

**UNIVERSIDADE DE CAXIAS DO SUL
ÁREA DO CONHECIMENTO DE EXATAS E ENGENHARIAS**

MATHEUS GONÇALVES MUSSI

**CLASSIFICAÇÃO DE BIOSINAIS DE MOTOR IMAGERY COLETADOS POR EEG
PROCESSADOS EM TEMPO-FREQUÊNCIA COM REDES NEURAIAS
CONVOLUCIONAIS**

**CAXIAS DO SUL
2018**

MATHEUS GONÇALVES MUSSI

**CLASSIFICAÇÃO DE BIOSINAIS DE MOTOR IMAGERY COLETADOS POR EEG
PROCESSADOS EM TEMPO-FREQUÊNCIA COM REDES NEURAIAS
CONVOLUCIONAIS**

Trabalho de Conclusão apresentado à Área de Ciências Exatas e Engenharias da Universidade de Caxias do Sul como requisito para obtenção do título de Engenheiro de Controle e Automação.

Orientador:
Prof^a. Dra. Marilda Machado Spindola

**CAXIAS DO SUL
2018**

MATHEUS GONÇALVES MUSSI

**CLASSIFICAÇÃO DE BIOSINAIS DE MOTOR IMAGERY COLETADOS POR EEG
PROCESSADOS EM TEMPO-FRÉQUÊNCIA COM REDES NEURAIAS
CONVOLUCIONAIS**

Trabalho de Conclusão apresentado à Área de Ciências Exatas e Engenharias da Universidade de Caxias do Sul como requisito para obtenção do título de Engenheiro de Controle e Automação.

Orientador:
Prof^a. Dra. Marilda Machado Spindola

Aprovado em ____/____/____

Banca Examinadora

Prof^a. Dra. Marilda Machado Spindola (orientador)
Universidade de Caxias do Sul - UCS

Prof. Dr. André Gustavo Adami
Universidade de Caxias do Sul - UCS

Prof. Me. Patric Janner Marques
Universidade de Caxias do Sul - UCS

RESUMO

Pessoas que sofrem de traumas e patologias como o derrame e a paralisia ou que possuem membros amputados, apesar de terem limitações motoras, possuem capacidade de comando cerebral que pode ser utilizada para assisti-las nas suas atividades diárias. Para estudar essa possibilidade, sinais cerebrais de participantes voluntários são coletados em um experimento planejado com equipamento de Eletroencefalografia (EEG). São realizados todos os processos de orientação e aplicação dos eletrodos no escalpo dos participantes. Os bio-sinais gerados de *Motor Imagery* (MI) são coletados em baterias de testes, realizadas em dias distintos, que são armazenados em uma base de dados. Esta base de dados é processada e convertida, pela Transformada de Wavelet Contínua (CWT) de Morlet, em imagens. As frequências theta (4 a 8Hz), alfa (8 a 13Hz) e beta (14 a 30) são bandas significativas para o MI. Portanto, as imagens são tratadas para conterem informações de 4 a 35Hz. São estudados os efeitos de dois tamanhos de janela do sinal, com 250 e com 750 amostras. Esta base de imagens é tratada e nele é aplicado uma Rede Neural Convolutiva (CNN) com camadas convolucionais unidimensionais de frequência para classificação. Por fim, quatro métodos de avaliação pautam os resultados: o método de *Leave-One-Subject-Out Cross Validation* (LOSOCV) é o método que avalia a transferência de características de indivíduo para indivíduo, o de *Holdout* testa os padrões de bio-sinais em toda a base, o teste individual examina a capacidade do modelo de adaptar-se aos dados de cada indivíduo, e a comparação de ensaios de MI com ensaios motores afere se existe alguma similaridade entre os bio-sinais de MI e os bio-sinais gerados pelo cérebro durante o movimento. Pode-se verificar que a utilização da janela de 3s para os dados com *baseline* permitiu um aumento relativo de acurácia de 2.3% no método de LOSOCV, 9.3% no teste individual e 13.8% no método de *Holdout*.

Palavras-chave: Motor Imagery. Transformada de Wavelet Contínua. Eletroencefalografia. Rede Neural Convolutiva.

ABSTRACT

People that suffer from traumas and pathologies like stroke and paralysis or that have amputated limbs, although having motor limitations, possess capacity to generate brain commands which may assist them on daily activities. In order to study this possibility, brain signals from volunteers are collected on a planned experiment with Electroencephalography (EEG). Participants are instructed and electrodes are applied to their scalp. Motor Imagery (MI) biosignals are collected in test sets, applied at different days, and stored in a small dataset. This dataset is processed and converted, through the Continuous Wavelet Transform (CWT) with Morlet, to images. Theta (4 to 8Hz), alpha (8 to 13Hz) and beta (14 to 30Hz) are significant frequency bands for MI. Therefore, images are treated so they contain information from 4 to 35Hz. The effects of two window sizes are studied, with 250 samples and 750 samples. The Images dataset is processed and a Convolutional Neural Network (CNN) is applied with 1-D frequency-wise convolutional layers for classification. Lastly four evaluation methodologies rule the results: the Leave-One-Subject-Out Cross Validation (LOSOCV) measures the individual-to-individual characteristics transference, the Holdout method tests the patterns in biosignals within the whole dataset, the individual test examines the model capacity to fitting for individual data and the comparison between MI sessions and motor sessions assesses if there is any similarity between MI biosignals and biosignals generated by the brain during movement. It is possible to verify that the application of a 3s window at the baseline data allows a relative accuracy increase of 2.3% using LOSOCV method, 9.3% using the individual test and 13.8% using the Holdout method.

Keywords: Motor Imagery. Continuous Wavelet Transform. Electroencephalography. Convolutional Neural Network.

*A Deus, pela inspiração e fortalecimento.
A minha família e aos amigos, pelo apoio e compreensão.*

AGRADECIMENTOS

Gostaria de agradecer às pessoas que colaboraram com o trabalho, seja de maneira mais singela ou ostensiva. Primeiramente à minha orientadora, Prof^a. Marilda Spindola, e ao Prof. Alexandre Mesquita pela tutela, colaboração com o meu desenvolvimento acadêmico e por todo o conhecimento compartilhado ao longo deste ano. Ao Luciano Salerno, ao Nicolau José Mussi e ao Felipe Pizzetta pelo seu tempo e disposição para contribuir com o projeto. Igualmente à banca avaliadora, pelo empenho e tempo dedicado à correção deste trabalho.

Aos colegas de curso que acompanharam esta trajetória de perto, em especial Gustavo de Camargo e Guilherme Viganó, e aos meus amigos, que dedicaram algumas horas das suas rotinas tribuladas para ler e dar *feedbacks* valiosos. Também aos professores Lucas Furstenau de Oliveira, por ter facilitado o entendimento sobre algumas questões do cérebro, Angelo Zerbetto, pela introdução às Redes Neurais, e André Gustavo Adami, pelos ensinamentos sobre reconhecimento de padrões.

Além disso, às pessoas que participaram de forma indireta, mas essencial para o êxito deste, Márcia Maria Gonçalves Mussi, Nicole Gonçalves Mussi e Douglas Jovenil Castilhos dos Santos. E por fim, a todos os demais familiares, amigos e colegas que mostraram interesse pela dissertação nas rodas de conversa ou nas redes sociais, que me apoiaram e me estimularam a pesquisar mais a fundo.

LISTA DE FIGURAS

1	Lobos cerebrais	13
2	Principais regiões primárias do córtex cerebral	14
3	Córtex Sensorial Primário	14
4	Mapa sensorial do córtex sensorial e representação no <i>homulucus</i>	15
5	Mapa muscular do córtex motor e representação no <i>homulucus</i>	16
6	Equipamentos de EEG	19
7	Células Nervosas	21
8	Célula Piramidal e seus componentes	22
9	Sinal ERP medido por cada eletrodo	22
10	Representação do componente LRP	23
11	Posicionamento dos eletrodos ao longo da linha anterior-posterior (média)	25
12	Posicionamento dos eletrodos ao longo da linha central	25
13	Posicionamento dos eletrodos ao longo da linha lateral (temporal)	26
14	Planificação da posição dos eletrodos no sistema internacional 10-20	27
15	Planificação da posição dos eletrodos no sistema internacional 10-10	28
16	Circuito equivalente de ligação eletrodo-derme	29
17	MI Cinestésico vs. MI Visual	30
18	Representação de um neurônio da RN	35
19	Representação de um neurônios em um perceptron de múltiplas camadas	36
20	Fluxo de sinal durante <i>backpropagation</i> .	37
21	<i>Local receptive fields</i>	38
22	Camada de subamostragem	39
23	Caixas de tempo-frequência da transformada Wavelet	41
24	Programa OpenViBE	47
25	Flexão de Pulso	48
26	Posicionamento do Participante	49
27	Linha do tempo de um estímulo	50
28	Estrutura de uma bateria de testes	50
29	Fluxograma de algoritmo de geração de imagens	51
30	Matrizes Tempo-Frequência Geradas	52
31	Arquitetura da Rede Neural	53
32	Procedimento Leave-One-Subject-Out Cross-Validation	54
33	Fluxograma dos resultados gerados	55
34	Acurácia entre janelamento de 1s e 3s para método LOSOCV.	57
35	Acurácia entre janelamento de 1s e 3s para método de Análise Individual.	59
36	Acurácia entre janelamento de 1s e 3s para método de Holdout.	60
37	Acurácia entre janelamento de 1s e 3s para classificação dos Ensaio Motores.	61

LISTA DE SIGLAS

AVC	Acidente Vascular Cerebral
BCI	<i>Brain-Computer Interface</i>
CNN	<i>Convolutional Neural Networks</i>
CSD	<i>Current Source Density</i>
EEG	Eletroencefalografia
ERP	<i>Event-Related Potential</i>
f_s	Frequência de Amostragem
fMRI	<i>functional Magnetic Resonance Imaging</i>
LFP	<i>Local Field Potential</i>
LOSOCV	<i>Leave-One-Subject-Out Cross-Validation</i>
LRP	<i>Lateralized Readiness Potential</i>
MEP	<i>Motor Evoked Potential</i>
MI	<i>Motor Imagery</i>
M1	Córtex Motor Primário
OMS	Organização Mundial da Saúde
PC	Paralisia Cerebral
PET	<i>Positron Emission Tomography</i>
PNE	Portador de Necessidades Especiais
PSP	Potencial Pós-Sináptico
ReLU	<i>Rectified Linear Unit</i>
RN	Rede Neural
SPS	<i>Samples per Second</i>
STFT	<i>Short Time Fourier Transform</i>
SVM	<i>Support Vector Machines</i>
S1	Córtex Sensorial Primário
TA	Tecnologia Assistiva
V1	Córtex Visual Primário

SUMÁRIO

1	INTRODUÇÃO	10
1.1	OBJETIVOS GERAIS	11
1.2	OBJETIVOS ESPECÍFICOS	11
1.3	ESCOPO E RESTRIÇÕES	11
1.4	APRESENTAÇÃO	12
2	REVISÃO BIBLIOGRÁFICA	13
2.1	CÓRTEX CEREBRAL	13
2.2	BIOSSINAIS	17
2.2.1	Sinais Cerebrais	18
2.3	ELETOENCEFALOGRAFIA	24
2.4	MOTOR IMAGERY	29
2.5	REDES NEURAIS	32
2.6	TRANSFORMADA DE WAVELET	40
2.7	FILTROS	41
2.8	ESTADO DA ARTE	42
3	MATERIAIS E MÉTODOS	44
3.1	MATERIAIS	44
3.1.1	Participantes	44
3.1.2	OpenBCI: Sistema de EEG	45
3.1.3	Sistema de Sincronização de Estímulos e Gravação de dados	46
3.2	METODOLOGIA	48
3.2.1	Preparação para coleta de dados	48
3.2.2	Coleta dos sinais e paradigma do MI	49
3.2.3	Pré-Processamento	51
3.2.4	Arquitetura da Rede Neural Convolutacional	53
3.2.5	Métodos de Avaliação e figuras de mérito	53
4	RESULTADOS	55
4.1	LEAVE-ONE-SUBJECT-OUT CROSS-VALIDATION	56
4.2	ANÁLISE INDIVIDUAL	58
4.3	HOLDOUT	59
4.4	VALIDAÇÃO ENSAIOS MOTORES	60
4.5	DISCUSSÃO DOS RESULTADOS	61
5	CONCLUSÃO	64
	REFERÊNCIAS	66
	APÊNDICE A-	72
	ANEXO A-	77
	ANEXO B-	78

1 INTRODUÇÃO

Segundo a Organização Mundial da Saúde (OMS), o número de Portadores de Necessidades Especiais (PNE) no mundo ultrapassa a marca de 1 bilhão de pessoas e tende a atingir 38% da população até 2050 (WORLD REPORT ON DISABILITY, 2011, p. 35-36). Acrescente-se a essa taxa a preocupação de que a incapacitação representa um problema correlato com a pobreza: a ocorrência deste pode aumentar o risco daquele e vice-versa, devido à dificuldade motora que assola a maioria dos necessitados.

No relatório técnico World Report on Disability (2011, p. 38), mostra-se que pessoas que sofrem com o Acidente Vascular Cerebral (AVC) têm a maior quantidade de limitações no cotidiano fora do ambiente clínico. Isso se dá principalmente pela alta perda de motricidade pós-derrame. Existem também os casos de paralisia decorrentes dos remanescentes casos de Pós-Polio (HOWARD, 2005) — causados pelo vírus da Poliomyelite —, as crianças acometidas pela Paralisia Cerebral (PC) ou *Spina Bifida* e os inúmeros amputados. Em todos estes cenários pode haver dificuldades com o controle da postura, com a movimentação dos membros e com a destreza dos membros superiores.

Paralelamente houve a emergência de sistemas *Brain-Computer Interface* (BCI). É uma engenhosidade que se desenvolve desde a publicação de Vidal (1973), onde se levantava a hipótese de que os sinais cerebrais não seriam meramente ruídos randômicos, porém uma "altamente complexa, mas significativa mistura (de sinais elétricos) que reflete os eventos neuronais ocultos". A partir de então, inúmeros sistemas BCI foram propostos para as mais diversas aplicações.

Dentre as aplicações, existem as que se apresentam como Tecnologia Assistiva (TA). Apesar de todas as barreiras motoras, sabe-se que, nas patologias que não acarretam deficiência intelectual, o efeito no cérebro pode tanto ser uma degeneração pós-traumática como ser inexistente, não acarretando em nenhuma morte celular (WU et al., 2014). Neste segundo caso, as funções cognitivas são preservadas e é possível estabelecer uma conexão entre o estímulo cerebral associado ao movimento e uma órtese motora que possa ser utilizada como instrumento auxiliar para pessoas desabilitadas ou amputadas. Essa possibilidade faz com que o potencial cortical constitua uma das melhores chances para a reconquista da independência motora pós-traumática. Pesquisas como as de Munzerta, Loreya e Zentgrafa (2009) e de Lotze e Halsband (2006) têm revisado os trabalhos que demonstram isso.

A exemplo de trabalhos que buscam implementar os sistemas BCI para auxiliar PNE, pode-se citar dois artigos: Horki et al. (2011) e Xu et al. (2011). O primeiro utiliza um sistema híbrido de eletroencefalografia (EEG) com *Motor Imagery* (MI) para movimentar uma órtese com 2 graus de liberdade e garras. O objetivo final das pesquisas subsequentes é possibilitar o controle de neuropróteses de cotovelo e mão. A pesquisa de Xu et al. (2011) executa um sistema integrando MI a um robô para auxiliar na reabilitação de pacientes após sofrerem o AVC, para explorar combinadamente a motivação e a atenção durante a recuperação.

Neste trabalho apresenta-se uma metodologia instrumental com modelagem matemática robusta para identificação de padrões de sinais cerebrais em áreas de comando motor utilizando técnicas de MI que poderão servir à TA para diferentes propostas de acionamento. Com técnica de Eletroencefalografia, processamento de sinais em tempo-frequência e Redes Neurais (RN) serão discutidos os processos de aquisição, de tratamento e de treinamento dos componentes do sistema.

1.1 OBJETIVOS GERAIS

Implementação de um sistema de condicionamento e reconhecimento de sinais, gerados por comandos cerebrais pela técnica de *Motor Imagery* (MI) e coletados por EEG, usando Redes Neurais para classificação a fim de obter sinais de comando para aplicações diversas, incluindo o movimento de órteses para membros superiores.

1.2 OBJETIVOS ESPECÍFICOS

As ações planejadas para o cumprimento do Objetivo Geral são:

- a- Preparar um modelo experimental para aquisição de biossinais evocados por MI referente a movimento de membros superiores;
- b- Aplicar a plataforma OpenBCI[®] na coleta de biossinais usando a técnica de MI, baseando-se no modelo experimental proposto;
- c- Criar uma Base de Dados composto por sinais captados por equipamento de eletroencefalografia relativos ao MI de membros superiores, evocados durante o experimento proposto;
- d- Aplicar técnicas de pós-processamento nos biossinais da base de dados com o intuito de treinar uma RN;
- e- Comparar técnicas de processamento de sinais de MI com redes neurais identificando a que apresentar melhor performance para o sistema proposto;

1.3 ESCOPO E RESTRIÇÕES

O objeto final que é apresentado na conclusão deste trabalho é um modelo experimental, de caráter prototipal, sem intuito de comercialização. Não são desenvolvidos instrumentos de EEG, sendo usados sistemas disponíveis no mercado. A programação da RN não faz parte do foco do trabalho, embora algumas funções utilizadas tenham sido modificadas. O funcionamento do sistema é garantido apenas para indivíduos lateralizados – i.e. que são destros, uma

vez que canhotos têm mais chance de interação entre hemisférios do cérebro, gerando "inconsistências" no sinal (CHERBUIN; BRINKMAN, 2006).

1.4 APRESENTAÇÃO

Este trabalho tem a seguinte distribuição, em capítulos:

O Capítulo 2 apresenta o referencial teórico, onde serão abordados temas básicos para desenvolver o conhecimento necessário que se aplica na captação do sinal de EEG ao classificador. Serão expostos conceitos sobre biosinais, sinais cerebrais, estruturas do córtex; eletroencefalografia, redes neurais, transformada de Wavelet, filtros e redes neurais convolucionais.

O Capítulo 3, Materiais e Métodos, discorre sobre os equipamentos utilizados, os voluntários envolvidos e o experimento realizado no projeto. Depois relata-se das metodologias utilizadas para avaliar e classificar os sinais para atingir os objetivos propostos.

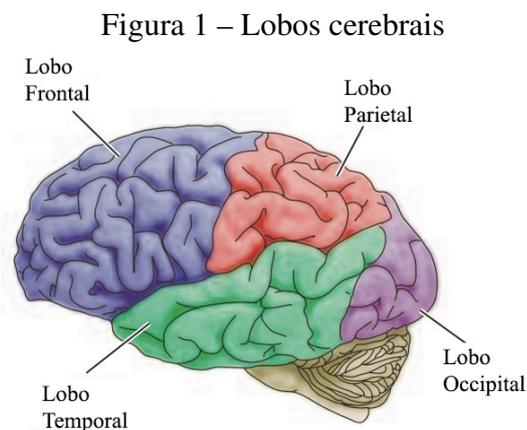
O Capítulo 4 trata dos resultados obtidos, apresentando-os e discutindo sobre eles, e o último capítulo trata as conclusões e as referências utilizadas na construção deste trabalho.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo seguirá da seguinte maneira: começa-se apresentando as partes principais do cérebro, explana-se conceitos básicos dos bioassinais, fala-se da técnica de Eletroencefalografia – explorando onde poderão ser captados os melhores sinais para o objetivo deste trabalho –, se revisita o sinal de *Motor Imagery* e por fim se discorre sobre a teoria de RN, transformada de Wavelet e Filtros.

2.1 CÓRTEX CEREBRAL

O córtex é a parte mais externa do cérebro, onde se encontram as células neurais piramidais, (abordadas em mais detalhes na seção seguinte). Os hemisférios do cérebro são formados por camadas contínuas de córtex flectidas. Há os giros, que são cristas de tecido cortical, e os sulcos, que são as fendas entre os giros. As fendas mais proeminentes podem ser chamadas de fissuras. Muito embora o padrão entre giros e sulcos seja diferente para cada indivíduo, algumas ‘marcações’ são consistentes, delimitando os quatro lobos cerebrais (Figura 1).



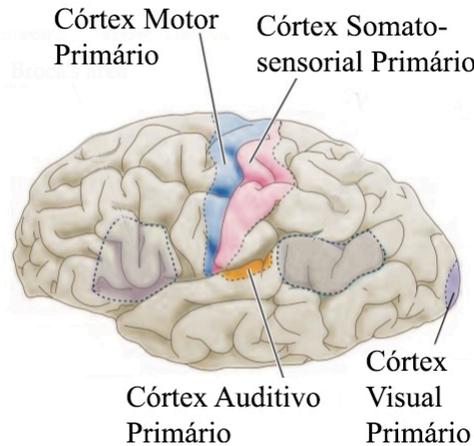
Fonte: Adaptado de [Purves et al. \(2004\)](#)

As denominações de cada lobo advêm do nome que recebem os ossos cranianos que os cobrem: Frontal, Temporal, Parietal e Occipital. Conforme a tabela encontrada em [Hooi et al. \(2018\)](#), p. 489, o lobo Frontal é responsável pelo planejamento, tomada de decisão, resolução de problemas, movimentos e emoções. O lobo Occipital se envolve com o processamento visual. O Parietal reconhece, percebe os estímulos, auxilia na movimentação e orientação. O lobo temporal esquerdo é envolvido em processamento de memórias verbais e o lobo temporal direito das não-verbais.

Os sulcos centrais dividem o lobo frontal do parietal e os giros imediatamente anteriores e posteriores a esta fenda, além de mais proeminentes, têm função significativa, sendo a saliência frontal responsável pelo controle do movimento, chamada de córtex motor primário, e a parietal responsável pelo sensorial corporal, chamada de córtex sensorial primário (S1)

(vide Figura 2). Essas regiões e o córtex visual primário (V1) são receptoras de informações diretamente do *tálamo* – localizado na região central do cérebro, um receptor direto de informação do sistema nervoso central –, mais diretamente relacionadas ao sensoriamento dos órgãos periféricos do corpo (PURVES et al., 2004).

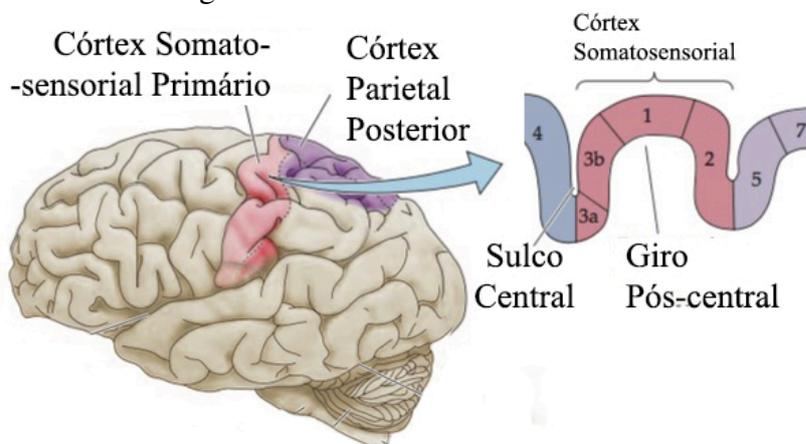
Figura 2 – Principais regiões primárias do córtex cerebral



Fonte: Adaptado de Purves et al. (2004)

Estudos indicam que dentro do S1 existem quatro áreas principais, chamadas de *áreas de Brodmann* (Figura 3). A área 3b e a 1 respondem a estímulos cutâneos, a 3a responde a estímulos de proprioceptores – unidades de sensoriamento indicadoras de posição relativa própria e emprego de esforço – e a 2 a estímulos cutâneos e proprioceptores. Os receptores do 3b, por exemplo, geram sinal quando há estímulo de um único dedo; as áreas 1 e 2 sinalizam quando há estímulo em múltiplos dedos e a região 2 se ativa para estímulos tácteis mais complexos (como uma forma geométrica).

Figura 3 – Córtex Sensorial Primário

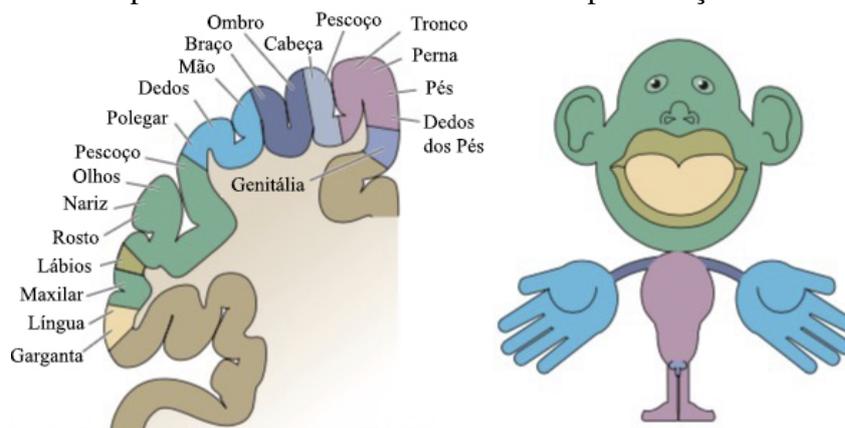


Fonte: Adaptado de Purves et al. (2004)

As quatro regiões corticais contêm a representação completa do corpo, chamado de mapa somatotópico (Figura 4). Este mapa não representa o corpo humano proporcionalmente. Quando

representado, o boneco *homunculus* possui as mãos e a cabeça aumentados em relação ao restante do corpo. Isto se dá devido à importância que o ser-humano dá para as mãos e a cabeça. Em outras espécies podem acontecer distorções em outras regiões, que são componentes mais essenciais para o sensoriamento. Em termos gerais, o órgão sensorial que causa o maior sinal de entrada no S1 (e de saída no córtex motor) e que é, portanto, mais significativo, terá uma representação cortical maior.

