

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

VINÍCIUS STOCK DA SILVA

**CLASSIFICAÇÃO DE MOVIMENTOS IMAGINÁRIOS ATRAVÉS DE REDES
BAYESIANAS EM SISTEMA BASEADO EM TOUCA EMOTIV**

Porto Alegre
2015

VINÍCIUS STOCK DA SILVA

**CLASSIFICAÇÃO DE MOVIMENTOS IMAGINÁRIOS ATRAVÉS DE REDES
BAYESIANAS EM SISTEMA BASEADO EM TOUCA EMOTIV**

Trabalho de conclusão de curso
apresentado como requisito parcial para
obtenção do grau de Bacharel em Engenharia
Elétrica na Universidade Federal do Rio
Grande do Sul.

ORIENTADOR: Prof. Dr. Eng. Alexandre
Balbinot

Porto Alegre

2015

CIP - Catalogação na Publicação

de Nardi Stock da Silva, Vinícius
Classificação de movimentos imaginários através de
Redes Bayesianas em sistema baseado em touca EMOTIV
/ Vinícius de Nardi Stock da Silva. -- 2015.
114 f.

Orientador: Alexandre Balbinot.

Trabalho de conclusão de curso (Graduação) --
Universidade Federal do Rio Grande do Sul, Escola de
Engenharia, Curso de Engenharia Elétrica, Porto
Alegre, BR-RS, 2015.

1. Brain-Computer Interface. 2. Event Related
Desynchronization. 3. Common Spatial Pattern. 4.
Redes Bayesianas. 5. Naive Bayes. I. Balbinot,
Alexandre, orient. II. Título.

VINÍCIUS STOCK DA SILVA

**CLASSIFICAÇÃO DE MOVIMENTOS IMAGINÁRIOS ATRAVÉS DE REDES
BAYESIANAS EM SISTEMA BASEADO EM TOUCA EMOTIV**

Este trabalho de CC foi analisado e julgado adequado para a obtenção do grau de Bacharel em Engenharia Elétrica e aprovado em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Departamento de Engenharia Elétrica da Universidade Federal do Rio Grande do Sul.

Prof. Dr. Eng. Alexandre Balbinot

Prof. Dr. Eng. Ály Ferreira Flores Filho

Aprovado em: ____/____/____

BANCA EXAMINADORA

Prof. Dr. Eng. Alexandre Balbinot – U.F.R.G.S. _____

Prof^a. Dr^a. Eng^a. Leia Bagesteiro – U.F.R.G.S. _____

Prof. Me. Eng. Juliano Machado – IFSUL _____

AGRADECIMENTOS

Ao Prof. Dr. Eng. Alexandre Balbinot, pelo tempo e esforço compartilhados na orientação deste trabalho.

Aos voluntários que participaram neste estudo, André Pigatto e Sandro Buzacchi, pela dedicação aos ensaios experimentais realizados.

Aos colegas do Programa de Graduação em Engenharia Elétrica, pela ajuda compartilhada, não apenas durante a confecção deste trabalho, mas durante a totalidade do curso.

Aos colegas do IEE (laboratório de instrumentação eletroeletrônica) pelo auxílio nos ensaios experimentais.

À minha família e amigos, pelo apoio incondicional durante o curso, e compreensão durante os momentos de ausência.

RESUMO

Interfaces cérebro computador (BCI) são um meio de comunicação e controle, para tecnologia assistiva, que não necessitam de atuação motora do usuário. O objetivo deste trabalho é classificar duas classes de movimentos imaginários, sendo estes mãos esquerda e direita, e realizar uma análise preliminar em relação aos resultados de outros estudos da área. O processamento de sinais de eletroencefalografia (EEG) é realizado através de filtros *Common Spatial Pattern* e o classificador utilizado é o *Naive Bayes*. A aquisição dos sinais de EEG é realizada com a touca de eletrodos EMOTIV, em dois voluntários, para dois modelos de trilhas diferentes. Os canais selecionados são os FC5, FC6, P7 e P8 do sistema 10-20, e uma discussão sobre as diferenças do uso dos canais C3, C4, P3 e P4 é realizada. O banco de dados número 3 do BCI *Competition II* também é analisado pelo sistema desenvolvido. Os resultados máximos de classificação para o experimento proposto e para o banco de dados do BCI *Competition* foram, respectivamente, de 79 % e 85 %. A conclusão do estudo é que as posições de eletrodos adotadas podem ser usadas para sistemas BCI de duas classes, com taxas de acerto satisfatórias.

Palavras-chaves: *Brain-Computer Interface. Event related desynchronization. Common Spatial Pattern. Eletroencefalografia. Redes Bayesianas. Naive Bayes.*

ABSTRACT

Brain-computer interfaces (BCI) provide means of communications and control, in assistive technology, which do not require motor activity from the user. The goal of this study is to promote classification of two types of imaginary movement, left and right hands, and to perform a preliminary analysis with respect to results obtained by other experiments in this field. Processing of the electroencephalography (EEG) signals is done applying Common Spatial Pattern filters and the chosen classifier is the Naive Bayes. The EMOTIV electrodes cap is used for EEG acquisition, in two test subjects, for two distinct trial formats. The channels picked are FC5, FC6, P7 and P8 of the 10-20 system, and a discussion about the differences of using C3, C4, P3 and P4 positions is proposed. Dataset 3 of the BCI Competition II is also analyzed for the implemented system. The maximum classification results for the proposed experiment and for the BCI Competition dataset were, respectively, 79 % and 85 %. The conclusion of this study is that the picked positions for electrodes can be may be applied for BCI systems with satisfactory classification rates.

Keywords: Brain-Computer Interface. Event related desynchronization. Common Spatial Pattern. Electroencephalography. Bayesian Networks. Naive Bayes.

LISTA DE FIGURAS

Figura 1: Localização dos giros e lobos em vista lateral.	14
Figura 2: Áreas do cérebro por funcionalidade.....	15
Figura 3: Regiões do córtex responsáveis por cada membro.....	16
Figura 4: Posicionamento dos eletrodos pelo sistema 10-20.	17
Figura 5: Posicionamento dos eletrodos para o Sistema 10-20 com 75 eletrodos.....	18
Figura 6: Posicionamento dos eletrodos para a touca EMOTIV.	18
Figura 7: Etapas do cálculo da potência relativa para detecção de ERD e ERS.....	20
Figura 8: Sistema proposto composto de touca e computador.....	26
Figura 9: Exemplo de uma trilha gerada com o estímulo visual sendo uma seta para a direita.	27
Figura 10: Programa de aquisição de dados do Simulink: (a) bloco de aquisição e (b) bloco de geração de estímulos.	28
Figura 11: Fluxograma das etapas de pré-processamento.	30
Figura 12: Resposta em frequência do filtro α (8 – 13 Hz).	31
Figura 13: Resposta em frequência do filtro β (14 – 24 Hz).....	31
Figura 14: Etapas para a obtenção do filtro CSP.	32
Figura 15: Fluxograma para a classificação dos sinais.	34
Figura 16: Exemplo de matriz de confusão.	35
Figura 17: Estrutura das trilhas utilizadas no BCI Competition II.	37
Figura 18: Energia relativa do canal FC5 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 1.....	38
Figura 19: Energia relativa do canal FC6 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 1.....	39
Figura 20: Energia relativa do canal P7 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 1.	39
Figura 21: Energia relativa do canal P8 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 1.	39
Figura 22: Energia relativa do canal FC5 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 1.....	40
Figura 23: Energia relativa do canal FC6 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 1.....	40
Figura 24: Energia relativa do canal P7 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 1.	40
Figura 25: Energia relativa do canal P8 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 1.	41
Figura 26: Resultados intermediários do pré-processamento.	41
Figura 27: Energia relativa do canal FC5 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 1.....	42
Figura 28: Energia relativa do canal FC6 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 1.....	42
Figura 29: Energia relativa do canal P7 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 1.	43
Figura 30: Energia relativa do canal P8 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 1.	43
Figura 31: Energia relativa do canal FC5 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 1.....	43
Figura 32: Energia relativa do canal FC6 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 1.....	44
Figura 33: Energia relativa do canal P7 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 1.	44
Figura 34: Energia relativa do canal P8 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 1.	44
Figura 35: Índice de lateralização para o modelo de trilha 1, sessão 1, sujeito 1.	45
Figura 36: Índice de lateralização para o modelo de trilha 2 sessão 1 sujeito 1.	45
Figura 37: Energia relativa do canal C3 para as trilhas para a direita e esquerda (ritmos α).	46
Figura 38: Energia relativa do canal Cz para as trilhas para a direita e esquerda (ritmos α).....	47
Figura 39: Energia relativa do canal C4 para as trilhas para a direita e esquerda (ritmos α).	47
Figura 40: Energia relativa do canal C3 para as trilhas para a direita e esquerda (ritmos β).....	47
Figura 41: Energia relativa do canal Cz para as trilhas para a direita e esquerda (ritmos β).....	48
Figura 42: Energia relativa do canal C4 para as trilhas para a direita e esquerda (ritmos β).....	48
Figura 43: Índice de lateralização para o BCI Competition II.	49
Figura 44: Espectro de frequência do canal CSP1 sujeito 1 sessão 1 trilha 1.....	50
Figura 45: Espectro de frequência do canal CSP2 sujeito 1 sessão 1 trilha 1.....	51

Figura 46: Espectro de frequência do canal CSP1 sujeito 1 sessão 1 trilha 2.....	51
Figura 47: Espectro de frequência do canal CSP2 sujeito 1 sessão 1 trilha 2.....	51
Figura 48: Espectro de frequência do canal CSP1 BCI <i>Competition</i>	53
Figura 49: Espectro de frequência do canal CSP2 BCI <i>Competition</i>	53

LISTA DE TABELAS

Tabela 1: Organização das trilhas para aquisição de dados.	27
Tabela 2: Lista de variáveis enviadas pela touca ao Simulink.....	29
Tabela 3: Janelas utilizadas para a extração das características no experimento proposto com a touca EMOTIV.	36
Tabela 4: Janelas utilizadas para a extração das características no BCI <i>Competition</i>	36
Tabela 5: Resultados para a classificação Sujeito 1 modelo de trilha 1.	54
Tabela 6: Resultados para a classificação Sujeito 2 modelo de trilha 1.	55
Tabela 7: Resultados para a classificação Sujeito 1 modelo de trilha 2.	55
Tabela 8: Resultados para a classificação Sujeito 2 modelo de trilha 2.	56
Tabela 9: Resultados para a classificação para o BCI <i>Competition II</i>	57

LISTA DE ABREVIATURAS

BCI: *Brain Computer Interface*

SNC: Sistema Nervoso Central

SNP: Sistema Nervoso Periférico

EEG: Eletroencefalograma

IL: Índice de lateralização

CSP: *Common Spatial Pattern*

ERD: *Event-related desynchronization*

ERS: *Event-related synchronization*

TA: Tecnologia Assistiva

LDA: *Linear Discrimination Analysis*

SUMÁRIO

1. INTRODUÇÃO.....	11
1.1 JUSTIFICATIVA	11
1.2 OBJETIVOS	11
2. REVISÃO BIBLIOGRÁFICA.....	13
2.1 SISTEMAS BCI.....	13
2.2 ANATOMIA DO CÉREBRO E DO SNC	14
2.3 FUNCIONALIDADES DO CÓRTEX CEREBRAL	15
2.4 FUNDAMENTOS SOBRE ELETROENCEFALOGRAFIA.....	16
2.4.1 Aquisição do sinal de EEG e Sistema 10-20.....	16
2.4.2 Potenciais Relacionados a Eventos	19
2.5 FILTRO <i>COMMON SPATIAL PATTERN</i> (CSP)	22
2.6 CLASSIFICADOR <i>NAIVE BAYES</i>	24
3. METODOLOGIA EXPERIMENTAL	26
3.1 SISTEMA PROPOSTO	26
3.2 AQUISIÇÃO DE DADOS DE EEG.....	26
3.3 PRÉ-PROCESSAMENTO	30
3.4 FILTRO <i>COMMON SPATIAL PATTERN</i> (CSP)	32
3.5 CLASSIFICADOR <i>NAIVE BAYES</i>	33
3.6 EXTRAÇÃO DE CARACTERÍSTICAS	35
3.7 BCI <i>COMPETITION</i>	36
4. RESULTADOS E DISCUSSÕES	38
4.1 PRÉ-PROCESSAMENTO.....	38
4.1.1 Experimento realizado com a touca EMOTIV	38
4.1.2 BCI <i>Competition</i> II.....	46
4.2 FILTRO <i>COMMON SPATIAL PATTERN</i> (CSP)	49
4.2.1 Experimento proposto com a touca EMOTIV	49
4.2.2 BCI <i>Competition</i> II.....	52
4.3 CLASSIFICADOR	53
4.3.1 Experimento proposto com a touca EMOTIV	54
4.3.2 BCI <i>Competition</i> II.....	57
5. CONCLUSÕES	59
6. PROPOSTA PARA TRABALHOS FUTUROS.....	61
REFERÊNCIAS BIBLIOGRÁFICAS	62
APÊNDICE A – ALGORITMO PARA SEPARAÇÃO DO SINAL DE EEG.....	65
APÊNDICE B – ALGORITMO UNIR O SINAL DE DIFERENTES SESSÕES EM VARIÁVEL	67
APÊNDICE C – ALGORITMO PARA UNIR SINAIS SEPARADOS EM ESQUERDA E DIREITA.....	68
APÊNDICE D – ALGORITMO PARA CÁLCULO DA ENERGIA RELATIVA	69

APÊNDICE E – SCRIPT PARA GERAÇÃO DE GRÁFICOS	72
APÊNDICE F – FUNÇÃO PARA CÁLCULO DA MATRIZ DE COVARIÂNCIA.....	74
APÊNDICE G – ALGORITMO PARA APLICAÇÃO DO FILTRO CSP PARA O EXPERIMENTO PROPOSTO	75
APÊNDICE H – ALGORITMO PARA APLICAÇÃO DO FILTRO CSP PARA O BCI COMPETITION	78
APÊNDICE I – FUNÇÃO PARA EXTRAIR CARACTERÍSTICAS DOS SINAIS	81
APÊNDICE J – SCRIPT PARA GERAR OS GRÁFICOS DE ESPECTRO DE FREQUÊNCIA.....	82
APÊNDICE K – FUNÇÃO PARA REALIZAR A CLASSIFICAÇÃO	83
APÊNDICE L – SCRIPT PARA OBTENÇÃO DOS RESULTADOS	84
ANEXO A – CURVAS DE ENERGIA RELATIVA SUJEITO 1 MODELO DE TRILHA 1 SESSÃO 2	85
ANEXO B – CURVAS DE ENERGIA RELATIVA SUJEITO 1 MODELO DE TRILHA 2 SESSÃO 2	88
ANEXO C – CURVAS DE ENERGIA RELATIVA SUJEITO 2 MODELO DE TRILHA 1 SESSÃO 1	91
ANEXO D – CURVAS DE ENERGIA RELATIVA SUJEITO 2 MODELO DE TRILHA 1 SESSÃO 2	94
ANEXO E – CURVAS DE ENERGIA RELATIVA SUJEITO 2 MODELO DE TRILHA 2 SESSÃO 1	97
ANEXO F – CURVAS DE ENERGIA RELATIVA SUJEITO 2 MODELO DE TRILHA 2 SESSÃO 2	100
ANEXO G – CURVAS DE ESPECTRO DE FREQUÊNCIA.....	103
ANEXO H – MATRIZES DE COVARIÂNCIA.....	108
ANEXO I – CURVAS DE ÍNDICE DE LATERALIZAÇÃO	110

1. INTRODUÇÃO

Tecnologia assistiva (TA) é uma área que busca auxiliar pessoas portadoras de deficiência a realizar tarefas cotidianas com maior conforto e facilidade. O objetivo é garantir a estes indivíduos maior independência, principalmente para a execução de tarefas motoras, promovendo a inclusão social. Um campo que contribui para este tema é o de sistemas BCI (*Brain-Computer Interface*), interfaces que utilizam leituras de potencial elétrico proveniente de atividade cerebral para atuar sobre outros dispositivos. Por meio, por exemplo, de um eletroencefalograma (EEG), equipamento empregado para a medição deste potencial, os sinais gerados no córtex cerebral são capturados, para então serem processados e traduzidos em ações que possam controlar equipamentos, como, por exemplo, próteses biomecânicas e cadeiras de rodas. Portanto, baseado nestas afirmações, é possível desenvolver dispositivos de TA acionados por sinais cerebrais, que podem ser controlados sem ações motoras.

1.1 Justificativa

Principalmente durante as últimas três décadas, pesquisas sobre controle e comunicação, através de sistemas BCI, foram intensificadas, graças aos avanços em instrumentação biomédica, na melhor compreensão das funcionalidades do cérebro e na maior conscientização sobre os problemas enfrentados por portadores de deficiência (DORNHEGE *et al.*, 2007). O desenvolvimento e o estudo de diferentes técnicas de processamento e classificação de sinais de EEG são elementos essenciais para o aperfeiçoamento de sistemas BCI. Com a consolidação de ferramentas que garantam confiabilidade aos processos envolvidos, é possível proporcionar a introdução de novos dispositivos de TA para o uso cotidiano.

Assim, o projeto desenvolvido, neste trabalho, é justificado pelo estudo das ferramentas de análise de sinais de EEG, que visam traduzir potencial elétrico gerado no cérebro em comandos de controle e comunicação, para que possam integrar sistemas de TA.

1.2 Objetivos

Este trabalho visa avaliar o desempenho de Redes Bayesianas, quando utilizadas para a classificação de movimentos motores imaginários, para a mão esquerda e mão direita, em um sistema BCI. Os objetivos principais são: estabelecer um modelo de processamento de sinais que permita o reconhecimento dos movimentos imaginados pelo usuário do sistema e

realizar uma análise preliminar entre os resultados obtidos deste modelo em relação aos obtidos por outros trabalhos semelhantes desta área. Como objetivos secundários, têm-se:

- Realizar uma análise preliminar entre os resultados obtidos neste trabalho e os obtidos em (MACHADO, 2012)
- Avaliar o desempenho da classificação dos movimentos sem o uso dos eletrodos C3 e C4, considerados os mais importantes para detecção do movimento das mãos (DORNHEGE *et al.*, 2007)
- Avaliar o uso da touca EMOTIV para classificação baseada em *Event-related desynchronization* (ERD) e *event-related synchronization* (ERS)

As medições executadas são realizadas de maneira não invasiva, com o uso da touca de eletrodos EMOTIV, e a classificação dos movimentos é realizada *offline*. Além dos dados obtidos experimentalmente, com o uso deste equipamento, o banco de dados da BCI *Competition II* (BCI *Competition II*, 2003), que é um conjunto de sinais obtidos para classificação de duas classes de movimento, é também utilizado como entrada para o sistema de processamento de forma a permitir a comparação entre os resultados para diferentes amostras.

No sistema em estudo, a classificação dos movimentos motores imaginários, efetuada de forma síncrona, leva em consideração 2 classes: esquerda e direita. Estas devem ser reconhecidas, respectivamente, pelo planejamento do movimento da mão esquerda e da mão direita.

2. REVISÃO BIBLIOGRÁFICA

2.1 Sistemas BCI

A ideia de medir potenciais elétricos gerados por atividade cerebral é um conceito antigo. O primeiro registro deste fenômeno, atribuído ao cientista britânico Richard Caton, foi realizado em 1875. Seguido por estudos mais aprofundados sobre EEG por Hans Berger em 1920 (SANEI & CHAMBERS, 2007). No entanto, a integração dos sinais gerados pelo cérebro humano com dispositivos externos só passou a ser objeto de estudo mais intenso há aproximadamente três décadas (DORNHEGE *et al.*, 2007).

Para poder desenvolver esta integração, de maneira a habilitar o usuário do sistema BCI a realizar ações controladas, é necessária uma definição de estímulos que incitem respostas no cérebro que possam ser identificadas pelo sistema e que sejam facilmente reproduzidos pelo indivíduo. Por este motivo, a classificação de movimentos motores imaginários é comumente empregada (MACHADO, 2012)(CARRA, 2012)(YI, 2013), visto que são estímulos que geram sinais passíveis de serem reconhecidos por sistemas de processamento e são de fácil reprodução.

Além de sistemas por identificação de classe de movimento, estudos sobre outras aplicações de sistemas BCI, como o aumento do desempenho humano (WANG *et al.*, 2011) e identificação de respostas cerebrais involuntárias (por exemplo, epilepsia) já foram conduzidos (SANEI & CHAMBERS, 2007). Estes visam à possibilidade de desenvolvimento de interfaces homem máquina ou para realizar o monitoramento da atividade cerebral durante determinadas atividades e eventos. Estes conceitos podem ser aplicados para sofisticar a segurança de operações e desenvolver sistemas que se adaptem no decorrer do uso, de acordo com o estado mental do usuário (DORNHEGE *et al.*, 2007).

Sistemas BCI tipicamente podem ser classificados como síncronos ou assíncronos. Quando síncronos, o usuário é apresentado com estímulos que indicam o momento no qual se deve iniciar a imaginar ou a realizar movimentos (MACHADO, 2012)(CARRA, 2012)(PFURTSCHELLER & SILVA, 1999). Esta abordagem não exige a detecção do instante de tempo no qual ocorre o movimento, visto que este já é predeterminado. No caso de sistemas assíncronos, não se sabe previamente o momento no qual o movimento foi executado (ou imaginado), pois o usuário não está restrito a estímulos. Para este método, não só a classificação de qual membro do corpo realizou o movimento, mas também a identificação do instante de execução é de essencial importância (IBÁÑEZ *et al.*, 2014).

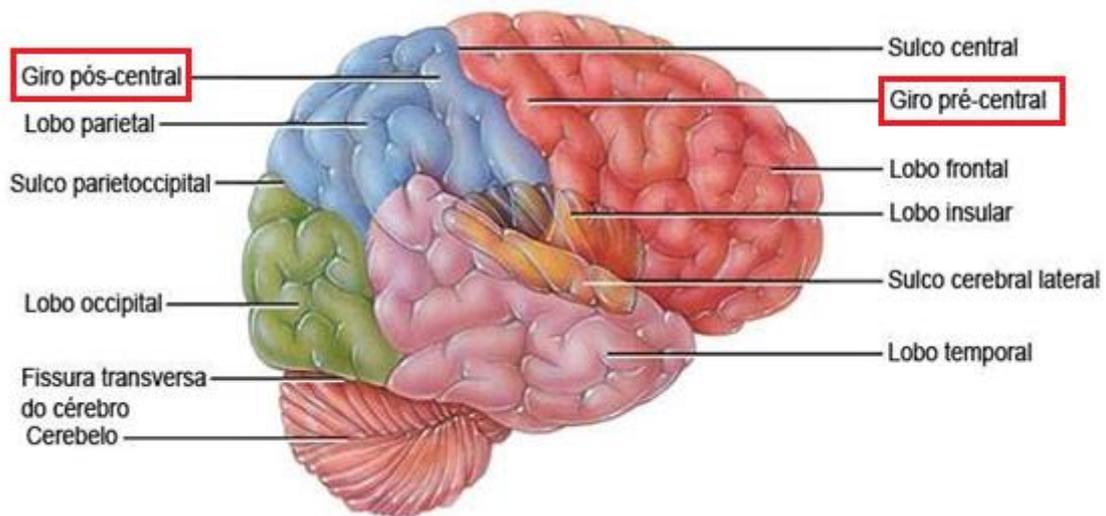
Em sistemas BCI, como o estudado neste trabalho, o planejamento do movimento de certos membros do corpo é associado a uma série de comandos. Através de uma análise da

energia do sinal medido e da região do córtex cerebral que o originou, determina-se qual movimento foi imaginado e executa-se a ação associada a este. Portanto, é necessária a compreensão do funcionamento do cérebro humano, quanto à geração de estímulos motores, do tipo de sinais obtidos pelo EEG, como processá-los e, finalmente, classificá-los para que possam ser traduzidos em uma ação.

2.2 Anatomia do Cérebro e do SNC

O Sistema Nervoso Central (SNC) é composto de duas partes: o encéfalo e a medula espinhal. O telencéfalo (cérebro) é um dos elementos do encéfalo responsável pela geração de impulsos e pela interpretação de estímulos externos. Este possui várias divisões próprias, como os lobos e os giros, além da sua separação em dois hemisférios, dada pela fissura longitudinal, como pode ser observado na vista lateral da Figura 1. Os giros pré-central e pós-central são onde estão localizadas, respectivamente, a área motora primária e a área somatossensorial (TORTORA, 2012), que são as principais regiões de interesse para a identificação de movimentos através do EEG.

Figura 1: Localização dos giros e lobos em vista lateral.



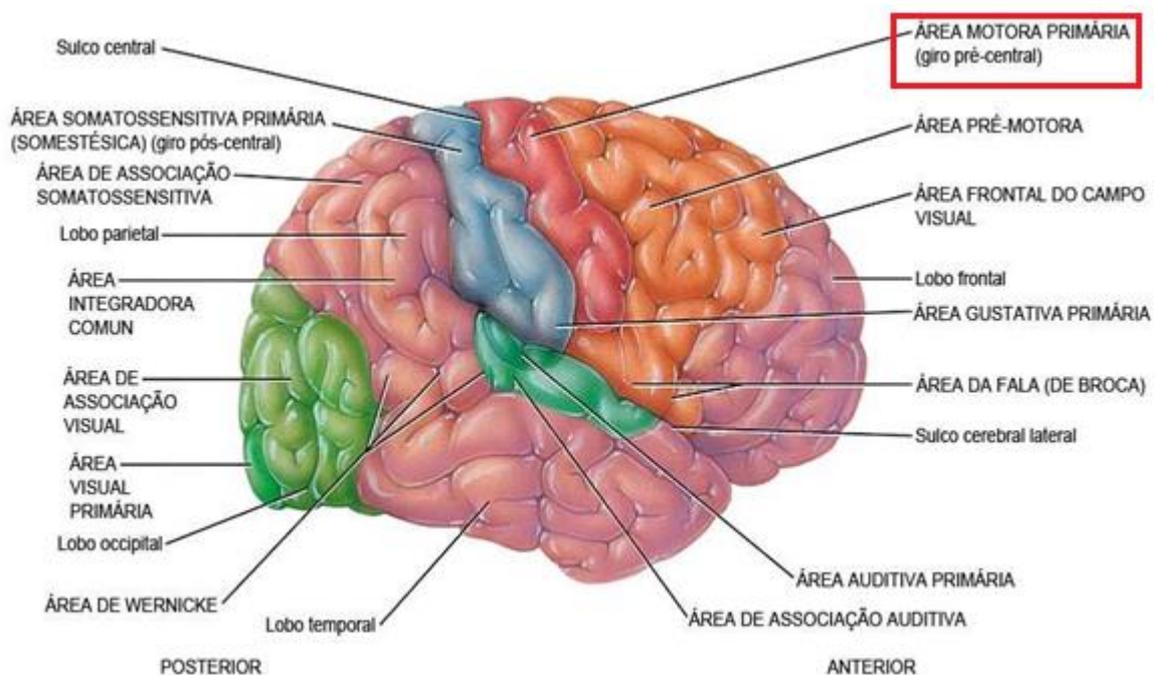
Fonte: Adaptado de TORTORA, 2012.

O segundo elemento do SNC, a medula espinhal, possui 31 pares de nervos espinais, que são os membros que realizam a comunicação com cada uma das áreas específicas do corpo. Elas são parte do sistema nervoso periférico e sua função é a conexão entre o SNC e os músculos e receptores sensitivos (TORTORA, 2012).

2.3 Funcionalidades do Córtex Cerebral

O córtex cerebral, parte que constitui o telencéfalo, possui diversas funções essenciais para o ser humano, divididas por áreas. A região somatossensitiva primária, que se localiza principalmente da metade posterior do telencéfalo até o sulco central (ver Figura 2), é onde são recebidos os sinais de sensações, como o tato, a dor e a temperatura. A parcela responsável pelas atividades motoras, chamada de área motora primária, está localizada na porção anterior de cada hemisfério no giro pré-central, e é onde se originam sinais de movimento voluntários (TORTORA, 2012).

Figura 2: Áreas do cérebro por funcionalidade.

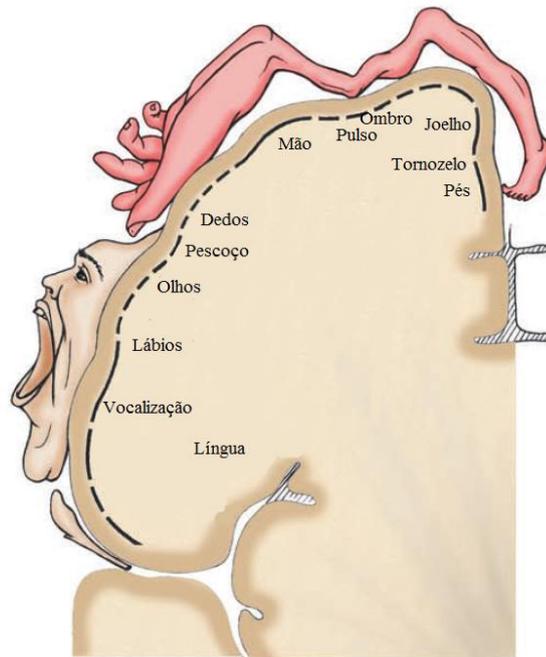


Fonte: Adaptado de TORTORA, 2012.

Dentro da área motora primária, diferentes porções do cérebro são responsáveis pelos sinais de movimento de cada membro do corpo humano, como pode ser visto na Figura 3. O fato de que a região que gera os impulsos relacionados com as mãos estar localizada mais afastada do centro permite uma identificação mais fácil de qual hemisfério originou o sinal através do EEG, e conseqüentemente, de qual mão imaginou-se o movimento (esquerda ou direita). A área responsável pela geração de sinais referentes aos pés e pernas, próxima do sulco central, torna mais difícil a distinção entre qual lado originou o impulso de movimento. Por este motivo, trabalhos sobre sistema BCI frequentemente realizam a classificação de mão

esquerda e direita separadamente (MACHADO, 2012)(CARRA, 2012), mas consideram o movimento de pés ou pernas como um comando único (YI, 2013).

Figura 3: Regiões do córtex responsáveis por cada membro.



Fonte: Adaptado de TORTORA & DERRICKSON, 2009.

2.4 Fundamentos sobre Eletroencefalografia

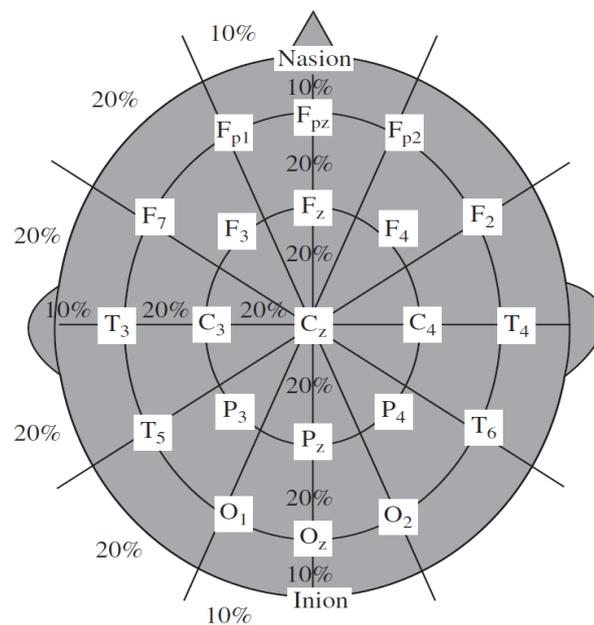
Quando uma ação é planejada, ou efetuada, correntes elétricas passam a fluir no córtex cerebral graças à atividade de vários neurônios em conjunto. Estas correntes geram um campo magnético, que pode ser medido através de magnetoencefalografia (MEG), e um campo elétrico, que pode ser medido via EEG (SANEI & CHAMBERS, 2007). Durante diferentes atividades, as ondas observadas no escalpo apresentam-se em frequências distintas e, portanto, são classificadas como 5 tipos de ritmos cerebrais, chamados de α , θ , β , δ e γ . Para a detecção de movimento, pode-se analisar as ondas α e β que são tipicamente encontradas no intervalo de 8 a 13 Hz e de 14 a 26 Hz, com amplitudes inferiores a 50 μ V e 30 μ V (SANEI & CHAMBERS, 2007), respectivamente.

2.4.1 Aquisição do sinal de EEG e Sistema 10-20

Sistemas de aquisição de sinais de EEG, atualmente, são compostos por um conjunto de eletrodos, podendo estar fixados a uma touca ou livres, amplificadores diferenciais, filtros e conversores analógicos para digitais (SANEI & CHAMBERS, 2007). O posicionamento

destes eletrodos no escalpo é dado por uma das diversas convenções internacionais existentes. Neste trabalho, a convenção utilizada é a denominada de Sistema 10-20, que especifica o local de cada um dos eletrodos para um conjunto de 21 eletrodos no total. Esta definição considera uma série de distâncias entre pontos de interesse de medição, e então utiliza 10 % ou 20 % desta distância como a separação entre os eletrodos (SANEI & CHAMBERS, 2007). Na Figura 4, pode-se observar a distribuição do Sistema 10-20, assim como, as referências para cada eletrodo.

