

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

Gabriel da Costa Florisbal

**Análise e Classificação de Sinais de EEG a
partir de Movimentação Passiva em Pacientes
Sedados**

Porto Alegre

2021

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

Gabriel da Costa Florisbal

**Análise e Classificação de Sinais de EEG a partir de
Movimentação Passiva em Pacientes Sedados**

Trabalho de Conclusão de Curso de Engenharia Elétrica desenvolvido no Laboratório de Instrumentação Eletro Eletrônica & Instrumentação Biomédica como parte dos requisitos para aprovação na disciplina de Projeto de Diplomação.

UFRGS

Orientador: Prof. Dr. Alexandre Balbinot

Porto Alegre

2021

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

Gabriel da Costa Florisbal

Análise e Classificação de Sinais de EEG a partir de Movimentação Passiva em Pacientes Sedados

Trabalho de Conclusão de Curso de Engenharia Elétrica desenvolvido no Laboratório de Instrumentação Eletro Eletrônica & Instrumentação Biomédica como parte dos requisitos para aprovação na disciplina de Projeto de Diplomação.

Prof. Dr. Alexandre Balbinot
Orientador

Prof. Dr. Tiago Oliveira Weber
UFRGS
Banca Examinadora

Prof. Me. Juliano Costa Machado
IFSUL
Banca Examinadora

Porto Alegre

2021

Dedico este trabalho ao meu pai, Carlos Augusto (*in memoriam*), e a minha mãe, Maria Corinta, que sempre me apoiaram e deram todo suporte necessário para realização dos meus objetivos de vida, não medindo esforços para me proporcionarem tudo que estava aos seus alcances.

AGRADECIMENTOS

Ao meu orientador, Alexandre Balbinot, pela oportunidade de realização desse trabalho e por todo aprendizado durante a jornada no IEE.

Aos colegas do Laboratório de Instrumentação Eletro-eletrônica e Biosinais por todo conhecimento e momentos compartilhados. Em especial ao professor Juliano Machado, por todo incentivo ao acesso à pesquisa e desenvolvimento acadêmico.

RESUMO

Recentemente, a eletroencefalografia é o foco de diversas pesquisas, como: análise de sinais, desenvolvimento de sistemas *Brain Computer Interface* (BCI), uso para diagnósticos e aumento sobre o conhecimento do cérebro humano. Estas pesquisas utilizam-se de diferentes fenômenos cerebrais. Um dos fenômenos estudados para distintas aplicações são os relacionados a *Event-Related Potential* (ERP) - potenciais relacionados a eventos. Neste trabalho são analisados dois fenômenos principais relacionados a eventos, o *Event-related desynchronization* (ERD) e *Event-related synchronization* (ERS). Estes fenômenos são relacionados à dessincronização/sincronização do sinal devido à realização de movimentos de forma ativa, passiva, ou ainda, imaginação de movimentos. O ERD e ERS podem ser analisados visualmente e através de classificadores em sinais adquiridos a partir de mobilização passiva em três pacientes sedados em UTI e dois voluntários não-sedados. Os sinais são divididos em trilhas, com mobilização passiva realizada em períodos síncronos nos braços esquerdo e direito. Este sinal é adquirido a partir da touca *Emotiv*, processado a partir de filtros *butterworth* digitais, filtros de *outliers* e filtros *Common Spatial Pattern* (CSP) a fim de aumentar a discriminação entre classes e permitir a visualização dos fenômenos. São extraídas as características no domínio tempo e frequência para utilização nos classificadores, sendo elas: RMS, *Differential Entropy*, PSD com o método de Welch e desvio padrão. São comparados os classificadores Discriminante Linear de Fischer (LDA) e *Extreme Learning Machines* (ELM). As melhores taxas de acerto obtidas a partir dos experimentos foram de $75,6 \pm 2\%$, para um voluntário do grupo de controle (voluntário não sedado) e de $78,3 \pm 2,8\%$ para um paciente sedado, com a média aritmética das taxas de acertos dos grupos na mesma faixa percentual.

Palavras-chave: *BCI*, eletroencefalografia, mobilização passiva, *LDA*, *ELM*.

ABSTRACT

Currently, electroencephalography is the focus of several researches, such as: signal analysis, development of BCI (Brain Computer Interface) systems, use for diagnostics and increased knowledge of the human brain. These researches use different brain phenomena. One of the phenomena studied for different applications are those related to ERP (event-related potentials). In this study, two main event-related phenomena are analyzed, ERD (Event-related desynchronization) and ERS (Event-related synchronization). These phenomena are related to desynchronization / synchronization of the signal due to the performance of movements in an active, passive way, or even, imagination of movements. ERD and ERS can be analyzed visually and through classifiers on signals acquired from passive mobilization in three ICU sedated patients and two non-sedated volunteers. The signals are divided into tracks, with passive mobilization performed in synchronous periods in the left and right arms. This signal is acquired from the Emotiv headset, filtered from digital butterworth filters, outliers filters and CSP filters (Common Spatial Pattern) in order to increase the discrimination between classes and allow visualization of the phenomena. Features in time and frequency domain for use in the classifiers are extracted: RMS, Differential Entropy, PSD with Welch method and standard deviation. LDA (Fischer Linear Discriminant) and ELM (Extreme Learning Machines) classifiers are compared. The best accuracy obtained from the experiments were 75.6 ± 2.2 % for a volunteer from control group and 78.3 ± 2.8 % from a sedated patient, with the arithmetic mean of accuracy of the groups in the same percentage range.

Keywords: BCI, electroencephalography, passive mobilization, LDA, ELM .

SUMÁRIO

1	INTRODUÇÃO	15
2	REVISÃO BIBLIOGRÁFICA	17
2.1	Introdução à Anatomia do Cérebro Humano e o Córtex Motor	17
2.2	Eletroencefalografia: princípios básicos	21
2.2.1	Potenciais Relacionados a Eventos	23
2.2.2	Captura do Sinal de EEG e Sistema Internacional 10-20	24
2.3	Típico Sistema BCI	25
2.4	Trabalhos Relacionados sobre Mobilização Passiva/Eletro-estimulada e Resposta Motora sobre alteração no Estado de Consciência	27
3	FUNDAMENTAÇÃO TEÓRICA	31
3.1	Filtros <i>Common Spatial Pattern</i>	31
3.2	Classificadores	34
3.2.1	<i>Linear Discriminant Analysis</i>	34
3.2.2	<i>Extreme Learning Machines</i>	36
4	METODOLOGIA	39
4.1	Plataforma Experimental e Protocolo de Aquisição	40
4.1.1	Pacientes Sedados em Unidades de Terapia Intensiva e Grupo de Controle	41
4.1.2	Interface de Aquisição	43
4.2	Pré-Processamento e Extração de Características	46
4.3	Etapa para Visualização do Sinal e Fenômenos	52
4.3.1	Visualização dos fenômenos de ERD/ERS	53
4.3.2	Visualização a partir do Índice de Laterização	53
4.4	Classificadores	54
4.4.1	<i>Linear Discriminant Analysis</i>	56
4.4.2	<i>Regularized Extreme Learning Machines</i>	56
4.5	Planejamento Experimental	58
4.5.1	Variações do Conjunto de <i>features</i> para o Modelo de ELM	58

4.5.2	Variação de Frequências e Janelas de Tempo	59
4.6	Base Padrão de Sinais de EEG	60
5	RESULTADOS E DISCUSSÕES	62
5.1	Validação do Método a partir da Base <i>BCI Competition II</i>	62
5.1.1	Análise do Sinal	62
5.1.2	Classificadores	66
5.2	Análise da Energia do Sinal - Pacientes Sedados e Grupos de Controle	68
5.2.1	Índice de Laterização no Tempo	72
5.2.2	Índice de Laterização no Domínio Frequência	74
5.3	Classificadores - Pacientes Sedados e Grupos de Controle	76
5.3.1	Classificador utilizando LDA	79
5.3.2	Classificador utilizando ELM	80
5.4	Experimentos Propostos	83
5.4.1	Variações do Conjunto de <i>Features</i> para o Modelo de ELM	83
5.4.2	Variação de Frequências e Janelas de Tempo	85
6	CONCLUSÕES	90
6.1	Trabalhos Futuros	91
	REFERÊNCIAS	92
	ANEXO A – CÓDIGOS DESENVOLVIDOS NO <i>SOFTWARE LAB-</i>	
	<i>VIEW</i>	96
	ANEXO B – FORMA DE ONDA DE ATRIBUTOS PARA SUJEI-	
	TOS E PACIENTES	99

LISTA DE FIGURAS

Figura 1 – Representação da divisão do Encéfalo. Fonte: (TORTORA; DERRICKSON, 2016).	17
Figura 2 – Vista Superior das Subdivisões do Córtex. Fonte: (TORTORA; DERRICKSON, 2016).	18
Figura 3 – Vista Lateral Direita das Subdivisões do Córtex. Fonte: (TORTORA; DERRICKSON, 2016).	19
Figura 4 – Áreas Funcionais do Cérebro. Adaptado livremente de (TORTORA; DERRICKSON, 2016).	20
Figura 5 – Mapa funcional das áreas sensorial e motora: (a) área somatossensorial primária e (b) área motora primária. Fonte: (TORTORA; DERRICKSON, 2016).	20
Figura 6 – Sinal típico de EEG (a) no domínio do tempo e (b) correspondente forma de onda no domínio da frequência. Fonte: (TONG; THAKOR, 2009).	21
Figura 7 – Bandas características de sinais de EEG. Fonte: (TORTORA; DERRICKSON, 2016).	22
Figura 8 – Etapas típicas para o processamento do sinal de EEG para caracterização do ERD e do ERS. Fonte: (PFURTSCHELLER; SILVA, 1999).	24
Figura 9 – Sistema de posicionamento dos eletrodos no Sistema Internacional 10-20. Fonte: (SANEI; CHAMBERS, 2007).	25
Figura 10 – Exemplo de sistema BCI utilizando SSEP. Fonte: (HONG <i>et al.</i> , 2009).	27
Figura 11 – Exemplo de aplicação de Filtro CSP. Adaptado de (BLANKERTZ <i>et al.</i> , 2007).	34
Figura 12 – Diagrama de Blocos do Algoritmo LDA. Fonte: (DUDA; HART; STORK, 2012).	35
Figura 13 – Topologia de uma rede <i>Feedforward</i> com uma única camada oculta. Fonte: (AKUSOK <i>et al.</i> , 2015).	37
Figura 14 – Diagrama de Blocos do Sistema Proposto.	39
Figura 15 – Temporização de uma trilha apresentada na tela do computador.	41

Figura 16 – Posicionamento dos eletrodos da touca <i>Emotiv</i> considerando o padrão internacional. Extraído de (EMOTIV, 2019).	44
Figura 17 – Fluxograma do Desenvolvimento da Plataforma de aquisição.	45
Figura 18 – Interface para auxílio do Usuário e sincronização dos tempos de realização do movimento.	46
Figura 19 – Fluxo de Pré-Processamento.	47
Figura 20 – Fluxograma do Função <i>cspfilter()</i> desenvolvida no <i>Matlab</i> , versão 2012b.	49
Figura 21 – Fluxograma para Visualizações dos Sinais.	52
Figura 22 – Fluxograma para Classificação dos Sinais.	55
Figura 23 – Temporização de cada Trilha no BCI Competition II, base III. Adaptado de (BCI Competition II, 2003).	60
Figura 24 – Disposição de Eletrodos do Experimento. Extraído de (BCI Competition II, 2003).	61
Figura 25 – Energia média Relativa dos canais CSP1 e CSP2 para a Base BCI Competition.	63
Figura 26 – Índice de laterização no domínio tempo os Canais CSP1 e CSP2.	64
Figura 27 – Índice de laterização para os Canais CSP1 e CSP2 na Frequência.	65
Figura 28 – Intervalos para características o Experimento <i>BCI Competition</i>	67
Figura 29 – Energia média Relativa dos canais FC5 e FC6 para o Sujeito 1.	68
Figura 30 – Energia média Relativa dos canais FC5 e FC6 para o Paciente 3.	69
Figura 31 – Energia média Relativa dos canais CSP1 e CSP2 para o Sujeito 1.	70
Figura 32 – Energia média Relativa dos canais CSP1 e CSP2 para o Paciente 3.	71
Figura 33 – Índice de Laterização no tempo entre os canais CSP1 e CSP2 para o Sujeito 1.	73
Figura 34 – Índice de Laterização no tempo entre os canais CSP1 e CSP2 para o Paciente 3.	73
Figura 35 – Índice de Laterização na frequência entre os canais CSP1 e CSP2 para o Sujeito 1.	74
Figura 36 – Índice de Laterização na frequência entre os canais CSP1 e CSP2 para o Paciente 3.	75
Figura 37 – Intervalos para características do Sujeito 1.	76
Figura 38 – Intervalos para características do Paciente 3.	77
Figura 39 – Intervalos para Número de Neurônios na camada oculta para o Sujeito 1.	81

Figura 40 – Intervalos para Características do Paciente 3.	82
Figura 41 – Intervalos para Conjuntos de features para o Sujeito 2.	84
Figura 42 – Intervalos para Variação de Janelas de Frequência para o Paciente 1. . .	85
Figura 43 – Intervalos para Variação de Janelas de Tempo para o Paciente 1. . . .	86
Figura 44 – Código desenvolvido de aquisição do Sinal da Touca <i>Emotiv</i>	96
Figura 45 – Código criado para geração de Estímulos Aleatorizados Divididos nas Classes.	97
Figura 46 – Código de Sincronização dos tempos de apresentação do estímulo visual para realização do movimento ao fisioterapeuta.	97
Figura 47 – Código criado para Salvar dados das aquisições.	98
Figura 48 – Energia média Relativa dos canais FC5 e FC6 para o Sujeito 2.	99
Figura 49 – Energia média Relativa dos canais FC5 e FC6 para o Paciente 1.	100
Figura 50 – Energia média Relativa dos canais FC5 e FC6 para o Paciente 2.	100
Figura 51 – Energia média Relativa dos canais CSP1 e CSP2 para o Sujeito 2. . . .	101
Figura 52 – Energia média Relativa dos canais CSP1 e CSP2 para o Paciente 1. . .	101
Figura 53 – Energia média Relativa dos canais CSP1 e CSP2 para o Paciente 2. . .	102
Figura 54 – Índice de Laterização no tempo entre os canais CSP1 e CSP2 para o Sujeito 2.	102
Figura 55 – Índice de Laterização no tempo entre os canais CSP1 e CSP2 para o Paciente 1.	103
Figura 56 – Índice de Laterização no tempo entre os canais CSP1 e CSP2 para o Paciente 2.	103
Figura 57 – Índice de Laterização na frequência entre os canais CSP1 e CSP2 para o Sujeito 2.	104
Figura 58 – Índice de Laterização na frequência entre os canais CSP1 e CSP2 para o Paciente 1.	104
Figura 59 – Índice de Laterização na frequência entre os canais CSP1 e CSP2 para o Paciente 2.	105
Figura 60 – Intervalos para características do Sujeito 2.	105
Figura 61 – Intervalos para características do Paciente 1.	106
Figura 62 – Intervalos para características do Paciente 2.	106

LISTA DE TABELAS

Tabela 1 – Graduação segundo a escala <i>Richmond</i> RASS (JUNIOR <i>et al.</i> , 2008).	42
Tabela 2 – Representação das <i>features</i>	58
Tabela 3 – Valores para características por canal e movimento no Experimento <i>BCI Competition</i>	67
Tabela 4 – Valores para características por canal e movimento no Experimento com o Grupo de Controle.	78
Tabela 5 – Valores para características por canal e movimento no Experimento com o Grupo de Pacientes Sedados.	79
Tabela 6 – Resultados LDA para cada voluntário.	79
Tabela 7 – Resultados ELM e respectivos número de neurônios e valor de Parâmetro Regularizador para cada indivíduo.	82
Tabela 8 – Resultados ELM e respectivos número de neurônios, valor de Parâmetro Regularizador e melhor conjunto de <i>features</i> para cada indivíduo.	84
Tabela 9 – Resultados LDA e Melhores Frequências e Tempo Inicial.	86
Tabela 10 – Resultados ELM e respectivos número de neurônios, valor de Parâmetro Regularizador, Melhores Frequências e Tempo.	87
Tabela 11 – Comparação ELM e LDA - Melhores Resultados.	88

LISTA DE ABREVIATURAS E SIGLAS

AAGA	<i>Accidental awareness during general anesthesia</i>
BCI	<i>Brain Computer Interface</i>
CSP	<i>Common Spatial Pattern</i>
DE	<i>Differential Entropy</i>
DTFT	<i>Discrete-Time Fourier Transform</i>
EEG	Eletroencefalografia
ELM	<i>Extreme Learning Machines</i>
EMG	Eletromiografia
EOG	Eletro-Oculograma
ERD	<i>Event-related desynchronization</i>
ERS	<i>Event-related synchronization</i>
ERP	<i>Event-Related Potential</i>
FES	Estimulação Elétrica Funcional
FFT	<i>Fast Fourier Transform</i>
IL	Índice de Laterização
LDA	<i>Linear Discriminant Analysis</i>
LSB	<i>Least Significant Bit</i>
PCA	<i>Principal Component Analysis</i>
PSD	<i>Power Spectral Density</i>
RASS	<i>Richmond Agitation Sedation Scale</i>

RMS	<i>Root Mean Square</i>
RMSE	<i>Root Mean Square Error</i>
SNC	Sistema Nervoso Central
SSEP	<i>Somatosensory evoked potential</i>
STD	<i>Standard Deviation</i>
TA	Tecnologia Assistiva
UTI	Unidade de Terapia Intensiva

1 INTRODUÇÃO

A utilização de eletroencefalografia tanto em aplicações médicas como para sistemas *Brain Computer Interface* (BCI), avança conforme os métodos de processamento desses sinais, as pesquisas em instrumentação biomédica e o conhecimento sobre o funcionamento do cérebro evoluem (DORNHEGE, 2007) (LOTTE *et al.*, 2018) (CRAIK; HE; CONTRERAS-VIDAL, 2019) (HOSSEINI; HOSSEINI; AHI, 2020). Os sistemas BCI incorporam a evolução de dispositivos de Tecnologia Assistiva (TA), sistemas que buscam melhorar a qualidade de vida e possibilitar maior autonomia e independência para idosos, pessoas com deficiência, incapacidade ou mobilidade reduzida, como por exemplo acionamento de próteses e cadeiras de rodas (CARRA, 2012)(SILVA, 2015). Na área de eletroencefalografia hospitalar os sinais podem ser caracterizados para detecção de distúrbios e doenças, como pré-disposição ao alcoolismo ou epilepsia, como também para detecção de estado mental, nível de consciência e profundidade de anestesia. Portanto, a utilização de eletroencefalografia permite a solução de problemas de diversas áreas dentro de Engenharia de Reabilitação através da sua análise e de seu processamento.

Sabe-se que a realização ativa, imaginação e realização passiva de movimentos geram fenômenos conhecidos como *Event-related desynchronization* (ERD) e *Event-related synchronization* (ERS) no sinal de EEG. Fenômenos os quais, por exemplo, possibilitam a distinção de movimentos de braço esquerdo e direito devido às suas características - ERD ocorre mais intensamente no lado contralateral ao do evento enquanto o ERS ocorre no período pós-evento e é visível nos lados contralateral e ipsilateral, possibilitando distinção da laterização do lado do movimento ao acontecimento do evento no sinal de EEG. Assim, a análise destes fenômenos pode ser utilizada para verificação de movimentação passiva através da aquisição de sinais de eletroencefalografia em diferentes condições. (PFURTSCHELLER; SILVA, 1999)(DORNHEGE, 2007). No escopo deste trabalho, a análise do ERD e ERS é, especificamente, a partir da condição de mobilização passiva (movimentação realizada por outra pessoa ou equipamento no sujeito) nos braços esquerdo e direito para pacientes sedados em Unidades de Terapia Intensiva (UTI) e ainda para voluntários não sedados, chamados também de grupo de controle.

Esta pesquisa é justificada a partir das aplicações - como a análise e comparação de sinais para definição de padrões de estados de atividade motora e excitação cerebral - que a confirmação da possibilidade e a elaboração dos métodos necessários de classificação de sinais provenientes de eletroencefalografia com movimentos passivos em pacientes sedados e não sedados permite. Este estudo da atividade motora pode ser utilizada em diversas aplicações hospitalares para análise da resposta da região motora do cérebro, a partir dos estímulos passivos em indivíduos em estado de sedação.

O objetivo principal desse trabalho é avaliar - com a aquisição de dados de pacientes saudáveis e de pacientes em estado de sedação - os sinais eletroencefalográficos a partir de movimentação passiva. Visa-se a análise e entendimento dos sinais de forma visual, identificando os fenômenos de ERD e ERS e avaliar após o pré-processamento e extração de características a taxa de acerto na classificação entre movimentos no braço direito e esquerdo. Como objetivos secundários pode-se citar:

- Avaliar e identificar o comportamento de sinais de ERD e ERS para o método de aquisição proposto;
- Comparar sinais de EEG de movimentos passivos de pessoas sedadas ao de pessoas conscientes;
- Comparar diferentes características extraídas dos sinais e seus desempenhos;
- Analisar a utilização dos métodos de classificação *Linear Discriminant Analysis* (LDA) e *Extreme Learning Machines* (ELM) e suas respectivas taxas de acerto;
- Aplicar o método proposto para a base *BCI Competition II*;
- Realizar um estudo de frequências e janelas de tempo para classificação.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo são revisados e discutidos temas e trabalhos pertinentes e necessários para o entendimento da correspondente pesquisa. Primeiramente, é realizada uma introdução à anatomia do cérebro humano e mais especificamente do córtex motor, uma breve discussão sobre o sinal de eletroencefalografia, seu comportamento em relação a potenciais relacionados a eventos e sua aquisição e, por último, uma discussão sobre sistemas BCI e sobre as pesquisas existentes relacionadas ao trabalho.

2.1 Introdução à Anatomia do Cérebro Humano e o Córtex Motor

O Sistema Nervoso Central (SNC) é composto pelo encéfalo e pela medula espinhal. O encéfalo é o centro controlador para o registro de sensações, tomada de decisões, execução de tarefas e centro de inteligência, das emoções, do comportamento e da memória e é formado por quatro partes principais: tronco encefálico, cerebelo, diencefalo e telencéfalo (TORTORA; DERRICKSON, 2016). A Figura 1 apresenta essas quatro principais partes do encéfalo.




Figura 1 – Representação da divisão do Encéfalo. Fonte: (TORTORA; DERRICKSON, 2016).

O telencéfalo pode ser definido como a "sede da inteligência", e é responsável

pela capacidade de ler, escrever, falar, imaginar. Ele é composto por um córtex cerebral externo, uma região interna de substância branca e núcleos de substância cinzenta. O córtex cerebral, que forma a face externa do cérebro, pode ser dividido em duas metades denominadas hemisférios cerebrais. Essas metades ainda podem ser divididas em vários lobos que estão representados na Figura 2 a partir da vista superior e na Figura 3 a partir da vista lateral direita (TORTORA; DERRICKSON, 2016).




Figura 2 – Vista Superior das Subdivisões do Córtex. Fonte: (TORTORA; DERRICKSON, 2016).

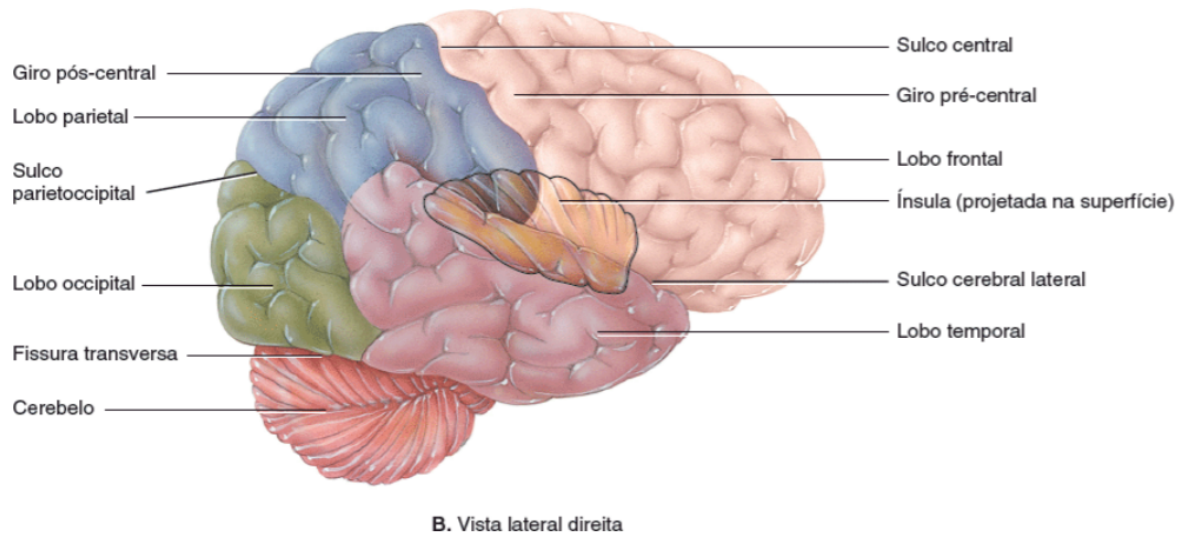


Figura 3 – Vista Lateral Direita das Subdivisões do Córtex. Fonte: (TORTORA; DERRICKSON, 2016).

O córtex cerebral ainda pode ser organizado a partir da funcionalidade, já que tipos diferentes de sinais sensitivos, motores e integradores são processados em regiões distintas do córtex cerebral. As áreas sensitivas basicamente recebem informações sensitivas e estão ligadas à percepção. As áreas motoras controlam a execução de movimentos voluntários e as áreas associativas lidam com funções integradores complexas, como emoções e raciocínio (TORTORA; DERRICKSON, 2016). A localização das áreas funcionais do telencéfalo estão disponíveis na Figura 4.

As eferências motoras do córtex motor são localizadas principalmente na parte anterior de cada hemisfério e as áreas motoras mais importantes são a área motora primária (em destaque com um retângulo vermelho na Figura 4) e a área de Broca (BEAR; CONNORS; PARADISO, 2007). A área motora primária está localizada no giro pré-central do lobo frontal e tanto nela como na área somatossensitiva primária pode-se localizar um mapa de todo corpo, disponível na Figura 5. Estímulos elétricos em qualquer ponto em um lado da área motora primária causam contração de fibras musculares esqueléticas no lado oposto do corpo, os diferentes músculos apresentam diferentes representações e localizações (TORTORA; DERRICKSON, 2016).




Figura 4 – Áreas Funcionais do Cérebro. Adaptado livremente de (TORTORA; DERRICKSON, 2016).




Figura 5 – Mapa funcional das áreas sensorial e motora: (a) área somatossensorial primária e (b) área motora primária. Fonte: (TORTORA; DERRICKSON, 2016).