Figura 4 – Mapa sensorial do córtex sensorial e representação no *homulucus*



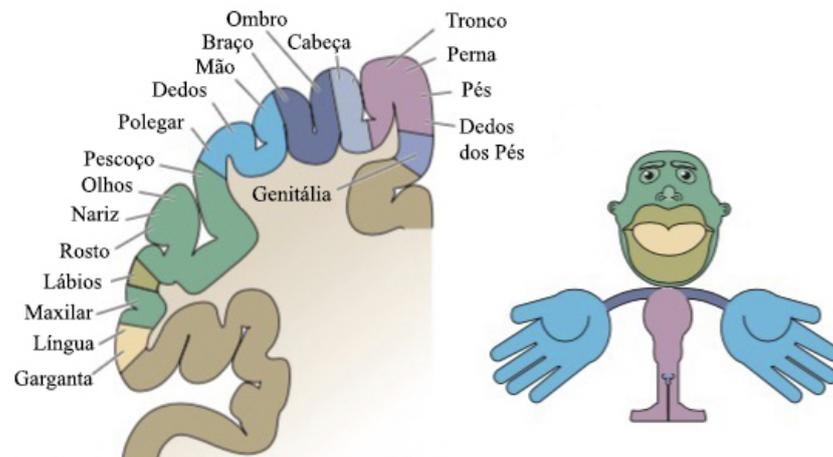
Fonte: Adaptado de [Purves et al. \(2004\)](#)

O córtex motor primário (M1) é a região essencial para planejamento, inicialização e sequenciamento de movimentos voluntários. Se distingue das áreas adjacentes pela sua citoarquitetura, que é majoritariamente composta por células piramidais e pela facilidade com que se estimulam movimentos aplicando correntes de baixa intensidade nessa região ([PURVES et al. 2004](#), p. 405-407). Isso indica o seu caminho de comunicação direto com as regiões mais internas de neurônios motores.

Os pulsos elétricos realizam contrações musculares na contralateral do corpo. Correlacionando o local do estímulo com o respectivo músculo contraído, pôde-se mapear o mapa muscular do corpo humano, que também é completo. Similarmente ao mapa sensorial encontrado no córtex somático, no mapa muscular existem as mesmas desproporcionalidades. Neste caso o tamanho refere-se às regiões que demandam maior precisão no controle do movimento (Figura 5).

Os lobos occipital, parietal e temporal são envolvidos no processamento de imagens e informações visuais. Na região posterior, no lobo occipital, reside uma região conhecida por córtex visual primário, comumente chamado de V1, que ativa todas essas áreas. Ela faz parte de uma região chamada córtex extra-estriado. Ela é separada basicamente em dois sistemas separados: o *fluxo ventral* e o *fluxo dorsal*. O ventral vai de V1 até a parte inferior do lobo temporal e o dorsal se estende de V1 até o lobo parietal, incluindo a região central do lobo temporal. A área temporal média (MT) situa-se no fluxo dorsal e identifica unicamente movimentos nas imagens, enquanto que a região V4 situa-se no fluxo ventral e processa somente as cores.

Figura 5 – Mapa muscular do córtex motor e representação no *homulucus*



Fonte: Adaptado de [Purves et al. \(2004\)](#)

Os córtices de associação, diferentemente dos córtices sensorial e motor primários, são aqueles formados por regiões corticais que recebem informações de outras regiões do próprio córtex, já processadas pelos S1 e M1. É nessa região que se localiza o córtex auditivo primário (A1), responsável pela interpretação dos sons. A interligação dessa região é possível graças ao tipo de conexão nervosa que possui. A inervação chama-se de conexão corticocortical. Ela liga as regiões corticais de associação umas às outras e ao primário sensorial e motor, permitindo o recebimento e a troca de informações.

A sensação das emoções têm influência nas operações cerebrais que são responsáveis por executar decisões racionais e julgamentos interpessoais. Indivíduos que têm lesões em regiões do cérebro como o córtex medial frontal e pré-frontal possuem dificuldade com essas duas faculdades. É uma região envolvida em processar emoções e também tem a responsabilidade do pensamento racional. Localiza-se na região mais anterior do lobo frontal e está na região dos córtices de associação.

Sabe-se que a plasticidade é a capacidade cerebral de reorganizar os circuitos corticais após danos ou perda da ligação com membros. As áreas receptoras dos estímulos dos membros perdidos passam a responder aos estímulos de outros membros. Acontece uma remodelagem dos axônios dos nervos periféricos. No entanto, o quadro é distinto para nervos do sistema central. Os neurônios do sistema nervoso central, geralmente falham na sua reconstituição, devido em grande parte ao comprimento do seu axônio que se estende por toda a medula ([PURVES et al., 2004](#)). Por esse motivo, os que sofrem com traumas na espinha, geralmente não atingem uma recuperação completa, mesmo com a atuação da plasticidade cerebral, inibindo a chegada de sinais das extremidades ao tálamo e conseqüentemente às regiões dos córtices primários e conseqüentemente ao córtex de associação.

Também aqueles que passam por hemorragia cerebral (AVC) têm perdas na sua capacidade de regeneração. A inflamação causa em uma limpeza fisiológica das células mortas, desconexão de sinapses inoperantes e rompimento da barreira hematoencefálica, que permite o funciona-

mento metabólico normal do cérebro (KRUCOFF et al., 2016). Os efeitos colaterais finais são cicatrizes nas glias, que barram física e quimicamente a recuperação neuronal.

Por outro lado, pesquisas como as de Sabbah et al. (2002) e Munzerta, Loreya e Zentgrafa (2009) mostram que mesmo após anos de lesão ou amputação, a tentativa consciente de movimentar os membros, a execução de MI ou o estimulação própria dos membros, geraram ativação dos circuitos corticais referentes ao movimento e sensoriamto (M1 e V1). MI resulta, quando imaginado em primeira pessoa, em uma ativação das mesmas áreas de quando há uma execução do movimento de fato. A revisão da literatura na área de MI de Lotze e Halsband (2006) mostra que, de fato, a imaginação de tarefas motoras, ativa a região contralateral do M1. Com base nesses estudos, pode-se justificar o uso de eletrodos em todas as regiões estudadas, mesmo que para pacientes lesionados.

2.2 BLOSSINAIS

Kaniusas (2012) diz que um sinal biomédico ou *Blossinal* pode ser definido como "uma descrição de um fenômeno fisiológico". Ao longo dos séculos, o Blossinal passou de um simples diagnóstico visual sobre sinais impressos coletados por equipamentos rudimentares, para aprimoradas medições com múltiplos sensores, amostradas com frequências altas e armazenadas digitalmente para pós-processamento. Hoje é usado tanto para fins terapêuticos como para fins de diagnose.

A quantidade dos blossinais passíveis de coleta, atualmente, exige uma série de conhecimentos: metodologia adequada para a aquisição, disposição dos sinais em modelos matemáticos apropriados, identificação de padrões de sinais associados às respostas cognitivas correspondentes e projetos para correlacionar sinais a possíveis respostas motoras. É necessária a sua classificação quanto: à sua existência, sua dinâmica e sua origem. A existência prevê se o sinal é permanente ou induzido. O primeiro tipo indica um sinal existente a qualquer momento, enquanto que o segundo um sinal que apenas se obtém através de um estímulo externo, ou seja, a aplicação do estímulo externo tem como efeito o sinal desejado. A dinâmica indica se é um sinal *quasi* estático, onde as mudanças são estáveis e somente perceptíveis ao longo do tempo, ou dinâmico, onde as mudanças são claras e visíveis no domínio do tempo. Por fim, a origem é a mais diversificada das classificações. Diz respeito, até certo ponto, à maneira que extraiu-se o sinal (KANIUSAS, 2012, p. 18). Muito embora não sejam os únicos, os mais notáveis grupos são os blossinais do tipo:

Elétricos: refletem atividade elétrica de órgãos através de um conjunto de impulsos. São exemplos deste grupo o Eletroencefalograma, o Eletromiograma e o Eletrocardiograma.

Magnéticos: indicam um campo magnético induzido, geralmente por uma corrente não estacionária, como exemplo o Magnetocardiograma, a Magnetoencefalografia, que é análoga à EEG e a Imagem por Ressonância Magnética (fMRI).

Mecânicos: provenientes de deformações corporais ocasionadas para extração de dados, como o se faz para medição de pressão sanguínea, por exemplo, ou para medição de respiração.

Ópticos: fazem uso da luminosidade para medições. A Fotopletismografia é usada para detectar mudanças volumétricas no sangue.

Acústicos: fazem uso de sons corporais para interpretar acontecimentos fisiológicos, como o Fonocardiograma.

Químicos: oriundos da mudança da composição química ao longo do tempo. Usados no diagnóstico da diabetes de acordo com o nível de glicose.

Térmicos: baseados nos mecanismos de ganho ou perda de calor, como a Termografia utilizada em detecção de câncer e osteoporose.

2.2.1 Sinais Cerebrais

No cérebro humano estima-se que haja 86 bilhões de células nervosas, que são células diferenciadas do corpo humano (HERCULANO-HOUZEL, 2012). Sua especialidade é a comunicação intercelular. Diferentemente do outro tipo de células do sistema nervoso – as células gliais ou neurogliais – os neurônios têm a capacidade de transmitir sinais elétricos por grandes distâncias (em comparação com o seu tamanho). Este sinal conhece-se na Neurociência como potencial de ação. As ondas elétricas são propagadas de um axônio a outro(s) – sendo que cada neurônio possui apenas um axônio.

Conforme diz Purves et al. (2004), "neurônios nunca funcionam em isolamento", é necessário que haja um circuito neural para o processamento de informações. As células nervosas que *levam* a informação até o cérebro ou medula espinhal são neurônios aferentes; as que *trazem* são neurônios eferentes e as células que participam ao longo do caminho, de maneira local, são os interneurônios.

A atividade de células nervosas gera corrente elétrica. Em volumes de tecido cerebral, essas correntes se sobrepõem e geram um potencial V_e [V], com respeito a um referencial. A diferença de potencial entre pontos medidos gera um vetor de amplitude [V/m], definido como o gradiente espacial negativo e este campo elétrico pode ser medido por eletrodos, com resolução em tempo de sub-milissegundos (BUZSÁKI; ANASTASSIOU; KOCH, 2012).

Os tipos de aquisição de eventos extracelulares tomam como base o mesmo potencial V_e . A eletroencefalografia (EEG) é uma das mais antigas na pesquisa da atividade cerebral. Sua medição é feita de modo não intrusivo, através do couro cabeludo, e é uma versão suavizada espaço-temporalmente do campo de potencial local (*Local Field Potential* - LFP), integrando em torno de 10cm^2 de medição, segundo Buzsáki, Anastassiou e Koch (2012). O LFP, também conhecido como micro-EEG são as aquisições feitas por eletrodos intracranianos, diretamente

no cérebro. São os sinais eletrogêneos mais informativos, podendo conter a maior parte da informação neuronal da região medida.

A eletrocoriografia (ECoG) é o meio termo, sendo que as medidas são na região subdural, ou seja, sob a *dura-máter* – membrana mais exterior e dura que envolve o cérebro e a medula espinhal – muito aplicada para estudos clínicos. E por fim a magnetoencefalografia (MEG) utiliza magnetômetros sensíveis, denominados de *superconducting quantum interface devices* (SQUIDs), para identificar campos magnéticos amenos, advindos das correntes cerebrais, na parte externa da cabeça. Esta técnica evita as distorções no sinal causadas pela capacitância da pele nas altas frequências, mas o custo, o tamanho e a falta de portabilidade do maquinário são muito elevados, inviabilizando o seu uso para os fins deste trabalho. Por esses motivos, justifica-se o uso de EEG para desenvolver BCI: requer um equipamento mais compacto (Figura 6), mais simples de ser operado, que permite a manipulação por pesquisadores que não são especializados em usar eletrodos intra-cranianos. O sistema de EEG permite coletar sinais com resolução temporal maior, e possui um baixo custo se comparado a outros métodos (CREASE, 1991).

Das vantagens do EEG, as maiores são a baixa quantidade de equipamento necessário para ser extrair e interpretar as medições (vide Figura 6), gera um sinal com resolução temporal considerável e possui um baixo custo se comparado a outros métodos (CREASE, 1991).

Figura 6 – Exemplos de Equipamento EEG comerciais: Emotiv EPOC+ (esq.), OpenBCI Cyton (dir.)



Fonte: Emotiv (2018) (esq.) ; Conor Russomano por Steve Hopson (dir.).

O sinal de LFP é o registro intracraniano de V_e . As características deste sinal, como amplitude e frequência, variam conforme as contribuições das atividades das células neuronais e as propriedades do tecido cerebral. A intensidade do sinal é dada de forma inversamente proporcional à distância da medição. Não só as contribuições individuais de cada sinal formam o campo, mas também a sua sincronia temporal (LUCK, 2014).

Existem múltiplas fontes que constituem as correntes extracelulares. Uma das mais importantes, em situações fisiológicas, é a que provém da atividade sináptica. O *Glutamato* é o transmissor biológico mais importante no funcionamento regular do cérebro. Estima-se, segundo [Purves et al. \(2004\)](#), p.137), que mais da metade das sinapses cerebrais liberam este agente. Os receptores ionotrópicos dos neurotransmissores AMPA¹ e NMDA² são canais de cátions, liberando a passagem de íons Na⁺ (sódio) e K⁺ (potássio) da fenda sináptica (substância proteica em que os neurônios estão submergidos) para dentro das células pelos dendritos. A afluência destes cátions do espaço extracelular para o intracelular cria uma corrente de retorno, em sentido oposto ao do movimento iônico, para balancear a troca de componentes químicos de fora para dentro da célula. Deste modo, a ativação destes receptores sempre produz resposta de potencial pós-sináptico (PSP), que pode ser tanto excitatório quanto inibitório, dependendo da polaridade do dipolo formado. A corrente gerada é proveniente de eventos relativamente lentos.

Os potenciais de ação rápida geram as correntes mais fortes na membrana neuronal e podem ser detectados como ‘picos’ de atividade. A liberação de Na⁺ eleva o potencial de V_e , mas sua duração é curta, menos de 2 milissegundos. Em comparação, o PSP dura de dezenas a milhares de milissegundos ([LUCK, 2014](#), p. 40). Devido à essa curta duração, dificilmente os potenciais de ação são captados por eletrodos de superfície (no couro cabeludo, EEG). Picos de cálcio são causados por eventos não sinápticos e tem longa duração (10-100 ms). Os picos de Ca²⁺ são disparados pelo potenciais pós-sinápticos de excitação do receptor NMDA e podem se propagar dentro das células.

Ainda há outras fontes, como as que criam um diferencial de potencial quando uma frequência externa faz neurônios ressoarem, chamada correntes e ressonâncias intrínsecas; os picos pós-hiperpolarização, causados por elevada concentração intracelular de determinado íon, que leva ao fluxo de outro íon para fora do neurônio; as sinapses, tidas como a comunicação direta entre neurônios e o efeito efáptico, que é o efeito da propagação dos sinais elétricos de um neurônio em si próprio e nos demais. Mas outros fatores que contribuem para o sinal são a geometria do neurônio e a sua organização ([BUZSÁKI; ANASTASSIOU; KOCH, 2012](#)).

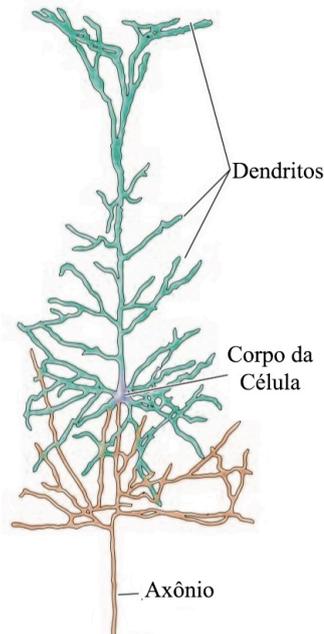
A célula piramidal (Figura 7) é o tipo que mais se tem na região cortical e que possui grande contribuição nas correntes extracelulares. Elas possuem um conjunto de dendritos basais e um único dendrito apical (Figura 8). Na citoarquitetura (arranjo das células nervosas) dessa região, usualmente as células piramidais encontram-se lado a lado perpendiculares à superfície, com seus dendritos paralelos, permitindo que o sinal aferente passe de maneira perpendicular ao eixo do dendrito, sincronizando o efeito de dipolo. Quanto mais alinhados os dendritos estejam ao ‘plano’ pelo qual o sinal aferente passa, maior será a amplitude do sinal.

No entanto, como mencionado, a sincronia temporal dos potenciais das membranas desenvolve um papel chave na amplitude do sinal. Estados cerebrais promovem diferentes oscilações da rede neuronal e com isso tem-se uma sincronia maior ou menor, que influencia na magnitude

¹α-amino-3-hidroxi-5-metil-4-isoxazolpropiónico

²N-metil-D-aspartato

Figura 7 – Células Nervosas Piramidal



Fonte: Adaptado de [Purves et al. \(2004\)](#)

do LFP. Diz-se da potência do sinal de LFP que sua amplitude é inversamente proporcional à frequência, $1/f^n$ – onde n é definido por diversos fatores, variando de 1 a 2 ([BUZSÁKI; ANASTASSIOU; KOCH, 2012](#)). A compressão ou espichamento deste sinal se dá em parte pela característica passa-baixa encontrada nos dendritos.

A relação entre o potencial V_e e a densidade da fonte de corrente (*current source density* - CSD) J [$A \cdot m^{-2}$] pode ser calculada através da *equação de Maxwell*:

$$\nabla(\vec{\sigma} V_e) = -\nabla \vec{J} \quad (1)$$

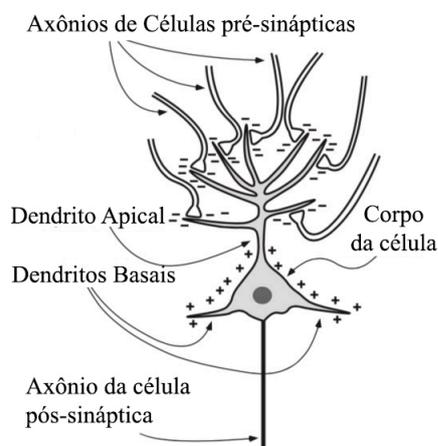
onde σ é a condutividade extracelular [$(\Omega \cdot m)^{-1}$ ou, no S.I., $S \cdot m^{-1}$]. Se a fenda sináptica for homogênea e isotrópica, pode-se assumir um σ constante, simplificando a equação

$$\sigma V_e = J \quad (2)$$

que pode ser solucionada com $V_e = I/4\pi\sigma r$, sendo I a amplitude da corrente no ponto, medida em [A], e r a distância da fonte, medida em [m].

O potencial V_e definido acima é o dipolo médio dos dipolos individuais próximos ao ponto de medição. Sabe-se que em qualquer ponto do couro cabeludo a medição de dipolo será a soma ponderada de todos os outros dipolos, em que os pesos de cada um será definido por sua distância r . Este dipolo médio gera a corrente medida, chamada de corrente equivalente de dipolo, que é a corrente medida de fato. Quando se evoca um potencial por estímulos externos, essas correntes equivalentes constituem um sinal de *event-related potential* (ERP) para uma

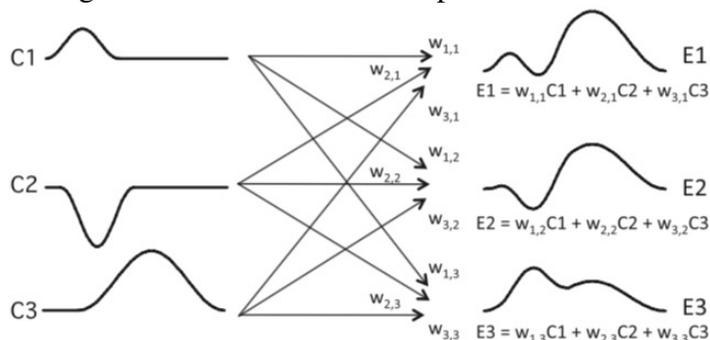
Figura 8 – Célula Piramidal e seus componentes



Fonte: Adaptado de Luck (2014)

determinada região medida. Esta técnica é uma das existentes para identificar reações padronizadas do cérebro. Uma exemplificação gráfica deste sinal é apresentada na Figura 9, onde cada C_i , $i = 1, 2, 3$ é um componente do sinal e cada E_i , $i = 1, 2, 3$ é um sinal medido por um eletrodo (LUCK, 2014). Componentes de ERP são subdivididos em três categorias principais: exógenos, que são disparados por presença de estímulo; endógenos, que são dependentes de tarefas; e motores que despontam quando há preparação e execução de um movimento.

Figura 9 – Sinal ERP medido por cada eletrodo

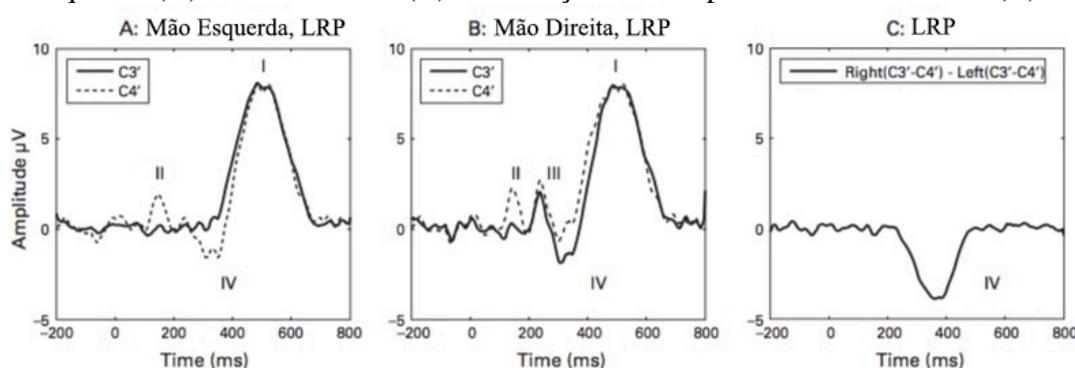


Fonte: Luck (2014)

Pode-se concluir que todos os pontos de medições possuem praticamente todos os componentes no seu sinal e que todos os pontos terão exatamente os mesmos componentes, porém com ponderações diferentes em cada um. Cada componente pode ser definido como "um sinal captado na superfície do couro cabeludo que é gerado por um módulo neuroanatômico específico quando operações computacionais específicas são realizadas" (LUCK, 2014, p. 66). Isso quer dizer que cada componente é uma parcela do sinal que representa uma atividade funcional distinta para cada região neuronal. Não há meios de isolar tais atividades através da captação de EEG. Quando usada a análise por ERP, se separam os componentes através de processamento computacional.

A exemplo disso, um dos componentes, chamado potencial de prontidão, é o pico negativo aparente na onda de ERP anteriormente à resposta fisiológica (levantar a mão, esticar a perna, etc.) que pode começar até um segundo antes. A lateralização deste componente é a LRP (*lateralized readiness potential*) e pode ser facilmente isolado de outros componentes. É gerado no córtex motor e tem também característica contralateral (i.e. estimulado de um lado, mas com atividade no lado oposto do cérebro), como mostrado na Figura 10 (A e B), onde C4' e C3' são eletrodos posicionados na região central, sendo o primeiro para a direita e o segundo para a esquerda.

Figura 10 – Representação do componente LRP. No hemisfério direito e esquerdo: ao levantar a mão esquerda (A) e a mão direita (B). A extração do componente mostra-se em (C).



Fonte: Adaptado de Luck (2014)

Para obter a resposta isolada do LRP a captação de ambos os lados é necessária. Como mostrado na Figura 10 C, é possível extrair o sinal de LRP subtraindo o componente contralateral do ipsilateral. E não é apenas para as mãos que se nota o seu efeito: o sinal de LRP precedente ao movimento das pernas também é visto, porém com polaridade invertida.

Um outro sinal, o *steady state* (estado estacionário, em tradução livre ou regime permanente), acontece quando a frequência de estímulos é elevada (e.g. 8 estímulos por segundo), apresentando no ERP uma onda similar a um somatório de dois senos, um com a frequência dos estímulos e a outra com o dobro. É importante ter em mente que este tipo de sinal existe para ter cautela durante os experimentos. Um estímulo perceptível não planejado no ambiente pode criar pulsos ressonantes nas coletas e diminuir a qualidade da informação temporal captada (LUCK, 2014).

Existem ainda outros quatro fenômenos capturados no EEG, chamados ritmos corticais (ou oscilações cerebrais). Segundo Purves et al. (2004, pg. 668), o significado funcional destes sinais é desconhecido desde a sua descoberta. Cheron et al. (2016) mostra um apanhado de estudos que procuram relacionar as oscilações a acontecimentos, estados fisiológicos e estímulos, mas muitas conclusões permanecem indefinidas.

As primeiras ondas alfa primeiramente captadas se mostraram na frequência de 10 Hz, quando o indivíduo estava relaxado, com os olhos fechados. Mas se percebe também uma amplitude elevada nas frequências alfa em estado "relaxado mas focado" (CHERON et al., 2016).

As frequências alfa do sistema visual, mu do sistema sensoriomotor e tau do sistema auditivo compõe essa banda. Têm ~8 a 13 Hz de frequência e uma amplitude de 10-50 mV. Ela é mais notória nas regiões occipitais e é modulada pela abertura e fechamento dos olhos. A oscilação beta tem de ~14 a 30 Hz e indica a atividade mental e atenção. Se encontra consistentemente na localização do córtex motor primário e se apresenta tanto ao se executar um movimento quanto ao se observar um movimento.

Os ritmos theta, que giram em torno dos ~4 a 8 Hz, e as ondas delta, de ~1 a 5 Hz, indicam sonolência, sono ou alguma condição patológica. Para indivíduos saudáveis, essas frequências são uma marca do sono não-REM (*rapid eye movement*). [Ofori, Coombes e Vaillancourt \(2015\)](#) demonstraram que os ritmos Theta também incrementam de maneira contralateral durante movimentos simples com os membros superiores. Desta forma, assume-se que é uma banda que tem importância para o controle motor.