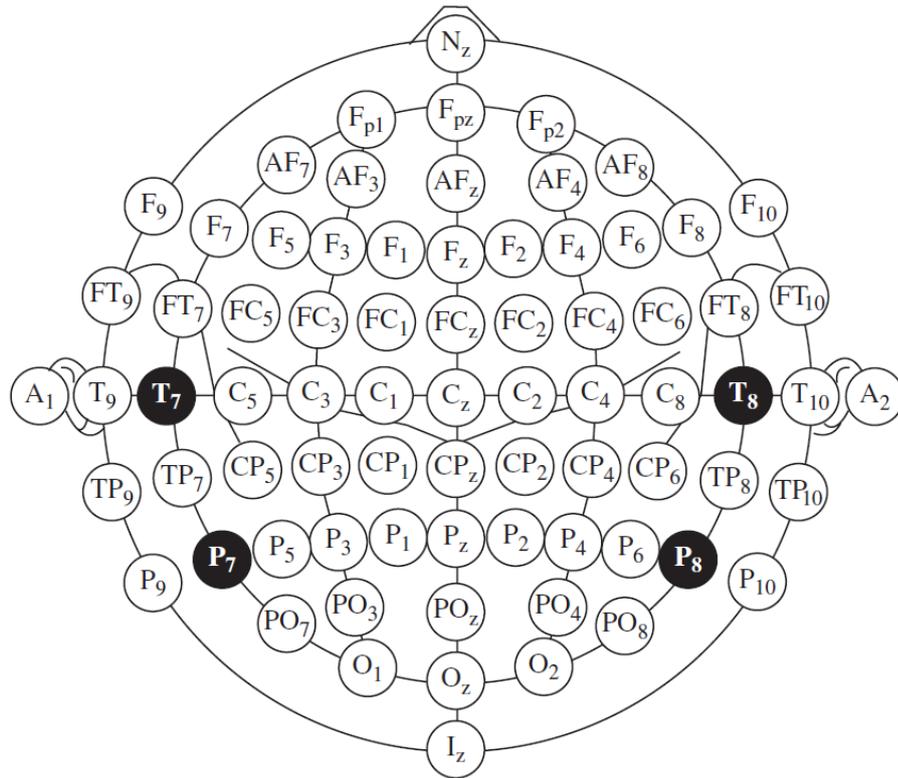
Figura 4: Posicionamento dos eletrodos pelo sistema 10-20.



Fonte: Adaptado de SANEI & CHAMBERS, 2007.

O sistema 10-20 possui também a definição das posições de cada eletrodo para uma configuração com um total de 75 unidades, como apresenta a Figura 5. Este arranjo coloca os eletrodos adicionais com distâncias iguais entre as posições do sistema para 21 unidades. Apesar da posição de cada um dos eletrodos ser especificada, aplicações de sistemas BCI não necessariamente requerem que todas as unidades sejam utilizadas, podendo se limitar ao uso de até mesmo um único eletrodo (SANEI & CHAMBERS, 2007).

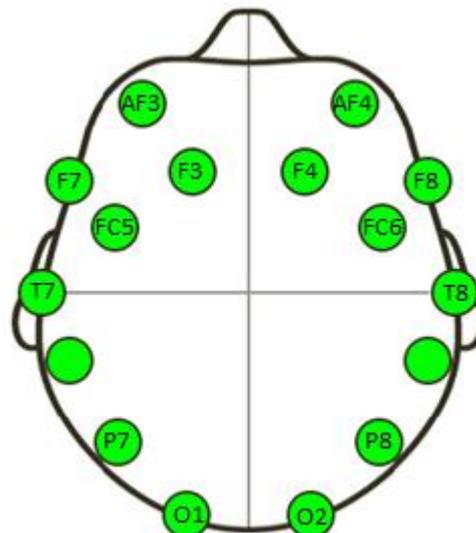
Figura 5: Posicionamento dos eletrodos para o Sistema 10-20 com 75 eletrodos.



Fonte: Adaptado de SANEI & CHAMBERS, 2007.

A touca EMOTIV possui 14 eletrodos posicionados de acordo com o Sistema 10-20 para 75 eletrodos. A Figura 6 mostra a configuração da touca EMOTIV com as referências de cada canal.

Figura 6: Posicionamento dos eletrodos para a touca EMOTIV.



Fonte: Adaptado do manual de usuário da touca EMOTIV.

2.4.2 Potenciais Relacionados a Eventos

Durante a etapa de planejamento de um movimento, cerca de 1 a 1,5 segundos antes da sua execução, uma diminuição na intensidade dos ritmos sensório-motores pode ser observada no sinal de EEG. Este fenômeno é denominado *Event Related Desynchronization* (ERD) e também pode ser encontrado durante a imaginação de movimentos (DORNHEGE *et al.*, 2007). Este ERD ocorre mais intensamente no lado contralateral (lado oposto) do cérebro em relação ao movimento, na faixa de frequência das ondas α , apesar de também ser observado nas ondas β (NAM *et al.*, 2011).

O efeito contrário, *Event Related Synchronization* (ERS), é definido pelo aumento de energia em determinadas bandas de frequência, e pode ser observado no término de movimentos motores, ou da imaginação destes, principalmente na faixa das ondas β (PFURTSCHELLER & SILVA, 1999). O ERS pode ser observado, neste período de pós-movimento, em ambos os lados contralateral e ipsilateral (mesmo lado), e é associado com o repouso do córtex motor (NAM *et al.*, 2011).

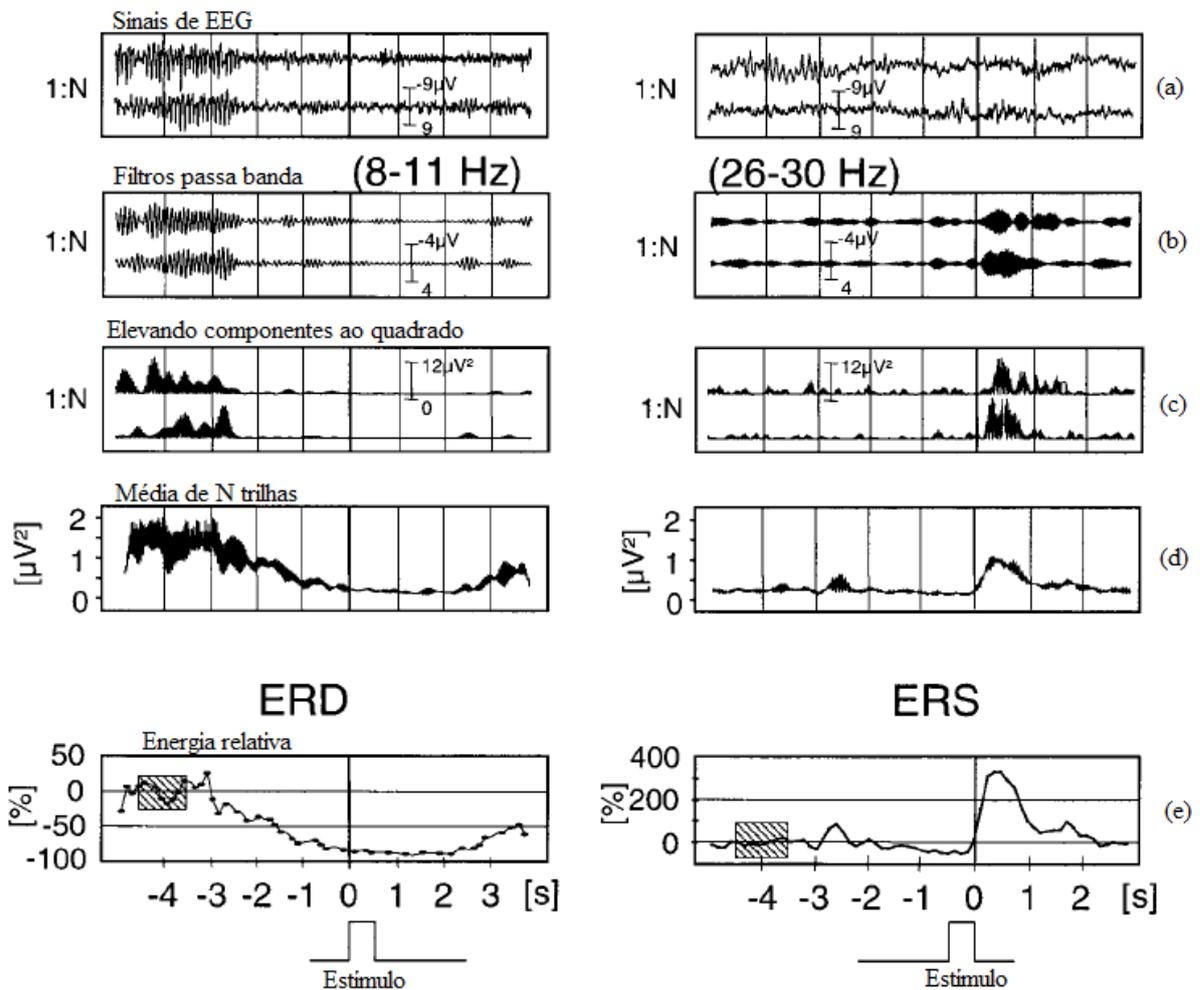
A detecção destes dois eventos pode ser feita através do método exposto em (PFURTSCHELLER & SILVA, 1999), determinando a energia relativa entre o período de estímulo e o período de referência. Inicialmente, os sinais são filtrados para separar os ritmos α e β , então se eleva suas componentes ao quadrado para obtenção da potência. Para reduzir a variabilidade, calcula-se a média entre todas as trilhas que apresentam o mesmo tipo de estímulo. Finalmente, a potência relativa é dada pela Equação (1), onde A é a potência durante o estímulo e R é a potência durante o período de referência.

$$ERD\% = \frac{A-R}{R} \times 100 \quad (1)$$

É interessante ressaltar que esta modulação dos ritmos cerebrais pode variar de acordo com o usuário, podendo ter impacto na detecção do ERD e, conseqüentemente, na classificação dos movimentos. Em (BAMDADIAN *et al.*, 2014), um estudo sobre o diferente desempenho de usuários considerando seus níveis de atenção, estimados através de um índice que relaciona os ritmos θ , α e β , sugere que indivíduos com melhor capacidade de concentração apresentam taxas de acertos maiores na classificação. Além disto, é possível observar diferenças espaciais para a ocorrência do ERD na comparação de indivíduos saudáveis e indivíduos que sofreram algum trauma, como, por exemplo, acidente vascular cerebral (AVC) (IBÁÑEZ *et al.*, 2014).

A Figura 7 apresenta um exemplo da aplicação deste método, incluindo cada uma de suas etapas, para ondas α (lado esquerdo da figura) e β (lado direito da figura). Na Figura 7 (a), tem-se os sinais de EEG adquiridos sem qualquer tipo de processamento. Em (b), os sinais de EEG são filtrados nas bandas de frequência referentes aos ritmos α e β . O cálculo da energia, realizado elevando as componentes do sinal ao quadrado e dividindo pelo número total de componentes, está em (c). A Figura 7 (d) exibe a média da energia ao longo do tempo para N trilhas e a Figura 7 (e) exibe a energia relativa, obtida através da Equação (1), para a identificação dos fenômenos de ERD e ERS.

Figura 7: Etapas do cálculo da potência relativa para detecção de ERD e ERS.



Fonte: Adaptado de PFURTSCHELLER & SILVA, 1999.

Outro fator que pode ser utilizado na elaboração de experimentos para aumentar a taxa de acerto na detecção de ERD é a repetição das tarefas do usuário. Como demonstrado em

(NAKAYASHIKI *et al.*, 2014), a repetição do movimento das mãos produz um ERD com módulo da energia relativa maior em relação a movimentos únicos.

Devido à característica dos potenciais relacionados a eventos ocorrerem de forma lateralizada (para movimentos de mão esquerda e direita), é possível definir um indicador que avalie a diferença de energia entre os dois hemisférios. Denominado Índice de Lateralização (IL), este indicador é definido como a média da diferença de potência entre os dois lados do cérebro (escolhendo um eletrodo de cada lado) para cada classe de movimento (DOYLE *et al.*, 2005)(NAM *et al.*, 2011), de acordo com a Equação (2):

$$IL = \frac{(P_{FC5} - P_{FC6})_{\text{Movimento esquerdo}} + (P_{FC6} - P_{FC5})_{\text{Movimento direito}}}{2} \quad (2)$$

Neste caso, os eletrodos selecionados são FC5 e FC6, onde IL é o Índice de Lateralização e P_{FC5} e P_{FC6} são, respectivamente, as potências nos eletrodos FC5 e FC6.

O fato de que diferentes movimentos ocasionam fenômenos distintos em regiões do cérebro também permite a combinação de ações em sistemas BCI. Por exemplo, em um sistema de 3 classes, utilizando mão direita, mão esquerda e os pés, pode-se associar comandos com a imaginação do movimento de uma das mãos e dos pés ao mesmo tempo. Isto permite a adição de novas ações para o usuário. O estudo de (XIA *et al.*, 2015) aplica este conceito ao controle de um cursor e (YI *et al.*, 2013) faz uma comparação entre as respostas nos ritmos α e β obtidas para diferentes combinações de membros do corpo humano. O experimento proposto em (MORASH *et al.*, 2008) utiliza também o movimento da língua.

Além do uso de diferentes membros, estratégias mentais que não envolvem movimento, como realizar abstrações, imaginar palavras e imaginar a rotação de objetos em 3 dimensões, também já foram investigadas quanto a sua potencialidade de integrar sistemas BCI, e os resultados indicam que empregar estes métodos pode ser adequado, mas que o desempenho para cada estratégia é dependente do usuário (FRIEDRICH *et al.*, 2012).

O ERD, além de permitir a classificação *offline* de movimentos (análise de dados salvos em ensaios prévios), também é utilizado em tentativas de desenvolvimento de sistemas *online*, isto é, que procuram identificar as intenções do usuário durante o uso (IBÁÑEZ *et al.*, 2014). Neste caso, o sinal de EEG é analisado por trechos (dividido em janelas) buscando identificar o momento e qual lado originou o ERD. Em (IBÁÑEZ *et al.*, 2014), o uso de um giroscópio conectado ao braço do usuário é empregado para eliminar a dificuldade de determinação do instante de início de movimento.

2.5 Filtro *Common Spatial Pattern* (CSP)

Uma característica que afeta a análise de sinais de EEG é o fato de que cada eletrodo, apesar de estar posicionado em um local específico do escalpo, captura ondas de regiões adjacentes a sua posição. Este efeito pode dificultar a avaliação de movimentos imaginários, se estas ondas geradas por outras fontes no cérebro ocuparem a mesma porção do espectro que os ritmos α e β , principalmente para análise de uma trilha única (quando se quer classificar o movimento sem utilizar a média de diversos ensaios, como descrito na Seção 2.4.2) (BLANKERTZ *et al.*, 2008).

O filtro CSP realiza uma operação que projeta os sinais de um conjunto de canais de EEG em um novo espaço, onde o objetivo é maximizar a variância do sinal em uma condição (por exemplo, movimento para a esquerda, indicada como condição positiva) e minimizá-la na condição contrária (para a direita, denotada como condição negativa) (BLANKERTZ *et al.*, 2008). Esta etapa de processamento é muito utilizada, visando aumentar as taxas de acerto, em estudos sobre a classificação de movimentos (MACHADO, 2012)(CARRA, 2012)(IBÁÑEZ *et al.*, 2014)(BASHASHATI *et al.*, 2015), não apenas em sistemas para avaliar o ERD, mas também outros fenômenos cerebrais, como, por exemplo, o *Bereitschaftspotential* (IBÁÑEZ *et al.*, 2014).

É importante observar que o desempenho do filtro espacial em discriminar as classes e melhorar as taxas de acertos de classificação é dependente da seleção das bandas de frequência para quais os sinais são filtrados e do número de canais a serem levados em consideração, e estes parâmetros podem ser diferentes entre indivíduos sujeitos ao experimento (MENG *et al.*, 2012). Por este motivo, variações do filtro CSP sugeriram, levando em consideração seleções automatizadas de parâmetros, e os resultados apresentados indicam melhoras significativas no desempenho em relação ao método original (MENG *et al.*, 2012)(ZHANG *et al.*, 2015). Neste trabalho, o método adotado é o filtro CSP, de forma a manter a possibilidade de comparação com os resultados obtidos em (MACHADO, 2012).

Considerando $\mathbf{x}(t) \in \mathbb{R}^C$ como o vetor que contém os valores para a amostra t para o número total de canais de EEG (C) e como o conjunto de filtros espaciais, onde cada coluna da matriz é um filtro diferente, o sinal projetado no novo espaço $\mathbf{x}_{csp}(t) \in \mathbb{R}^C$ é dado pela Equação (3) (BLANKERTZ *et al.*, 2008). Observe que, neste trabalho, matrizes são representadas em negrito.

$$\mathbf{x}_{csp}(t) = \mathbf{W}^T \mathbf{x}(t) \quad (3)$$

O conjunto para o número total de amostras (T), para todos os canais, é dado por $\mathbf{X} = [x(t), x(t + 1), \dots, x(t + T - 1)]$. Isto significa que \mathbf{X} possui T elementos e cada um destes é um vetor contendo os valores das amostras para cada canal, ou seja, $\mathbf{X} \in \mathbb{R}^{C \times T}$ (BLANKERTZ *et al.*, 2008). O primeiro passo para a obtenção da matriz \mathbf{W} é a construção das matrizes que estimam a covariância em duas condições: trilhas para a esquerda e trilhas para a direita. Sendo $\mathbf{\Sigma}^{(c)}$ a matriz de covariância na condição c e N o número total de trilhas para a condição, a construção da matriz é dada pela Equação (4).

$$\mathbf{\Sigma}^{(c)} = \frac{1}{N} \sum_{i \in N} \mathbf{X}_i^{(c)} \mathbf{X}_i^{(c)T} \quad (4)$$

A relação da Equação (5), utilizando a matriz de filtros espaciais \mathbf{W} e a matriz de covariâncias, produz a matriz $\mathbf{\Lambda}^c$, que representa as novas covariâncias de cada canal para cada condição c para a projeção do filtro CSP. Esta matriz $\mathbf{\Lambda}^c \in \mathbb{R}^{C \times C}$ é diagonal, e a soma das suas duas condições deve ser igual à matriz identidade \mathbf{I} , de acordo com a Equação (6) (BLANKERTZ *et al.*, 2008):

$$\mathbf{W}^T \mathbf{\Sigma}^{(c)} \mathbf{W} = \mathbf{\Lambda}^c \quad (5)$$

$$\mathbf{\Lambda}^+ + \mathbf{\Lambda}^- = \mathbf{I} \quad (6)$$

De posse da matriz de covariâncias em cada condição, calcula-se a matriz composta de covariância $\mathbf{\Sigma} = \mathbf{\Sigma}^{(+)} + \mathbf{\Sigma}^{(-)}$ e efetua-se a decomposição nos seus autovalores λ e autovetores \mathbf{B} , de maneira a respeitar a relação da Equação (7).

$$\mathbf{\Sigma} = \mathbf{B} \mathbf{\lambda} \mathbf{B}^T \quad (7)$$

A matriz \mathbf{P} , Equação (8), é resultado da operação de *whitening transformation* sobre a matriz de autovetores \mathbf{B} . Este processo escala \mathbf{B} por um fator $1/\sqrt{\lambda}$ e ocasiona que \mathbf{P} respeite a relação dada pela Equação (9) (FUKUNAGA, 1990) (RAMOSER, MÜLLER-GERKING & PFURTSCHHELLER, 2000).

$$\mathbf{P} = \lambda^{-1/2} \mathbf{B}^T \quad (8)$$

$$\mathbf{P} \boldsymbol{\Sigma} \mathbf{P}^T = \mathbf{I} \quad (9)$$

Usando a matriz \mathbf{P} , realiza-se a transformação das matrizes de covariância em cada condição, obtendo-se \mathbf{S}^c na Equação (10):

$$\mathbf{S}^c = \mathbf{P} \boldsymbol{\Sigma}^c \mathbf{P}^T \quad (10)$$

Desta forma, \mathbf{S}^+ e \mathbf{S}^- possuem autovetores (\mathbf{U}) iguais e seus autovalores são os que compõe a matriz $\boldsymbol{\Lambda}$ (BLANKERTZ *et al.*, 2008). Assim, faz-se a decomposição de \mathbf{S}^c como apresentado na Equação (11).

$$\mathbf{S}^c = \mathbf{U} \boldsymbol{\Lambda}^c \mathbf{U}^T \quad (11)$$

Os filtros espaciais \mathbf{W} são obtidos pela Equação (12). Observe que cada coluna da matriz representa um filtro diferente, que pondera cada canal de EEG utilizado na análise. A seleção de quais destes filtros são mais significativos para serem aplicados aos sinais é feita pelos autovalores $\boldsymbol{\Lambda}^c$. Os maiores valores das novas variâncias representam as maiores diferenciações entre as classes de movimento, e, portanto, deve-se escolher as colunas de \mathbf{W} correspondentes a estas ocorrências (RAMOSER, MÜLLER-GERKING & PFURTSCHELLER, 2000).

$$\mathbf{W} = (\mathbf{U}^T \mathbf{P})^T \quad (12)$$

2.6 Classificador *Naive Bayes*

O classificador *Naive Bayes* é um método probabilístico que pode ser utilizado para determinar a qual classe um sinal pertence (para o caso deste estudo, as classes são: movimento imaginário da mão esquerda e da mão direita) (MITCHELL, 1997). Esta abordagem, que é focada neste trabalho, é eficaz para classificações baseadas em ERD e é comumente empregada em trabalhos deste gênero (IBÁÑEZ *et al.*, 2014)(MACHADO, 2012). Outros classificadores, como o *Linear Discrimination Analysis* (LDA) (MACHADO & BALBINOT, 2014), também são populares, e a combinação de diferentes métodos de

classificação em conjuntos já foi estudada visando aumentar as taxas de acerto (AHANGI *et al.*, 2012).

A variável v_{MAP} , que efetua a classificação, é baseada no teorema de probabilidade condicional de Bayes de acordo com a Equação (13) (MITCHELL, 1997). No entanto, nesta forma, a resolução da Equação (13) é custosa computacionalmente, visto que envolve estimar probabilidades condicionais que relacionam todas as variáveis a_i , e exige um grande volume de dados que as estimações sejam adequadas. Frente a este fato, considera-se que as variáveis a_i são independentes, o que permite a simplificação da Equação (13) para a Equação (14) (MITCHELL, 1997).

$$v_{MAP} = \operatorname{argmax}_{v_j \in V} P(a_1, a_2 \dots a_n | v_j) P(v_j) \quad (13)$$

$$v_{NB} = \operatorname{argmax}_{v_j \in V} P(v_j) \prod_i P(a_i | v_j) \quad (14)$$

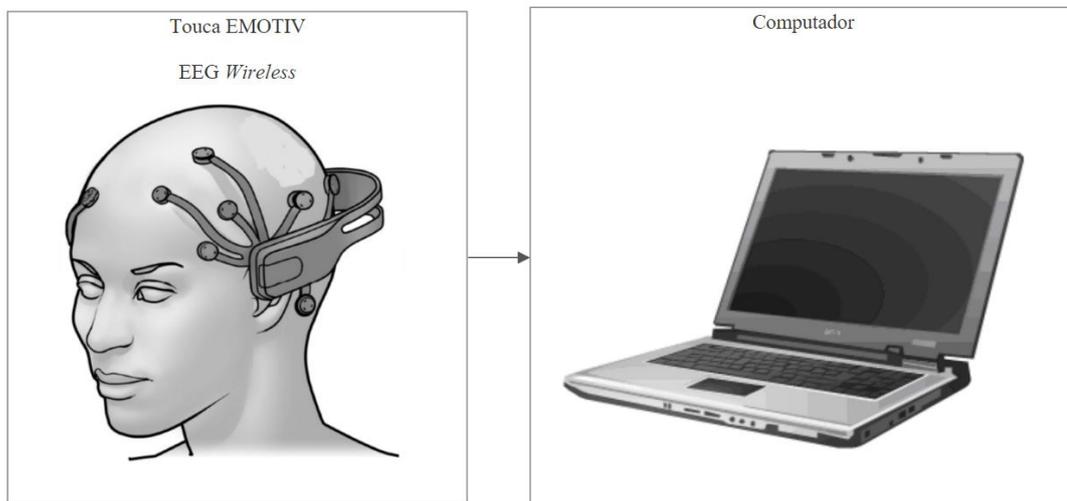
Onde $P(a_i | v_j)$ é a probabilidade da característica a_i , dada a classe v_j , e $P(v_j)$ é a probabilidade da classe.

3. METODOLOGIA EXPERIMENTAL

3.1 Sistema Proposto

O sistema utilizado, neste trabalho é composto essencialmente de dois elementos: a touca de eletrodos EMOTIV, modelo EPOC, que é um EEG sem fio com eletrodos, e um computador, para geração de estímulos, gravação de dados, processamento de sinais e exibição dos resultados. A touca possui um módulo de comunicação *bluetooth* que permite o envio dos sinais adquiridos diretamente para o programa Simulink. O diagrama de blocos da Figura 8 exemplifica o sistema descrito.

Figura 8: Sistema proposto composto de touca e computador.



Fonte: Adaptado do manual do usuário EMOTIV.

3.2 Aquisição de dados de EEG

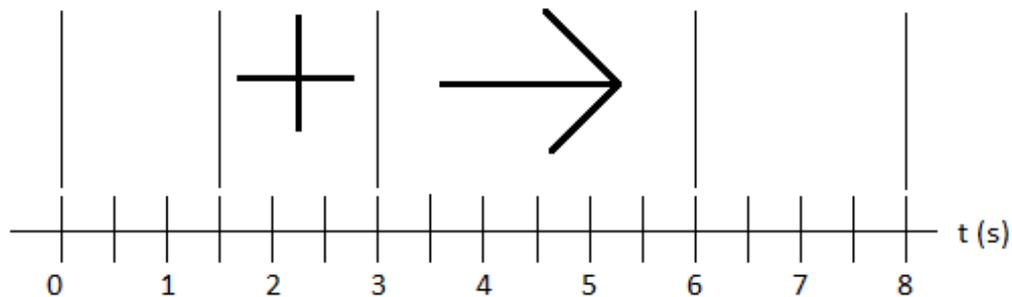
A aquisição dos dados de EEG foi baseada no registro dos sinais de cada um dos canais da touca de eletrodos durante sessões de apresentação de estímulos visuais ao indivíduo sujeito ao experimento. A apresentação de estímulos foi organizada em trilhas com os intervalos descritos na Tabela 1. Os períodos de referência e de pós-estímulo apresentam somente uma tela em branco, de forma a obter os sinais de EEG durante o repouso. A cruz do pré-estímulo indica para o indivíduo que o estímulo visual principal está prestes a ser exibido, sendo este uma seta, que pode apontar para a esquerda ou para a direita. A direção é gerada aleatoriamente para cada trilha. Esta metodologia de geração de estímulos visuais já foi empregada em outros trabalhos para a classificação de movimento, como por exemplo, nos trabalhos de (MACHADO, 2012)(CARRA, 2012)(DOYLE *et al.*, 2005) e (NAM *et al.*, 2011).

Tabela 1: Organização das trilhas para aquisição de dados.

Tempo	Apresentação visual	Período
0,0 a 1,5 segundos	Tela em branco	Referência
1,5 a 3,0 segundos	Cruz	Pré-estímulo
3,0 a 6,0 segundos	Seta	Estímulo
6,0 a 8,0 segundos	Tela em branco	Pós-estímulo

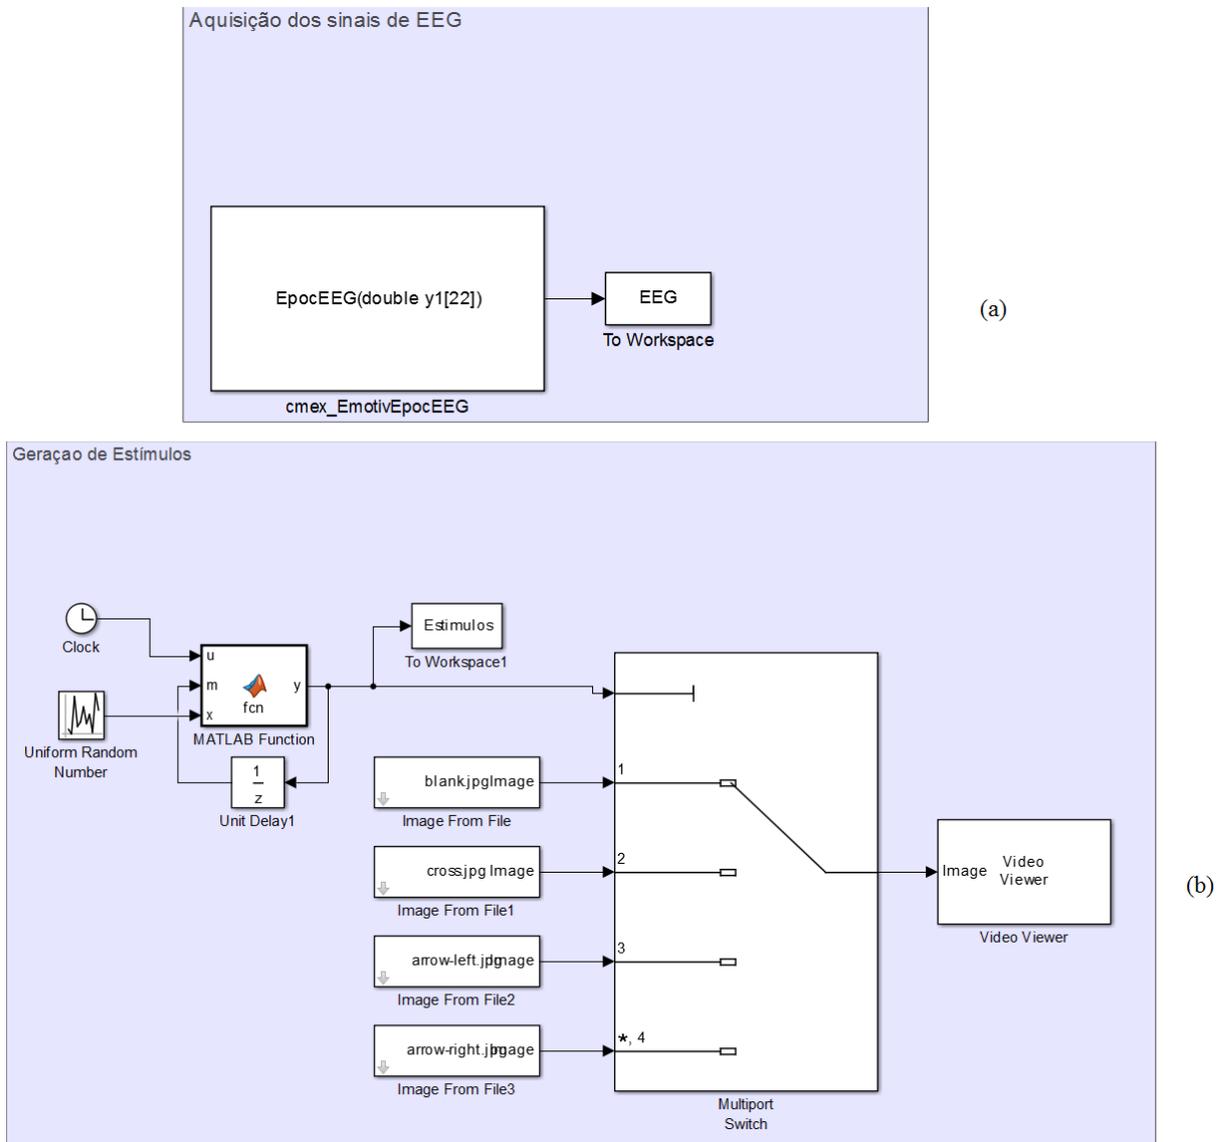
O registro dos dados obtidos pela touca de eletrodos da EMOTIV é realizado pelo programa MATLAB através do módulo USB de comunicação *bluetooth*, que faz parte do conjunto da touca. De forma a gravar os sinais de EEG e as informações das trilhas criadas de maneira sincronizada, a geração dos estímulos também foi feita através do mesmo *software*. A Figura 9 exemplifica o formato em que cada trilha é gerada e registrada, para o caso de um estímulo para a direita.

Figura 9: Exemplo de uma trilha gerada com o estímulo visual sendo uma seta para a direita.



A Figura 10 apresenta os blocos desenvolvidos no Simulink para realizar a aquisição, sendo (a) o bloco que recebe os dados da touca e (b) o bloco que apresenta as trilhas no formato descrito. Na Figura 10(a), todos os valores lidos, durante a execução do programa, são registrados em uma variável. Para geração das trilhas, o tempo de simulação, um número aleatório e a saída (valor que representa qual imagem deve ser exibida na tela) da última iteração são inseridos como entrada em uma função do MATLAB. De acordo com estas três variáveis, a função determina qual imagem deve ser apresentada em cada instante de tempo, para formar as trilhas no formato descrito. Uma variável contendo todos os estímulos gerados ao longo da simulação também é salva.

Figura 10: Programa de aquisição de dados do Simulink: (a) bloco de aquisição e (b) bloco de geração de estímulos.



A tarefa do indivíduo usando a touca EMOTIV é imaginar os seguintes movimentos para cada tipo de estímulo:

- seta para esquerda: imaginar o fechamento da mão esquerda;
- seta para direita: imaginar o fechamento da mão direita.

Desta forma, ao término da execução de um grupo de trilhas, têm-se duas estruturas: uma contendo o estímulo apresentado para cada instante de tempo e outra contendo o sinal de cada canal usado para o EEG, para o mesmo período. A frequência de amostragem da touca EMOTIV é de 128 Hz e os dados são enviados para o MATLAB, através do programa Simulink, em um bloco com 22 variáveis e seus respectivos valores para cada instante de

tempo. Estas variáveis são os valores lidos para cada um dos canais da touca, além de sinais de controle. Os códigos de MATLAB dos APÊNDICES A e B são usados para separar os sinais adquiridos em variáveis divididas por trilhas e unir diferentes sessões experimentais, respectivamente. A lista de todas as variáveis contidas no bloco, como fornecida pelo fabricante, está na Tabela 2.

Tabela 2: Lista de variáveis enviadas pela touca ao Simulink.

COUNTER	F3	P7	P8	F4	GYROX	FUNC_ID	SYNC_SIGNAL
AF3	FC5	O1	T8	F8	GYROY	FUNC_VALUE	
F7	T7	O2	FC6	AF4	TIMESTAMP	MARKER	

Participaram do experimento proposto, neste trabalho, dois voluntários, denominados para referência nas seções de resultados como 1 e 2. O sujeito 1 não tinha conhecimento prévio sobre a área de BCI, enquanto o sujeito 2 já tinha participado de um experimento em outra ocasião. Os procedimentos envolvidos foram expostos detalhadamente para ambos os indivíduos, que consentiram em participar.