Já a área de Broca está localizada no lobo frontal, próxima ao sulco cerebral lateral, e é responsável pela fala e compreensão da linguagem. No geral, para cerca de 97% da população, esta área situa-se no hemisfério esquerdo. Os impulsos nervosos originados na área de Broca passam para as regiões pré-motoras que controlam os músculos da laringe, da faringe e da boca (TORTORA; DERRICKSON, 2016).

2.2 Eletroencefalografia: princípios básicos

Eletroencefalografia é a medição da atividade elétrica dos neurônios a partir de eletrodos fixados no couro cabeludo humano (escalpo) (PUTZ; PABST, 2006). Este tipo de medição é utilizada para o estudo das funções encefálicas normais e para o diagnóstico de uma série de distúrbios encefálicos, como epilepsia, tumores, traumatismo e doenças degenerativas. O eletroencefalograma (registro dos sinais cerebrais) também pode ser utilizado para afastar ou confirmar a morte encefálica (SANEI; CHAMBERS, 2007)(TORTORA; DERRICKSON, 2016). As primeiras aquisições desse sinal foram atribuídas a Hans Berger e publicados em 1929 (SANEI; CHAMBERS, 2007). Um sinal típico de EEG está disponível na Figura 6.

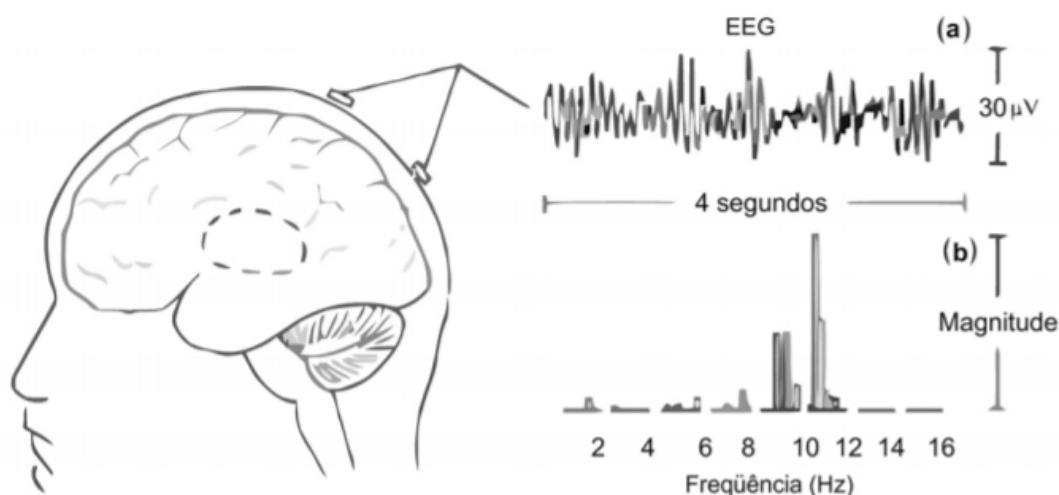


Figura 6 – Sinal típico de EEG (a) no domínio do tempo e (b) correspondente forma de onda no domínio da frequência. Fonte: (TONG; THAKOR, 2009).

O sinal de EEG possui uma faixa típica de amplitude de 1 a $50\mu\text{V}$ e frequência de até 100 Hz dependendo do tipo de estudo clínico que será realizado. Normalmente,

na área clínica, o sinal de EEG é caracterizado em faixas de frequências definidas por: bandas alfa, beta, teta e delta e podem ser visualizadas na Figura 7. Portanto, as principais bandas avaliadas em estudos clássicos de sinais de eletroencefalografia são (TOWE, 2009) (TORTORA; DERRICKSON, 2016):

- ondas alfa: ocorrem em uma frequência de cerca de 8 a 13 Hz. As ondas alfa estão presentes nos sinais de EEG de quase todos os indivíduos normais que estejam acordados e com os olhos fechados;
- ondas beta: a frequência destas ondas situa-se entre 14 e 30 Hz. As ondas beta em geral aparecem quando o sistema nervoso está ativo, ou seja, durante os períodos de estimulação sensitiva e de atividade mental;
- ondas teta: apresentam frequência de 4 a 7 Hz. As ondas teta normalmente surgem em crianças e em adultos com estresse emocional. Elas também estão presentes em várias doenças encefálicas;
- ondas delta: a frequência é de 1 a 5 Hz. As ondas delta ocorrem durante o sono profundo em adultos, mas elas são normais em lactentes acordados. Quando presentes em um adulto acordado, indicam lesão encefálica (TORTORA; DERRICKSON, 2016).




Figura 7 – Bandas características de sinais de EEG. Fonte: (TORTORA; DERRICKSON, 2016).

2.2.1 Potenciais Relacionados a Eventos

Durante o movimento humano ou alguma etapa de seu planejamento (intenção ou imaginação de um dado movimento) podem ser observados padrões de sincronização e dessincronização característicos. Nos sinais de EEG, relacionados a eventos, estes são chamados de *Event Related Desynchronization* (ERD) e de *Event Related Synchronization* (ERS) (DORNHEGE, 2007) (PFURTSCHELLER; SILVA, 1999).

O fenômeno de ERD ocorre mais intensamente no lado contralateral ao do evento e é definido como a diminuição da energia do sinal. Este padrão ocorre principalmente na banda de frequência alfa, mas é possível observá-lo também na banda beta (PFURTSCHELLER; SILVA, 1999) (NAM *et al.*, 2011). De forma contrária, o fenômeno de ERS é definido pelo aumento da energia. O ERS ocorre no período pós-evento e é visível nos lados contralateral e ipsilateral e é visível principalmente na banda de frequência beta (PFURTSCHELLER; SILVA, 1999).

A detecção destes padrões de ERD/ERS pode variar de acordo com o usuário devido ao ser humano apresentar uma variabilidade grande no seu sinal de EEG devido à forte característica estocástica do mesmo. Podendo assim o fenômeno ocorrer de forma mais proeminente em apenas um dos hemisférios, ou até ocorrer em bandas de frequência diferentes ou mesmo em regiões diferentes do córtex motor (MACHADO, 2012) (GRAIMANN; ALLISON; PFURTSCHELLER, 2009).

É possível observar uma representação dos fenômenos citados anteriormente através das etapas típicas para o processamento do sinal de EEG na caracterização do ERD e do ERS na Figura 8. Onde em (a) é possível observar o sinal de EEG bruto adquirido, em (b) o sinal filtrado nas bandas alfa e beta, em (c) o sinal elevado ao quadrado, em (d) a média de N seções de aquisição do mesmo movimento e em (e) a energia relativa considerando um período de referência, onde é realmente possível observar de forma clara o ERD (com a diminuição da energia relativa) e o ERS (com o aumento da energia relativa após estímulo).

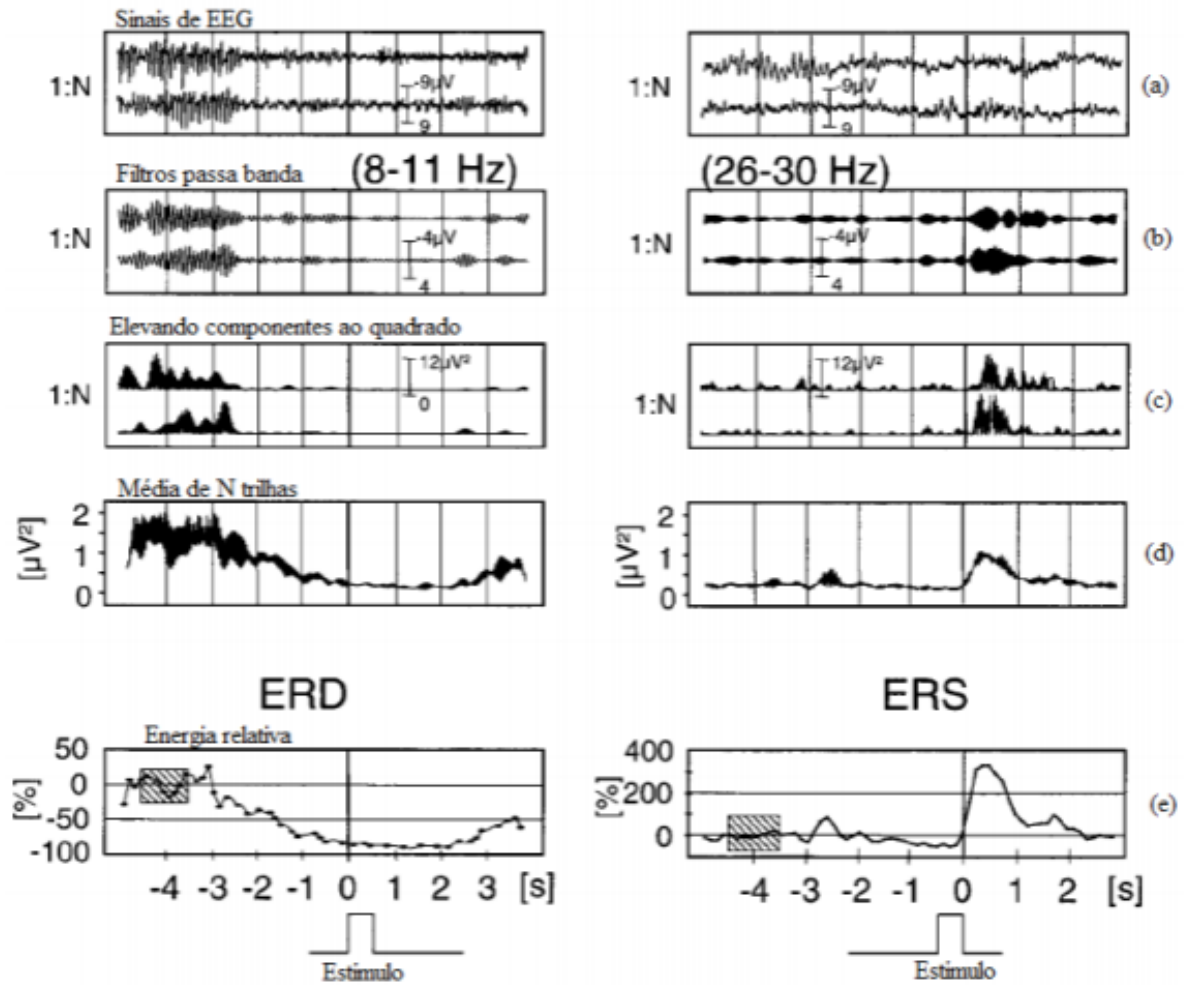


Figura 8 – Etapas típicas para o processamento do sinal de EEG para caracterização do ERD e do ERS. Fonte: (PFURTSCHELLER; SILVA, 1999).

2.2.2 Captura do Sinal de EEG e Sistema Internacional 10-20

O condicionamento do sinal de eletroencefalografia é realizado com o uso de um equipamento denominado popularmente de EEG. A disponibilidade deste sinal à entrada do EEG pode ser realizada por eletrodos invasivos e não-invasivos. Os eletrodos não-invasivos são amplamente utilizados pela praticidade e por permitirem uma captura com menor risco ao paciente. Os eletrodos invasivos são utilizados principalmente quando é necessária uma captura em uma região interna do cérebro onde a captura com eletrodos não-invasivos não basta. De forma geral, o típico equipamento de EEG utiliza eletrodos não-invasivos normalmente dispostos em toucas ou fixados no escalpo (SANEI; CHAMBERS, 2007).

A disposição dos eletrodos respeita padrões de posicionamento, assim, o Sistema

Internacional 10-20 é o padrão recomendado pela Federação Internacional das Sociedades de Eletroencefalografia e Neurofisiologia Clínica. Esse padrão é composto por 21 eletrodos considerando medidas anatômicas especificadas a partir do local onde a medida deve ser feita, posicionando os eletrodos entre 10 ou 20% entre si - do comprimento das distâncias entre os pontos de referência, Ná시오 e Ínion e os pontos pré-auriculares ao crânio - como é possível observar na Figura 9 (CARRA, 2012) (SANEI; CHAMBERS, 2007).




Figura 9 – Sistema de posicionamento dos eletrodos no Sistema Internacional 10-20. Fonte: (SANEI; CHAMBERS, 2007).

2.3 Típico Sistema BCI

Apesar de sistemas BCI não serem o foco da pesquisa é interessante observar como os sinais de potenciais relacionados a eventos utilizados neste trabalho são amplamente utilizados nesses sistemas. Um sistema BCI define a partir de estímulos que incitam certos padrões no cérebro e da intenção do usuário uma determinada ação para classificação do sinal de EEG captado de forma invasiva ou não-invasiva em determinadas regiões do cérebro. Toda forma natural de comunicação e controle necessita de nervos periféricos e de

músculos onde a partir da intenção do usuário processos complexos são gerados no cérebro, ativando e produzindo padrões em determinadas áreas, esses sinais são enviados pelo sistema nervoso periférico para assim gerar uma saída motora (GRAIMANN; ALLISON; PFURTSCHELLER, 2009).

Com o objetivo de facilitar a definição de estímulos a ser utilizada, muitos sistemas BCI utilizam a classificação de movimentos motores a partir de estímulo visual, tanto para movimentos reais como para imaginários (MACHADO, 2012) (CARRA, 2012) (SILVA, 2015) (ORTEGA *et al.*, 2016) (RAMOS *et al.*, 2017) (MEZIANI *et al.*, 2019) (ALZAHAB; ALIMAM; ALNAHHAS, 2019) (NAKAYASHIKI *et al.*, 2014). Algumas aplicações desse tipo de sistema BCI baseado em intenções de movimentos são o controle de cadeiras de rodas e próteses (GRAIMANN; ALLISON; PFURTSCHELLER, 2009).

Existem sistemas BCI que utilizam também o SSEP. Os Potenciais Evocados Sustentados (SSEP) são potenciais originados a partir de estímulos (visuais, auditivos ou táteis) que são gerados em frequências determinadas, produzindo um aumento na energia em frequências próximas da oscilação do estímulo. Sistemas que utilizam o SSEP possuem vantagens como a não necessidade de treinamento prévio e são utilizadas em aplicações como soletrar utilizando uma matriz de letras onde cada letra está oscilando em frequências diferentes (WOLPAW; BOULAY, 2009) (HONG *et al.*, 2009). Como por exemplo, pode-se observar um sistema com base no SSEP apresentado no diagrama da Figura 10.

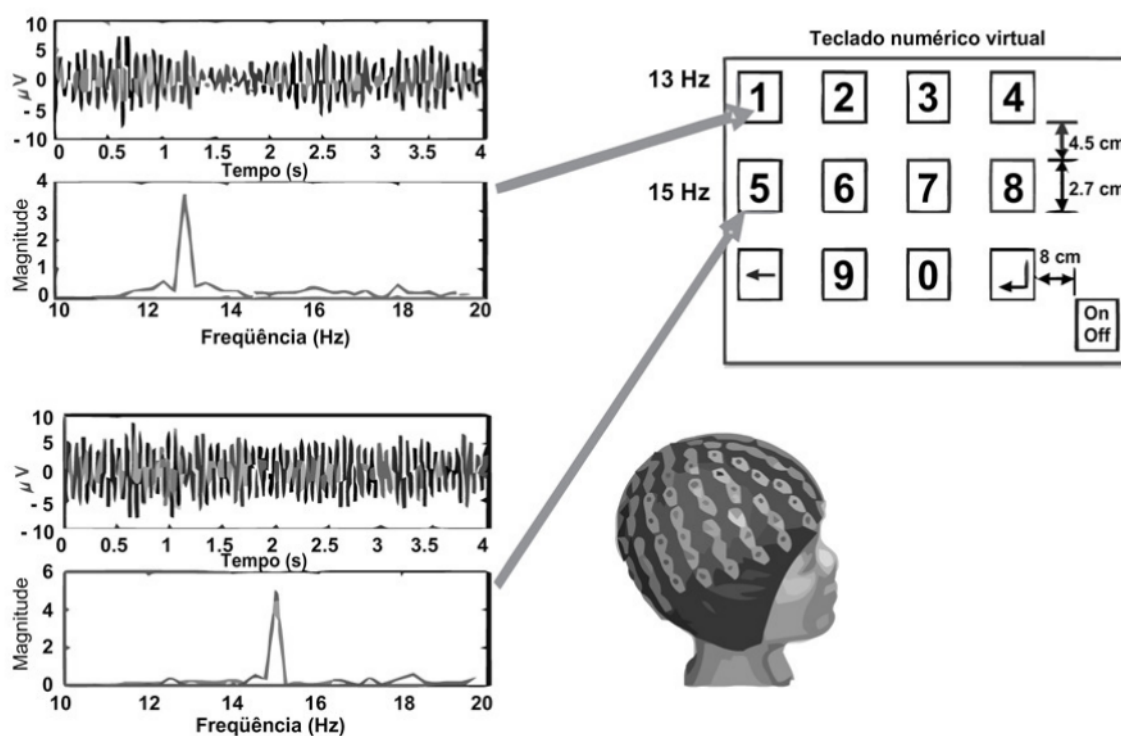


Figura 10 – Exemplo de sistema BCI utilizando SSEP. Fonte: (HONG *et al.*, 2009).

Os sistemas BCI podem ser síncronos ou assíncronos. Nos sistemas síncronos são definidos tempos de repouso e de estímulo, logo, o usuário só realiza instruções para classificação em determinados períodos. No geral são muito utilizados para sistemas BCI que utilizam intenção de movimentos. Já em sistemas assíncronos o usuário pode realizar a tarefa a qualquer momento como em sistemas que utilizam o SSEP.

2.4 Trabalhos Relacionados sobre Mobilização Passiva/Eleto-estimulada e Resposta Motora sobre alteração no Estado de Consciência

Estudos sobre a análise de sinais de EEG a partir de movimentação passiva e/ou eletro-estimulada são empregadas em diversos trabalhos, como (QIU *et al.*, 2015) (MÜLLER-PUTZ *et al.*, 2007) (GARAVAGLIA *et al.*, 2015) (PITTACCIO *et al.*, 2011) (PITTACCIO *et al.*, 2013) (MÜLLER *et al.*, 2003) (RIMBERT *et al.*, 2019) (MURPHY *et al.*, 2011).

Considerando sistemas utilizando movimentação eletro-estimulada a partir de *Functional Electrical Stimulation* (FES), no geral avalia-se através de classificadores e também por mapas espectrais as frequências onde é possível verificar maior laterização do sinal (MÜLLER *et al.*, 2003). Também são comparadas as frequências de ERD/ERS em sinais gerados a partir de movimentação passiva, ativa e/ou eletro-estimulada em (MÜLLER-PUTZ *et al.*, 2007) (QIU *et al.*, 2015). Em (GARAVAGLIA *et al.*, 2015) e (PITTACCIO *et al.*, 2013) são discutidos e analisados sinais de EEG para verificação de estimulação a partir de mobilização passiva.

Com os resultados dos trabalhos, é possível verificar que os mesmos padrões de ERD/ERS são encontrados tanto em movimentação passiva, quanto com movimentação eletro-estimulada. Porém, discute-se sobre as respostas em frequência para esses padrões, sendo encontrados em frequências diferentes em grupos de estudos em (MÜLLER-PUTZ *et al.*, 2007) e em (QIU *et al.*, 2015), mas ainda podendo ser explicada pela grande variabilidade desses padrões para cada pessoa e/ou ensaio.

Em (BLOKLAND *et al.*, 2016) é realizado um estudo com respostas motoras do sinal de EEG durante alterações no estado de consciência a partir de diferentes dosagens do medicamento Propofol. O objetivo deste trabalho foi verificar uma possível tentativa de reação motora durante um procedimento utilizando o anestésico Propofol, onde o indivíduo estaria tomando consciência do procedimento, mas estaria sem conseguir realizar a movimentação devido a bloqueadores neuromusculares. Neste trabalho foram avaliados 12 sujeitos saudáveis. Primeiramente, são realizados ensaios preliminares com cada voluntário onde é solicitado a movimentação sem nenhum tipo de aplicação de Propofol. A partir deste ensaio, são elaborados os classificadores baseados em regressão logística classificando em não-movimento e movimento e as características utilizadas são baseados em *Power Spectral Density* (PSD) utilizando o método de Welch. Posteriormente, é realizado o mesmo ensaio, com cada um dos voluntários, porém com duas dosagens de Propofol, 0,5 e 1,0 ug/ml .

Os resultados do trabalho (BLOKLAND *et al.*, 2016) mostraram que, com a maior dosagem, os voluntários obtiveram maior dificuldade de concentração e de realização das tarefas solicitadas e também maior atraso a resposta do estímulo. No geral, as taxas de acerto foram diminuindo conforme a dosagem de Propofol é aumentada, porém somente

para quatro usuários a taxa de acerto de classificação reduziu de forma abrupta. Também foi possível verificar que, para a maior dosagem de Propofol, as frequências com maior energia em relação aos ensaios sem uso da substância foram alteradas. Sem o uso do Propofol, as maiores energias concentravam-se na banda alfa. Já para os ensaios com 1,0 ug/ml foram deslocadas para a banda beta. Como conclusão, a partir dos resultados do trabalho, é possível afirmar que, para esse grupo e para essas dosagens de anestésico, a classificação de padrões motores associados à movimentação ou não-movimentação, no geral, não são reduzidas de maneira tão significativa.

Em (RIMBERT *et al.*, 2019) é apresentado um protocolo de estudo para investigação de atividades cerebrais durante uma sedação com Propofol, com o objetivo de estudar os sinais de EEG para elaboração de um sistema BCI que auxilie na identificação de Consciência Acidental durante Anestesia Geral (AAGA). A AAGA ocorre em cerca de 0,1% a 0,2% procedimentos cirúrgicos com anestesia, porém essa taxa aumenta para até 1% em pacientes de alto risco.

No protocolo de (RIMBERT *et al.*, 2019) são propostas elaboração de diferentes tarefas relacionadas ao movimento do braço, sendo elas: movimento real, movimento imaginário, movimento imaginário com uso de estimulação do nervo mediano e somente estimulação do nervo mediano. Essas tarefas são propostas para serem realizadas com diferentes níveis de concentração de Propofol: $0 \mu g.ml^{-1}$, $0,5 \mu g.ml^{-1}$ e $1 \mu g.ml^{-1}$ para identificação dos fenômenos de ERD e ERS em diferentes níveis e tarefas, sendo o Propofol um dos principais medicamentos utilizados para indução e manutenção de anestesia geral e manutenção de sedação. O estudo propõe a aquisição durante diferentes seções em um período de até um mês por indivíduo - incluindo período para treinamento da realização do experimento, com 50 *trials* por tipo de *task*, divididos em trilhas com tempos pré-determinados para realização de alguma tarefa e período de descanso. Até o momento de publicação o recrutamento de voluntários havia começado, mas ainda não haviam sido adquiridos os sinais e nem haviam resultados.

Ainda, em (MURPHY *et al.*, 2011) compara-se as atividades cerebrais utilizando EEG de alta densidade para registros de indivíduos sedados com anestesia utilizando Propofol e indivíduos no estado de sono. Foram analisados oito indivíduos saudáveis e os resultados mostraram que o estado de anestesia com Propofol se assemelha ao estado de

sono, onde existe o surgimento de ondas lentas associadas a diminuição de consciência, apesar de que no estado de anestesia ainda existiram presenças de grande atividade nas ondas gama.

3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão abordadas questões teóricas relacionadas a métodos e modelos utilizados para pré-processamento e classificação de sinais de EEG.

3.1 Filtros *Common Spatial Pattern*

O sinal de EEG, por ser um sinal de baixíssima amplitude, está sujeito a muitas formas e componentes de ruído, então é necessário tratar o sinal para escolher-se características com um grande poder discriminativo entre as classes. Logo, com o grande objetivo de reduzir o espaço de características e maximizar a discriminação entre as classes esse sinal deve ser pré-processado (DORNHEGE, 2007).

Como discutido no Capítulo 2, o movimento e a imaginação de movimento geram certos padrões que podem ser detectados em regiões específicas do escalpo. Além disso, cada eletrodo obtém sinais das regiões adjacentes à sua localização. Visto isso, é necessário selecionar canais onde ocorram maiores discriminações entre as classes de movimentos e também reduzir componentes não associadas ao tipo de tarefa. A utilização de filtros digitais para ressaltar as frequências alfa e beta. Frequências onde ocorrem os fenômenos relacionados a ERD e ERS, auxilia no processamento, mas ainda não elimina outras ondas que possam ocupar o mesmo espectro. Logo, é importante um processamento capaz de minimizar interferências comum entre os canais e maximizar as componentes realmente significativas para o fenômeno observado, como a utilização de filtros *Common Spatial Pattern* (CSP) (BLANKERTZ *et al.*, 2007).

O uso de um filtro CSP busca através da projeção dos sinais de EEG multicanais em um novo espaço a maximização da atividade discriminativa entre as duas classes, maximizando a variância do sinal em uma condição e, por consequência, minimizando em outra (BLANKERTZ *et al.*, 2007). A aplicação de filtros CSP é comumente utilizada em trabalhos para classificação de movimentos reais ou imaginários com base em sinais de EEG (MACHADO, 2012) (SILVA, 2015) (BLANKERTZ *et al.*, 2007) (BLANKERTZ *et*

al., 2011) (JAMALOO; MIKAEILI, 2015).