2.3 ELETROENCEFALOGRAFIA

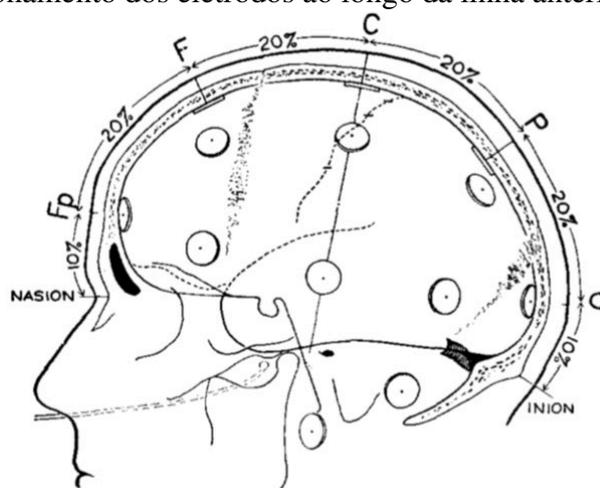
Conforme visto na seção anterior, o córtex cerebral é composto por cristas e fissuras e a atividade dos neurônios de cada região determinará o potencial medido no escalpo. Os pontos de aplicação dos eletrodos são usados para mapear a variação do comportamento da tensão no couro cabeludo. Cada eletrodo representa um ponto de tensão. Quanto maior o número de eletrodos, mais fidedigno será o mapeamento da atividade neuronal [\(SCHOMER; SILVA, 2011\)](#).

O sistema internacional 10-20 de alocação de eletrodos foi acordado em 1957, publicado pelo comitê de exame clínico por EEG da época no "[Report of the committee on methods of clinical examination in electroencephalography](#)"³. Este sistema prevê 21 eletrodos ao longo do escalpo e uma sistemática para distribuição. Na linha central do crânio deve-se medir a distância entre o násio (depressão inferior da testa que separa os olhos) e o ínio (proeminência do osso occipital). Cinco eletrodos serão colocados nesta linha. Começando pelo násio, dez por cento da distância medida deve ser considerado para marcar a primeira posição do eletrodo, chamada de posição Fp (posição frontal). As posições seguintes serão separadas por 20% da distância total (Figura [11](#)). No sentido násio-ínio as posições serão, em ordem, F (frontal), C (central), P (parietal) e O (occipital).

No plano central, o mesmo procedimento será feito, no entanto as medidas serão tomadas das depressões pré-auriculares direita até a esquerda. O primeiro ponto a partir da depressão se distancia 10% do comprimento total e é denominado de T (temporal). Os pontos centrais seguintes serão separados por 20% da medida total. A Figura [12](#) mostra como fica a distribuição. As posições centrais serão a T (temporal, direita e esquerda) e C (central, direita e esquerda), além da Cz (central zero, que fica em cima do do córtex sensório-motor).

³ [\(REPORT OF THE COMMITTEE ON METHODS OF CLINICAL EXAMINATION IN ELECTROEN-CEPHALOGRAPHY, 1958\)](#)

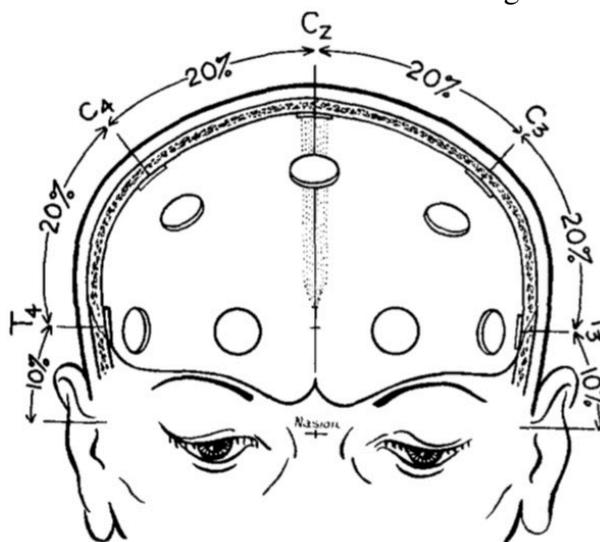
Figura 11 – Posicionamento dos eletrodos ao longo da linha anterior-posterior (média)



Fonte: [Report of the committee on methods of clinical examination in electroencephalography \(1958\)](#)

Na lateral do escalpo a medida base é a distância entre o ponto médio dos eletrodos Fp e o ponto médio dos eletrodos occipitais O, passando pelo ponto temporal T. Os 10% iniciais e finais da medida serão os que indicam a posição dos eletrodos Fp e O de fato (Figura 13). Os eletrodos meio-Frontais e meio-Parietais serão colocados nas linhas Frontal e Parietal com espaçamento equidistante entre a linha média e a linha temporal.

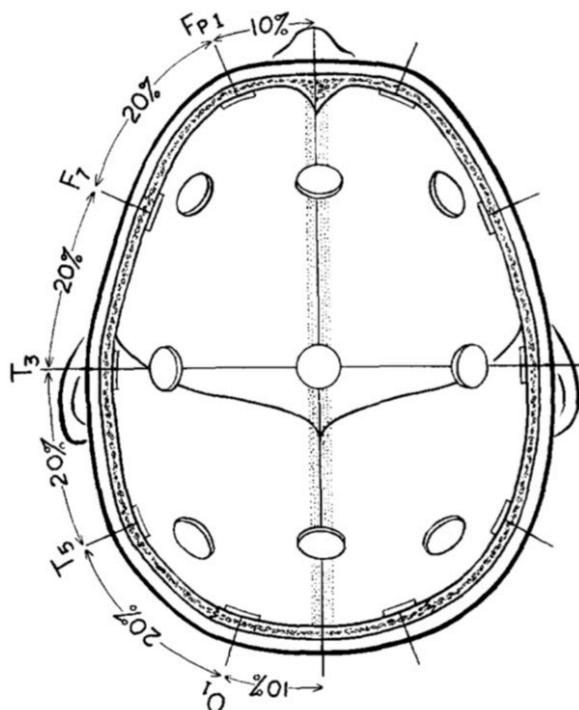
Figura 12 – Posicionamento dos eletrodos ao longo da linha central



Fonte: [Report of the committee on methods of clinical examination in electroencephalography \(1958\)](#)

A numeração dos eletrodos também foi pensada para padronizar as posições. Os eletrodos com números pares correspondem ao hemisfério direito e os ímpares ao hemisfério esquerdo. Quanto maior o número, mais distante da linha média, e os eletrodos na linha média são os eletrodos zero (batizados de 'z' para evitar confusões entre o algarismo '0' e a letra 'O' de

Figura 13 – Posicionamento dos eletrodos ao longo da linha lateral (temporal)



Fonte: [Report of the committee on methods of clinical examination in electroencephalography \(1958\)](#)

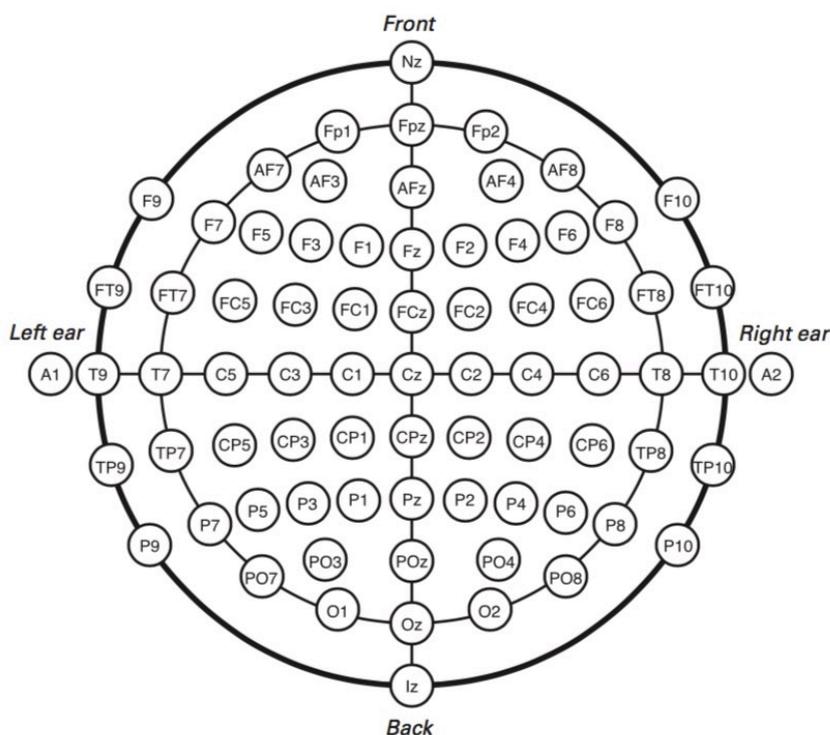
Occipital). Dentro do sistema 10-20 as posições padrão serão o Fp2, F4, F8, C4, P4, T4, T6 e O2 para o lado direito e Fp1, F3, F7, C3, P3, T3, T5 e O1 para o lado esquerdo. Além destes os eletrodos alocados na nasofaringe – se existirem – são denominados Pg1 e Pg2 e os eletrodos posicionados na região mais alta da nuca (eletrodos do cerebelo) são denominados Cb1 e Cb2. A planificação das posições dos eletrodos para este sistema são vistas na Figura [14](#).

Embora este seja o padrão clínico adotado, estima-se que são necessários ao menos 100 eletrodos para captar sinais mais fiéis e específicos ([SCHOMER; SILVA, 2011](#), p. 144). Para este propósito há o sistema 10%, que segue uma lógica do sistema 10-20%, porém com distanciamento de dez por cento da distância total. Neste sistema os eletrodos originais T3, T4, T5 e T6 são substituídos pelos T7, T8, P7 e P8, por conta das novas ‘linhas’ que são desenhadas. Na Figura [15](#) pode-se ver que, paralelas à linha central, existem também a linha Parietal-Occipital (PO), a Central-Parietal (CP) a Frontal-Central (FC) e a Anterior-Frontal (AF). Este sistema conta com 81 eletrodos no total. Ainda existem sistemas com 128, 256 e até 320 eletrodos, conforme descrito por [Jurcak, Tsuzuki e Dan \(2007\)](#).

Outro princípio básico para uma boa aquisição é que quanto mais limpos forem os dados, menos coletas serão necessários para uma análise bem executada ([LUCK, 2014](#)). A fim de maximizar a qualidade da coleta dos dados, é necessário o uso de três eletrodos para um único canal: o ativo (A), o referência (R) e o terra (G, de *ground* em inglês).

Um dos grandes problemas que se encontra no EEG é o ruído. Uma das fontes mais comuns de ruído são os equipamentos elétricos. O ambiente pode infringir na captação um ruído

Figura 15 – Planificação da posição dos eletrodos no sistema internacional 10-10, advindo do sistema 10-20



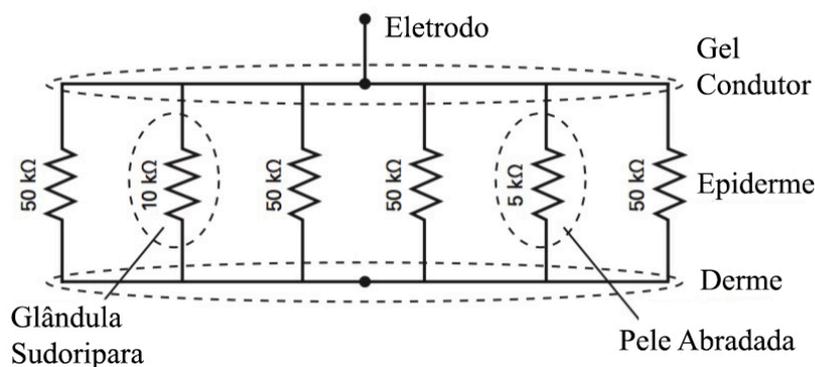
Fonte: Luck (2014)

Outro fator importante é a impedância da pele. Uma vez que existe uma ligação elétrica entre o eletrodo e a pele, é importante tentar estabilizar essa variável nas aquisições de dados. A sequência da ligação eletrodo-derme é: eletrodo, gel condutor, óleos da pele, suor, epiderme e derme. A epiderme é a camada de células mortas acima da derme e os óleos são gerados pelas glândulas sebáceas, gorduras da pele. As células mortas e o sebo são condutores elétricos fracos e aumentam a impedância da ligação. Com o passar do tempo, o gel condutor pode hidratar a camada de células mortas e diminuir a impedância da ligação, mas um outro agente que reduz a impedância é o suor. Por ser uma substância salinizada, é um excelente condutor de eletricidade. Mas por se dar em camadas não homogêneas na superfície de contato, pode causar variações aleatórias na aquisição dos dados. Uma prática usual que pode anteceder a aplicação dos eletrodos é o desgaste da pele, que remove parte da pele morta e os óleos superficiais, no entanto, deve-se ter cautela com a prática, pois pode reduzir demais a impedância da pele e causar queimaduras (LUCK, 2014). O circuito equivalente da Figura 16 mostra como pode ser representada a impedância da ligação.

Uma vez que o EEG é um sinal analógico, é necessário digitalizá-lo. Para digitalizá-lo, é necessário amplificar o sinal para que a tensão esteja em um intervalo adequado, que possa ser convertido. Geralmente amplificadores entregam um sinal de $\pm 500 \mu\text{V}$. Os conversores analógico-digital (ADC) têm 16-32 bits (ou seja, 2^{16} ou 2^{32} passos de resolução) e uma saída de $\pm 5 \text{ V}$. A frequência de amostragem (f_s) desses conversores deve seguir o *teorema de Nyquist*,

que diz que a $f_{s_{min}}$ de um sinal deve ser maior que o dobro da maior frequência do sinal capturado. Segundo Luck (2014, p. 180-181), a f_s mais adequada para a maioria dos experimentos de cognição e afetividade é de aproximadamente 250 Hz. Para experimentos que objetivem reconhecer respostas rápidas, f_s deve ser maior, mas geralmente é uma frequência diferente para cada área de pesquisa. O único empecilho ao elevar a f_s é que ruídos indesejados passam a fazer parte do sinal e para isso é necessário uma filtragem.

Figura 16 – Circuito equivalente de ligação eletrodo-derme



Fonte: Adaptado de Luck (2014)

Ao analisarmos um sinal de EEG utilizando a *transformada de Fourier* veremos a sua composição em frequências. O espectro de frequências expõe as frequências que, somadas, compõem a onda, Mas isso não significa dizer que o cérebro oscilou àquela frequência. Luck (2014, p. 224) explica não ser a mesma coisa, pois um é uma equivalência matemática, diferente da equivalência fisiológica. As frequências no espectro são as frequências, que somadas, reconstroem a onda; o cérebro pode ou não ter oscilado nessa frequência, mas a decomposição em frequências de *Fourier* não pode dar certeza sobre isso.

Recomenda-se filtrar o mínimo possível durante a captação do sinal. Apesar de adquirir algumas frequências indesejadas, e possivelmente alguns ruídos, isso permitirá que poucas informações sejam perdidas. No geral, a filtragem *offline* é superior, pode ser simulada mais de uma vez com os mesmos dados e não se corre o risco de perder informações. Ainda assim, um filtro *anti-aliasing* – filtro passa-baixa que elimina, pelo menos, as frequências adquiridas que sejam mais altas que a metade de f_s – é um filtro necessário para quase todos os casos.

2.4 MOTOR IMAGERY

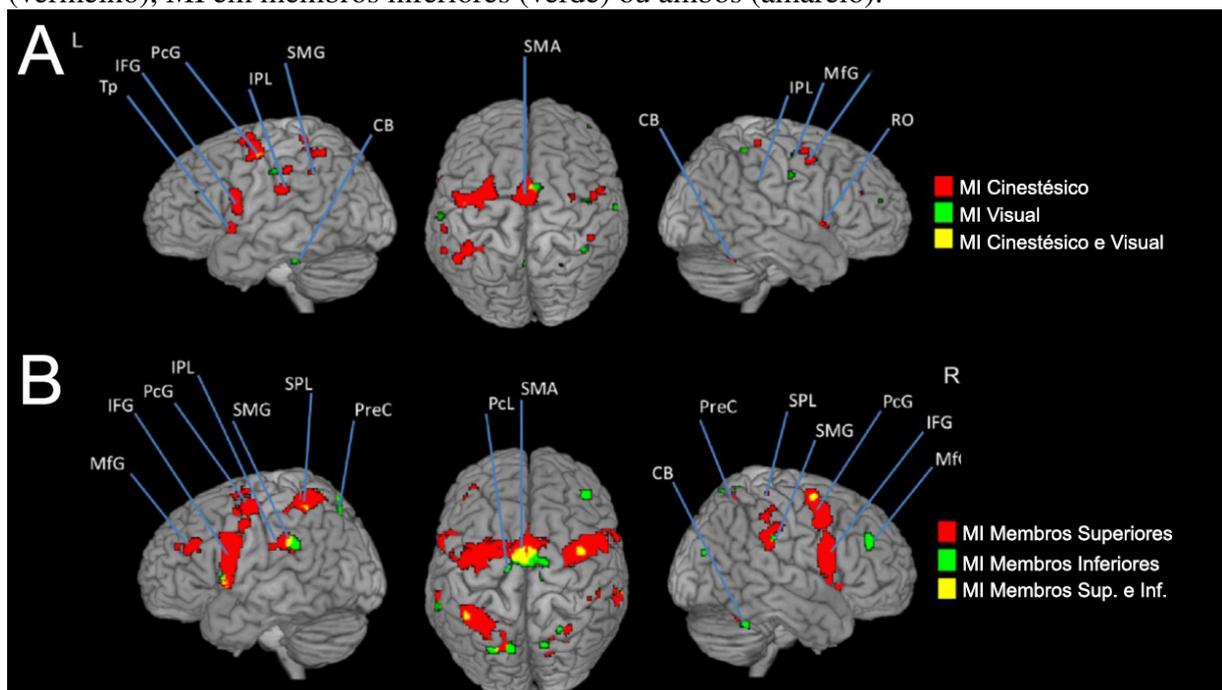
Há sinais de EEG espontâneos que serão objeto de estudo nesta pesquisa chamados de *motor imagery* (MI), diferentemente dos ERPs, que são potenciais evocados por estímulos externos. Como pode ver-se no levantamento de Héту et al. (2013), a partir de 2000 houve um crescimento na publicação de artigos sobre MI. É um tema recente, estudado desde o início da década de 90. Estes sinais acontecem quando o sujeito ensaia a execução de determinada ação mentalmente sem de fato executá-la. Jeannerod (1995) trabalhou com a hipótese de que a representação

motora da ação e a do imaginário da ação são o mesmo mecanismo, com a diferença de que apenas no primeiro a execução é levada a cabo.

Um efeito que corrobora com essa hipótese é observado nos músculos estimulados durante o MI (i.e., os músculos que são utilizados durante a visualização mental). Em condições normais, quando há estimulação do córtex motor primário, o músculo gera uma resposta mensurável chamada de Potencial Motor Evocado (MEP). Durante a execução do MI, pode-se medir um aumento no MEP durante o período de imaginação (CÉLIA RUFFINO; LEBON, 2016), indicando que a mesma região de processamento do movimento de fato está sendo estimulada. Munzerta, Loreya e Zentgrafa (2009) em seu artigo compendiam *papers* que o evidenciam.

A prática do MI, no entanto, pode ser realizada de diversas maneiras. Cada modalidade gera uma resposta diferente. Héту et al. (2013) investigaram as áreas com maior atividade no córtex durante o MI para diversas combinações destas modalidades. A revisão compreende 75 artigos que aferiram a atividade cerebral pelos métodos de *Positron Emission Tomography* (PET) ou fMRI, captando atividade inclusive sub-cortical. Em algumas pesquisas imagina-se os movimentos em membros superiores, em outras membros inferiores. Com relação à categoria, existem a Visual, que instrui o indivíduo a imaginar espacialmente a ação requisitada, e a Cinestésica, que instrui o indivíduo a experienciar a sensação muscular correspondente à ação motora de fato. Os resultados do estudo podem ser vistos na Figura 17. Nota-se que há mais regiões ativas quando se trata de MI de membros superiores e há regiões maiores quando se trata de MI cinestésico

Figura 17 – Mapa meta-analítico mostrando regiões de ativação consistente durante (A) MI Cinestésico (vermelho), Visual (verde) ou ambos (amarelo) e (B) MI em membros superiores (vermelho), MI em membros inferiores (verde) ou ambos (amarelo).



Fonte: Adaptado de Héту et al. (2013)

E as áreas corticais que se ativam com o movimento executado e com o movimento imaginado são semelhantes. Inclusive os tempos de execução de um e de outro são equiparáveis (CÉLIA RUFFINO; LEBON, 2016; JEANNEROD, 1995). As áreas mais ativas, independente da modalidade do *motor imagery*, são principalmente as regiões próximas ao córtex pré-motor, mas também áreas do parietal (HÉTU et al., 2013; MUNZERTA; LOREYA; ZENTGRAFA, 2009). É sabido que pacientes com lesões no lobo parietal têm dificuldades ao calcular o tempo necessário para imaginar a ação, evidenciando a importância da região para o MI (LOTZE; HALSBAND, 2006). Quanto ao córtex motor primário (M1) há conclusões controversas. Munzerta, Loreya e Zentgrafa (2009) mostram uma série de pesquisas que relatam atividade no M1, mas Hétu et al. (2013) indicam que apenas 18% dos experimentos conduzidos mostram ativação do M1. Uma possível explicação relatada pelos autores é a de que a resolução temporal do PET e do fMRI é menor do que a de métodos como o EEG, impedindo que se meçam as mudanças sutis no M1.

No âmbito clínico, o MI é utilizado para reabilitação. Nos pacientes que perderam motricidade, a unção de informações externas e internas, proporcionada pelo exercício do MI, instiga uma representação neuronal para imaginar o movimento e conseqüentemente impele a uma reaprendizagem no cérebro, recuperando a capacidade de planejamento de movimentação perdida na lesão (MUNZERTA; LOREYA; ZENTGRAFA, 2009; CÉLIA RUFFINO; LEBON, 2016). No âmbito de aprendizado, se utiliza tanto para aquisição de novas habilidades como para aprimoramento de atletas e músicos. Uma das pesquisas pioneiras que conseguiu mostrar isso foi a de Pascual-Leone et al. (1995), demonstrando a reorganização cortical devido à prática mental. Após cinco dias de treinamento, dois grupos que praticaram um exercício específico de piano, um fisicamente e um mentalmente, mostraram um aumento da plasticidade no córtex, enquanto que o grupo de controle que não praticou o exercício e apenas tocou piano sem objetivo específico não mostrou alteração. Assim, supostamente o treinamento mental pode produzir efeitos no córtex parecidos com os produzidos por treinamento físico.

Todavia, a boa execução do MI requer prática e concentração. Collet et al. (2011) propõe o *Motor imagery Index*, que é uma métrica para medição da qualidade do movimento imaginado. Esse índice leva em consideração uma auto-avaliação, um questionário para análise da aptidão do participante na prática MI, a duração do movimento imaginado e as respostas eletrodermais (MEP) e respiratórias do indivíduo durante os testes. E Mahmoudi e Erfanian (2006) demonstram a importância do treinamento mental e meditação para geração de um bom sinal de MI.

No contexto deste trabalho, o MI será utilizado para classificação. Diversos são os estudos que já aplicaram o sinal para tal. A grande vantagem é oferecer uma possibilidade de acionamento para indivíduos que tenham perdido a mobilidade, mas que continuem com o córtex em perfeito estado. Pessoas com LME ou amputadas conseguem gerar esse tipo de sinal (SABBAH et al., 2002; LOTZE; HALSBAND, 2006; MUNZERTA; LOREYA; ZENTGRAFA, 2009).

A Tabela 2.4 reúne alguns trabalhos de 2005 até 2018 mostrando quais são as características

principais observadas para capturar e processar o sinal. Grande parte dos trabalhos faz a leitura com 250Hz ou 128Hz. O tempo que é dado ao participante para que visualize o movimento gira em torno de 4s e deste período são utilizados 1, 2 ou 3 segundos. Alguns estudos utilizam todo o período de MI, mas geralmente se descartam as primeiras ou as últimas amostras. [Lindig-Leon et al. \(2017\)](#), [Wang et al. \(2018\)](#) e [Eltvik \(2018\)](#), utilizam janelamento com sobreposição, mas [Lu et al. \(2017\)](#) mostram em seus resultados que o janelamento móvel em análises tempo-frequência não agrega e até reduz a acurácia da classificação.

2.5 REDES NEURAIAS

Brain-Computer Interface (BCI) é o termo cunhado pela primeira vez por [Vidal \(1973\)](#), para descrever sistemas que comunicam o cérebro a um dispositivo externo. Quebrando o paradigma de processamento *offline* da época, propôs-se um meios de classificar os dados recebidos em tempo real, providenciando dados concretos sobre o funcionamento do cérebro para determinadas tarefas ([VIDAL, 1977](#)). As pesquisas mais recentes que utilizam BCI relatam o uso tanto de classificadores paramétricos como não paramétricos; há soluções que utilizam classificadores lineares, quadráticos ([YU et al., 2017](#); [KILICARSLAN et al., 2013](#); [LIANG et al., 2016](#)) e outros classificadores ([CECOTTI, 2011](#); [BALDWIN; PENARANDA, 2012](#); [LALITHARATNE et al., 2014](#)) para reconhecerem padrões.

[Baldwin e Penaranda \(2012\)](#) buscaram classificar o nível de sobrecarga intelectual de indivíduos sujeitos à testes de diferentes dificuldades captado por EEG. O objetivo é transferir essa informação a um sistema automatizado de apoio adaptativo (*adaptive aiding*) que reduz a dificuldade da tarefa, se necessário. Obtiveram uma acurácia entre 86 e 89% para indivíduos novatos nas tarefas com um perceptron de múltiplas camadas. [Lalitharatne et al. \(2014\)](#) utilizaram múltiplos *support vector machines* (SVM) binários para distinguir se o usuário anção de um sistema robótico auxiliar requeria ou não assistência muscular e obtiveram 84% da classificação correta unindo sinais de MEG e EEG. A pesquisa de [Cecotti \(2011\)](#) implementou um classificador por rede neural convolucional modificado, batizado de *time-frequency convolutional neural network*, para classificar cinco tipos diferentes de sinais de EEG em estado estacionário, obtendo 95.61% de acerto.

Na presente pesquisa serão utilizados classificadores não paramétricos. [Haykin \(2009, p. 2-4\)](#) cita alguns benefícios ao se usar redes neurais. Dentre elas, a não linearidade atingível com uma RN é uma propriedade importante, uma vez que os sinais de EEG que serão captados também são não lineares. Outro fator importante é a adaptatividade, que provê ao classificador a capacidade de se ajustar a condições adversas com novos treinamentos. Outrossim, é tolerante a falhas: sua distribuição natural dos dados permite uma quantidade maior de dados falhos ou anômalos antes de uma queda na qualidade das respostas. Tendo isso em mente, alguns conceitos básicos de funcionamento serão abordados a seguir.

