sessão S1 (banda  $\mu$ ).

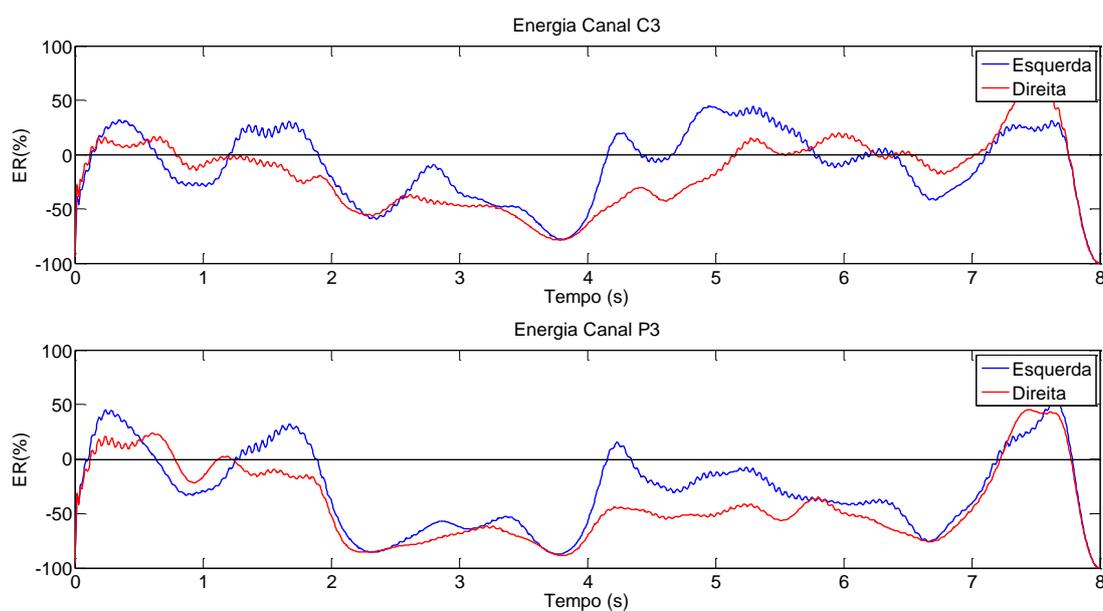


Figura 45: Energia média relativa dos canais C3 e P3 durante a sessão S1 (banda  $\mu$ ).

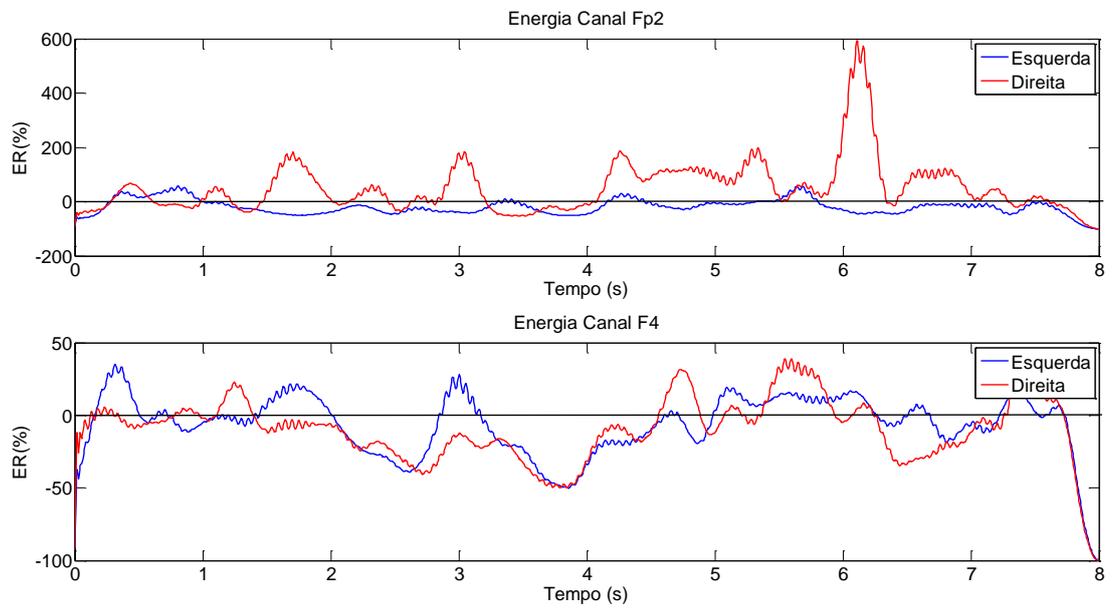


Figura 46: Energia média relativa dos canais Fp2 e F4 durante a sessão S1 (banda  $\mu$ ).