Considerando o vetor que contém os valores de cada t amostra e para cada número de canal \mathbf{C} como $x(t) \in \mathbb{R}^C$, o sinal projetado a partir de uma decomposição supervisionada para o novo espaço de canais $x_{csp}(t) \in \mathbb{R}^C$ é dado pela Equação (3.1). Sendo cada coluna da matriz quadrada \mathbf{W} um filtro espacial que recombina linearmente as componentes de todos os canais formando um novo canal (BLANKERTZ *et al.*, 2007). Salienta-se que as matrizes estão representadas em negrito neste trabalho.

$$\mathbf{X}_{csp}(t) = \mathbf{W}^T \mathbf{x}(t) \quad (3.1)$$

Logo, é necessário o cálculo da matriz \mathbf{W} . Para isso, primeiramente define-se o conjunto para o número total de amostras como $\mathbf{X} \in \mathbb{R}^{C \times T}$, sendo \mathbf{X} o vetor concatenado de sinais $x(t)$'s, \mathbf{C} o vetor de canais e \mathbf{T} o vetor de Tempos. Com \mathbf{X} definido, é necessário estimar a covariância para cada uma das duas condições. Sendo $\Sigma^{(c)}$ definida como a matriz de covariância a partir da Equação (3.2) para a condição c e com N trilhas para cada a condição específica.

$$\Sigma^{(c)} = \frac{1}{N} \sum_{i \in N} \mathbf{X}_i^{(c)} \mathbf{X}_i^{(c)T} \quad (3.2)$$

A partir da soma das matrizes Σ^+ e Σ^- - definindo as condições como condição positiva e negativa - pode-se decompor a matriz soma (definida como Σ) em seus autovalores e autovetores, como na Equação (3.3). Sendo \mathbf{B} a matriz composta pelos autovetores descrevendo o comportamento da matriz de covariância e $\boldsymbol{\lambda}$ a matriz diagonal dos autovalores.

$$\Sigma = \mathbf{B} \boldsymbol{\lambda} \mathbf{B}^T \quad (3.3)$$

A partir da matriz de autovetores \mathbf{B} calcula-se a matriz \mathbf{P} , que é resultado da operação de *whitening transformation*, que escala \mathbf{B} como na Equação (3.4) ocasionando que \mathbf{P} respeite a Equação (3.5). Essa operação transforma os sinais correlacionados em sinais

descorrelacionados, ou seja, ruído branco (DUDA; HART; STORK, 2012) (FUKUNAGA, 2013).

$$P = \lambda^{-1/2} B^T \quad (3.4)$$

$$P \Sigma P^T = I \quad (3.5)$$

Ainda, é necessário transformar as matrizes de covariância de cada classe a partir da Equação (3.6), onde \mathbf{S} para as duas condições compartilhara os mesmos autovalores, respeitando a Equação (3.5). Também é necessário partir da Equação (3.7) estimar a nova covariância de cada canal, definida por Λ^c para cada condição, essa matriz é diagonal e a soma dela nas duas condições deve ser igual a matriz identidade, como definido na Equação (3.8), como condição positiva e negativa.

$$S^C = P \Sigma^C P^T \quad (3.6)$$

$$W^T \Sigma^{(c)} W = \Lambda^C \quad (3.7)$$

$$\Lambda^+ + \Lambda^- = I \quad (3.8)$$

O maior valor da nova matriz de covariância Λ^c para cada classe terá o menor valor para a outra, e então, esses dois respectivos canais serão os com maiores discriminações entre as classes (BLANKERTZ *et al.*, 2007). Essas matrizes Λ^c serão os autovalores para cada classe, como na Equação (3.9).

$$S^C = U \Lambda^C U^T \quad (3.9)$$

Logo, os filtros espaciais podem ser encontrados a partir da Equação (3.10) e os canais podem ser definidos pelos maiores valores das matrizes de covariância.

$$\mathbf{W} = (\mathbf{U}^T \mathbf{P})^T \quad (3.10)$$

A partir da Figura 11, é interessante observar a aplicação de um filtro CSP em uma variável bidimensional, e como são ortogonalizadas as variâncias. Na primeira imagem é possível observar uma grande sobreposição nos pontos, e com a aplicação do filtro CSP é possível observar a ortogonalização entre as componentes principais.

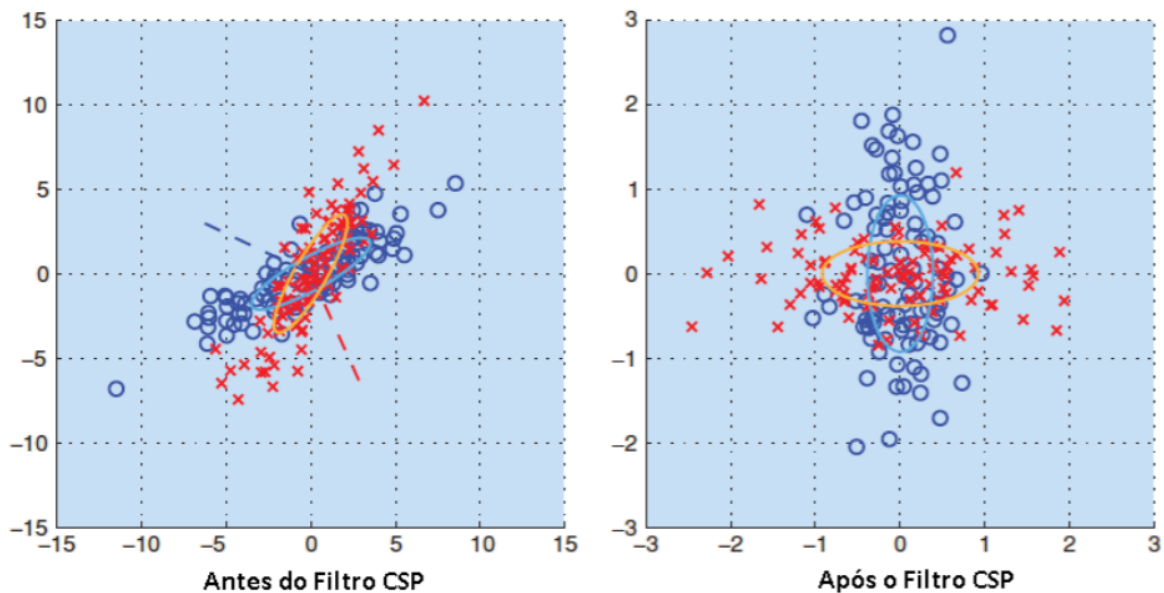


Figura 11 – Exemplo de aplicação de Filtro CSP. Adaptado de (BLANKERTZ *et al.*, 2007).

3.2 Classificadores

3.2.1 *Linear Discriminant Analysis*

O método *Linear Discriminant Analysis* (LDA), também chamado de Discriminante Linear de Fisher, é um classificador linear em que o objetivo é projetar um conjunto de vetores de dados em um hiperplano dentro do espaço de características onde a orientação desse hiperplano resulte na projeção com melhor discriminação entre as classes.

Esse classificador pressupõe uma distribuição normal dos dados, com matriz de covariância igual para as duas classes (DUDA; HART; STORK, 2012) (FUKUNAGA, 2013).

Uma função discriminante que é uma combinação de componentes de \mathbf{x} , onde \mathbf{w} é o vetor de pesos e w_0 uma constante de *threshold*, pode ser definida pela Equação (3.11). Onde esse classificador linear, utilizado para duas classes, define a partir de uma regra que: se $g(\mathbf{x})$ maior que zero pertence a Classe 1 e se $g(\mathbf{x})$ menor que zero pertence a Classe 2. A equação $g(\mathbf{x}) = 0$ define a superfície de decisão (também chamada de hiperplano de decisão) que separa os pontos pertencentes a cada classe. No caso de um classificador para mais de duas classes são definidos mais de um hiperplano.

$$g(\mathbf{x}) = \mathbf{w}^T \cdot \mathbf{x} + w_0 \quad (3.11)$$

Na Figura 12 é possível observar o fluxo de um classificador linear onde existem d entradas, cada uma correspondente a um valor de uma característica. Cada uma dessas entradas é multiplicada pelo seu respectivo peso e como saída é implementada a regra de decisão a partir da definição de classe pelos valores de $g(\mathbf{x})$.




Figura 12 – Diagrama de Blocos do Algoritmo LDA. Fonte: (DUDA; HART; STORK, 2012).

O vetor \mathbf{w} é calculado de forma que maximize a atividade discriminativa entre as classes em relação à atividade comum. A norma do vetor de pesos determina a direção do

hiperplano. Esse vetor é definido a partir da maximização do coeficiente de Rayleigh.

3.2.2 *Extreme Learning Machines*

O *Extreme Learning Machine* (ELM) é um método de classificação e regressão supervisionado, com topologia baseada em redes neurais *feedforward* com uma única camada, como na Figura 13. O ELM é um método não iterativo, garantindo a solução ótima a partir da resolução analítica do sistema (HUANG; ZHU; SIEW, 2006). É um modelo independente das entradas que utiliza um hiperparâmetro (número de neurônios da camada oculta) no modelo simplificado e muito mais rápido quando comparado a métodos como redes *Multilayer Perceptron* (MLP), por esse motivo tornou-se um método explorado nas áreas de *Machine Learning* e *Big Data* (QIU *et al.*, 2016)(CAO; LIN, 2015). Trabalhos recentes relativos a *tasks* utilizando EEG e classificação de movimentos mostram resultados comparáveis a métodos clássicos como *Support Vector Machine* (SVM), porém com uma redução no tempo de processamento (ZHANG *et al.*, 2018)(LIANG *et al.*, 2006).

O método de ELM clássico, como é um método não iterativo e possui somente como hiperparâmetro o número de neurônios da camada oculta, pode ser levado ao *underfitting* quando utilizado poucos neurônios e ao *overfitting* quando utilizado uma quantidade muito elevada de neurônios. Uma solução para evitar esses problemas de treinamento é a utilização de versões adaptadas do método, sendo uma delas o ELM Regularizado (RELM) (AKUSOK *et al.*, 2015).

O RELM evita a influência em demasia das entradas na saída do modelo partir da utilização de uma regressão regularizada para a minimização do erro. Assim, é utilizado um método de regressão definido como *Ridge-Regression*, onde existe a adição de um termo no cálculo do erro deixando assim o sistema mais genérico, entendendo diferenças nas entradas, diminuindo a possibilidade de *overfitting* (AKUSOK *et al.*, 2015).

Na arquitetura apresentada na Figura 13 identifica-se a arquitetura de uma rede ELM, onde \mathbf{X}_1 , \mathbf{X}_2 e \mathbf{X}_3 são os vetores que compõem a matriz de entrada \mathbf{X} que possuem N linhas de treinamento ou predição. Os pesos de entrada \mathbf{W} e de bias b nas redes ELM são definidos de forma aleatória, logo, os pesos β são independentes dos pesos de entrada e possuem uma solução direta não iterativa. A matriz \mathbf{H} , composta de fh_1 a fh_5 é definida

como a a matriz de neurônios da camada oculta que possui L neurônios (no exemplo $L=5$), que pode possuir diferentes tipos de funções de ativação f dos neurônios (AKUSOK *et al.*, 2015).




Figura 13 – Topologia de uma rede *Feedforward* com uma única camada oculta. Fonte: (AKUSOK *et al.*, 2015).

A partir da arquitetura e das definições do ELM, pode-se definir, considerando as N linhas de treinamento distintas (representadas por x_i) e a função de ativação ϕ , a equação de saída do ELM y_i na Equação (3.12), que é igual a $(t_i + \epsilon)$, onde ϵ representa ruído, tanto ruído aleatório quanto ruído formado pela dependência entre as variáveis (AKUSOK *et al.*, 2015). De forma simplificada, a saída \mathbf{T} é representada pela Equação (3.13), onde \mathbf{H} é representado pela Equação (3.14).

$$y_i = t_i + \epsilon = \sum_{j=1}^L \beta_j \phi(w_j x_i + b_j), i \in [1, N] \quad (3.12)$$

$$\mathbf{T} = \mathbf{H}\beta \quad (3.13)$$

$$\mathbf{H} = \phi(\mathbf{W}\mathbf{X} + \mathbf{b}) \quad (3.14)$$

A solução do ELM pode ser obtida a partir do cálculo da pseudo-inversa, onde busca-se a solução da Equação (3.13). A solução única para a pseudo-inversa pode ser determinada a partir da norma mínima L_2 de treinamento para sistemas sobredeterminados e subdeterminados (com número de neurônios menor que o número de amostras de treinamento ou maior, respectivamente). A pseudo-inversa da matriz \mathbf{H} , denotada por \mathbf{H}^\dagger na Equação (3.15), pode ser definida a partir da Equação (3.16). Como a pseudo-inversa calculada pode ser suscetível à instabilidades, na *toolbox* implementada em (AKUSOK *et al.*, 2015) é utilizado um pequeno parâmetro regularizador, como na Equação (3.17) com $\alpha = 50\epsilon$, onde ϵ é o ponto flutuante de precisão da tecnologia utilizada (*toolbox* possui implementação em *Python* e em *Matlab*) (AKUSOK *et al.*, 2015).

$$\boldsymbol{\beta} = \mathbf{H}^\dagger \mathbf{T} \quad (3.15)$$

$$\mathbf{H}^\dagger = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \quad (3.16)$$

$$\mathbf{H}^\dagger = (\mathbf{H}^T \mathbf{H} + \alpha \mathbf{I})^{-1} \mathbf{H}^T \quad (3.17)$$

Este parâmetro regularizador α pode ser modificado, e, inclusive, utilizado como parâmetro de regularização para exploração dentro das soluções de um classificador, ideal para utilização em sistemas subdeterminados por não possuírem boa generalização sem este fator de ajuste, deixando o sistema não singular a partir da adição do termo (AKUSOK *et al.*, 2015).

4 METODOLOGIA

O aparato experimental está dividido em dois blocos principais: coleta de dados e processamento e classificação dos sinais de EEG. Nas seguintes seções cada um dos blocos principais será detalhado. A Figura 14 apresenta o diagrama de blocos do sistema experimental proposto neste trabalho.

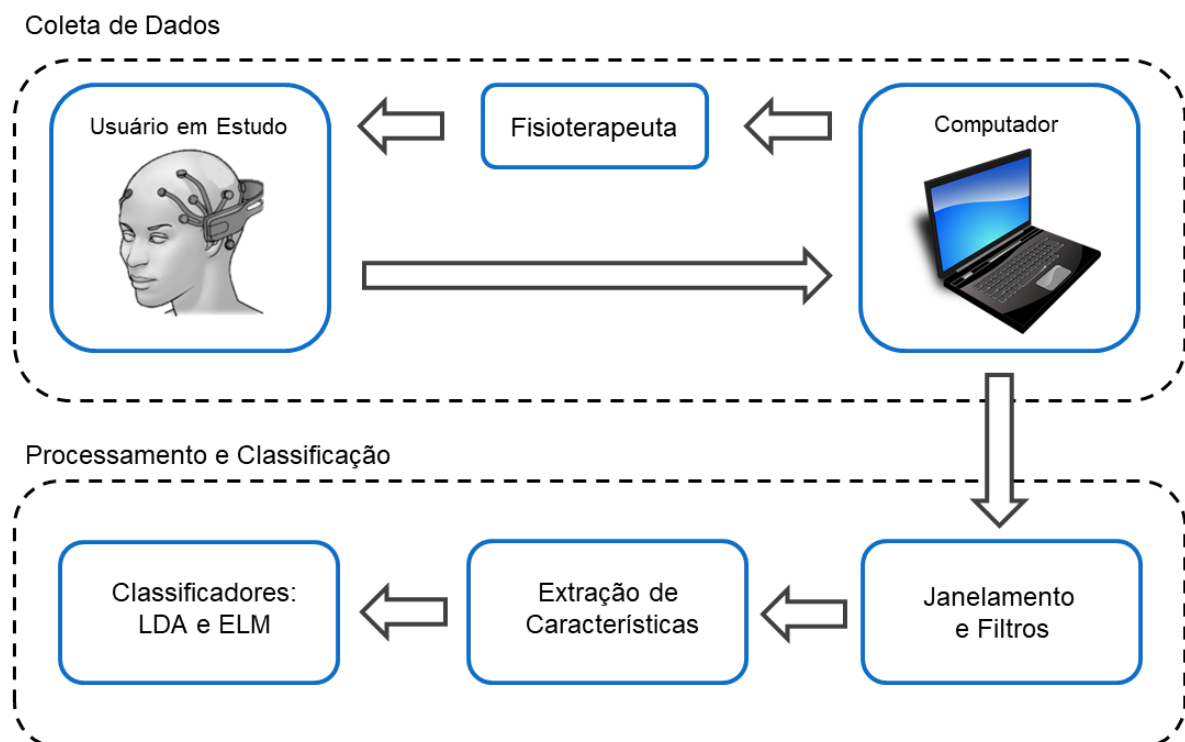


Figura 14 – Diagrama de Blocos do Sistema Proposto.

Sobre a coleta de dados representada na Figura 14 são as subdivisões:

- computador: geração das orientações ao fisioterapeuta sobre os movimentos a serem realizados e aquisição de forma síncrona entre essas orientações e os sinais de EEG adquiridos a partir de uma interface desenvolvida no *Software Labview*;
- fisioterapeuta: o fisioterapeuta é o responsável por realizar os movimentos de flexão do braço e repouso no usuário a partir da sequência indicada no computador;

- usuário em estudo: o usuário em estudo pode ser pertencente ao grupo de pacientes sedados ou ao grupo de controle com pacientes não-sedados. Este está utilizando uma touca de EEG modelo *Emotiv Epop+* (EMOTIV, 2019) que envia os sinais ao computador.

Ainda sobre a Figura 14 as subdivisões do pré-processamento, para visualização e extração de características, e classificação são:

- janelamento e filtros: o janelamento é realizado por *timestamp* com sua respectiva classe definida pela sequência apresentada ao fisioterapeuta. O sinal é filtrado nas bandas de frequência de interesse e os canais ainda passam por um filtro *CSP* para utilização dos dois canais com maior distinção entre classes no novo espaço gerado a partir do filtro CSP;
- extração de características: são extraídas características no domínio tempo e frequência, sendo elas: *Root Mean Square* (RMS), Desvio Padrão, *Power Spectral Density* (PSD) e *Differential Entropy* (DE);
- Classificadores: para classificação binária entre os movimentos de flexão no braço direito e esquerdo são utilizados dois tipos de classificadores: LDA e ELM.

4.1 Plataforma Experimental e Protocolo de Aquisição

A aquisição dos sinais é realizada de maneira a configurar um sistema síncrono, logo, os movimentos passivos são realizados por um fisioterapeuta a partir de instantes de tempo específicos, configurados como na Figura 15.

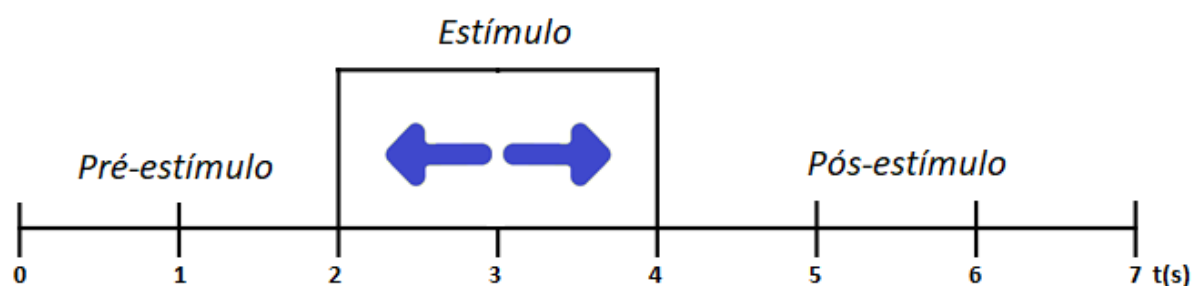


Figura 15 – Temporização de uma trilha apresentada na tela do computador.

Os primeiros dois segundos são definidos como intervalo pré-estímulo, os dois segundos seguintes são o momento de realização do movimento pelo fisioterapeuta e os últimos três segundos são definidos como período pós-estímulo. A aquisição do sinal de EEG é realizada durante todo o período de 7 segundos de trilha para todo o ensaio. Cada trilha de sinal é composta por um movimento definido aleatoriamente representando a flexão do braço esquerdo ou do braço direito. Cada seção é composta por 10 trilhas de 7 segundos e são realizadas n seções por usuário.

A aquisição do sinal é feita utilizando a touca *Emotiv Epoc* através de uma interface com o *software Labview* versão 13, da *National Instruments*, a uma taxa de 128 Hz (EMOTIV, 2019). No próprio *Labview* são gerados os tempos e as indicações de movimento. Todos os dados, dos sinais adquiridos por canal e dos estímulos realizados (sendo definido o valor '1' para estímulo do braço esquerdo do usuário e '2' para o direito), são salvos em arquivos no padrão 'UsuárioX_Data_TipoDeDado_n.lvm' para posterior processamento.

4.1.1 Pacientes Sedados em Unidades de Terapia Intensiva e Grupo de Controle

O paciente sedado internado na UTI precisou obedecer a alguns critérios de inclusão, sendo eles:

- pacientes adultos de ambos os gêneros;
- pacientes maiores de 18 anos;

- pacientes que estejam em uso de sedo-analgesia contínua com RASS -3 a -5 (indicação da representação da graduação na Tabela 1);
- pacientes que estejam em uso de ventilação mecânica invasiva entre 48 e 72 horas.

Tabela 1 – Graduação segundo a escala *Richmond* RASS (JUNIOR *et al.*, 2008).

Pontos	Termo	Descrição
+4	Combativo	Claramente combativo, violento, representando risco para a equipe.
+3	Muito agitado	Puxa ou remove tubo e cateteres, agressivo verbalmente.
+2	Agitado	Movimentos despropositados frequentes, briga com o ventilador.
+1	Inquieto	Apresenta movimento, mas que não são agressivos ou vigorosos.
0	Alerta e calmo	
-1	Sonolento	Adormecido, mas acorda ao ser chamado (estímulo verbal) e mantém os olhos abertos por mais de 10 segundos.
-2	Sedação leve	Despertar precoce ao estímulo verbal, mantém contato visual por menos de 10 segundos.
-3	Sedação moderada	Movimentação ou abertura ocular ao estímulo verbal (mas sem contato visual).
-4	Sedação intensa	Sem resposta ao ser chamado pelo nome, mas apresenta movimentação ou abertura ocular ao toque (estímulo físico).
-5	Não desperta	Sem resposta ao estímulo verbal ou físico.

O protocolo oferece baixo risco ao paciente, já que a mobilização passiva não exige nenhum esforço do indivíduo sendo uma conduta utilizada em UTI's. Todos os movimentos são realizados por um fisioterapeuta e acompanhados pela equipe interdisciplinar do setor. Atendendo aos critérios de inclusão e com autorização dos responsáveis, as coletas foram realizadas a partir do protocolo de aquisição para posterior processamento. Todos os procedimentos realizados foram aprovados pelo comitê institucional de pesquisa sob o Certificado de Apresentação para Apreciação Ética (número: 11253312.8.0000.5347).

Foram coletados sinais de três pacientes que atenderam aos critérios apresentados anteriormente, denominados no trabalho como 'Paciente 1', 'Paciente 2' e 'Paciente 3'. Para o 'Paciente 1' foram realizados 50 movimentos divididos igualmente entre as classes, limitado em 50 movimentos devido à hiperventilação e alteração no estado de sedação

durante a realização do ensaio impossibilitando a aquisição de mais tempo de ensaio, para os demais pacientes foram realizados 100 movimentos também divididos igualmente entre as classes. No grupo de controle os critérios de inclusão são voluntários adultos sem doenças neuromusculares prévias. O procedimento é realizado de forma a simular o ambiente da UTI, logo, o voluntário mantém-se de olhos fechados e deitado com apoio ao seu pescoço.

Foram adquirido sinais de dois voluntários que atenderam aos critérios de inclusão, foram mantidas todas as medidas para que o procedimento seguisse os padrões do ambiente hospitalar, com o indivíduo deitado com apoio na região do pescoço, iluminação reduzida e posicionamento do fisioterapeuta lateral ao voluntário, como na UTI. Os voluntários são denominados no trabalho como 'Sujeito 1' e 'Sujeito 2', em ambos foram realizados 100 movimentos divididos igualmente entre as duas classes.

4.1.2 Interface de Aquisição

A touca da marca *Emotiv*, modelo *Epoc+*, utilizada nas aquisições, é uma touca de EEG comercial e portátil baseada no sistema 10-20, que permite a captura dos sinais brutos de EEG, a partir da licença e integração com o *software* da marca. Ela possui 14 eletrodos para acesso ao sinal possuindo mais dois eletrodos de referência. O posicionamento, como pode ser visto na Figura 16, é baseado no padrão com 75 eletrodos. Possui resolução de 14 bits, taxa de aquisição de 128 Hz, filtros digitais de 0,2 a 45Hz e filtros *notch* em 50 e 60 Hz e *range* de 8400 μ V (EMOTIV, 2019). A conexão ao computador é feita a partir de um *dongle* USB com conexão via *bluetooth*. Todos os eletrodos são adquiridos durante o ensaio para processamento utilizando o filtro CSP, em processamentos sem o filtro CSP utiliza-se filtro para somente os eletrodos FC5 e FC6 - eletrodos mais próximos a região do córtex motor disponíveis no equipamento. Existem já diversos estudos utilizando a touca Emotiv Epoc para aquisição em diferentes tasks, como aplicações relacionadas a P300 (EKANAYAKE, 2010) (DUVINAGE *et al.*, 2013), SSVEP (LIU *et al.*, 2012) e fenômenos de ERP (SILVA, 2015) (BADCOCK *et al.*, 2015).

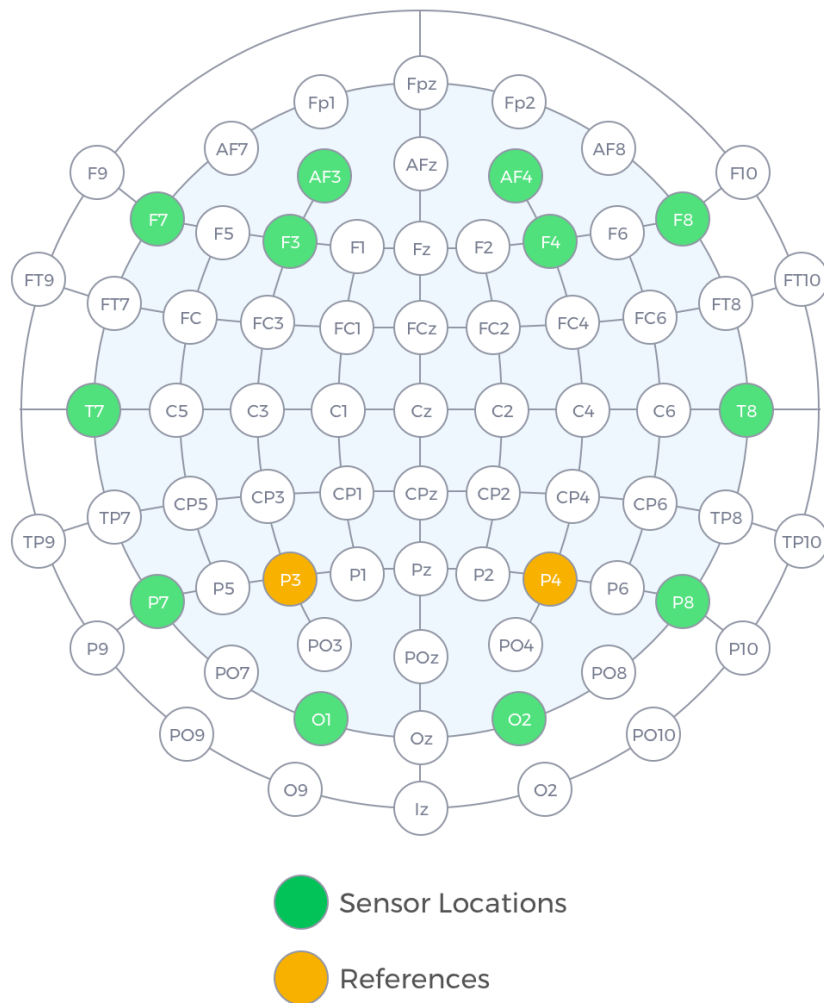


Figura 16 – Posicionamento dos eletrodos da touca *Emotiv* considerando o padrão internacional. Extraído de (EMOTIV, 2019).