Tabela 1 – Principais características experimentais dos artigos de MI estudados.

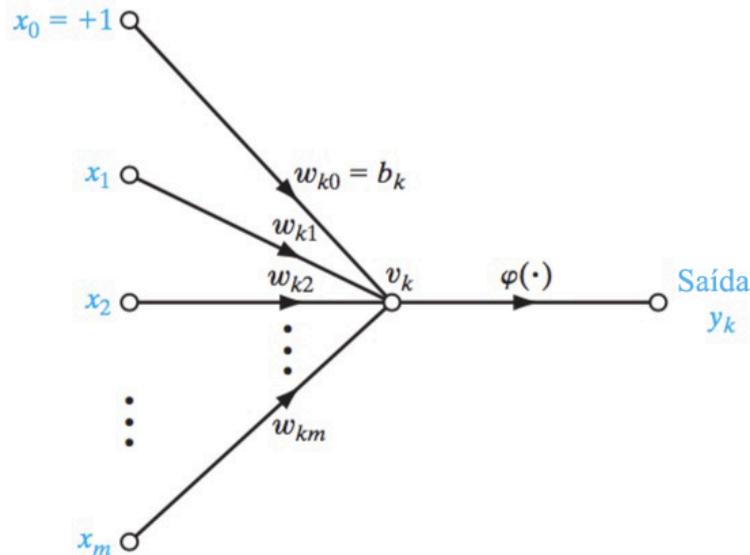
Autor, Data	f_a	t Gravado	t Usado	Pré-proc.	Movimento
Schlögl et al. (2005)	250Hz	4s	Subamostrado em 125Hz	Processo Adaptativo Auto-Regressão e Kalman	Mão Direita Mão Esquerda Língua Pés
Xiao e Hu (2008)	–	4s	Janelas de 1–2s, 1–3s, 1–4s e 1–5s	STFT	Mão Direita Mão Esquerda
Herman et al. (2008)	128Hz 125Hz	5s 4s	Janela $\leq 2s$	Power-Spec. Decom. Atômica Distri. Quadr. Energia Transformada Wavelet Auto-Regressão	Mão Direita Mão Esquerda
Ming-Ai et al. (2009)	128Hz	6s	6s	DWT	Mão Direita Mão Esquerda
Hsu (2012)	128Hz	5s	Janela de 1s mais significativo	CWT	Mão Direita Mão Esquerda
García-Laencina, Rodríguez-Bermudez e Roca-Dorda (2014)	256Hz	4s	Janela de 1s	PCA LLP	Mão Direita Mão Esquerda
Li et al. (2015)	–	6s	2–5s	FFT	Mão Direita Mão Esquerda Descanso
Tabar e Halici (2016)	128Hz 259Hz	4s	2 janelas de 2s	STFT	Mão Direita, Mão Esquerda
Muthong, Vateekul e Sriyudthsak (2016)	250Hz	4s	0,5–3,5s	WT	Mão Direita Mão Esquerda
Broniec (2016)	1200Hz	6s	6s	Flicker-Noise (FSN) ERD/ERS	Mão Direita Mão Esquerda
Tanga, Lib e Sunb (2017)	1000Hz	5s	1° ao 4°s	FFT	Mão Direita, Mão Esquerda

Autor, Data	f_a	t Gravado	t Usado	Pré-proc.	Movimento
Rashid e Ahmad (2017)	256Hz	7s	4s para mãos, 8s para pés	DWT	Mão Direita Mão Esquerda Pés
Lindig-Leon et al. (2017)	256Hz 250Hz	6s	6s janela 250ms offset 125ms	ERD/ERS	Mão Direita, Mão Esquerda, Pés, Combinações e Descanso
Batres-Mendoza et al. (2017)	256Hz	5s	Janelas durando de 3s a 0,5s	Quaternion-based Signal Analysis (QSA)	Mão Direita, Mão Esquerda, Descanso
Lu et al. (2017)	250Hz	4s	4s	FFT DWT	Mão Direita Mão Esquerda
Li et al. (2017)	128Hz	6s	0,5–5s	WPT	Mão Direita Mão Esquerda
Lee e Choi (2018)	250Hz	4s	Janela de 2s	CWT	Mão Direita Mão Esquerda
Wang et al. (2018)	256Hz	2s	2s janela 64 am. offset 32 am.	STFT	Mão Direita Mão Esquerda
Hettiarachchi et al. (2018)	250Hz	7s 9s	1–3s 0,5–2,5s	Common Spatial Pattern (CSP)	Mão Direita Mão Esquerda Língua Pés
Eltvik (2018)	100Hz	3,5s	2s janela 64 am. offset 32 am.	STFT CWT Hilbert-Huang (HHT)	Mão Direita Pé Esquerdo
Donovan e Yu (2018)	160Hz	4s	4s	DWT	Mão Direita (A/F) Mão Esquerda (A/F)

Análogas ao sistema nervoso humano, as redes neurais emulam o comportamento do cérebro. Dentro da RN, um neurônio é uma unidade de processamento de informação. Sinapses são as conexões entre os neurônios, que atribuem pesos (coeficientes) a cada informação. Dentro do neurônio há um somador ou combinador linear e em seguida uma função de ativação, responsável por limitar a amplitude da saída de cada neurônio. Geralmente se normaliza a amplitude da saída entre $[0,1]$ ou $[-1,1]$. E, na maioria dos casos, há um *bias* (termo independente) que aumenta ou diminui o somatório das entradas para cada neurônio.

Seja k a camada de neurônios atual e j a seguinte no sentido de avanço da rede. Se x_m são os sinais de entrada advindos de cada neurônio da camada anterior, w_{km} são os pesos para cada sinal (sendo w_{k0} é o peso que representa o *bias*), v_k é o somatório dos sinais de entrada ponderados por seus respectivos w , chamado de campo local induzido, $\varphi(\cdot)$ a função de ativação, e a saída $y_k = \varphi(v_k)$, um neurônio poderia ser representada conforme a Figura 18.

Figura 18 – Representação de um neurônio da RN. Fluxo do sinal na propagação.



Fonte: Adaptado de Haykin (2009)

A escolha da função de ativação definirá a não linearidade. As funções contínuas que atribuem essa característica são a função sigmóide e a função tangente hiperbólica. A escolha entre as duas se dá basicamente pelo fato da primeira gerar valores no intervalo $[0,1]$ e a segunda $[-1,1]$. A saída ativada de cada neurônio y_k formará o conjunto de entradas da próxima camada.

A junção de vários neurônios em camadas e a junção de camadas criam topologias diversas de RN. Em um perceptron de múltiplas camadas além dos neurônios de entrada e de saída, existem as camadas ocultas. Essas camadas atuam como detectoras de características, transformando de maneira não linear os dados de entrada em um espaço de características (HAYKIN, 2009, p. 126). Todos os neurônios de uma camada são conectados a todos os neurônios da próxima, sendo uma estrutura totalmente conectada.

Há duas fases de funcionamento nessa modalidade: a de propagação (*forward*) e a de retropropagação (*backpropagation*). Na propagação, os pesos são fixados e o sinal se propaga

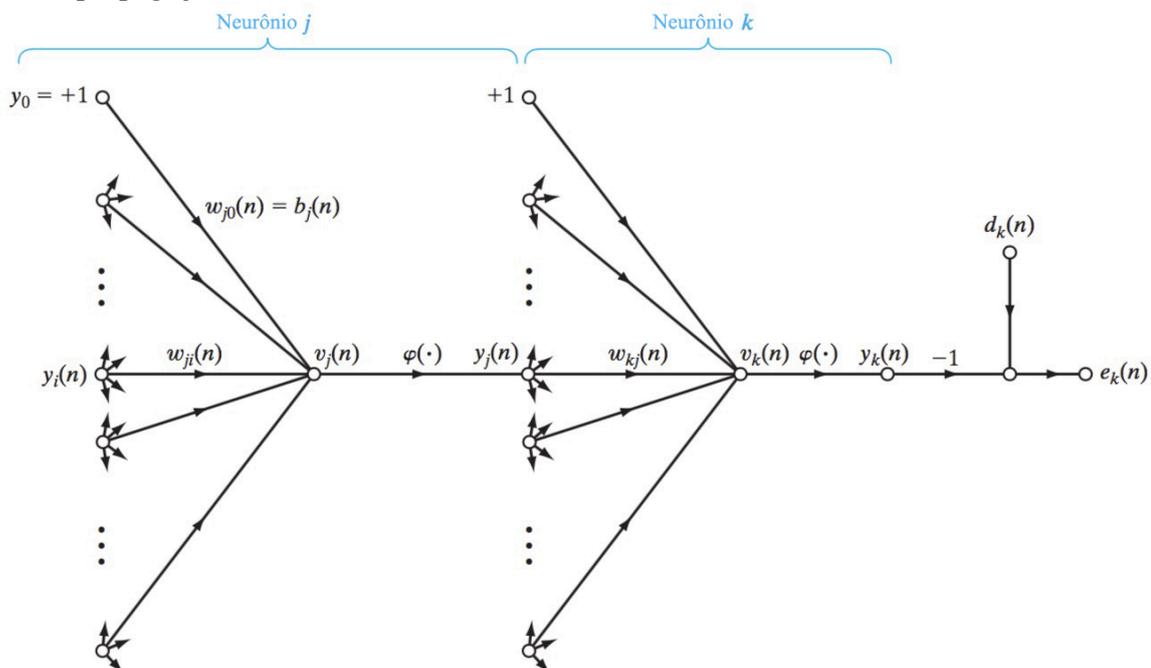
do início ao fim da rede. Na retropropagação, com base no erro entre a resposta esperada (d) e a resposta dada (y), se recalculam os pesos do final até o início e pode-se reiniciar a fase de avanço. Esse comportamento é cíclico e se repetirá até que o erro seja suficientemente pequeno. Neste caso considerar-se-á que a camada de neurônios oculta é a camada j , a anterior i e a última a k (conforme Figura 19). Para a última camada (a de saída), o erro em cada neurônio se representa como

$$e_k(n) = d_k(n) - y_k(n) \quad (3)$$

e a energia do erro instantâneo total através de

$$\mathcal{E}(n) = \sum \mathcal{E}_k(n) = \frac{1}{2} \sum e_k^2(n) \quad (4)$$

Figura 19 – Representação de um neurônios em um perceptron de múltiplas camadas. Fluxo do sinal na propagação.



Fonte: Adaptado de Haykin (2009)

Na fase de retropropagação, é necessário o cálculo de uma correção, denominada Δw_{kj} que é proporcional ao fator de sensibilidade, equacionado com base no método da cadeia (HAYKIN, 2009, p. 130), definido por:

$$\frac{\partial \mathcal{E}(n)}{\partial w_{kj}(n)} = -e_k(n) \cdot \varphi'(v_k(n)) \cdot y_k(n) = \delta_k(n) \cdot y_k(n) \quad (5)$$

onde δ é o gradiente local e $\varphi'(v_k(n))$ é a derivada da função de ativação. Por esse motivo, é importante que a função de ativação seja contínua, para que a derivada no cálculo de reajuste dos pesos não gere valores que tendam a ∞ .

A correção se dá pela ponderação do fator de sensibilidade por η , que é a taxa de aprendizagem. Esse parâmetro definirá a taxa com que se ajustarão os pesos. É importante notar que η muito grandes podem levar o sistema à instabilidade e muito pequenos levarão a muitos ciclos de processamento:

$$\Delta w_{kj}(n) = -\eta \frac{\partial \mathcal{E}(n)}{\partial w_{kj}(n)} \quad (6)$$

Caso o neurônio não seja de saída, o erro não pode ser calculado da mesma maneira que na Equação 3, pois não se tem o valor de referência d_j . Se o gradiente local δ_j é a derivada do fator de sensibilidade pelo campo local induzido, pela regra da cadeia, tem-se que

$$\delta_j(n) = \frac{\partial \mathcal{E}(n)}{\partial y_j(n)} \cdot \frac{\partial y_j(n)}{\partial v_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial y_j(n)} \cdot \varphi'(v_j(n)) \quad (7)$$

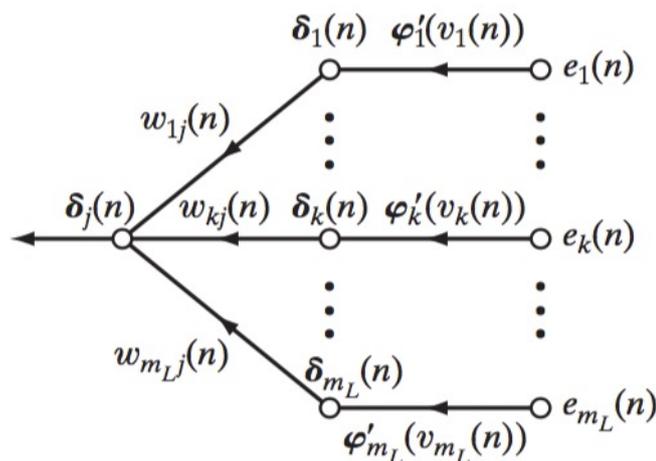
e aplicando novamente a regra da cadeia à derivada do erro pela entrada da camada anterior, ter-se-á

$$\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} = \sum_k e_k(n) \cdot \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (8)$$

Resolvendo ambos diferenciais, teremos que a derivada do erro (Equação 3) será a derivada primeira da função de ativação da camada posterior (i.e. a camada k), $-\varphi'(v_k(n))$, e a derivada do campo local serão o somatório dos pesos $w_{kj}(n)$. Portanto, o gradiente local para todas as camadas que não são a última é expresso por

$$\begin{aligned} \delta_j(n) &= \varphi'(v_j(n)) \sum_k e_k(n) \cdot \varphi'(v_k(n)) \cdot w_{kj}(n) \\ &= \varphi'(v_j(n)) \sum_k \delta_k(n) \cdot w_{kj}(n) \end{aligned} \quad (9)$$

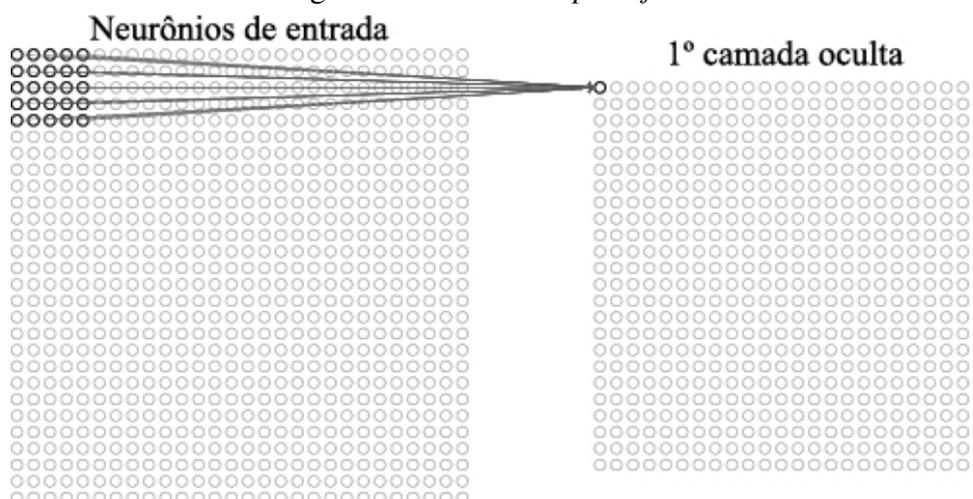
Figura 20 – Fluxo de sinal durante *backpropagation*.



A topologia que acabou-se de discutir chama-se de *feedforward*. Porém há alguns fatores ressaltados por [LeCun et al. \(1998\)](#) que devem ser considerados. Digamos que os dados de entrada sejam demasiado grandes, milhares de unidades, por exemplo. As ligações só entre as primeiras camadas já terão milhares de pesos. Será requerida uma quantidade considerável de memória apenas para guardar estas variáveis e uma série de treinos maior. O segundo aspecto é que essa topologia não possui "invariância embutida com respeito à translação ou distorção local das entradas" ([LECUN et al., 1998](#), p. 5). Isso expressa como nas redes totalmente conectadas a topologia da entrada é desconsiderada. Por outro lado, entradas como imagens ou sinais (na representação tempo-frequência) têm uma correlação maior entre as variáveis adjacentes em tempo ou espaço, como é o caso do EEG. Com essas motivações, se farão algumas considerações sobre redes neurais convolucionais (CNN), que poderão se adequar melhor, devido à natureza do sinal.

CNNs foram concebidas para trabalhar com imagens, mas com alguns artifícios, pode-se processar sinais temporais com a mesma estrutura. A primeira diferença com relação às redes *feedforward* é a maneira como ocorre a fase de propagação. As redes convolucionais não são totalmente conectadas. Da camada de entrada para a primeira camada oculta existem algumas sinapses que ligam algumas unidades próximas da entrada com um neurônio dessa primeira camada. Cada uma das sinapses, assim como no perceptron, tem um peso (vide Figura [21](#)).

Figura 21 – *Local receptive fields*



Fonte: Adaptado de [Nielsen \(2017\)](#)

Essa janela de varredura de um conjunto de unidades com tamanho constante denomina-se de *local receptive field* (campo receptivo local, em tradução livre). Desse campo local os neurônios podem extrair "características visuais", segundo [LeCun et al. \(1998\)](#), como cantos, pontas ou arestas. E para que na camada oculta se possa extrair características específicas da imagem, que sejam identificadas mesmo com distorções ou deslocamentos, fixa-se a matriz de pesos desse campo receptivo local durante toda a varredura. A camada oculta que recebe o resultado dessa operação se denomina de mapa de característica (*feature map*).

Camadas ocultas completas de redes convolucionais possuem mais de um mapa de característica. Para cada característica adota-se uma matriz de pesos diferente. A construção de um mapa de características se dá através do deslocamento do campo receptivo local de unidade em unidade. Portanto haverá sobreposição de unidades nos campos locais próximos e a camada oculta será necessariamente menor do que a camada anterior (a menos que se utilize a técnica de *zero padding*). Essa operação é a que nomeia a rede, porque é similar a uma convolução.

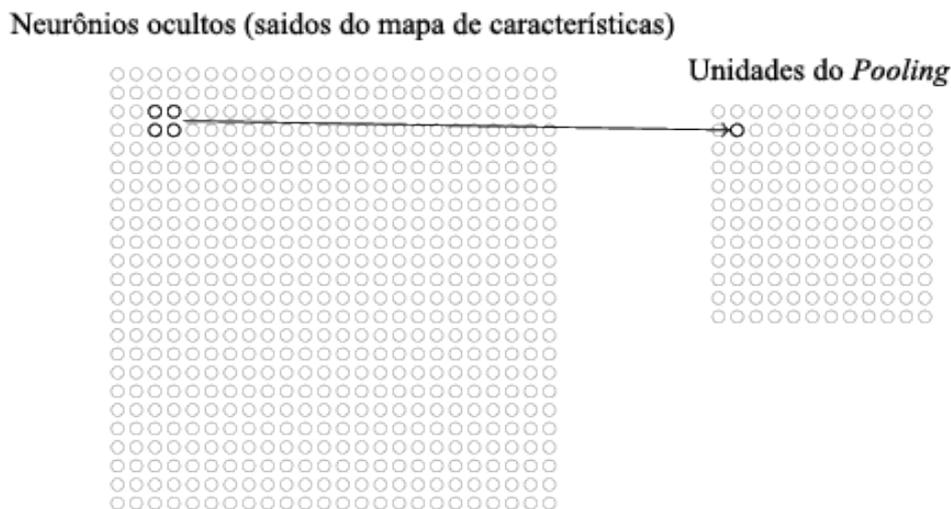
Com esse mecanismo reduz-se o número de pesos das sinapses. Como cada mapa de características utiliza um conjunto de pesos fixos (que com o bias se denominam *kernel*), a quantidade de coeficientes entre cada camada convolucional será a área do campo local multiplicado pelo número de mapas de características utilizado. Nielsen (2017) demonstra a equação para o cálculo de cada neurônio de um dos i mapas de característica como sendo

$$C_{i,j,k} = \varphi \left(b + \sum_{l=0}^n \sum_{m=0}^u w_{l,m} \cdot x_{j+l,k+m} \right) \quad (10)$$

onde φ continua sendo a função de ativação, x continua sendo o conjunto de entradas, b é o *bias*, comum para o conjunto e $n \times u$ é o tamanho do campo receptivo local.

Usualmente, depois de uma camada convolucional existem camadas de *pooling*, que nada mais são do que camadas de subamostragem para "reduzir a sensibilidade da saída a deslocamentos e distorções" (LECUN et al., 1998). Calcula-se a média de um conjunto de unidades do mapa de características ou escolhe-se o maior valor do conjunto e o resultado passa para uma nova camada (depois de passar pela função de ativação e de ter sido adicionado ao *bias*). Isso acontece para cada um dos mapas de características (Figura 22).

Figura 22 – Camada de subamostragem



Fonte: Adaptado de Nielsen (2017)

Às vezes ao invés de uma função de ativação, após a camada de *pooling*, pode ser utilizada uma unidade de retificação linear (*Rectified Linear Unit* - ReLU), que se descreve pela função

de $f(x) = \max(0, x)$. Isso se traduz em que $f(x)$ receberá o valor de x , caso seja maior que zero; se for menor que zero, receberá zero. Essa função em alguns problemas reduz o tempo de processamento (NIELSEN, 2017).

Sucessivas camadas de convolução e subamostragem formam uma estrutura piramidal, em que se aumenta a quantidade de camadas ocultas, mas se diminui o tamanho de cada camada. Ao final da rede, adota-se novamente uma estrutura totalmente conectada para gerar a saída e a partir dela realizar a retropropagação. A retropropagação para a rede convolucional se dá da mesma maneira que na topologia *feedforward*. A única ressalva é que ao calcular o fator de correção (Equação 6) para um *kernel*, o termo $\frac{\partial \mathcal{E}(n)}{\partial w_{kj}(n)}$ será a soma das derivadas parciais dos pesos de cada conexão (LECUN et al., 1998, p. 42).

2.6 TRANSFORMADA DE WAVELET

Os sinais de EEG, para que sejam passados de não estacionários para estacionários, necessitam ser transformados do domínio do tempo para a representação tempo-frequência. Dessa maneira não se terá uma representação insuficiente e esparsa da informação, como acontece no domínio do tempo, e nem se perderá resolução temporal, como acontece no domínio da frequência (MOHAMED et al., 2018).

Para tal, uma das transformadas que se pode utilizar é a Transformada de Wavelet Contínua (CWT). Tem como diferença da transformada de Fourier no tempo (STFT) que possui uma resolução tempo-frequência variável (MALLAT, 2009) e não é acometida pela compensação natural de resolução temporal em detrimento da resolução na frequência e vice-versa (HERMAN et al., 2008). Ambas são decompositoras locais de tempo-frequência, porém uma utiliza a função senoide e a outra uma função mãe de wavelet (mother Wavelet) para decomposição. Há diversas funções wavelet. A que mais se adéqua aos sinais de EEG é a de Morlet (HERMAN et al., 2008; MUTHONG; VATEEKUL; SRIYUDTHSAK, 2016; LEE; CHOI, 2018). Tem a sua função representada pela por (BRONIEC, 2016)

$$\Psi(t) = \pi^{-\frac{1}{4}} e^{-\frac{1}{2}t^2} e^{jkt} \quad (11)$$

onde t é a translação no tempo e k é uma constante arbitrária. Este sinal é transladado e dimensionado, convoluindo com o sinal analisado e o resultado é uma localização dos componentes espectro-temporais (HERMAN et al., 2008), representado na por

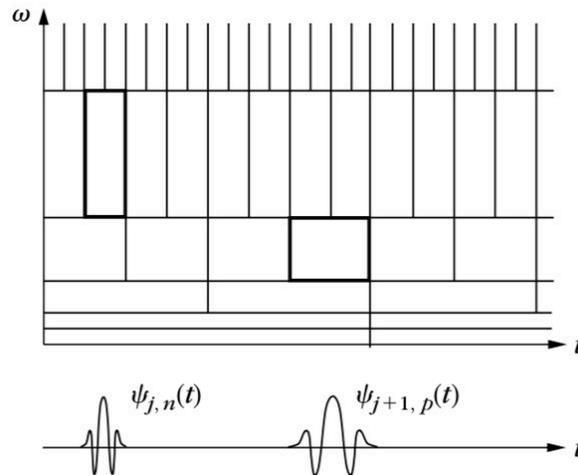
$$Wf(u, s) = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \Psi^* \left(\frac{t-u}{s} \right) \quad (12)$$

que mede a variação de f na vizinhança u proporcional ao dimensionamento s .

Quando o dimensionamento s reduz, a capacidade de decomposição temporal diminui, mas em troca é possível deduzir frequências mais altas no sinal. Desta maneira, as "caixas" de tempo-

frequência de Wavelet não tem sempre a mesma geometria, como as da STFT tem, mas aumentam seu alcance temporal quando seu dimensionamento permite a análise de baixas frequências e aumenta seu alcance frequencial quando seu dimensionamento permite análise de altas frequências, como representado na Figura 23.

Figura 23 – Caixas de tempo-frequência da transformada Wavelet



Fonte: Mallat (2009)

2.7 FILTROS

"Um filtro [...] ideal deve não apenas rejeitar completamente as frequências indesejadas, mas também ter sensibilidade uniforme para as frequências desejadas", definiu Butterworth (1930). O filtro Butterworth de ordem N tem a forma (NALON, 2009)

$$|H(\Omega)|^2 = \frac{1}{1 + (\Omega/\Omega_c)^{2N}}, \quad (13)$$

onde Ω_c é a frequência de corte e H é a função de transferência do filtro. Quanto maior a ordem do filtro, mais abrupto é o decaimento e mais se aproxima de um filtro ideal. Para um filtro de primeira ordem, o decaimento do filtro é de -6dB por oitava. Neste trabalho se utilizam filtros de 4ª ordem, com decaimento de -24dB por oitava. A faixa da banda que passa praticamente não possui oscilações e a faixa de banda que não passa tende a zero.