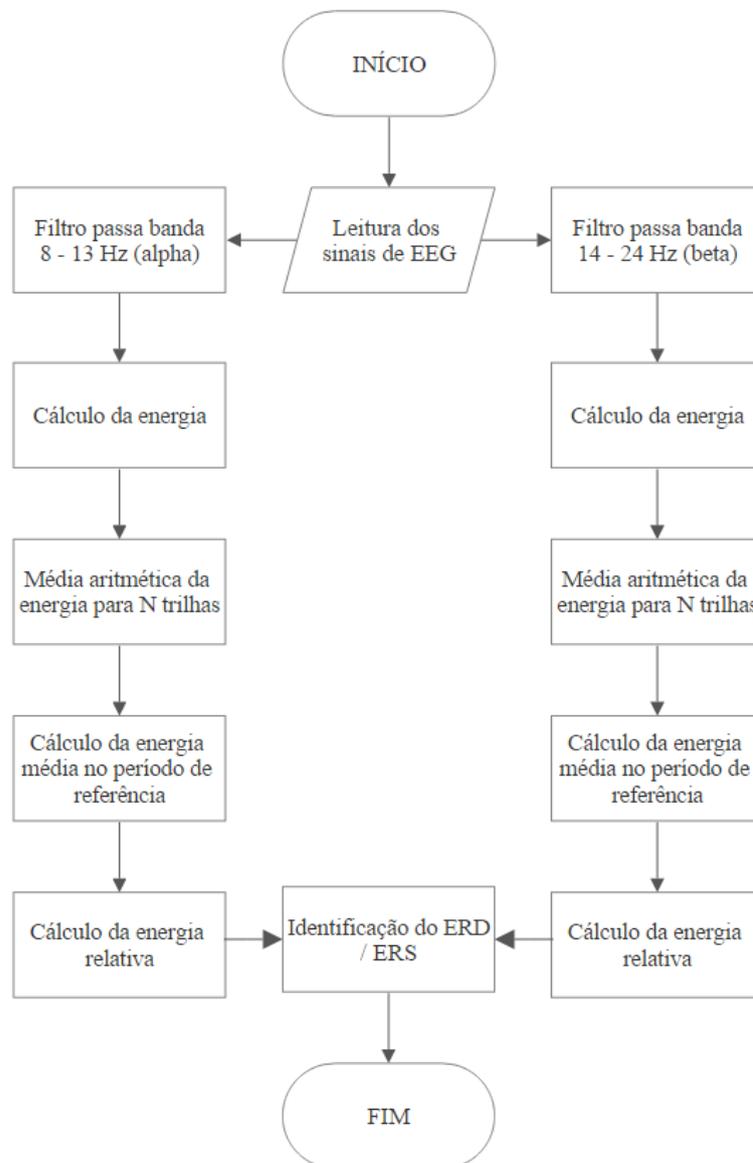
As aquisições foram divididas em duas sessões, realizadas em datas diferentes, compostas cada uma delas de 140 trilhas no formato adotado por (MACHADO, 2012) mais 140 trilhas no padrão utilizado em (BCI Competition, 2003), que está detalhadamente descrito na Seção 3.7. De forma a facilitar a referência a cada formato, primeiro é chamado de modelo de trilha 1 e o segundo é chamado de modelo de trilha 2 na seção de resultados. Cada sessão também foi particionada em 8 parcelas de 35 trilhas, totalizando as 280 nos dois padrões, de forma a permitir um período de descanso para os sujeitos, visto que o experimento exige concentração.

Os sinais adquiridos, neste trabalho, por definição inicial, não são investigados para descartar artefatos. Isto é, se um dos sujeitos acidentalmente mover algum músculo durante uma das trilhas do experimento, por exemplo, o que resulta em perturbações no sinal de EEG (artefato), aquela trilha não é removida da análise. Apesar de piorar as taxas de acerto de classificação dos movimentos, este tipo de abordagem busca proximidade com aplicações reais de sistemas BCI, onde o usuário pode eventualmente produzir artefatos na tentativa de utilizar o equipamento. Desta forma, sessões experimentais possivelmente contaminadas por artefatos são traduzidas em baixas taxas de acerto, mas não são descartadas do estudo. É importante ressaltar que não foram desenvolvidos métodos para minimização ou filtragem de artefatos em sinais de EEG.

3.3 Pré-processamento

O pré-processamento dos sinais de EEG consiste na separação dos ritmos α e β e no cálculo da energia relativa, como apresentado na Figura 7. O fluxograma da Figura 11 apresenta as etapas as quais os sinais são submetidos, que foi implementado no código do APÊNDICE D. Os filtros digitais utilizados são do tipo *Butterworth* de quarta ordem. A Figura 12 e a Figura 13 apresentam as respostas em frequência dos dois filtros passa banda implementados. Observe que as bandas de frequência para os ritmos α e β podem variar entre sujeitos, porém, de forma a possibilitar a comparação de resultados, as bandas escolhidas para filtragem são as mesmas utilizadas em (MACHADO, 2012).

Figura 11: Fluxograma das etapas de pré-processamento.



Portanto os sinais são, primeiramente, separados em ritmos α e β com os filtros passa banda. Para cada tipo de onda, avalia-se a energia ao longo do tempo para cada trilha e então se calcula a média aritmética para todas as trilhas que possuem o mesmo estímulo (isto é, um cálculo para a média de energia para estímulos para a esquerda e outro para estímulos para a direita). De posse da média aritmética de energia para todas as trilhas, para esquerda e direita, ao longo do tempo, calcula-se a energia média do período de referência e, finalmente, a energia relativa, como exposta na expressão da Equação (1).

Assim, o produto final das etapas de pré-processamento é a energia relativa da média de todas as trilhas dos sinais de EEG, separados em ritmos α e β e estímulos para esquerda e direita. Estas etapas são aplicadas aos canais de interesse do EEG, que então são apresentados graficamente para análise dos fenômenos de ERD e ERS.

Figura 12: Resposta em frequência do filtro α (8 – 13 Hz).

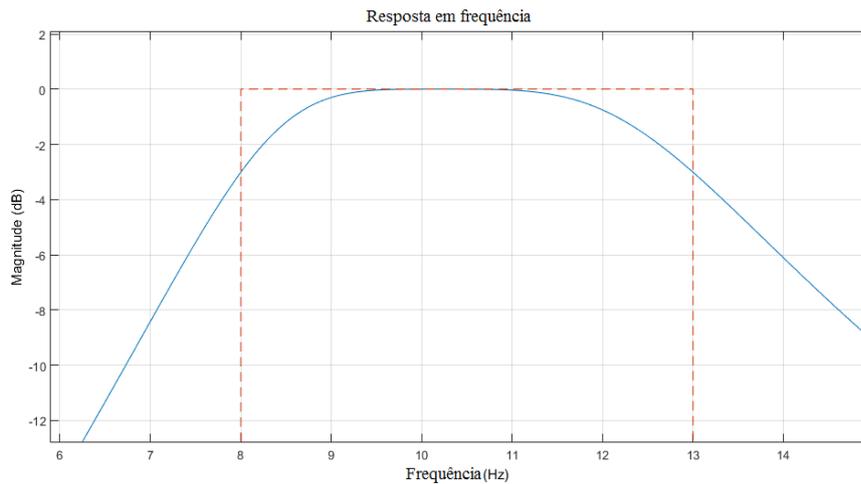
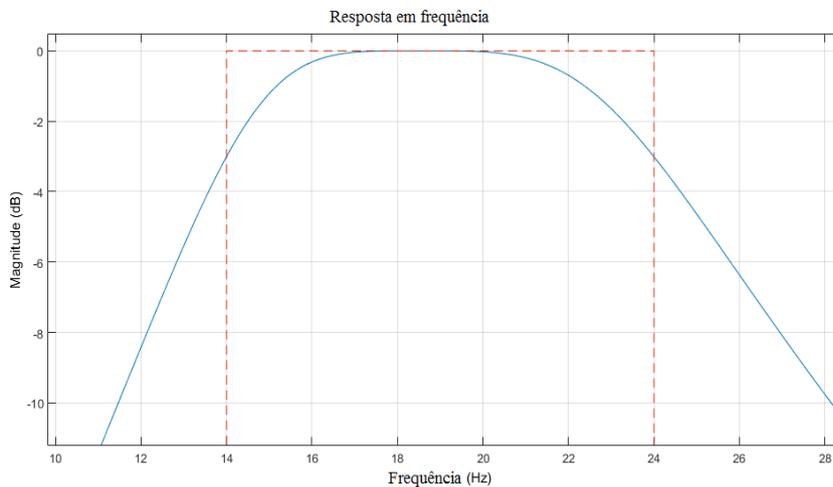


Figura 13: Resposta em frequência do filtro β (14 – 24 Hz).

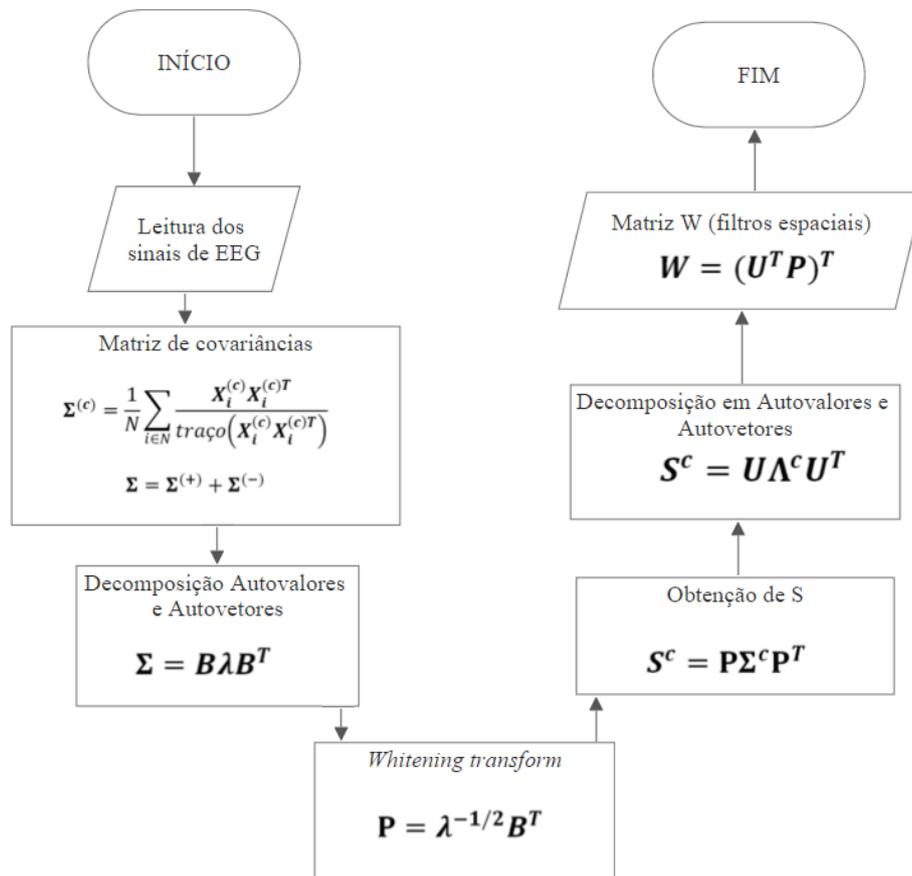


Os sinais são filtrados de maneira a não receberem contribuições de fase dos filtros, metodologia conhecida como *zero-phase filtering*, com a função *filtfilt* do MATLAB. Esta função, inicialmente, aplica o filtro normalmente, alterando a fase do sinal, e, então, aplica o filtro novamente em modo reverso, provendo uma contribuição de fase inversa em relação a primeira aplicação, cancelando as alterações de fase, mas mantendo as atenuações de amplitude (como descrito na documentação do *software* MATLAB).

3.4 Filtro *Common Spatial Pattern* (CSP)

As etapas para o desenvolvimento do filtro CSP, realizado em MATLAB (ver APÊNDICE G e H), estão apresentadas de acordo com o fluxograma da Figura 14. Observe que a Equação (4) é alterada de acordo com o proposto em (RAMOSER, MÜLLER-GERKING & PFURTSCHELLER, 2000) de forma a manter o padrão utilizado em (MACHADO, 2012), para permitir a comparação dos resultados. A função traço é a soma de todos os elementos da diagonal principal.

Figura 14: Etapas para a obtenção do filtro CSP.



A obtenção da matriz W , que possui j colunas (sendo cada uma delas um filtro espacial), inicia-se, então, com o cálculo das matrizes de covariância nas duas condições (trilhas para esquerda e para direita) e da matriz composta de covariância (soma da condição positiva e negativa). A matriz de covariância composta é então decomposta em seus autovetores (B) e autovalores (λ). Aplica-se a *whitening transform* para geração da matriz P , que é utilizada junto com as matrizes de covariância para cada condição para calcular S , também em cada condição. Finalmente, decompõe-se S (para cada condição) em seus respectivos autovetores (U) e autovalores (Λ) e utiliza-se U e P para obter W . Observe que os autovetores (U) são iguais para as duas condições, como descrito na Seção 2.5.

Após calcular W , realiza-se a análise da matriz de autovalores (Λ) para cada condição. Os maiores valores desta matriz diagonal indicam quais canais fazem maior distinção entre as classes de movimento (RAMOSER, MÜLLER-GERKING & PFURTSCHHELLER, 2000). Assim, baseado em quais colunas de Λ apresentam os maiores autovalores, escolhe-se as duas colunas de W correspondentes. A multiplicação destas duas colunas pela matriz de sinais X gera os dois novos canais, baseados na recombinação dos canais originais (BLANKERTZ *et al.*, 2008).

Todas as decomposições são realizadas através da função “*eig*” do MATLAB, que retorna os autovalores e autovetores de uma matriz. Os canais utilizados em (MACHADO, 2012) para determinação do filtro espacial foram C3, C4, P3 e P4. Na touca EMOTIV, como pode ser visto na Figura 6, não existem eletrodos nestas posições. Um dos objetivos deste trabalho é, justamente, fazer uma análise preliminar dos resultados obtidos com esta touca, utilizando os eletrodos disponíveis. Assim, foram escolhidas as posições FC5, FC6, P7 e P8 para substituir C3, C4, P3 e P4, respectivamente. Porém, é importante ressaltar que existe diferença espacial no posicionamento dos eletrodos, no escalpo do sujeito, entre a touca EMOTIV e a touca utilizada em (MACHADO, 2012).

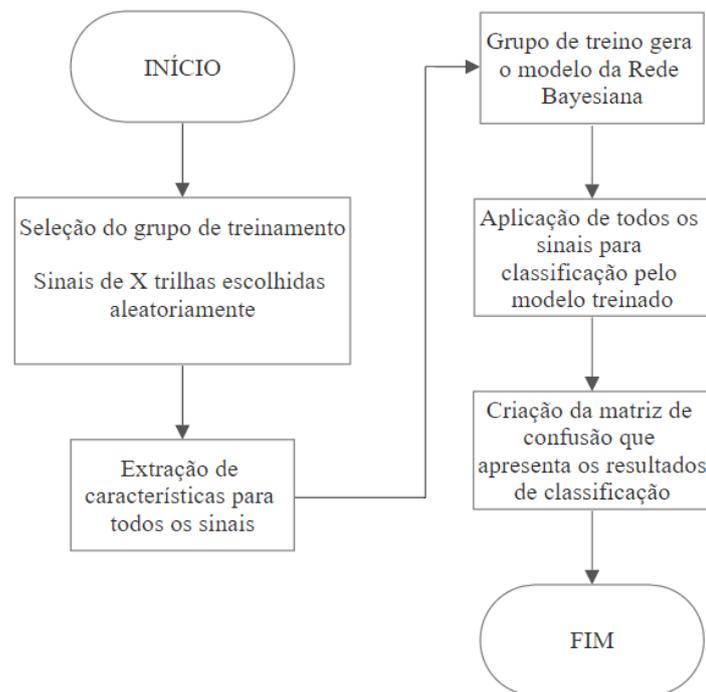
3.5 Classificador *Naive Bayes*

O classificador *Naive Bayes*, descrito na Seção 2.6, é desenvolvido em MATLAB pela função “*fitNaiveBayes*”. Esta função tem como argumentos as variáveis que contém as características usadas para classificação e as classes (neste caso movimento da mão esquerda e direita) que são usadas para treinar o modelo. Através do método “*predict*” do objeto retornado pela função, pode-se fazer a classificação para uma série de dados fornecidos. Para visualização dos resultados, a função “*confusionmat*” exibe a quantidade de acertos e erros na

classificação. Assim, o classificador é treinado com uma parcela dos dados e usado para classificar a totalidade destes.

A Figura 15 apresenta o fluxograma com as etapas de classificação. Primeiro um grupo de amostras de treinamento é selecionado aleatoriamente do total de trilhas. As características escolhidas para a classificação são, então, extraídas de todos os sinais (para a totalidade de trilhas). Usando o grupo de treino, o modelo da rede Bayesiana é criado com a função *fitNaiveBayes*. Com o modelo construído, realiza-se a classificação de todas as trilhas e, finalmente, exibe-se os resultados através de uma matriz de confusão, que indica quantas amostras foram associadas à classe correta.

Figura 15: Fluxograma para a classificação dos sinais.



A obtenção dos resultados é feita através da execução repetida 100 vezes do algoritmo descrito na Figura 15, mantendo o padrão empregado em (MACHADO, 2012). O produto final é a média aritmética e o desvio padrão do conjunto de taxas de acertos obtidas nas 100 execuções. A Figura 16 apresenta um exemplo de matriz de confusão, que é obtida após uma execução do algoritmo. As linhas desta matriz são as classes verdadeiras dos sinais, ou seja, a informação prévia sobre qual classe cada sinal pertence. As colunas são as classes previstas para os sinais pelo classificador desenvolvido. Assim, as taxas de acertos, para cada classe, são os elementos da diagonal principal, divididos pela soma total da sua respectiva linha (FUKUNAGA, 1990).

Figura 16: Exemplo de matriz de confusão.

		Classe prevista	
		1	2
Classe verdadeira	1	100	0
	2	19	81

Fonte: Adaptado de FUKUNAGA, 1990.

3.6 Extração de Características

Todos os sinais são filtrados entre 8 e 24 Hz para a extração de características, mantendo o padrão utilizado em (MACHADO, 2012). As características extraídas dos sinais de EEG para a classificação são: valor RMS, variância e os valores obtidos pela Equação (15). A característica da Equação (15) utiliza o filtro espacial CSP como apresentado em (BLANKERTZ *et al.*, 2008), onde \mathbf{W} é a matriz de filtros espaciais e \mathbf{X} é a matriz com os sinais para cada canal, como descrito na Seção 2.5.

$$característica_i = \log(\mathbf{W}_i^T \mathbf{X}^T \mathbf{X} \mathbf{W}_i) \quad (15)$$

Para a classificação, as características são extraídas em diferentes janelas dos sinais originais, visto que a resolução temporal pode alterar o seu desempenho (MENG *et al.*, 2012), no mesmo modelo de (MACHADO, 2012) para comparação. A Tabela 3 apresenta as janelas utilizadas para extração de características para o experimento proposto, e a Tabela 4 para o banco de dados do BCI *Competition*.

Os resultados são obtidos de duas maneiras: com e sem o uso do filtro CSP. Desta maneira, quando em uso o filtro CSP, todas as características são utilizadas na classificação, enquanto, quando não em uso o filtro CSP, apenas valor RMS e variância são aplicados à rede Bayesiana. Portanto, nas seções de resultados, todas as tabelas possuem as taxas de acerto para classificação dos movimentos imaginários, com e sem o filtro CSP, para todas as diferentes janelas apresentadas. Isto permite observar a influência da resolução temporal para a extração de características e do uso do filtro espacial.

Tabela 3: Janelas utilizadas para a extração das características no experimento proposto com a touca EMOTIV.

Janela	Início (s)	Fim (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
W ₇	4,1	5,0
W ₈	4,2	5,0
W ₉	4,3	5,0
W ₁₀	4,4	5,0

Tabela 4: Janelas utilizadas para a extração das características no BCI *Competition*.

Janela	Início (s)	Fim (s)
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

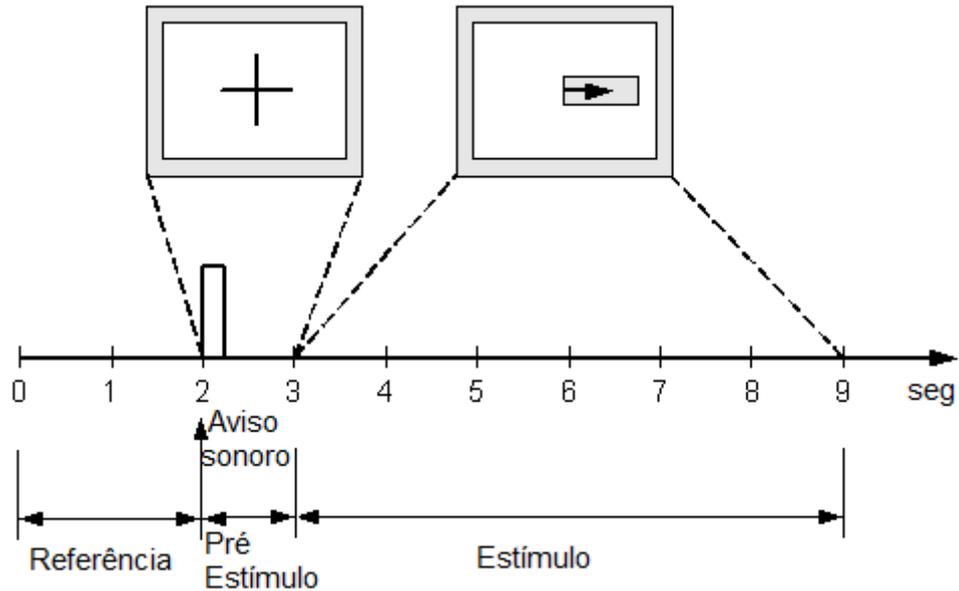
Os códigos que contém a aplicação das janelas, extração de características e implementação do classificador estão apresentados nos APÊNDICE G, H, I, K e L.

3.7 BCI *Competition*

O banco de dados da BCI *Competition*, gerado pelo Instituto de Engenharia Biomédica da Universidade de Graz (BCI *Competition*, 2003) é também analisado, neste trabalho, de forma a produzir resultados que possam ser comparados aos obtidos com os dados adquiridos com a touca EMOTIV. Neste experimento, um sujeito feminino foi exposto a uma série de 140 trilhas com duração de 9 segundos. Estas trilhas possuem um período de

referência, um período pré-estímulo antecedido por um aviso sonoro e o estímulo (BCI Competition, 2003). A Figura 17 apresenta a composição de cada trilha para o caso de um estímulo para a direita.

Figura 17: Estrutura das trilhas utilizadas no BCI Competition II.



Fonte: Adaptado de BCI Competition II, 2003.

A tarefa do sujeito ao experimento foi imaginar o movimento das mãos esquerda e direita de acordo com o estímulo aleatório apresentado. Foram salvos, em um banco de dados do MATLAB, os sinais de três eletrodos (C3, Cz e C4) para as 140 trilhas. Cada um destes foi filtrado entre 0,5 e 30 Hz e adquirido com uma frequência de amostragem de 128 Hz.

4. RESULTADOS E DISCUSSÕES

Para cada sujeito do experimento, para cada modelo de trilha e para cada sessão, foram gerados os resultados de pré-processamento, processamento e classificação. De forma a não sobrecarregar o texto com imagens, curvas mais representativas são apresentadas nas próximas seções, enquanto o restante dos resultados é apresentado nos anexos.

4.1 Pré-Processamento

4.1.1 Experimento realizado com a touca EMOTIV

Os sinais dos canais selecionados para a classificação foram submetidos às etapas de pré-processamento. Os gráficos da Figura 18 até a Figura 25 mostram a energia relativa obtida para as duas classes de movimento, para os ritmos α e β , para os canais FC5, FC6, P7 e P8, para o sujeito número 1, para o modelo de trilha 1, para a sessão 1.

A energia relativa, para o experimento proposto, é calculada utilizando o período de referência de 0 a 1,5 segundos. O período de estímulo, onde se espera encontrar os fenômenos do ERD, é de 3 até 6 segundos.

A Figura 26 apresenta um exemplo dos resultados intermediários do pré-processamento, nos mesmos moldes da Figura 7, para uma trilha selecionada. Em (a), tem-se os sinais de EEG, antes de qualquer processamento, que são filtrados nas bandas dos ritmos α e β resultando em (b). Em (c), calcula-se a energia do sinal para cada trilha para, então, fazer a média aritmética das N trilhas totais em (d). Finalmente, a energia relativa é apresentada em (e).

Figura 18: Energia relativa do canal FC5 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 1.

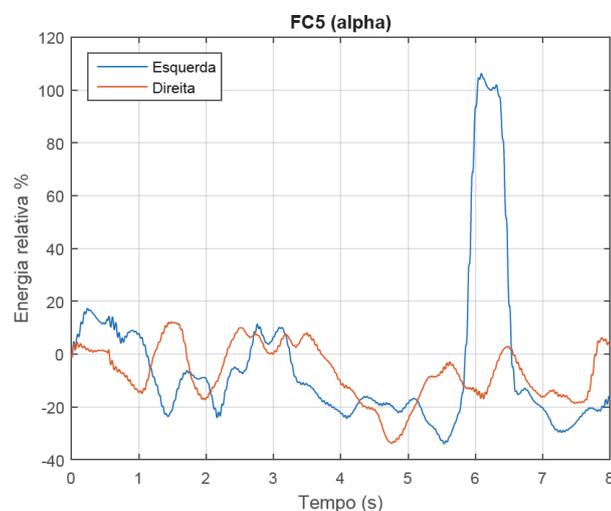


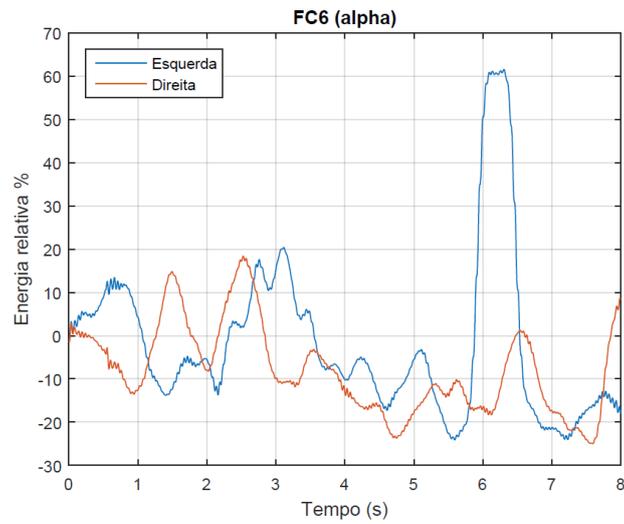
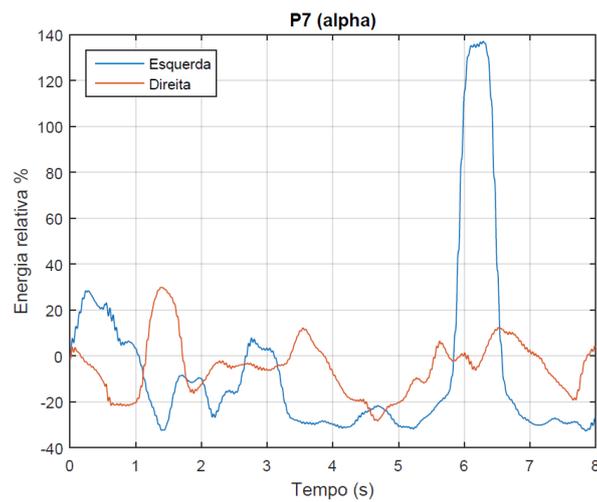
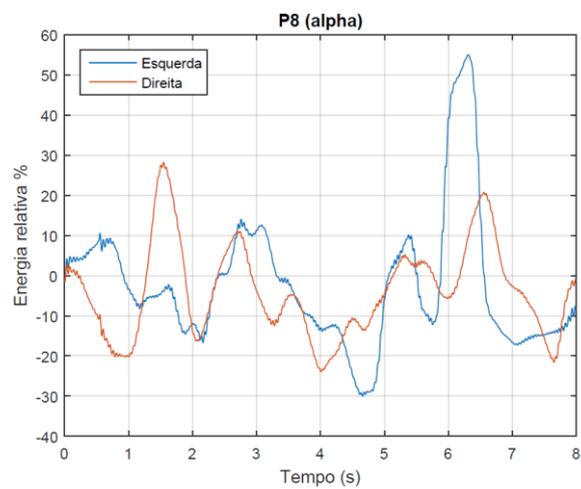
Figura 19: Energia relativa do canal FC6 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 1.Figura 20: Energia relativa do canal P7 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 1.Figura 21: Energia relativa do canal P8 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 1.

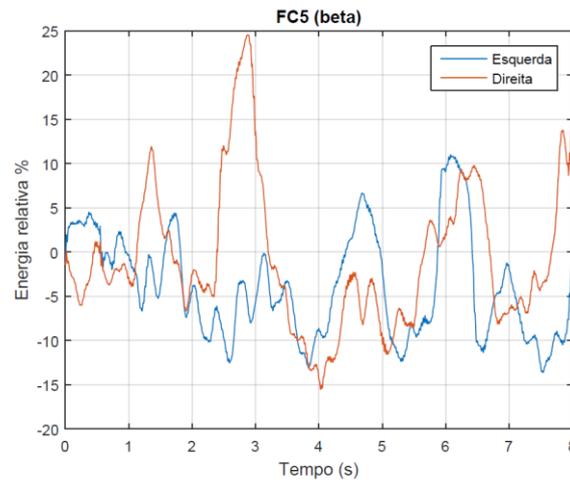
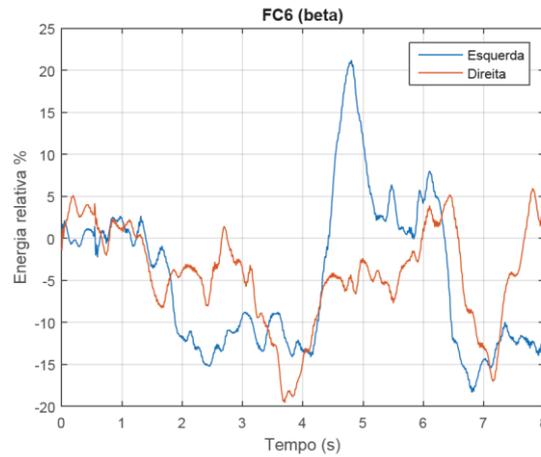
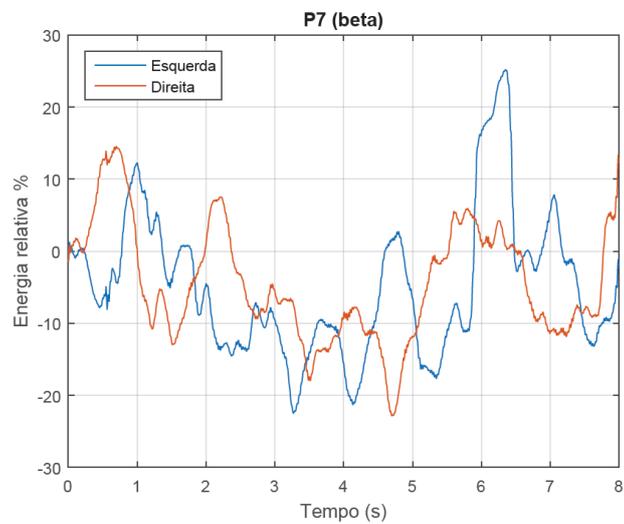
Figura 22: Energia relativa do canal FC5 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 1.Figura 23: Energia relativa do canal FC6 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 1.Figura 24: Energia relativa do canal P7 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 1.

Figura 25: Energia relativa do canal P8 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 1.

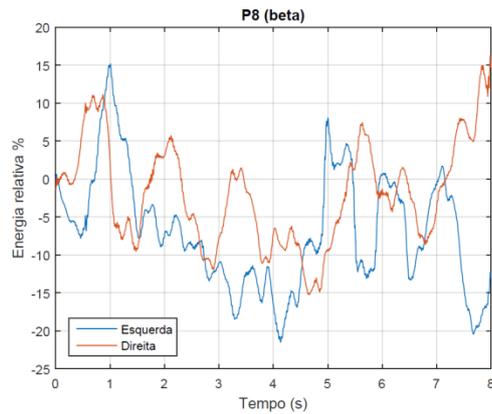
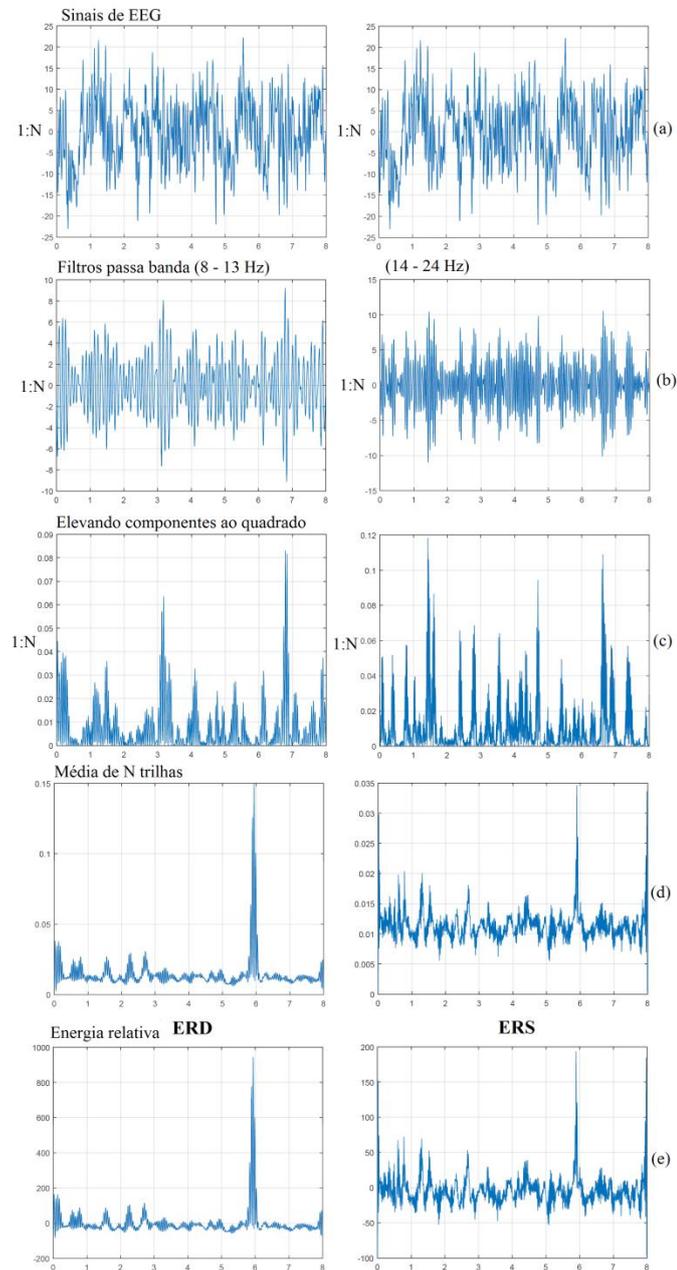


Figura 26: Resultados intermediários do pré-processamento.