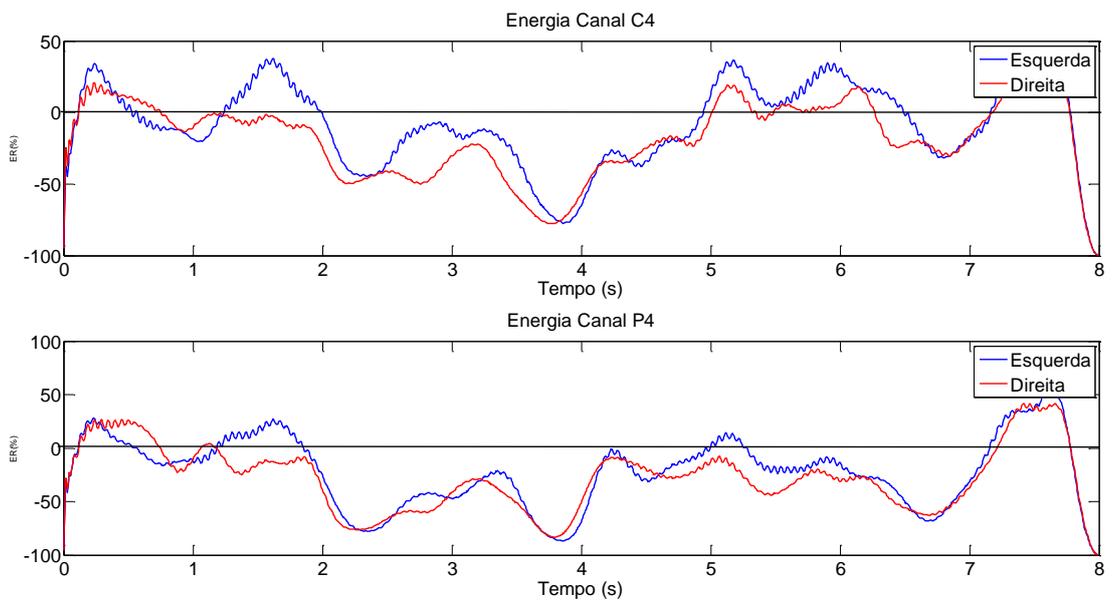


Figura 47: Energia média relativa dos canais C4 e P4 durante a sessão S1 (banda  $\mu$ ).