A interface para geração dos estímulos visuais e aquisição para o fisioterapeuta realizar os movimentos no voluntário foi projetada a partir do *software Labview*, versão 13. Primeiramente, podemos ver a divisão dos blocos na Figura 17 com a interface gráfica disponível para identificação e definição de parâmetros em azul, a aquisição e integração da touca no fluxo em verde e a identificação, aleatorização e sincronização dos movimentos em amarelo. Os códigos desenvolvidos estão disponíveis no Apêndice A.

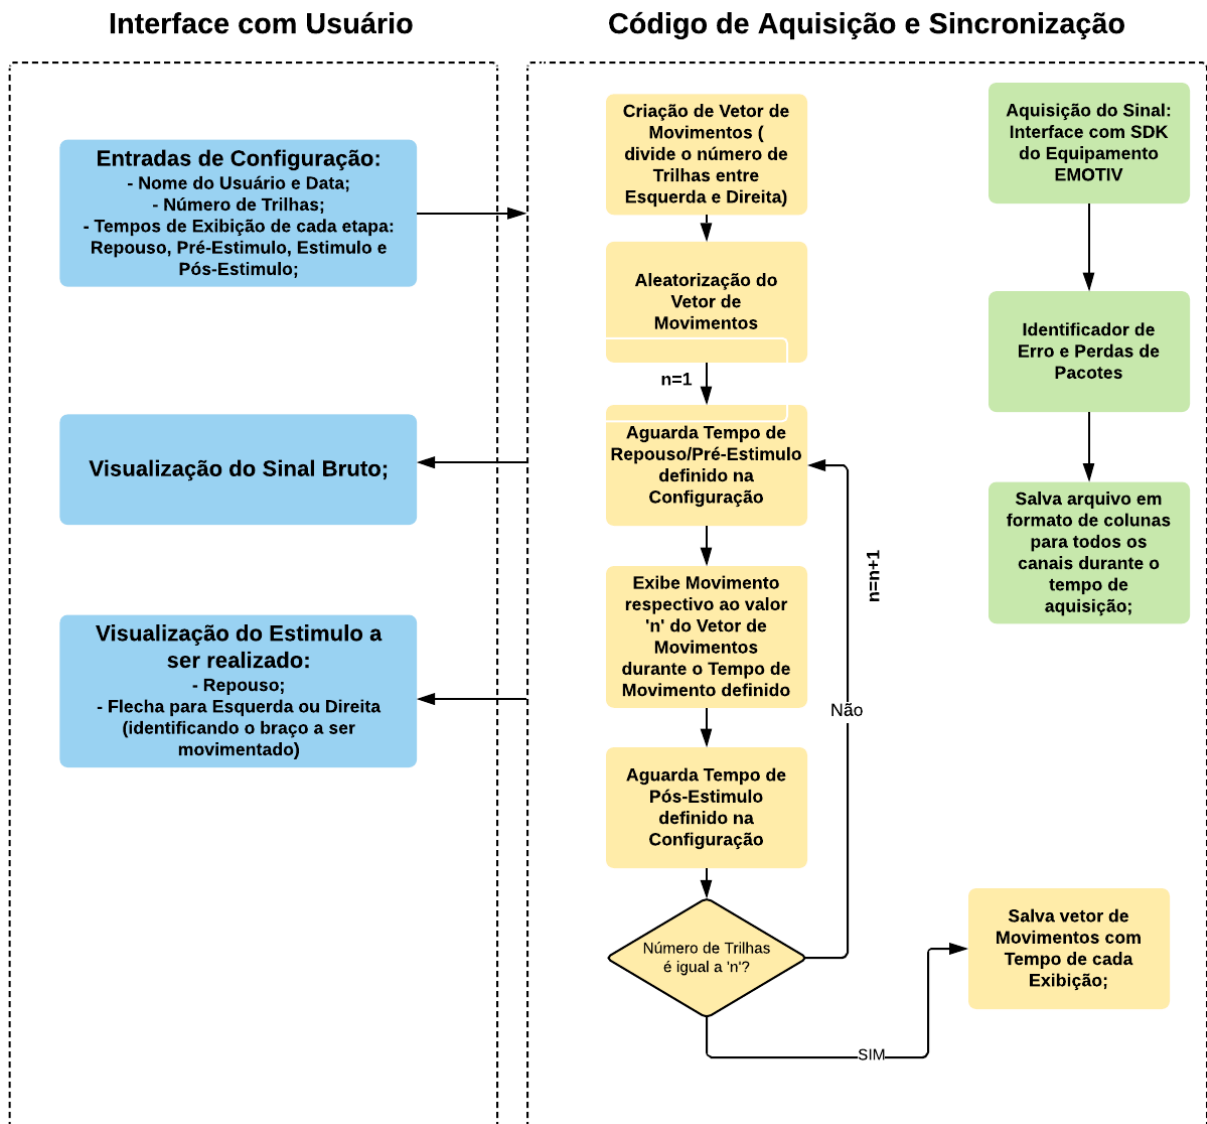


Figura 17 – Fluxograma do Desenvolvimento da Plataforma de aquisição.

A partir do bloco de aquisição é realizada a leitura do sinal a partir da comunicação entre *Labview* e *software* de visualização dos dados da touca de eletrodos. Este bloco possibilita a criação de uma visualização do sinal para possíveis monitoramentos de ruídos e da correta aquisição, e, também o sinal é modificado no formato de vetores para ser salvo.

No bloco de sincronização é criado um vetor com o tamanho definido pelo número de repetições definidas pelo usuário. Esse número de repetições é dividida igualmente entre as classes, gerando um vetor com valores iguais a '1' ou '2' balanceados. Esse

vetor então tem seus valores aleatorizados, gerando assim um vetor balanceado com movimentos representados por valores '1' e '2' com aleatorização na sua ordem. Após a criação e aleatorização da ordem do vetor existe a etapa de sincronização dos tempos, onde o vetor de movimentos é percorrido dentro de um fluxo de exibição de repouso, movimento identificado na ordem do vetor e pós-estímulo, este mesmo bloco é responsável pela finalização do programa após percorrer todos os movimentos e salvar o momento de realização de cada etapa.

O resultado final de todos os blocos de programas é a interface para o usuário que irá realizar os movimentos. Essa interface está disponível na Figura 18, onde é possível observar a demonstração visual para qual braço realizar o movimento, definições de nomes e datas para salvar arquivos e também definições dos tempos e repetições, deixando o *software* genérico o suficiente para aquisições com mudanças nos protocolos e tempos.

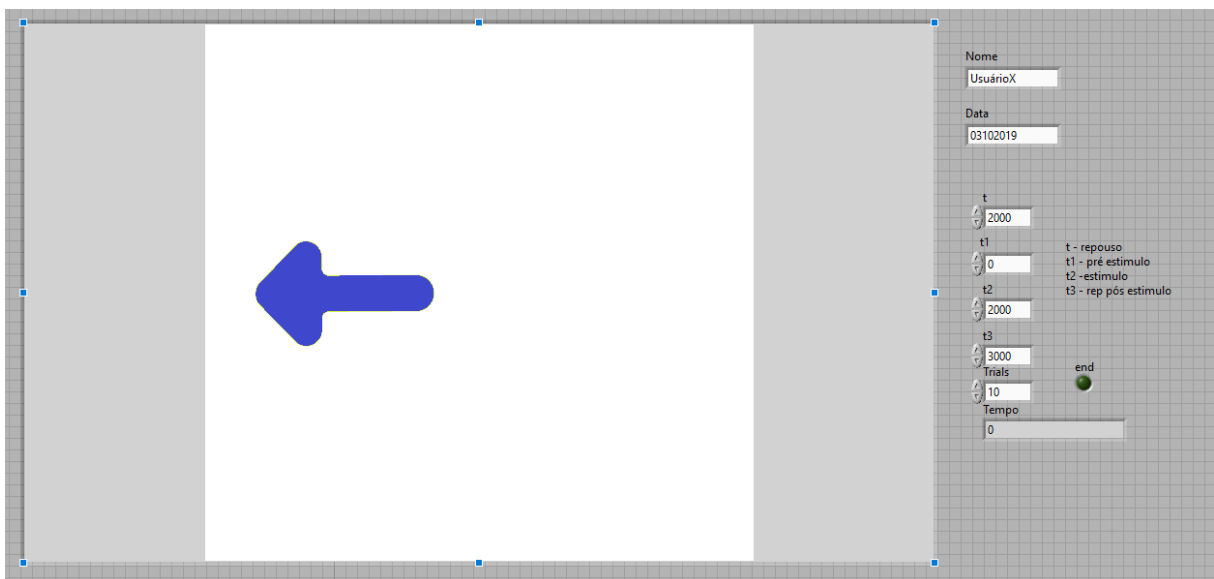


Figura 18 – Interface para auxílio do Usuário e sincronização dos tempos de realização do movimento.

4.2 Pré-Processamento e Extração de Características

O pré-processamento pode ser dividido na visualização dos fenômenos de ERD/ERS e também na extração de características. A extração de características foi dividida em cinco etapas: (1) leitura do sinal bruto; (2) aplicação dos filtros digitais; (3) separação dos sinais em n trilhas representando cada trilha de movimento; (4) aplicação dos filtros CSP;

(5) extração de características. Todas as etapas foram realizadas utilizando o *software Matlab*, versão 2012b e estão disponíveis na Figura 19.

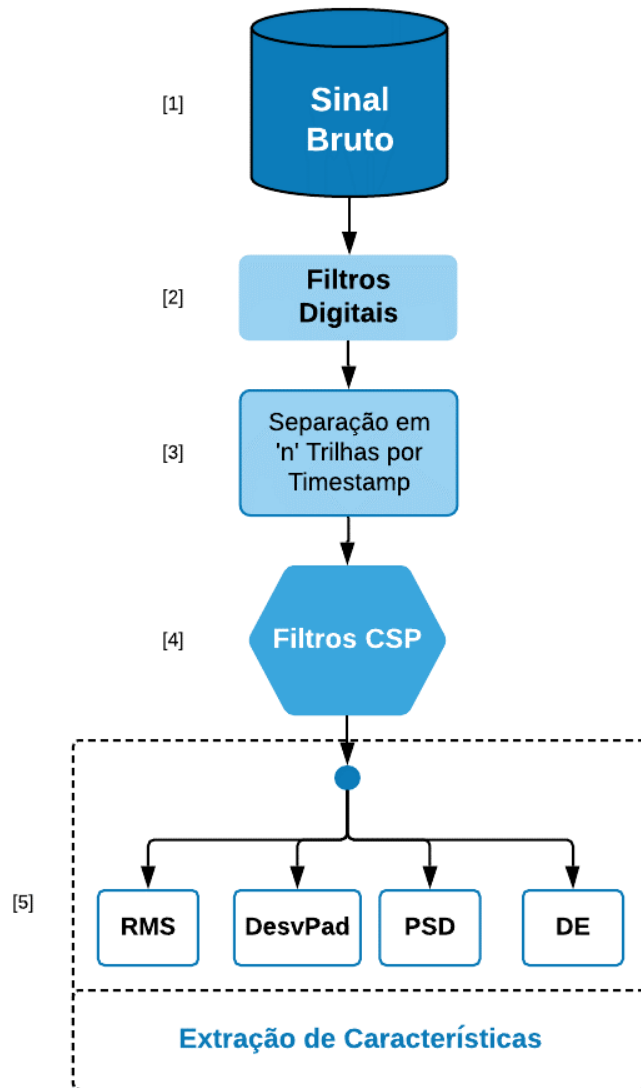


Figura 19 – Fluxo de Pré-Processamento.

Em (1) as diferentes sessões são abertas no *software Matlab* e agrupadas, formando duas matrizes, compostas pelos movimentos relativos e o sinal adquirido no tempo para todos canais.

Em (2) o sinal é filtrado nas frequências relativas aos fenômenos analisados. O filtro implementado é um filtro *butterworth* digital de quarta ordem na faixa de 7 a 14 Hz utilizando a função *filtfilt*. A função *filtfilt* não contribui com alterações de fase nos dados, o que pode causar alterações quando utilizado o algoritmo para extração de características,

e só atenua o sinal na amplitude.

Ainda em (2) é implementado um filtro para minimizar possíveis ruídos de grande amplitude, que possam ser provenientes de ruídos de EMG, EOG ou outra fonte externa e que possuam a mesma faixa de frequência do sinal. Esses pontos considerados *outliers* para análise do sinal são definidos a partir de um filtro considerando média aritmética e desvio padrão de cada seção. Primeiramente, é calculada a média aritmética do sinal e seu desvio padrão, e então todo o sinal que possui amplitude maior que três desvios padrões da média aritmética do sinal é considerado *outlier* e seu valor é substituído pelo valor imediatamente anterior, método baseado em (AMABILE *et al.*, 2008) e com validação a partir de ensaios preliminares a partir de aquisições com movimentos e análises das distribuições de sinal, comparado a referência.

Já em (3) separa-se esse sinal em 100 trilhas para todos usuários, exceto o 'Paciente 1' onde foram realizadas somente 50 trilhas, cada trilha corresponde a cada um dos movimentos realizados afim de possibilitar a implementação do filtro CSP e da extração de características de forma simples. Essa etapa é necessária já que a aquisição é feita com 10 trilhas por seção.

O passo (4) é onde aplica-se o filtro *Common Spatial Patern* para maximizar a discriminação a partir de uma transformação do espaço amostral. A aplicação do filtro é realizada pela função desenvolvida *cspfilter* tendo como base as equações discutidas na seção 3.1 e o método aplicado em (RAMOSER; MULLER-GERKING; PFURTSCHELLER, 2000). O fluxograma de desenvolvimento está disponível na Figura 20.

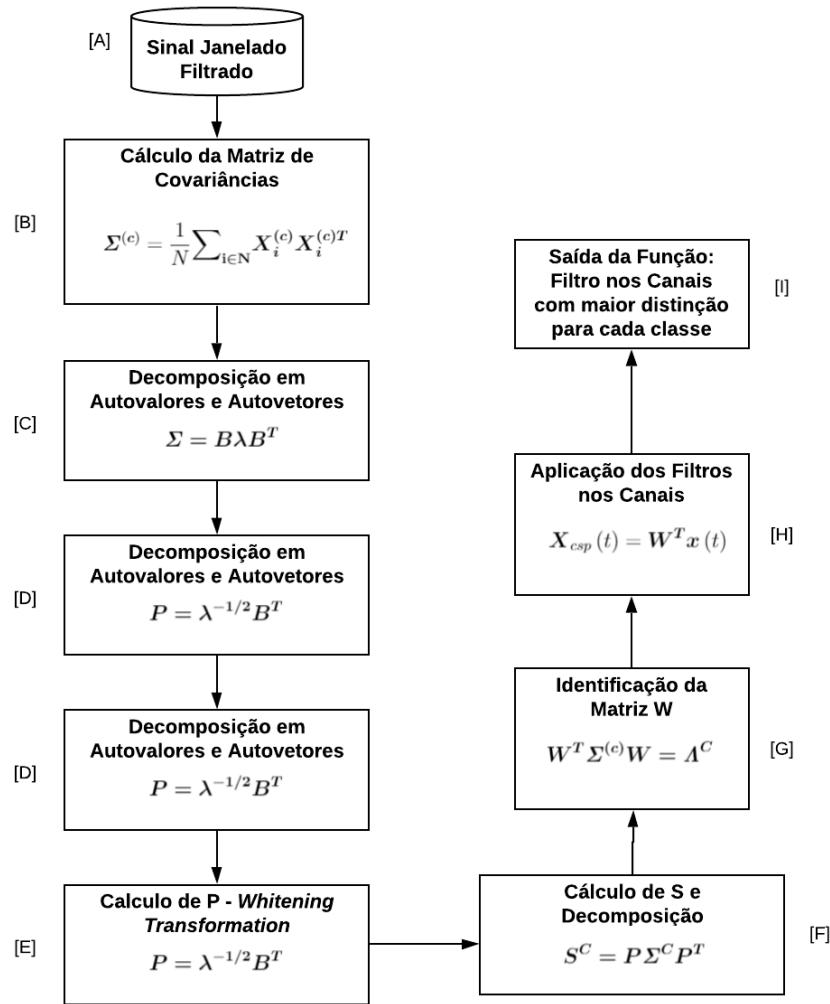


Figura 20 – Fluxograma do Função *cspfilter()* desenvolvida no *Matlab*, versão 2012b.

Na Figura 20 entrada (A) da função é o sinal já filtrado e dividido em trilhas para cada classe, onde em (B) é calculada a matriz de covariância utilizando a Equação (3.2) para cada uma das classes. Em (C) decompõe-se a soma das matrizes de covariância para as classes em seus autovalores e autovetores utilizando a função *eig()* no *software Matlab*, aplicando a Equação (3.7). Após o cálculo dos autovalores e autovetores calcula-se a matriz P a partir da operação de *whitening transformation* em (D), com a Equação (3.8), e ainda calculada em (E) a matriz S para as duas classes utilizando os autovalores e autovetores respectivos calculados em (B). Em (F) é decomposta a matriz S de cada classe para obter W a partir da Equação (3.5), em (G). São definidos os dois canais com maior distinção a partir dessa matriz diagonal W, identificado pelo maior valor da matriz de covariância

calculada para cada classe com W . Com os canais CSP definidos, multiplica-se a matriz de sinais de cada trilha por W , como na Equação (3.1), e filtra-se as colunas correspondentes para os canais com maior distinção.

No passo (5), da Figura 19, são extraídas as características que serão utilizadas para a classificação das trilhas do sinal, essas características foram baseadas no trabalho (ALZAHAB; ALIMAM; ALNAHHAS, 2019), onde foi realizado um estudo com diversas características aplicadas de forma não combinada. Assim, foram extraídas as seguintes características: valor RMS, desvio padrão, *Power Spectral Density* (PSD) e *Differential Entropy* (DE).

O valor RMS do sinal foi feito para cada trilha utilizando a função *rms* e o valor do desvio padrão utilizando a partir da função de estatística *std*. A utilização do desvio padrão e do valor RMS mostram-se interessante na utilização da detecção de ERD/ERS sendo que esses fenômenos alteram as amplitudes de forma mais acentuada em um lado do cérebro.

A PSD foi estimada a partir do método do Periodograma de Welch, método dependente da transformada de Fourier. Este método utiliza janelas sobrepostas onde é realizado a FFT do sinal e é comumente utilizado para sinais de EEG por este não possuir caráter estacionário no tempo, logo, a partir do janelamento sobreposto de K amostras é possível diminuir o erro aleatório para janelas de até 50% de sobreposição (STOICA; MOSES *et al.*, 2005)(WELCH, 1967) (ALZAHAB; ALIMAM; ALNAHHAS, 2019).

Para implementação do método, o sinal \mathbf{X} é dividido em K partes sobrepostas, representadas por $\mathbf{X}_k(j)$, onde L é o tamanho do vetor de cada divisão. Então, aplica-se a transformada discreta de Fourier para as sequências do sinal janelado multiplicadas pelo janelamento $\mathbf{W}(j)$, descritas nas Equações Equação (4.1) e Equação (4.2) (WELCH, 1967).

$$\mathbf{W}(j) = 1 - \left(\frac{j - \frac{L-1}{2}}{\frac{L+1}{2}} \right)^2 \quad (4.1)$$

$$\mathbf{A}_k(\mathbf{n}) = \frac{1}{L} \sum_{j=1}^L \mathbf{X}_k(j) \mathbf{W}(j) e^{-\frac{2kjn\sqrt{-1}}{L}} \quad (4.2)$$

Logo, o K periodograma modificado pode ser encontrado pela Equação (4.3) onde f_n é representado pela Equação (4.4) e U é representado pela Equação (4.5), obtendo assim a média do periodograma que representa a PSD calculado com o periodograma de Welch na Equação (4.6) (WELCH, 1967).

$$I_k(f_n) = \frac{L}{U} |\mathbf{A}_k|^2 \quad (4.3)$$

$$f_n = \frac{n}{L}; n = 0, 1, \dots, \frac{L}{2} \quad (4.4)$$

$$U = \frac{1}{L} \sum_{j=1}^L \mathbf{W}^2(j) \quad (4.5)$$

$$P(f_n) = \frac{1}{K} \sum_{k=1}^K I_k(f_n) \quad (4.6)$$

No trabalho, foi utilizada a função *pwelch* disponível no software *Matlab* versão 2012b e realizada a média da magnitude na frequência.

O método de *differential entropy* mede a complexidade de uma variável continua com caráter estocástico. É mostrado em (SHI; JIAO; LU, 2013) que o sinal de EEG pode ser relacionado com uma distribuição gaussiana, a partir disso a DE pode ser calculada aproximadamente pela Equação (4.7). Sendo utilizada para extrair métricas complexas ao comparar com uso de estatísticas como média aritmética e desvio padrão (SHI; JIAO; LU, 2013).

$$DE = \frac{1}{2} \log(2\pi e \sigma_i^2) \quad (4.7)$$

4.3 Etapa para Visualização do Sinal e Fenômenos

Como o sinal de EEG possui grandes particularidades e os fenômenos propostos a serem analisados no trabalho são fenômenos difíceis de serem visualizados, é preciso criar uma rotina somente para a visualização dos dados e entendimento de características do fenômeno para os diferentes usuários, como o atraso na aparição do fenômeno de ERD/ERS e frequências onde o sinal é mais discriminado para cada usuário. Nesta seção será descrito os procedimentos para geração das visualizações do sinal a partir da soma do sinal para os diferentes movimentos no tempo e análise a partir do índice de laterização. Fluxograma do processo de visualizações disponível na Figura 21.

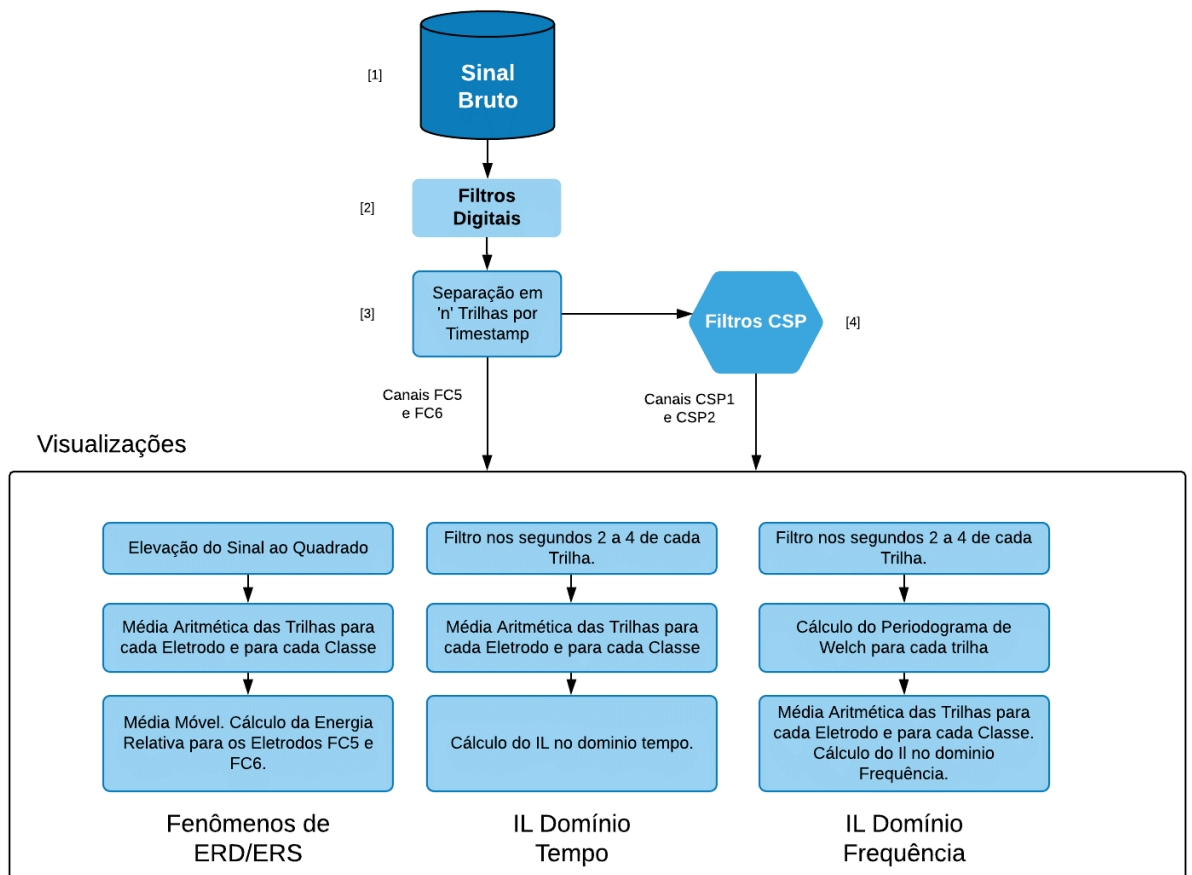


Figura 21 – Fluxograma para Visualizações dos Sinais.

4.3.1 Visualização dos fenômenos de ERD/ERS

A visualização dos fenômenos de ERD e ERS é extremamente importante para distinguir as diferenças existentes nos canais, principalmente, localizados próximas a região do córtex motor. Essa visualização é feita no domínio tempo.

Para análise do sinal os passos da Figura 19 são seguidos até a etapa [3] ou [4], sendo a etapa [3] para análise dos canais FC5 e FC6, sinais mais próximos à região do córtex motor disponíveis na touca *Emotiv* - logo, locais onde espera-se maior distinção entre os canais existentes na touca - e a etapa [4] para visualização dos sinais dos canais definidos como CSP1 e CSP2, canais com maiores distinção entre os movimentos de esquerda e direita gerados e identificados a partir do Filtro CSP. Para visualização do sinal foi definida a faixa de frequência dos filtros na banda alfa do sinal (frequências de 8 a 13 Hz).

Após as etapas [3] e [4] o sinal ainda é processado a fim de facilitar sua visualização, primeiramente cada ponto do sinal é elevado ao quadrado e então para cada movimento é feito a média aritmética de todas as trilhas para cada canal. Assim, é obtida uma matriz para cada movimento contendo a média dos canais para cada ponto de aquisição do sinal. De forma a suavizar as curvas ainda é utilizado um filtro média móvel com 51 pontos para cada canal. Por fim, é calculada a Energia Relativa de forma percentual para cada eletrodo, a partir da divisão de todos pontos da trilha pela média do período de referencia pré estímulo. Essas etapas seguem procedimentos descritos na Figura 8.

Após todo pré-processamento para visualização dos fenômenos, são gerados as figuras para todo sujeito de análise separadamente. O formato de análise é por movimento (braço esquerdo ou braço direito) e a comparação é feita entre os canais FC5 e FC6 ou CSP1 e CSP2.