Para implementação dos filtros no MatLab utiliza-se a função `butter`, que recebe por parâmetros a ordem do filtro, a(s) frequência(s) de corte e o tipo, e retorna os polos, os zeros e o ganho da função de transferência do filtro projetado (MATHWORKS, 2018). Para os filtros passa-banda ou suprime-banda, a declaração da ordem do filtro é $N/2$. As frequências de corte devem estar em π radianos por segundo, portanto são calculadas como a divisão entre Ω_c e a metade da frequência de amostragem, $\Omega_c/(f_s/2)$. Assim os valores das frequências de corte devem residir entre 0 e 1, sendo 1 a frequência de Nyquist ($f_s/2$).

Os filtros implementados neste trabalho, um *notch* de 59Hz a 61Hz, para atenuar as frequências da rede e um passa-banda de 4 a 40Hz, para isolar as frequências de interesse para o processamento de MI, têm os seguintes comandos:

```
[p, z] = butter(2, [59, 61]/(250/2), 'stop')
e
[p, z] = butter(2, [4, 40]/(250/2), 'bandpass')
```

e para aplicar os filtros ao sinal desejado, deve-se utilizar a função `filter`. Se é necessário que uma variável y receba um sinal filtrado, denominado x , e os polos e zeros do filtro estão definidos pelos vetores p e z , respectivamente, a sintaxe que deve ser utilizada no MatLab é: `y = filter(p, z, x)`.

2.8 ESTADO DA ARTE

A seguir se apresentam alguns trabalhos que empreenderam classificar sinais de MI, como se fez neste trabalho, pré-processando os bio-sinais por Transformada Contínua de Wavelet (CWT), para que os resultados possam ser comparados no Capítulo 4, na Seção de Discussão de Resultados (Tabela 11):

- Na pesquisa de Hsu (2012) classifica-se movimento da mão direita e da mão esquerda. Toma-se 5s de coletas de MI e escolhe-se o segundo mais significativo da coleta. O bio-sinal extraído dos eletrodos C3 e C4 é pré-processados com a CWT e nele se aplica um filtro anisotrópico Gaussiano. Extraem-se características da representação Multi-resolução, geradas com a Transformada Wavelet Discreta (DWT), que são as entradas do classificador. Utiliza-se uma Rede Neural Fuzzy de Hopfield e a metodologia de *10-Fold Cross-Validation* para validação. Os resultados apresentados são referentes aos com apenas o 1s selecionado por serem melhores.
- Lee e Choi (2018) processam o bio-sinal dos eletrodos C3, Cz e C4 advindos de MI da mão esquerda e da direita com CWT, filtra-se as frequências (reduzindo o tamanho da imagem) e aplicam-se reduções por interpolações bi-cúbicas. A imagem resultante é imputada por uma CNN que possui uma camada convolucional uni-dimensional. Os resultados são gerados a partir da validação de *10-Fold Cross-Validation*. Utilizou-se duas wavelet mãe para avaliação, a de Morlet e a de Bump, mas a de Morlet possibilitou o melhor resultado e este é o apresentado.
- Em sua tese de mestrado, ELTVIK (2018) pré-processa os dados de MI para movimento de braço direito e de pé esquerdo por Transformada Contínua de Wavelet, com a wavelet de Ricker. Utiliza, de um set de 118 canais, 8 canais: Fp1, Fp2, F3, F4, C3, C4, O1 e O2.

Também aqui os resultados são gerados por *10-Fold Cross-Validation* e processados por CNN. Apresenta-se os resultados da melhor arquitetura.

Entre outros trabalhos passíveis de comparação que também fazem classificação do sinal de MI, mas pré-processam os bioSSinais com STFT, estão o de [Tabar e Halici \(2016\)](#) e o de [Wang et al. \(2018\)](#). Ambos utilizaram CNN para classificar os dados, bioSSinais de MI advindos de movimento nas mãos e os eletrodos C3, Cz e C4 para seu *dataset*. O método de avaliação é o *k-Fold Cross-Validation*.

Há ainda alguns artigos que investigam a classificação com mão direita, mão esquerda e também o *baseline*. [Batres-Mendoza et al. \(2017\)](#) propõe um método de *Quaternion-Based Analysis* para processamento dos sinais, utilizando os eletrodos F3, F4, FC5 e FC6. A validação dos resultados é feita por 10 Árvores de Decisão e são utilizados *holdouts* para cada estágio.

[Lindig-Leon et al. \(2017\)](#) vão ainda mais além tentando classificar 8 ações. São combinações de movimento de mão direita, mão esquerda, pés e *baseline*. Converte-se o sinal de MI para dessincronização relacionada a eventos (ERD) e sincronização relacionada a eventos (ERS) e se classifica por análise discriminante linear (LDA) as informações de 26 eletrodos.

O trabalho proposto apresenta um modelo experimental que envolve a técnica de Eletroencefalografia com bioSSinais espontâneos de MI. Estes sinais são tratados com filtros e transformados para o domínio tempo-frequência por Wavelets. Desta forma obtêm-se sinais representados com informações no tempo e na frequência. As matrizes 2D geradas no pré-processamento são entregues à Rede Neural arquitetada para procurar características no espectro ao longo do tempo, por camadas convolucionais uni-dimensionais. Os resultados de acurácia da rede são estudados através de diversos métodos de avaliação e posteriormente são comparados quanto ao seu janelamento e relevância estatística. No capítulo a seguir entram-se nos detalhes de execução e experimentação realizados neste trabalho.

3 MATERIAIS E MÉTODOS

Neste capítulo serão expostos os materiais e as metodologias para registro dos sinais de EEG, armazenamento dos dados, pré-processamento do sinal e treinamento do classificador para obter os resultados finais. As ferramentas tecnológicas de *hardware* e *software* utilizadas no projeto, bem como os dados dos participantes que estão sendo utilizados na formação de uma base de dados, são apresentados junto à proposta metodológica adotada para a realização experimental. O paradigma do MI é inicialmente especificado, com seus detalhes técnicos e práticos. Na sequência descritiva, inclui-se o pré-processamento dos dados e também o sistema para o classificador.

3.1 MATERIAIS

A plataforma de coleta deste experimento é constituída pelo OpenBCI juntamente com o *software* para sincronização de estímulos, o OpenViBE. Todas as coletas foram realizadas em um MacBook Pro, Retina Display 15 polegadas, versão 2013. O processador é um Intel Core i7 de 2,3GHz. Os sistemas operacionais que rodam neste computador são o macOS High Sierra versão 10.13.6 e, através do Virtual Box 5.2.18, uma máquina virtual Windows 7 Professional 64 bits. O sistema da Microsoft foi instalado para poder coletar a partir do OpenViBE. O pré-processamento e o treinamento da rede foram executados no programa MatLab R2018a.

3.1.1 Participantes

Quatro voluntários saudáveis constituíram a base de dados de EEG utilizados neste trabalho. Um deles possuía experiências anteriores com a gravação de sinais cerebrais, mas nenhum tinha feito um exercício de MI. Dentre eles, 3 eram homens e uma mulher; todos eram destros. A Tabela 2 sumariza as informações principais de cada um e a quantidade de baterias de testes realizadas. A Folha de Rosto para pesquisa com seres Humanos aprovado pelo Sistema da Plataforma Brasil para esta pesquisa se encontra no Anexo A (CAAE 90590318.9.0000.5341). Os indivíduos I2 e I3 não foram incluídos no *dataset*, porque após a análise de seus dados pessoais verificou-se que eram indivíduos canhotos. Uma vez que a bibliografia, em sua maioria, utiliza apenas indivíduos destros, os dados de I2 e I3 foram descartados da base de dados.

Tabela 2 – Tabela de participantes constituintes da base de dados.

Indivíduo	Idade	Sexo	n. Baterias
I1	22	Masc	3
I4	23	Masc	2
I5	55	Fem	2
I6	56	Masc	2

O indivíduo I1 é um estudante de engenharia. Na época das gravações tinha cabelo curto. Os experimentos realizados com este indivíduo ocorreram nos dias da penúltima semana de outubro (de 2018). Os horários de coleta variaram. No primeiro dia aconteceram entre as 22:00 e 23:00, e nos 2º e 3º dia das 9:30 às 10:00. O ambiente utilizado para gravação possuía pouco ruído e boa iluminação natural durante a manhã. No período da noite, as luzes foram apagadas, permanecendo apenas a luminosidade do monitor. Este sujeito reportou leve sonolência no segundo dia.

O indivíduo I4 e I5 fizeram as coletas no mesmo período e local. As gravações foram feitas em dias consecutivos da primeira semana de novembro, em horário próximo às 14:30 e 15:00. O ambiente possuía ruído baixo vindo da rua em alguns momentos, mas no geral era silencioso. A iluminação natural era boa e não foram utilizadas outras fontes de luz.

O I4 é universitário, estudante de engenharia. Seu cabelo estava aparado nos dias de coleta. Durante as gravações reportou dificuldade em evitar piscadas e nos últimos testes mencionou leve sonolência. Para ele foi feita uma coleta extra de 10 amostras por lado para compensar um suposto deslocamento de eletrodo, que posteriormente mostrou-se em ordem. Também citou uma maior facilidade de realizar o MI com o braço direito.

O indivíduo I5 é uma Professora universitária. No dia das gravações tinha cabelos longos que tiveram de ser penteados de modo que os eletrodos pudessem ter contato com o escalpo. Não mencionou nenhuma sonolência ou dificuldade com os testes. Anteriormente à coleta para este trabalho, já havia gravado EEG em outras ocasiões.

O indivíduo I6 é gerente de uma fábrica. Possui cabelo ralo, facilitando a colocação dos eletrodos. Durante os testes pôde notar-se sonolência. Quando indagado, reportou que todos os estímulos foram devidamente compreendidos e executados, apesar da sonolência. Os testes foram realizados em dias consecutivos, em local naturalmente bem iluminado e silencioso. O primeiro dia de gravações ocorreu por volta das 18:00 e o segundo das 16:30. Os dois dias de gravação também se deram na primeira semana de novembro.

3.1.2 OpenBCI: Sistema de EEG

O sistema utilizado para captar as ondas de EEG foi o OpenBCI Cyton[®] com comunicação via Bluetooth[™]. É uma placa para reconhecimento de biopotenciais *open source* que possui 8 canais. Dispõe de um processador PIC32MX250F128B de 32 bits e um conversor da Texas Instruments[®] ADS1299-x com taxa de aquisição de 250 amostras por segundo (*Samples per Second* - SPS) a 16 kSPS. A resolução dos seus canais é de 24 bits e sua taxa de amostragem entregue é de 250 Hz. Para cada canal do conversor Analógico-Digital há um filtro digital passa-baixa sinc 3 (INSTRUMENTS, 2012). Tem ganho programável, individual para cada canal, de 1, 2, 4, 6, 8, 12 ou 24. Possui também de um acelerômetro LIS3DH de 16 bits e uma entrada para cartão Micro-SD para gravação de dados.

Conta com dois sistemas de referência. Existe a possibilidade de referência geral para os canais ou a de referência individual para cada canal. Esta flexibilidade permite a aquisição de mais de um tipo de biossinal simultaneamente. Para isso existem os pinos SRB que alternam a funcionalidade. Caso estejam ligados no SRB negativo (pino inferior), todos os pinos negativos de cada canal serão referenciados ao primeiro. Se o SRB estiver em positivo (pino superior), é possível referenciar individualmente cada canal, sendo o pino negativo a entrada e o pino positivo a referência (OPENBCI, 2017a). No presente trabalho, utilizam-se apenas 6 canais dos 8 disponíveis, com ganho de 24 em todos os eletrodos, a uma taxa de aquisição de $f_s = 250\text{Hz}$. Cada entrada é referenciada ao pino SRB negativo.

Os eletrodos utilizados são disco CASTED banhados em ouro e com 200cm de cabo (Spes Medica, REF.: DSGS202600). Os pontos dos eletrodos escolhidos são os F4, C4, P4, F3, C3 e P3. Estão respectivamente conectados às entradas N1, N2, N3, N4, N5 e N6 da placa. O terra e o bias foram ligados aos pontos A2 e A1, nesta ordem. Todas as posições respeitam ao sistema 10-20 (conforme representado na Figura 14 da Seção 2.3).

3.1.3 Sistema de Sincronização de Estímulos e Gravação de dados

Para a exibição de estímulos e sincronização dos tempos de exibição com os sinais coletados, utiliza-se um *software* para desenvolvimento, teste e uso de BCI: o OpenViBE® (OPEN-VIBE, 2013). Para instalação e *setup* do OpenViBE seguiu-se as instruções fornecidas pelo site da OpenBCI (2017b). O sistema pode ser utilizado tanto para coleta de dados, para processamento de sinais e para execução de comandos. A sua estrutura se dá em blocos de funcionalidades que, ligados, executam diversos algoritmos. Este projeto utilizou-o com a finalidade de capturar, filtrar e armazenar os dados, sincronizando-os com os estímulos exibidos.

Dentro das possibilidades do *software*, existem alguns *presets* desenvolvidos para aplicações consolidadas. Dentro das opções há um conjunto de arquivos específicos para captação de MI, denominado de "*Motor Imagery BCI*". O programa utilizado neste trabalho foi gerado a partir deste *preset*. O arquivo modificado, mostrado na Figura 24, contém em um visualizador do experimento, chamado "*Graz visualization*", que mostra o experimento decodificado pelo bloco "*Graz Motor Imagery BCI Stimulation*" a partir de um código `.lua`. Essa visualização pode conter um fundo preto, uma cruz verde e setas indicativas vermelhas (mais detalhes na Seção 3.2.2). O bloco "*Aquisition client*" capta os dados diretamente do OpenBCI, e o bloco que registra os dados obtidos é o "*CSV File Writer*". Ainda há dois blocos para filtragem temporal *online*, os "*Temporal Filter*", e os blocos para apresentação dos sinais captados, os "*Signal display*".

Um dos filtros é um *Notch Filter* Butterworth de 4ª ordem, de 59 a 61Hz para filtrar as frequências de rede elétrica. O outro um passa-banda Butterworth de 4ª ordem, de 0,5 a 30Hz. Salvou-se também os sinais em um arquivo com os dados sem filtragem para o caso de ser necessário uma filtragem offline diferente.

Os arquivos salvos em formato `.csv` apresentam-se com 16 colunas:

Coluna 1: tempo, iniciando em $0s$, com passo de $1/f_s$, ou seja, $0,004s$.

Coluna 2: as épocas às quais as amostras pertencem, sendo que cada época se conclui a cada segundo.

Coluna 3 a 13: onze colunas de dados, sendo as oito primeiras referentes às entradas dos eletrodos e as últimas três às componentes x, y, z geradas pelo acelerômetro.

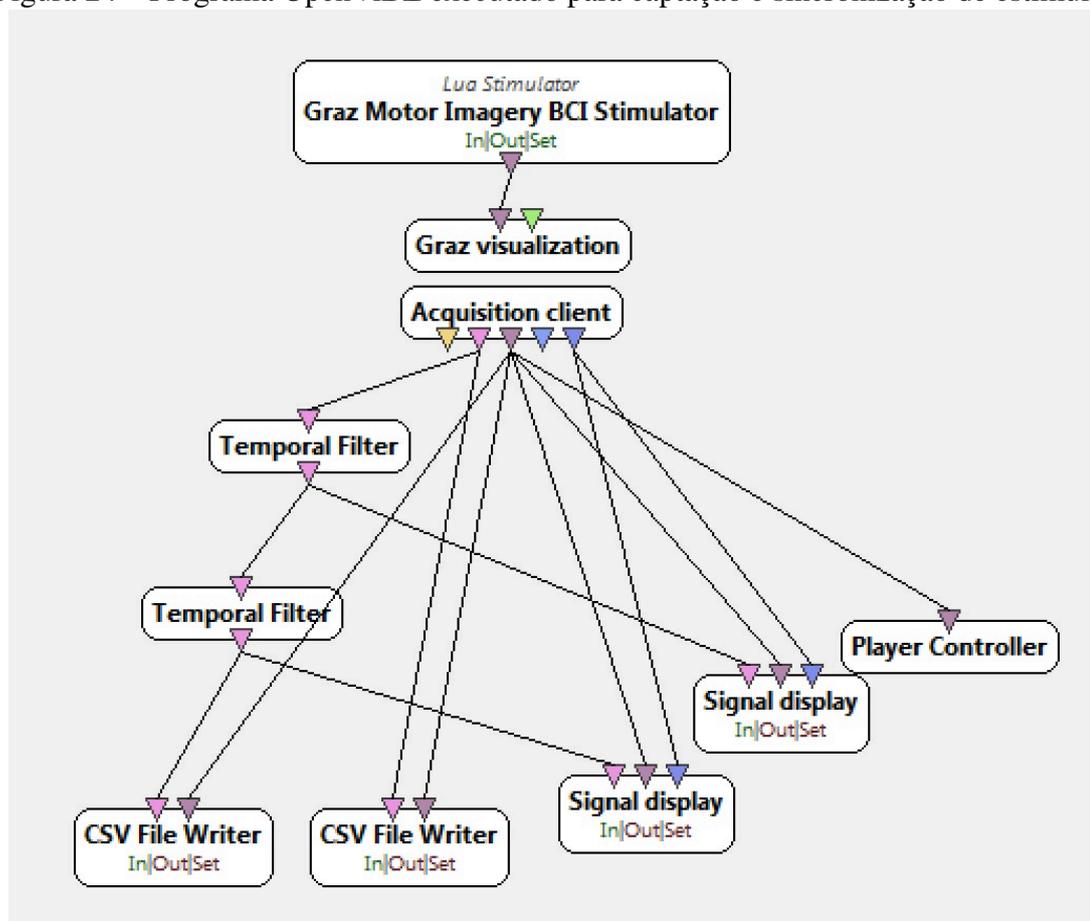
Coluna 14: os identificadores dos *triggers*.

Coluna 15: os momentos em que os *triggers* ocorreram.

Coluna 16: duração dos *triggers*. Todos os estímulos utilizados tinham duração infinitesimal.

Desta tabela utiliza-se as colunas 1, 3 a 8, 14 e 15.

Figura 24 – Programa OpenViBE executado para captação e sincronização de estímulos

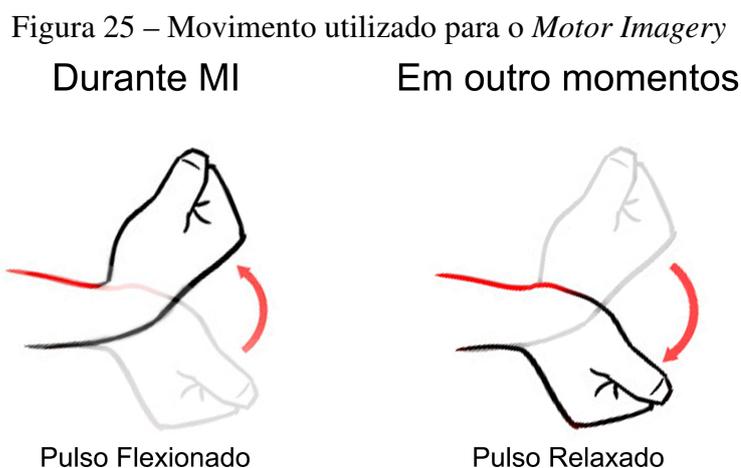


Fonte: O Autor.

As colunas 3 a 8 correspondem, em ordem, às informações dos eletrodos F4, C4, P4, F3, C3 e P3. Na coluna 14, os triggers relevantes para este trabalho são o de início do *Baseline*, $0x8007$ (32775_{10}), fim do *Baseline*, $0x8008$ (32776_{10}), início de estímulo de mão esquerda, $0x301$ (769_{10}), e início de estímulo de mão direita, $0x302$ (770_{10}).

3.2 METODOLOGIA

Nas coletas foram gerados sinais de MI para movimento da mão direita e da mão esquerda. Aos indivíduos explicou-se sobre o MI que deve-se procurar sentir o movimento, sem executá-lo, que o movimento imaginário sentido será apenas do membro indicado (antebraço/punho) em flexão na direção indicada, deve-se manter a posição imaginária durante todo o período do estímulo indicado e os movimentos reais devem ser contidos. Neste experimento utilizou-se uma flexão de punho, como é mostrado na Figura 25.



Fonte: Adaptado de [PT-Helper \(2015\)](#)

3.2.1 Preparação para coleta de dados

Antes do primeiro dia de testes, cada um dos participantes assinou o Termo de Consentimento (Anexo B) aprovado pelo Comitê de Ética da Universidade de Caxias do Sul, onde foi esclarecido que não haveria danos ou riscos à saúde dos voluntários durante as coletas. Também receberam instrução sobre os testes, tiraram dúvidas iniciais sobre o experimento, sua aplicação e demais esclarecimentos técnicos.

Os participantes sentaram-se em uma cadeira posicionada junto a uma mesa onde o monitor de um computador foi colocado a uma distância de 100cm da visão do colaborador da pesquisa. Os antebraços dos voluntários foram acomodados lateralmente e paralelamente sobre a mesa de forma relaxada para a execução dos testes, para colocação dos eletrodos. No escalpo foram colocados os eletrodos de forma individual. O próprio pesquisador experimental utilizou a touca de eletrodos na configuração Jasper 10-20 para medir os pontos desejados. Também foram fixados nos lóbulos das orelhas com fita microporosa os eletrodos da referência e do *bias*. Antes de aderi-los à pele, procurou-se limpar a área com gaze umedecida com álcool. A concavidade dos eletrodos foi preenchida com solução condutora Carbogel[®] previamente à sua colocação para minimizar a impedância (mantida abaixo de 5k Ω).

Após, os cabos foram fixados com fita na parte traseira da cadeira para minimizar ruídos por movimentação e o OpenBCI ficou apoiado em uma superfície onde não há nenhum equipamento ligado à rede elétrica. Os participantes foram instruídos a colocar o antebraço, com as palmas das mãos voltadas para cima, sobre a mesa, conforme é mostrado na Figura 26.

Figura 26 – Foto ilustrativa do posicionamento do participante durante as coletas



Fonte: O autor.

Após equipar o sujeito com o EEG, solicitou-se que olhasse fixamente para o monitor sem desviar o olhar e sem piscar; que movimentasse a cabeça o mínimo possível e também que não engolisse saliva ou pigarreasse. Caso fosse de extrema necessidade lubrificar os olhos ou engolir, pediu-se que o fizesse nos intervalos em que não houvesse sinal útil. Seguido das instruções iniciais, começou-se a bateria de testes.

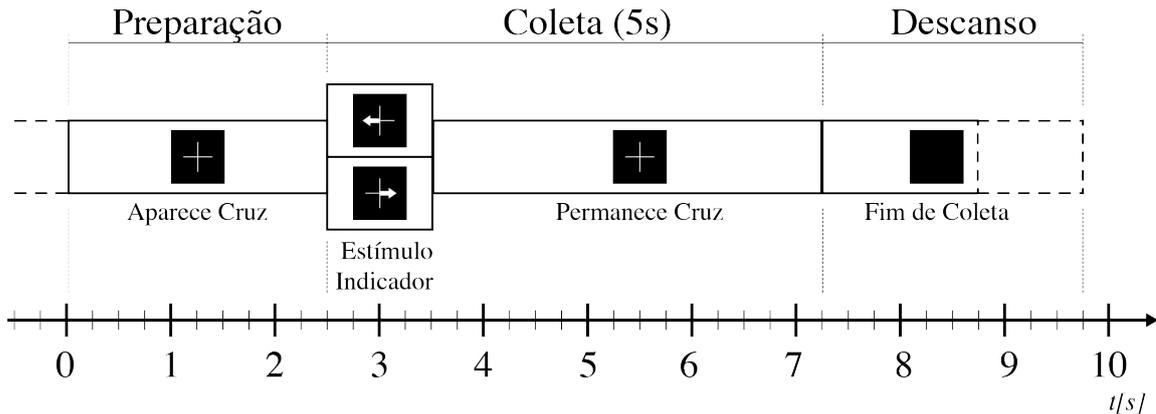
3.2.2 Coleta dos sinais e paradigma do MI

Cada bateria/sessão de testes consistiu-se de 80 coletas (40 para o lado esquerdo e 40 para o lado direito). Apenas uma bateria foi realizada por dia. Cada bateria foi formada de 3 rotinas de coletas. A rotina inicia com 5 segundos de inicialização e 10 segundos de captação de sinais de base (momento prévio à tarefa, no qual solicitou-se que o participante procurasse relaxar). Esses 15 segundos foram chamados de *baseline* e receberam o rótulo '0'. Em alguns experimentos, 5 desses segundos iniciais foram descartados e em outros 10s, devido à grande quantidade de ruídos.

Logo após iniciou-se os estímulos para MI. No fundo preto aparecia uma cruz durante 2,25s. Em seguida o estímulo, representado por uma seta vermelha para a direita ou para a esquerda, indicava ao usuário se deveria imaginar o movimento da mão direita (rótulo '1') ou esquerda (rótulo '2'). Esse estímulo ficava na tela durante 1,25s e depois apenas a cruz permanecia na tela. A partir deste momento, o usuário tinha mais 3,75s para realizar o MI. Os participantes

eram instruídos a começar seu MI assim que a seta aparece. Desse modo, teve-se 5s de MI por estímulo. Quando a cruz verde desaparecia da tela o indivíduo devia cessar o seu MI para aquele braço e esperar o início do próximo estímulo. Essa espera variava de 1,5s a 2,5s para que não houvesse um condicionamento do cérebro. A Figura 27 mostra um esboço do experimento. Esse ciclo foi repetido a quantidade de vezes estipulada na rotina para cada um dos lados.

Figura 27 – Linha do tempo de um estímulo



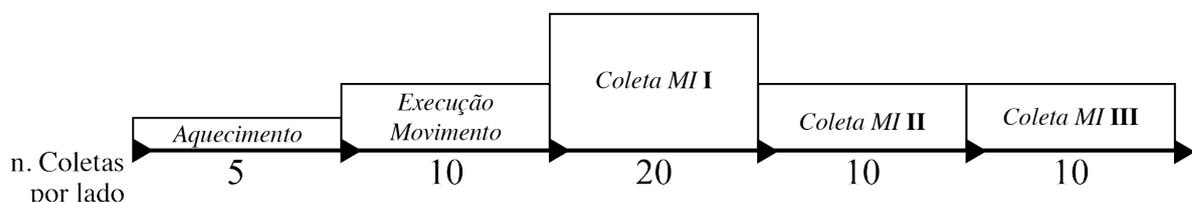
Fonte: O Autor

A cada sessão o participante realizou 5 rotinas de coletas, como ilustrado na Figura 28. A primeira rotina, chamada de "Aquecimento", consistia de 5 estímulos para cada lado coletando sinais de MI. Se a cabo desta sequência o participante tivesse dúvidas ou requeresse uma nova tentativa, a primeira sequência era repetida, com intuito de clarificar e compenetrar o indivíduo ao máximo. Estas coletas foram descartadas.