Pode-se verificar a presença de artefatos nos sinais adquiridos, por exemplo, na Figura 18, onde se observa um pico de energia em aproximadamente 6 segundos. Este tipo de resposta ocorre quando o sujeito executa uma ação que cause maior variação nos sinais, como o movimento acidental de um membro, ou piscar os olhos. Estes picos de energia causam alteração da média de energia para todas as trilhas, o que pode dificultar a visualização do ERD nas curvas. A definição inicial deste trabalho é de não descartar trilhas que possuam artefatos, portanto estes acidentes vêm a afetar as taxas de acerto em classificação, mas não são excluídos da análise.

Da Figura 27 até a Figura 34, tem-se uma série de gráficos nos mesmos padrões que os apresentados até aqui, nesta seção, para o modelo de trilha 2, para a sessão 1, de forma a exemplificar os resultados de pré-processamento para o segundo modelo de trilha.

Figura 27: Energia relativa do canal FC5 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 1.

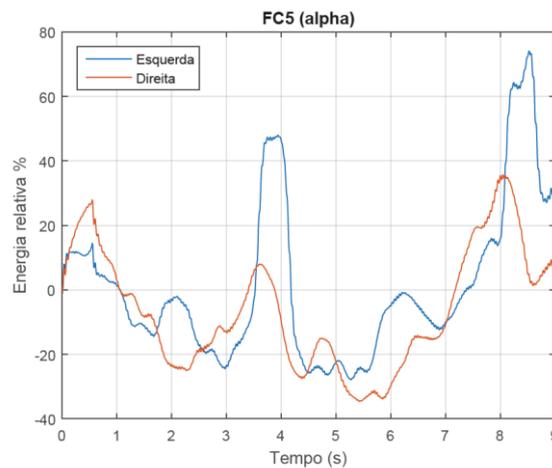


Figura 28: Energia relativa do canal FC6 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 1.

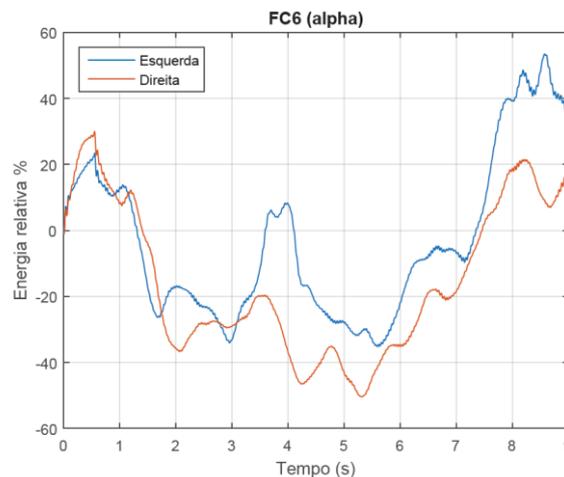


Figura 29: Energia relativa do canal P7 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 1.

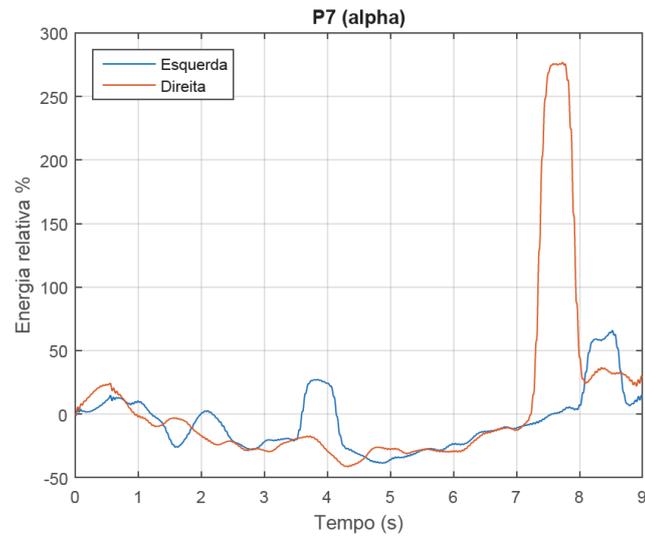


Figura 30: Energia relativa do canal P8 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 1.

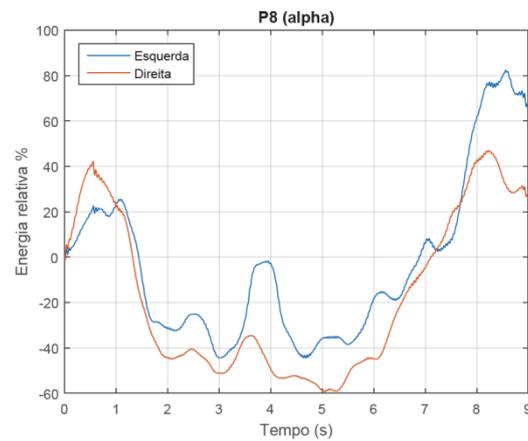


Figura 31: Energia relativa do canal FC5 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 1.

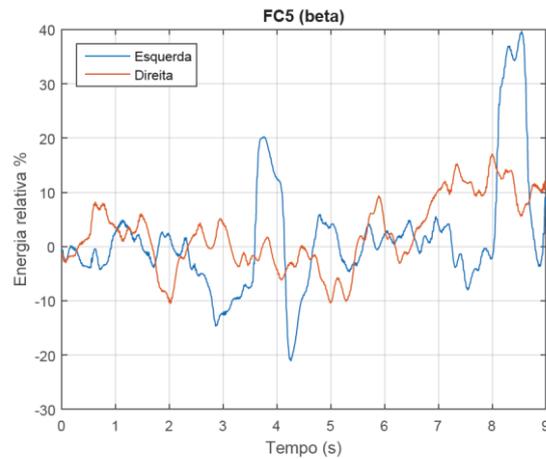
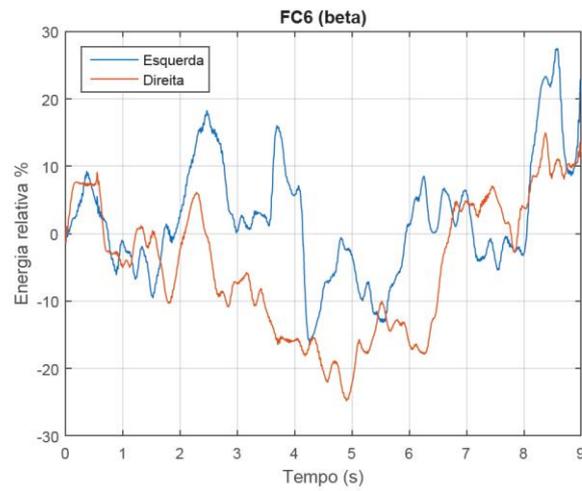
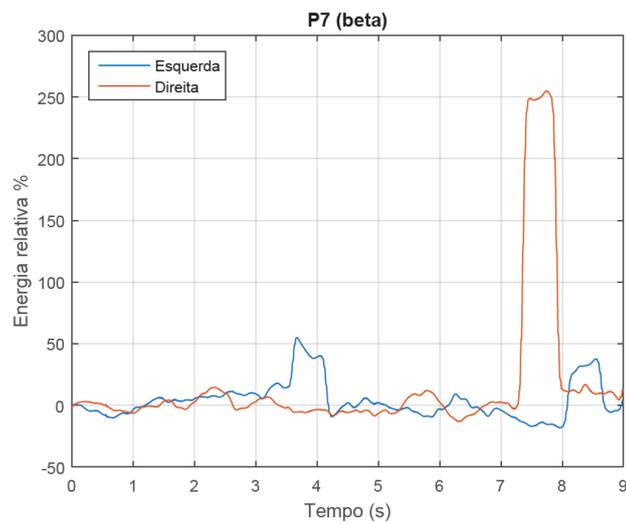
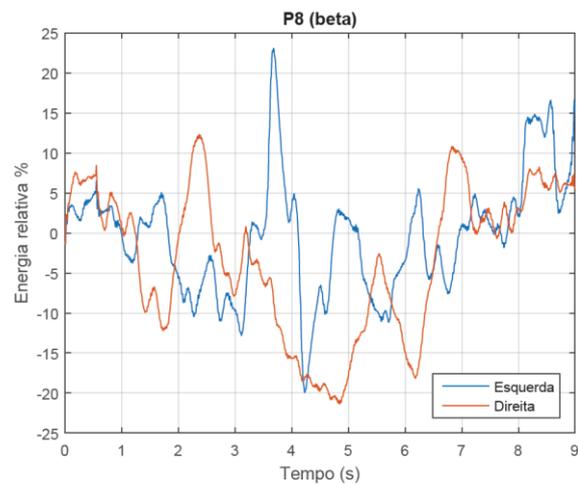


Figura 32: Energia relativa do canal FC6 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 1.Figura 33: Energia relativa do canal P7 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 1.Figura 34: Energia relativa do canal P8 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 1.

Nos resultados do modelo de trilha 2, sessão 1, também foram encontrados alguns artefatos, que, novamente, prejudicam a identificação do ERD e diminuem as taxas de acerto em classificação, mas não são removidos da análise neste estudo. Observe que o ERD também pode ser encontrado nos ritmos β , apesar de não ser tão acentuado quanto nos ritmos α , o que fica mais claro ao visualizar a energia média dos sinais no domínio da frequência (Seção 4.2).

Os índices de lateralização correspondentes para as duas séries de resultados apresentados (modelo de trilha 1 e 2, sessão 1, sujeito 1), estão apresentados na Figura 35 e na Figura 36, respectivamente.

Figura 35: Índice de lateralização para o modelo de trilha 1, sessão 1, sujeito 1.

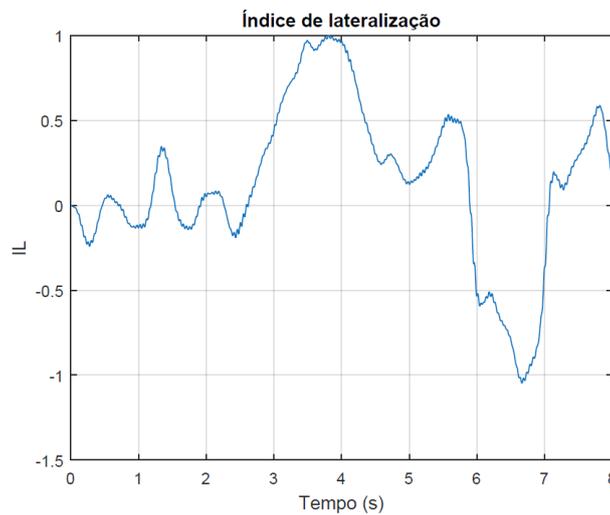
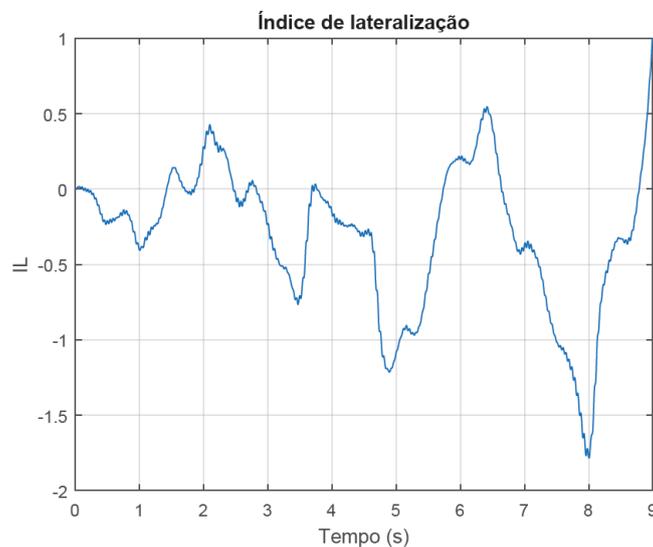


Figura 36: Índice de lateralização para o modelo de trilha 2 sessão 1 sujeito 1



Nos intervalos de 3 a 5 segundos para modelo de trilha 1 (Figura 35), pode-se verificar o valor de pico para o índice de lateralização. Para o modelo de trilha 2, não foi identificado o maior valor do índice de lateralização, dentro do mesmo intervalo. Ele indica o quão grande é a diferença de energia entre os lados do cérebro, como descrito na Seção 2.4.2, portanto se espera que os maiores valores aconteçam quando há mais atividade discriminativa, após a apresentação do estímulo.

Observe que os artefatos causam variações no IL que não correspondem à distinção entre as duas classes de movimento. Este problema se torna mais evidente ao comparar os resultados obtidos no experimento proposto com os obtidos no banco de dados BCI *Competition* (Seção 4.1.2), nos quais as trilhas com artefatos foram descartadas.

4.1.2 BCI *Competition* II

Os sinais do banco de dados da BCI *Competition* II foram submetidos às etapas de pré-processamento adotadas neste trabalho. Da Figura 37 até a Figura 42, são apresentados os resultados obtidos no pré-processamento para cada canal utilizado (C3, Cz e C4), para os ritmos α e β , para as trilhas para a esquerda e para a direita.

Figura 37: Energia relativa do canal C3 para as trilhas para a direita e esquerda (ritmos α).

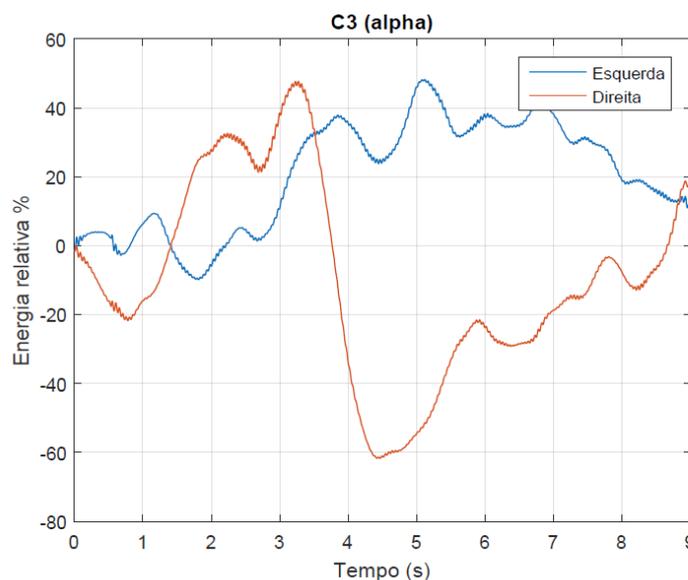


Figura 38: Energia relativa do canal Cz para as trilhas para a direita e esquerda (ritmos α).

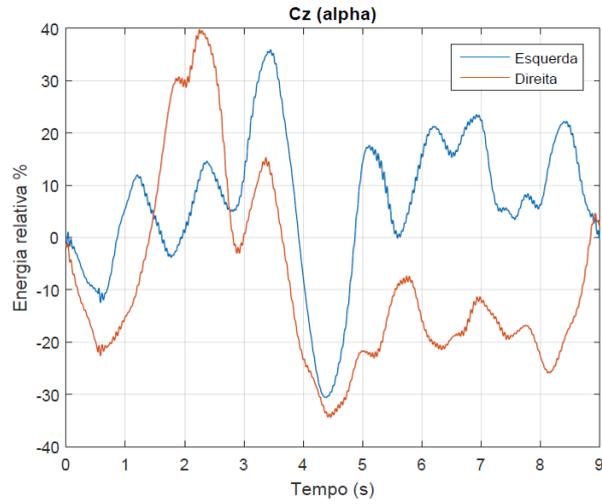


Figura 39: Energia relativa do canal C4 para as trilhas para a direita e esquerda (ritmos α).

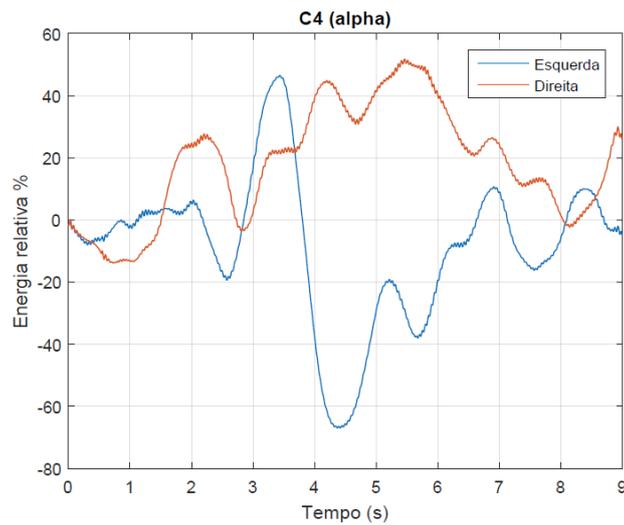


Figura 40: Energia relativa do canal C3 para as trilhas para a direita e esquerda (ritmos β).

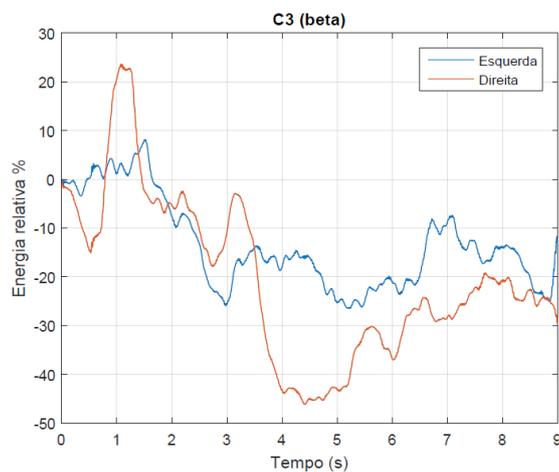


Figura 41: Energia relativa do canal Cz para as trilhas para a direita e esquerda (ritmos β).

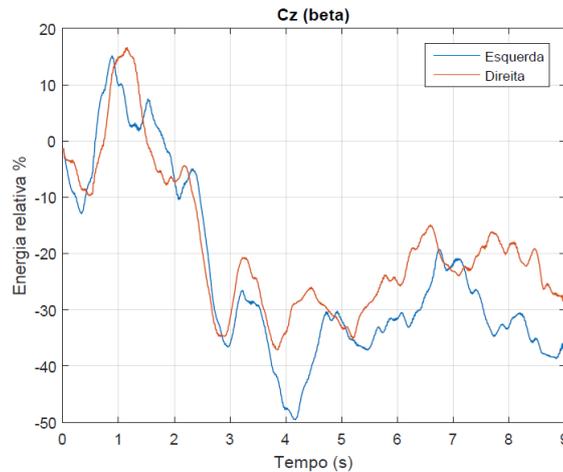
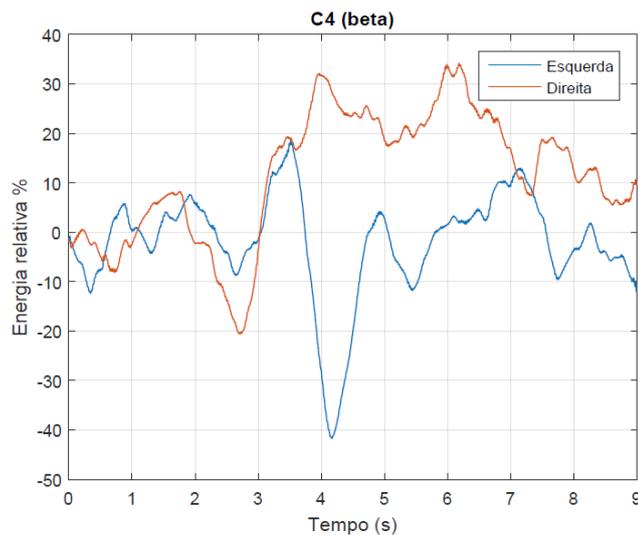


Figura 42: Energia relativa do canal C4 para as trilhas para a direita e esquerda (ritmos β).

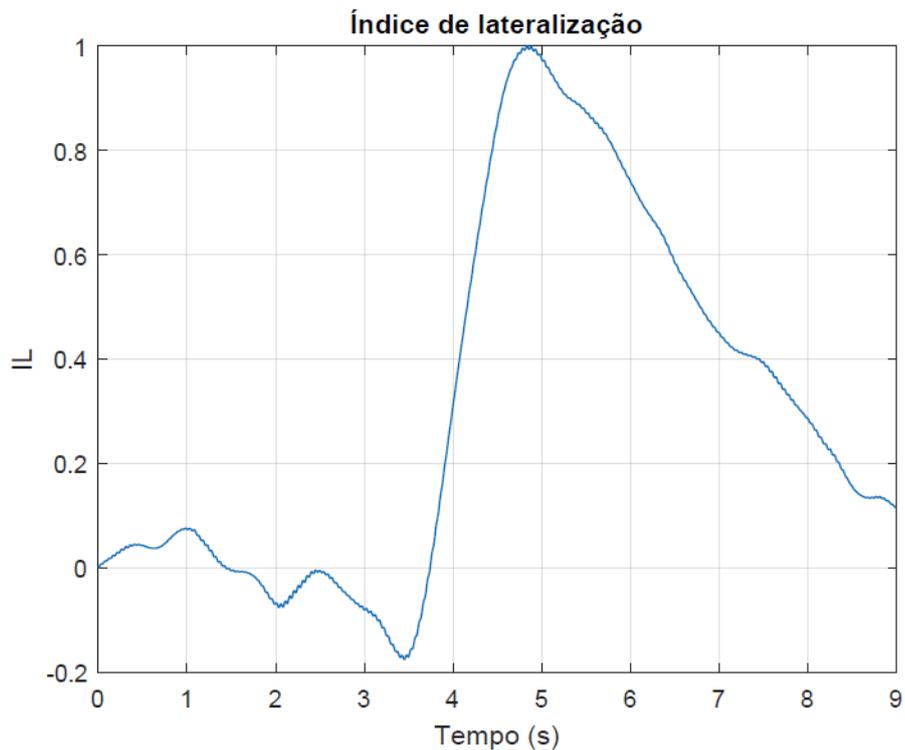


É possível observar, no gráfico da Figura 37, o fenômeno do ERD para estímulos para a direita e, no gráfico da Figura 39, para a esquerda, entre 3 e 5 segundos. Os sinais do banco de dados, sem artefatos, adquiridos em um sistema com realimentação para o usuário (indicações de que a imaginação do movimento está sendo realizada de forma correta que são exibidas durante a aquisição), permitem uma clara distinção entre as classes de movimento. A qualidade destes sinais acarreta taxas de acerto de classificação mais altas em relação aos dados adquiridos no experimento proposto.

O índice de lateralização está apresentado na Figura 43. Nesta figura, é possível visualizar a diferença de energia entre os dois hemisférios do cérebro, onde seu valor máximo

é atingido no intervalo de 3 a 5 segundos. Como citado na Seção 4.1.1, observa-se a vantagem de analisar um conjunto de sinais que não possuem artefatos. O IL apresenta um comportamento suave, sem picos que não possuem correspondência com a atividade discriminativa do indivíduo.

Figura 43: Índice de lateralização para o BCI *Competition II*



4.2 Filtro *Common Spatial Pattern* (CSP)

Nesta etapa, foram obtidos os filtros espaciais para cada reprodução do experimento, analisando as matrizes de autovalores Λ e calculando os dois novos canais que buscam maximizar a distinção entre classes. Os espectros de frequência também foram obtidos para estes canais, de forma a analisar a diferença de energia entre as classes.

4.2.1 Experimento proposto com a touca EMOTIV

Para o experimento proposto, o filtro CSP foi obtido utilizando os canais FC5, FC6, P7 e P8. As matrizes de autovalores Λ , nas duas condições (esquerda e direita), estão apresentadas para os experimentos do sujeito 1, sessão 1, modelos de trilha 1, nas Equações (16) e (17) e modelos de trilha 2, nas Equações (18) e (19).

$$\Lambda^d = \begin{bmatrix} 0,5425 & 0 & 0 & 0 \\ 0 & 0,5123 & 0 & 0 \\ 0 & 0 & 0,4867 & 0 \\ 0 & 0 & 0 & 0,4829 \end{bmatrix} \quad (16)$$

$$\Lambda^e = \begin{bmatrix} 0,4575 & 0 & 0 & 0 \\ 0 & 0,4877 & 0 & 0 \\ 0 & 0 & 0,5133 & 0 \\ 0 & 0 & 0 & 0,5171 \end{bmatrix} \quad (17)$$

$$\Lambda^d = \begin{bmatrix} 0,4688 & 0 & 0 & 0 \\ 0 & 0,5227 & 0 & 0 \\ 0 & 0 & 0,5129 & 0 \\ 0 & 0 & 0 & 0,5037 \end{bmatrix} \quad (18)$$

$$\Lambda^e = \begin{bmatrix} 0,5312 & 0 & 0 & 0 \\ 0 & 0,4773 & 0 & 0 \\ 0 & 0 & 0,4871 & 0 \\ 0 & 0 & 0 & 0,4963 \end{bmatrix} \quad (19)$$

Observe que os autovalores que mais causam distinção entre as classes estão nas colunas 1 e 2, correspondentes aos canais FC5 e FC6, que são os mais próximos dos canais C3 e C4. Baseado nestes autovalores, foram escolhidas as colunas da matriz W e os novos canais CSP foram obtidos. Da Figura 44 até a Figura 47, tem-se a energia média dos canais CSP no domínio da frequência. É importante ressaltar que os artefatos são uma fonte de aumento de energia do sinal, e podem contaminar esta análise em frequência.

Figura 44: Espectro de frequência do canal CSP1 sujeito 1 sessão 1 trilha 1.

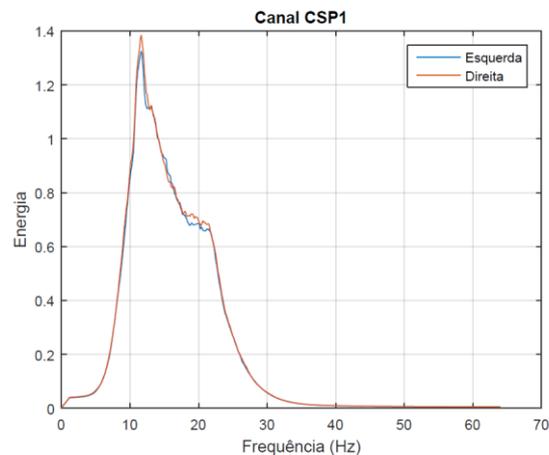


Figura 45: Espectro de frequência do canal CSP2 sujeito 1 sessão 1 trilha 1.

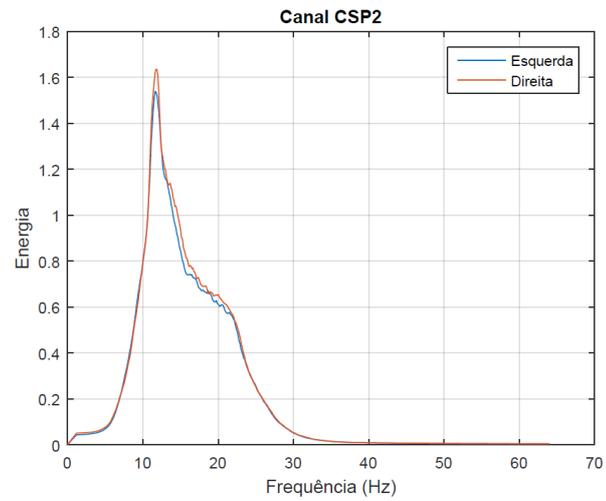


Figura 46: Espectro de frequência do canal CSP1 sujeito 1 sessão 1 trilha 2.

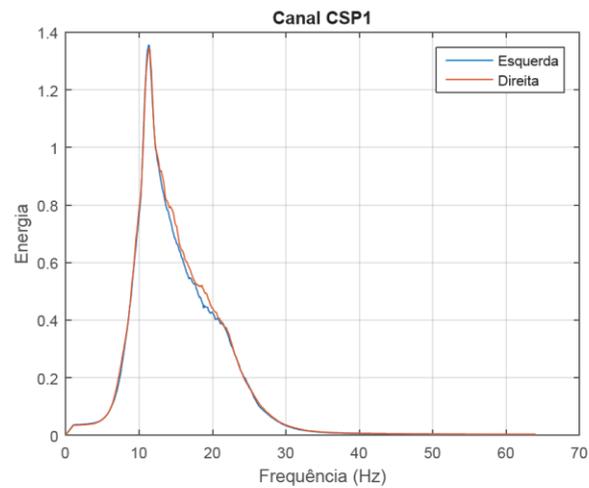
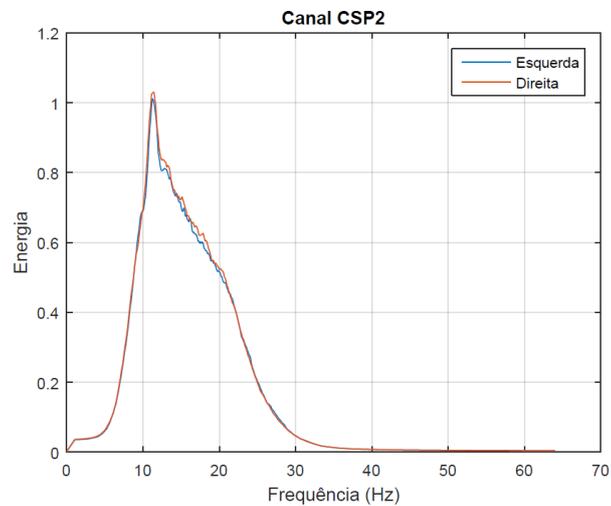


Figura 47: Espectro de frequência do canal CSP2 sujeito 1 sessão 1 trilha 2.



Principalmente em torno de 10 Hz, na banda dos ritmos α , pode-se identificar uma diferença de energia entre as classes de movimento. A distinção não acontece muito acentuadamente para os ritmos β e, portanto, para este sujeito, o uso apenas da banda α poderia beneficiar os resultados de classificação. No entanto, de maneira a possibilitar a comparação com os resultados obtidos em (MACHADO, 2012), mantém-se a banda β na análise.

4.2.2 BCI Competition II

As matrizes de autovalores Λ para o banco de dados do BCI *Competition* apresentaram os maiores valores de distinção entre as classes para os canais C3 e C4. As Equações (20) e (21) apresentam as matrizes nas condições direita e esquerda, respectivamente.

$$\Lambda^d = \begin{pmatrix} 0,7039 & 0 & 0 \\ 0 & 0,4820 & 0 \\ 0 & 0 & 0,3146 \end{pmatrix} \quad (20)$$

$$\Lambda^e = \begin{pmatrix} 0,2961 & 0 & 0 \\ 0 & 0,5180 & 0 \\ 0 & 0 & 0,6854 \end{pmatrix} \quad (21)$$

Assim, analisando os autovalores, as colunas da matriz W escolhidas para gerar os novos canais CSP são 1 e 3. Os gráficos da Figura 48 e da Figura 49 apresentam a energia média no domínio da frequência para os novos canais. Observe que, nos sinais livres de artefatos do banco de dados, pode-se visualizar a distinção entre as classes mais facilmente do que no experimento proposto. A energia entre as bandas α e β , intervalo entre aproximadamente 11 e 18 Hz, é inferior em relação aos intervalos de interesse. Isto é um indicativo de que se está analisando somente componentes relativos à atividade discriminativa, e não respostas provenientes de outras fontes.

Figura 48: Espectro de frequência do canal CSP1 BCI *Competition*.