4.3.2 Visualização a partir do Índice de Laterização

Ainda é possível realizar a análise gráfica para distinção entre os movimentos e a diferença de comportamento do sinal entre a esquerda e direita utilizando o Índice de Laterização (IL), ver Equação (4.8) para canais *Emotiv* e Equação (4.9) para os canais CSP. Essa análise permite verificar a distinção do sinal tanto no domínio tempo quanto

no domínio frequência, possibilitando uma análise individualizada para melhor janela de tempo e de frequência com maior distinção para cada sujeito. No trabalho é calculado o IL com os canais CSP1 (canal representado pelo lado esquerdo, com maior distinção do movimento de esquerda em relação ao movimento de direita) e CSP2 (canal representando o lado direito, com maior distinção do movimento de direita em relação ao movimento de esquerda).

$$\begin{aligned}
 IL = \frac{1}{2} & \{ (EnergiaFC5_{movimentoesquerdo} \\
 & - EnergiaFC6_{movimentoesquerdo}) \\
 & + (EnergiaFC6_{movimentodireito} \\
 & - EnergiaFC5_{movimentodireito}) \} \quad (4.8)
 \end{aligned}$$

$$\begin{aligned}
 IL = \frac{1}{2} & \{ (EnergiaCSP1_{movimentoesquerdo} \\
 & - EnergiaCSP2_{movimentoesquerdo}) \\
 & + (EnergiaCSP2_{movimentodireito} \\
 & - EnergiaCSP1_{movimentodireito}) \} \quad (4.9)
 \end{aligned}$$

No trabalho, o IL no domínio tempo é calculado no período do movimento, entre os segundos 2 e 4. O sinal é processado seguindo a mesma forma da visualização dos fenômenos de ERD e ERS e então são geradas as figuras.

Para o IL no domínio frequência é utilizado o sinal originado a partir da saída dos filtros CSP, etapa [4] na Figura 14. Neste sinal é aplicado o periodograma de Welch para todas as trilhas e realizada a média das componentes de magnitude para todas as frequências para cada um dos movimentos, e então é realizado o cálculo do IL. Assim, é possível observar as componentes de frequência onde o sinal possui maior distinção.

4.4 Classificadores

O fluxo de treinamento e utilização dos classificadores está disponível na Figura 22. É possível verificar que as etapas de filtros digitais e separação nas trilhas por *Timestamp* seguem os fluxos anteriores, porém, agora existe a necessidade da etapa [4], onde divide-se

as amostras em 80% do total da base para treinamento e 20% da base para teste da performance do modelo, percentual da base onde ocorre o cálculo do desempenho e das taxas de acerto.

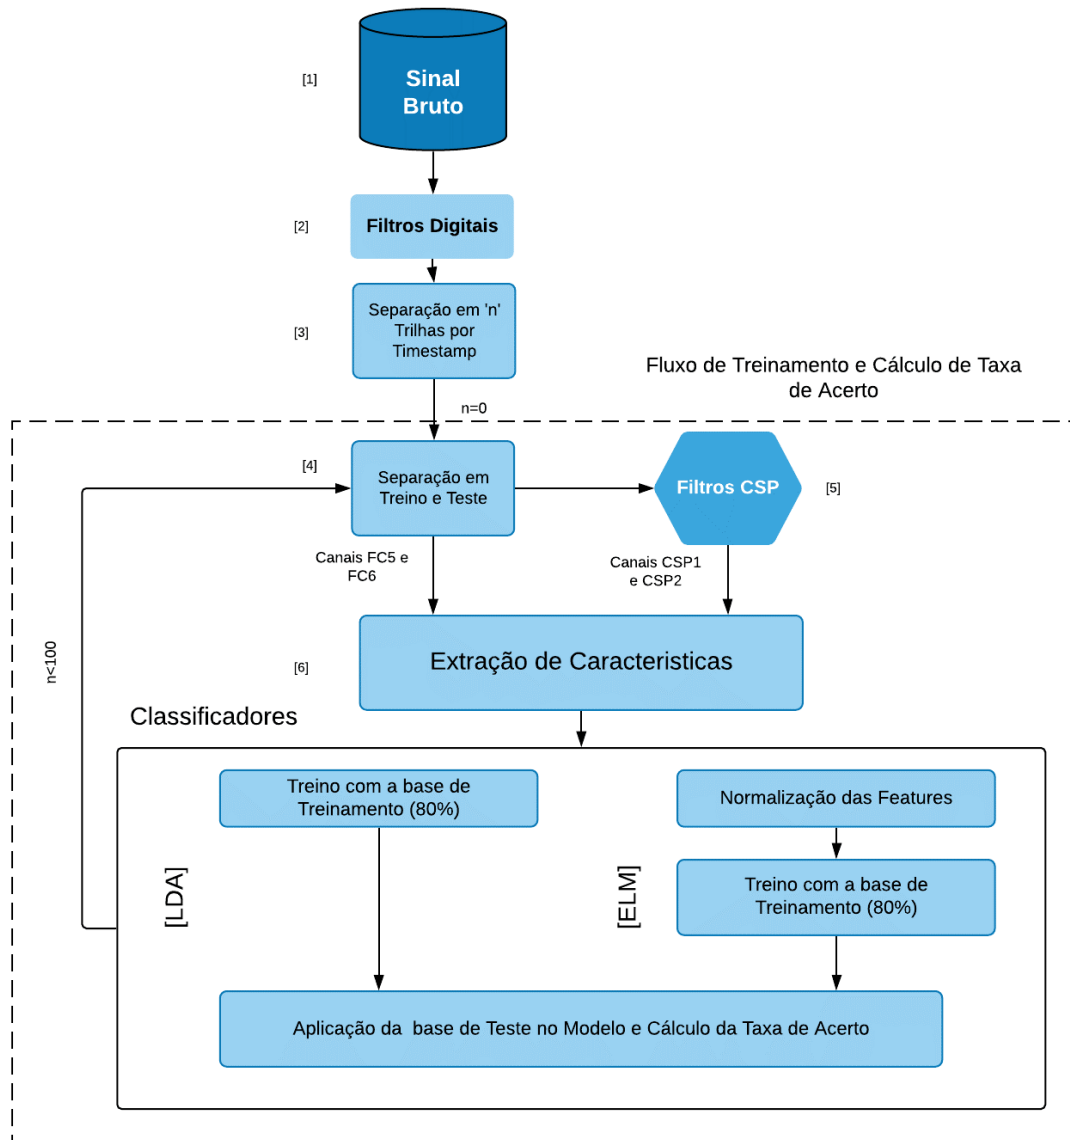


Figura 22 – Fluxograma para Classificação dos Sinais.

No 'Fluxo de Treinamento e Cálculo de Taxa de Acerto' ocorre ainda a extração das *features* para as amostras já com filtro CSP aplicado, ou sem filtro caso desejado. Após ocorre realmente a utilização das amostras para treinamento com os modelos diferentes e assim calcula-se a taxa de acerto para cada modelo separadamente.

Ainda, deve-se notar que o fluxo a partir da separação da base em treino e teste ocorre 100 vezes, de forma a separar as bases de treino e teste aleatoriamente com diferentes amostras. Esse fluxo de treinamento sempre é utilizado quando realizadas variações de hiperparâmetros ou de janelas de trilhas e filtros nos experimentos propostos.

4.4.1 *Linear Discriminant Analysis*

O classificador LDA utilizado no trabalho foi desenvolvido utilizando a *toolbox* nativa do *software Matlab*, versão 2012b, denominada *Classification Learner*. Nessa *toolbox* é possível escolher entre diferentes modelos de treinamento, permitir o uso de paralelismo computacional para treinamento, definir valores de validação, uso de *Principal Component Analysis* e também gerar um código função para cada modelo.

O código função é gerado a partir da *toolbox* para um modelo de classificador LDA, de forma a ser possível comparar resultados com outros trabalhos da área, como (MACHADO, 2012) e (SILVA, 2015), que é treinado com 80% do total da base e testado com 20% da base. As taxas de acerto são definidas utilizando a média do treinamento da base de testes 100 vezes com separações aleatórias entre teste e treino.

4.4.2 *Regularized Extreme Learning Machines*

A implementação do algoritmo do RELM foi realizada a partir da adaptação matemática do modelo de (AKUSOK *et al.*, 2015), onde transformou-se o parâmetro regularizador α como parâmetro de entrada na *toolbox*, explorada no subseção 3.2.2. Essa modificação é necessária pela exploração do classificador como um modelo subdeterminado no trabalho (AKUSOK *et al.*, 2015). Logo, utilizou-se da função/*toolbox* modificada com o acréscimo do parâmetro regularizador do algoritmo de ELM desenvolvida em (AKUSOK *et al.*, 2015) com a implementação da solução com a pseudo-inversa para classificação do sinal entre movimentos de esquerda e movimentos de direita. No algoritmo é possível definir a base para treino, a base para teste, a utilização como um classificador ou regressor, a função de kernel do algoritmo, número de neurônios e ainda ativar ou não a regularização e definir o parâmetro de regularização. A função retorna valores de taxa de acerto para classificador ou *Root Mean Square Error*(RMSE) quando utilizado o algoritmo como regressor e classes/valores preditos para cada amostra de treino e de teste. No trabalho, a

divisão entre treino e teste é realizada anteriormente, como visto em Figura 22 e é utilizado somente o classificador da *toolbox*, a taxa de acerto também é calculada posteriormente como no fluxograma.

No trabalho, além do pré-processamento e extração de *features* citados anteriormente, ainda realizou-se a normalização de todas as *features*, como demonstrado em Figura 22, etapa que é extremamente importante quando utilizado o ELM/RELM (AKUSOK *et al.*, 2015). A normalização é realizada para cada conjunto de *feature*-canal utilizando a Equação (4.10), onde \mathbf{X} é o vetor para cada *feature*-canal e X_{max} e X_{min} seus valores máximo e mínimo, respectivamente.

$$\mathbf{X}_{normalizado} = \frac{\mathbf{X} - X_{min}}{X_{max} - X_{min}} \quad (4.10)$$

São utilizadas todas as *features* definidas anteriormente como entradas do modelo. Foi definido como função de ativação do modelo como a função *hardlim* e dividida a base em 20% amostras de testes e 80% amostras de treino, aleatoriamente para cada iteração. Para cada indivíduo foi treinado um modelo independente, definindo os hiperparâmetros de número de neurônios na camada oculta e valor do parâmetro de regularização a partir do planejamento experimental individualizado para cada parâmetro, confirmando as diferenças de taxa de acerto nas bases de teste.

Após a definição de todos os hiperparâmetros do ELM treinou-se para cada voluntário 100 vezes o modelo, variando aleatoriamente as amostras de treino e de teste e então foram calculadas as médias aritméticas e desvios padrões¹.

¹ Devido ao baixo número de amostras para cada treinamento, utilizou-se a base de testes para definição dos melhores hiper-parâmetros e também para os melhores resultados considerando o Planejamento Experimental. Em trabalhos futuros, com um número de amostras e pacientes maior, sugere-se a separação da base em três partes, uma utilizada para treinamento, outra para validação - onde ajustam-se os parâmetros - e uma terceira para teste, onde não são realizadas melhorias relacionando essa base. Também é sugerido a utilização de um método de validação para discussão em um estudo com um tamanho amostral maior, como validação cruzada. No trabalho há separação dos resultados sem definição dos melhores hiper-parâmetros e os resultados considerando essa definição considerando a base que foi definida como base de testes.

4.5 Planejamento Experimental

4.5.1 Variações do Conjunto de *features* para o Modelo de ELM

De forma a validar o conjunto de *features* com melhor taxa de acerto para o modelo de ELM utiliza-se a combinação entre todas os conjuntos de características. Ao todo possuem 15 combinações, que foram definidas com números para representação, como consta na Tabela 2.

Tabela 2 – Representação das *features*.

Número do Conjunto	<i>features</i> Representadas
1	Todas
2	Welch
3	RMS
4	STD
5	DE
6	Welch + RMS
7	Welch + STD
8	Welch + DE
9	RMS + STD
10	RMS + DE
11	STD + DE
12	Welch + RMS + STD
13	Welch + RMS + DE
14	Welch + STD + DE
15	RMS + STD + DE

Os canais não foram variados, ou seja, para todos os conjuntos estão incluídos os canais relativos ao lado esquerdo e direito do cérebro nas *features* respectivas.

O modelo ELM foi treinado 100 vezes para cada conjunto de *features* para cada voluntário, obtendo o conjunto de características com melhor taxa de acerto para cada. Os resultados foram analisados a partir do planejamento experimental para justificar a escolha, caso a diferença seja visível ao analisar o intervalo de médias aritméticas e desvios padrões, o conjunto de *features* escolhido é o que possui maior taxa de acerto média entre os treinamentos.

4.5.2 Variação de Frequências e Janelas de Tempo

Como o sinal de EEG e os fenômenos analisados no trabalho possuem uma grande variabilidade por indivíduo e até mesmo por seção, nível de concentração e diversos outros fatores é proposta a classificação a partir de determinação de melhores frequências e melhores períodos iniciais para análise em cada um dos pacientes, obtendo assim os melhores resultados possíveis.

Para essa análise é feito o algoritmo baseado no Figura 22. Todo o 'Fluxo de Treinamento e Cálculo de Taxa de Acerto' é mantido igual, sendo os parâmetros frequência de corte do sinal e corte do movimento na separação de trilhas iterados e variados para os testes.

Primeiramente, percorre-se janelas de frequência de 5 Hz (com frequências centrais de 3 a 23 Hz e passo de 1 Hz por iteração - percorrendo assim toda a região típica dos fenômenos ERD e ERS e todas as bandas típicas de EEG) e aplica esse filtro digital no sinal (Etapa [2] do pré-processamento). O algoritmo é treinado com o modelo de LDA e o modelo de ELM 100 vezes para cada frequência central relativa ao filtro passa banda, assim a definição da melhor janela de frequência é realizada manualmente com a escolha da frequência com melhor média aritmética de taxa de acerto para os dois métodos.

Após definida a melhor frequência, o algoritmo percorre as janelas de tempo. O período que o movimento começa a ocorrer idealmente é no segundo 2, porém tanto por atraso na execução ou demora no surgimento dos fenômenos são definidas janelas de dois segundos com passo de 0,25 segundos. São percorridas com esse passo considerando o início do fenômeno do segundo 2 ao segundo 3. Da mesma forma que para escolha da frequência, o algoritmo treina 100 vezes por início do período de movimento e define-se a janela ideal a partir da média aritmética de taxa de acerto e seu desvio padrão.

Com as frequências centrais e os períodos de tempo ideais definidos, é calculada a média para o classificador LDA. Ainda, é necessário realizar toda a etapa de definição de hiperparâmetros ideias para o ELM novamente, assim, obtém-se uma tabela final dos resultados de taxa de acerto médio nos testes para os modelos e indivíduos.

4.6 Base Padrão de Sinais de EEG

Serão analisadas em conjunto ao trabalho proposto a base *BCI Competition 2000*, afim de validar os métodos de processamento e classificação empregados para detecção de fenômenos de ERD e ERS.

O banco de dados *BCI Competition 2000* é considerada padrão na área de sistemas BCI pela utilização por diversos trabalhos da área (CARRA, 2012)(SILVA, 2015)(MACHADO, 2012) (MOHAMMADPOUR; GHORBANIAN; MOZAFFARI, 2016)(RAMOS *et al.*, 2017).

Neste trabalho é utilizada a base III do *BCI Competition II*, base onde um sujeito (sexo feminino e 25 anos) realiza movimentos em um total de 280 trilhas, com um movimento cada, divididos entre movimentos imaginários da mão esquerda e direita. A disposição de tempo da trilha está representada na Figura 23, onde os dois segundos iniciais são de repouso, o terceiro segundo é representado por uma cruz de atenção pré-movimento e nos segundos seguintes é realizado o movimento imaginário.

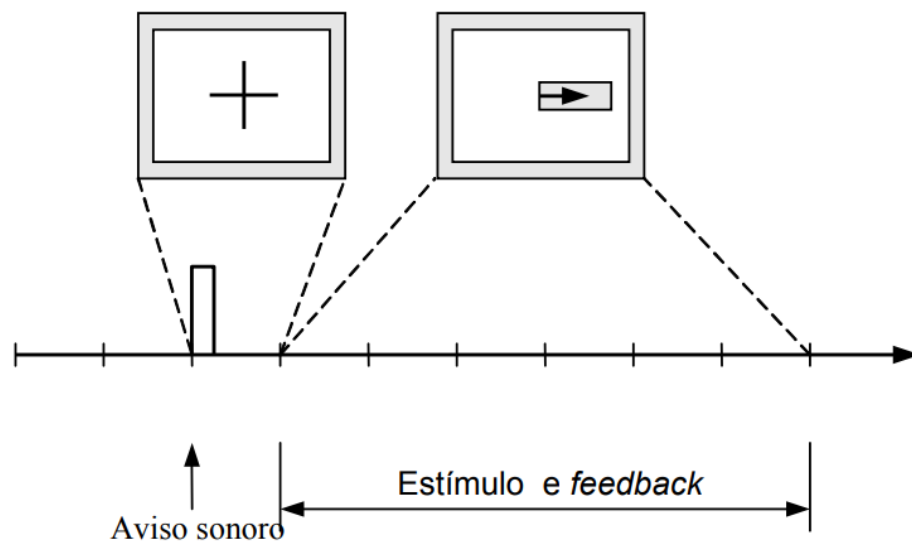


Figura 23 – Temporização de cada Trilha no BCI Competition II, base III. Adaptado de (BCI Competition II, 2003).

Os dados foram adquiridos a uma frequência de amostragem de 128 Hz e o equipamento utilizado filtra os sinais de 0,5 a 30 Hz. Os dados são adquiridos a partir de 3 eletrodos, C3, C4 e Cz, como pode ser observado na Figura 24.




Figura 24 – Disposição de Eletrodos do Experimento. Extraído de (BCI Competition II, 2003).

5 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados e realizadas as discussões relativas à cada subseção. Primeiramente, é feita a validação do método de visualização, das *features* e dos classificadores a partir de uma base de referência da área, a base da *BCI Competition* que possui dados de um Voluntário somente, com 240 amostras.

Após, são levantados os resultados visuais do trabalho, com a apresentação da análise da energia do sinal para verificação dos fenômenos de ERD e ERS para todos os indivíduos, também é apresentado os resultados das análises do sinal a partir do IL no tempo e na frequência.

A partir disso, são analisados os resultados dos classificadores individualmente, e também apresentadas as análises das *features* extraídas para os modelos. São verificados e analisados os experimentos propostos, com treinamento com diferentes *features* e também o estudo de frequências e tempos.

5.1 Validação do Método a partir da Base *BCI Competition II*

5.1.1 Análise do Sinal

Para análise do sinal da base da *BCI Competition* utilizou-se somente os canais CSP para visualização, sendo que estes possuem maior distinção entre as classes e permitem melhor entendimento do comportamento do sinal, como discutido em (BLANKERTZ *et al.*, 2007). Na Figura 25 está disponível a análise dos fenômenos ERD/ERS, e na Figura 26 e Figura 27 estão disponíveis as análises do índice de laterização.

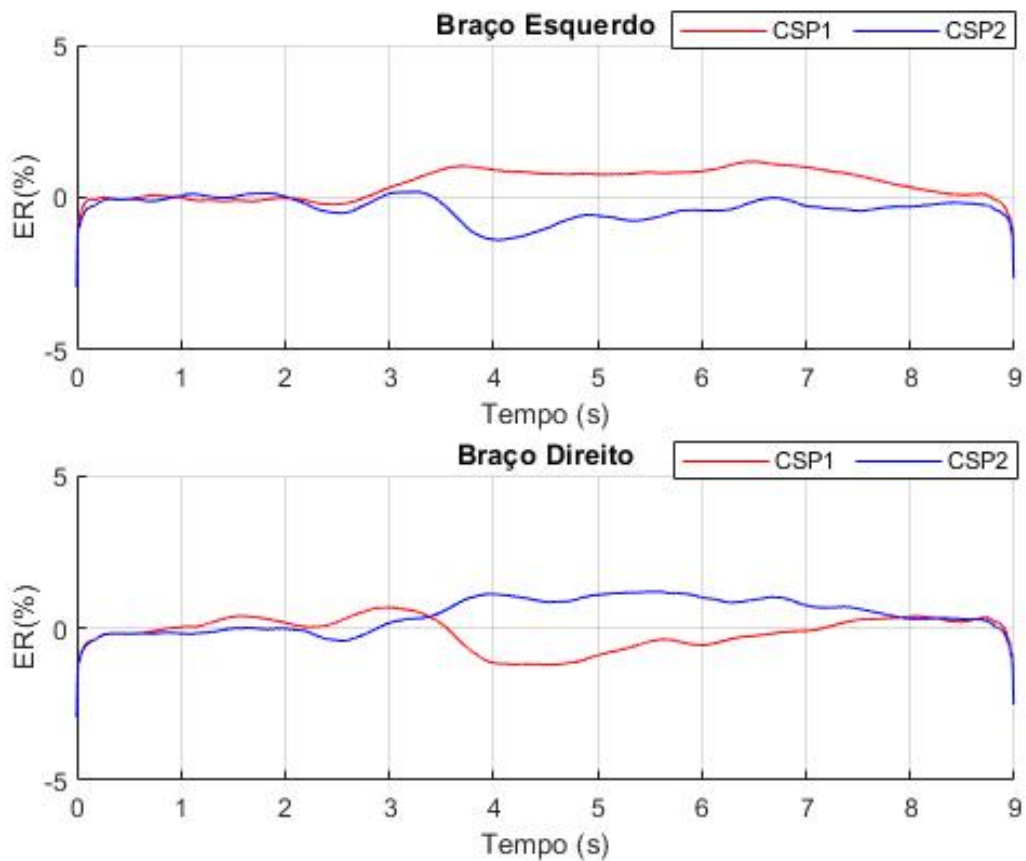


Figura 25 – Energia média Relativa dos canais CSP1 e CSP2 para a Base BCI Competition.

É possível perceber como existe uma distinção de amplitude para os sinais durante todo o período de imaginação de movimento, a partir do terceiro segundo, tanto nos movimentos de esquerda quanto nos movimentos de direita. Verifica-se o fenômeno de ERD ocorrendo principalmente no canal localizado no lado contralateral ao movimento logo após o segundo três e logo após o acontecimento do fenômeno de ERS no lado ipsilateral ao movimento, como descrito em (PFURTSCHELLER; SILVA, 1999) e identificados utilizando a mesma base referência em (MACHADO, 2012) e (SILVA, 2015).

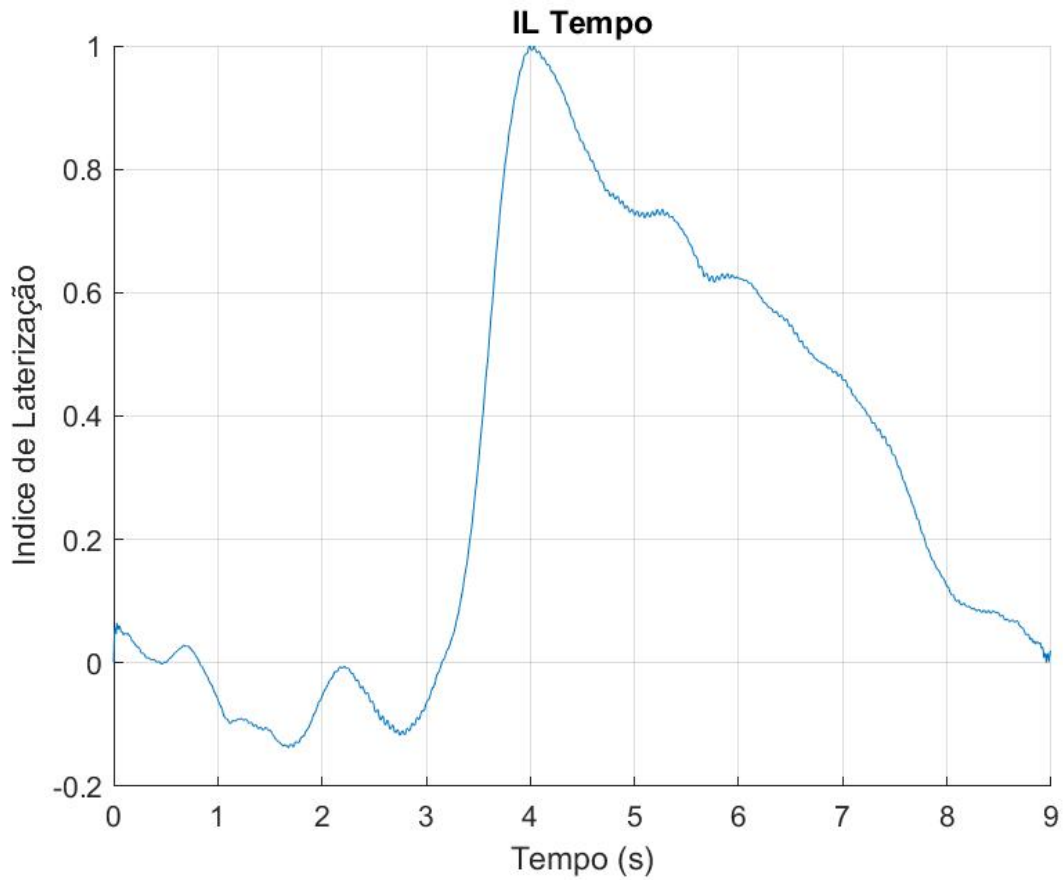


Figura 26 – Índice de laterização no domínio tempo os Canais CSP1 e CSP2.

É possível verificar a diferença de amplitude entre as classes em relação aos canais a partir do índice de laterização no tempo, utilizando a Equação (4.9), que possui seu valor de pico próximo a 3,8 segundos indicando assim que o máximo valor de IL, que indica a região em que há uma maior diferença entre os sinais para cada classe e canal.

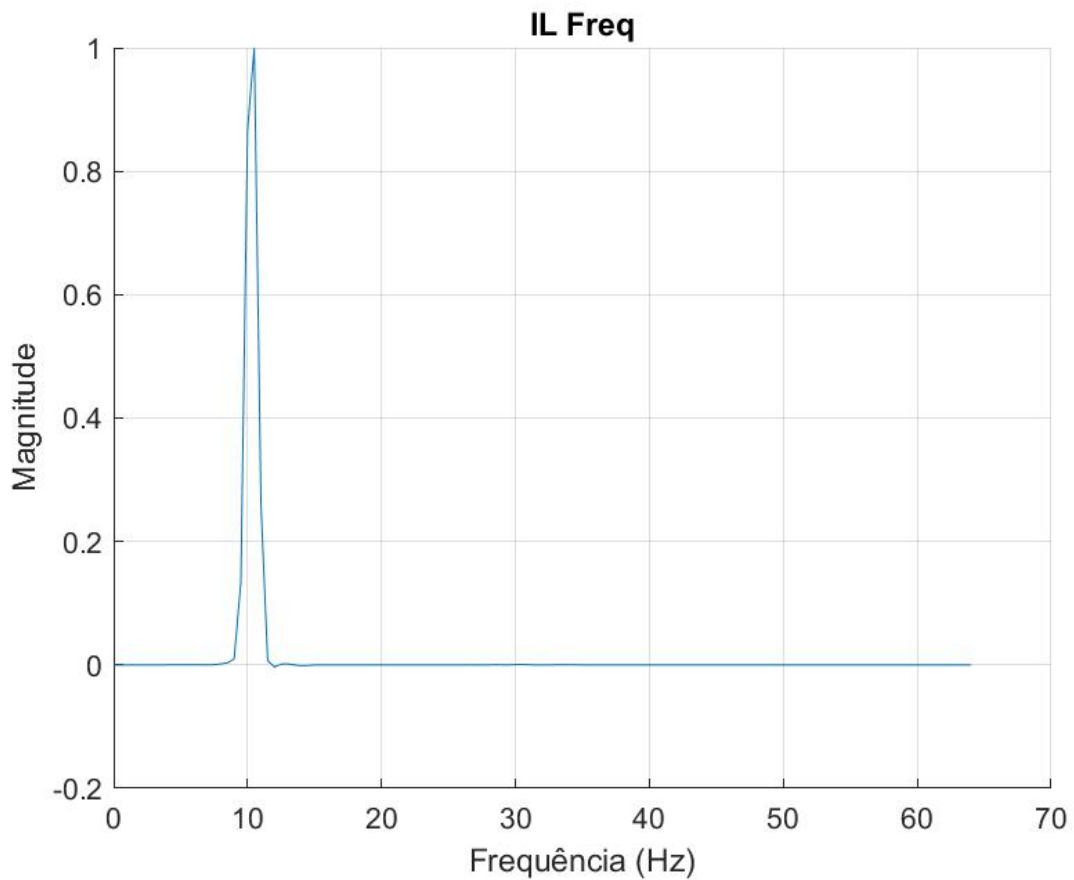


Figura 27 – Índice de laterização para os Canais CSP1 e CSP2 na Frequência.