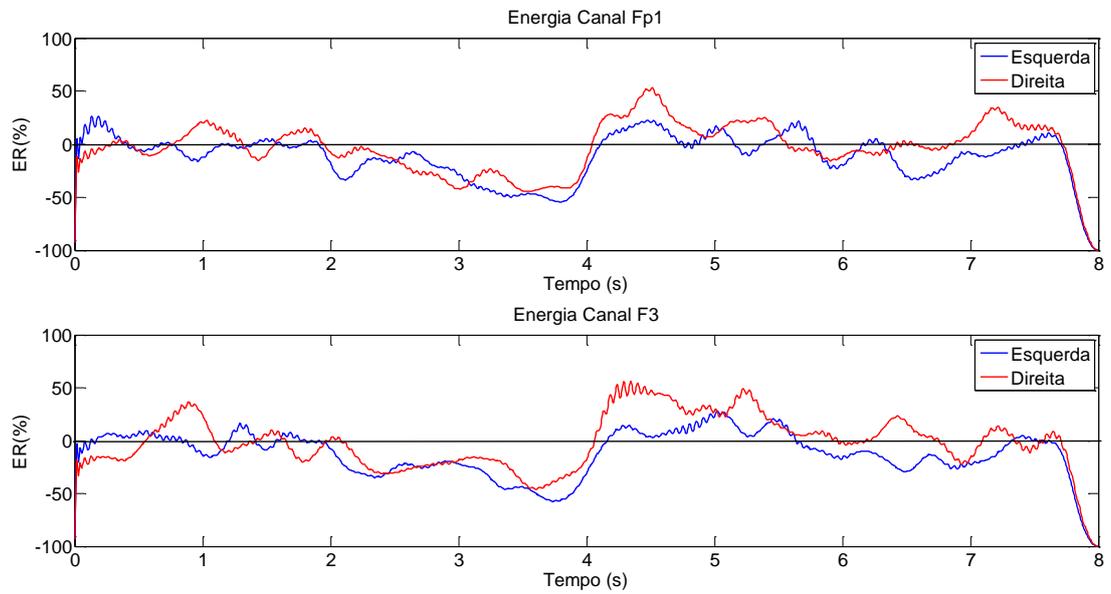


Figura 48: Energia média relativa dos canais Fp1 e F3 durante a sessão S2 (banda  $\mu$ ).

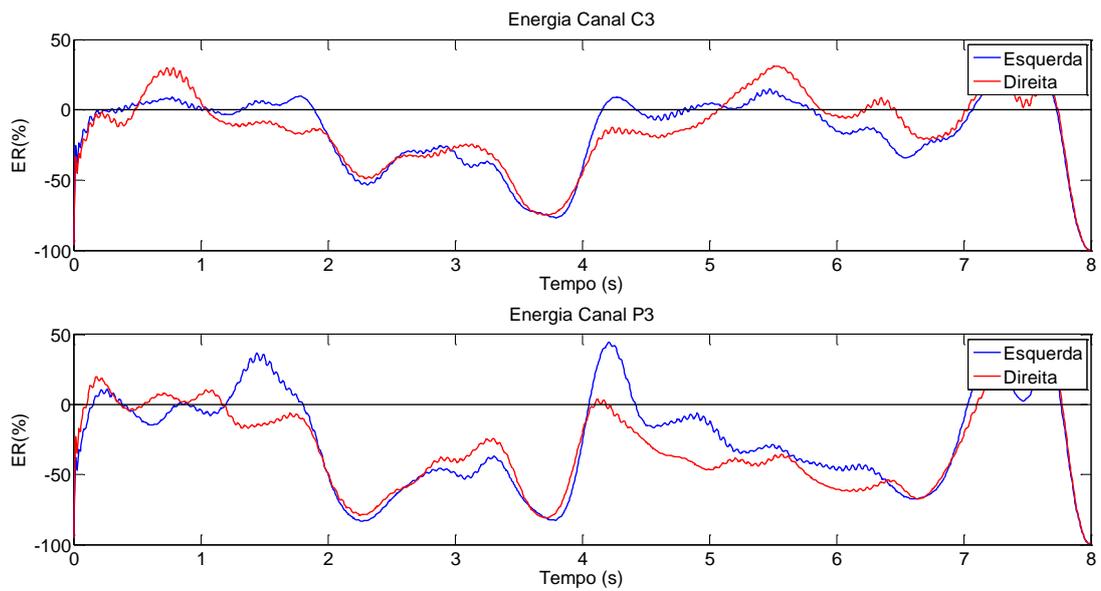


Figura 49: Energia média relativa dos canais C3 e P3 durante a sessão S2 (banda  $\mu$ ).