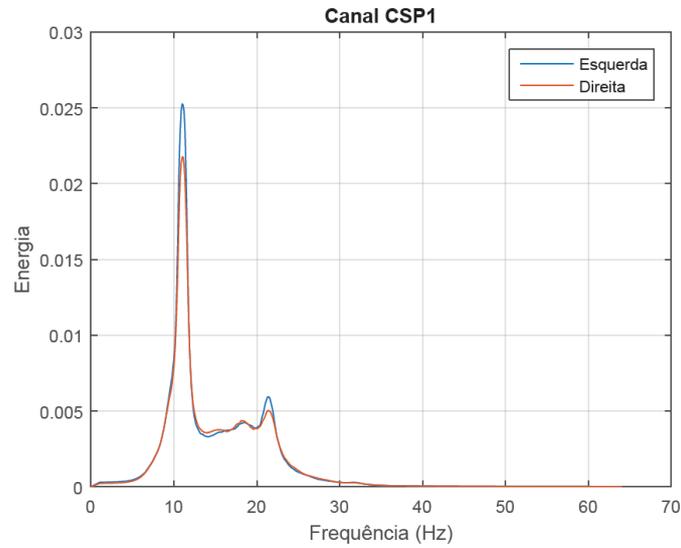
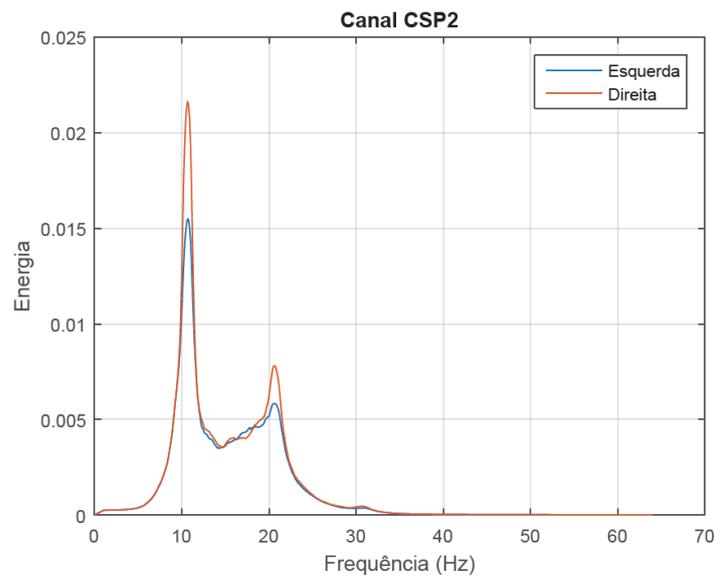


Figura 49: Espectro de frequência do canal CSP2 BCI *Competition*.



4.3 Classificador

Os modelos classificadores *Naive Bayes* foram treinados com amostras de metade da totalidade dos dados, sendo estas selecionadas aleatoriamente. Depois de obtido o modelo, a totalidade dos dados foi submetida à classificação, como detalhado na Seção 3.5. As janelas de tempo para quais são exibidos os resultados estão descritas na Seção 3.6.

4.3.1 Experimento proposto com a touca EMOTIV

Os resultados de classificação, em termos da taxa de acerto média para as 100 execuções do algoritmo, estão apresentados da Tabela 5 até a Tabela 8. Para todas as reproduções do experimento, a aplicação do filtro CSP acarretou uma melhora nas taxas de acerto. Os melhores resultados foram obtidos pelo sujeito 1, na sessão 1, para o modelo de trilha 2, atingindo o máximo de 79,4 % de acerto.

Tabela 5: Resultados para a classificação Sujeito 1 modelo de trilha 1.

	Taxa de acerto média \pm Desvio padrão (%)			
	Sessão 1		Sessão 2	
Janela	(Sem filtro CSP)	(Com filtro CSP)	(Sem filtro CSP)	(Com filtro CSP)
W₁	51,1 \pm 2,3	54,0 \pm 3,9	51,1 \pm 3,6	52,5 \pm 4,2
W₂	51,8 \pm 2,4	53,3 \pm 3,7	50,5 \pm 2,1	52,3 \pm 2,9
W₃	51,6 \pm 2,0	54,7 \pm 2,9	51,1 \pm 2,6	52,0 \pm 4,3
W₄	50,9 \pm 2,7	54,3 \pm 3,4	52,9 \pm 2,7	53,0 \pm 3,9
W₅	50,2 \pm 2,8	54,0 \pm 3,2	53,2 \pm 2,8	54,3 \pm 3,9
W₆	50,2 \pm 2,5	54,2 \pm 4,1	52,4 \pm 1,9	55,1 \pm 4,6
W₇	50,6 \pm 2,4	52,8 \pm 4,5	52,8 \pm 3,0	53,4 \pm 4,5
W₈	52,5 \pm 2,0	52,8 \pm 4,4	54,2 \pm 1,6	52,9 \pm 3,6
W₉	52,6 \pm 1,4	51,6 \pm 4,2	54,1 \pm 2,6	54,6 \pm 3,0
W₁₀	53,4 \pm 2,2	51,7 \pm 4,3	55,8 \pm 2,3	56,2 \pm 2,7

Tabela 6: Resultados para a classificação Sujeito 2 modelo de trilha 1.

	Taxa de acerto média \pm Desvio padrão (%)			
	Sessão 1		Sessão 2	
	(Sem filtro CSP)	(Com filtro CSP)	(Sem filtro CSP)	(Com filtro CSP)
Janela				
W₁	53,0 \pm 3,5	64,2 \pm 5,0	51,6 \pm 2,3	55,4 \pm 3,4
W₂	52,5 \pm 2,1	62,4 \pm 5,0	52,0 \pm 2,7	56,2 \pm 2,5
W₃	52,4 \pm 2,5	62,2 \pm 4,4	50,9 \pm 1,7	57,0 \pm 2,1
W₄	50,4 \pm 1,7	62,4 \pm 3,7	49,1 \pm 1,9	57,4 \pm 3,1
W₅	50,8 \pm 1,2	63,1 \pm 4,3	50,4 \pm 1,7	59,5 \pm 2,7
W₆	50,6 \pm 1,7	62,3 \pm 4,0	51,2 \pm 2,0	60,1 \pm 2,0
W₇	52,8 \pm 3,2	61,7 \pm 4,7	50,8 \pm 1,7	59,3 \pm 2,2
W₈	53,1 \pm 2,9	62,6 \pm 4,2	51,2 \pm 1,5	57,8 \pm 2,6
W₉	53,3 \pm 3,3	62,3 \pm 5,4	52,9 \pm 2,5	58,4 \pm 1,9
W₁₀	53,8 \pm 2,4	61,9 \pm 5,4	52,6 \pm 1,9	55,3 \pm 2,1

Tabela 7: Resultados para a classificação Sujeito 1 modelo de trilha 2.

	Taxa de acerto média \pm Desvio padrão (%)			
	Sessão 1		Sessão 2	
	(Sem filtro CSP)	(Com filtro CSP)	(Sem filtro CSP)	(Com filtro CSP)
Janela				
W₁	51,9 \pm 2,8	79,4 \pm 3,2	53,5 \pm 2,1	70,1 \pm 8,0
W₂	57,4 \pm 2,1	78,6 \pm 4,1	54,5 \pm 2,4	66,6 \pm 9,4
W₃	59,2 \pm 2,2	77,6 \pm 5,5	52,5 \pm 3,2	66,5 \pm 9,6
W₄	59,2 \pm 4,0	78,6 \pm 5,2	51,6 \pm 1,2	67,3 \pm 9,3
W₅	59,5 \pm 3,5	78,9 \pm 4,6	54,6 \pm 1,3	69,5 \pm 7,9
W₆	58,7 \pm 2,0	78,5 \pm 3,5	52,0 \pm 1,9	69,4 \pm 7,2
W₇	56,1 \pm 2,9	78,2 \pm 4,6	50,2 \pm 3,8	70,7 \pm 8,1

Tabela 8: Resultados para a classificação Sujeito 2 modelo de trilha 2.

Janela	Taxa de acerto média \pm Desvio padrão (%)			
	Sessão 1		Sessão 2	
	(Sem filtro CSP)	(Com filtro CSP)	(Sem filtro CSP)	(Com filtro CSP)
W_1	53,4 \pm 1,3	68,9 \pm 8,8	52,0 \pm 3,5	67,6 \pm 6,0
W_2	52,5 \pm 1,7	66,0 \pm 9,4	52,0 \pm 3,1	65,7 \pm 6,0
W_3	55,8 \pm 1,7	64,1 \pm 9,4	52,8 \pm 1,7	65,2 \pm 5,9
W_4	53,5 \pm 1,9	64,6 \pm 9,0	53,3 \pm 1,4	64,4 \pm 4,6
W_5	54,5 \pm 1,4	70,2 \pm 7,4	52,3 \pm 1,4	65,2 \pm 5,0
W_6	54,7 \pm 2,0	67,6 \pm 6,7	50,0 \pm 2,9	63,1 \pm 3,7
W_7	55,2 \pm 1,3	69,0 \pm 6,0	48,2 \pm 2,8	64,5 \pm 3,2

As taxas de acertos foram melhores para o modelo de trilha 2, apresentando valores, principalmente, no intervalo de 65 até 80 %. A grande quantidade de artefatos não descartados é uma fonte potencial para a diminuição nas taxas de acerto e, em alguns casos, mesmo a aplicação do filtro CSP não garante taxas muito mais elevadas.

O melhor ensaio, em termos de taxas de acerto de classificação, foi promovido pelo sujeito 1, na sessão 1, modelo de trilha 2.

Em comparação aos resultados obtidos em (MACHADO, 2012), onde as aquisições foram realizadas utilizando apenas o modelo de trilha 1, as taxas de acerto obtidas possuem ordens de grandeza parecidas, variando, principalmente, entre 55 até 65 %. O trabalho realizado em (MACHADO, 2012) também não promoveu o descarte de trilhas com artefatos. Desta forma, as principais diferenças entre o trabalho citado e o desenvolvido neste estudo, é o uso de posição de eletrodos distintos (devido às configurações da touca EMOTIV) e o fato de que, aqui, os movimentos foram imaginados e não executados.

Os resultados obtidos para o modelo de trilha 2 apresentaram taxas mais altas em relação aos obtidos para o modelo 1. Isto pode ser devido a alguns fatores, como a melhor adaptação do sujeito a este tipo de ensaio em particular, diferenças de resposta para durações de movimento distintas, como sugerido em (NAKAYASHIKI *et al.*, 2014), ou simplesmente menor contaminação por artefatos. As taxas obtidas pelo modelo de trilha 2 são comparadas com as obtidas utilizando o banco de dados do BCI *Competition* na Seção 4.3.2.

Em relação a outros classificadores, o desempenho do método *Naive Bayes* apresentou taxas de acerto condizentes com as obtidas em outros trabalhos, como por exemplo, em (BASHASHATI *et al.*, 2015). Apesar dos métodos aqui utilizados serem fixos, os resultados também não se distanciaram muito do que foi apresentado em estudos com processamentos adaptativos, como em (WANG *et al.*, 2012) ou (ZHANG *et al.*, 2015), onde taxas de acerto em torno de 80 % foram obtidas para algumas metodologias adaptativas.

4.3.2 BCI *Competition II*

Os resultados de classificação para o banco de dados para o BCI *Competition II* estão expostos na Tabela 9. Observe que os resultados obtidos são muito próximos dos apresentados em (MACHADO, 2012), entre 75 e 85 %, o que é um indicativo de que os modelos de processamento de sinais foram aplicados nos mesmos moldes, possibilitando a comparação. Para este estudo, a aplicação do filtro espacial também promoveu maiores taxas de acerto, atingindo um máximo de 85,5 %.

Tabela 9: Resultados para a classificação para o BCI *Competition II*

Janela	Taxa de acerto média \pm Desvio padrão (%) (Sem filtro CSP)	Taxa de acerto média \pm Desvio padrão (%) (Com filtro CSP)
W ₁	83,6 \pm 3,5	85,5 \pm 1,4
W ₂	83,2 \pm 4,2	85,0 \pm 1,3
W ₃	81,3 \pm 3,4	83,8 \pm 1,5
W ₄	79,9 \pm 3,2	81,4 \pm 1,9
W ₅	77,3 \pm 4,4	79,4 \pm 2,2
W ₆	76,9 \pm 5,0	77,9 \pm 1,7
W ₇	74,7 \pm 3,7	75,9 \pm 2,1

As taxas de acerto resultantes para o banco de dados foram as maiores obtidas neste trabalho, variando entre aproximadamente 75 até 85 %. Os resultados obtidos para o modelo de trilha 2 no experimento proposto, apesar de apresentarem taxas inferiores em relação as obtidas pelo BCI *Competition*, não ficaram muito distantes, variando entre 65 até 80 %.

Possivelmente as taxas de acerto inferiores para o experimento proposto se devem ao fato de que nos ensaios realizados não foram promovidos descartes de trilhas com artefatos e

que o sistema aqui utilizado não possui realimentação para o usuário. Estes dois fatores, juntamente com a característica de que as posições de eletrodos utilizadas não foram as mesmas para os trabalhos comparados, são potencialmente a fonte das diferenças entre os resultados.

5. CONCLUSÕES

Os objetivos deste trabalho foram desenvolver os algoritmos de processamento e classificação para sinais de EEG, utilizando filtro espacial CSP e *Naive Bayes*, para identificar movimentos imaginários de duas classes. Além disto, buscou-se realizar uma análise preliminar entre os resultados obtidos neste estudo em relação aos obtidos no trabalho de (MACHADO, 2012), também utilizando o banco de dados da BCI *Competition*, para verificar se a ausência dos eletrodos das posições C3, C4, P3 e P4 acarretariam prejuízos nas taxas de acerto. As taxas de acerto obtidas foram condizentes com outros trabalhos da área, incluindo os utilizados para comparação.

A aquisição de dados poderia ter sido beneficiada utilizando um sistema com realimentação. A indicação para o usuário de que ele está efetuando a imaginação correta do movimento pode auxiliar tanto para a compreensão do experimento, quanto para os ensaios. Sinais obtidos com este tipo de abordagem podem resultar em taxas de acertos mais altas. O fato de não remover trilhas contaminadas por artefatos também causou alterações nos resultados, e diminuição dos acertos, mas esta era uma definição inicial da proposta.

Os resultados da classificação do banco de dados BCI *Competition* foram comparados com (MACHADO, 2012) de forma a verificar os modelos de processamento e classificação gerados neste trabalho. As porcentagens de acerto de ambos os estudos apresentaram valores muito próximos, na mesma ordem de outros trabalhos nesta área, com métodos semelhantes, como, por exemplo, (BASHASHATI *et al.*, 2015). Os níveis de classificação para o banco de dados foram os mais altos obtidos neste estudo. A diferença em relação aos obtidos no experimento proposto se deve, principalmente, à realimentação para o usuário durante aquisição de dados, à ausência de artefatos e à utilização dos eletrodos das posições C3 e C4.

A aplicação do filtro CSP aumentou as taxas de acertos para todos os ensaios, mas apenas alguns destes acréscimos foram significativos em relação à porcentagem de acertos e ao desvio padrão. É possível que a seleção de eletrodos (posições FC5, FC6, P7 e P8), que foi baseada na proximidade em relação aos utilizados em (MACHADO, 2012) (posições C3, C4, P3 e P4) não tenha sido ideal para os sujeitos do experimento. Uma análise mais detalhada quanto à seleção de canais, ou um método adaptativo para a escolha de canais, poderia beneficiar a análise desenvolvida e melhor validar as vantagens do uso do filtro CSP.

Apesar da diferente configuração de eletrodos, as taxas de acerto de classificação obtidas estão na mesma ordem das apresentadas em (MACHADO, 2012). Isto é um indicativo de que, mesmo sem a remoção de artefatos, as diferentes seleções podem retornar resultados com níveis de classificação parecidos.

A seleção de bandas de frequência também é uma fonte de diminuição nas taxas de acerto. Os sujeitos aqui analisados apresentaram maior resposta na banda dos ritmos α , principalmente em torno de 10 – 11 Hz, e pouca atividade discriminativa foi verificada nos ritmos β . É possível que a utilização de apenas os ritmos α retornasse níveis maiores de classificação, e seria interessante o desenvolvimento de um método com seleção de bandas de frequência automática para o filtro CSP.

Por fim, a utilização de um sistema de aquisição mais elaborado, com realimentação, e a obtenção de um banco de dados maior pode ajudar a melhor verificar e compreender quais as melhores abordagens para cada sujeito.

6. PROPOSTA PARA TRABALHOS FUTUROS

De forma a continuar o estudo desenvolvido neste trabalho, melhorias podem ser aplicadas em três diferentes estágios: na aquisição dos sinais de EEG, no processamento de sinais e na classificação dos movimentos.

Para a aquisição, um sistema com *feedback* que indique ao usuário se está imaginando os movimentos corretamente pode melhorar a qualidade dos sinais obtidos. Além disto, o desenvolvimento de um método para minimizar e filtrar artefatos pode ser efetuado, para reduzir efeitos que prejudicam a classificação.

O processamento poderia ser realizado com algoritmos mais robustos que o filtro CSP, como por exemplo, os métodos adaptativos propostos no trabalho de (MENG *et al.*, 2012), que busca identificar a melhor resolução temporal para classificação, ou no trabalho de (ZHANG *et al.*, 2015), que sugere modelos com seleção de bandas de frequência que melhor se adequam ao usuário.

A utilização de outros classificadores, de forma a serem comparados quanto ao seu desempenho em relação do *Naive Bayes*, também pode acarretar melhorias nas taxas de acerto. Os métodos LDA e SVM (*Support Vector Machine*) são comumente escolhidos em trabalhos nesta área, e muitas vezes fornecem resultados nas taxas de acerto em relação a outros classificadores, como pode ser visto na comparação de (BASHASHATI *et al.*, 2015).

Como última proposta, a análise do desempenho de algoritmos para classificação de movimentos também pode ser interessante quanto à perspectiva computacional. Para aplicações de sistemas portáteis, não apenas a qualidade na classificação, mas o atraso e o consumo de baterias aparecem como desafios. Assim, uma avaliação de níveis de acerto de classificação em relação a custo computacional dos algoritmos envolvidos pode ser relevante para a possibilidade de aplicações *online*.

REFERÊNCIAS BIBLIOGRÁFICAS

WANG, Y. et al. A Collaborative Brain-Computer Interface for Improving Human Performance. **PLOS ONE**, San Francisco, v. 6, n. 5, Mai. 2011.

YI, W. et al. EEG feature comparison and classification of simple and compound limb motor imagery. **Journal of NeuroEngineering and Rehabilitation**, London, v. 10, n. 1, p. 106-106, Out. 2013.

MACHADO, J. **Pré-processamento, extração de características e classificação offline de sinais eletroencefalográficos para uso em sistemas BCI**. 2012. 113 f. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal do Rio Grande do Sul, Porto Alegre, Nov. 2012.

CARRA, M. **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.

TORTORA, G. J. **Corpo Humano: Fundamentos de Anatomia e Fisiologia**. 8. ed. Porto Alegre: Artmed, 2012.

TORTORA, G.J.; DERRICKSON, B. **Principles of anatomy and physiology**. 12. ed. New York: John Wiley & Sons, 2009.

BCI Competition II. 2003. Disponível em: <<http://www.bbci.de/competition/ii/>>. Acesso em: 04 Set. 2015.

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

DORNHEGE, G. et al. **Toward brain-computer interfacing**. London: MIT, 2007.

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

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

DOYLE, L. M. F. et al. Lateralization of event-related beta desynchronization in the EEG during pre-cued reaction time tasks. **Clinical Neurophysiology**, Amsterdam, v. 116, n. 8, p. 1879-1888, Mar. 2005.

XIA, B. et al. A combination strategy based brain-computer interface for two-dimensional movement control. **Journal of Neural Engineering**. United Kingdom, v. 12, n. 4, p. 46021-46030, Jun. 2015.

BASHASHATI, H. et al. Comparing Different Classifiers in Sensory Motor Brain Computer Interfaces. **PLOS ONE**, San Francisco, v. 10, n. 6, Jun. 2015.

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.

FUKUNAGA, K. **Introduction to Statistical Pattern Recognition**. 2. ed. New York: Academic Press, 1990.

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.

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

IBÁÑEZ, J. et al. Detection of the onset of upper-limb movements based on the combined analysis of changes in the sensorimotor rhythms and slow cortical potentials. **Journal of Neural Engineering**, United Kingdom, v. 11, n. 5, Ago. 2014.

BAMDADIAN, A. et al. The predictive role of pre-cue EEG rhythms on MI-based BCI classification performance. **Journal of Neuroscience Methods**, Amsterdam, v. 235, p. 138-144, Jun. 2014.

NAKAYASHIKI, K. et al. Modulation of event-related desynchronization during kinematic and kinetic hand movements. **Journal of NeuroEngineering and Rehabilitation**, London, v. 11, p. 90-98, Mai. 2014.

AHANGI, A. et al. Multiple classifier system for EEG signal classification with application to brain-computer interfaces. **Neural Computing & Applications**, Berlin, v. 23, n. 5, p. 1319-1327, Jul. 2012.

WANG, Y. et al. Adaptive estimation of EEG for subject-specific reactive band identification and improved ERD detection. **Neuroscience Letters**, CIDADE, v. 528, n. 2, p. 137-142, Set. 2012.

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

MENG, J. et al. Optimizing spatial spectral patterns jointly with channel configuration for brain-computer interface. **Neurocomputing**, v. 104, n. NÚMERO, p. 115-126, Nov. 2012.

ZHANG, Y. et al. Optimizing spatial patterns with sparse filter bands for motor-imagery based brain-computer interface. **Journal of Neuroscience Methods**, v. 255, p. 85-91, Ago. 2015.

MORASH, V. et al. Classifying EEG signals preceding right hand, left hand, tongue, and right foot movements and motor imageries. **Clinical Neurophysiology**, Amsterdam, v. 119, n. 11, p. 2570-2578, Ago. 2008.

FRIEDRICH, E. et al. The effect of distinct mental strategies on classification performance for brain-computer interfaces. **International Journal of Psychophysiology**, v. 84, n. 1, p. 86-94, Jan. 2012.

- PFURTSCHELLER, G. et al. Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks. **Neuroimage**, v. 31, n. 1, p. 153-159, Dez. 2005.
- SHAN, H. et al. A novel channel selection method for optimal classification in different motor imagery BCI paradigms. **BioMedical Engineering Online**, v. 14, Out. 2015.
- IBÁÑEZ, J. et al. Online detector of movement intention based on EEG—Application in tremor patients. **Biomedical Signal Processing and Control**, v. 8, n. 6, p. 822-829, Jul. 2013.
- JEON, Y. et al. Event-related (De)synchronization (ERD/ERS) during motor imagery tasks: Implications for brain–computer interfaces. **International Journal of Industrial Ergonomics**, v. 41, n. 5, p. 428-436, Mar. 2011.
- FORMAGGIO, E. et al. Modulation of event-related desynchronization in robot-assisted hand performance: brain oscillatory changes in active, passive and imagined movements. **Journal of NeuroEngineering and Rehabilitation**, London, v. 10, p. 24-34, Fev. 2013.
- KAISER, J. On a simple algorithm to calculate the ‘energy’ of a signal. **IEEE Conference Publications**, Albuquerque, v. 1, p. 381-384, Abr. 1990.
- SICURANZA, G. L. Quadratic Filters for Signal Processing. **IEEE Signal Processing Magazine**, New York, v. 80, n. 8, p. 1263-1285, Ago. 1992.
- MUMOLO, E.; CARINI, A. On the Stability of Discrete Time Recursive Volterra Filters. **IEEE Signal Processing Magazine**, New York, v. 6, n. 9, p. 230-232, Set. 1999.

APÊNDICE A – ALGORITMO PARA SEPARAÇÃO DO SINAL DE EEG

```
%{
trilhas
```

Esta função recorta os sinais de EEG adquiridos com o programa do Simulink "aquisicao". A função salva os dados em um banco .mat e também retorna ambos para o workspace.

Os vetores de retorno da função possuem o seguinte formato

```
z(comp*fs, canais, n_trilhas)
es(1, n_trilhas)
```

onde comp é o "comprimento" de cada trilha (8 segundos), canais é o número de canais totais da touca EMOTIV (14) e n_trilhas é o número de trilhas adquiridas.

O argumento "file" é a string com o caminho para o banco de dados .mat gravado pelo programa de Simulink.

```
%}
```

```
function [z, es] = trilhas(file)
```

```
% Inicializações e constantes
```

```
load(file);
canais = 14;
fs = 128;
comp = 9;
atraso = 5;
n_trilhas = (length(EEG.Data(:,2)) - (atraso*fs + 1)) / (comp * fs);
x = zeros(comp*128*n_trilhas, canais);
y = zeros(comp*128, canais, n_trilhas);
e = zeros(comp*128, n_trilhas);
es = zeros(1, n_trilhas);
z = zeros(comp*128, canais, n_trilhas);
```

```
% Recorte de cada trilha para cada canal
```

```
for i = atraso*fs : length(EEG.Data(:,2))
    for j = 1 : canais
        x(i - atraso*fs + 1, j) = EEG.Data(i, j + 1);
    end
end
```

```
for i = 1 : n_trilhas
    k = 1;
```

```
    for j = (i-1)*fs*comp + 1 : i*fs*comp
```

```
        e(k, i) = Estimulos.Data(j + (atraso*fs));
```

```
        for q = 1 : canais
            y(k, q, i) = x(j ,q);
        end
        k = k + 1;
    end

    es(i) = max(e(:, i));
end

% Filtrando os sinais com passa banda 0.5 - 30 Hz

H =
designfilt('bandpassiir','FilterOrder',4,'HalfPowerFrequency1',0.5,'HalfPowerFrequ
ency2',30,'SampleRate',128);

for i = 1 : n_trilhas
    for j = 1 : canais
        r = y(:, j, i);% - mean(y(:, j, i));
        z(:, j, i) = filtfilt(H, r);
    end
end

save(['Filtrado_' file], 'z', 'es');

end
```

APÊNDICE B – ALGORITMO UNIR O SINAL DE DIFERENTES SESSÕES EM VARIÁVEL

```

function [x, e] = unir(x1, x2, x3, x4, e1, e2, e3, e4)

    amostras = length(x1(:, 1, 1));
    canais = length(x1(1, :, 1));
    trilhas = length(x1(1, 1, :));

    x = zeros(amostras, canais, 4*trilhas);
    e = zeros(1, 4 * trilhas);

    for i = 1 : 4 * trilhas
        for j = 1 : canais

            if i <= trilhas
                x(:, j, i) = x1(:, j, i);
            elseif i <= 2 * trilhas
                x(:, j, i) = x2(:, j, i - trilhas);
            elseif i <= 3 * trilhas
                x(:, j, i) = x3(:, j, i - 2*trilhas);
            else
                x(:, j, i) = x4(:, j, i - 3*trilhas);
            end
        end

        if i <= trilhas
            e(i) = e1(i);
        elseif i <= 2 * trilhas
            e(i) = e2(i - trilhas);
        elseif i <= 3 * trilhas
            e(i) = e3(i - 2*trilhas);
        else
            e(i) = e4(i - 3*trilhas);
        end
    end

end

end

```

APÊNDICE C – ALGORITMO PARA UNIR SINAIS SEPARADOS EM ESQUERDA E DIREITA

```

function [x, e] = unir_esqdir(x1, x2)

    amostras = length(x1(:, 1, 1));
    canais = length(x1(1, :, 1));
    trilhas_esq = length(x1(1, 1, :));
    trilhas_dir = length(x2(1, 1, :));

    x = zeros(amostras, canais, trilhas_esq + trilhas_dir);
    e = zeros(1, trilhas_esq + trilhas_dir);

    % Esquerda
    for i = 1 : trilhas_esq
        for j = 1 : canais

            x(:, j, i) = x1(:, j, i);

        end

        e(i) = 3;
    end

    % Direita
    for i = trilhas_esq + 1 : trilhas_esq + trilhas_dir
        for j = 1 : canais

            x(:, j, i) = x2(:, j, i - trilhas_esq);

        end

        e(i) = 4;
    end

end

```

APÊNDICE D – ALGORITMO PARA CÁLCULO DA ENERGIA RELATIVA

```

%{
  erp

  Esta função filtra os ritmos alpha e beta, calcula a potência, faz a
  média de todas as trilhas que possuem o mesmo estímulo (mesma direção)
  e calcula a energia relativa para identificar ERD e ERS.

  Retornos

  x1(fs*comp, canais, 2) : Energia relativa para trilhas para a esquerda
  para todos os canais e para os ritmos alpha e beta

  x2(fs*comp, canais, 2) : Energia relativa para trilhas para a direita
  para todos os canais e para os ritmos alpha e beta

  x3(fs*comp, canais, 2) : Energia relativa para trilhas para a frente
  para todos os canais e para os ritmos alpha e beta

  Argumentos

  z(fs*comp, canais, trilhas) : Sinal de EEG para várias trilhas e canais

  es(trilhas) : Estímulo apresentado para cada trilha

      3 - esquerda
      4 - direita
      5 - frente

  ref : tempo (em segundos) para qual termina o período de referência
  iniciado em t = 0

%}

function [x1, x2, x3, f1, f2] = erp(z, es, ref)

  % Definições e inicialização de variáveis

  fs = 128;
  comp = length(z(:, 1, 1)) / fs;
  canais = length(z(1,:,1));
  n_trilhas = length(z(1,1,:));

  H1 =
  designfilt('bandpassiir', 'FilterOrder',4, 'HalfPowerFrequency1',8, 'HalfPowerFrequen
  cy2',13, 'SampleRate',128);
  H2 =
  designfilt('bandpassiir', 'FilterOrder',4, 'HalfPowerFrequency1',14, 'HalfPowerFrequen
  cy2',24, 'SampleRate',128);

  alpha = filtfilt(H1, z);
  beta = filtfilt(H2, z);

  y1 = zeros(fs*comp, canais, n_trilhas);

```

```

y2 = zeros(fs*comp, canais, n_trilhas);
x1 = zeros(fs*comp, canais, 2);
x2 = zeros(fs*comp, canais, 2);
x3 = zeros(fs*comp, canais, 2);
R1 = zeros(fs*ref, canais, 2);
R2 = zeros(fs*ref, canais, 2);
R3 = zeros(fs*ref, canais, 2);
M1 = zeros(1, canais, 2);
M2 = zeros(1, canais, 2);
M3 = zeros(1, canais, 2);
x1n = 0;
x2n = 0;
x3n = 0;

% Elevando o sinal ao quadrado e dividindo pelo número de componentes
% Cálculo da potência do sinal

for i = 1 : n_trilhas
    for j = 1 : fs*comp
        for k = 1 : canais
            y1(j, k, i) = alpha(j, k, i)^2;
            y2(j, k, i) = beta(j, k, i)^2;
        end
    end
end

for i = 1 : n_trilhas
    for k = 1 : canais
        y1(:,k,i) = y1(:,k,i) ./ length(y1(:,k,i));
        y2(:,k,i) = y2(:,k,i) ./ length(y2(:,k,i));
    end
end

% Média do sinal para trilhas para esquerda, direita e frente

for i = 1 : n_trilhas
    for k = 1 : canais
        if es(i) == 3
            x1(:, k, 1) = x1(:, k, 1) + y1(:,k,i);
            x1(:, k, 2) = x1(:, k, 2) + y2(:,k,i);
        elseif es(i) == 4
            x2(:, k, 1) = x2(:, k, 1) + y1(:,k,i);
            x2(:, k, 2) = x2(:, k, 2) + y2(:,k,i);
        else
            x3(:, k, 1) = x3(:, k, 1) + y1(:,k,i);
            x3(:, k, 2) = x3(:, k, 2) + y2(:,k,i);
        end
    end
    if es(i) == 3
        x1n = x1n + 1;
    elseif es(i) == 4
        x2n = x2n + 1;
    else
        x3n = x3n + 1;
    end
end

for k = 1 : canais

```

```

x1(:, k, 1) = x1(:, k, 1) ./ x1n;
x1(:, k, 2) = x1(:, k, 2) ./ x1n;
x2(:, k, 1) = x2(:, k, 1) ./ x2n;
x2(:, k, 2) = x2(:, k, 2) ./ x2n;
x3(:, k, 1) = x3(:, k, 1) ./ x3n;
x3(:, k, 2) = x3(:, k, 2) ./ x3n;
end

f1 = x1;
f2 = x2;

% Calculando a energia média no período de referência

for i = 1 : ref*fs
    for k = 1 : canais
        R1(i, k, 1) = x1(i, k, 1);
        R1(i, k, 2) = x1(i, k, 2);
        R2(i, k, 1) = x2(i, k, 1);
        R2(i, k, 2) = x2(i, k, 2);
        R3(i, k, 1) = x3(i, k, 1);
        R3(i, k, 2) = x3(i, k, 2);
    end
end

for k = 1 : canais
    M1(k, 1) = mean(R1(:,k, 1));
    M1(k, 2) = mean(R1(:,k, 2));
    M2(k, 1) = mean(R2(:,k, 1));
    M2(k, 2) = mean(R2(:,k, 2));
    M3(k, 1) = mean(R3(:,k, 1));
    M3(k, 2) = mean(R3(:,k, 2));
end

% Calculando a energia relativa

for k = 1 : canais
    x1(:, k, 1) = 100*(x1(:, k, 1) - M1(k, 1)) / M1(k, 1);
    x1(:, k, 2) = 100*(x1(:, k, 2) - M1(k, 2)) / M1(k, 2);
    x2(:, k, 1) = 100*(x2(:, k, 1) - M2(k, 1)) / M2(k, 1);
    x2(:, k, 2) = 100*(x2(:, k, 2) - M2(k, 2)) / M2(k, 2);
    x3(:, k, 1) = 100*(x3(:, k, 1) - M3(k, 1)) / M3(k, 1);
    x3(:, k, 2) = 100*(x3(:, k, 2) - M3(k, 2)) / M3(k, 2);
end
end

```

APÊNDICE E – SCRIPT PARA GERAÇÃO DE GRÁFICOS

```

%load('Montado_Andre.mat');
%load('Montado_Sandro2.mat');

[x1, x2, x3] = erp(xs, e, 1.5);
t = 0 : (1/128) : 8 - (1/128);

ma_coef = ones(1, 70) / 70;
avg_x = filter(ma_coef, 1, x1(:,1,1));
avg_x2 = filter(ma_coef, 1, x2(:,1,1));
figure(2);
plot(t, [avg_x avg_x2]);
grid on;
legend('Esquerda', 'Direita', 'location', 'northwest');
ylabel('Energia relativa %');
xlabel('Tempo (s)');
title('FC5 (alpha)');

avg_x = filter(ma_coef, 1, x1(:,2,1));
avg_x2 = filter(ma_coef, 1, x2(:,2,1));
figure(3);
plot(t, [avg_x avg_x2]);
grid on;
legend('Esquerda', 'Direita', 'location', 'southwest');
ylabel('Energia relativa %');
xlabel('Tempo (s)');
title('P7 (alpha)');

avg_x = filter(ma_coef, 1, x1(:,3,1));
avg_x2 = filter(ma_coef, 1, x2(:,3,1));
figure(4);
plot(t, [avg_x avg_x2]);
grid on;
legend('Esquerda', 'Direita', 'location', 'northwest');
ylabel('Energia relativa %');
xlabel('Tempo (s)');
title('FC6 (alpha)');

avg_x = filter(ma_coef, 1, x1(:,4,1));
avg_x2 = filter(ma_coef, 1, x2(:,4,1));
figure(5);
plot(t, [avg_x avg_x2]);
grid on;
legend('Esquerda', 'Direita', 'location', 'northwest');
ylabel('Energia relativa %');
xlabel('Tempo (s)');
title('P8 (alpha)');

avg_x = filter(ma_coef, 1, x1(:,1,2));
avg_x2 = filter(ma_coef, 1, x2(:,1,2));
figure(6);
plot(t, [avg_x avg_x2]);
grid on;
legend('Esquerda', 'Direita', 'location', 'northwest');
ylabel('Energia relativa %');