Já na análise do sinal na frequência é possível ver que, para o sujeito analisado a frequência com maior valor de IL fica exatamente na região central do filtro digital, localizada na banda alfa, sendo as possíveis distinções em outras frequências atenuadas. Esse resultado é similar a análise de IL realizada em (MACHADO, 2012) e (SILVA, 2015) que também indicaram maior distinção (ou seja, maior índice de laterização) na região da frequência alfa para o experimento da (BCI Competition II, 2003).

O valor de índice de laterização no tempo com valores elevados na região em que ocorre o movimento e os fenômenos de ERD e ERS presentes também no período dos movimentos indicam que existem diferenças presentes nos sinais dos eletrodos para os movimentos distintos, possibilitando que sejam extraídas *features* buscando a classificação destas diferentes trilhas de sinal.

5.1.2 Classificadores

Foram utilizadas os classificadores LDA e ELM sem ajustes de frequência e tempo ideais e utilizando todas as *features* extraídas para a classificação do sinal, selecionando os melhores hiperparâmetros para o ELM. Os resultados obtidos foram de $83,1 \pm 1,8\%$ para o classificador LDA e $84,5 \pm 1,6\%$ para o ELM. Observa-se taxas de acerto compatíveis com as de outros trabalhos que utilizaram a mesma base (MACHADO, 2012)(SILVA, 2015).

Observando a Figura 28 e a Tabela 3 é possível ver uma distinção de valores entre os intervalos considerando média e desvio padrão (média mais ou menos um desvio padrão possui diferença para as classes - 1 definido como esquerda e 2 como direita - em cada segmento e canal) em todas *features*, exceto RMS, utilizadas em todos os canais analisados. Importante salientar que esses resultados consideram somente um intervalo de um desvio padrão em relação a média aritmética, e não a distribuição total do conjunto. Um ponto a ser analisado é a quantidade de repetições para cada movimento, que nessa base totalizam 280 movimentos divididos entre as classes, possuindo 140 amostras para cada classe. Outro ponto interessante é que na touca do experimento do *BCI Competition* a localização dos eletrodos é exatamente na região do córtex motor e, ainda, utilizou-se local totalmente controlado para a aquisição neste experimento, assim sendo uma base de referência na área onde os sinais apresentam claramente os fenômenos de ERD e ERS explorados para distinção entre movimentos.

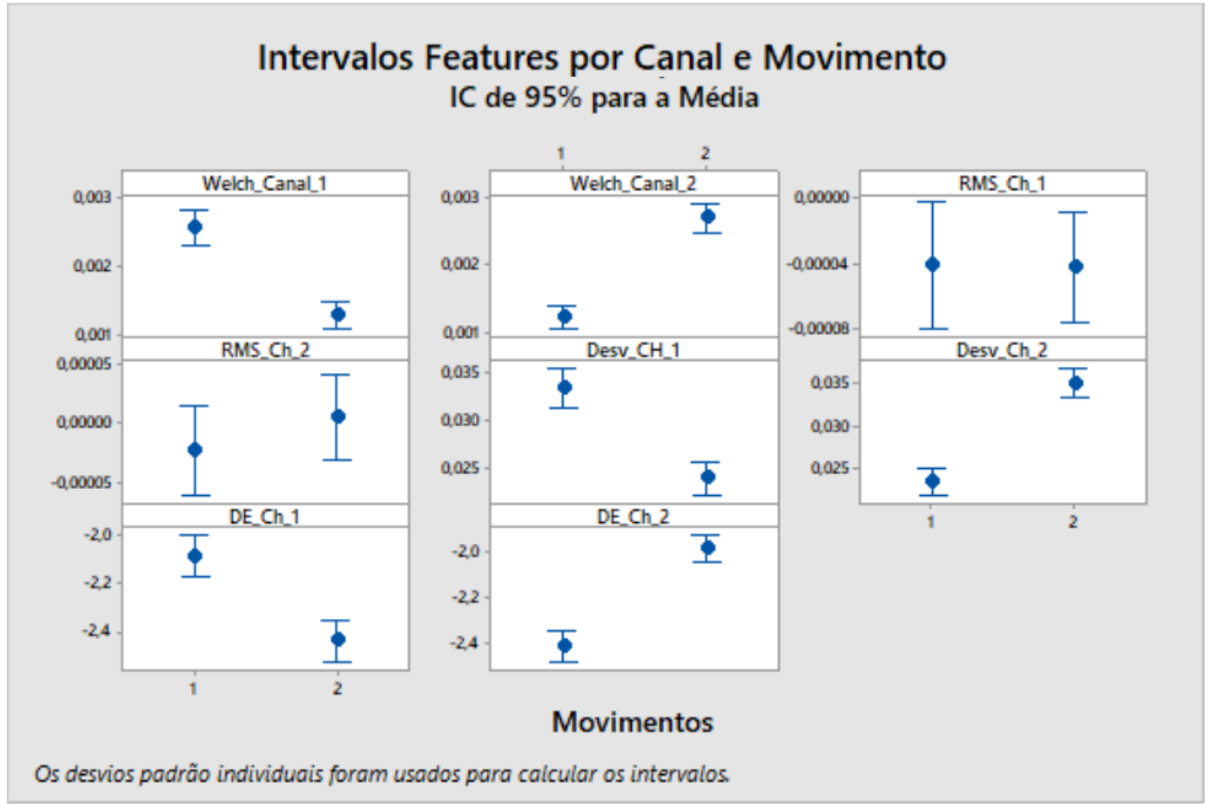


Figura 28 – Intervalos para características o Experimento *BCI Competition*.

Tabela 3 – Valores para características por canal e movimento no Experimento *BCI Competition*.

Características - Canal	Movimento	Sujeito BCI Competition
Welch - Canal Esquerda	<i>Esquerda</i>	0,0026 ± 0,0002
	<i>Direita</i>	0,0013 ± 0,0002
Welch - Canal Direita	<i>Esquerda</i>	0,0013 ± 0,0003
	<i>Direita</i>	0,0028 ± 0,0002
RMS - Canal Esquerda	<i>Esquerda</i>	- 0,00004 ± 0,00004
	<i>Direita</i>	- 0,00004 ± 0,00003
RMS - Canal Direita	<i>Esquerda</i>	- 0,00003 ± 0,00002
	<i>Direita</i>	0,00002 ± 0,00002
Desvio Padrão - Canal Esquerda	<i>Esquerda</i>	0,033 ± 0,002
	<i>Direita</i>	0,023 ± 0,002
Desvio Padrão - Canal Direita	<i>Esquerda</i>	0,022 ± 0,001
	<i>Direita</i>	0,035 ± 0,001
Diff. Entropy - Canal Esquerda	<i>Esquerda</i>	-2,1 ± 0,1
	<i>Direita</i>	-2,4 ± 0,1
Diff. Entropy - Canal Direita	<i>Esquerda</i>	-2,4 ± 0,1
	<i>Direita</i>	-2,0 ± 0,1

Assim, é possível verificar a consistência do método proposto, que mesmo sem

ajustes dos melhores hiperparâmetros do modelo de ELM, das janelas de frequência e tempo permitem a visualização dos fenômenos e possuem resultados compatíveis com a literatura e trabalhos com outras metodologias de análise utilizando a base (BCI Competition II, 2003)(MACHADO, 2012)(SILVA, 2015).

5.2 Análise da Energia do Sinal - Pacientes Sedados e Grupos de Controle

Para análise da energia relativa do sinal e visualização dos fenômenos são realizadas as etapas descritas na metodologia a partir do sinal filtrado na banda alfa e na Figura 21. Na Figura 29 e na Figura 30 estão disponíveis os resultados considerando os canais FC5 e FC6. Os resultados para os outros sujeito e pacientes estão disponíveis no Apêndice B.

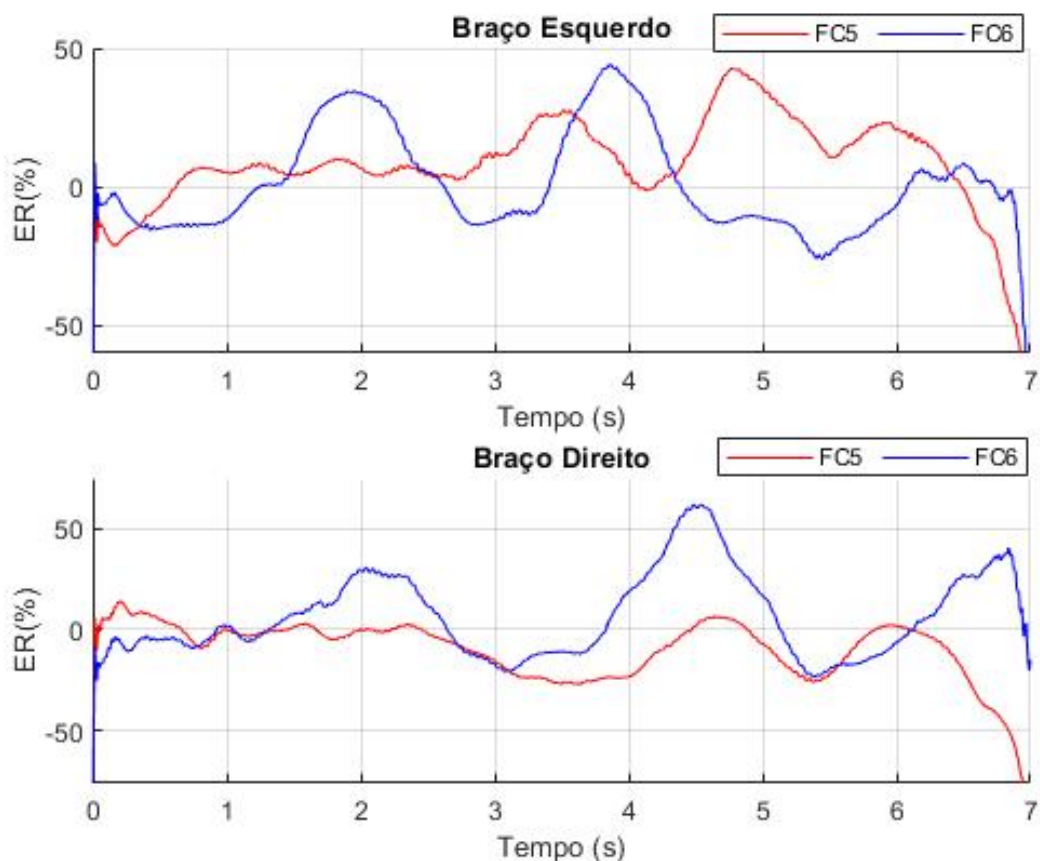


Figura 29 – Energia média Relativa dos canais FC5 e FC6 para o Sujeito 1.

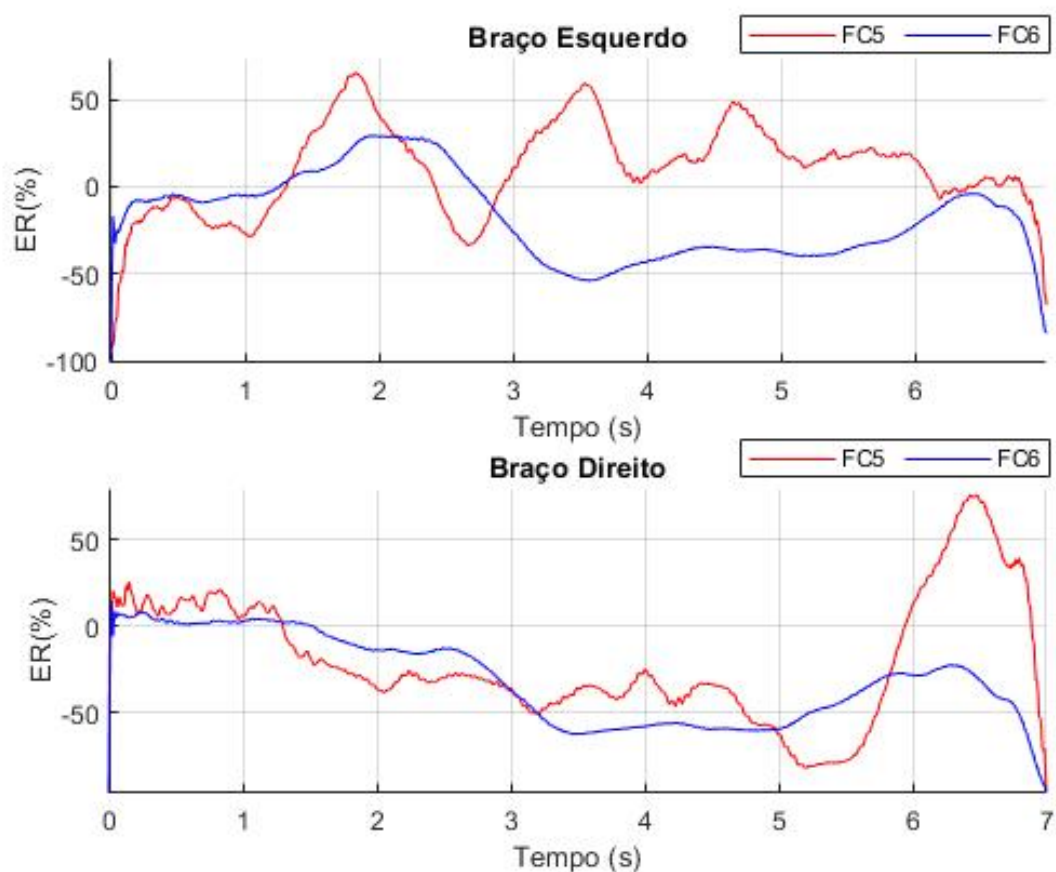


Figura 30 – Energia média Relativa dos canais FC5 e FC6 para o Paciente 3.

É possível observar forte dessincronização logo antes e imediatamente após o início do movimento, ao tempo igual a dois segundos, principalmente para o Sujeito 1 e os Paciente 3 tanto nos movimentos de esquerda quanto nos movimentos de direita. O fenômeno de ERS também pode ser observado para todos os participantes, porém ocorrem em momentos distintos, como para o Sujeito 1 que começa a ocorrer cerca de $700ms$ após a realização do movimento e para o Paciente 3 que ocorre principalmente a partir de $500ms$ após o movimento. Ainda é possível observar que a laterização no Paciente 3 não é tão evidente quanto nos outros participantes. O Paciente 3 tem um fenômeno de ERD acentuado tanto na realização dos movimentos do braço esquerdo quanto nos movimentos do lado direito no canal FC6, porém é possível observar uma diferença relativa entre os canais FC5 e FC6 nos movimentos do braço direito menor quando comparada aos movimentos do braço esquerdo, onde o fenômeno de ERS ocorre de maneira clara no canal FC5.

Os resultados analisados de forma geral mostram uma variabilidade nos momentos de dessincronização do sinal, bem como do fenômeno de ERS demonstram também características como maior discriminação de um movimento em relação ao outro. Porém, apresentam os fenômenos característicos, como visíveis em (MACHADO, 2012)(CARRA, 2012) e principalmente (SILVA, 2015) onde também é utilizado a touca *Emotiv* e os canais FC5 e FC6, canais mais próximos da região do córtex motor disponíveis mas não localizados na região onde os fenômenos são mais visíveis (região dos canais C3 e C4, canais utilizados em (BCI Competition II, 2003)) (SANEI; CHAMBERS, 2007).

As figuras dos canais CSP1 e CSP2 estão disponíveis nas Figura 31 e Figura 32, enquanto os resultados para os outros sujeitos e pacientes estão disponíveis no Apêndice B.

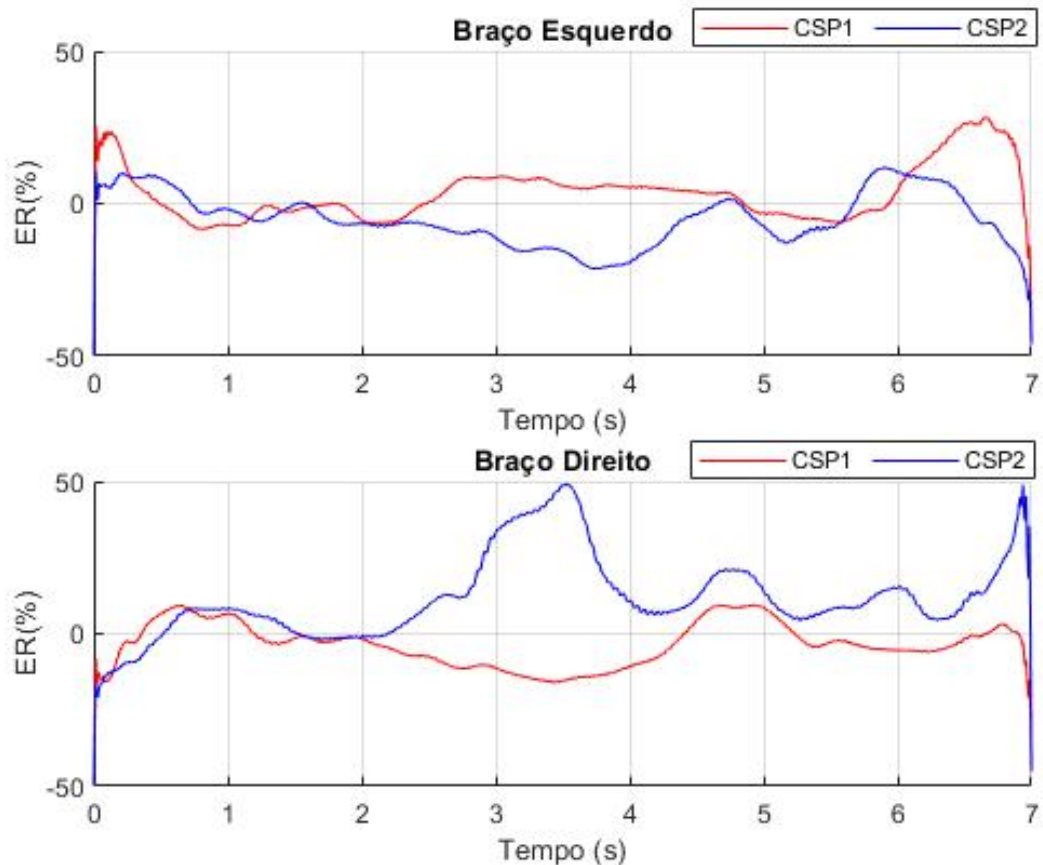


Figura 31 – Energia média Relativa dos canais CSP1 e CSP2 para o Sujeito 1.

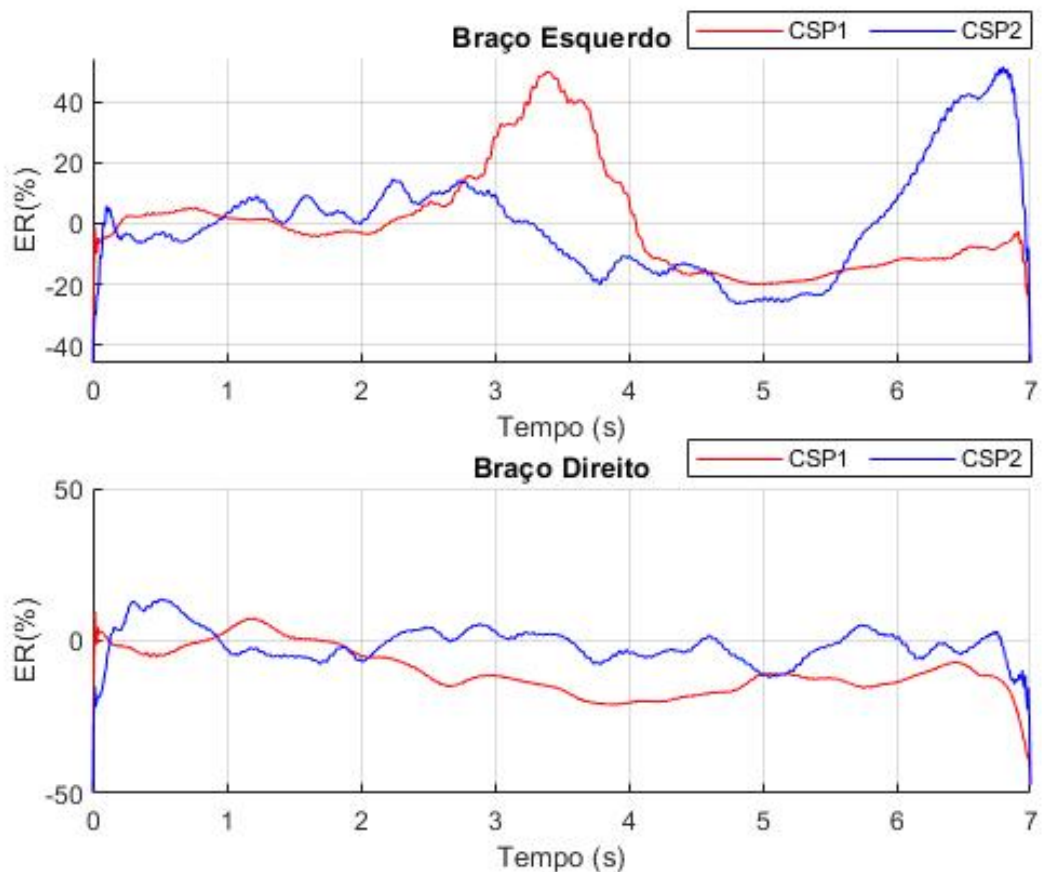


Figura 32 – Energia média Relativa dos canais CSP1 e CSP2 para o Paciente 3.

Quando comparados as figuras dos canais FC5 e FC6 evidenciam a melhora na visualização dos fenômenos de ERD e ERS. É possível observar essa melhora para todos os indivíduos, principalmente na discriminação entre o segundo 2 e 4, utilizados como intervalo de tempo para aplicação do filtro CSP para transformação espacial com maior distinção entre as classes considerando todos canais. Para todos os sujeitos os fenômenos de ERD e ERS são discriminados e a laterização entre os canais possui valores altos, próximos de 1 no período de realização do movimento.

Essa melhora na identificação e visualização dos sinais deve-se ao filtro CSP maximizar a discriminação entre classes no período do movimento entre todos os canais aplicados ao filtros, não se restringindo somente aos canais FC5 e FC6 (BLANKERTZ *et al.*, 2007). A exibição dos sinais deixa mais claro os fenômenos que podem ser comparados a própria base (BCI Competition II, 2003) analisada no trabalho com o filtro CSP e também

as análises utilizadas em outros trabalhos (MACHADO; BALBINOT, 2014)(SILVA, 2015).

Observa-se também que mesmo com a aplicação dos filtros CSP ainda há uma variabilidade nos momentos de visualização dos fenômenos, sendo esse um parâmetro que também deve-se atentar para aplicação do filtro, de forma a aplicá-lo no tempo onde realmente há a maior diferença entre as classes de movimento nos canais, porém é necessária a análise do Índice de Laterização no Tempo para identificar essa região com maior distinção (maior valor de laterização do sinal) individualmente.

É possível verificar diferenças entre os sujeitos, porém não é possível afirmar que há diferença entre os fenômenos de ERD e ERS entre grupo de controle e sedados, primeiramente pelo pequena amostra de sujeitos em cada grupo e devido a variância dos fenômenos de indivíduo a indivíduo, podendo oscilar inclusive para o mesmo indivíduo para diferentes seções (GRAIMANN; ALLISON; PFURTSCHELLER, 2009).

5.2.1 Índice de Laterização no Tempo

O índice de laterização no tempo foi calculado como explicitado na metodologia. Foi plotado os valores de IL para todos os indivíduos de estudo com os valores de IL para os canais já filtrados CSP1 e CSP2 no período de realização do movimento. Essas análises estão disponíveis na Figura 33 e na Figura 34, para os demais sujeitos as visualizações estão disponíveis na Apêndice B.

Como já observado na análise dos fenômenos de ERD e ERS a laterização ocorria para todos os voluntários. Pode-se perceber que como também já observado, mas a partir da análise de IL evidenciado, os sinais possuem laterização em períodos distintos entre os indivíduos.




Figura 33 – Índice de Laterização no tempo entre os canais CSP1 e CSP2 para o Sujeito 1.




Figura 34 – Índice de Laterização no tempo entre os canais CSP1 e CSP2 para o Paciente 3.

Ainda é possível observar que esse fenômeno possui seus maiores valores de laterização entre 2,5 segundos e 3 segundos. Ocorrendo ainda valores altos de laterização para os Sujeitos 1 e Pacientes 3 próximos do final do período analisado, indicando uma laterização na realização do movimento e também ao final do mesmo.

A análise entre o Sujeito 1 e o Paciente 3 indicam uma semelhança nas curvas do fenômeno para os indivíduos de grupos diferentes, ocorrendo somente um atraso para o Sujeito 1 em relação ao Paciente 3. Essa diferença é comum em diferentes indivíduos e descrita na literatura, onde os fenômenos podem ter suas maiores distinções entre 1 e até 2 segundos após início do estímulo (PFURTSCHELLER; SILVA, 1999) (NAM *et al.*, 2011).

5.2.2 Índice de Laterização no Domínio Frequência

A análise do Índice de Laterização no domínio frequência tem o mesmo objetivo de analisar a região em que o sinal possui maior distinção entre os canais entre as classes. O cálculo é feito como descrito na metodologia utilizando o sinal pré-processado com filtros na banda alfa e filtros CSP. Os resultados das análises estão disponíveis na Figura 35 e na Figura 36, da mesma forma estão disponíveis no Apêndice B para os outros indivíduos.