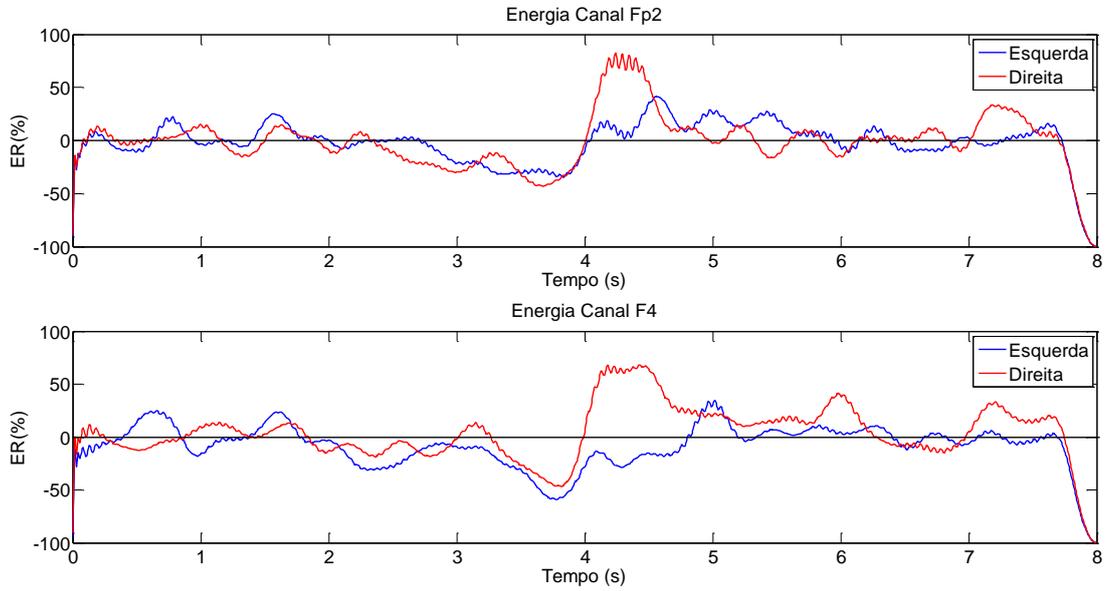


Figura 50: Energia média relativa dos canais Fp2 e F4 durante a sessão S2 (banda  $\mu$ ).

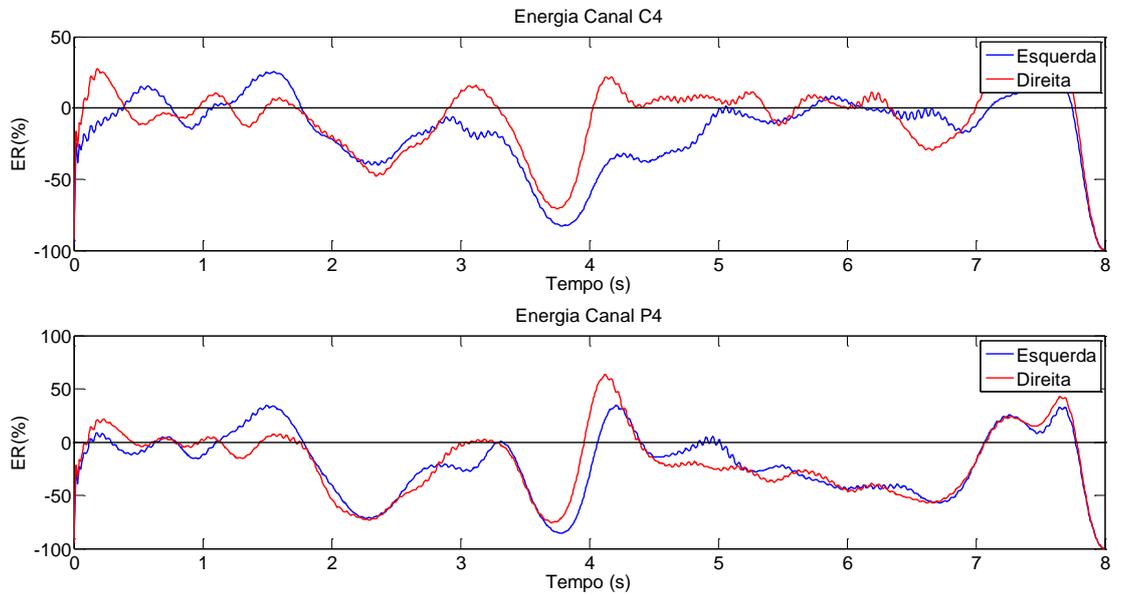


Figura 51: Energia média relativa dos canais C4 e P4 durante a sessão S2 (banda  $\mu$ ).