```

```

xlabel('Tempo (s)');
title('FC5 (beta)');

avg_x = filter(ma_coef, 1, x1(:,2,2));
avg_x2 = filter(ma_coef, 1, x2(:,2,2));
figure(8);
plot(t, [avg_x avg_x2]);
grid on;
legend('Esquerda', 'Direita', 'location', 'southwest');
ylabel('Energia relativa %');
xlabel('Tempo (s)');
title('P7 (beta)');

avg_x = filter(ma_coef, 1, x1(:,3,2));
avg_x2 = filter(ma_coef, 1, x2(:,3,2));
figure(9);
plot(t, [avg_x avg_x2]);
grid on;
legend('Esquerda', 'Direita', 'location', 'northeast');
ylabel('Energia relativa %');
xlabel('Tempo (s)');
title('FC6 (beta)');

avg_x = filter(ma_coef, 1, x1(:,4,2));
avg_x2 = filter(ma_coef, 1, x2(:,4,2));
figure(10);
plot(t, [avg_x avg_x2]);
grid on;
legend('Esquerda', 'Direita', 'location', 'northeast');
ylabel('Energia relativa %');
xlabel('Tempo (s)');
title('P8 (beta)');

% Índice de lateralização

y = (x1(:, 3, 1) - x1(:, 1, 1) + x2(:, 1, 1) - x2(:, 3, 1)) ./ 2;
y = y ./ max(y);

ma_coef = ones(1, 140) / 140;
avg_y = filter(ma_coef, 1, y);

avg_y = avg_y ./ max(avg_y);

figure(11);
plot(t, avg_y);
ylabel('IL');
xlabel('Tempo (s)');
title('Índice de lateralização');
grid on;

```

APÊNDICE F – FUNÇÃO PARA CÁLCULO DA MATRIZ DE COVARIÂNCIA

```

function x_csp = csp(y)

    canais = length(y(1, :, 1));
    amostras = length(y(:, 1, 1));
    trilhas = length(y(1, 1, :));

    S = zeros(canais, canais);
    X = zeros(canais, amostras, trilhas);

    for i = 1 : trilhas
        X(:, :, i) = y(:, :, i)';
    end

    for i = 1 : trilhas
        S = S + (X(:, :, i)*X(:, :, i)' ./ traco(X(:, :, i)*X(:, :, i)'));
    end

    x_csp = S ./ trilhas;
end

function Z = traco(X)

    Z = 0;

    for i = 1 : length(X(:, 1))
        for j = 1 : length(X(:, 1))
            if i == j
                Z = Z + X(i, j);
            end
        end
    end
end
end

```

APÊNDICE G – ALGORITMO PARA APLICAÇÃO DO FILTRO CSP PARA O EXPERIMENTO PROPOSTO

```

%load('Montado_Andre2.mat');
load('Montado_Sandro2.mat');

% Colocando os dados no formato esperado pelo filtro CSP

trilhas = length(x(1, 1, :));
amostras = length(x(:, 1, 1));

xs = zeros(amostras, 4, trilhas);

for i = 1 : trilhas

    xs(:, 1, i) = x(:, 4, i);
    xs(:, 2, i) = x(:, 6, i);
    xs(:, 3, i) = x(:, 11, i);
    xs(:, 4, i) = x(:, 9, i);

end

canais = length(xs(1, :, 1));
fs = 128;

janela_i = 4*fs;
janela_f = 6*fs;

xesq = zeros(janela_f - janela_i + 1, canais, 1);
xdir = zeros(janela_f - janela_i + 1, canais, 1);
sesq = zeros(amostras, canais, 1);
sdir = zeros(amostras, canais, 1);

k = 1;
q = 1;

H =
designfilt('bandpassiir', 'FilterOrder',4,'HalfPowerFrequency1',8,'HalfPowerFrequen
cy2',24,'SampleRate',128);

for i = 1 : trilhas
    for j = 1 : canais
        xs(:, j, i) = filtfilt(H, xs(:, j, i));
    end
end

for i = 1 : trilhas
    for j = 1 : canais
        if e(i) == 3
            xesq(:, j, k) = xs(janela_i : janela_f, j, i);
            sesq(:, j, k) = xs(:, j, i);
        else
            xdir(:, j, q) = xs(janela_i : janela_f, j, i);
            sdir(:, j, q) = xs(:, j, i);
        end
    end
end

```

```

end

if e(i) == 3
    k = k + 1;
else
    q = q + 1;
end
end

% Matrizes de covariância

xesq_csp = csp(xesq);
xdir_csp = csp(xdir);
covar = xesq_csp + xdir_csp;

% Decomposição em autovalores e autovetores
% e determinação de W

[autovetores, autovalores] = eig(covar);
P = (autovalores^(-0.5)) * autovetores';
S_esq = P * xesq_csp * P';
S_dir = P * xdir_csp * P';

[avet_esq, aval_esq] = eig(S_esq);
[avet_dir, aval_dir] = eig(S_dir);

W = (avet_esq' * P)';

val_e = W' * xesq_csp * W;
val_d = W' * xdir_csp * W;

% Características e aplicação do filtro nos sinais

carac = zeros(1, trilhas);
carac2 = zeros(1, trilhas);

for i = 1 : trilhas
    carac(i) = log(W(:, 1)' * xs(:, :, i)' * xs(:, :, i) * W(:, 1));
    carac2(i) = log(W(:, 2)' * xs(:, :, i)' * xs(:, :, i) * W(:, 2));
end

z_csp_esq = zeros(2, amostras, k - 1);
z_csp_dir = zeros(2, amostras, q - 1);
r_esq = zeros(amostras, 2, k - 1);
r_dir = zeros(amostras, 2, q - 1);

for i = 1 : k - 1
    z_csp_esq(1, :, i) = W(:, 2)' * s_esq(:, :, i)';
    z_csp_esq(2, :, i) = W(:, 1)' * s_esq(:, :, i)';
end

for i = 1 : q - 1
    z_csp_dir(1, :, i) = W(:, 2)' * s_dir(:, :, i)';
    z_csp_dir(2, :, i) = W(:, 1)' * s_dir(:, :, i)';
end

```

```
for i = 1 : k - 1
    r_esq(:, :, i) = z_csp_esq(:, :, i)';
end

for i = 1 : q - 1
    r_dir(:, :, i) = z_csp_dir(:, :, i)';
end

[xr, er] = unir_esqdir(r_esq, r_dir);
```

APÊNDICE H – ALGORITMO PARA APLICAÇÃO DO FILTRO CSP PARA O BCI COMPETITION

```

load('dataset3.mat');

% Colocando os dados no formato esperado pelo filtro CSP

amostras = length(x_train(:, 1, 1));
canais = length(x_train(1, :, 1));
trilhas = length(x_train(1, 1, :));
fs = 128;

janela_i = 4*fs;
janela_f = 6*fs;

xesq = zeros(janela_f - janela_i + 1, canais, 1);
xdir = zeros(janela_f - janela_i + 1, canais, 1);
sesq = zeros(amostras, canais, 1);
sdir = zeros(amostras, canais, 1);

k = 1;
q = 1;

H =
designfilt('bandpassiir','FilterOrder',4,'HalfPowerFrequency1',8,'HalfPowerFrequen
cy2',24,'SampleRate',128);

x_filt = zeros(amostras, canais, trilhas);

% Filtrando os sinais para cada canal e trilha

for i = 1 : trilhas
    for j = 1 : canais
        x_filt(:, j, i) = filtfilt(H, x_train(:, j, i));
    end
end

% Recortando na janela especificada e separando em esquerda e direita

for i = 1 : trilhas
    for j = 1 : canais

        % Esquerda
        if y_train(i) == 1
            xesq(:, j, k) = x_filt(janela_i : janela_f, j, i);
            sesq(:, j, k) = x_filt(:, j, i);

            % Direita
        else
            xdir(:, j, q) = x_filt(janela_i : janela_f, j, i);
            sdir(:, j, q) = x_filt(:, j, i);
        end
    end
end

```

```

    if y_train(i) == 1
        k = k + 1;
    else
        q = q + 1;
    end
end

% Matrizes de covariância

xesq_csp = csp(xesq);
xdir_csp = csp(xdir);
covar = xesq_csp + xdir_csp;

% Decomposição em autovalores e autovetores
% e determinação de W

[autovetores, autovalores] = eig(covar);
P = (autovalores^(-0.5)) * autovetores';
S_esq = P * xesq_csp * P';
S_dir = P * xdir_csp * P';

[avet_esq, aval_esq] = eig(S_esq);
[avet_dir, aval_dir] = eig(S_dir);

W = (avet_esq' * P)';

val_e = W' * xesq_csp * W;
val_d = W' * xdir_csp * W;

% Características do filtro CSP

carac = zeros(1, trilhas);
carac2 = zeros(1, trilhas);

for i = 1 : trilhas
    carac(i) = log(W(:, 1)' * x_filt(:, :, i)' * x_filt(:, :, i) * W(:, 1));
    carac2(i) = log(W(:, 3)' * x_filt(:, :, i)' * x_filt(:, :, i) * W(:, 3));
end

% Aplicação do filtro nos sinais

z_csp_esq = zeros(2, amostras, k - 1);
z_csp_dir = zeros(2, amostras, q - 1);
r_esq = zeros(amostras, 2, k - 1);
r_dir = zeros(amostras, 2, q - 1);

for i = 1 : k - 1
    z_csp_esq(1, :, i) = W(:, 3)' * s_esq(:, :, i)';
    z_csp_esq(2, :, i) = W(:, 1)' * s_esq(:, :, i)';
end

for i = 1 : q - 1
    z_csp_dir(2, :, i) = W(:, 1)' * s_dir(:, :, i)';
    z_csp_dir(1, :, i) = W(:, 3)' * s_dir(:, :, i)';
end

```

```
end

for i = 1 : k - 1
    r_esq(:, :, i) = z_csp_esq(:, :, i)';
end

for i = 1 : q - 1
    r_dir(:, :, i) = z_csp_dir(:, :, i)';
end

xm = zeros(amostras, 2, trilhas);
xm(:, 1, :) = x_filt(:, 1, :);
xm(:, 2, :) = x_filt(:, 3, :);
[xr, er] = unir_esqdir(r_esq, r_dir);
```

APÊNDICE I – FUNÇÃO PARA EXTRAIR CARACTERÍSTICAS DOS SINAIS

```
function [Vrms, std_dev] = extract(x, inicio, fim)

    fs = 128;
    trilhas = length(x(1, 1, :));
    canais = 2;

    Vrms = zeros(canais, trilhas);
    std_dev = zeros(canais, trilhas);

    for i = 1 : trilhas

        Vrms(1, i) = rms(x(ceil(inicio*fs) : ceil(fim*fs), 1, i));
        Vrms(2, i) = rms(x(ceil(inicio*fs) : ceil(fim*fs), 2, i));
        std_dev(1, i) = std(x(ceil(inicio*fs) : ceil(fim*fs), 1, i))^2;
        std_dev(2, i) = std(x(ceil(inicio*fs) : ceil(fim*fs), 2, i))^2;

    end

end
```

APÊNDICE J – SCRIPT PARA GERAR OS GRÁFICOS DE ESPECTRO DE FREQUÊNCIA

```

%Esquerda
L = 1024;
P = zeros(L/2 + 1, 1);
canal = 1;

Y = zeros(L, 140);
P1 = zeros(L/2 + 1, 140);

for i = 1 : k - 1
    Y(:, i) = fft(xr(:, canal, i));
    P2 = abs(Y(:, i)/L);
    P1(:, i) = P2(1:L/2+1);
    P1(2:end-1, i) = 2*P1(2:end-1, i);
end

for i = 1 : k - 1
    P = P + P1(:, i);
end

P = P ./ (k - 1);

f = 128*(0:(L/2))/L;

ma_coef = ones(1, 10) / 10;
avg_x = filter(ma_coef, 1, P);

plot(f,avg_x)
hold on;

% Direita

for i = 1 : q - 1
    Y(:, i) = fft(xr(:, canal, i + k - 1));
    P2 = abs(Y(:, i)/L);
    P1(:, i) = P2(1:L/2+1);
    P1(2:end-1, i) = 2*P1(2:end-1, i);
end

for i = 1 : q - 1
    P = P + P1(:, i);
end

P = P ./ (q - 1);

avg_x = filter(ma_coef, 1, P);

plot(f,avg_x)
grid on;
xlabel('Frequência (Hz)')
ylabel('Energia')
legend('Esquerda', 'Direita')
title('Canal CSP1')
%axis([0 30 0 0.03])

```

APÊNDICE K – FUNÇÃO PARA REALIZAR A CLASSIFICAÇÃO

```

function [C_MAT, avg_rt] = classificador(x, es, inicio, fim, carac, carac2, treino)

    [Vrms, std_dev] = extract(x, inicio, fim);
    trilhas = length(x(1, 1, :));
    select = ceil(rand*treino);

    data = [Vrms; std_dev; carac; carac2]';
    meas = [Vrms(:, select:treino + select) Vrms(:, trilhas - treino - select + 1:
    trilhas - select); std_dev(:, select: treino+select) std_dev(:, trilhas - treino -
    select + 1: trilhas - select); carac(:, select: treino+select) carac(:, trilhas -
    treino - select + 1: trilhas - select); carac2(:, select: treino+select) carac2(:,
    trilhas - treino - select + 1: trilhas - select)]';
    %data = [Vrms; std_dev]';
    %meas = [Vrms(:, select:treino + select) Vrms(:, trilhas - treino - select + 1:
    trilhas - select); std_dev(:, select:treino + select) std_dev(:, trilhas - treino
    - select + 1: trilhas - select)]';

    ez = [es(select:treino+select) es(trilhas - treino - select + 1:trilhas -
    select)];

    NB = fitNaiveBayes(meas, ez);
    P = NB.predict(data);
    C_MAT = confusionmat(es, P);

    rt_esq = C_MAT(1, 1) / (C_MAT(1, 1) + C_MAT(1, 2));
    rt_dir = C_MAT(2, 2) / (C_MAT(2, 1) + C_MAT(2, 2));
    avg_rt = (rt_esq + rt_dir)/2;

end

```

APÊNDICE L – SCRIPT PARA OBTENÇÃO DOS RESULTADOS

```

% Seleção do tipo de janela

BCI = 0;

if BCI == 0
    janelas = 10;
    inc = (0.1);
    fim = 5;
else
    janelas = 7;
    inc = (0.25);
    fim = 6;
end

% Inicializações

rates = zeros(janelas, 100);
resultados = zeros(2, janelas);
H =
designfilt('bandpassiir','FilterOrder',4,'HalfPowerFrequency1',8,'HalfPowerFrequen
cy2',24,'SampleRate',128);
canais = 2;
xr_f = zeros(amostras, canais, trilhas);

% Filtragem do sinal

for i = 1 : trilhas
    for j = 1 : canais
        xr_f(:, j, i) = filtfilt(H, xr(:, j, i));
    end
end

% Classificação em 100 repetições para cada janela selecionada

for j = 1 : 100
    for i = 1 : janelas
        [C_MAT, rates(i, j)] = classificador(xr_f, er, 3.5 + (i-1)*inc, fim, carac,
carac2, 35);
    end
end

% Cálculo das taxas médias e desvio padrão

for i = 1 : janelas
    resultados(1, i) = mean(rates(i, :));
    resultados(2, i) = std(rates(i, :));
end

```

ANEXO A – CURVAS DE ENERGIA RELATIVA SUJEITO 1 MODELO DE TRILHA 1 SESSÃO 2

Figura A1: Energia relativa do canal FC5 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 2.

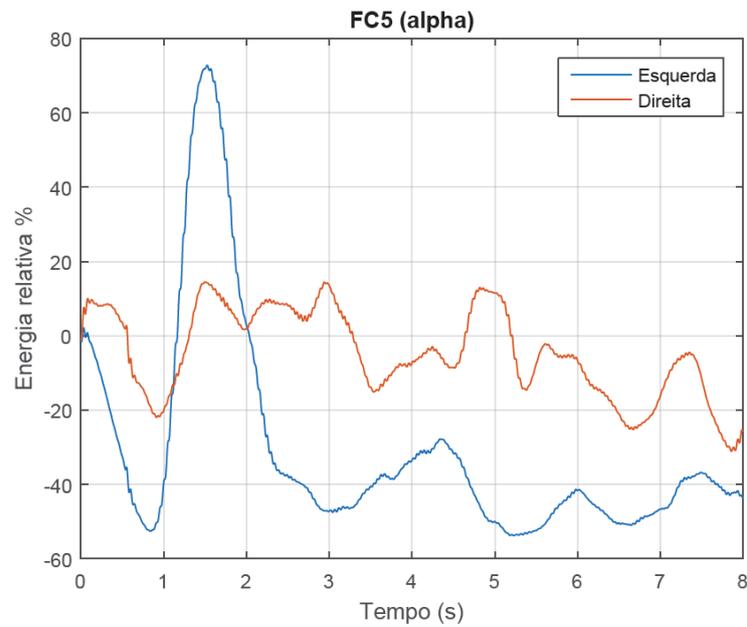


Figura A2: Energia relativa do canal FC6 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 2.

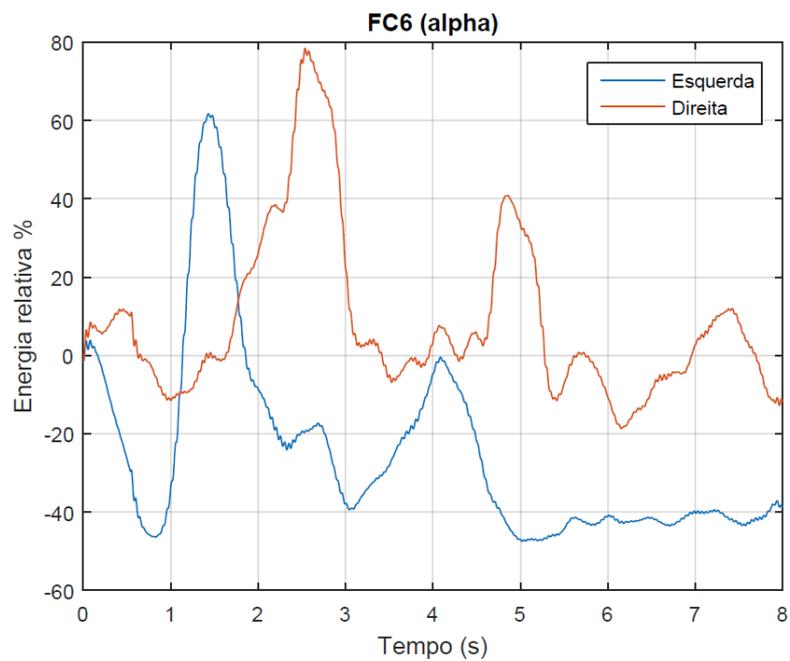


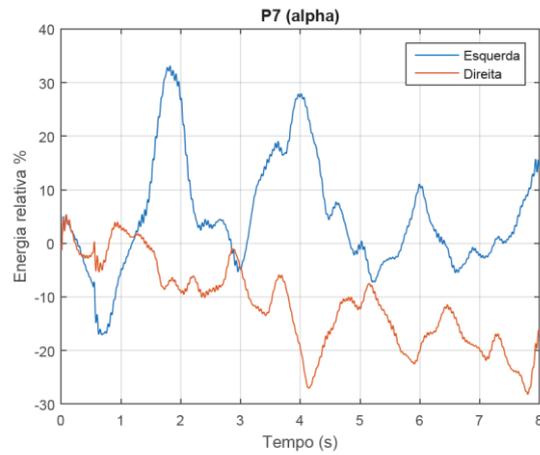
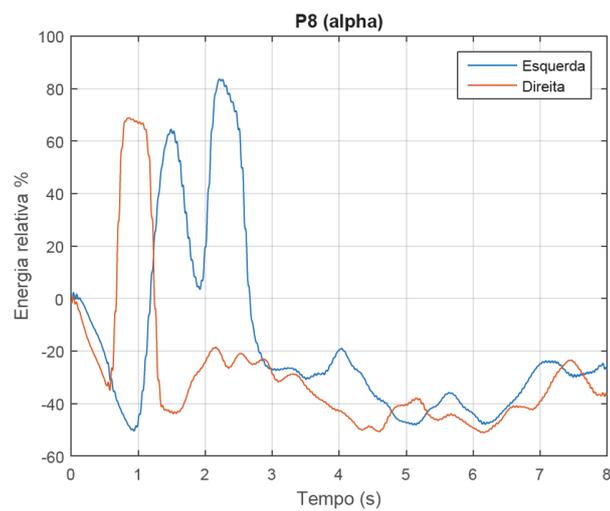
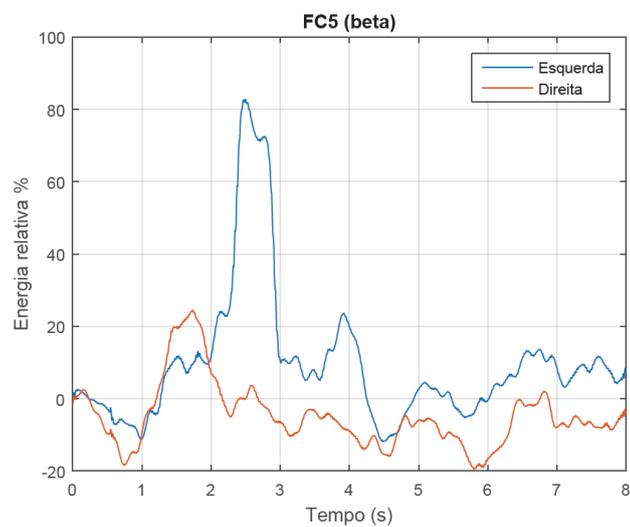
Figura A3: Energia relativa do canal P7 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 2.Figura A4: Energia relativa do canal P8 Sujeito 1 (ritmos α) modelo de trilha 1 sessão 2.Figura A5: Energia relativa do canal FC5 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 2.

Figura A6: Energia relativa do canal FC6 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 2.

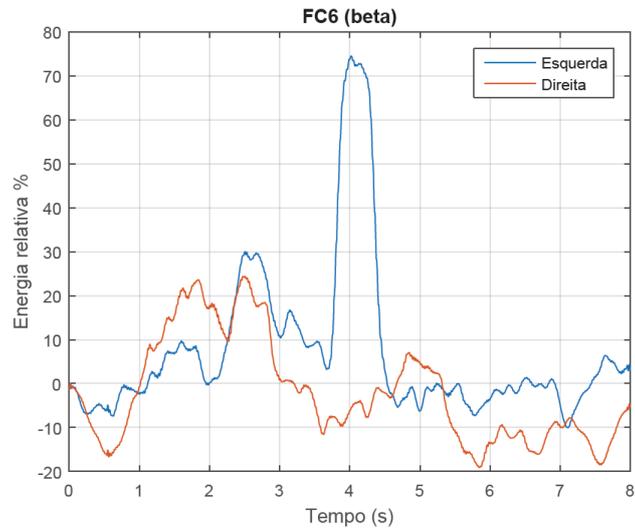


Figura A7: Energia relativa do canal P7 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 2.

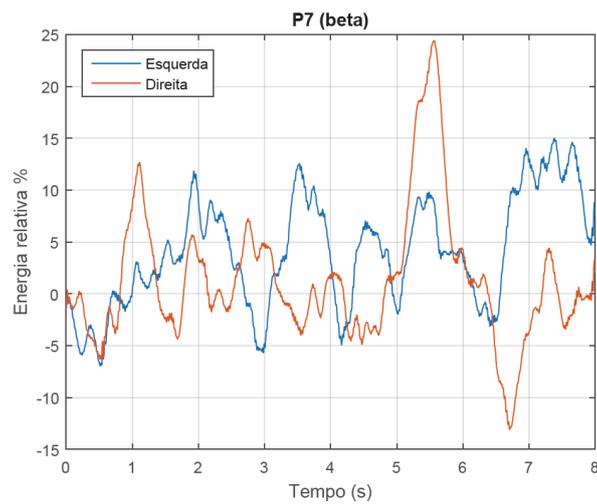
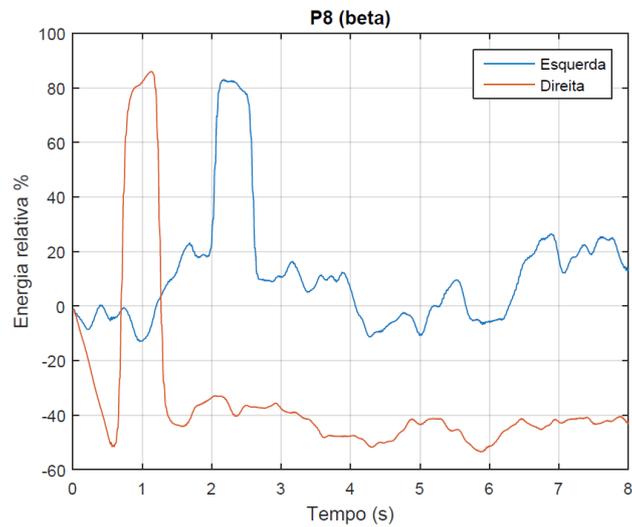


Figura A8: Energia relativa do canal P8 Sujeito 1 (ritmos β) modelo de trilha 1 sessão 2.



ANEXO B – CURVAS DE ENERGIA RELATIVA SUJEITO 1 MODELO DE TRILHA 2 SESSÃO 2

Figura B1: Energia relativa do canal FC5 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 2.

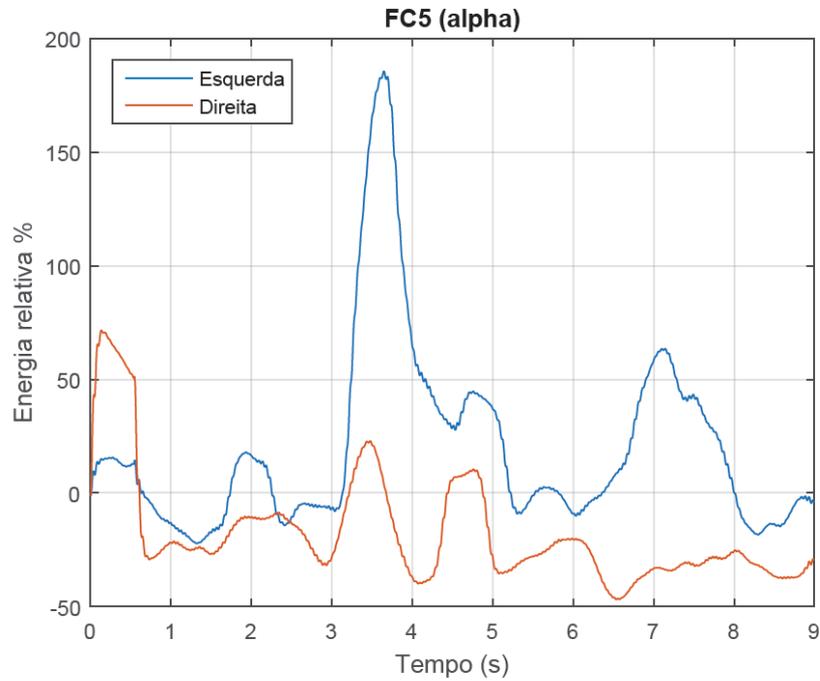


Figura B2: Energia relativa do canal FC6 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 2.

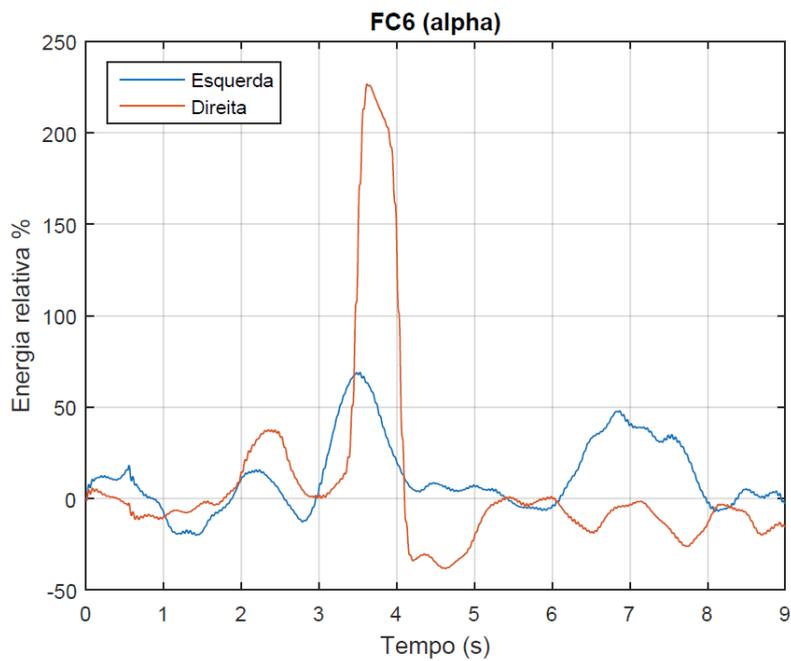


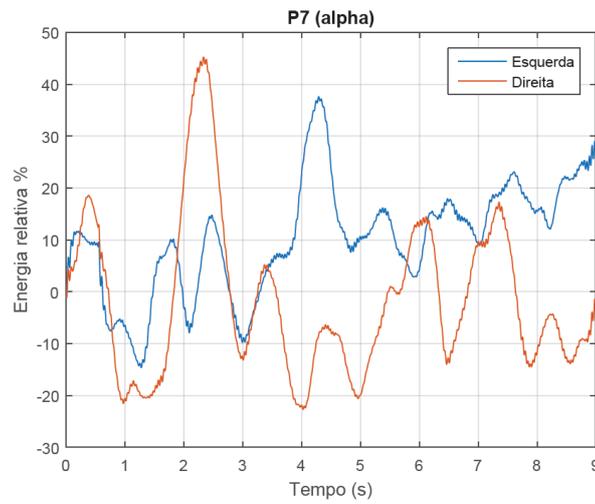
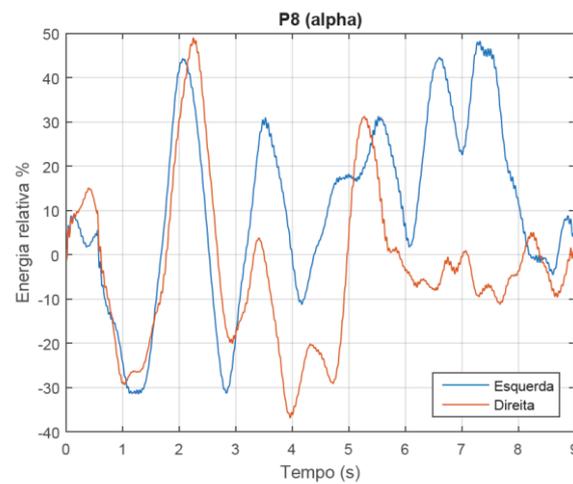
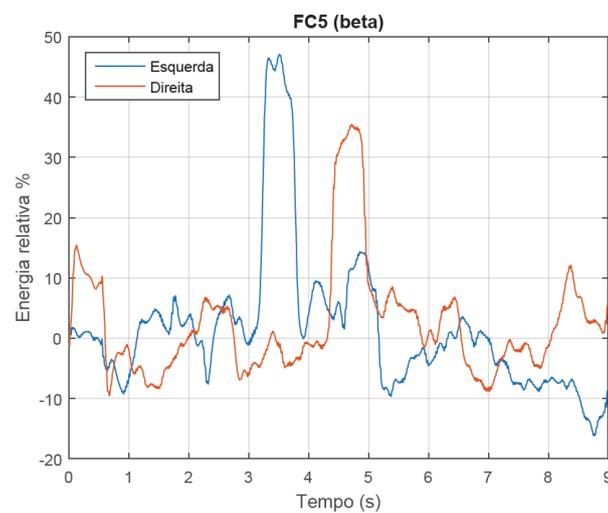
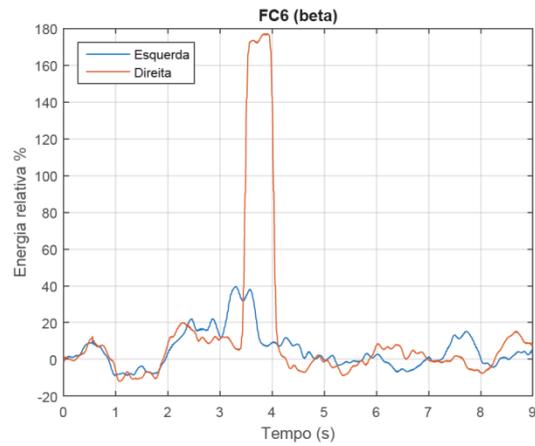
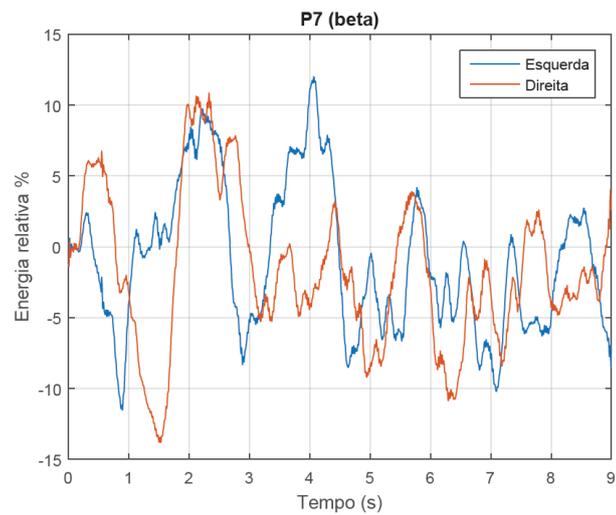
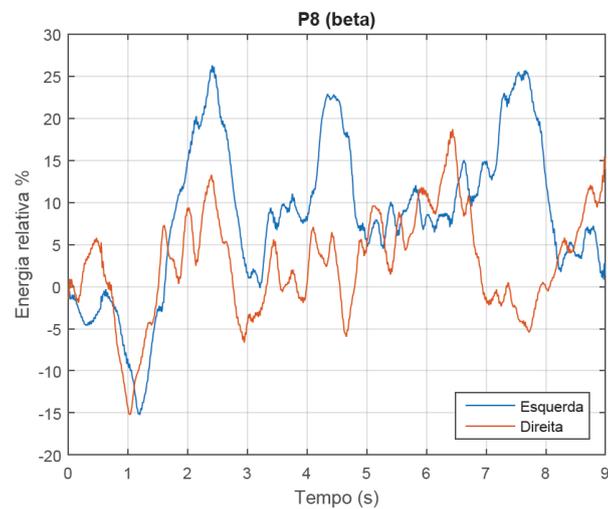
Figura B3: Energia relativa do canal P7 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 2.Figura B4: Energia relativa do canal P8 Sujeito 1 (ritmos α) modelo de trilha 2 sessão 2.Figura B5: Energia relativa do canal FC5 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 2.