Figura 35 – Índice de Laterização na frequência entre os canais CSP1 e CSP2 para o Sujeito 1.




Figura 36 – Índice de Laterização na frequência entre os canais CSP1 e CSP2 para o Paciente 3.

Como o filtro digital foi aplicado na banda alfa, é possível observar que a maior laterização ocorre exatamente na região de 8 a 13 Hz. Porém ainda é possível verificar que ainda restam componentes próximas a banda beta com relativa laterização, próximas da região de 30 Hz. Também é possível observar que tanto para o Sujeito 1 quanto para o Paciente 3 a região com maior laterização se expande acima da região da banda alfa, chegando com valores até próximo de 20 Hz, mesmo após realização dos filtros.

Com a análise do espectro do índice de laterização na frequência é possível determinar que a diferença entre as classes nesse domínio também é um fator com distinção entre os indivíduos. Considerando que as *features* extraídas para modelo de classificação, essa faixa de frequência também deve ser analisada para determinar a melhor para cada indivíduo.

Os resultados das frequências de maior laterização estão coerentes com os resultados na base de referência *BCI Competition* e com os visualizados em trabalhos com o mesmo tipo de análise de IL (MACHADO, 2012)(SILVA, 2015) e também com a bibliografia, onde as maiores laterizações são encontradas na banda alfa e também podendo ser encontradas nas bandas beta (PFURTSCHELLER; SILVA, 1999)(NAM *et al.*, 2011).

5.3 Classificadores - Pacientes Sedados e Grupos de Controle

Os resultados foram subdivididos nos dois classificadores utilizados, LDA e ELM, e na comparação entre os resultados da classificação entre os métodos. Todas as taxas de acerto explanadas no trabalho são relativas as taxas de acerto das bases de testes e em percentuais, como foram definidas na metodologia para cada modelo.

Ainda, consta neste capítulo a análise das *features* extraídas para cada classificador. A análise a seguir é feita utilizando intervalos para a média com mais ou menos um desvio padrão, e feita individualmente para cada um dos voluntários. As características são analisadas individualmente por canal CSP e verificadas as diferenças entre as classes esquerda e direita. Os resultados dessa análise estão disponíveis na Figura 37 e na Figura 38, para os outros indivíduos estão disponíveis em Apêndice B.




Figura 37 – Intervalos para características do Sujeito 1.




Figura 38 – Intervalos para características do Paciente 3.

Essa análise feita com intervalos permite verificar diferenças nas médias aritméticas de todas as características em todos canais para os movimentos de esquerda e direita. É possível ainda perceber que mesmo com todo o pré-processamento uma quantidade de movimentos não possui diferença quando analisadas individualmente entre o intervalo de amostras das médias aritméticas com desvios padrões, uma das explicações é a variabilidade do sinal, mesmo para o mesmo indivíduo e seções que ocorrem com pequenos intervalos de tempo.

Individualmente é possível verificar no Sujeito 1 a distinção entre as classes através dos intervalos que não se cruzam, enquanto para o Paciente 3 as médias aritméticas estão dentro do intervalo de um desvio padrão para todas características e canais. É possível verificar que as características com maior distinção (considerada aqui os intervalos de um desvio padrão da característica para classe) para um sujeito analisado não são necessariamente as mesmas para os outros, justificando assim o uso de diferentes *features* de forma ao modelo adaptar-se e entender as principais variáveis para cada treinamento.

Ainda, pela análise das características das *features* é possível observar que as médias aritméticas do movimento 1 (esquerda) tendem a ter média maior que as médias aritméticas do movimento 2 (direita) no canal CSP1, que corresponde ao canal com maior distinção para esses movimentos. Isso pode ser explicado pela analogia no calculo que todas essas características extraídas têm com a energia, média e oscilação do sinal no período do movimento.

Na Tabela 4 e na Tabela 5 estão disponíveis os resultados das médias aritméticas e desvios padrões para o grupo de controle e para os grupo de sedados em UTI, respectivamente. É possível perceber que a distinção na média aritmética em relação as análises feitas para o *BCI Competition* realizadas no trabalho possui a mesma característica (maior média no movimento esquerdo em relação ao movimento direito, quando analisado o canal do lado esquerdo e maior média no movimento direito em relação ao movimento esquerdo, quando analisado o canal do lado direito). Porém, no *BCI Competition* os intervalos não se cruzam para grande maioria das características enquanto para os indivíduos analisados no trabalho esses intervalos se cruzam, isso demonstra a maior qualidade do sinal da base de referência que pode ser devido tanto ao treinamento dos indivíduos, ambiente de aquisição totalmente controlado, tipo de *task* e equipamento e canais utilizados sendo os mais adequados.

Tabela 4 – Valores para características por canal e movimento no Experimento com o Grupo de Controle.

Características - Canal	Movimento	Sujeito 1	Sujeito 2
Welch - Canal Esquerda	<i>Esquerda</i>	0,0022 ± 0,0007	0,0023 ± 0,0025
	<i>Direita</i>	0,0018 ± 0,0006	0,0017 ± 0,0015
Welch - Canal Direita	<i>Esquerda</i>	0,0015 ± 0,0001	0,0015 ± 0,0008
	<i>Direita</i>	0,0026 ± 0,0042	0,0026 ± 0,0038
RMS - Canal Esquerda	<i>Esquerda</i>	0,036 ± 0,004	0,034 ± 0,015
	<i>Direita</i>	0,033 ± 0,005	0,030 ± 0,009
RMS - Canal Direita	<i>Esquerda</i>	0,030 ± 0,006	0,029 ± 0,008
	<i>Direita</i>	0,0341 ± 0,016	0,034 ± 0,016
Desvio Padrão - Canal Esquerda	<i>Esquerda</i>	0,046 ± 0,006	0,044 ± 0,020
	<i>Direita</i>	0,041 ± 0,006	0,039 ± 0,012
Desvio Padrão - Canal Direita	<i>Esquerda</i>	0,038 ± 0,008	0,038 ± 0,010
	<i>Direita</i>	0,044 ± 0,022	0,044 ± 0,021
Diff. Entropy - Canal Esquerda	<i>Esquerda</i>	-1,67 ± 0,13	-1,79 ± 0,37
	<i>Direita</i>	-1,78 ± 0,14	-1,87 ± 0,27
Diff. Entropy - Canal Direita	<i>Esquerda</i>	-1,88 ± 0,20	-1,89 ± 0,24
	<i>Direita</i>	-1,79 ± 0,35	-1,78 ± 0,37

Tabela 5 – Valores para características por canal e movimento no Experimento com o Grupo de Pacientes Sedados.

Características Canal	Movimento	Paciente 1	Paciente 2	Paciente 3
Welch - Canal Esquerda	<i>Esquerda</i>	0,0041 ± 0,0178	0,0022 ± 0,0009	0,0056 ± 0,0269
	<i>Direita</i>	0,0002 ± 0,0001	0,0018 ± 0,0005	0,0019 ± 0,0010
Welch - Canal Direita	<i>Esquerda</i>	0,0017 ± 0,0012	0,0010 ± 0,0004	0,0022 ± 0,0119
	<i>Direita</i>	0,0024 ± 0,0031	0,0028 ± 0,0055	0,0053 ± 0,019
RMS - Canal Esquerda	<i>Esquerda</i>	0,019 ± 0,025	0,036 ± 0,006	0,028 ± 0,026
	<i>Direita</i>	0,011 ± 0,002	0,033 ± 0,004	0,024 ± 0,005
RMS - Canal Direita	<i>Esquerda</i>	0,029 ± 0,006	0,025 ± 0,004	0,013 ± 0,025
	<i>Direita</i>	0,029 ± 0,008	0,031 ± 0,027	0,020 ± 0,039
Desvio Padrão Canal Esquerda	<i>Esquerda</i>	0,031 ± 0,052	0,046 ± 0,008	0,035 ± 0,038
	<i>Direita</i>	0,015 ± 0,003	0,041 ± 0,005	0,031 ± 0,007
Desvio Padrão Canal Direita	<i>Esquerda</i>	0,040 ± 0,012	0,032 ± 0,007	0,017 ± 0,029
	<i>Direita</i>	0,042 ± 0,019	0,042 ± 0,033	0,024 ± 0,045
Diff. Entropy - Canal Esquerda	<i>Esquerda</i>	-2,47 ± 0,69	-1,68 ± 0,17	-2,05 ± 0,36
	<i>Direita</i>	-2,81 ± 0,22	-1,77 ± 0,12	-2,09 ± 0,21
Diff. Entropy - Canal Direita	<i>Esquerda</i>	-1,84 ± 0,30	-2,03 ± 0,19	-3,02 ± 0,62
	<i>Direita</i>	-1,82 ± 0,38	-1,94 ± 0,54	-2,85 ± 0,77

5.3.1 Classificador utilizando LDA

O classificador LDA foi implementado conforme descrito na metodologia para todas as características extraídas do sinal e treinado 100 vezes por indivíduo. Os resultados para cada voluntário estão disponíveis na Tabela 6. É possível observar taxas de acerto na mesma ordem para todos os analisados, com os melhores resultados para o Paciente 2, seguido do Sujeito 1 e Paciente 1.

Ainda, é possível verificar que as taxas de acerto possuem um desvio padrão abaixo de 2% para todos os sujeitos, indicando que apesar das diferenças nas bases de treinamento o modelo possui taxas parecidas para as diferentes seções da base de treino e teste, performando próximo ao valor da média aritmética para os 100 diferentes treinamentos variando seções das bases de treino e teste aleatoriamente.

Tabela 6 – Resultados LDA para cada voluntário.

	Sujeito 1	Sujeito 2	Paciente 1	Paciente 2	Paciente 3
Taxa de Acerto Teste LDA (%)	66,3 ± 1,9	60,5 ± 1,6	64,9 ± 2,7	67,4 ± 1,8	59,8 ± 1,1

Pela amostra de indivíduos não é possível afirmar que existem diferenças de performance entre grupos de controle e pacientes sedados. É possível verificar dentro dos grupos voluntários que obtiveram taxa superior em relação a outros, porém não há homogeneidade dentro do próprio grupo, indicando o que já é visto na literatura, que os fenômenos podem variar de indivíduo a indivíduo e até entre seções (GRAIMANN; ALLISON; PFURTSCHELLER, 2009). O resultado, junto as análises das dispersões das *features* e das visualizações dos fenômenos de ERD e ERS indicam a necessidade do estudo individualizado para definir as melhores faixas de frequência e tempo para identificação dos movimentos.

5.3.2 Classificador utilizando ELM

O classificador ELM foi implementado conforme descrito no capítulo de metodologia a partir da Figura 22, variando os hiperparâmetros e percorrendo o 'Fluxo de Treinamento e Cálculo de Taxa de Acerto' para cada conjunto de variação.

Primeiramente, variou-se o número de neurônios na camada oculta com valores de 50 a 2000 com passo de 50 neurônios, utilizando o ELM sem regularização e treinando 100 vezes para cada valor utilizando diferentes amostras para teste e treino geradas aleatoriamente. Para o melhor resultado médio de taxa de acerto na base de testes foi definido o número de neurônios, como disponível na Figura 39.

Com o número de neurônios na camada oculta definidos, variou-se o valor do parâmetro regularizador de 0 a 2 com passo de 0,05, treinando 10 vezes para cada um dos valores utilizando amostras aleatórias para as bases de treino e teste. Da mesma forma, definiu-se o parâmetro regularizador a partir do maior valor nas médias aritméticas de taxa de acerto, como disponível na Figura 40.

Pela Figura 39 é possível perceber o comportamento do classificador para menos de 700 neurônios tendendo a *underfitting* e após um valor de quantidade de neurônios próximo de 1700 os resultados de teste começam a reduzir, tendendo a um *overfitting* - caso os resultados de treinamento continuem a uma melhora e os resultados continuassem com a tendencia de redução com um aumento ainda maior de número de neuronios. O mesmo comportamento encontrado para o Sujeito 1 foi visto para os outros indivíduos,

e para cada um deles foi definido o número ótimo de neurônios, disponível na Tabela 7. No parâmetro regularizador é possível perceber uma característica não bem definida para os diferentes valores, mas da mesma forma foi definido o melhor valor para cada um dos indivíduos, disponível também na Tabela 7, lembrando que a utilização do parâmetro é necessária considerando que o modelo explorado é subdeterminado (AKUSOK *et al.*, 2015).




Figura 39 – Intervalos para Número de Neurônios na camada oculta para o Sujeito 1.




Figura 40 – Intervalos para Características do Paciente 3.

A partir das definições de hiperparâmetros ideais para cada indivíduo, obtemos a taxa de acerto da base de testes (base definida aleatoriamente para cada treinamento). É possível perceber que as taxas de acerto mudam entre os indivíduos, e que em geral, o valor de desvio padrão é alto em relação ao LDA (acima de 3,7% para todos indivíduos e chegando a 7,7% para o Paciente 1), devido principalmente a variabilidade das *features* nas diferentes seções e ao modelo ser dependente das trilhas com resultados que representem as características gerais da base serem definidas para as bases de treinamento. Sendo os melhores resultados médios para os Paciente 1 e Sujeito 1, que também possuem o maior desvio padrão entre os treinamentos.

Tabela 7 – Resultados ELM e respectivos número de neurônios e valor de Parâmetro Regularizador para cada indivíduo.

	Sujeito 1	Sujeito 2	Paciente 1	Paciente 2	Paciente 3
Número de Neurônios na Camada Oculta	1650	1850	1100	850	1800
Parâmetro Regularizador	1,80	1,10	1,10	0,05	1,00
Taxa de Acerto Teste (%)	71,0±5,5	61,9±3,7	75,9±7,6	61,0±4,7	62,1±3,9

É possível, a partir da Tabela 7, identificar a variabilidade nos hiperparâmetros para cada indivíduo, sendo necessária essa etapa de análise e identificação manual dos hiperparâmetros que apresentam melhor resultado individualmente para melhor taxa de acerto. Percebe-se que quanto maior o número de neurônios, os valores de parâmetro regularizador também foram maiores. Isso pode ocorrer devido ao aumento do número de neurônios estar relacionado a complexidade do modelo, sendo que esse aumento pode tender ao *overfitting*, como pode ser visto na Figura 39, enquanto o parâmetro regularizador está relacionado a aumentar a generalização do modelo. Logo, ao aumentar a complexabilidade do modelo foi necessário aumentar a sua generalização em relação a base de treinamento, deixando o modelo com melhores resultados para a base de testes.

5.4 Experimentos Propostos

5.4.1 Variações do Conjunto de *Features* para o Modelo de ELM

A variação de *features* utilizando o modelo ELM conforme descrita na metodologia auxilia na verificação de conjuntos de variáveis que representam melhor o modelo em relação ao uso de todas elas. Na Figura 41 é possível verificar o estudo realizado para o Sujeito 2. Pode-se perceber que mesmo com o desvio padrão o conjunto 2 (PSD com periodograma de Welch) tem em média valores mais altos que o restante dos conjuntos. Essa mesma característica que está presente na Figura 60, onde é possível observar a maior distinção entre as classes nesses eletrodos utilizando o periodograma.




Figura 41 – Intervalos para Conjuntos de features para o Sujeito 2.

Com os modelos variando as *features* treinado para todos os indivíduos foi possível preencher a Tabela 8. Observa-se que para os Sujeitos 1, Paciente 1 e Paciente 3 os melhores conjuntos foram com todas as variáveis, enquanto houve melhora no Sujeito 2 e melhora na média para o Paciente 2.

Tabela 8 – Resultados ELM e respectivos número de neurônios, valor de Parâmetro Regularizador e melhor conjunto de *features* para cada indivíduo.

	Sujeito 1	Sujeito 2	Paciente 1	Paciente 2	Paciente 3
Número de Neurônios na Camada Oculta	1650	1850	1100	850	1800
Parâmetro Regularizador	1,80	1,10	1,10	0,05	1
<i>Features</i>	1	2	1	14	1
Taxa de Acerto Teste (%)	71,0±5,5	70,0±6,9	75,9±7,6	63,5±4,2	62,3±4,2

Um dos motivos de em geral a utilização de todas as *features* possuírem melhores resultados está relacionado a forma como o ELM é modelado, possuindo uma estrutura de redes neurais *feedforward* com pesos entre cada camadas, então, a solução ótima do modelo calculada já deve definir pesos para que essas entradas não exerçam influencia no resultado

final da classificação, e identificando as entradas que possuem a maior influencia na saída (HUANG; ZHU; SIEW, 2006).

5.4.2 Variação de Frequências e Janelas de Tempo

A variação de frequências e janelas de tempo foi realizada conforme a descrição na metodologia, onde os modelos foram treinados 100 vezes para cada conjunto de frequências e posteriormente 100 vezes para cada conjunto de tempos.

Na Figura 42 é possível ver um exemplo para o Paciente 1 dos resultados em diferentes frequências centrais no classificador LDA. Ainda, verifica-se que a frequência central é uma variável fundamental para o modelo e o filtro digital utilizado e afeta diretamente no resultado final de taxa de acerto do modelo. Da mesma forma, na Figura 43 o comportamento em diferentes janelas de tempo influencia na taxa de acerto, sendo o valor no eixo de tempo da figura representado pelo *lag* de 0,25 segundos na janela de tempo inicial, sendo os valores de 0 a 4 representados como tempo inicial 2, 2,25, 2,5, 2,75 e 3 segundos, respectivamente. Como demonstrado, a janela de tempo também influi nos valores de taxa de acerto do modelo.




Figura 42 – Intervalos para Variação de Janelas de Frequência para o Paciente 1.




Figura 43 – Intervalos para Variação de Janelas de Tempo para o Paciente 1.

Os resultados foram separados por classificador na Tabela 9 e na Tabela 10, onde verifica-se que as melhores frequências e períodos de tempo são os mesmos para os dois classificadores. Na Tabela 10 ainda encontram-se os valores ideais dos hiperparâmetros utilizados.

Tabela 9 – Resultados LDA e Melhores Frequências e Tempo Inicial.

	Sujeito 1	Sujeito 2	Paciente 1	Paciente 2	Paciente 3
Frequência Central (Hz)	13	10	8	13	9
Tempo Inicial (s)	2,00	2,00	2,25	2,75	2,75
Taxa de Acerto Teste LDA (%)	75,6±2,2	69,9±1,4	75,1±2,2	78,1±3,0	63,3±1,1

Tabela 10 – Resultados ELM e respectivos número de neurônios, valor de Parâmetro Regularizador, Melhores Frequências e Tempo.

	Sujeito 1	Sujeito 2	Paciente 1	Paciente 2	Paciente 3
Frequência Central (Hz)	13	10	8	13	9
Tempo Inicial (s)	2,00	2,00	2,25	2,75	2,75
Número de Neurônios na Camada Oculta	1650	1850	1100	850	1800
Parâmetro Regularizador	1,80	1,10	1,10	0,05	1
Taxa de Acerto Teste ELM (%)	73,5±3,1	71,5±3,0	76,0±4,7	78,3±2,8	65,5±3,7

Na Tabela 11 está disponível a comparação entre os resultados para todas as *features* antes e após a definição de melhor frequência e melhor tempo. É possível verificar que para todos os analisados e para os dois métodos a seleção de frequência e tempo trazem resultados de melhora na média de taxa de acerto. Ainda, percebe-se que o modelo de ELM ficou mais estável quando comparado ao mesmo modelo sem ajuste de frequência e tempo, relacionado a possuir menores desvios padrões quando comparados ao modelo sem ajuste, para todos os analisados.

Quando comparados os modelos de LDA e ELM não é possível afirmar estatisticamente diferenças entre os dois afim de justificar a escolha de um a outros, apenas afirmar que pela média aritmética, existe um modelos com resultados de taxa de acerto médias maiores para cada um dos indivíduos quando comparado ao outro modelo. A partir do desvio padrão nas taxas de acerto o modelo de LDA tende a ser mais estável com a mudança do conjunto de treinamento e testes, podendo esse ser um parâmetro de escolha para um modelo. O LDA ainda não possui grandes dificuldades para *tuning* de parâmetros enquanto o ELM possui a necessidade de identificação dos melhores hiperparâmetros como foi possível verificar na Tabela 7, apresentando outra característica que indica facilidade para seu uso.

É possível perceber que para o volume atual de dados de treino para cada paciente o ponto ótimo de escolha de parâmetros ainda possui maior desvio padrão na taxa de acerto quando comparado ao LDA, o que verificado pelas taxas de acerto de treino e teste

indicam que em certas combinações de separação das bases aleatoriamente há padrões de *overfitting* ou *underfitting*. A tendência é que com maior quantidade de dados o modelo possa ficar mais robusto, entender melhor as variações entre as amostras e obter uma taxa de acerto maior e com menor desvio padrão entre os diferentes treinos, podendo até serem realizados testes com o ELM sem parâmetro regularizador, que com uma maior quantidade de dados (dados de treinamento maiores que o número de neurônios) pode-se treinar um modelo sobredeterminado (AKUSOK *et al.*, 2015).

Ainda, é possível realizar uma comparação das médias aritméticas entre pacientes do grupo de controle e dos pacientes sedados em UTI, porém não é possível afirmar com significância estatística que há diferença entre as amostras considerando o número de voluntários e o desvio padrão das amostras. Pode-se perceber somente que existem diferenças entre os intervalos dos indivíduos analisados, mostrando como mesmo após todo processamento do sinal ainda há diversos fatores que influenciam os resultados como, por exemplo, qualidade do contato dos eletrodos, concentração na tarefa, ruídos externos que possam afetar a aquisição e o sinal, como discutido em (GRAIMANN; ALLISON; PFURTSCHELLER, 2009).

Em relação às comparações de tempo inicial e frequências centrais, é possível perceber que em média as frequências não possuem distinção, mas em relação ao tempo inicial, este é menor para o grupo de voluntários não sedados (com média no segundo 2, enquanto para o outro grupo a média é no segundo 2,58).

Tabela 11 – Comparação ELM e LDA - Melhores Resultados.

	Sujeito 1	Sujeito 2	Paciente 1	Paciente 2	Paciente 3
Taxa de Acerto Teste LDA (%)	66,3±1,9	60,5±1,6	64,9±2,7	67,4±1,8	59,8±1,1
Taxa de Acerto Teste LDA (%) (Melhores Períodos)	75,6±2,2	69,9±1,4	75,1±2,2	78,1±3,0	63,3±1,1
Taxa de Acerto Teste ELM (%)	71,0±5,5	61,9±3,7	75,9±7,6	61,0±4,7	62,1±3,9
Taxa de Acerto Teste ELM (%) (Melhores Períodos)	73,5±3,1	71,5±3,0	76,0±4,7	78,3±2,8	65,5±3,7

Ao final, analisando a Tabela 11 pode-se perceber que as maiores diferenças

absolutas entre médias de taxas de acerto ocorreram nas comparações entre a utilização de definição de períodos ideais para classificação ou a utilização padrão definida (utilizando todo o período de movimento de cada trilha e a banda alfa como filtro na frequência), como visto em (MACHADO, 2012). Logo, a partir dos resultados pode-se afirmar que essa etapa é imprescindível, e mostrou melhoria na média aritmética dos resultados superior a utilização de um ou outro modelo explorados.

6 CONCLUSÕES

A partir dos resultados obtidos com o desenvolvimento deste trabalho pode-se concluir que o método, utilizando os equipamentos propostos, possibilita a análise de diferenças dos sinais de EEG a partir de mobilização passiva com movimentos exercidos nos braços direito e esquerdo. Verifica-se laterização e a presença dos fenômenos de ERD e ERS para todos os indivíduos em estudo, estando eles não-sedados ou sedados.

A utilização dos filtros CSP mostrou-se uma grande ferramenta no auxílio para a visualização e a identificação de diferenças entre as classes do sinal quando utilizado uma touca com quantidade razoável de eletrodos e sinais com filtros digitais e tratamento de *outliers*, como no trabalho. Observa-se com maior facilidade a distinção entre as classes e os eletrodos referentes ao lado esquerdo e direito do cérebro quando utilizado o filtro em todos os indivíduos.

Não é possível afirmar que há distinção no tempo em que ocorre os fenômenos ou a frequência entre os pacientes sedados e o grupo de controle. É possível somente observar diferenças individuais considerando o total de indivíduos analisados e mesmo, ainda, entre seu respectivo grupo, confirmando assim uma grande dificuldade para análise de tais fenômenos e sinais.

As diferentes características extraídas analisadas em conjunto permitem verificar também a existência dos fenômenos e essa variabilidade no sinal. É possível verificar que as características com maior distinção entre as classes variam entre os sujeitos analisados, sendo que para alguns sujeitos determinadas características não possuem distinção entre os movimentos. A partir do estudo utilizando diferentes *features* foi possível perceber a diferença entre o uso de diferentes conjuntos de características para cada sujeito, obtendo um conjunto ideal para cada voluntário.

Não foi possível verificar diferenças estatísticas entre a utilização dos dois tipos de classificadores, mostrando resultados compatíveis entre os resultados para cada indivíduo. O classificador LDA mostrou-se de aplicação mais simples quando comparado ao ELM,

e mesmo mais simples obteve resultados melhores, em média, para um indivíduo, e sem diferenças para os outros quatro indivíduos. O classificador ELM mostrou-se de difícil ponderação na utilização de parâmetros para uma base com poucos movimentos, tendendo uma hora ao *underfitting* e outra ao *overfitting*, dependendo das separações aleatórias em treino e teste.

Quando analisadas as taxas de acerto dos classificadores, os resultados foram coerentes aos de outros trabalhos que utilizaram realização ativa ou imaginação de movimento (MACHADO, 2012)(CARRA, 2012) e também trabalhos que utilizaram imaginação de movimento e a touca *Emotiv* (SILVA, 2015). Quando analisados os resultados da base *BCI Competition* também foram encontrados resultados coerentes com os da área e da base (BCI Competition II, 2003).

6.1 Trabalhos Futuros

Durante o trabalho pode-se perceber a grande variabilidade do sinal entre sujeitos e até mesmo entre diferentes seções para cada sujeito, mostrando uma grande dificuldade na afirmação com significância estatística com um pequeno volume de dados. Sendo assim, propõe-se como trabalhos futuros o aumento da base gerada pelo trabalho (aumento no número de indivíduos e aumento na quantidade de movimentos por indivíduo), mesmo com as dificuldades encontradas tanto para repetição com o mesmo sujeito, quanto para disponibilidade de voluntários sedados em UTI.

Propõe-se também a utilização de equipamentos com maior resolução de canais (maior quantidade de canais por área do cérebro), principalmente na região do córtex motor, e que permitam a utilização em diferentes plataformas de aquisição.

Ainda, a partir do estudo dos fenômenos e características é proposto o desenvolvimento de um modelo em que não sejam utilizadas trilhas e momentos específicos de movimento, gerando um modelo de BCI assíncrono, que permite grandes avanços na área de BCI e na análise de sinais de EEG como um todo.