A seguinte rotina foi realizada com o movimento de fato. O participante realizou o movimento da mão a cada estímulo a fim de sentir a musculatura e reafirmar a sensação antes da coleta do MI. Este arquivo foi salvo para futuras comparações e classificações.

Logo após, se realizaram as 3 rotinas de coleta de MI. A primeira consistiu em 20 estímulos para cada lado, totalizando 40 estímulos. A segunda e a terceira apresentavam 10 estímulos para cada lado, totalizando outros 40 estímulos. A primeira coleta foi mais extensa com intuito de aproveitar o indivíduo recém treinado e descansado mentalmente. As outras coletas foram mais curtas para evitar sonolência e desvio de atenção.

Figura 28 – Estrutura de uma bateria de testes

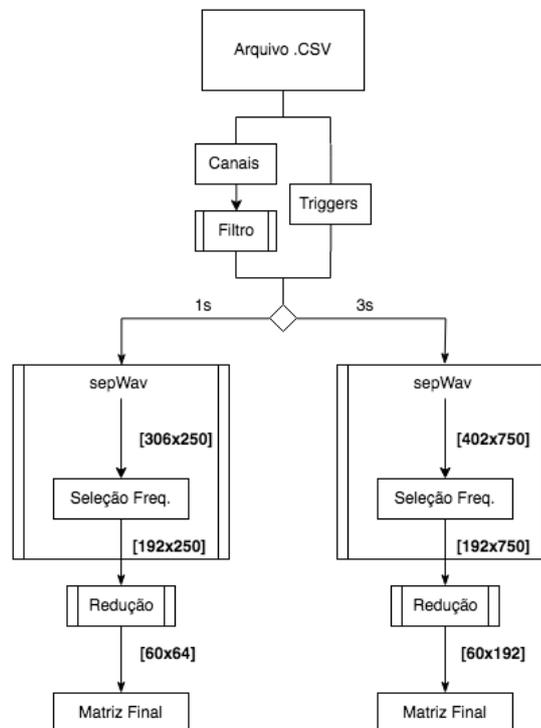


Fonte: O Autor

3.2.3 Pré-Processamento

No MatLab, os arquivos `.csv` com informação sem filtragem foram importados como tabelas. O algoritmo a partir da importação das tabelas até a geração da imagem está representado na Figura 29. As colunas com informações temporais e dos canais (1 a 13) foram separadas das colunas com informações de *trigger* (14 e 15). Nas colunas 14 e 15 ordenou-se os tempos e os rótulos dos gatilhos e criou-se os vetores `r_idx`, `l_idx`, `bli_idx` e `ble_idx`, que contêm os índices onde começam os estímulos da mão direita, da mão esquerda, início e final do *baseline*, respectivamente. Estes vetores foram utilizados para encontrar os intervalos de tempo correspondentes aos estímulos.

Figura 29 – Fluxograma de algoritmo de geração de imagens



Fonte: O Autor

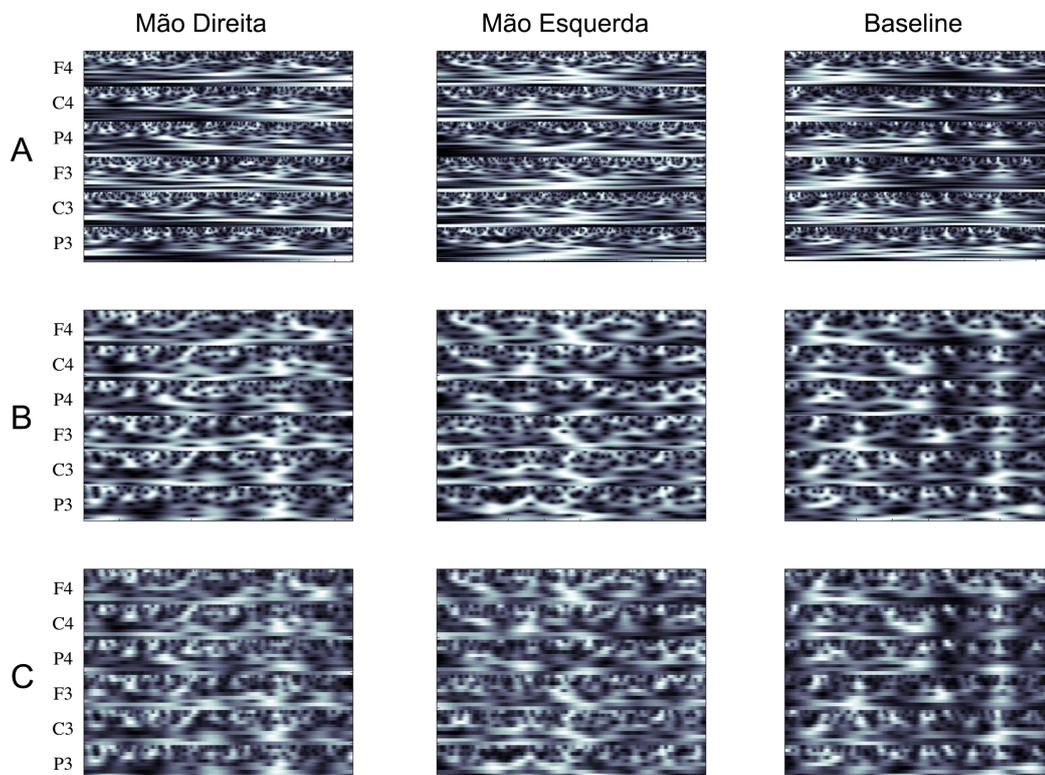
Às informações dos canais foram aplicados dois filtros Butterworth de 4ª ordem. Um de 59 a 60Hz *notch* com função de diminuir a influência da frequência da rede (60Hz) nas medições e um outro de 4 a 40Hz passa banda para isolar apenas as frequências de interesse. Não foram utilizados os arquivos filtrados gerados diretamente do OpenViBE, porque foi necessário passar de 30Hz para 40Hz a frequência de corte no passa banda.

A função criada, chamada `sepWave`, faz o seccionamento, transforma o sinal unidimensional para tempo-frequência (t-f) e gera o vetor de rótulos/verdade. Do tempo de captação dos estímulos foram retirados o primeiro e o último segundo, remanescendo de $t = 1s$ a $t = 4s$ para processamento. Do tempo utilizado para o *baseline* retirou-se os 2s iniciais. O sinal foi

nivelado subtrair-se a média para cada canal. O intervalo de tempo de cada canal foi convertido em uma matriz através da função `cwt`. Todos os canais foram concatenados um abaixo do outro e a função retornava a matriz.

Dois tipos de janelamento foram utilizados, o primeiro de 1s com deslocamento de 1s e o segundo de 3s, ambos sem sobreposição. Como demonstrado na pesquisa de [Lu et al. \(2017\)](#), o janelamento com sobreposição reduz a acurácia dos resultados e por esse motivo foi descartado. Se o íterim fosse de 1s (250 amostras), gerava-se uma matriz de $[51 \times 250]$. Se fosse de 3s (750 amostras), gerava-se uma matriz de $[67 \times 750]$ para cada canal (Figura [30-A](#)).

Figura 30 – Matrizes Tempo-Frequência geradas. (A) Matriz gerada pela função `cwt`. (B) Matriz com as bandas de frequências de interesse de 4 a 35Hz. (C) Matriz reduzida por interpolação cúbica.



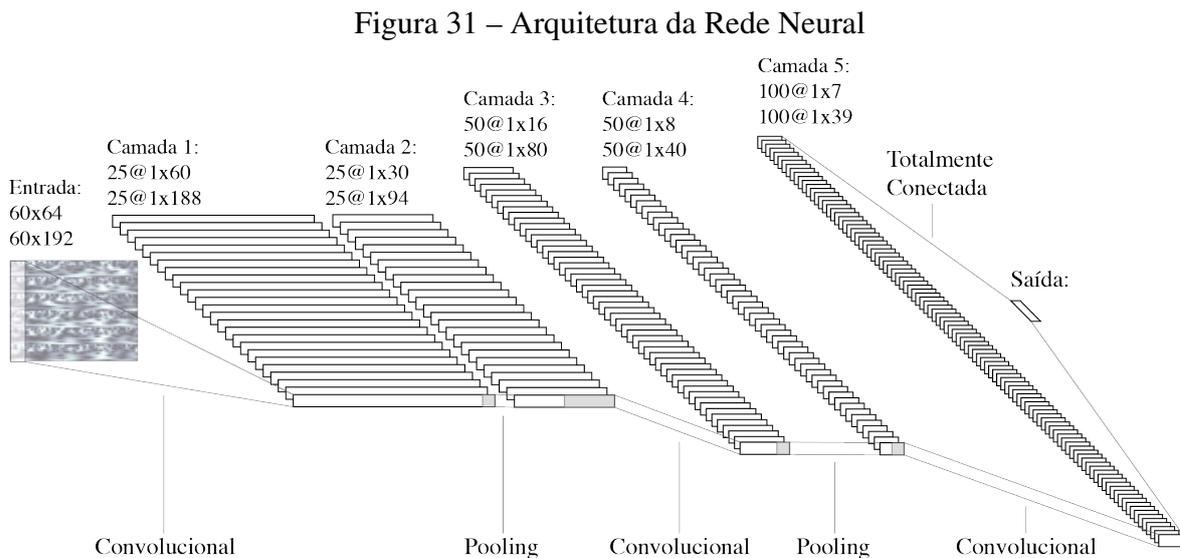
Fonte: O Autor

Dessa matriz foram utilizadas apenas as frequências de 4 a 35Hz. Isso diminuiu a dimensão da frequência a 32 unidades em qualquer um dos casos. A matriz concatenada final retornada pela função tinha $[192 \times 250]$ ou $[192 \times 750]$ de tamanho (Figura [30-B](#)).

Por fim, a imagem passava por uma redução dimensional por interpolação cúbica. Nesta técnica varre-se a matriz em conjuntos de $[4 \times 4]$ e resulta que cada pixel é a média ponderada desse intervalo. Na frequência, a informação de cada canal foi reduzida a 10 unidades e no tempo, a cada 0,5s se utilizavam 32 unidades. Dessa maneira as matrizes de janelas 1s e 3s ficaram reduzidas a $[60 \times 64]$ e $[60 \times 192]$, respectivamente.

3.2.4 Arquitetura da Rede Neural Convolucional

A topologia da RN utilizada consiste em 3 camadas convolucionais e uma totalmente conectada (Figura 31). A primeira, como em Lee e Choi (2018), é uma camada convolucional 1D para "avaliação das características espectrais ao longo do tempo" de dimensões $[60 \times 5]$, com 25 mapas de características. É seguida de uma camada ReLU e uma camada de *max pooling* de $[1 \times 2]$.



Fonte: O Autor

A segunda camada convolucional produz 50 características e tem tamanho $[1 \times 15]$ e também é seguida de uma camada ReLU e uma *max pooling*. A terceira produz 100 características, tem tamanho $[1 \times 2]$ e é seguida apenas de uma camada ReLU. Em seguida há uma camada totalmente conectada e a camada de classificação com 2 ou 3 saídas.

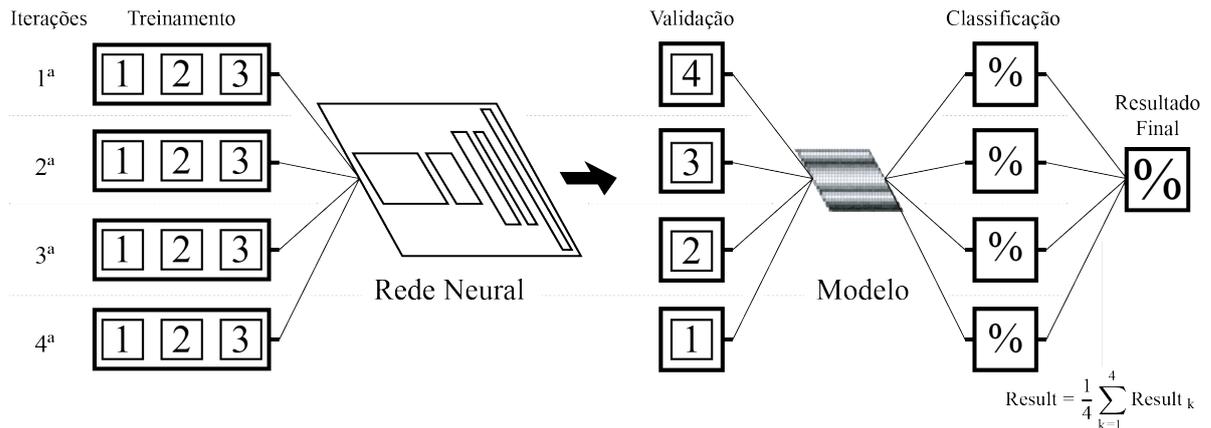
A taxa de aprendizado é inicialmente 0,02, mas a cada 7 épocas de treinamento decai a um fator de 0,5. Em todos os treinamentos a RN convergia entre 30 e 37 épocas. Porém, por segurança estipulou-se 100 épocas de treinamento o máximo permitido. A toda época os dados de treinamento são embaralhados.

3.2.5 Métodos de Avaliação e figuras de mérito

São avaliados neste trabalho dois tipos de janelamento sobre os 3s de MI escolhidos. O primeiro janelamento é de 1s, deslocado a cada 1s; o segundo janelamento é de 3s. Também é feita uma avaliação com e sem o *baseline*. Se faz essa distinção, porque, no caso de embarcar-se o sistema, seria necessário que pudesse identificar também quando o cérebro está em "modo de espera". Sobre cada uma dessas possibilidades aplicam-se 4 procedimentos de avaliação, rearranjando a base de dados.

O primeiro é o *Leave-One-Subject-Out Cross-Validation* (LOSOCV). Esse método mostra a capacidade de transferência de características de indivíduo para indivíduo do modelo. Treina-se com todos os sujeitos, menos um e se valida com este sujeito excluído, como representado na Figura 32. Desse modo, se há alguma característica comum a todos os indivíduos, inclusive o que não está dentro da base, esse procedimento evidenciará isto.

Figura 32 – Procedimento Leave-One-Subject-Out Cross-Validation



Fonte: O Autor

O segundo método é o de separação de 2/3 de todos os arquivos para treinamento e o outro 1/3 para validação, conhecido como *holdout*. Todos os indivíduos são utilizados para treinamento. Pode haver dependência temporal nos dados para o janelamento de 1s, porque os dados são separados aleatoriamente após serem processados. Por outro lado, esse método mostra a capacidade de generalização do modelo matemático para o janelamento de 3s. Isso ressaltará as características do conjunto de indivíduos utilizado.

O terceiro utiliza a sessão de movimentação de todos os indivíduos para validação. Neste procedimento procura-se avaliar se há alguma semelhança entre o sinal gerado pelo movimento de fato e o MI.

O último procedimento faz a avaliação indivíduo a indivíduo. Utiliza-se 2/3 dos dados de cada indivíduo para treinamento e 1/3 dos dados do mesmo indivíduo para validação. Assim é possível avaliar se o modelo é capaz de moldar-se a características específicas de cada sujeito. De maneira semelhante à metodologia do *holdout*, pode haver dependência temporal entre os dados de treinamento e os dados de validação para o janelamento de 1s.

Para avaliação dos resultados, a figura de mérito mais utilizada nas pesquisas do estado-da-arte é a acurácia. Também é adotada aqui para avaliação, calculada de acordo com

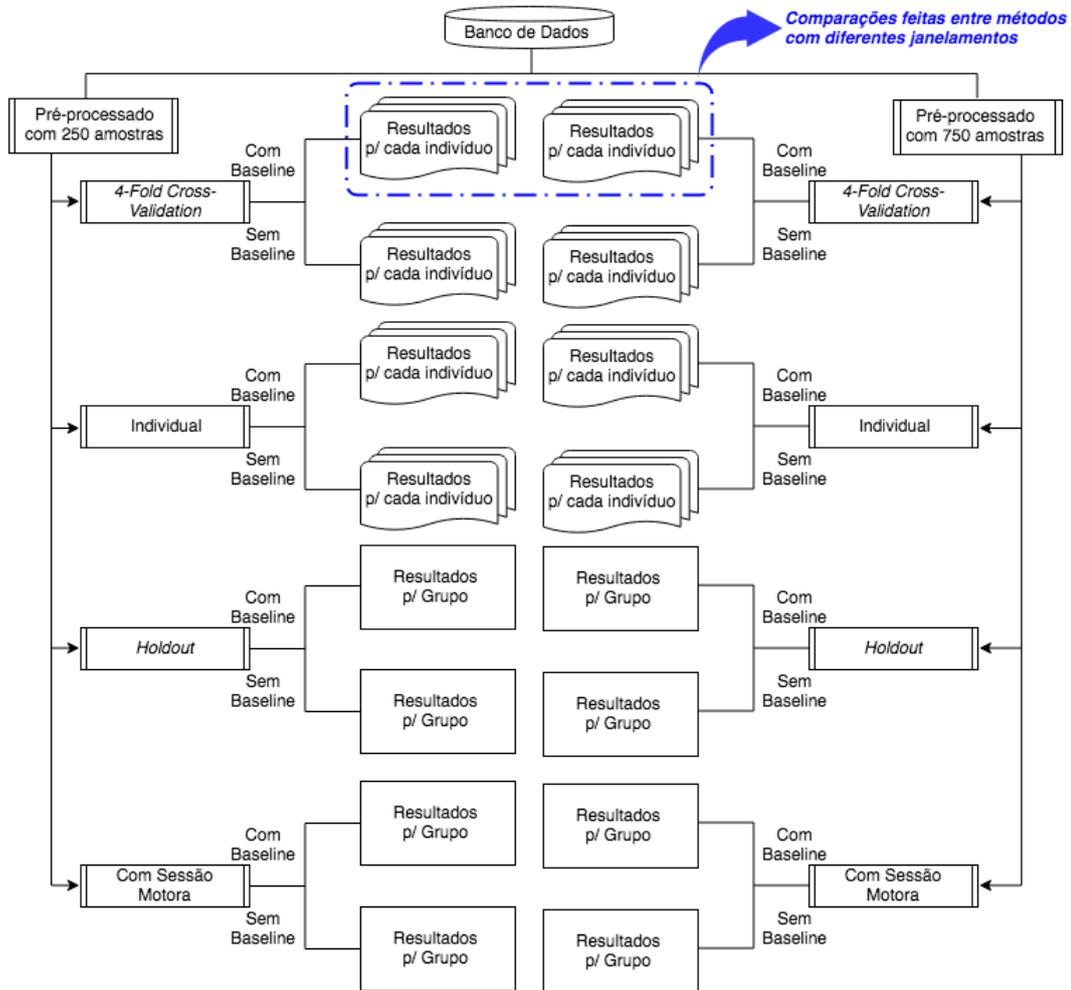
$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (14)$$

Todas as avaliações são repetidas 5 vezes e o resultado exposto será a média delas.

4 RESULTADOS

Neste capítulo se discutem os resultados obtidos através dos métodos de análise. Para cada um dos métodos se fará uma comparação entre os dois tipos de janelamento utilizados, com e sem o *baseline*, como é representado no fluxograma de resultados da Figura 33. Primeiramente se discute da validação cruzada, em seguida da análise individual, depois do *holdout* e por fim dos resultados obtidos comparando os ensaios de MI com os de movimentação de fato. Posteriormente se tratará dos resultados em um geral e se confrontará com os resultados do estado da arte.

Figura 33 – Fluxograma dos resultados gerados



Fonte: O Autor

Para toda a comparação entre resultados com janelamento de 1s e 3s utilizou-se o teste t de Student para avaliar a significância estatística com nível de significância de 10%. Calculou-se o valor-p como feito por Saa e Çetin (2012), Lu et al. (2017) e Wang et al. (2018) para comparação entre métodos e por Mahmoudi e Erfanian (2006) para comparação entre sessões.

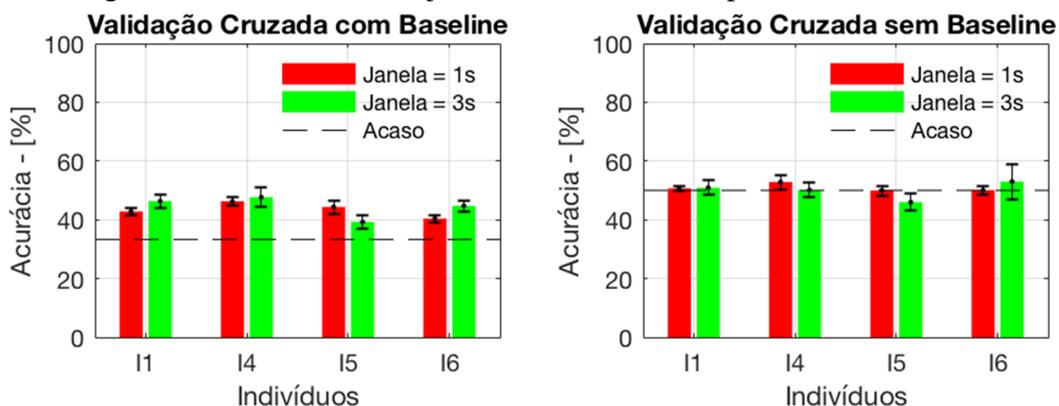
Para verificar se a mudança do janelamento tem alguma significância estatística sobre os resultados da diferença da classificação, calculou-se o valor-p mostrado na Tabela 5. O valor médio indica que, para os resultados sem *baseline* (p-valor = 0.1867), não se pode descartar a hipótese nula de que os conjuntos de resultados são estatisticamente similares, enquanto que para os resultados com *baseline* pode-se, devido ao seu p-valor = 0.0519.

Tabela 5 – p-valor entre as acurácias pelo método de LOSOCV com janelas de 1s e 3s.

<i>p-Valor</i>		<i>Com Baseline</i>		
I1	I4	I5	I6	\bar{x}
0.0037	0.1972	0.0040	0.0027	0.0519
<i>p-Valor</i>		<i>Sem Baseline</i>		
I1	I4	I5	I6	\bar{x}
0.4328	0.1208	0.0066	0.1452	0.1867

Em ambos os casos, com 1 e 3 segundos, os resultados com *baseline* ficaram acima da taxa de classificação ao acaso, que neste caso é de 33.3%. A tendência geral percebida é a de que com uma janela maior de amostras haja uma melhoria no percentual da acurácia. A média das médias passa de 43.5% para 44.5%, que corresponde a um aumento relativo de 2.2% na acurácia. Na Figura 34 ilustra-se os resultados de uma forma gráfica. Com isso, é possível dizer que na classificação de MI com o *baseline* pelo método de validação cruzada no *dataset*, a janela de amostras influencia positivamente quando aumenta de tamanho.

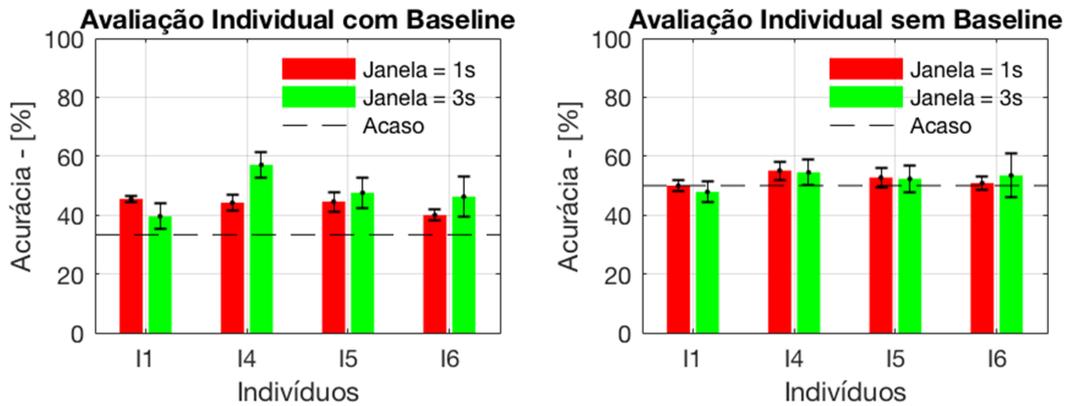
Figura 34 – Acurácia entre janelamento de 1s e 3s para método LOSOCV.



Fonte: O Autor

Para os resultados sem *baseline*, por outro lado, nem todos os resultados superaram a taxa de classificação ao acaso, de 50%. A média do desvio padrão na base com janelamento de 1s foi de 1.6% e na base com janelamento de 3s foi de 3.5%. O aumento na dispersão indica que houve uma maior aleatoriedade na classificação. Devido ao p-valor calculado, no entanto, não se podem tirar outras conclusões com relação ao impacto do janelamento sobre a classificação do *dataset*. A Figura 34 mostra a sobreposição dos desvios.

Figura 35 – Acurácia entre janelamento de 1s e 3s para método de Análise Individual.



Fonte: O Autor

Tabela 7 – Comparação estatística entre as acurácias obtidas pelo método de validação individual com 250 e 750 amostras para cada indivíduo.

<i>p-Valor</i>		<i>Com Baseline</i>		
I1	I4	I5	I6	\bar{x}
0.0252	0.0031	0.2099	0.0688	0.0768
<i>p-Valor</i>		<i>Sem Baseline</i>		
I1	I4	I5	I6	\bar{x}
0.1917	0.3900	0.4452	0.2860	0.3282

4.3 HOLDOUT

Para os resultados de *Holdout* retirou-se 1/3 dos dados de todos os indivíduos, utilizados apenas para validação, e treinou-se a rede com os 2/3 restantes. Realizou-se cinco repetições de treinamento e validação, e os resultados para a janela de 1s e 3s, juntamente com as médias, são apresentados na Tabela 8.