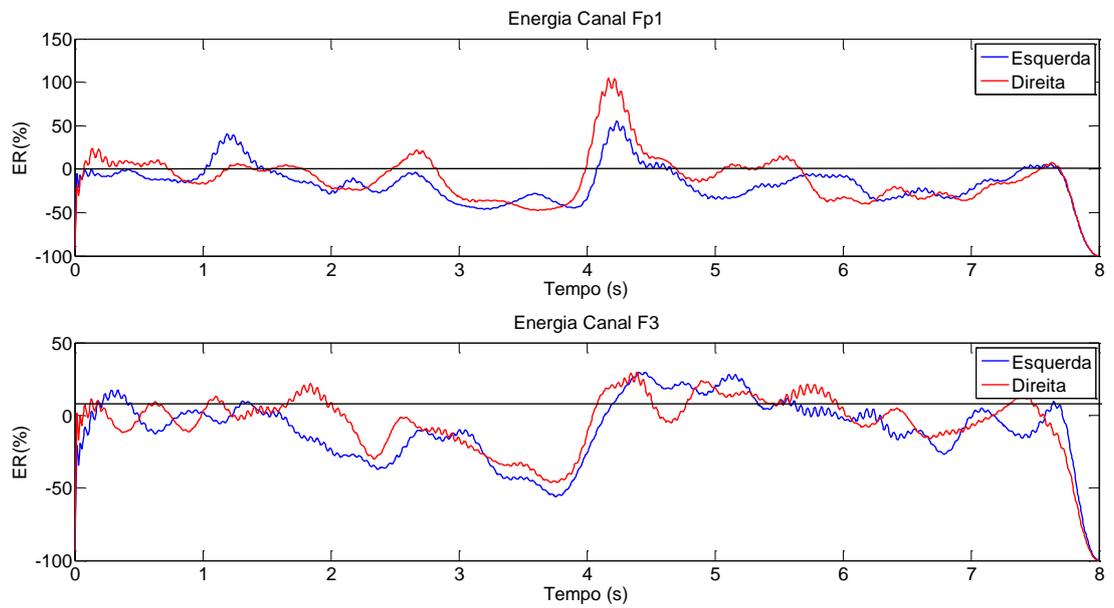


Figura 52: Energia média relativa dos canais Fp1 e F3 durante a sessão S4 (banda  $\mu$ ).

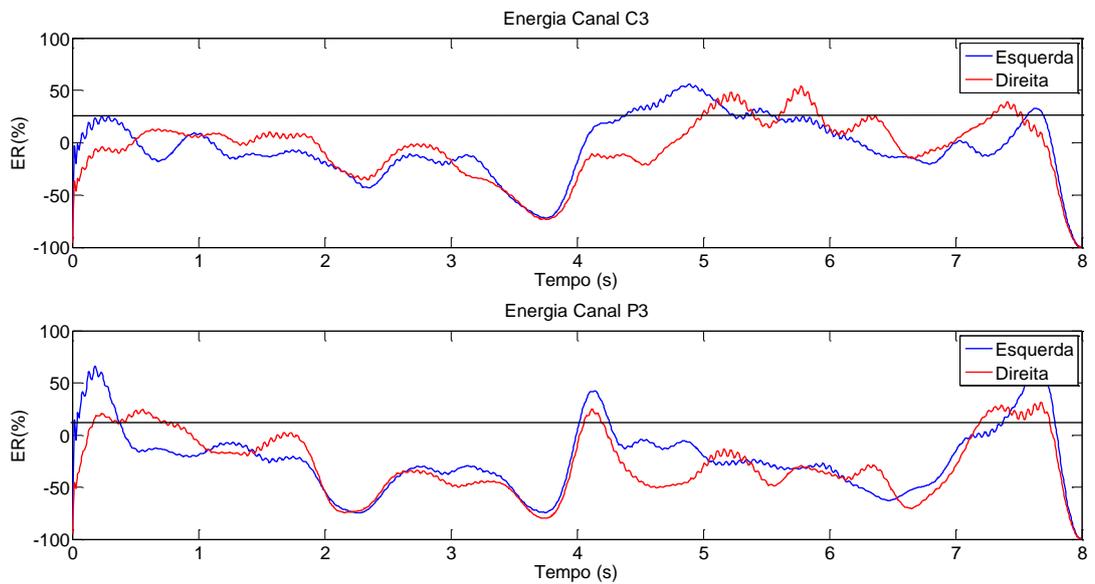


Figura 53: Energia média relativa dos canais C3 e P3 durante a sessão S4 (banda  $\mu$ ).