Figura B6: Energia relativa do canal FC6 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 2.Figura B7: Energia relativa do canal P7 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 2.Figura B8: Energia relativa do canal FC5 Sujeito 1 (ritmos β) modelo de trilha 2 sessão 2.

ANEXO C – CURVAS DE ENERGIA RELATIVA SUJEITO 2 MODELO DE TRILHA 1 SESSÃO 1

Figura C1: Energia relativa do canal FC5 Sujeito 2 (ritmos α) modelo de trilha 1 sessão 1.

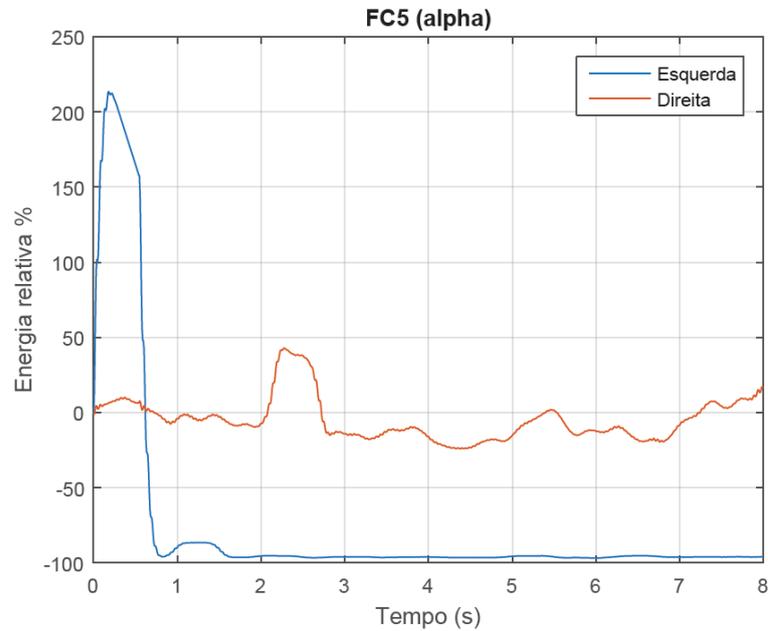


Figura C2: Energia relativa do canal FC6 Sujeito 2 (ritmos α) modelo de trilha 1 sessão 1.

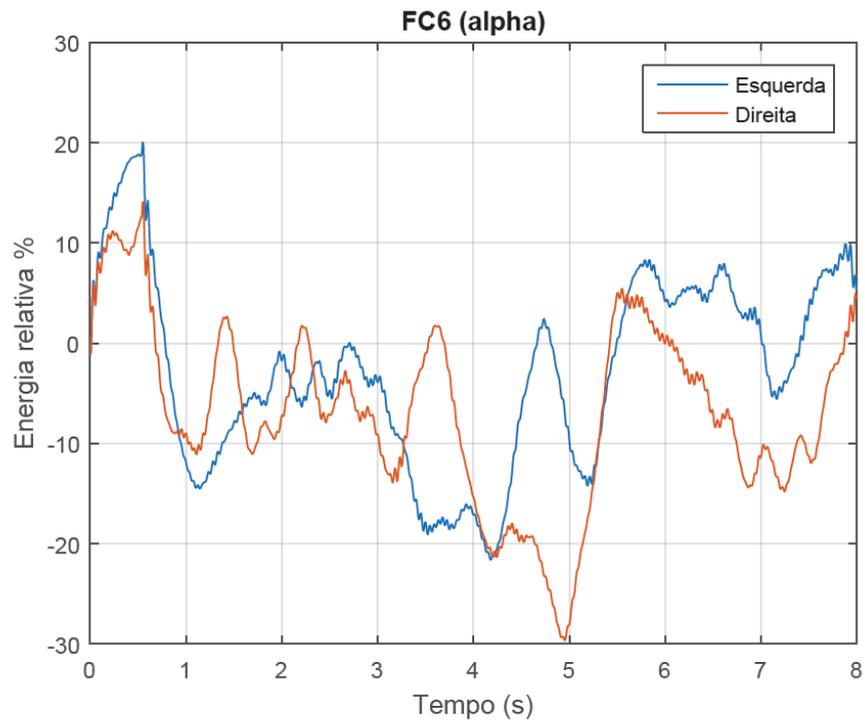


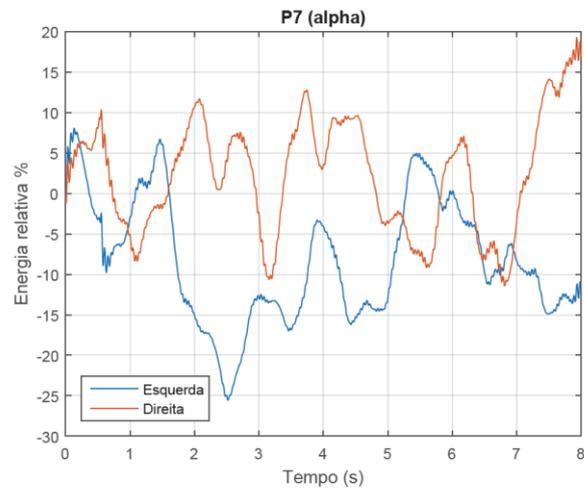
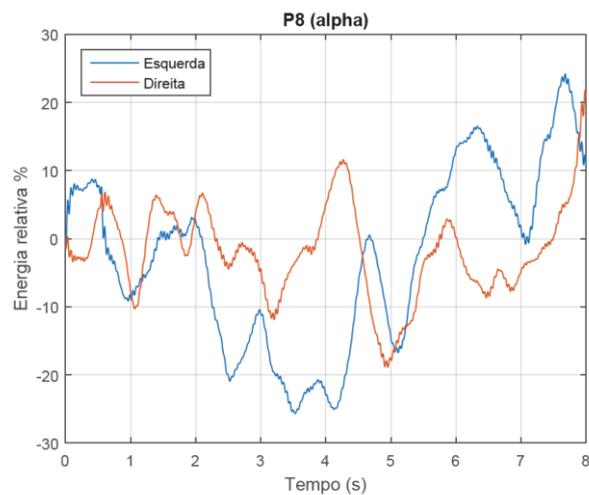
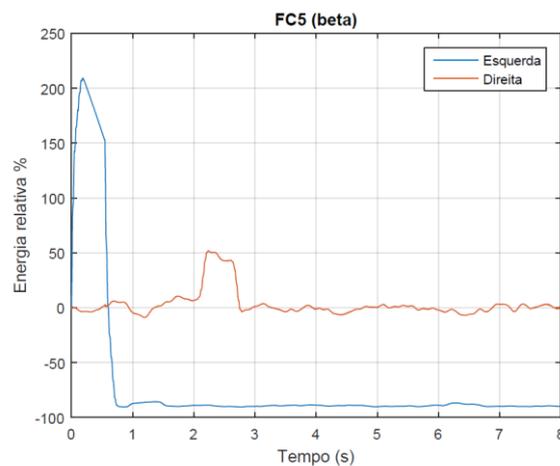
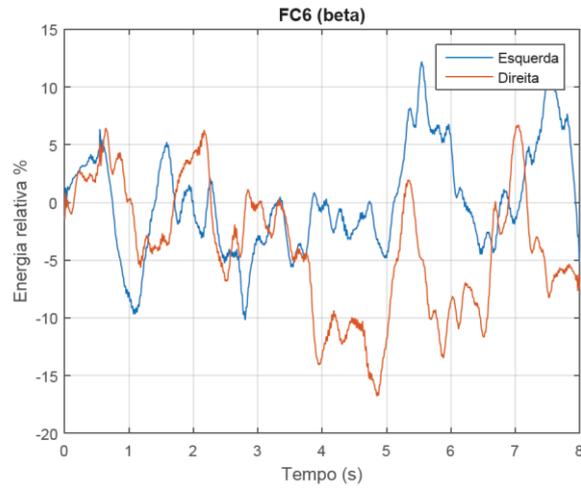
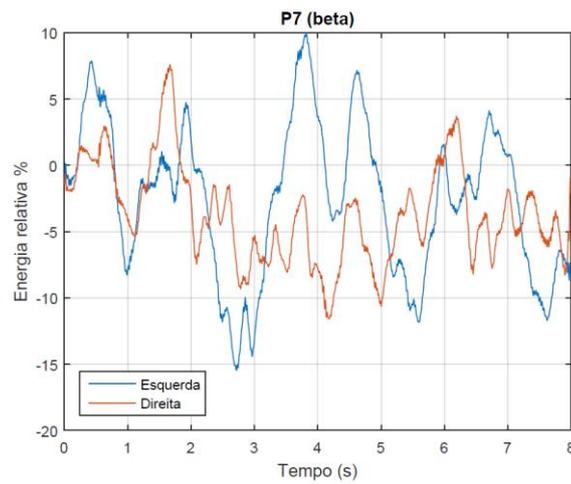
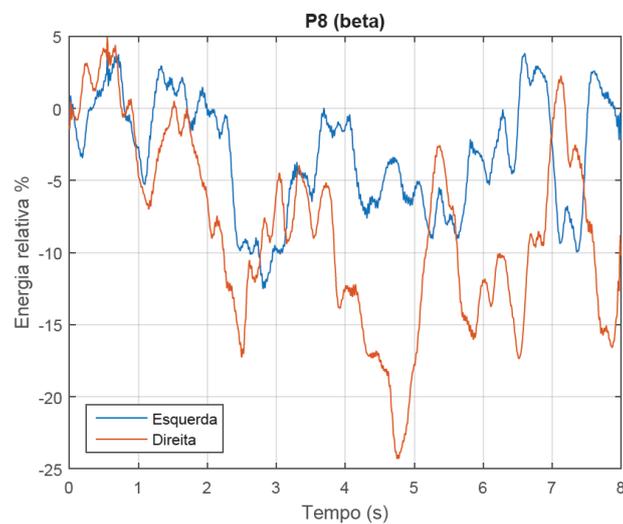
Figura C3: Energia relativa do canal P7 Sujeito 2 (ritmos α) modelo de trilha 1 sessão 1.Figura C4: Energia relativa do canal P8 Sujeito 2 (ritmos α) modelo de trilha 1 sessão 1.Figura C5: Energia relativa do canal FC5 Sujeito 2 (ritmos β) modelo de trilha 1 sessão 1.

Figura C6: Energia relativa do canal FC6 Sujeito 2 (ritmos β) modelo de trilha 1 sessão 1.Figura C7: Energia relativa do canal P7 Sujeito 2 (ritmos β) modelo de trilha 1 sessão 1.Figura C8: Energia relativa do canal P8 Sujeito 2 (ritmos β) modelo de trilha 1 sessão 1.

ANEXO D – CURVAS DE ENERGIA RELATIVA SUJEITO 2 MODELO DE TRILHA 1 SESSÃO 2

Figura D1: Energia relativa do canal FC5 Sujeito 2 (ritmos α) modelo de trilha 1 sessão 2.

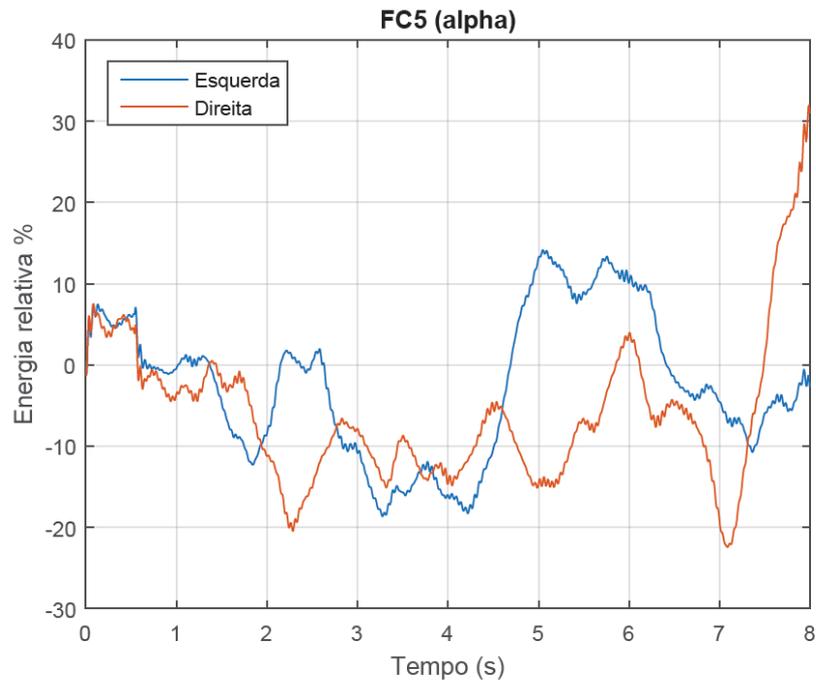


Figura D2: Energia relativa do canal FC6 Sujeito 2 (ritmos α) modelo de trilha 1 sessão 2.

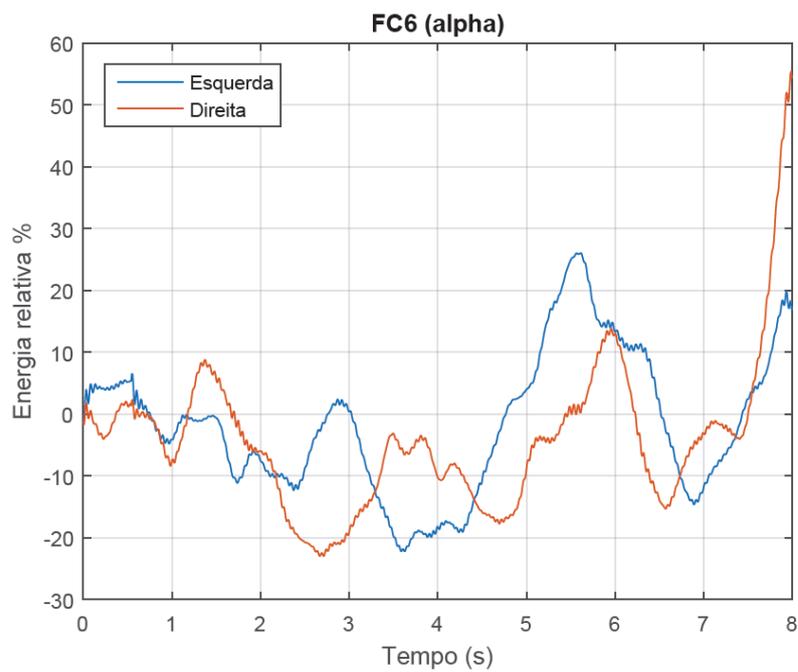


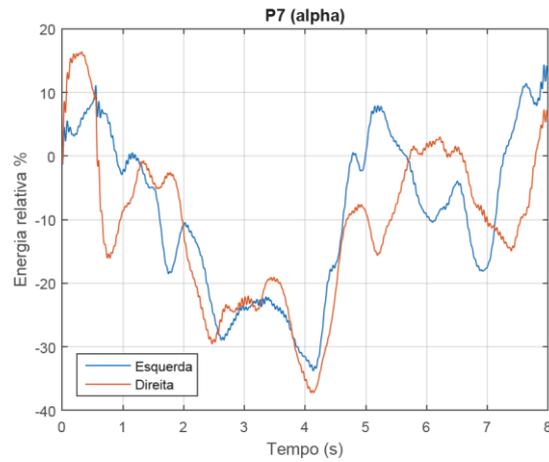
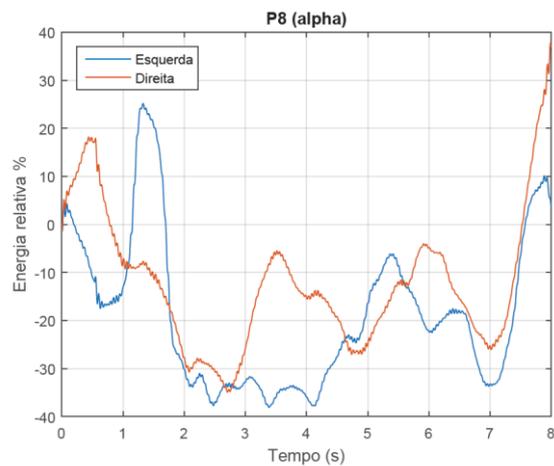
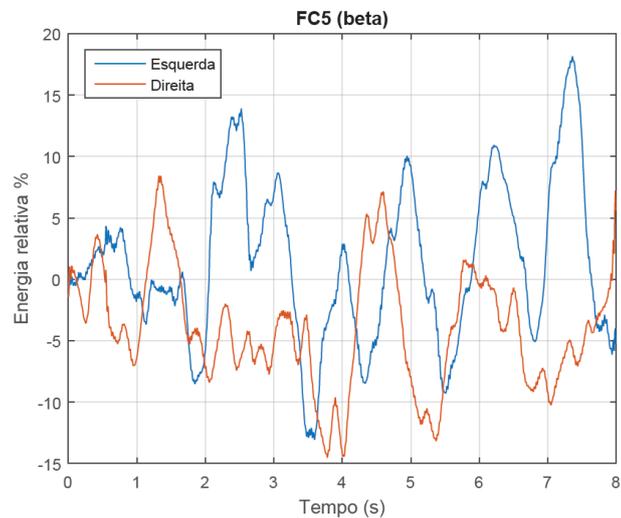
Figura D3: Energia relativa do canal P7 Sujeito 2 (ritmos α) modelo de trilha 1 sessão 2.Figura D4: Energia relativa do canal P8 Sujeito 2 (ritmos α) modelo de trilha 1 sessão 2.Figura D5: Energia relativa do canal FC5 Sujeito 2 (ritmos β) modelo de trilha 1 sessão 2.

Figura D6: Energia relativa do canal FC6 Sujeito 2 (ritmos β) modelo de trilha 1 sessão 2.

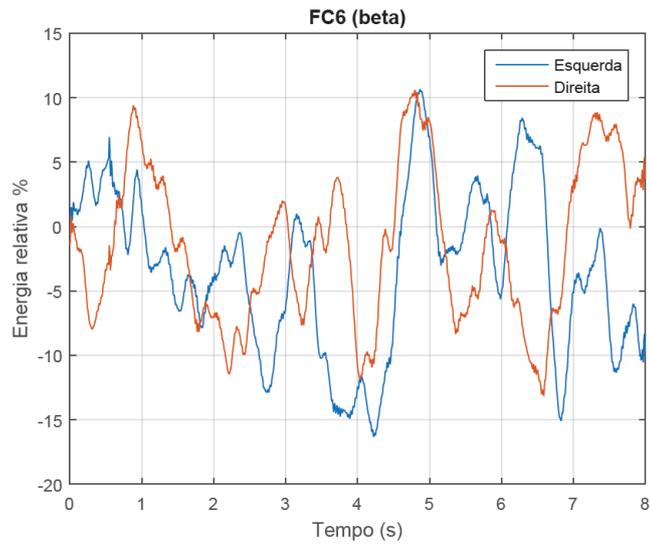


Figura D7: Energia relativa do canal P7 Sujeito 2 (ritmos β) modelo de trilha 1 sessão 2.

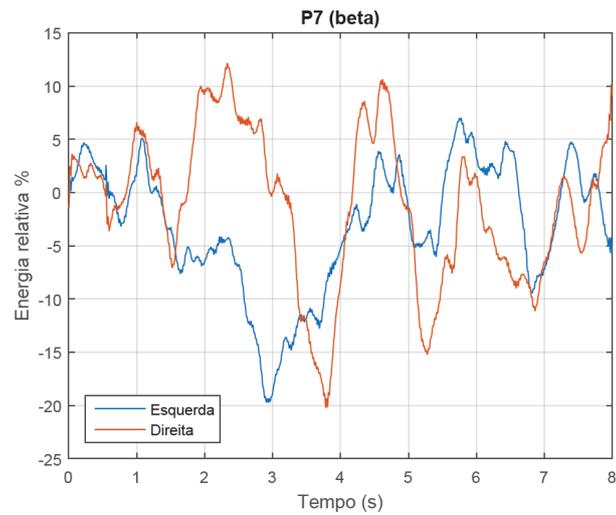
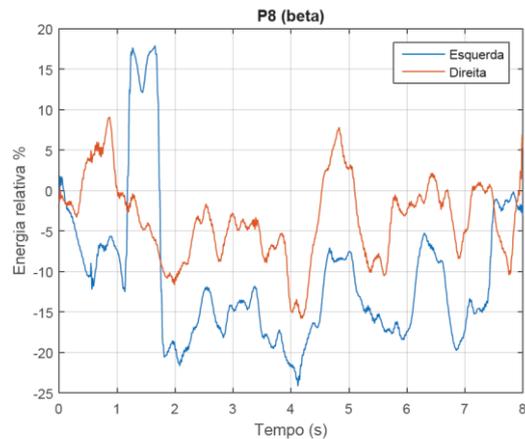


Figura D8: Energia relativa do canal P8 Sujeito 2 (ritmos β) modelo de trilha 1 sessão 2.



ANEXO E – CURVAS DE ENERGIA RELATIVA SUJEITO 2 MODELO DE TRILHA 2 SESSÃO 1

Figura E1: Energia relativa do canal FC5 Sujeito 2 (ritmos α) modelo de trilha 2 sessão 1.

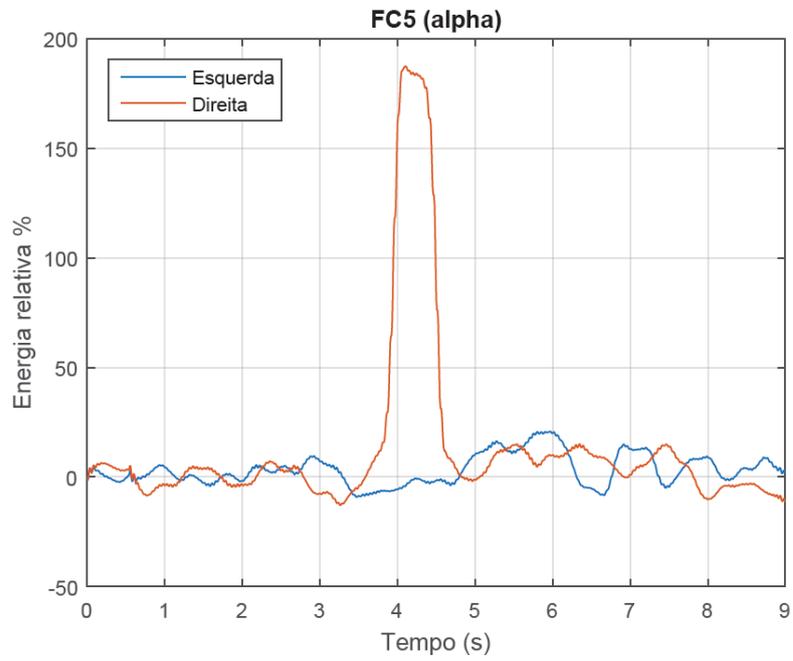


Figura E2: Energia relativa do canal FC6 Sujeito 2 (ritmos α) modelo de trilha 2 sessão 1.

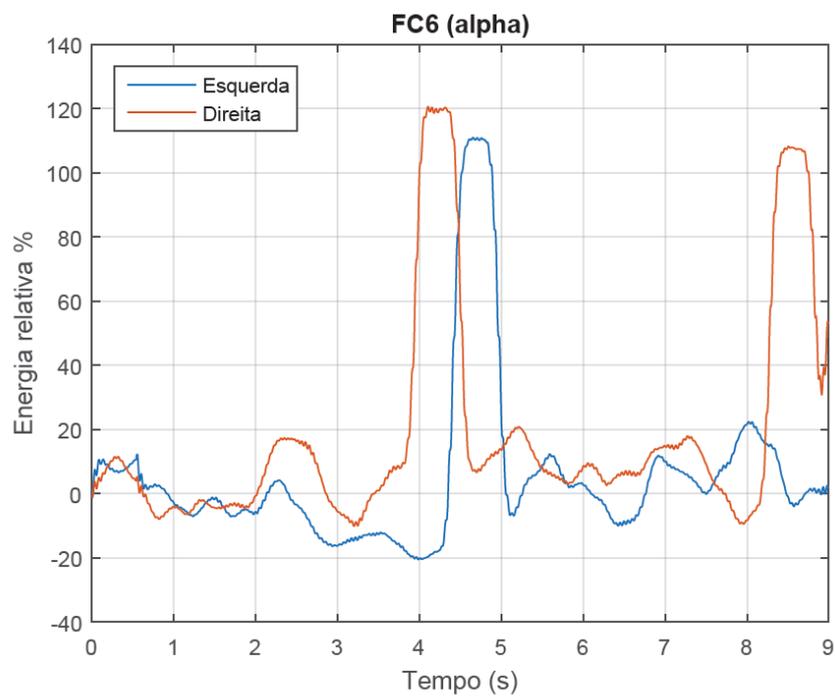


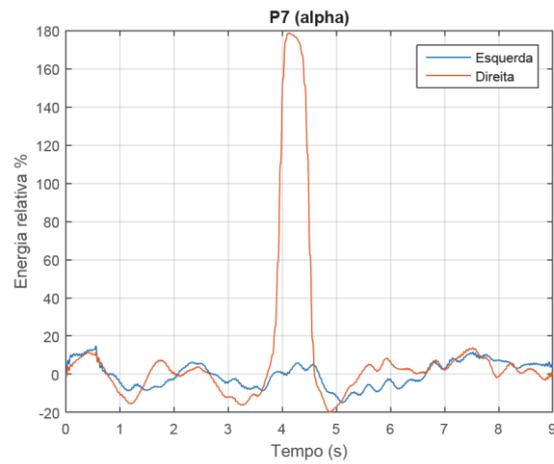
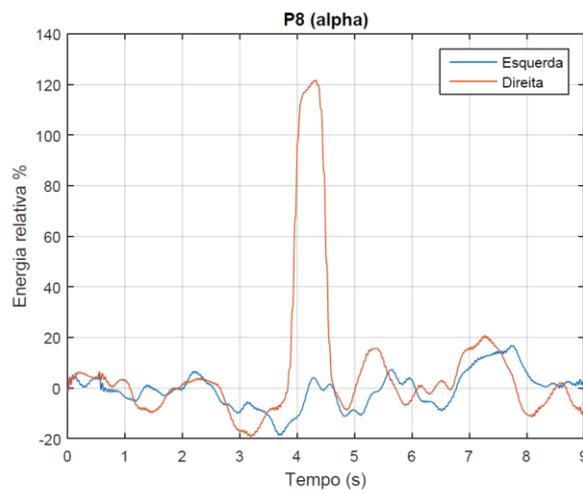
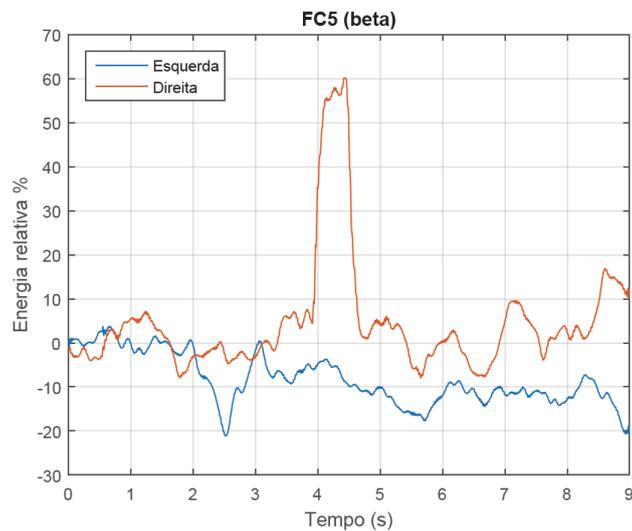
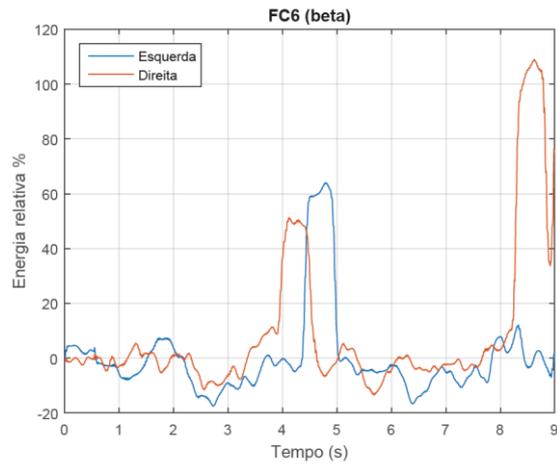
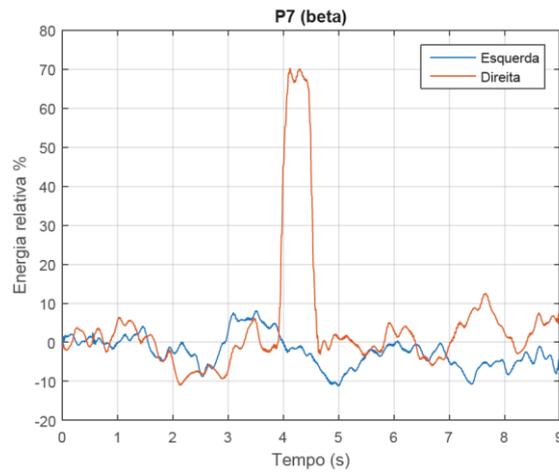
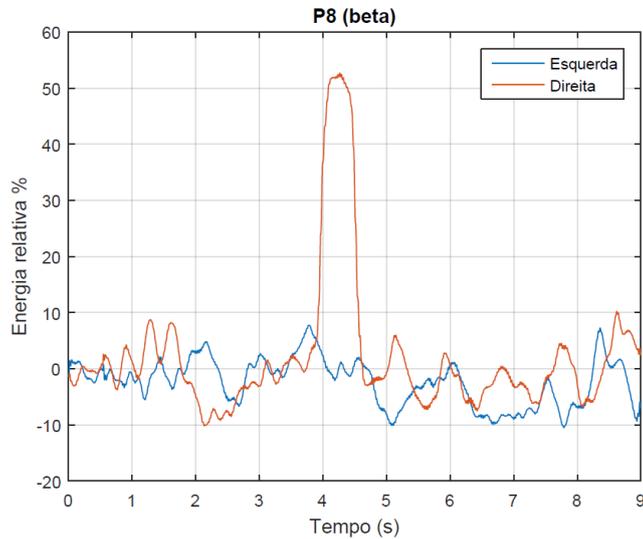
Figura E3: Energia relativa do canal P7 Sujeito 2 (ritmos α) modelo de trilha 2 sessão 1.Figura E4: Energia relativa do canal P8 Sujeito 2 (ritmos α) modelo de trilha 2 sessão 1.Figura E5: Energia relativa do canal FC5 Sujeito 2 (ritmos β) modelo de trilha 2 sessão 1.

Figura E6: Energia relativa do canal FC6 Sujeito 2 (ritmos β) modelo de trilha 2 sessão 1.Figura E7: Energia relativa do canal P7 Sujeito 2 (ritmos β) modelo de trilha 2 sessão 1.Figura E8: Energia relativa do canal P8 Sujeito 2 (ritmos β) modelo de trilha 2 sessão 1.

ANEXO F – CURVAS DE ENERGIA RELATIVA SUJEITO 2 MODELO DE TRILHA 2 SESSÃO 2

Figura F1: Energia relativa do canal FC5 Sujeito 2 (ritmos α) modelo de trilha 2 sessão 2.