REFERÊNCIAS

- AKUSOK, A. *et al.* High-performance extreme learning machines: a complete toolbox for big data applications. *IEEE Access*, IEEE, v. 3, p. 1011–1025, 2015.
- ALZAHAB, N. A.; ALIMAM, H.; ALNAHHAS, M. Determining the optimal feature for two classes motor-imagery brain-computer interface (l/r-mi-bci) systems in different binary classifiers. *International Journal of Mechanical and Mechatronics Engineering IJMME-IJENS*, v. 19, n. 01, p. 132–150, 2019.
- AMABILE, R. A. *et al.* Remoção automática de artefatos em sinais de eeg usando local ssa. In: *XVII Congresso Brasileiro de Automática*. [S.l.: s.n.], 2008.
- BADCOCK, N. A. *et al.* Validation of the emotiv epoc eeg system for research quality auditory event-related potentials in children. *PeerJ*, PeerJ Inc., v. 3, p. e907, 2015.
- BCI Competition II. 2003. Dataset. Disponível em: <<http://www.bbci.de/competition/ii/>>. Acesso em: 16 set 2019.
- BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. *Neuroscience*. [S.l.]: Lippincott Williams & Wilkins, 2007. v. 2.
- BLANKERTZ, B. *et al.* Single-trial analysis and classification of erp components—a tutorial. *NeuroImage*, Elsevier, v. 56, n. 2, p. 814–825, 2011.
- BLANKERTZ, B. *et al.* Optimizing spatial filters for robust eeg single-trial analysis. *IEEE Signal processing magazine*, IEEE, v. 25, n. 1, p. 41–56, 2007.
- BLOKLAND, Y. *et al.* Decoding motor responses from the eeg during altered states of consciousness induced by propofol. *Journal of neural engineering*, IOP Publishing, v. 13, n. 2, p. 026014, 2016.
- CAO, J.; LIN, Z. Extreme learning machines on high dimensional and large data applications: a survey. *Mathematical Problems in Engineering*, Hindawi, v. 2015, 2015.
- CARRA, M. ***Desenvolvimento de uma interface cérebro computador baseada em ritmos sensório motores para controle de dispositivos***. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, Porto Alegre, mar. 2012.
- CRAIK, A.; HE, Y.; CONTRERAS-VIDAL, J. L. Deep learning for electroencephalogram (eeg) classification tasks: a review. *Journal of neural engineering*, IOP Publishing, v. 16, n. 3, p. 031001, 2019.
- DORNHEGE, G. **Toward brain-computer interfacing**. London: MIT, v. 1, 2007.
- DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern classification*. [S.l.]: John Wiley & Sons, 2012.
- DUVINAGE, M. *et al.* Performance of the emotiv epoc headset for p300-based applications. *Biomedical engineering online*, BioMed Central, v. 12, n. 1, p. 1–15, 2013.

- EKANAYAKE, H. P300 and emotiv epoc: Does emotiv epoc capture real eeg? *Web publication <http://neurofeedback.visaduma.info/emotivresearch.htm>*, v. 133, 2010.
- EMOTIV. *User Manual*. 2019. <<https://emotiv.gitbook.io/epoc-user-manual/>>. Acesso em 20/10.
- FUKUNAGA, K. *Introduction to statistical pattern recognition*. [S.l.]: Elsevier, 2013.
- GARAVAGLIA, L. *et al.* Pilot study of the cortical correlates and clinical effects of passive ankle mobilisation in children with upper motorneuron lesions. In: IEEE. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.], 2015. p. 6614–6617.
- GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. Brain–computer interfaces: A gentle introduction. In: *Brain-computer interfaces*. [S.l.]: Springer, 2009. p. 1–27.
- HONG, B. *et al.* Quantitative eeg-based brain-computer interface. *TONG, Shanbao. Quantitative EEG Analysis Methods and Applications*. MA: Artech House Publishers, p. 193–224, 2009.
- HOSSEINI, M.-P.; HOSSEINI, A.; AHI, K. A review on machine learning for eeg signal processing in bioengineering. *IEEE reviews in biomedical engineering*, IEEE, 2020.
- HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: theory and applications. *Neurocomputing*, Elsevier, v. 70, n. 1-3, p. 489–501, 2006.
- JAMALOO, F.; MIKAEILI, M. Discriminative common spatial pattern sub-bands weighting based on distinction sensitive learning vector quantization method in motor imagery based brain-computer interface. *Journal of medical signals and sensors*, Wolters Kluwer–Medknow Publications, v. 5, n. 3, p. 156, 2015.
- JUNIOR, A. P. N. *et al.* Validity, reliability and applicability of portuguese versions of sedation-agitation scales among critically ill patients. *Sao Paulo Medical Journal*, SciELO Brasil, v. 126, n. 4, p. 215–219, 2008.
- LIANG, N.-Y. *et al.* Classification of mental tasks from eeg signals using extreme learning machine. *International journal of neural systems*, World Scientific, v. 16, n. 01, p. 29–38, 2006.
- LIU, Y. *et al.* Implementation of ssvep based bci with emotiv epoc. In: IEEE. *2012 IEEE International Conference on Virtual Environments Human-Computer Interfaces and Measurement Systems (VECIMS) Proceedings*. [S.l.], 2012. p. 34–37.
- LOTTE, F. *et al.* A review of classification algorithms for eeg-based brain–computer interfaces: a 10 year update. *Journal of neural engineering*, IOP Publishing, v. 15, n. 3, p. 031005, 2018.
- MACHADO, J. ***Pré-processamento, extração de características e classificação offline de sinais eletroencefalográficos para uso em sistemas BCI***. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, Porto Alegre, nov. 2012.
- MACHADO, J.; BALBINOT, A. Executed movement using eeg signals through a naive bayes classifier. *Micromachines*, Multidisciplinary Digital Publishing Institute, v. 5, n. 4, p. 1082–1105, 2014.

- MEZIANI, A. *et al.* A lasso quantile periodogram based feature extraction for eeg-based motor imagery. *Journal of Neuroscience Methods*, Elsevier, v. 328, p. 108434, 2019.
- MOHAMMADPOUR, M.; GHORBANIAN, M.; MOZAFFARI, S. Comparison of eeg signal features and ensemble learning methods for motor imagery classification. In: IEEE. *2016 Eighth International Conference on Information and Knowledge Technology (IKT)*. [S.l.], 2016. p. 288–292.
- MÜLLER, G. *et al.* Event-related beta eeg changes during wrist movements induced by functional electrical stimulation of forearm muscles in man. *Neuroscience letters*, Elsevier, v. 340, n. 2, p. 143–147, 2003.
- MÜLLER-PUTZ, G. R. *et al.* Event-related beta eeg-changes during passive and attempted foot movements in paraplegic patients. *Brain research*, Elsevier, v. 1137, p. 84–91, 2007.
- MURPHY, M. *et al.* Propofol anesthesia and sleep: a high-density eeg study. *Sleep*, Oxford University Press, v. 34, n. 3, p. 283–291, 2011.
- NAKAYASHIKI, K. *et al.* Modulation of event-related desynchronization during kinematic and kinetic hand movements. *Journal of neuroengineering and rehabilitation*, BioMed Central, v. 11, n. 1, p. 90, 2014.
- NAM, C. S. *et al.* Movement imagery-related lateralization of event-related (de) synchronization (erd/ers): motor-imagery duration effects. *Clinical Neurophysiology*, Elsevier, v. 122, n. 3, p. 567–577, 2011.
- ORTEGA, J. *et al.* Classification of motor imagery tasks for bci with multiresolution analysis and multiobjective feature selection. *Biomedical engineering online*, BioMed Central, v. 15, n. 1, p. 73, 2016.
- PFURTSCHELLER, G.; SILVA, F. L. D. Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical neurophysiology*, Elsevier, v. 110, n. 11, p. 1842–1857, 1999.
- PITTACCIO, S. *et al.* Can passive mobilization provide clinically-relevant brain stimulation? a pilot eeg and nirs study on healthy subjects. In: IEEE. *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.], 2013. p. 3547–3550.
- PITTACCIO, S. *et al.* Primary sensory and motor cortex activities during voluntary and passive ankle mobilization by the shade orthosis. *Human brain mapping*, Wiley Online Library, v. 32, n. 1, p. 60–70, 2011.
- PUTZ, R.; PABST, R. *Sobotta-Atlas of Human Anatomy: Head, Neck, Upper Limb, Thorax, Abdomen, Pelvis, Lower Limb; Two-volume set*. [S.l.: s.n.], 2006.
- QIU, J. *et al.* A survey of machine learning for big data processing. *EURASIP Journal on Advances in Signal Processing*, Springer, v. 2016, n. 1, p. 67, 2016.
- QIU, S. *et al.* Event-related beta eeg changes during active, passive movement and functional electrical stimulation of the lower limb. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 24, n. 2, p. 283–290, 2015.

- RAMOS, A. C. *et al.* Ensemble of classifiers applied to motor imagery task classification for bci applications. In: IEEE. *2017 International Joint Conference on Neural Networks (IJCNN)*. [S.l.], 2017. p. 2995–3002.
- RAMOSER, H.; MULLER-GERKING, J.; PFURTSCHELLER, G. Optimal spatial filtering of single trial eeg during imagined hand movement. *IEEE transactions on rehabilitation engineering*, IEEE, v. 8, n. 4, p. 441–446, 2000.
- RIMBERT, S. *et al.* Motana: study protocol to investigate motor cerebral activity during a propofol sedation. *Trials*, Springer, v. 20, n. 1, p. 1–9, 2019.
- SANEI, S.; CHAMBERS, J. A. Eeg signal processing. Wiley Online Library, 2007.
- SHI, L.-C.; JIAO, Y.-Y.; LU, B.-L. Differential entropy feature for eeg-based vigilance estimation. In: IEEE. *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.], 2013. p. 6627–6630.
- SILVA, V. S. da. *Classificação de Movimentos Imaginários através de redes Bayesianas em Sistema baseado em touca Emotiv*. 2015. TCC.
- STOICA, P.; MOSES, R. L. *et al.* Spectral analysis of signals. Pearson Prentice Hall Upper Saddle River, NJ, 2005.
- TONG, S.; THAKOR, N. V. **Quantitative EEG analysis methods and clinical applications**. Boston: Artech House, 2009.
- TORTORA, G. J.; DERRICKSON, B. *Corpo Humano-: Fundamentos de Anatomia e Fisiologia*. [S.l.]: Artmed Editora, 2016.
- TOWE, B. C. Bioelectricity and its measurement: **Biomedical engineering and design handbook**. New York: McGraw-Hill, p. p.481–528, 2009.
- WELCH, P. The use of fast fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms. *IEEE Transactions on audio and electroacoustics*, IEEE, v. 15, n. 2, p. 70–73, 1967.
- WOLPAW, J. R.; BOULAY, C. B. Brain signals for brain–computer interfaces. In: *Brain-computer interfaces*. [S.l.]: Springer, 2009. p. 29–46.
- ZHANG, Y. *et al.* Multi-kernel extreme learning machine for eeg classification in brain-computer interfaces. *Expert Systems with Applications*, Elsevier, v. 96, p. 302–310, 2018.

ANEXO A – CÓDIGOS DESENVOLVIDOS NO *SOFTWARE LABVIEW*

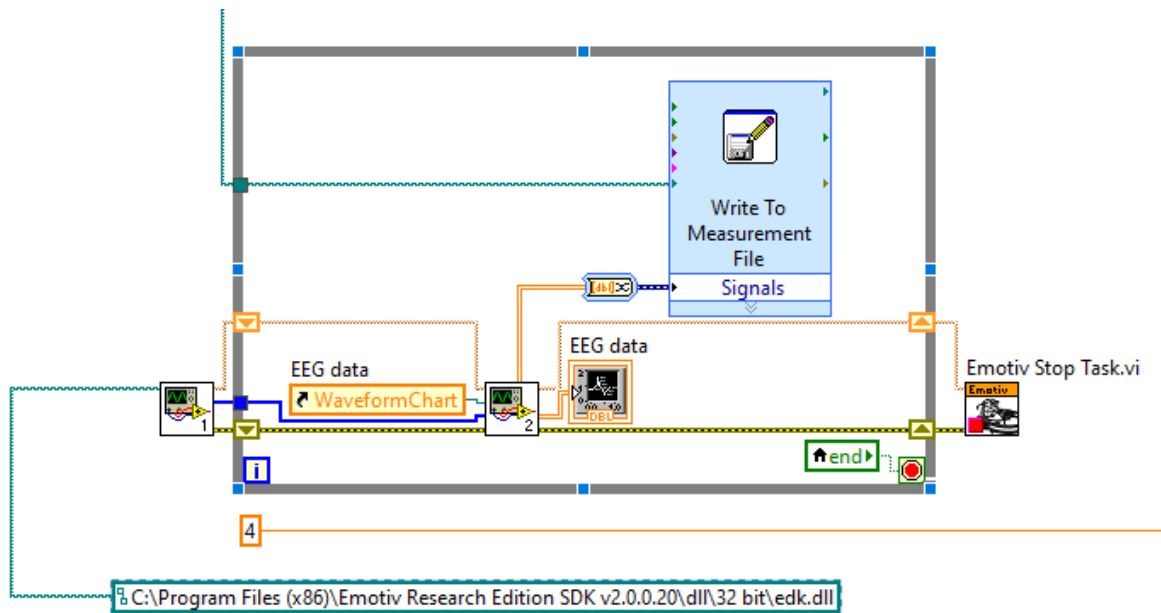


Figura 44 – Código desenvolvido de aquisição do Sinal da Touca *Emotiv*.

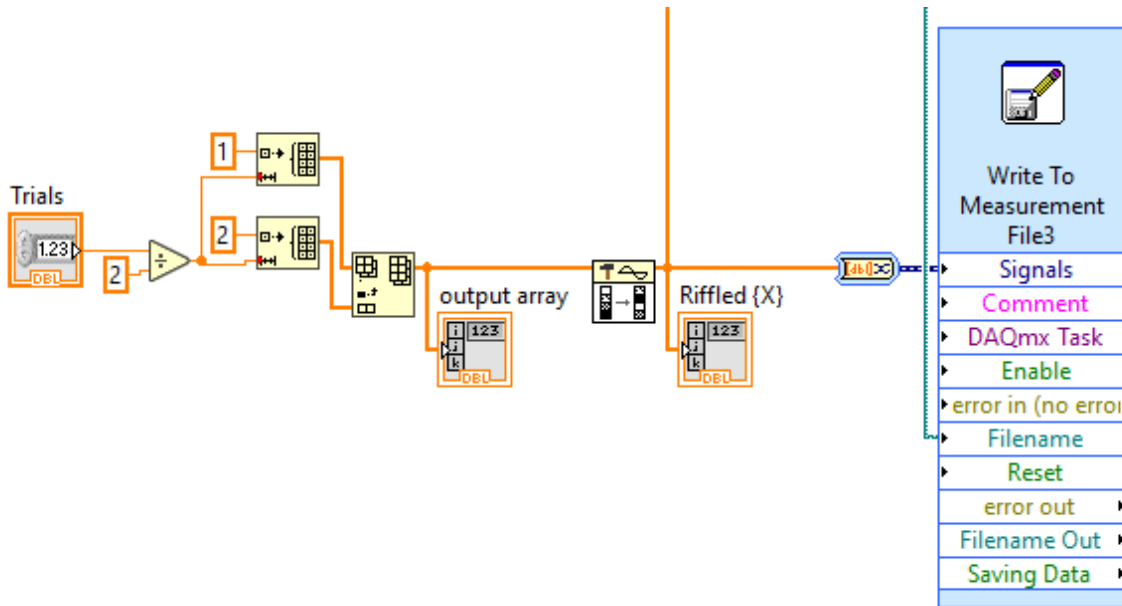


Figura 45 – Código criado para geração de Estímulos Aleatorizados Divididos nas Classes.

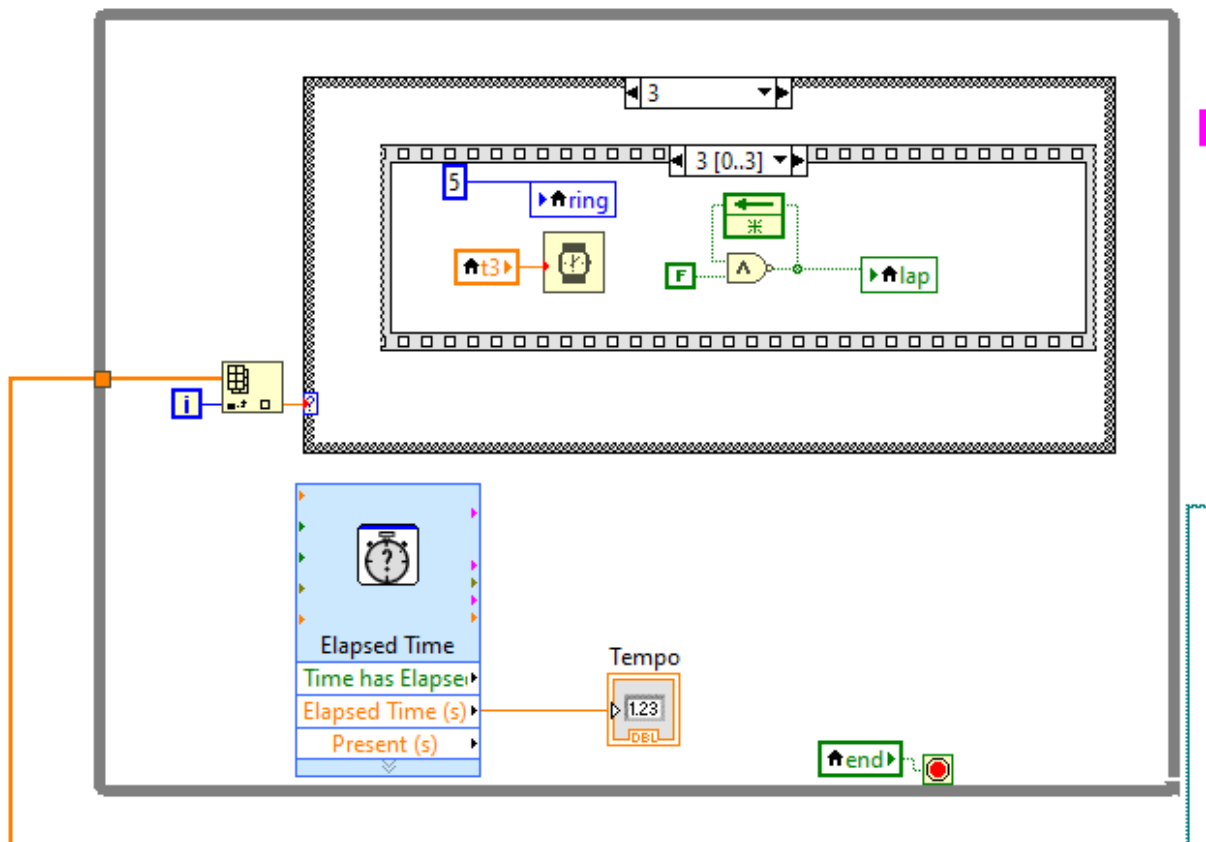


Figura 46 – Código de Sincronização dos tempos de apresentação do estímulo visual para realização do movimento ao fisioterapeuta.

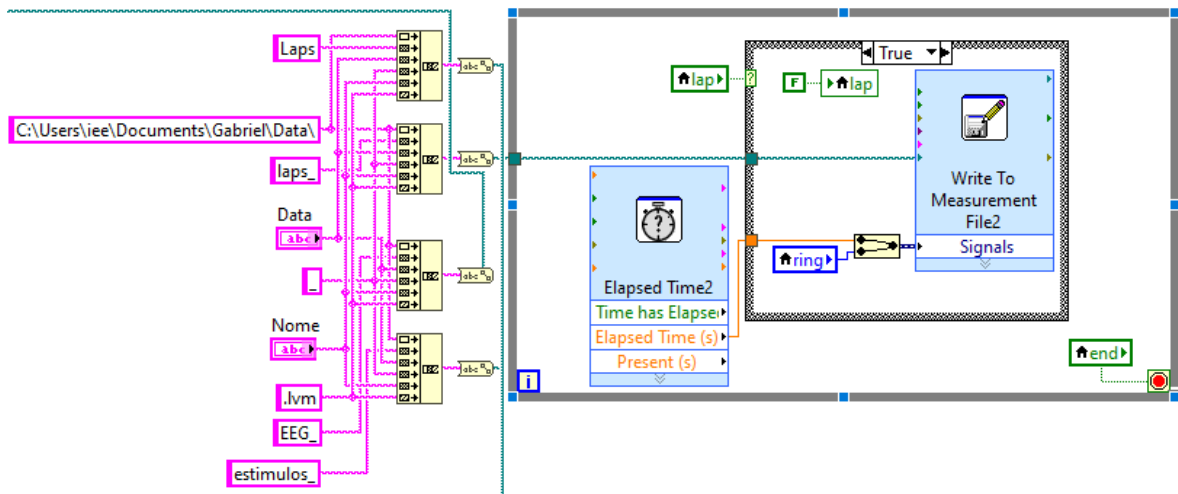


Figura 47 – Código criado para Salvar dados das aquisições.

ANEXO B – FORMA DE ONDA DE ATRIBUTOS PARA SUJEITOS E PACIENTES




Figura 48 – Energia média Relativa dos canais FC5 e FC6 para o Sujeito 2.




Figura 49 – Energia média Relativa dos canais FC5 e FC6 para o Paciente 1.




Figura 50 – Energia média Relativa dos canais FC5 e FC6 para o Paciente 2.




Figura 51 – Energia média Relativa dos canais CSP1 e CSP2 para o Sujeito 2.




Figura 52 – Energia média Relativa dos canais CSP1 e CSP2 para o Paciente 1.




Figura 53 – Energia média Relativa dos canais CSP1 e CSP2 para o Paciente 2.




Figura 54 – Índice de Laterização no tempo entre os canais CSP1 e CSP2 para o Sujeito 2.

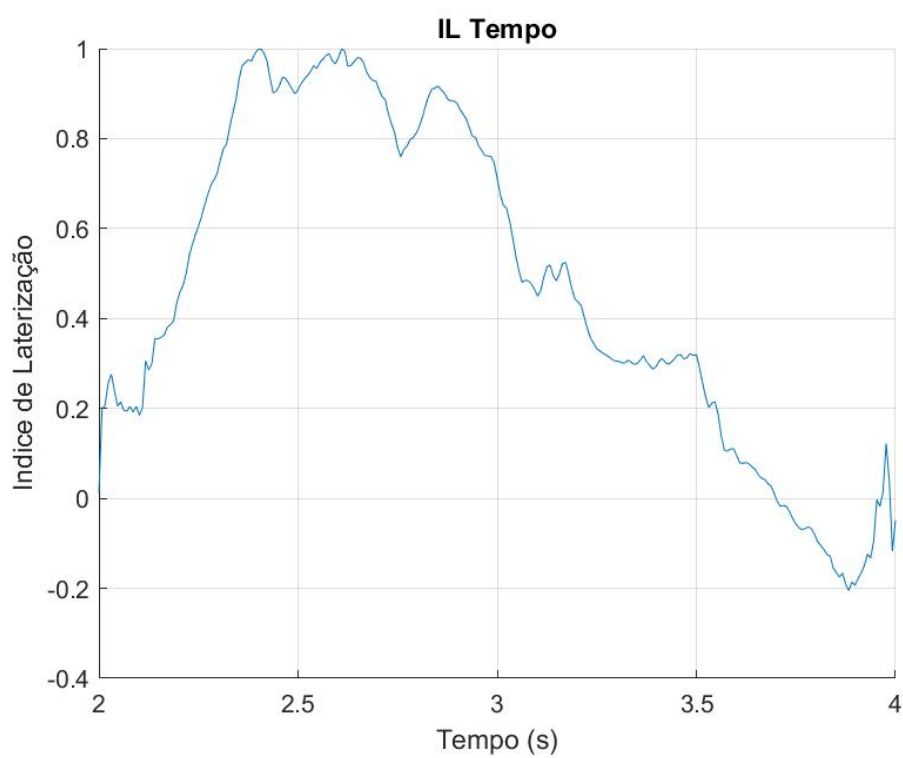


Figura 55 – Índice de Laterização no tempo entre os canais CSP1 e CSP2 para o Paciente 1.

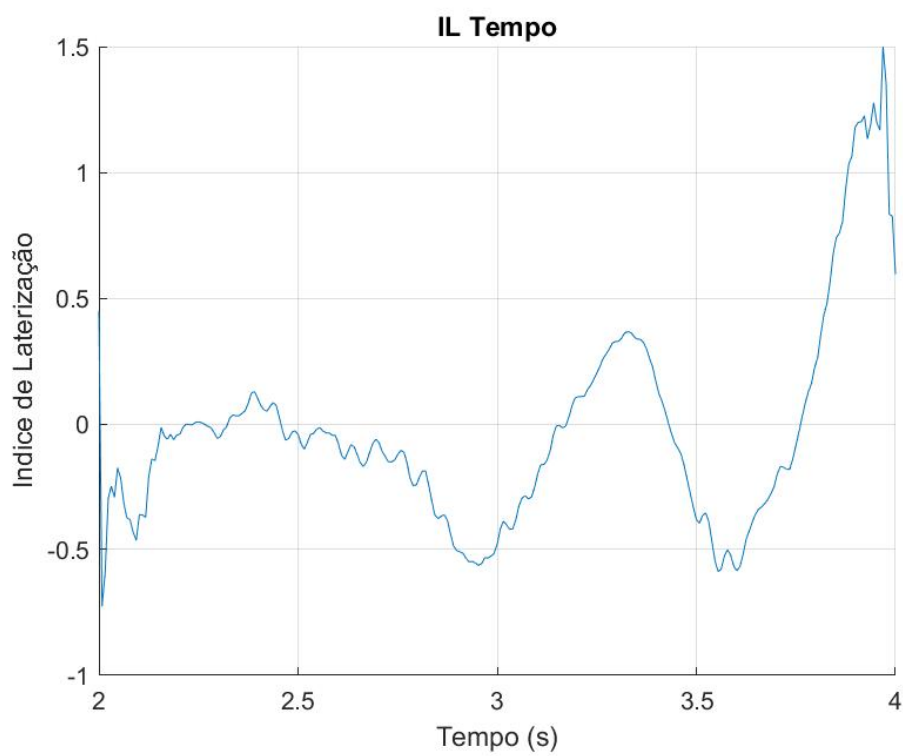


Figura 56 – Índice de Laterização no tempo entre os canais CSP1 e CSP2 para o Paciente 2.




Figura 57 – Índice de Laterização na frequência entre os canais CSP1 e CSP2 para o Sujeito 2.




Figura 58 – Índice de Laterização na frequência entre os canais CSP1 e CSP2 para o Paciente 1.




Figura 59 – Índice de Laterização na frequência entre os canais CSP1 e CSP2 para o Paciente 2.




Figura 60 – Intervalos para características do Sujeito 2.




Figura 61 – Intervalos para características do Paciente 1.




Figura 62 – Intervalos para características do Paciente 2.