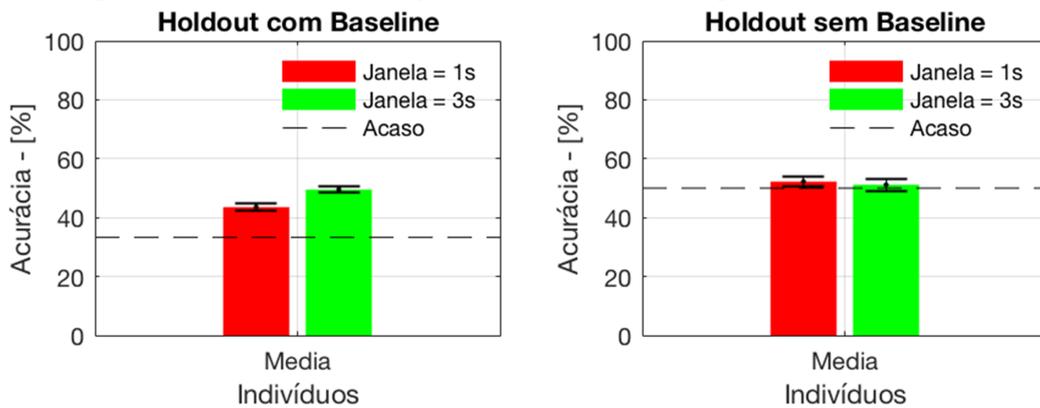
O p-valor do teste de t de student aplicado às acurácias dos ensaios com *baseline* mostra uma maior probabilidade de rejeição da condição nula, com p-valor = 0.0003. Porém sem o *baseline* o p-valor salta para 0.2033, impedindo a inferência de que os conjuntos de dados são dissociados estatisticamente (Figura 36). Deste modo, nenhuma conclusão pode ser tirada do efeito do janelamento par o *dataset* sem o *baseline*.

Para os testes com *baseline*, nota-se novamente uma diferença para melhor nos resultados com janela maior: um aumento relativo de 13.8%. A dispersão para este método não aumentou de maneira considerável quando o *dataset* processou-se com a janela de 3s.

Tabela 8 – Acurácia resultante após treinamento da RN com todos os indivíduo, com *holdout* de 1/3 e com janelamento de 1s e 3s.

Janela 1s						Janela 3s					
ACC% – Com <i>Baseline</i>											
1	2	3	4	5	\bar{x}	1	2	3	4	5	\bar{x}
43.0	44.7	41.8	43.8	44.5	43.5±1.2	48.9	48.6	49.3	49.3	51.4	49.5±1.1
ACC% – Sem <i>Baseline</i>											
1	2	3	4	5	\bar{x}	1	2	3	4	5	\bar{x}
53.9	51.3	52.8	53.6	49.6	52.2±1.8	53.7	51.6	51.6	48.0	50.8	51.1±2.1

Figura 36 – Acurácia entre janelamento de 1s e 3s para método de Holdout.



Fonte: O Autor

4.4 VALIDAÇÃO ENSAIOS MOTORES

Finalmente realizou-se o teste comparativo entre os sinais gerados pelo cérebro durante o MI e durante a execução do mesmo movimento. Todos os arquivos com movimentação foram processados da mesma maneira que os arquivos de MI. Para realizar a validação, todas as amostras processadas do ensaio motor foram utilizadas (2 sessões, por pessoa, de 10 estímulos para cada lado, para os 4 indivíduos gera, aproximadamente, 160 trechos de 3s e 480 de 1s mais os intervalos de *baseline*) e para treinamento, foram utilizadas todos as amostras de MI de todos os indivíduos. Os resultados da acurácia são mostrados na Tabela 9.

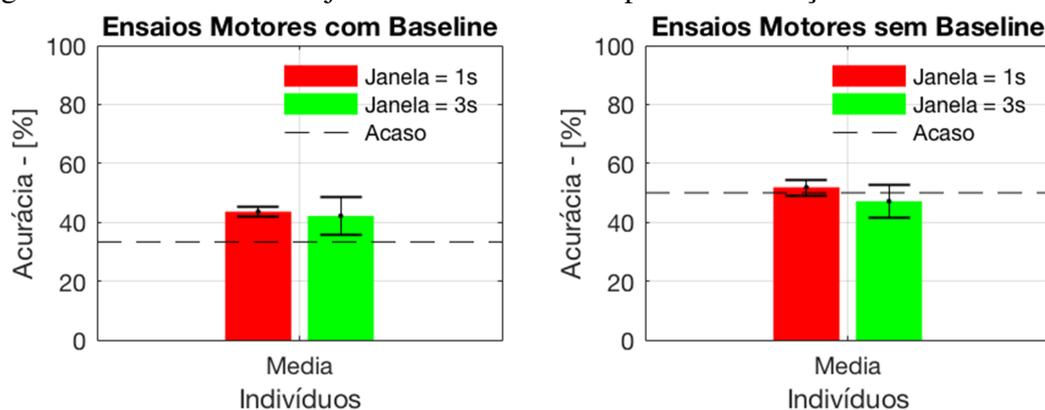
Por se tratarem de bio-sinais de naturezas distintas, esperava-se uma baixa acurácia na classificação. Porém, como os resultados mostram, o modelo matemático foi capaz de prever, com o *baseline*, 43.6% e 42.2% corretamente, acima da taxa do acaso em todas as iterações (Figura 37). Porém, neste caso, o janelamento não causou uma diferenciação estatística. O valor-p calculado foi de 0,3271.

Tabela 9 – Acurácia resultante após treinamento da RN com todos os indivíduo, utilizando os arquivos motores para treinamento, com janelamento de 1s e 3s.

Janela 1s						Janela 3s					
ACC% – Com <i>Baseline</i>											
1	2	3	4	5	\bar{x}	1	2	3	4	5	\bar{x}
43.5	45.1	44.5	41.0	44.0	43.6±1.6	35.6	40.7	51.5	45.4	37.6	42.2±6.4
ACC% – Sem <i>Baseline</i>											
1	2	3	4	5	\bar{x}	1	2	3	4	5	\bar{x}
54.4	50.2	53.1	53.5	47.9	51.8±2.7	51.2	45.6	39.4	45.6	53.7	47.1±5.6

Da mesma maneira, no cenário sem o *baseline* não há influência no resultado advinda do janelamento, sendo 0,1080 o p-valor calculado pela diferença estatística dos dois conjuntos de resultados.

Figura 37 – Acurácia entre janelamento de 1s e 3s para classificação dos Ensaio Motores.



Fonte: O Autor

Não houve uma melhoria aparente na classificação dos dois sinais com a mudança de 1s para 3s de intervalo, mas pode-se notar uma maior dispersão tanto na circunstância de ter-se o *baseline* ou não.

4.5 DISCUSSÃO DOS RESULTADOS

Como já havia sido evidenciado por [Lu et al. \(2017\)](#), ao se tentar a transferência de padrões de bio-sinais de indivíduo para indivíduo acaba-se perdendo acurácia na classificação. Se comparadas as médias para os dois métodos de avaliação (validação cruzada e testes individuais), em todos os casos as médias da acurácia da avaliação individual são maiores, conforme a Tabela [10](#).

Outra tendência geral é que o sistema expande a sua capacidade de diferenciar o que é *baseline* e o que são os movimentos de mão quando há uma janela de amostras maior. Em todos

os métodos de classificação que utilizaram apenas MI, a janela de 3s levou a um aumento na acurácia (aumento relativo para a validação cruzada, +2.3%, para a avaliação individual, +9.3% e para o *holdout*, +13.8%). Em contraste, quando não há *baseline*, os resultados não apresentam diferença estatisticamente significativa. Portanto, o modelo proposto, com janela maior, classifica com mais acuracidade o MI se nele há *baseline*. Caso contrário, não há significância estatística para afirmá-lo.

Tabela 10 – Comparação das médias de acurácia para os métodos de validação cruzada e avaliação individual.

Método	4-Fold Cross-Validation			
	Com Baseline		Sem Baseline	
Dataset	250	750	250	750
ACC%	43.467	44.488	50.890	50.008
Método	Avaliação Individual			
	Com Baseline		Sem Baseline	
Dataset	250	750	250	750
ACC%	43.568	47.614	52.184	52.027

Com base nas principais pesquisas apresentadas na Seção 2.8, a Tabela 11 compara os resultados obtidos neste trabalho com o Estado da Arte. Todos os resultados das outras pesquisas utilizaram o método de *k-Fold Cross-Validation*. Comparam-se com o método *Leave-One-Subject-Out Cross-Validation* utilizado neste trabalho.

Tabela 11 – Comparação dos resultados finais por LOSOCV com o *k-Fold Cross-Validation* utilizado no estado-da-arte.

Comparação de resultados					
Autores	Hsu (2012)	Lee e Choi (2018)	Eltvik (2018)	250 amostras	750 amostras
	ACC%	83,100	78,930	55,930	50,890

As demais pesquisas citadas na Seção 2.8 também comparam-se a seguir:

- Tabar e Halici (2016) obtiveram uma acurácia de 74.8% utilizando apenas CNN e WANG et al. (2018) 86.7% utilizando a CNN com ReLU. Eltvik (2018) também testa os resultados com pré-processamento por STFT e consegue a sua melhor acurácia de 58.0%.
- Batres-Mendoza et al. (2017), com uma janela de 256 amostras atingiram 80.2% de acurácia. Em comparação, no presente trabalho a melhor média de acurácia conseguida foi de 49.5% utilizando o *holdout* e o janelamento de 1s (250 amostras).
- Pelo método de análise de *k-Fold Cross-Validation*, Lindig-Leon et al. (2017) obtiveram uma média de 31.6% de acurácia na classificação dos oito movimentos.

Comparando os resultados obtidos com outras pesquisas com métodos similares pode-se ver que, embora tenha-se tido resultados de acurácia inferiores, quase equipararam-se às acurácias obtidas por [Eltvik \(2018\)](#). As hipótese que podem ser levantadas para que não se tenha chegado a resultados similares:

Base: Captou-se sinal apenas de 4 indivíduos e apenas entre 80 e 120 amostras para cada. Pode ser que o tamanho da base de dados também tenha impactado na qualidade dos resultados.

Captura: Embora todas as precauções tenham sido tomados durante as gravações, os ambientes escolhidos para realizar os ensaios não eram dedicados à captação de sinais cerebrais. Assim sendo, não se tinha total controle sobre ruídos externos, temperatura de ambiente e iluminação. O equipamento de captura utilizado também não era profissional e nenhum dos participantes possuía treinamento ou experiência com MI (o treinamento, segundo [Mahmoudi e Erfanian \(2006\)](#), tem influência sobre um bom sinal de MI).

Movimento: Na maioria dos artigos utiliza-se o "movimento de mão" para coleta do MI. Nem sempre é especificado como é exatamente este movimento. Neste trabalho utilizou-se a flexão de punho, porém pode ser que este sinal não seja característico o suficiente como para ser classificado.

5 CONCLUSÃO

A proposta deste trabalho foi implementar um sistema de condicionamento e reconhecimento de sinais, gerados por comandos cerebrais utilizando a técnica de Motor Imagery (MI) com EEG. Os resultados permitiram avaliar diferentes possibilidades de reconhecimento destes sinais evocados por MI e comparar técnicas de processamento com redes neurais identificando as que apresentaram melhor performance para o sistema proposto.

A metodologia utilizada para este processamento foi a classificação dos bio-sinais coletados, após o treinamento por uma Rede Neural Convolutiva. Foram extraídos sinais dos pontos F3, F4, C3, C4, P3 e P4 de quatro indivíduos destros saudáveis durante diferentes sessões de coleta. Os intervalos temporais dos sinais de interesse foram processados através da Transformada de Wavelet Contínua, utilizando a wavelet de Morlet. Um filtro em frequência passa-banda de 4 a 35Hz foi aplicado para isolar as frequências de interesse do sinal de MI processado.

Nesta proposta, além de preparar um modelo experimental para aquisição de bio-sinais evocados por MI referentes a movimentos de membros superiores, foi possível validar o uso da plataforma OpenBCI e também planejar seu uso em experimentos futuros, incluindo a aquisição de bio-sinais para comandos em aplicações motoras diversas.

Mediante as possíveis metodologias de análise dos sinais, pôde-se concluir sobre o modelo de classificação projetado, que o seccionamento do sinal em janelas de 750 amostras ao invés de 250 permite uma maior diferenciação entre sinais de movimento e sinais de repouso, sugerindo que a escolha do maior janelamento dos sinais é benéfico apenas para classificar dados que incluam o *baseline*, que foi o tempo de aquisição sem evocação de sinais estimulados.

Para a classificação do conjunto de dados que contém apenas sinais de MI para mão direita e mão esquerda, o janelamento não causou resultado estatisticamente significativo para definir se este procedimento auxilia ou não na identificação dos sinais.

Também foi possível atingir um nível de acuracidade equiparável entre as respostas classificatórias sobre os dados resultantes de movimentos de membros superiores reais e os simulados apenas pelo pensamento (MI), quando classificados pela rede treinada com os ensaios de MI. Portanto pode-se inferir que ambos os sinais guardam certa similaridade.

Também confirmou-se que a identificação de padrões entre indivíduos gera resultados de menor acuracidade do que a transferência entre sessões do mesmo indivíduo.

Por fim, demonstrou-se que sinais evocados por Motor Imagery, apesar de ser não probabilístico, é um bio-sinal passível para classificação, que guarda muitos benefícios para aplicação em sistemas de apoio, como órteses para PNEs.

Com base nos resultados obtidos e nas hipóteses levantadas no Capítulo anterior, pode-se propor para futuros trabalhos as seguintes investigações:

- 1 - O estudo sobre a qualidade da captação, procurando repetir a classificação com o modelo proposto através de dados captados em ambientes e com equipamentos especializados.

- 2 - A verificação do efeito do tipo de movimento sobre o MI, buscando se há melhorias na classificação quando se utilizam diferentes tipos de movimento.
- 3 - Aumentar a base de dados, com mais indivíduos e mais amostras por pessoa para estudar os efeitos disso nos resultados.
- 4 - Experimentar outras características sobre a mesma base de dados para verificar se há melhorias na acurácia. [Hung et al. \(2005\)](#), por exemplo, conseguiram uma melhoria de 54% e 57% para 75,5% e 76,5% na acurácia, respectivamente, utilizando Redes Neurais, apenas utilizando diferentes características de entrada.
- 5 - Estudar as possibilidades de aplicar os resultados obtidos em sistemas de acionamento de motores para órteses de membros superiores e/ou outras aplicações de TA.

REFERÊNCIAS

- BALDWIN, C. L.; PENARANDA, B. Adaptive training using an artificial neural network and eeg metrics for within- and cross-task workload classification. **NeuroImage**, Fairfax, Estados Unidos, v. 59, n. 1, p. 48–56, jan. 2012.
- BATRES-MENDOZA, P. et al. Improving EEG-based motor imagery classification for real-time applications using the QSA method. **Computational Intelligence and Neuroscience**, Guanajuato, México, v. 2017, n. 9817305, p. 1–16, dez. 2017.
- BRONIEC, A. Analysis of EEG signal by flicker-noise spectroscopy: identification of right-/left-hand movement imagination. **Medical & Biological Engineering & Computing**, Cracóvia, Polônia, v. 54, n. 12, p. 1935–1947, dez. 2016.
- BUTTERWORTH, S. On the theory of filter amplifiers. **Experimental Wireless & the Wireless Engineer**, Londres, Reino Unido, v. 7, p. 536–541, out. 1930.
- BUZSÁKI, G.; ANASTASSIOU, C. A.; KOCH, C. The origin of extracellular fields and currents - eeg, ecog, lfp and spikes. **Nature Reviews Neuroscience**, New Jersey, Estados Unidos, v. 13, n. 6, p. 407–420, mai. 2012.
- CECOTTI, H. A time–frequency convolutional neural network for the offline classification of steady-state visual evoked potential responses. **Pattern Recognition Letters**, Bremen, Alemanha, v. 32, n. 8, p. 1145–1153, jun. 2011.
- CÉLIA RUFFINO, C. P.; LEBON, F. Neural plasticity during motor learning with motor imagery practice: review and perspectives. **Neuroscience**, Dijon, França, v. 341, p. 61–78, nov. 2016.
- CHERBUIN, N.; BRINKMAN, C. Hemispheric interactions are different in left-handed individuals. **Neuropsychology**, Canberra, Austrália, v. 20, n. 6, p. 700–707, 2006.
- CHERON, G. et al. Brain oscillations in sport: toward eeg biomarkers of performance. **Frontiers in Psychology**, Bruxelas, Bélgica, v. 7, n. 246, p. 1–25, feb. 2016.
- COLLET, C. et al. Measuring motor imagery using psychometric, behavioral, and psychophysiological tools. **Exercise and Sport Sciences Reviews**, Villeurbanne, França, v. 39, n. 2, p. 85–92, abr. 2011.
- CREASE, R. P. Images of conflict: MEG vs. EEG. **Science**, Washington, DC, Estados Unidos, v. 253, p. 374–375, jul. 1991.
- DONOVAN, R.; YU, X.-H. Motor imagery classification using tsf fuzzy inference neural networks. **International Joint Conference on Neural Networks (IJCNN)**, Rio de Janeiro, Brasil, p. 1–6, out. 2018.
- ELTVIK, A. **Deep learning for the classification of EEG time-frequency representation**. Dissertação (Mestrado em Ciências em Cibernética e Robótica) – Norwegian University of Science and Technology, Trondheim, Noruega, 2018.

- EMOTIV. **Emotiv EPOC+**., Disponível em: <https://bit.ly/2dHmvsw> Acesso em: 16 mai. 2018.
- HAYKIN, S. **Neural networks and learning machines**. 3. ed. New Jersey, Estados Unidos: Pearson Education, 2009. 906 p.
- HERCULANO-HOUZEL, S. The remarkable, yet not extraordinary, human brain as a scaled-up primate brain and its associated cost. **Proceedings of the National Academy of Sciences**, California, Estados Unidos, v. 109, n. Suppl. 1, p. 10661–10668, jun. 2012.
- HERMAN, P. et al. Comparative analysis of spectral approaches to feature extraction for eeg-based motor imagery classification. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, Derry, Irlanda do Norte, v. 16, n. 4, p. 317–326, jun. 2008.
- HETTIARACHCHI, I. T. et al. A fresh look at functional link neural network for motor imagery-based brain–computer interface. **Journal of Neuroscience Methods**, Geelong, Austrália, v. 305, p. 28–35, jul. 2018.
- HÉTU, S. et al. The neural network of motor imagery: an ale meta-analysis. **Neuroscience and Biobehavioral Reviews**, Virgínia, Estados Unidos, v. 37, n. 5, p. 930–949, jun. 2013.
- HOOI, L. S. et al. A novel method for tracking and analysis of eeg activation across brain lobes. **Biomedical Signal Processing and Control**, Perak, Malásia, v. 40, p. 488–504, fev. 2018.
- HORKI, P. et al. Combined motor imagery and ssvp based bci control of a 2 dof artificial upper limb. **Medical and Biological Engineering**, Graz, Áustria, v. 49, p. 567–577, mar. 2011.
- HOWARD, R. S. Poliomyelitis and the postpolio syndrome. **British Medical Journal**, London, Reino Unido, v. 330, p. 1314–1318, jun. 2005.
- HSU, W.-Y. Fuzzy hopfield neural network clustering for single-trial motor imagery EEG classification. **Expert Systems with Applications**, Taipei, Taiwan, v. 39, n. 1, p. 1055–1061, jan. 2012.
- HUNG, C.-I. et al. Recognition of motor imagery electroencephalography using independent component analysis and machine classifiers. **Annals of Biomedical Engineering**, Taipei, Taiwan, v. 33, n. 8, p. 1053–1070, ago. 2005.
- INSTRUMENTS, T. **Ads1299-x low-noise, 4-, 6-, 8-channel, 24-bit, analog-to-digital converter for eeg and biopotential measurements.**, Disponível em: <https://bit.ly/1ShsVNV>. Acesso em: 30 mai. 2018.
- J. PERNIER, F. P.; BERTRAND, O. Scalp current density fields: concept and properties. **Electroencephalography and clinical Neurophysiology**, Lyon, França, v. 69, n. 4, p. 385–389, abr. 1988.
- JEANNEROD, M. Mental imagery in the motor context. **Neuropsychologia**, Bron, França, v. 33, n. 11, p. 1419–1432, abr. 1995.
- JURCAK, V.; TSUZUKI, D.; DAN, I. 10/20, 10/10, and 10/5 systems revisited: their validity as relative head-surface-based positioning systems. **NeuroImage**, Tsukuba, Japão, v. 34, n. 4, p. 1600–1611, fev. 2007.

- KANIUSAS, E. **Biomedical signals and sensors I: linking physiological phenomena and biosignal**. XVIII. ed. Berlin, Alemanha: Springer-Verlag, 2012. 298 p.
- KILICARSLAN, A. et al. High accuracy decoding of user intentions using EEG to control a lower-body exoskeleton. **35th Annual International Conference of the IEEE EMBS**, Osaka, Japão, p. 5606–5609, jul. 2013.
- KRUCOFF, M. O. et al. Enhancing nervous system recovery through neurobiologics, neural interface training, and neurorehabilitation. **Frontiers in Neuroscience**, Miami, Estados Unidos, v. 10, n. 584, p. 1–23, dez. 2016.
- LALITHARATNE, T. D. et al. Evaluation of perception-assist with an upper-limb power-assist exoskeleton using EMG and EEG signals. **11th IEEE International Conference on Networking, Sensing and Control**, Miami, Estados Unidos, p. 524–529, abr. 2014.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, Red Bank, Estados Unidos, v. 86, n. 11, p. 2278–2324, nov. 1998.
- LEE, H. K.; CHOI, Y.-S. A convolution neural networks scheme for classification of motor imagery EEG based on wavelet time-frequency image. **International Conference on Information Networking (ICOIN)**, Chiang Mai, Tailândia, p. 906–909, abr. 2018.
- LI, M. et al. Recognition method of limb motor imagery EEG signals based on integrated back-propagation neural network. **The Open Biomedical Engineering Journal**, Changchun, China, v. 9, p. 83–91, mar. 2015.
- LI, Z. et al. Adaptive impedance control for an upper limb robotic exoskeleton using biological signals. **IEEE Transactions on Industrial Electronics**, Guangzhou, China, v. 64, n. 2, p. 1664–1674, fev. 2017.
- LIANG, H. et al. Investigation of the EEG scalp distribution for estimation of shoulder joint torque in the upper-limb power assistant system. **IEEE International Conference on Robotics and Biomimetics**, Quindao, China, p. 1912–1917, dez. 2016.
- LINDIG-LEON, C. et al. Scalp EEG activity during simple and combined motor imageries to control a robotic arm. **IEEE Ukraine Conference on Electrical and Computer Engineering**, Kiev, Ucrânia, v. 1, p. 322–327, nov. 2017.
- LOTZE, M.; HALSBAND, U. Motor imagery. **Journal of Physiology Paris**, Tübingen, Alemanha, v. 86, n. 4-6, p. 386–395, mai. 2006.
- LU, N. et al. A deep learning scheme for motor imagery classification based on restricted boltzmann machines. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, Shaanxi, China, v. 25, n. 6, p. 566–576, jun. 2017.
- LUCK, S. J. **An introduction to the event-related potential technique**. 2. ed. Massachusetts, Estados Unidos: MIT Press, 2014. 416 p.
- MAHMOUDI, B.; ERFANIAN, A. Electro-encephalogram based brain-computer interface: improved performance by mental practice and concentration skills. **Medical & Biological Engineering & Computing**, Tehran, Irã, v. 44, p. 959–969, out. 2006.
- MALLAT, S. **A wavelet tour of signal processing**. 3. ed. Massachusetts, Estados Unidos: Elsevier, 2009.

MATHWORKS. **butter.**, Disponível em: <https://la.mathworks.com/help/signal/ref/butter.html>
Acesso em: 5 nov. 2018.

MING-AI, L. et al. Feature extraction and classification of mental EEG for motor imagery. **International Conference on Natural Computation**, Tianjin, China, v. 5, p. 139–143, dez. 2009.

MOHAMED, E. A. et al. Comparasion of eeg signal decomposition methods in classification of motor-imagery bci. **Multimedia Tools and Applications**, Seri Iskandar, Malásia, v. 77, n. 294, p. 1–23, jan. 2018.

MUNZERTA, J.; LOREYA, B.; ZENTGRAFA, K. Cognitive motor processes: the role of motor imagery in the study of motor representations. **Brain Research Reviews**, Gießen, Alemanha, v. 60, n. 2, p. 306–326, jan. 2009.

MUTHONG, S.; VATEEKUL, P.; SRIYUDTHSAK, M. An adjustment strategy on multi-session EEG data for online left/right hand imagery classification. **International Conference on Knowledge and Smart Technology (KST)**, Chiangmai, Tailândia, v. 8, p. 179–183, mar. 2016.

NALON, J. A. **Introdução ao processamento digital de sinais**. Rio de Janeiro, Brasil: Grupo Editorial Nacional, 2009.

NIELSEN, M. A. **Neural networks and deep learning.**, Disponível em: <http://neuralnetworksanddeeplearning.com/chap6.html>. Acesso em: 30 mai. 2018.

OFORI, E.; COOMBES, S. A.; VAILLANCOURT, D. E. 3d cortical electrophysiology of ballistic upper limb movement in humans. **NeuroImage**, Gainesville, Estados Unidos, v. 115, p. 30–41, abr. 2015.

OPENBCI. **Cyton getting started guide.**, Disponível em: <https://bit.ly/2Ah6svL> Acesso em: 10 set. 2018.

OPENBCI. **3rd party software: OpenViBE.**, Disponível em: <https://bit.ly/2JGii5S> Acesso em: 13 set. 2018.

OPENVIBE. **OpenViBE: software for brain-computer interface and real time neurosciences.**, Disponível em: <http://openvibe.inria.fr/> Acesso em: 18 out. 2018.

PASCUAL-LEONE, A. et al. Modulation of muscle responses evoked by transcranial magnetic stimulation during the acquisition of new fine motor skills. **Journal of Neurophysiology**, Marilândia, Estados Unidos, v. 74, n. 3, p. 1037–1045, set. 1995.