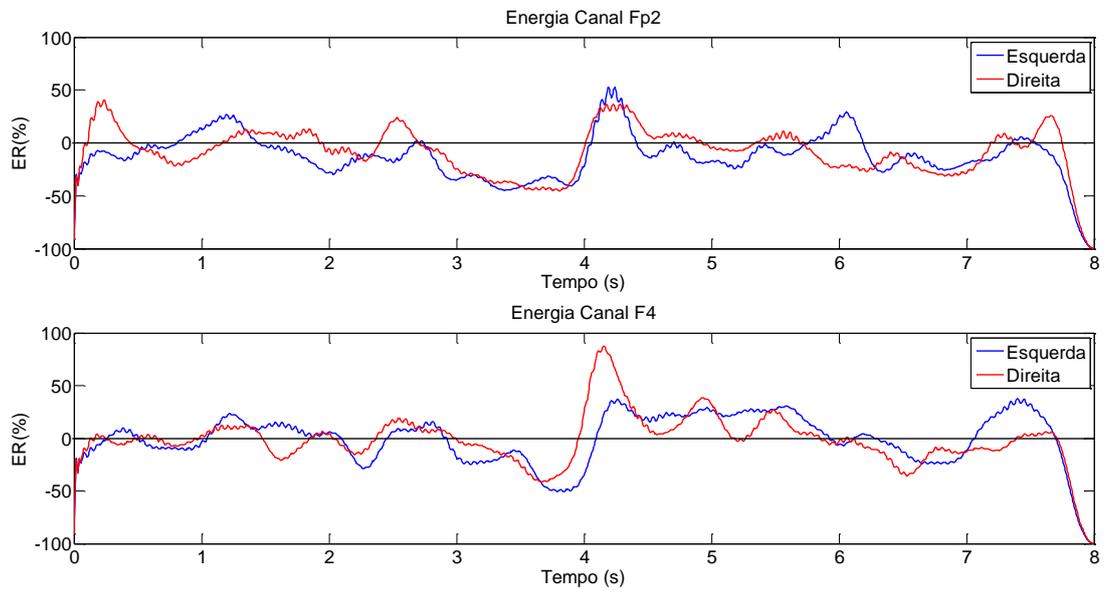


Figura 54: Energia média relativa dos canais Fp2 e F4 durante a sessão S4 (banda  $\mu$ ).

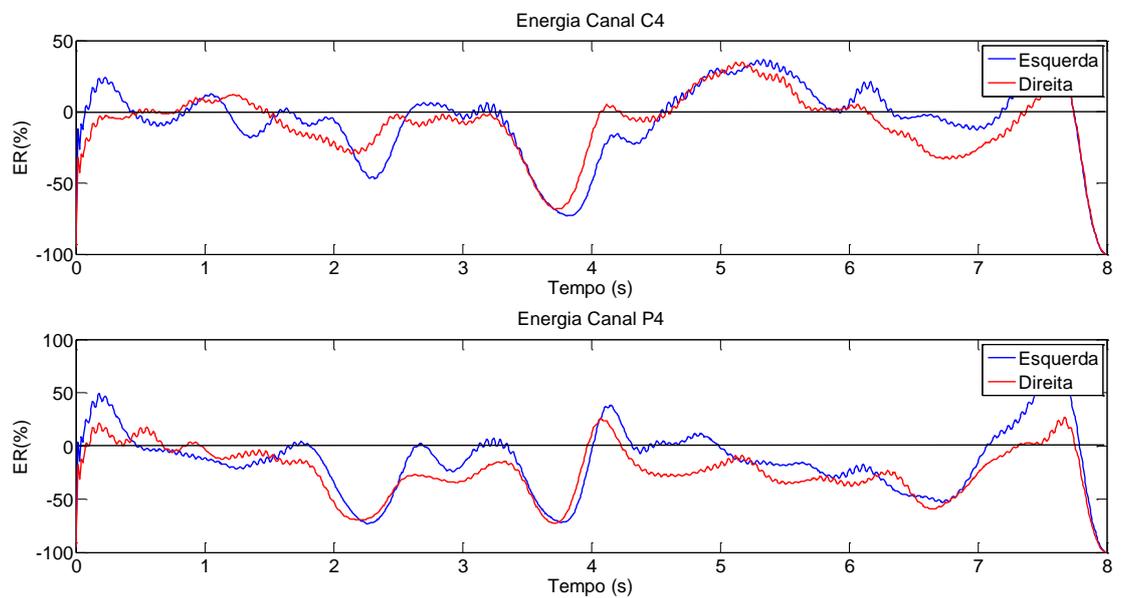


Figura 55: Energia média relativa dos canais C4 e P4 durante a sessão S4 (banda  $\mu$ ).