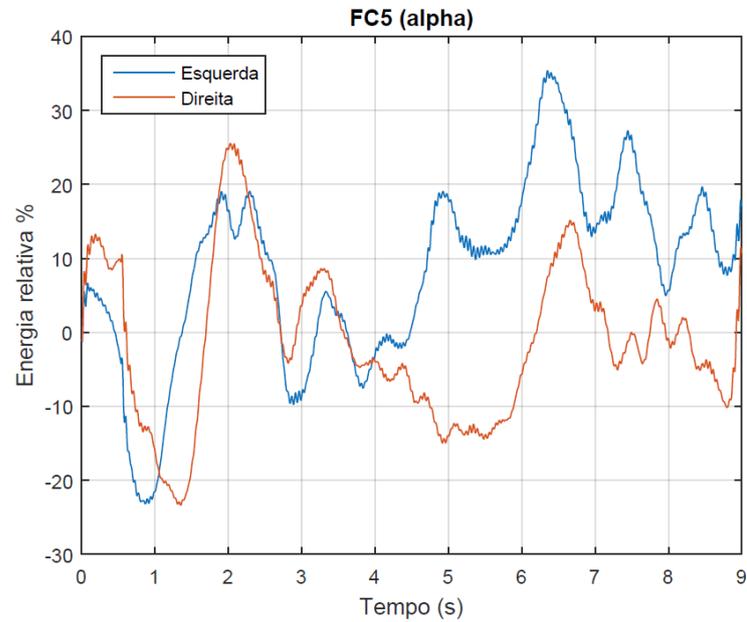


Figura F2: Energia relativa do canal FC6 Sujeito 2 (ritmos α) modelo de trilha 2 sessão 2.

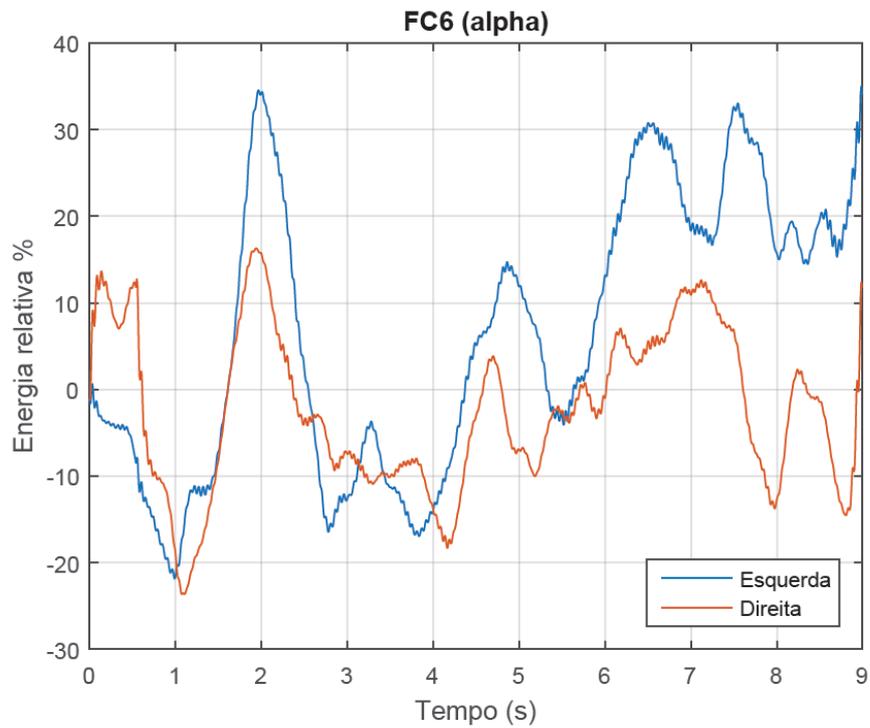


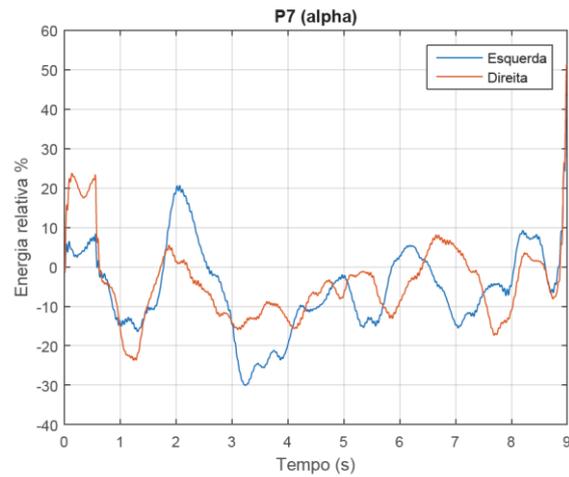
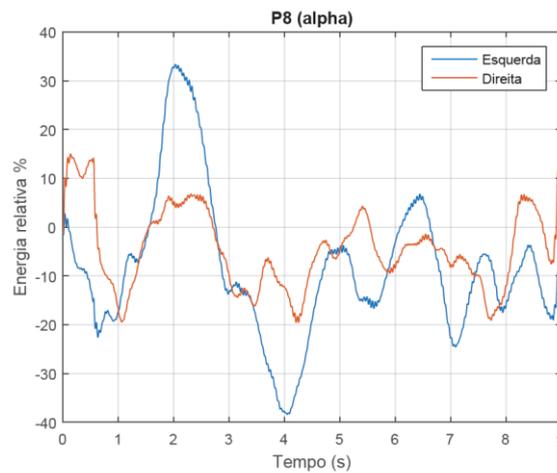
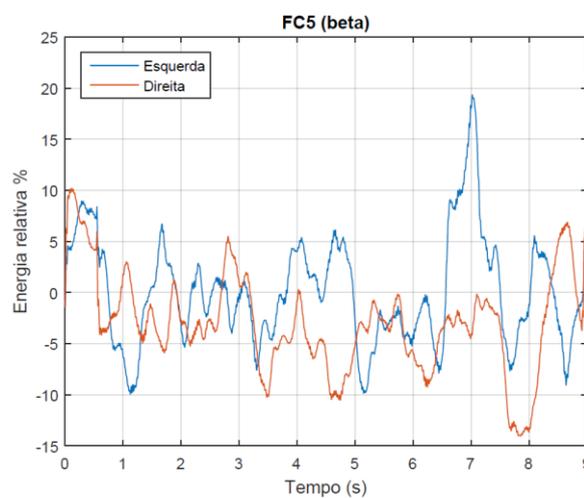
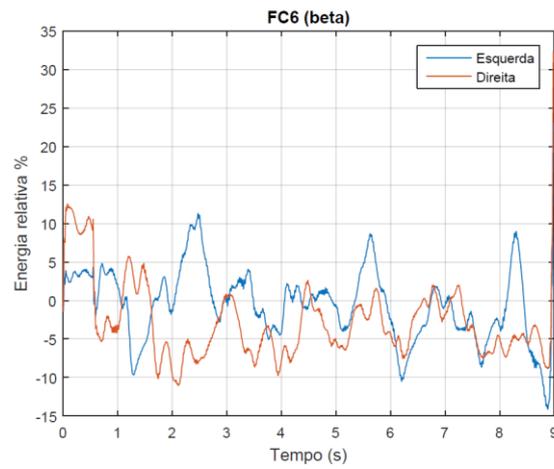
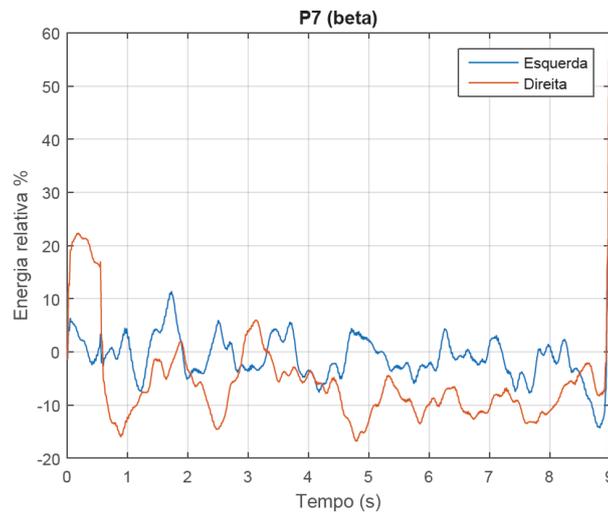
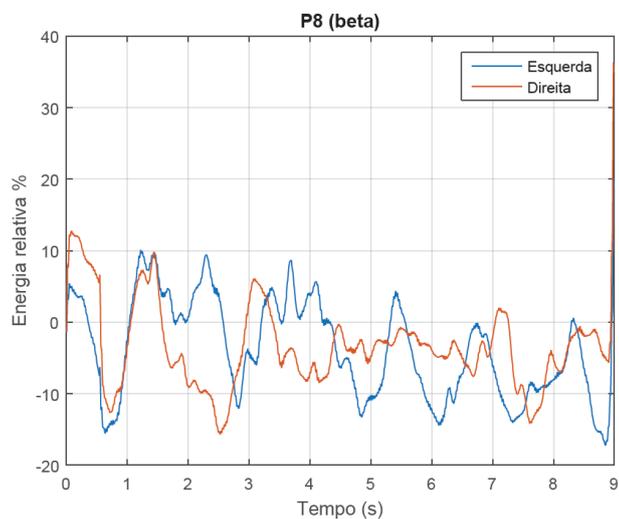
Figura F3: Energia relativa do canal P7 Sujeito 2 (ritmos α) modelo de trilha 2 sessão 2.Figura F4: Energia relativa do canal P8 Sujeito 2 (ritmos α) modelo de trilha 2 sessão 2.Figura F5: Energia relativa do canal FC5 Sujeito 2 (ritmos β) modelo de trilha 2 sessão 2.

Figura F6: Energia relativa do canal FC6 Sujeito 2 (ritmos β) modelo de trilha 2 sessão 2.Figura F7: Energia relativa do canal P7 Sujeito 2 (ritmos β) modelo de trilha 2 sessão 2.Figura F8: Energia relativa do canal P8 Sujeito 2 (ritmos β) modelo de trilha 2 sessão 2.

ANEXO G – CURVAS DE ESPECTRO DE FREQUÊNCIA

Figura G1: Espectro de frequência do canal CSP1 sujeito 1 sessão 2 trilha 1.

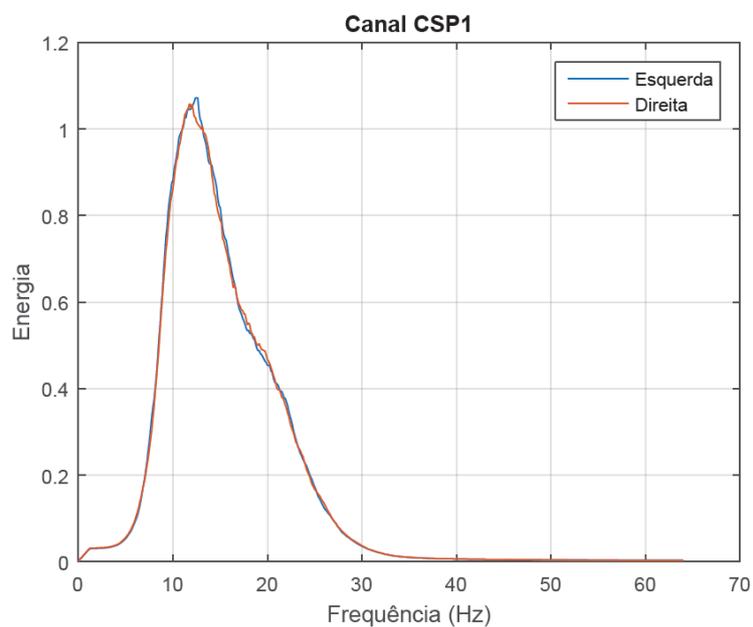


Figura G2: Espectro de frequência do canal CSP2 sujeito 1 sessão 2 trilha 1.

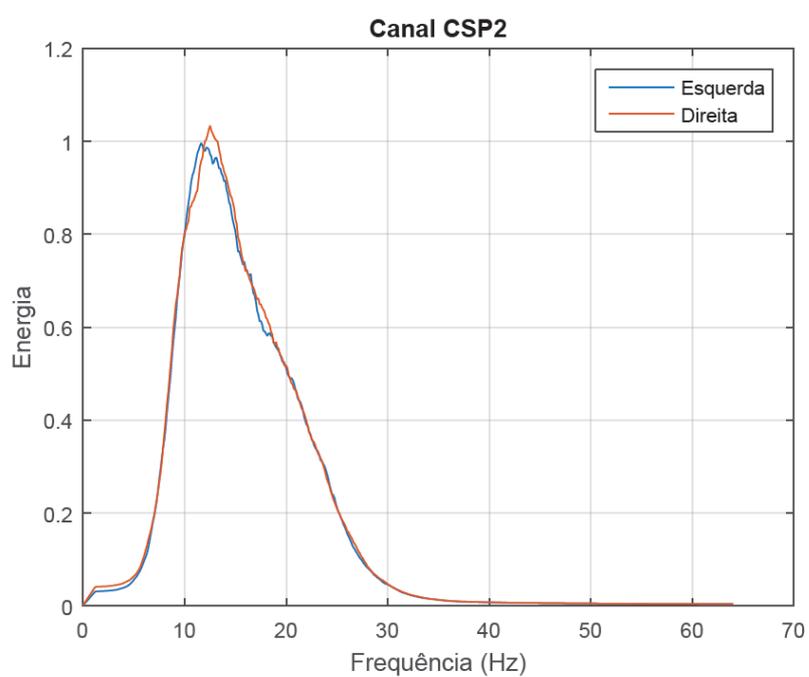


Figura G3: Espectro de frequência do canal CSP1 sujeito 1 sessão 2 trilha 2.

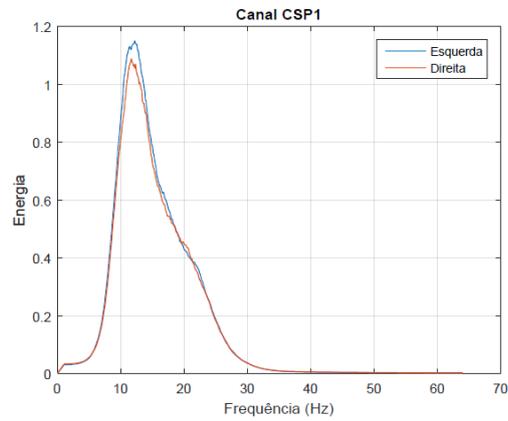


Figura G4: Espectro de frequência do canal CSP2 sujeito 1 sessão 2 trilha 2.

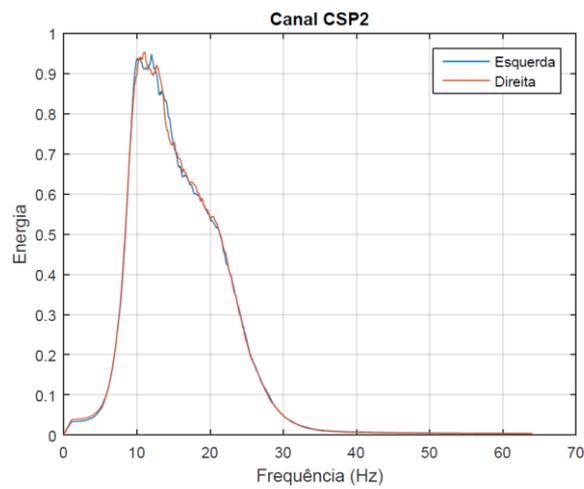


Figura G5: Espectro de frequência do canal CSP1 sujeito 2 sessão 1 trilha 1.

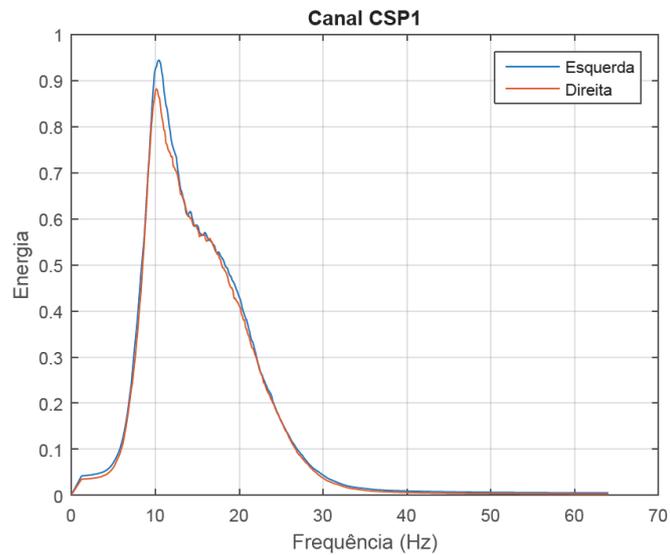


Figura G6: Espectro de frequência do canal CSP2 sujeito 2 sessão 1 trilha 1.

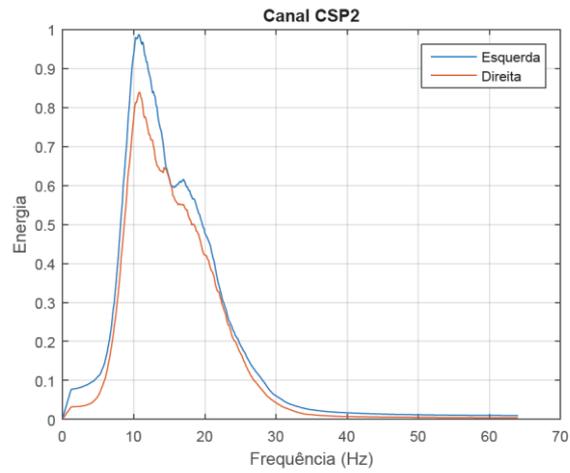


Figura G7: Espectro de frequência do canal CSP1 sujeito 2 sessão 2 trilha 1.

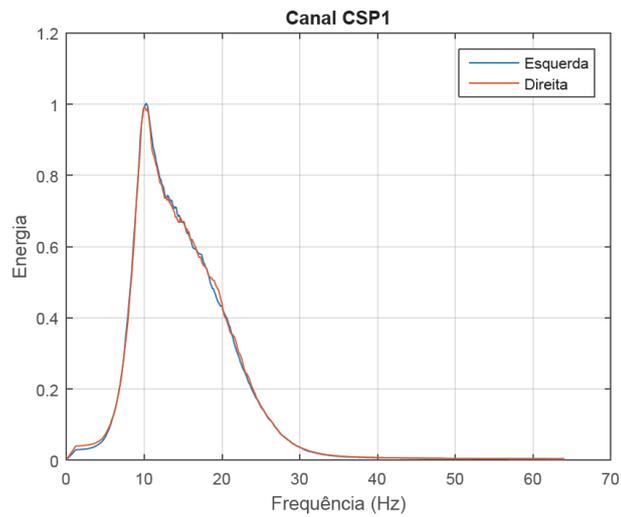


Figura G8: Espectro de frequência do canal CSP2 sujeito 2 sessão 2 trilha 1.

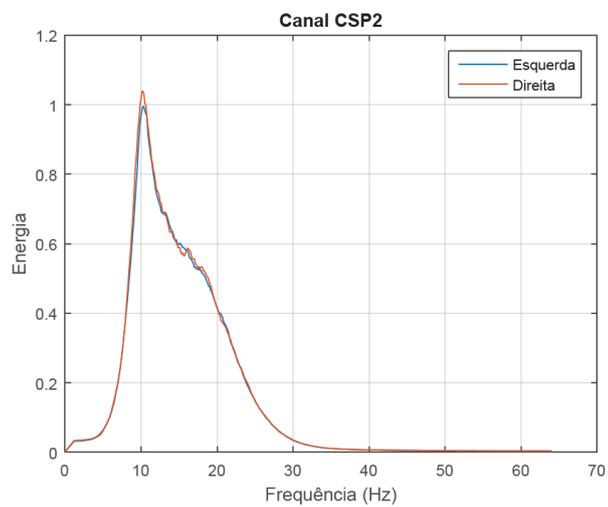


Figura G9: Espectro de frequência do canal CSP1 sujeito 2 sessão 1 trilha 2.

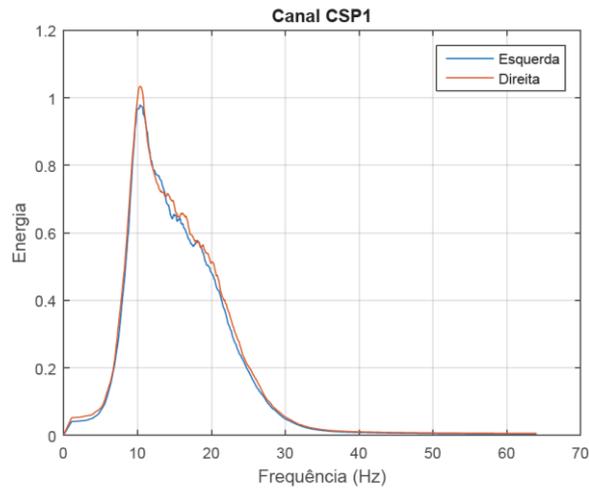


Figura G10: Espectro de frequência do canal CSP2 sujeito 2 sessão 1 trilha 2.

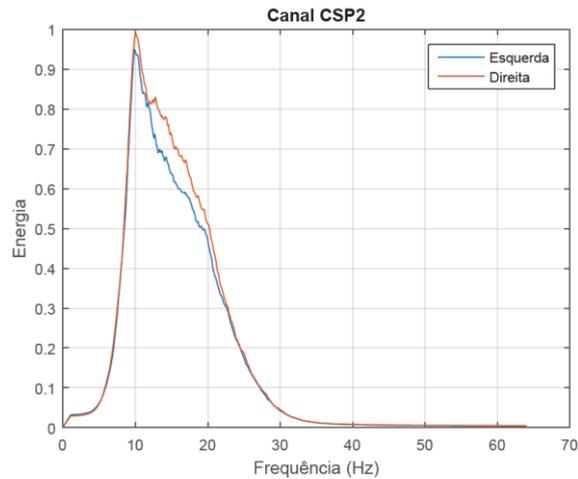


Figura G11: Espectro de frequência do canal CSP1 sujeito 2 sessão 2 trilha 2.

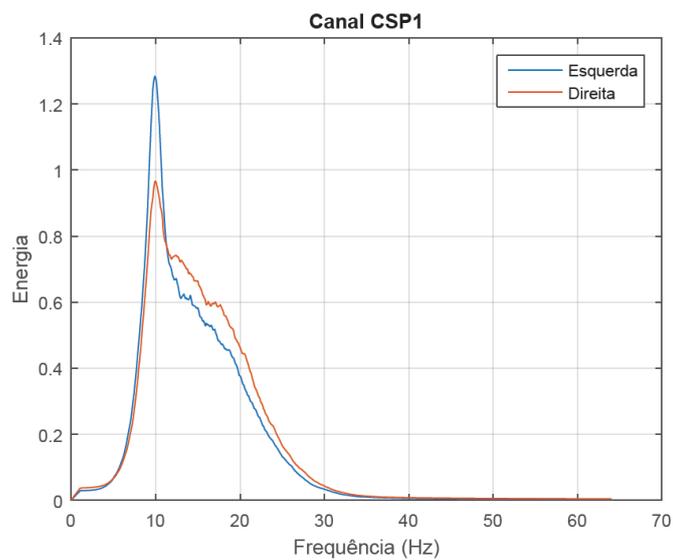
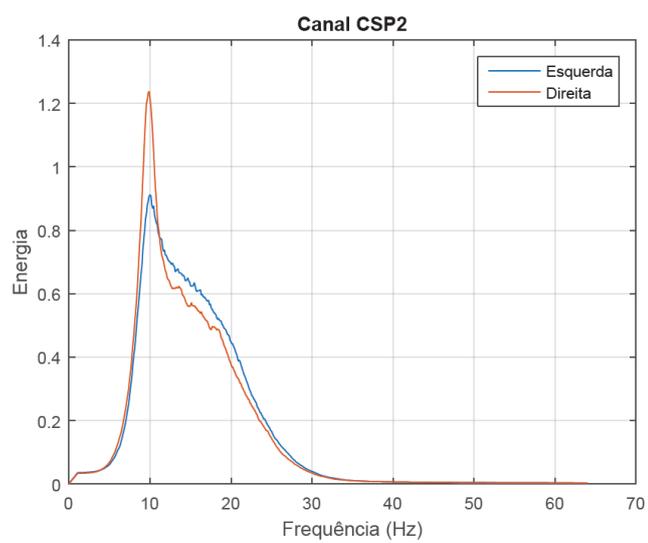


Figura G12: Espectro de frequência do canal CSP2 sujeito 2 sessão 2 trilha 2.



ANEXO H – MATRIZES DE COVARIÂNCIA

Sujeito 1 sessão 2 trilha 1:

$$\Lambda^d = \begin{pmatrix} 0,4757 & 0 & 0 & 0 \\ 0 & 0,5117 & 0 & 0 \\ 0 & 0 & 0,5080 & 0 \\ 0 & 0 & 0 & 0,4943 \end{pmatrix} \quad (22)$$

$$\Lambda^e = \begin{pmatrix} 0,5243 & 0 & 0 & 0 \\ 0 & 0,4883 & 0 & 0 \\ 0 & 0 & 0,4920 & 0 \\ 0 & 0 & 0 & 0,5057 \end{pmatrix} \quad (23)$$

Sujeito 1 sessão 2 trilha 2:

$$\Lambda^d = \begin{pmatrix} 0,4768 & 0 & 0 & 0 \\ 0 & 0,5320 & 0 & 0 \\ 0 & 0 & 0,5080 & 0 \\ 0 & 0 & 0 & 0,5024 \end{pmatrix} \quad (24)$$

$$\Lambda^e = \begin{pmatrix} 0,5232 & 0 & 0 & 0 \\ 0 & 0,4680 & 0 & 0 \\ 0 & 0 & 0,4920 & 0 \\ 0 & 0 & 0 & 0,4976 \end{pmatrix} \quad (25)$$

Sujeito 2 sessão 1 trilha 1:

$$\Lambda^d = \begin{pmatrix} 0,5227 & 0 & 0 & 0 \\ 0 & 0,5112 & 0 & 0 \\ 0 & 0 & 0,4860 & 0 \\ 0 & 0 & 0 & 0,4964 \end{pmatrix} \quad (26)$$

$$\Lambda^e = \begin{pmatrix} 0,4773 & 0 & 0 & 0 \\ 0 & 0,4888 & 0 & 0 \\ 0 & 0 & 0,5140 & 0 \\ 0 & 0 & 0 & 0,5036 \end{pmatrix} \quad (27)$$

Sujeito 2 sessão 2 trilha 1:

$$\Lambda^d = \begin{pmatrix} 0,5301 & 0 & 0 & 0 \\ 0 & 0,5015 & 0 & 0 \\ 0 & 0 & 0,4878 & 0 \\ 0 & 0 & 0 & 0,4852 \end{pmatrix} \quad (28)$$

$$\Lambda^e = \begin{pmatrix} 0,4699 & 0 & 0 & 0 \\ 0 & 0,4985 & 0 & 0 \\ 0 & 0 & 0,5122 & 0 \\ 0 & 0 & 0 & 0,5148 \end{pmatrix} \quad (29)$$

Sujeito 2 sessão 1 trilha 2:

$$\Lambda^d = \begin{pmatrix} 0,4629 & 0 & 0 & 0 \\ 0 & 0,5309 & 0 & 0 \\ 0 & 0 & 0,5080 & 0 \\ 0 & 0 & 0 & 0,4983 \end{pmatrix} \quad (30)$$

$$\Lambda^e = \begin{pmatrix} 0,5371 & 0 & 0 & 0 \\ 0 & 0,4691 & 0 & 0 \\ 0 & 0 & 0,4920 & 0 \\ 0 & 0 & 0 & 0,5017 \end{pmatrix} \quad (31)$$

Sujeito 2 sessão 2 trilha 2:

$$\Lambda^d = \begin{pmatrix} 0,5399 & 0 & 0 & 0 \\ 0 & 0,5176 & 0 & 0 \\ 0 & 0 & 0,4954 & 0 \\ 0 & 0 & 0 & 0,4829 \end{pmatrix} \quad (32)$$

$$\Lambda^e = \begin{pmatrix} 0,4601 & 0 & 0 & 0 \\ 0 & 0,4824 & 0 & 0 \\ 0 & 0 & 0,5046 & 0 \\ 0 & 0 & 0 & 0,5171 \end{pmatrix} \quad (33)$$

ANEXO I – CURVAS DE ÍNDICE DE LATERALIZAÇÃO

Figura I1: Índice de lateralização para o modelo de trilha 1 sessão 2 sujeito 1.

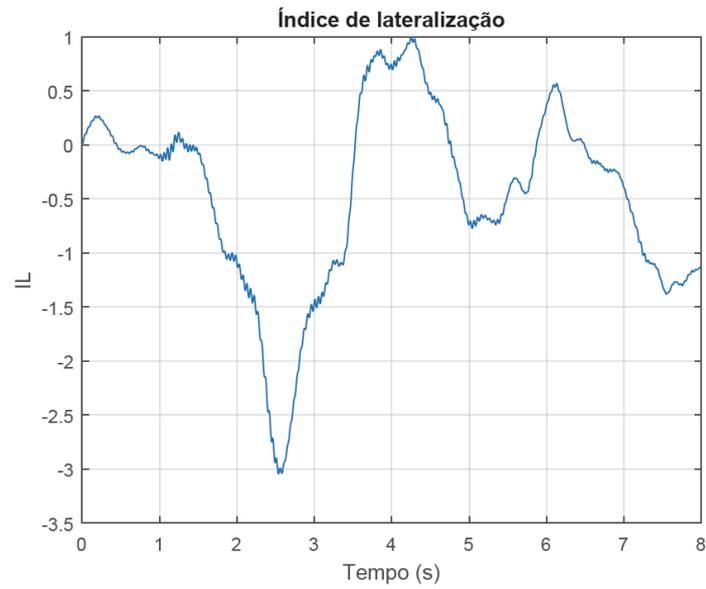


Figura I2: Índice de lateralização para o modelo de trilha 2 sessão 2 sujeito 1.

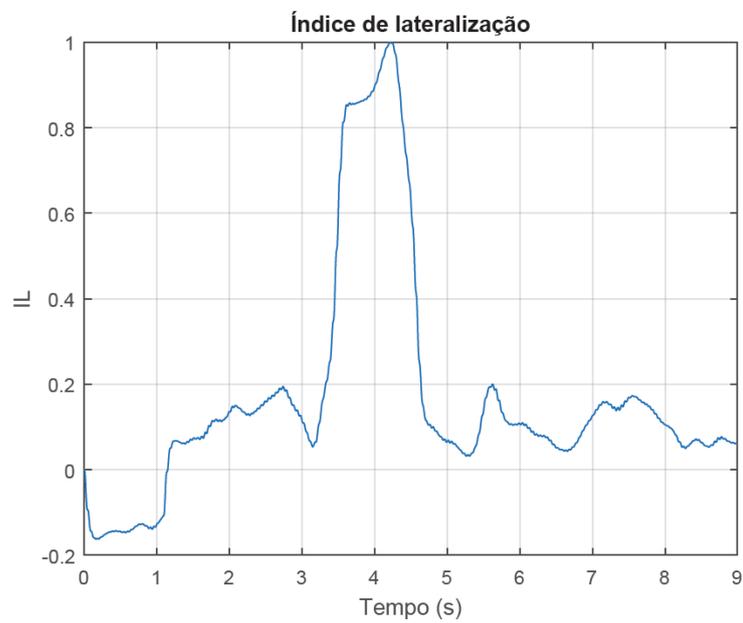


Figura I3: Índice de lateralização para o modelo de trilha 1 sessão 1 sujeito 2.

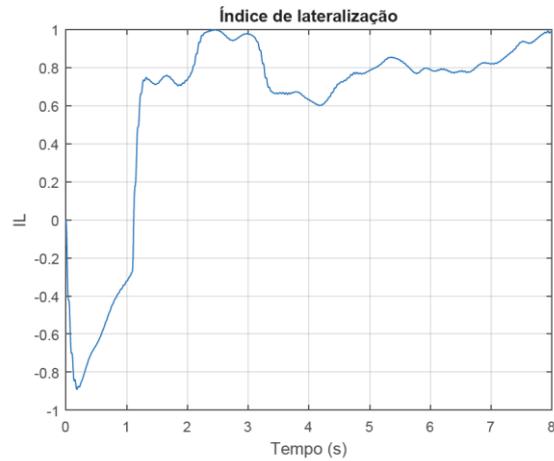


Figura I4: Índice de lateralização para o modelo de trilha 1 sessão 2 sujeito 2.

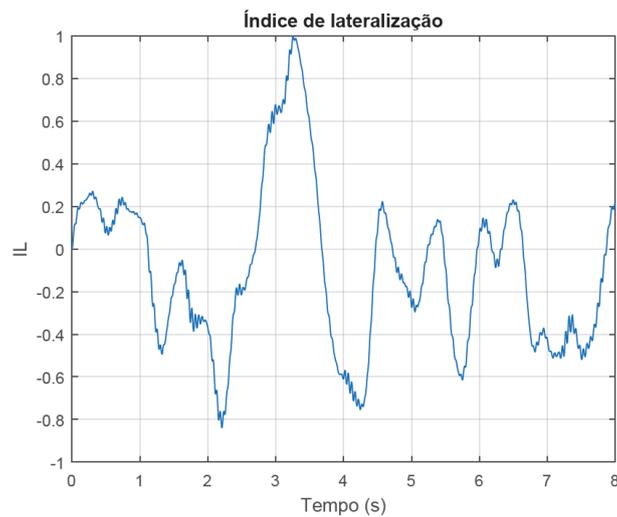


Figura I5: Índice de lateralização para o modelo de trilha 2 sessão 1 sujeito 2.

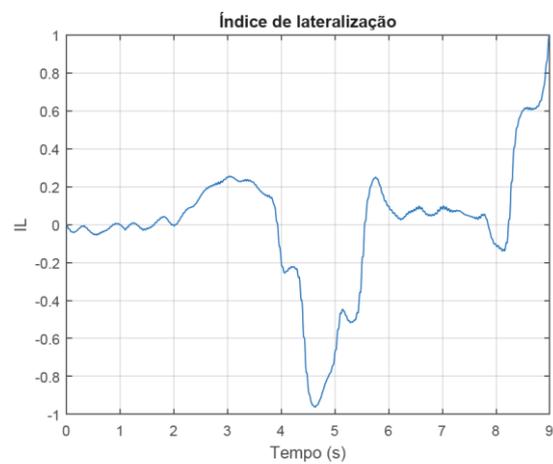


Figura I6: Índice de lateralização para o modelo de trilha 2 sessão 2 sujeito 2.