PERNIER, J. et al. Spherical splines for scalp potential and current density mapping. **Electroencephalography and clinical Neurophysiology**, Lyon, França, v. 72, n. 2, p. 184–187, fev. 1989.

PT-HELPER. **Wrist & Elbow.**, Disponível em: <http://www.pt-helper.com/wrist--elbow.html>
Acesso em: 5 nov. 2018.

PURVES, D. et al. **Neuroscience**. 3. ed. Massachusetts, Estados Unidos: Sinauer Associates, 2004. 773 p.

RASHID, M. M. O.; AHMAD, M. Multiclass motor imagery classification for bci application. **International Workshop on Computational Intelligence (IWCI)**, Dhaka, Bangladesh, p. 35–40, fev. 2017.

Report of the committee on methods of clinical examination in electroencephalography. [S.l.]: Elsevier, 1958. Technical Report.

SAA, J. F. D.; ÇETIN, M. A latent discriminative model-based approach for classification of imaginary motor tasks from eeg data. **Journal of Neural Engineering**, Istanbul, Turquia, v. 9, p. 1–9, mar. 2012.

SABBAH, P. et al. Sensorimotor cortical activity in patients with complete spinal cord injury: a functional magnetic resonance imaging study. **Journal of Neurotrauma**, Marseille, França, v. 19, n. 1, p. 53–60, jan. 2002.

SCHLÖGL, A. et al. Characterization of four-class motor imagery EEG data for the BCI-competition 2005. **Journal of Neural Engineering**, Graz, Áustria, v. 2, n. 4, p. L14–L22, ago. 2005.

SCHOMER, D. L.; SILVA, F. H. L. da. **Niedermeyer's electroencephalography: basic principles, clinical applications, and related fields.** 6. ed. Filadélfia, Estados Unidos: Lippincott Williams & Wilkins, 2011. 1241 p.

TABAR, Y. R.; HALICI, U. A novel deep learning approach for classification of eeg motor imagery signals. **Journal of Neural Engineering**, Ankara, Turquia, v. 14, n. 1, p. 1–11, nov. 2016.

TANGA, Z.; LIB, C.; SUNB, S. Single-trial eeg classification of motor imagery using deep convolutional neural networks. **Optik**, Hangzhou, China, v. 130, p. 11–18, fev. 2017.

VIDAL, J. J. Toward direct brain-computer communication. **Annual Review of Biophysics and Bioengineering**, Los Angeles, Estados Unidos, v. 2, p. 157–180, fev. 1973.

VIDAL, J. J. Real-time detection of brain events in eeg. **Proceedings of the IEEE**, Los Angeles, Estados Unidos, v. 65, n. 5, p. 633–641, mai. 1977.

WANG, Z. et al. Short time fourier transformation and deep neural networks for motor imagery brain computer interface recognition. **Concurrency and Computation Practice and Experience**, Xangai, China, v. e5032, p. 1–9, jan. 2018.

World report on disability. Geneva, Suíça: World Health Organization, 2011. Technical Report.

WU, J. et al. Spinal cord injury causes brain inflammation associated with cognitive and affective changes: role of cell cycle pathways. **The Journal of Neuroscience**, Baltimore, Estados Unidos, v. 34, p. 10989 – 11006, ago. 2014.

XIAO, D.; HU, J. Classification of motor imagery EEG based on a time-frequency analysis and second-order blind identification. **International Conference on Bioinformatics and Biomedical Engineering**, Shanghai, China, v. 2, p. 2199–2201, mai. 2008.

XU, B. et al. Robot-aided upper-limb rehabilitation based on motor imagery eeg. **International Journal of Advanced Robotics and Automation**, Jiangu, China, v. 8, n. 4, p. 88–97, set. 2011.

YU, G. et al. Eeg-based brain-controlled lower extremity exoskeleton rehabilitation robot.
IEEE 8th International Conference on CIS & RAM, Ningbo, China, p. 763–767, nov. 2017.

APÊNDICE A – CÓDIGOS

Todas as funções e códigos completos estarão disponíveis até o dia 01/jan/2019 pelo link [\[1\]](#). Os códigos estão disponíveis para uso acadêmico sem fins lucrativos mediante permissão e citação do autor.

Os programas executados para geração dos resultados foram os `main_*.m`. Cada um deles corresponde a um método de avaliação. Os parâmetros de treinamento são alterados de acordo com o método para formação da base de dados.

- Algoritmo para separação dos Dados:

```

%% FILE2DATASET.m
% ----- FLAGS de TRIGGERS -----
% OVTK_StimulationId_BaselineStart      = 0x8007 = 32775 <<<
% OVTK_StimulationId_BaselineStop      = 0x8008 = 32776 <<<
% OVTK_GDF_Left                        = 0x0301 = 769 <<<
% OVTK_GDF_Right                       = 0x0302 = 770 <<<
% OVTK_GDF_Feedback_Continuous         = 0x030D = 781 <<<
%% VERDADE
% 0 - Baseline
% 1 - Braco Direito
% 2 - Braco Esquerdo
%% INICIALIZACAO
train_vox = [];
train_truevox = [];
train_lbl = [];
val_vox = [];
val_truevox = [];
val_lbl = [];
logicPrint = {'false', 'true'};
%% TRATAMENTO DE ARQUIVOS
files = dir('coletas/*.csv');
for k = 1:2:size(files,1)
    clear chann chann2 r_idx l_idx bli_idx ble_idx d e;
    fprintf('---Arquivo_%s:\n', files(k).name);
    %% Selecciona Arquivos
    indiv = files(k).name(2);
    if ~use_indiv(str2num(indiv))
        fprintf('Pulando_individuo_%2.d\n---\n', str2num(indiv));
        continue
    end
    if opt_tr ~= 3 && strcmp(files(k).name(4), 'M')
        fprintf('Pulando_ensaio_'M'_de_individuo_%2.d\n---\n', str2num(indiv));
        continue
    end
    a = readtable(files(k).name, 'Delimiter', ',');
    %% Info Canais
    chann = table2array(a(:,1:13)); %c = cellfun(@str2num, chann);
    %% Aplica Filtro
    chann2 = Filters(chann);
    %% Tratamento de Triggers
    [e, d] = separaTrigger(a);
    %% Encontra Seccoes de MI
    r_idx = find(d(:) == 770);
    l_idx = find(d(:) == 769);
    bli_idx = find(d(:) == 32775);
    ble_idx = find(d(:) == 32776);
    %% Separa Baseline
    if baseline
        answ = 0;
        [lin_w] = sepWav(chann2, e, [bli_idx, ble_idx], tamanhoJanela, ...
            canais, fin, fou, false, false, answ);
        tr_w = ones(1, size(lin_w,4)) * answ;
        id_w = ones(1, size(lin_w,4)) * str2num(indiv);
        [lin, trw, id] = wavlet_split(lin_w, tr_w, id_w, tamanhoCorte);
        [lin] = redInterpCub(lin, red_size);
        switch opt_tr
            case 1
                %training
                tr_idx = randperm(size(lin,4), round(tr_per * size(lin,4)));

```

¹<https://github.com/mgmussi/TCCII-CodsAndFiles>

```

train_vox = cat(4, train_vox, lin(:, :, :, tr_idx));
train_truevox = [train_truevox; trw(tr_idx)'];
train_lbl = [train_lbl; id(tr_idx)'];
%validation
val_idx = setdiff(1:size(lin,4), tr_idx);
val_vox = cat(4, val_vox, lin(:, :, :, val_idx));
val_truevox =[val_truevox; trw(val_idx)'];
val_lbl = [val_lbl; id(val_idx)'];
case 2
if tr_indiv(str2num(indiv))
train_vox = cat(4, train_vox, lin);
train_truevox = [train_truevox; trw'];
train_lbl = [train_lbl; id'];
else
val_vox = cat(4, val_vox, lin);
val_truevox =[val_truevox; trw'];
val_lbl = [val_lbl; id'];
end
case 3
if strcmp(files(k).name(4), 'M')
val_vox = cat(4, val_vox, lin);
val_truevox =[val_truevox; trw'];
val_lbl = [val_lbl; id'];
else
train_vox = cat(4, train_vox, lin);
train_truevox = [train_truevox; trw'];
train_lbl = [train_lbl; id'];
end
end
end
%% Separa Mao Dir
answ = 1;
[lin_w] = sepWav(chann2, e, r_idx, tamanhoJanela, ...
               canais, fin, fou, false, false, answ);
trw_w = ones(1, size(lin_w,4)) * answ;
id_w = ones(1, size(lin_w,4)) * str2num(indiv);
[lin, trw, id] = wavlet_split(lin_w, trw_w, id_w, tamanhoCorte);
[lin] = redInterpCub(lin, red_size);
switch opt_tr
case 1
%training
tr_idx = randperm(size(lin,4), round(tr_per * size(lin,4)));
train_vox = cat(4, train_vox, lin(:, :, :, tr_idx));
train_truevox = [train_truevox; trw(tr_idx)'];
train_lbl = [train_lbl; id(tr_idx)'];
%validation
val_idx = setdiff(1:size(lin,4), tr_idx);
val_vox = cat(4, val_vox, lin(:, :, :, val_idx));
val_truevox =[val_truevox; trw(val_idx)'];
val_lbl = [val_lbl; id(val_idx)'];
case 2
if tr_indiv(str2num(indiv))
train_vox = cat(4, train_vox, lin);
train_truevox = [train_truevox; trw'];
train_lbl = [train_lbl; id'];
else
val_vox = cat(4, val_vox, lin);
val_truevox =[val_truevox; trw'];
val_lbl = [val_lbl; id'];
end
case 3
if strcmp(files(k).name(4), 'M')
val_vox = cat(4, val_vox, lin);
val_truevox =[val_truevox; trw'];
val_lbl = [val_lbl; id'];
else
train_vox = cat(4, train_vox, lin);
train_truevox = [train_truevox; trw'];
train_lbl = [train_lbl; id'];
end
end
end
%% Separa Mao Esq
answ = 2;
[lin_w] = sepWav(chann2, e, l_idx, tamanhoJanela, ...
               canais, fin, fou, false, false, answ);
trw_w = ones(1, size(lin_w,4)) * answ;
id_w = ones(1, size(lin_w,4)) * str2num(indiv);
[lin, trw, id] = wavlet_split(lin_w, trw_w, id_w, tamanhoCorte);
[lin] = redInterpCub(lin, red_size);
switch opt_tr
case 1

```

```

%training
tr_idx = randperm(size(lin,4), round(tr_per * size(lin,4)));
train_vox = cat(4, train_vox, lin(:, :, :, tr_idx));
train_truevox = [train_truevox; trw(tr_idx)'];
train_lbl = [train_lbl; id(tr_idx)'];
%validation
val_idx = setdiff(1:size(lin,4), tr_idx);
val_vox = cat(4, val_vox, lin(:, :, :, val_idx));
val_truevox = [val_truevox; trw(val_idx)'];
val_lbl = [val_lbl; id(val_idx)'];
case 2
if tr_indiv(str2num(indiv))
train_vox = cat(4, train_vox, lin);
train_truevox = [train_truevox; trw'];
train_lbl = [train_lbl; id'];
else
val_vox = cat(4, val_vox, lin);
val_truevox = [val_truevox; trw'];
val_lbl = [val_lbl; id'];
end
case 3
if stremp(files(k).name(4), 'M')
val_vox = cat(4, val_vox, lin);
val_truevox = [val_truevox; trw'];
val_lbl = [val_lbl; id'];
else
train_vox = cat(4, train_vox, lin);
train_truevox = [train_truevox; trw'];
train_lbl = [train_lbl; id'];
end
end
end
fprintf('\n\n... DONE\n\n>>Tamanho_Sets:\n. Treinamento:_(%d, %d)\n. Teste:_(%d, %d)\n', size(train_truevox), size(val_truevox));
%% Normalizar Wavs apos Formar Matrix
allin = cat(4, train_vox, val_vox);
minlin = min(allin(:));
train_vox = train_vox - minlin;
val_vox = val_vox - minlin;
allin = allin - minlin;
maxlin = max(allin(:));
train_vox = train_vox / maxlin;
val_vox = val_vox / maxlin;
%% Salva Arq.
validation = {val_vox, categorical(val_truevox)}; % categorical(val_lbl));
train = {train_vox, categorical(train_truevox)}; % categorical(train_lbl));
save('data.mat', 'train', 'validation');
fprintf('\n.Complete.\n');

```

• Função para realizar transformada de Wavelet:

```

function [linwav] = sepWav(data, time, sidx, tamjan, canais, frq_i, frq_s, shw, freqsum, answ)
linha = 1;
n_ch = sum(canais == 1);
idx_ch = find(canais);
fprintf('Tamanho_dados:_(%d, %d)\n', size(data));
fprintf('Idx_chave:\n');
fprintf('%d, ', sidx);
fprintf('\nTamanho_sidx:_(%d, %d)\n', size(sidx));
fprintf('\n');
step = 1*tamjan; %deslocamento da janela
wav_tot = zeros(22, tamjan, n_ch);
%SET TEMPO FINAL
if answ == 0
ini_idx = find(data(:,1) >= time(sidx(1)), 1);
ini_idx = ini_idx + 500; %Retirar primeiros 2 seg.
end_idx = find(data(:,1) >= time(sidx(1) + sidx(2)), 1);
final = round((data(end_idx,1) - data(ini_idx,1)) * 250);
sidx(2) = [];
else
final = 1000; %4s (corte dos 1s finais)
end
wavelet = [];
wavelet = [];
%PROCESSA AMOSTRAS EM SIDX (TRIGGERS)
for i = 1:length(sidx)
ini_idx = find(data(:,1) >= time(sidx(i)), 1);
ini_idx = ini_idx + 250; %1s (corte dos 1s iniciais)
for addon = tamjan+250:step:final
end_idx = ini_idx + tamjan - 1;
% fprintf('Processando de %d a %d - step: %d\n', ini_idx, end_idx, addon);
srch = data(ini_idx:end_idx, :);

```

```

ini_idx = ini_idx + step;

meanval = mean(srch,1);
cnt = 0;
for k = idx_ch
    cnt = cnt + 1;
    %Retira Media
    srch(:,k+2) = srch(:,k+2) - meanval(k+2);

    [-, frq, hg] = wavplot(srch(:,k+2), 250);
    freq_fin_idx = find(frq <= frq_i, 1)-1;
    freq_ini_idx = find(frq <= frq_s, 1);

    if freqsum
        wav_tot(:, :, cnt) = wav_tot(:, :, cnt) + hg(freq_ini_idx:freq_fin_idx, :);
    end
    wavelet = [wavelet; hg(freq_ini_idx:freq_fin_idx, :)];
    waveleT = [waveleT; hg];
end
%%SAVE IN VOXEL
linwav(:, :, 1, linha) = wavelet;
linha = linha + 1;

if shw
    figure;
    subplot(1,2,1);
    image(wavelet);
    colormap(gray(240));
    title(sprintf('Wavelet_Filtrado_de_%d_a_%dHz', frq_i, frq_s));
    %MOSTRA WAVELET COM TODAS AS FREQS.
    subplot(1,2,2);
    image(waveleT);
    title('Wavelet_sem_Filtro');
    colormap(gray(240));
    suptitle(sprintf('De_%d_a_%d_-%.2fs', ini_idx-step, end_idx, (end_idx-ini_idx-step)/250));
end

wavelet = [];
waveleT = [];

end
end
if shw
    pause;
    close all;
end
%PLOT DA SOMA DE FREQS
if freqsum
    figure;
    mmax = max(wav_tot(:));
    mmin = min(wav_tot(:));
    n = find(canais == 1);
    for i=1:n_ch
        subplot(2,3,i)
        imagesc((wav_tot(:, :, i)-mmin)/(mmax-mmin));
        switch n(i)
            case 1
                title('F4');
            case 2
                title('C4');
            case 3
                title('P4');
            case 4
                title('F3');
            case 5
                title('C3');
            case 6
                title('P3');
        end
    end
    colormap(jet(240));
    pause;
    close all;
end
end
end

```

• Função para aplicação de filtros:

```

function [chFilt2] = Filters(chann)
%% #SEMFILTRO
clear chFilt1 chFilt2
%% FILTRO NOTCH 59-61HZ

```

```

fs = 250;
fc = [59, 61];
[b,a] = butter(2,fc/(fs/2), 'stop');
chFilt2(:,1:2) = chann(:,1:2);
for i=1:6
    chFilt1(:,i) = filter(b,a,chann(:,i+2));
end
clear a b fc;

%% FILTRO BANDPASS 4–40Hz(?)
fc = [4, 40];
[b,a] = butter(2,fc/(fs/2), 'bandpass');
for i=1:6
    chFilt2(:,i+2) = filter(b,a,chFilt1(:,i));
end

```

● Programação da Rede Neural:

```

%% Rede Neural
tam = [size(train{1},1), size(train{1},2)];
saidas = size(countcats(train{2}),1);

layers = [
    imageInputLayer([tam, 1], 'Name', 'Entrada')
    convolution2dLayer([tam(1), 5], 25, 'Name', 'Camada1')
    batchNormalizationLayer
    reluLayer
    maxPooling2dLayer([1,2], 'Stride', 2)

    convolution2dLayer([1, 15], 50, 'Name', 'Camada2')
    batchNormalizationLayer
    reluLayer
    maxPooling2dLayer([1,2], 'Stride', 2)

    convolution2dLayer([1, 2], 100, 'Name', 'Camada3')
    batchNormalizationLayer
    reluLayer

    fullyConnectedLayer(saidas, 'Name', 'Saida')
    softmaxLayer
    classificationLayer];

bach_size = round(0.1* size(train{2},1));

param_train = trainingOptions('sgdm', ...
    'ExecutionEnvironment','cpu', ...
    'MaxEpochs', 100, ...
    'MiniBatchSize', bach_size, ...
    'Plots', 'training-progress', ...
    'ValidationData', validation, ...
    'ValidationFrequency', 10, ...
    'ValidationPatience', 30, ...
    'Shuffle', 'every-epoch', ...
    'Momentum', 0.5, ...
    'InitialLearnRate', 0.02, ...
    'LearnRateSchedule', 'piecewise', ...
    'LearnRateDropPeriod', 7, ...
    'LearnRateDropFactor', 0.5);

net = trainNetwork(train{1},train{2},layers,param_train);

```

ANEXO A – FOLHA DE ROSTO PARA PESQUISA ENVOLVENDO SERES HUMANOS



MINISTÉRIO DA SAÚDE - Conselho Nacional de Saúde - Comissão Nacional de Ética em Pesquisa – CONEP

FOLHA DE ROSTO PARA PESQUISA ENVOLVENDO SERES HUMANOS

1. Projeto de Pesquisa: Órtese robótica de fibra de carbono controlada por sistema de eletroencefalografia			
2. Número de Participantes da Pesquisa: 1			
3. Área Temática: Equipamentos e dispositivos terapêuticos, novos ou não registrados no País;			
4. Área do Conhecimento: Grande Área 3. Engenharias			
PESQUISADOR RESPONSÁVEL			
5. Nome: ALEXANDRE MESQUITA			
6. CPF: 618.918.940-72		7. Endereço (Rua, n.º): CARLOS GIESEN EXPOSICAO 285/805 CAXIAS DO SUL RIO GRANDE DO SUL 95084220	
8. Nacionalidade: BRASILEIRO		9. Telefone: (54) 3039-3096	10. Outro Telefone:
		11. Email: amesquit@ucs.br	
<p>Termo de Compromisso: Declaro que conheço e cumprirei os requisitos da Resolução CNS 466/12 e suas complementares. Comprometo-me a utilizar os materiais e dados coletados exclusivamente para os fins previstos no protocolo e a publicar os resultados sejam eles favoráveis ou não. Aceito as responsabilidades pela condução científica do projeto acima. Tenho ciência que essa folha será anexada ao projeto devidamente assinada por todos os responsáveis e fará parte integrante da documentação do mesmo.</p>			
Data: <u>04</u> / <u>05</u> / <u>2018</u>		 Assinatura	
INSTITUIÇÃO PROPONENTE			
12. Nome: Fundação Universidade de Caxias do Sul - FUCS/RS		13. CNPJ: 88.648.761/0001-03	14. Unidade/Orgão:
15. Telefone: (54) 3218-2100		16. Outro Telefone:	
<p>Termo de Compromisso (do responsável pela instituição): Declaro que conheço e cumprirei os requisitos da Resolução CNS 466/12 e suas Complementares e como esta instituição tem condições para o desenvolvimento deste projeto, autorizo sua execução.</p>			
Responsável: <u>Prof. Juliano Rodrigues Gimenez</u> <u>Diretor da Área do Conhecimento de Ciências Exatas e Engenharias</u> <u>Universidade de Caxias do Sul</u>		CPF: <u>715363700-10</u>	
Cargo/Função: <u>Diretor de Área</u>			
Data: <u>29</u> / <u>05</u> / <u>2018</u>		 Assinatura	
PATROCINADOR PRINCIPAL			

ANEXO B – TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO**UNIVERSIDADE DE CAXIAS DO SUL****TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO**

para participação no experimento do

Projeto de Pesquisa ORTEROBEEG

Nome do estudo:

Órtese robótica de fibra de carbono controlada por sistema de eletroencefalografia

Instituição:

Universidade de Caxias do Sul, Campus da Região dos Vinhedos (CARVI) de Bento Gonçalves/RS

Pesquisadores:

Alexandre Mesquita, Marilda Machado Spindola e Vagner Grison

Responsável pelo projeto na UCS:

Prof. Dr Alexandre Mesquita - Fone: 54-34495200

Pesquisadora responsável pelo experimento:

**Prof. Dra Marilda Spindola
Fone: 54-34495200
Email: mmspindola@ucs.br**

Comitê de Ética via Plataforma Brasil

Nome do aluno: _____ **Nº entrevista:** __|__|__|

Fui convidado a participar desse estudo que está sendo realizado por pesquisadores da Universidade de Caxias do Sul, e que **a pesquisa em questão envolve o desenvolvimento de uma órtese robótica em fibra de carbono, cujo sistema de**

acionamento dos motores, para gerar o movimento de caminhada, se dará pela aquisição e processamento de sinais cerebrais, capturados pela técnica de eletroencefalografia e controle por Lógica Fuzzy e Redes Neurais. Caso eu aceite os termos dispostos a seguir, **participarei como voluntário desta pesquisa intitulada "Órtese robótica de fibra de carbono controlada por sistema de eletroencefalografia".**

Fui devidamente informado sobre as etapas do projeto nas quais participarei como voluntário durante a pesquisa: a) vestimenta da órtese robótica e adaptação ao sistema mecânico; b) coleta dos sinais cerebrais através de Eletroencefalógrafo (equipamento da empresa Emotiv ou da empresa OpenBCI); e, c) comando da órtese robótica após processamento dos sinais cerebrais.

Fui informado que não terei um benefício direto com minha participação no estudo. De forma indireta, estarei participando de um projeto importante para a área que o estudo se dispõe a contribuir, no caso a Tecnologia Assistiva. No futuro, eu e meus semelhantes poderemos acessar os resultados desse estudo por meio de artigo científico que será encaminhado para publicação em revista/periódico de circulação nacional ou internacional, sendo que os devidos direitos de total preservação de minha identidade estarão respeitados.

Fui informado que não há nenhum benefício esperado durante ou imediatamente após a minha participação deste experimento. **Fui apresentado aos equipamentos (eletroencefalógrafo, gel que será colocado para fixação do eletrodo no meu escalpo, e a conexão dos fios ligados ao computador). Fui informado que o experimento terá duração de, aproximadamente 15-20 minutos para cada etapa. E, também, que não será necessário participar de todas as etapas sequencialmente. Fui alertado que poderei sentir desconforto com o uso desse equipamento de EEG que ficará acoplado na minha cabeça ou devido a**

permanência no local onde o experimento acontecerá, mas que não sofrerei qualquer risco a minha saúde física, mental ou moral. Referindo qualquer mal estar serei imediatamente desconectado dos equipamentos, assim como serei retirado do local, recebendo atendimento de forma personalizada de acordo com minhas necessidades.

Os possíveis desconfortos associados a esse estudo estão relacionados a conexão aos eletrodos no escalpo. Garante-se a monitoração de sinais vitais e todo o apoio necessário e deslocamento para posto de saúde, caso seja indicado.

Fui informado que poderei desistir de participar do estudo a qualquer momento.

Este experimento não apresentará um grupo de controle. Eu mesmo serei submetido ao monitoramento com EEG antes de iniciar o experimento, concentrado em minha respiração, o que será tido como meu parâmetro de 'normalidade'. O controle será feito pela aquisição de dados de EEG imediatamente (aproximadamente 60 segundos) antes e imediatamente após a exposição à metodologia de ensino.

Fui informado que qualquer esclarecimento que eu queira, antes e durante o curso do experimento, sobre o método da pesquisa ou qualquer outra dúvida, será oferecido imediatamente pelo pesquisador responsável, que estará presente durante o experimento, e que não haverá a inclusão de qualquer outro procedimento que não aqueles informados neste termo. Obtive a garantia que minhas informações pessoais, bem como dados que possam me identificar, serão mantidos em sigilo absoluto.

Todas as informações obtidas a partir deste estudo ficarão guardadas em sigilo sob responsabilidade do pesquisador e poderão ser publicadas com finalidade científica de forma anônima, ou seja, sem divulgação dos nomes das pessoas envolvidas.

Esse trabalho foi avaliado e aprovado pelo Comitê de Ética da UCS.

Caso o (a) Sr (a) tenha dúvidas adicionais ou deseje maiores esclarecimentos sobre a realização dessa pesquisa, pode entrar em contato com os pesquisadores por meio dos telefones aqui apresentados (ao início desse Termo de Consentimento).

Declaro ter lido e compreendido integralmente as informações acima, antes de assinar este Termo de Consentimento. Foi-me dada ampla oportunidade de fazer perguntas, esclarecendo plenamente minhas dúvidas. Por este Termo de consentimento, concordo em participar do presente estudo.

Assinatura do entrevistado

Assinatura da testemunha

Pesquisador responsável

Para alunos com menos de 18 anos, será necessário a assinatura do responsável

Nome do responsável pelo aluno _____

Assinatura _____

Bento Gonçalves, _____ de _____ de 20____.

OBSERVAÇÃO: Esse termo de consentimento será impresso em duas cópias, sendo uma de propriedade do participante da pesquisa, e outra de propriedade dos pesquisadores responsáveis.